



Министерство науки и высшего образования Российской Федерации
федеральное государственное автономное
образовательное учреждение высшего образования
«Национальный исследовательский Томский политехнический университет» (ТПУ)

Инженерная школа информационных технологий и робототехники
Направление подготовки: 09.04.01 Информатика и вычислительная техника
ООП/ОПОП: Искусственный интеллект и машинное обучение
Отделение школы (НОЦ): Отделение информационных технологий

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА МАГИСТРАНТА

Тема работы
Алгоритм повышения пространственного разрешения изображений на основе генеративно-состязательной сети

УДК 004.032.26:004.932

Обучающийся

Группа	ФИО	Подпись	Дата
8BM13	Монгуш Темир Валерьевич		

Руководитель ВКР

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОИТ ИШИТР	Иванова Ю.А.	К.Т.Н.		

КОНСУЛЬТАНТЫ ПО РАЗДЕЛАМ:

По разделу «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение»

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОСГН ШБИП	Былкова Т.В.	К.Э.Н.		

По разделу «Социальная ответственность»

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор ООД ШБИП	Федорчук Ю.М.	Д.Т.Н.		

ДОПУСТИТЬ К ЗАЩИТЕ:

Руководитель ООП, должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор ОИТ ИШИТР	Спицын В.Г.	Д.Т.Н.		

ПЛАНИРУЕМЫЕ РЕЗУЛЬТАТЫ ОСВОЕНИЯ ООП

Код компетенции	Наименование компетенции
Универсальные компетенции	
УК(У)-1	Способен осуществлять критический анализ проблемных ситуаций на основе системного подхода, вырабатывать стратегию действий
УК(У)-2	Способен управлять проектом на всех этапах его жизненного цикла
УК(У)-3	Способен организовывать и руководить работой команды, вырабатывая командную стратегию для достижения поставленной цели
УК(У)-4	Способен применять современные коммуникативные технологии, в том числе на иностранном (-ых) языке (-ах), для академического и профессионального взаимодействия
УК(У)-5	Способен анализировать и учитывать разнообразие культур в процессе межкультурного взаимодействия
УК(У)-6	Способен определять и реализовывать приоритеты собственной деятельности и способы ее совершенствования на основе самооценки
Общепрофессиональные компетенции	
ОПК(У)-1	Способен самостоятельно приобретать, развивать и применять математические, естественно-научные, социально-экономические и профессиональные знания для решения нестандартных задач, в том числе в новой или незнакомой среде и в междисциплинарном контексте
ОПК(У)-2	Способен разрабатывать оригинальные алгоритмы и программные средства, в том числе с использованием современных интеллектуальных технологий, для решения профессиональных задач
ОПК(У)-3	Способен анализировать профессиональную информацию, выделять в ней главное, структурировать, оформлять и представлять в виде аналитических обзоров с обоснованными выводами и рекомендациями
ОПК(У)-4	Способен применять на практике новые научные принципы и методы исследований
ОПК(У)-5	Способен разрабатывать и модернизировать программное и аппаратное обеспечение информационных и автоматизированных систем
ОПК(У)-6	Способен разрабатывать компоненты программно-аппаратных комплексов обработки информации и автоматизированного проектирования
ОПК(У)-7	Способен адаптировать зарубежные комплексы обработки информации и автоматизированного проектирования к нуждам отечественных предприятий
ОПК(У)-8	Способен осуществлять эффективное управление разработкой программных средств и проектов
Профессиональные компетенции	
ПК(У)-1	Способен разрабатывать и администрировать системы управления базами данных
ПК(У)-2	Способен проектировать сложные пользовательские интерфейсы
ПК(У)-3	Способен управлять процессами и проектами по созданию (модификации) информационных ресурсов
ПК(У)-4	Способен осуществлять руководство разработкой комплексных проектов на всех стадиях и этапах выполнения работ
ПК(У)-5	Способен проектировать и организовывать учебный процесс по образовательным программам с использованием современных образовательных технологий



Министерство науки и высшего образования Российской Федерации
федеральное государственное автономное
образовательное учреждение высшего образования
«Национальный исследовательский Томский политехнический университет» (ТПУ)

Инженерная школа информационных технологий и робототехники
Направление подготовки: 09.04.01 Информатика и вычислительная техника
ООП/ОПОП: Искусственный интеллект и машинное обучение
Отделение школы (НОЦ): Отделение информационных технологий

УТВЕРЖДАЮ:
Руководитель ООП/ОПОП

(Подпись) (Дата) Спицын В.Г.
(ФИО)

ЗАДАНИЕ на выполнение выпускной квалификационной работы

Обучающийся:

Группа	ФИО
8BM13	Монгуш Темир Валерьевич

Тема работы:

Алгоритм повышения пространственного разрешения изображений на основе генеративно-состязательной сети	
<i>Утверждена приказом директора (дата, номер)</i>	от 09.02.2023 №40-57/с

Срок сдачи обучающимся выполненной работы:

ТЕХНИЧЕСКОЕ ЗАДАНИЕ:

Исходные данные к работе	Объектом исследования является алгоритм повышения пространственного разрешения изображений на основе генеративно-состязательной сети.
Перечень разделов пояснительной записки подлежащих исследованию, проектированию и разработке	1. Суперразрешение при помощи генеративно-состязательной сети; 2. Методы удаления артефактов на сгенерированных изображениях; 3. Реализация генеративно-состязательной сети; 4. Обучение модели и результаты; 5. Результаты применения методов удаления артефактов на сгенерированных изображениях 6. Раздел ВКР «Финансовый менеджмент ресурсоэффективность и ресурсосбережение».

	7. Раздел ВКР «Социальная ответственность». 8. Раздел ВКР на английском языке.
Перечень графического материала (с точным указанием обязательных чертежей)	Презентация в формате *.pptx
Консультанты по разделам выпускной квалификационной работы (с указанием разделов)	
Раздел	Консультант
Финансовый менеджмент, ресурсоэффективность и ресурсосбережение	Доцент ОСГН, ШБИП к.э.н. Былкова Т.В.
Социальная ответственность	Профессор ООД, ШБИП д.т.н. Федорчук Ю.М.
Раздел на иностранном языке	Доцент ОИЯ, ШБИП к.п.н. Сидоренко Т.В.
Названия разделов, которые должны быть написаны на иностранном языке:	
Суперразрешения при помощи генеративно состязательной сети	
Реализация генеративно-состязательной сети	

Дата выдачи задания на выполнение выпускной квалификационной работы по линейному графику	
---	--

Задание выдал руководитель / консультант (при наличии):

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОИТ, ИШИТР	Иванова Юлия Александровна	К.Т.Н.		

Задание принял к исполнению обучающийся:

Группа	ФИО	Подпись	Дата
8BM13	Монгуш Темир Валерьевич		



Министерство науки и высшего образования Российской Федерации
федеральное государственное автономное
образовательное учреждение высшего образования
«Национальный исследовательский Томский политехнический университет» (ТПУ)

Инженерная школа информационных технологий и робототехники
Направление подготовки: 09.04.01 Информатика и вычислительная техника
Уровень образования: Магистратура
ООП/ОПОП: Искусственный интеллект и машинное обучение
Отделение школы (НОЦ): Отделение информационных технологий
Период выполнения весенний семестр 2022/2023 учебного года

КАЛЕНДАРНЫЙ РЕЙТИНГ-ПЛАН выполнения выпускной квалификационной работы

Обучающийся:

Группа	ФИО
8BM13	Монгуш Темир Валерьевич

Тема работы:

Алгоритм повышения пространственного разрешения изображений на основе генеративно-состязательной сети
--

Срок сдачи обучающимся выполненной работы:

Дата контроля	Название раздела (модуля) / вид работы (исследования)	Максимальный балл раздела (модуля)
	Основная часть	70
	Финансовый менеджмент, ресурсоэффективность и ресурсосбережение	10
	Социальная ответственность	10
	Обязательное приложение на иностранном языке	5
	Оформление пояснительной записки	5

СОСТАВИЛ:

Руководитель ВКР

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОИТ ИШИТР	Иванова Ю.А.	к.т.н.		

СОГЛАСОВАНО:

Руководитель ООП/ОПОП

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор ОИТ ИШИТР	Спицын В.Г.	д.т.н.		

Обучающийся

Группа	ФИО	Подпись	Дата
8BM13	Монгуш Темир Валерьевич		

РЕФЕРАТ

Выпускная квалификационная работа выполнена на 118 страницах, содержит 51 рисунок, 23 таблицы, 47 источников, 2 приложения.

Ключевые слова: суперразрешение, разрешение изображения, генеративно-состязательная сеть, увеличение разрешения изображения.

Объектом исследования является алгоритм повышения пространственного разрешения изображений на основе генеративно-состязательной сети.

Цель работы – реализация генеративно-состязательной сети для решения задачи пространственного увеличения разрешения изображения.

В процессе исследования проводились работы по изучению методов повышения разрешения изображений и визуального качества изображений. В ходе работы были рассмотрены существующие подходы к решению задачи суперразрешения.

В результате исследования были реализованы две модели генеративно-состязательных сетей, решающие задачу повышения пространственного разрешения изображения с постобработкой полученных результатов. Также проведены численные эксперименты для оценки качества реализованных моделей.

Область применения: медицинская диагностика – распознавание и анализ медицинских изображений; безопасность и криминалистика – улучшение четкости и видимости лиц, номеров автомобилей, отпечатков пальцев и других на низкокачественных изображениях с камер наблюдения или мобильных устройств; культурное наследие и искусство – может восстановить детали и цвета старых или поврежденных фотографий, картин, рукописей и других произведений искусства; развлечения и образование – может улучшить визуальный опыт при просмотре фильмов, игр на разных устройствах и экранах.

СОДЕРЖАНИЕ

Введение.....	10
1 Суперразрешение при помощи генеративно-состязательной сети.....	12
1.1 Проблема суперразрешения.....	12
1.2 Задача суперразрешения	15
1.3 Обзор методов	15
1.4 Обучение моделей. Функционал ошибки.....	17
1.5 Оценка качества моделей.....	19
1.6 Вывод	28
2 Методы удаления артефактов на сгенерированных изображениях.....	30
2.1 Медианный фильтр.....	30
2.2 Фильтр Gaussian blur.....	30
2.3 Двусторонняя фильтрация	31
2.4 Фильтр повышения резкости	32
2.5 Улучшение изображения при помощи нейронной сети	32
2.6 Улучшение изображения при помощи U-Net	33
2.7 Вывод	35
3 Реализация генеративно-состязательной сети	37
3.1 Генеративно состязательная сеть	37
3.2 Загрузка данных	38
3.3 Архитектура генератора А.....	38
3.4 Архитектура генератора В	39
3.5 Архитектура дискриминатора	40
3.6 Вывод	40
4 Обучение модели и результаты	42

4.1	Параметры обучения	42
4.2	Результаты генератора А.....	42
4.3	Результаты генератора В.....	44
4.4	Вывод	45
5	Результаты применения методов удаления артефактов на сгенерированных изображениях.....	47
5.1	Примеры сгенерированных изображений.....	47
5.2	Результаты медианного фильтра.....	48
5.3	Результаты фильтра Gaussian blur.....	50
5.4	Результаты двустороннего фильтра.....	51
5.5	Результаты полносвязной нейронной сети	53
5.6	Результаты U-Net	54
5.7	Вывод	58
6	Финансовый менеджмент, ресурсоэффективность и ресурсосбережение..	61
6.1	Оценка коммерческого потенциала и перспективности проведения научных исследований с позиции ресурсоэффективности и ресурсосбережения	61
6.1.1.	Потенциальные потребители результатов исследования	61
6.1.2.	Анализ конкурентных технических решений с позиции ресурсоэффективности и ресурсосбережения	63
6.1.3.	SWOT-анализ.....	64
6.1.4.	Оценка готовности проекта к коммерциализации.....	65
6.1.5.	Методы коммерциализации результатов научно-технического исследования.....	67
6.2	Инициация проекта.....	67
6.3	Планирование научно-исследовательских работ	68
6.3.1.	План проекта.....	68

6.3.2. Бюджет научного исследования	70
6.3.3. Реестр рисков проекта	73
6.4 Определение ресурсной, финансовой, бюджетной, социальной и экономической эффективности исследования	74
6.5 Вывод	76
7 социальная ответственность	79
7.1 Производственная безопасность	79
7.1.1. Вредные производственные факторы	79
7.1.2. Опасные производственные факторы	88
7.2 Экологическая безопасность	91
7.3 Безопасность в чрезвычайных ситуациях	92
7.4 Вывод	93
Заключение	95
Список использованной литературы.....	97
Приложение А	102
Приложение Б	114

ВВЕДЕНИЕ

Проблема восстановления изображения, целью которой является восстановление высококачественного содержимого изображения из его ухудшенной версии, находит многочисленные применения в сфере видеонаблюдения, компьютерной обработки изображений, в сфере телемедицины при, например, увеличении разрешающей способности снимков МРТ и дистанционном зондировании [13, 14]. Количество различных изображений растёт экспоненциальными темпами благодаря быстрому росту устройств, способных захватывать изображения, цифровых фотокамер, телефонов, и прочих. При получении изображений не всегда удаётся получить изображение высокого качества. Часто это происходит по причине физических ограничений камеры, например камеры некоторых смартфонов имеют узкую диафрагму и маленькую матрицу с ограниченным динамическим диапазоном, из-за чего они получают низкокачественные снимки с большим количеством шумов на получившейся фотографии. Другая причина низкокачественных изображений – это неподходящие условия освещения. Так, например, изображения, снятые при неподходящем освещении, получаются либо слишком темными, либо слишком яркими, теряя при этом порой важную информацию.

Для увеличения разрешающей способности цифровых устройств для съёмки можно дальше экстенсивно увеличивать ширину диафрагмы камеры, увеличивать матрицу устройства, при этом повышая стоимость конечного устройства. Либо же можно воспользоваться алгоритмами, позволяющими на основе изображения низкого качества, получить изображение более высокого качества. Проблема увеличения разрешающей способности изображений из изображения более низкого качества изучается в рамках задачи суперразрешения. Это сложная обратная задача, так как существует большое количество возможных отображений изображения высокого качества в низкое.

К настоящему времени было предложено большое количество методов, позволяющих получить изображение высокого разрешения из изображения с низким разрешением. Данная проблема активно развивается с момента появления основополагающей работы Цяя и Хуанга а 1984 году [15], за последние три десятилетия появилось большое количество методов, для повышения разрешения, начиная от методов обработки сигналов, заканчивая методами машинного обучения.

В данной работе будет представлен обзор некоторых методов для повышения разрешения изображений, а также представлена общая теория и концепции используемые при решении задачи суперразрешения.

Также будет представлена реализация генеративно-сопоставительной сети для решения задачи суперразрешения с последующим применением методов визуального улучшения качества сгенерированных изображений.

Целью выпускной квалификационной работы является – реализация генеративно-сопоставительной сети для решения задачи пространственного увеличения разрешения изображения.

Для достижения поставленной цели, в настоящей работе решаются следующие задачи:

- изучение проблемы суперразрешения;
- изучение метрик, используемых в задаче суперразрешения;
- изучение методов повышения разрешения изображения;
- изучение проблем производительности методов;
- реализация генеративно-сопоставительной сети;
- реализация методы визуального улучшения изображения.

Апробация работы: результаты работы были представлены на конференции: Молодежь и современные информационные технологии, г. Томск 2023, «Пространственное увеличение разрешения изображений при помощи генеративно-сопоставительной сети».

1 СУПЕРРАЗРЕШЕНИЕ ПРИ ПОМОЩИ ГЕНЕРАТИВНО-СОСТЯЗАТЕЛЬНОЙ СЕТИ

1.1 Проблема суперразрешения

В большинстве приложений, использующих цифровые изображения, для дальнейшей обработки изображений и анализа содержимого данного изображения требуются изображения с высоким разрешением. Необходимость в изображениях высокого разрешения порождается двумя причинами:

- улучшение восприятия изображения человеком;
- улучшение восприятия содержимого изображения машиной, компьютером [1].

Разрешение изображения играет важную роль в описании содержимого изображения: чем выше разрешение описываемого изображения, тем больше деталей может предоставить само изображение.

Существует несколько классификаций разрешения изображения:

- пиксельное разрешение;
- пространственное разрешение;
- спектральное разрешение;
- временное разрешение;
- радиометрическое разрешение.

В данной работе для изучения является интересным именно пространственное разрешение, так как оно характеризуется размерами наименьших объектов изображения, которые возможно различить на изображении.

Любое цифровое изображение состоит из множества неделимых элементов, называемыми пикселями. Как было упомянуто ранее, пространственное разрешение характеризует размер наименьших объектов, или же, другими словами, описывает плотность пикселей изображения.

Пространственное разрешение измеряется в количестве пикселей на единицу площади изображения. Ниже рисунок 1 демонстрирует пример пространственного разрешения изображения [1].




Рисунок 1 – Пример пространственного разрешения изображения

Стоит помнить, что разрешающая способность при пространственном разрешении сводится к возможностям датчиков, которые фиксируют изображение, или устройствами получения изображения. Современный датчик захвата изображения обычно представляет собой пиксельный датчик с зарядовой связью, так называемая ПЗС-матрица, или комплементарную структуру металл-оксид-полупроводник, также называемая КМОП [2]. Эти датчики обычно располагаются в матричном виде для захвата сигналов, соответствующих двумерному изображению. Тем самым пространственное разрешение сводится к количеству возможных элементов сенсора (размер сенсора) на единицу площади изображения. Иначе говоря, чем больше датчиков находятся ближе друг другу, или же чем выше плотность датчиков на сенсоре, тем будет выше пространственное разрешение получаемого изображения. Таким образом для системы, формирующей изображения для повышения пространственного разрешения достаточно увеличить количество датчиков. Но для увеличения плотности датчиков сенсора необходимо уменьшить физический размер самих датчиков, однако это приведет к уменьшению количества падающего света на датчик, что приведет к дробовому шуму. Также стоит учитывать увеличение стоимости аппаратного обеспечения сенсора с увеличенным количеством датчиков. Отсюда можно

сделать вывод, что пространственное разрешение получаемого изображения ограничено размером датчика, устанавливаемого на сенсоре.

Хотя датчики захвата изображения ограничивают пространственное разрешение изображения из-за размытия линз, связанного с функцией точечной коррекции датчика, аббераций оптических систем, дифракции и размытия. Использование микросхем и оптических приборов для получения изображений высокого разрешения является дорогим решением для многих реальных задач в повседневной жизни, например для камер видеонаблюдения в общественных или охраняемых местах и встроенных камер смартфонов. Также разрешение получаемого изображения зависит от скорости считывания данных камерой и аппаратной памятью устройства получения изображения. Также, например, для камер, используемых в спутниковой съёмке, использование высококачественных фиксирующих устройств ограничено физическими ограничениями самого спутника. Отсюда следует что способ увеличения разрешения изображения посредством увеличения разрешающей способности самого фиксирующего устройства имеет физические ограничения, которые трудно и дорого разрешить. Другим способом разрешения проблемы увеличения пространственного разрешения изображения является принятие факта ухудшения качества изображения в процессе съёмки. В этом случае вместо улучшения технических характеристик камеры есть возможность программно обрабатывать полученный сигнал с целью увеличения пространственного разрешения изображения. На основе подобных программ реализуются задачи суперразрешения [17].

Суперразрешение (Super-resolution, SR) – это метод, направленный на создание изображения высокого разрешения (High-resolution) из изображений низкого разрешения (Low-resolution). Это происходит путем увеличения высокочастотных составляющих изображения, что способствует устранению ухудшения, полученного в процессе создания изображения устройством с низкой разрешающей способностью [1]. Задача

суперразрешения является одной из наиболее активных областей исследований с момента появления работы Цая и Хуанга в 1984 году [15]. За последние два десятилетия было предложено множество методов, представляющих подходы от частотной до пространственной области и от обработки сигналов до машинного обучения.

1.2 Задача суперразрешения

Изображение с низким разрешением можно смоделировать из изображения с высоким разрешением, используя приведенную ниже формулу, где D - функция деградации, I_y - изображение с высоким разрешением, I_x -изображение с низким разрешением, а σ - шум.

$$I_x = D(I_y; \sigma) \quad (1)$$

Параметры деградации D и σ неизвестны. Имеется только изображение с высоким разрешением и соответствующее изображение с низким разрешением. Следовательно, теперь мы можем получить определение понятия суперразрешения.

Суперразрешение – это задача восстановления изображения высокого разрешением (Hr) из соответствующего изображения с низкого разрешения (Lr).

1.3 Обзор методов


Для задачи увеличения пространственного разрешения изображений используется большое количество методов. В последнее время, начиная с 2010-ых годов, методы, связанные с глубоким обучением, становятся наиболее используемыми в данной сфере [1]. Данная работа не является всеобъемлющей, здесь будут рассмотрены некоторые из таких методов, которые показались наиболее интересными в плане реализации, и наиболее перспективными в будущем.

Однако для начала необходимо описать некоторые из классических методов повышения дискретизации, так как в некоторых методах глубокого

обучения в качестве строительных блоков модели часто используются блоки апсемплинга, использующие классические методы.

Существуют следующие методы интерполяции [3]:

- интерполяция по ближайшему пикселю – простой метод с быстрой реализацией, но возможны проявления артефактов;
- билинейная интерполяция – требует больше вычислений, размывает границы объектов на изображении, что приводит к визуальному улучшению по качеству;
- бикубическая – хорошо показывает себя на непрерывных областях изображения, при переходе областей на границе наблюдаются искажения, называемое Гало-эффект;
- интерполяция В-сплайном – очень сильно размывает изображение;
- интерполяция на основе кубического Эрмитового сплайна, такой сплайн требует оценки частных производных в каждом пикселе изображения [3].



а) Интерполяция по ближайшему пикселю, б) Билинейная интерполяция, в) Бикубическая интерполяция, г) Интерполяция В-сплайном, е) Интерполяция на основе кубического Эрмитового сплайна

Рисунок 2 – Испытательная мишень

На рисунке 2 представлены примеры использования интерполяционных фильтров на примере интерполяции изображения печатной буквы «А».

Для решения задачи суперразрешения используются различные методы, основанные на глубоком обучении с учителем. Далее будут рассмотрены некоторые из этих методов. Многие методы увеличения пространственного разрешения используют свёрточные нейронные сети,

некоторые из них используют различные приёмы помимо классических 2D-свёрток. Возьмем, к примеру, статью [4], где применяются расширенные сверточные операции, позволяющие учесть информацию, разделенную большими пространственными расстояниями. Также частым решением является применение пространственного пирамидального пулинга или полносвязных блоков, которые для повышения производительности всей системы могут объединять признаки разных уровней [7].

1.4 Обучение моделей. Функционал ошибки

Модели, основанные на свёрточных нейронных сетях, используют различные функции потерь, для нахождения ошибок модели. Для оценки сгенерированного изображения используются функции потерь, которые показывают ошибку между реальным исходным высоким изображением и полученным путем генерации. Рассчитанная ошибка в дальнейшем применяется для оптимизации процесса обучения модели. В настоящее время используются множество различных функций потерь при оценке изображений.

В процессе обучения модели зачастую применяются несколько функций ошибок, результаты которых взвешиваются и суммируются для получения общей оценки. Это позволяет учитывать различные аспекты ошибки и более точно оценивать качество модели. Данный приём позволяет модели генерировать изображения с учётом различных аспектов модели изображения одновременно, учитывая ошибки, вносимые множественными функциями потерь [8].

Пиксельная ошибка (pixel loss) – это метод сравнения изображений, при котором каждый пиксель одного изображения сравнивается с соответствующим пикселем другого изображения. Этот метод применяется для оценки качества изображений и определения степени их сходства. Для оптимизации модели используются различные функции потерь. Это могут быть потери L1, L2 или их расширенные версии, такие как сглаженные

потери (Smooth L1). Данная функция ошибки напрямую влияет на разность пикселей, что ведёт к улучшению метрики PSNR (peak signal-to-noise ratio), которая будет рассмотрена позже, однако использование пиксельной ошибки не гарантирует улучшение визуального качества изображения, поэтому сгенерированные изображения могут не понравиться при восприятии человеком [8].

Другой популярной ошибкой, применяемой в задачах увеличения разрешения, является ошибка восприятия (perceptual loss), которая определяет качество изображения на основании его восприятия. Один из методов проверки подлинности изображения – это сравнение его характеристик с характеристиками других изображений, которые можно получить с использованием уже обученных сетей классификации изображений [10].

Ошибка текстуры – еще одна из функций ошибок, используемых в различных работах. Ошибка текстуры позволяет сгенерированному изображению сохранить или же перенять стиль исходного изображения, то есть основные параметры цвета, контраста и текстуры будут идентичны как у настоящего изображения. В изображении текстуры определяются на основе анализа корреляций между различными каналами. Каждый канал содержит уникальные особенности, что позволяет идентифицировать объекты на изображении. Карты признаков создаются с помощью предварительно обученных моделей классификации, и эта информация используется для создания текстур с более реалистичным видом и удовлетворительными визуальными характеристиками [11].

Также можно встретить ошибку, основанную на полной вариационной погрешности (TV – total variation) [8]. Она складывается из абсолютных изменений между соседними точками и показывает уровень шума в изображении. Для расчёта погрешности TV используется следующая формула:

Также следует упомянуть состязательную ошибку, применяемую во всех архитектурах генеративно-состязательных сетей [8]. Состязательная ошибка означает, что каждая компонента сети стремится минимизировать свою собственную ошибку, при условии, что другая компонента увеличивает свою ошибку. Это создает состязательную динамику между генератором и дискриминатором, приводя к совершенствованию и улучшению качества сгенерированных данных.

Таким образом, состязательная ошибка направлена на достижение равновесия между генератором и дискриминатором, при котором генерируемые данные становятся всё более реалистичными и неотличимыми от реальных данных. Это помогает генерировать высококачественные и убедительные синтезированные примеры, что является одним из ключевых преимуществ этой архитектуры.

1.5 Оценка качества моделей

Для оценки моделей используются различные метрики. Следует перечислить некоторые из них. Существуют различные методы оценки качества изображения, которые позволяют оценить различные параметры сгенерированного изображения. Все эти метрики относятся к двум категориям: субъективным и объективным.

Субъективные метрики основываются на субъективной оценке качества изображения человеком, в то время как объективные метрики используют вычислительные модели для оценки качества изображения. Хотя субъективные метрики могут быть более «точными», они могут быть неудобными в использовании, трудоемкими и дорогими для вычисления. Кроме того, эти две категории метрик не всегда соответствуют друг другу. Далее будут рассмотрены некоторые из метрик оценки моделей.

Одной из часто использующихся метрик является метрика PSNR (пиковое отношение сигнала к шуму). Она является объективной, и обратно

пропорциональна логарифму средней квадратичной ошибки между настоящим изображением высокого разрешения и сгенерированным [1].

$$MSE = \frac{1}{N} \sum_{i=1}^N \left(I(i) - \hat{I}(i) \right)^2, \quad (2)$$

$$PSNR = 10 * \log_{10} \left(\frac{L^2}{MSE} \right) \quad (3)$$

где L – это максимально возможное значение пикселя. Так как PSNR основан на пиксельной разнице, то данная метрика может не точно оценивать воспринимаемое качество изображения.

Structure similarity или же SSIM – метод структурного сходства, еще одна метрика оценки качества изображений. Это метод измерения сходства структур изображений на основе сравнения яркости, контраста и структуры. [1]. Метрика является взвешенным произведением яркости, контраста и структуры изображения, вычисленных независимо друг от друга.

$$SSIM(I, \hat{I}) = \frac{(2\mu_I\mu_{\hat{I}} + C_1)(\sigma_{I\hat{I}} + C_2)}{(\mu_I^2 + \mu_{\hat{I}}^2 + C_1)(\sigma_I^2 + \sigma_{\hat{I}}^2 + C_2)} \quad (4)$$

где μ_I – среднее значение конкретного изображения, σ_I – стандартное отклонение конкретного изображения, $\sigma_{I\hat{I}}$ – ковариация между изображениями, C_1 и C_2 – константы для стабилизации. Зачастую при оценке пользуются вычислением локальной метрики SSIM, в разных окнах изображения, при последующей взвешенной оценке получившихся результатов, для стабилизации процесса оценки. Поскольку SSIM является мерой качества реконструкции на основе зрительной системы человеческого глаза, она лучше подходит для оценки восприятия, чем другие метрики. Также для оценки моделей используются такие метрики как: средняя оценка мнений, являющийся ручным способом определения результатов модели, где людей просят оценить изображение, после чего результаты агрегируются, и в качестве показателя используется средний результат оценки, критерий достоверности информации, визуальная достоверность информации.

Для решения задачи суперразрешения используется множество методов и моделей, некоторые из них будут рассмотрены далее. Так в [12] изучается глубокая предварительная оценка изображений (deep image prior). Зачастую при решении задач восстановления изображения, очистки от шума и увеличения разрешения, многие характерные признаки изображения можно проанализировать ещё до этапа обучения. Несмотря на то, что многие исследования в данной области [20, 21] используют сверточные модели, обученные на большом объеме данных, существует предположение, которое подкреплено работой [12], о возможности получения некоторых предварительных оценок изображений до этапа обучения модели. В частности, в [12] используется необученная генеративная сеть, в структуре которой заложена модель изображения. Таким образом генеративная сеть в данной модели выступает в качестве параметризатора для входного изображения в функции вида: $x = f_{\theta}(z)$, где z представляет из себя фиксированный, случайный тензор $z \in R \times H \times W^3$, а x представляет из себя изображение $x \in R \times H \times W^3$.

В качестве эмпирических данных для обучения, модель использует только данные об изображении низкого качества. Постепенно в ходе обучения приближаясь к истинному изображению высокого качества (рисунок 3). Можно увидеть, что процесс начинается со случайных весов θ_0 , после чего веса модели итеративно обучаются, для минимизации значения энергии $E(f_{\theta}; x_0)$. На каждой итерации t веса отображаются на изображение $f_{\theta}(z)$, где z – случайно проинициализированный тензор, а отображение f – нейронная сеть с параметрами θ . Изображение x_0 используется для нахождения ошибки $E(x; x_0)$, после чего вычисляется градиент потерь в зависимости от весов θ .




Рисунок 3 – Процесс суперразрешения

Так как единственной эмпирической информацией, которую может использовать модель для процесса увеличения разрешения, является изображение низкого качества, то учитывая минимизатор, который можно найти как $\theta^* = \operatorname{argmin}_{\theta} E(f_{\theta}(z); x_0)$, сгенерированное изображение может быть получено как $x^* = f_{\theta^*}(z)$. Данный подход показан на рисунке 4.




Рисунок 4 – Визуализация процесса SR

На рисунке 4 изображён процесс нахождения изображения высокого разрешения x_{gt} из ухудшенного изображения x_0 . Истинное изображение расположено в пространстве с нулевой энергией $E(x; x_0) = 0$, то оптимизация может завершиться на точке x^* , которая находится далеко от x_{gt} (фиолетовая кривая на графике). Однако, если добавить обычную предварительную оценку изображения в виде регуляризатора $R(x)$, то энергия будет изменена таким образом, что оптимизация завершится на точке x^* ближе к истинному значению (зеленая кривая на графике). Глубокая предварительная оценка также может быть использована для достижения

точки оптимизации, близкой к истинным значениям, но это происходит за счет перепараметризации хода оптимизации, что может привести к лучшим результатам.

Рассмотренная выше модель, по сути является вручную спроектированным фильтром, также, как например телевизионная норма. Архитектура, использованная в рассмотренном подходе – это архитектура песочных часов (hourglass) с пропуском соединений. С помощью данного метода удалось достигнуть значительных результатов: метрика PSNR, вычисленная для него и для моделей на основе свёрточных сетей, оказалась выше при увеличении разрешения в 8 раз.

Развитием этой идеи является работа [7] в которой используется генеративно состязательная модель, которая также используется для предварительной оценки статистики, содержащейся в изображении для различных задач связанных с суперразрешением, восстановлением, раскраской и так далее. Работа использует модель генератора и дискриминатора для того, чтобы извлекать из большого множества входных исходных изображений предварительные статистические данные высокого уровня, такие как цвет, текстура, контраст и так далее, в отличие от deep image prior, которая сбирала низкоуровневую статистику изображения. Поэтому итоговая модель способна показывать хорошие результаты на большом количестве разнообразных естественных изображений, и способна справляться с различными задачами, требующими подкрепления данными высокого уровня, так как GAN предстаёт в качестве хорошего аппроксиматора для большого многообразия изображений.

Учитывая проблемы моделей GAN-инверсии, например разрыв между множеством приближенных изображений и исходными изображениями, которые требуется обработать, многие исследователи предлагают использовать генератор с изменяемыми параметрами обучения θ вместо фиксированной модели. Это позволяет генератору настраивать параметры

обучения на лету, что в свою очередь упрощает процесс нахождения необходимого отображения. Таким образом, процесс нахождения необходимого отображения можно представить в виде:

$$\theta^*, z^* = \underset{\theta, z}{\operatorname{argmin}} L(\hat{x}, \varphi(G(z; \theta))), \quad (5)$$

$$x^* = G(z^*; \theta^*), \quad (6)$$

где L – это метрика расстояния, например метрика $L2$, G – это генератор генеративно состязательной сети, и θ – это параметры сети, φ – функция деградации изображения. Таким образом процесс увеличения разрешения может быть представлен как, представление случайно проинициализированного тензора z на латентное пространство, после чего нахождение оптимального изображения $x^* = G(z^*; \theta^*)$, содержащую недостающую семантику исходного изображения $\hat{x}$ наиболее подходящее к $\hat{x}$ после процесса деградации φ . При этом важным моментом для сохранения предварительной оценки статистики изображений, является правильная разработка метрики расстояния L и правильной стратегии оптимизации.

Авторы статьи на множестве задач исследовали различные метрики, использующие среднеквадратичное расстояние MSE на основе AlexNet/VGGNet [22, 23]. При этом было обнаружено, что использование этих метрик может вызывать неверные результаты в начале оптимизации, что закономерно может привести к неверным результатам в конце. Поэтому авторы решили использовать метрику расстояния, основанную на дискриминаторе, которая измеряет расстояние $L1$ в пространстве признаков дискриминатора.

$$L(x_1, x_2) = \sum_{i \in I} ||D(x_1, i), D(x_2, i)|| \quad (7)$$

где x_1 и x_2 – это изображения, D – дискриминатор сети, связанный с генератором, а i – это индекс блока генераторной сети.

Также довольно интересным является решение постепенного обучения блоков генеративно-состязательной сети, в процессе воссоздания изображения с высоким разрешением. Суть идеи в том, что блоки сети при одновременной настройке параметров, могут иногда пропускать в начале обучения семантику более высокого уровня, обучаясь низкоуровневым признакам изображения, так называемый эффект «задержки информации». Данная идея продемонстрирована на рисунке 5.




Рисунок 5 – Использование постепенного обучения

Как можно заметить на рисунке, сеть генератора постепенно, итеративно на каждом шаге обучает блок ответственный за более глубокие статистики, хранящиеся в изображении. Модель показала свою пригодность, так, при измерении метрики SSIM, она показала лучшие результаты чем многие другие модели, использующие генеративно состязательные сети[5].

Кроме генеративно-состязательных моделей существуют и иные подходы к решению задачи увеличения разрешения изображения. В работе [6] исследуется многомасштабный подход (multi-scale approach). В подходе используется свёрточная нейронная сеть, имеющая в своей основе многомасштабный остаточные блоки (multiscale residual block), которые

способны сохранять признаки характерные изображению высокого разрешения вдоль иерархии сети, минимизируя тем самым потерю точных пространственных деталей. Кроме того, модель использует параллельные свёрточные потоки, обрабатывающие признаки с более низким пространственным разрешением. Таким образом параллельные потоки дополняют главный поток, сохраняющий признаки высокого разрешения. В отличие от подходов в [24, 25], которые обрабатывают каждое измерение по отдельности, подход в [6] постепенно объединяет разные измерения на каждом уровне разрешения, что позволяет обмениваться информацией между измерениями. Данным механизм обеспечивается при помощи селективного слияния ядер свёртки, позволяющие обмениваться информацией между различными потоками модели. Блок слияния динамически выбирает полезный набор ядер из каждого представления потока, используя подход самонаблюдения, необходимо подчеркнуть, что данный блок объединяет признаки с различными рецептивными полями, сохраняя их отличительные дополнительные характеристики.

Общая суть метода увеличения разрешения, проводимая в [6], заключается в том, что, получив изображение $I \in R^{H \times W \times 3}$, сеть сначала применяет свёрточный слой для извлечения низкоуровневых признаков $X_0 \in R^{H \times W \times C}$. После чего карта признаков X_0 проходит через N рекуррентных остаточных групп, получая глубокие признаки изображения $X_d \in R^{H \times W \times C}$, где каждая рекуррентная группа имеет в себе несколько многомасштабный остаточных блоков, после чего слой свёртки применяется к глубоким признакам X_d , для получения остаточного изображения $R \in R^{H \times W \times C}$. Наконец, изображение высокого разрешения можно получить как:

$$\hat{I} = I + R \quad (8)$$

В качестве функции потерь модель использует потерю Шарбонье:

$$L(\hat{I}, I^*) = \sqrt{\|\hat{I} - I^*\|^2 + \varepsilon^2} \quad (9)$$

где I^* – это истинное изображение высокого разрешения, а ε – константа для стабилизации процесса обучения. Архитектурно модель представлена на рисунке 6.




Рисунок 6 – Архитектура сети MIRNet

Как можно увидеть на рисунке, сеть состоит из слоя свёртки в начале для извлечения карт признаков, нескольких рекуррентных остаточных групп, для получения глубоких признаков изображения, и последнего слоя свёртки – для получения остаточного изображения с последующей конкатенацией и исходным изображением. Можно заметить, что остаточная группа состоит из нескольких многомасштабных остаточных блоков, которые в свою очередь состоят из нескольких параллельных потоков, которые в свою очередь обмениваются информацией посредством блока селективного слияния признаков ядра, для консолидации признаков высокого разрешения с помощью признаков низкого разрешения и наоборот.

В итоге можно сказать, что модель MIRNet хорошо справляется с задачами увеличения разрешения изображений. Модель имеет хорошие показатели метрики PSNR, при сравнении её с некоторыми современными моделями основанными на генеративно состязательных сетях.

Интересной также представляется работа [9], в которой исследователи предлагают метод повышения производительности модели увеличения

разрешения. Метод основан на дополнении данных в процессе тестирования модели. Суть его заключается в том, что модель, названная исследователями CutBlur, вырезает участок с низким разрешением и вставляет его в соответствующий участок изображения с высоким разрешением и наоборот. Таким образом CutBlur позволяет модели, решающей задачу увеличения разрешения научиться не только «как», но и «где» улучшать разрешение изображения.

Модель позволяет оптимизировать модели суперразрешения тем, что проводит дополнение существующей модели данными. Суть в том, что, применяя функцию деградации на исходное изображение высокого разрешения, например функцию JPEG, иногда можно попасть в ситуацию, когда имеется разрыв между данными, на которых проводилось обучение и реальными естественными изображениями низкого качества. CutBlur же, создавая два деградированных в локальных местах изображения на основе LR и HR, создаёт эффект регуляризации, побуждает модель суперразрешения учиться не только тому «как» проводить семплирование но и «где». На рисунке 7 представлена схема работы модели.




Рисунок 7 – Схема работы CutBlur

Как можно заметить, модель берёт два изображения: одно с низким разрешением, другое с высоким, после чего меняет участки изображения друг с другом, получая в итоге два новых изображения LR.

1.6 Вывод

Таким образом, в разделе "Суперразрешение при помощи генеративно-сопоставительной сети" мы рассмотрели важную и актуальную технологию, которая имеет большую значимость в современных задачах обработки изображений. Генеративно-сопоставительные сети (GAN) предлагают

эффективный подход к преобразованию низкокачественных изображений в более детализированные и реалистичные версии. В силу развития вычислительной мощности и доступности больших объемов данных, современные методы суперразрешения на основе GAN достигают впечатляющих результатов, превосходящих традиционные подходы. Это делает данную область актуальной и перспективной для исследований и практического применения.

Одной из актуальных областей применения суперразрешения с использованием GAN является улучшение качества изображений в медицинской диагностике, где детализация и четкость изображений имеют решающее значение для точности диагноза. Кроме того, в области компьютерного зрения, связанной с видеонаблюдением, суперразрешение позволяет извлечь дополнительную информацию из видеопотоков низкого разрешения и улучшить распознавание объектов.

Будущее суперразрешения, вероятно, будет связано с постоянным развитием и усовершенствованием GAN, а также интеграцией с другими современными технологиями компьютерного зрения.

При оценке качества суперразрешения изображений рекомендуется использовать PSNR и SSIM, чтобы получить более полное представление о достоверности и визуальном качестве восстановления. Однако важно помнить, что эти метрики являются лишь приближенными оценками и не всегда полностью отражают восприятие качества изображений человеческим глазом. Дополнительные методы, такие как оценка субъективной качества с помощью восприятия экспертов, могут также быть включены в процесс оценки качества.

2 МЕТОДЫ УДАЛЕНИЯ АРТЕФАКТОВ НА СГЕНЕРИРОВАННЫХ ИЗОБРАЖЕНИЯХ

2.1 Медианный фильтр

Медианный фильтр – это цифровой фильтр, который уменьшает шум в сигналах и изображениях. Он относится к нелинейным КИХ-фильтрам [28]. Он работает так: берет набор элементов в окне фильтра, сортирует их по величине и выбирает средний элемент как выходной. Если в окне чётное число элементов, то выходной элемент – это среднее двух средних элементов. Окно сдвигается по фильтруемому сигналу и процесс повторяется. Медианный фильтр хорошо справляется с импульсными помехами (Рисунок 8).



Рисунок 8 – Медианный фильтр

Пример: медианный фильтр – это скользящее окно размером 3×3 пикселя. Он принимает 9 значений (пикселей) и выдаёт одно. Он упорядочивает входные пиксели по величине и выдаёт медиану (серединный элемент).

2.2 Фильтр Gaussian blur

Эффект Gaussian blur – это линейная операция, которая сводится к свёртке изображения с матрицей фильтра. Каждый пиксель заменяется на

взвешенную сумму соседних пикселей [28]. Фильтр называется Gaussian, потому что он основан на функции гауссианы e^{-x^2} (Рисунок 9).




Рисунок 9 – График функции гауссианы

Размытие по Гауссу названо в честь математика Карла Фридриха Гаусса. Это метод размытия изображения с помощью математической функции. «Этот фильтр создаёт эффект полупрозрачного материала поверх изображения, например пергамента, – объясняет фотограф Кентон Вальтц (Kenton Waltz). – Он делает изображение более мягким». Размытие по Гауссу – это низкочастотный фильтр, который выравнивает перепады значений пикселей изображения, обрезая самые высокие значения [36].

2.3 Двусторонняя фильтрация

Двусторонняя фильтрация эффективно удаляет шум, не размывая края. Но эта операция медленнее других фильтров. Мы уже знаем, что фильтр Гаусса берет окрестности вокруг пикселя и находит средневзвешенное значение Гаусса. Этот фильтр Гаусса является функцией только пространства, то есть при фильтрации учитываются близлежащие пиксели. Он не учитывает, имеют ли пиксели почти одинаковую интенсивность. Он не учитывает, является ли пиксель краевым пикселем или нет. Поэтому он размывает края, чего мы не хотим [31].

Двусторонняя фильтрация также применяет фильтр Гаусса, но добавляет ещё один фильтр, который зависит от разницы в интенсивности пикселей. Гауссов фильтр по расстоянию гарантирует, что для размытия используются только близкие пиксели, а гауссов фильтр по интенсивности гарантирует, что для размытия используются только пиксели с похожей

интенсивностью на центральный пиксель. Таким образом, он сохраняет края, так как пиксели на краях будут иметь большую разницу в интенсивности.

Двусторонняя фильтрация применяется в улучшении изображения, устранении матовости, шумоподавлении, восстановлении изображения.

2.4 Фильтр повышения резкости

Повышение резкости изображений помогает выделить текстуру и привлечь внимание зрителя. Кроме того, любой цифровой снимок нуждается в повышении резкости на определённом этапе – потому что сенсоры цифровых камер и объективы всегда немного размывают изображение, и это нужно исправить. Однако не все методы повышения резкости одинаково хороши. Если применять их слишком сильно, могут появиться нежелательные артефакты обработки. С другой стороны, если использовать их правильно, повышение резкости может улучшить видимое качество изображения даже больше, чем покупка дорогого объектива [32].

$$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 9 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$

Рисунок 10 – Ядро повышения резкости

Повышение резкости изображения можно представить в виде свёртки изображения с матрицей фильтра (Рисунок 10).

2.5 Улучшение изображения при помощи нейронной сети

Также можно реализовать сеть, визуально улучшающую изображение, на вход нейронная сеть будет получать фрагменты изображений, полученных путем генерации, а в качестве правильных значений признаков будем использовать фрагменты изображений высокого разрешения.

Нейронная сеть представлена в виде полносвязной линейной сети, состоящей из линейного слоя из 9 нейронов, функции активации LeakyRelu, после которого идет линейный слой из одного нейрона и функцией

активации LeakyReLU [33]. В качестве функции активации использовались функции активации Relu, Linear, LeakyReLU, но результаты были идентичны.




Рисунок 11 – Модель нейронной сети

В качестве функции ошибки используется квадратичная ошибка. Тренировка производилась в течении 100 эпох, с размером входных данных равным 100

2.6 Улучшение изображения при помощи U-Net

Название сети происходит от ее U-образной формы. Первоначально U-Net была использовалась для сегментации биомедицинских изображений. В широком смысле его архитектуру можно представить как сеть кодировщика, за которой следует сеть декодера. Сеть является полностью сверточной сетью. Они не использовали никаких других слоев, таких как плотный или плоский или другие подобные слои [34].




Рисунок 12 – Архитектура U-Net

Архитектура показывает, что входное изображение проходит через модель, а затем за ним следует пара сверточных слоев с функцией активации ReLU. Мы можем заметить, что размер изображения уменьшается с 572x572 до 570x570 и, наконец, до 568x568. Причина этого сокращения в том, что они использовали свертки без дополнений, что приводит к уменьшению общей размерности. у нас есть блок кодировщика с левой стороны, за которым следует блок декодера с правой стороны.

Энкодер – это первая половина схемы архитектуры. Обычно это предварительно обученная классификационная сеть, такая как VGG/ResNet, где применяются блоки свертки, за которыми следует понижающая дискретизация maxpool для кодирования входного изображения в представления признаков на нескольких разных уровнях.

Блок энкодера имеет постоянное уменьшение размера изображения с помощью max-pooling. У нас также есть повторяющиеся сверточные слои с растущим числом фильтров в архитектуре кодировщика.

Декодер – это вторая половина архитектуры. Его цель – семантически преобразовать характеристические признаки (с меньшим разрешением), полученные кодировщиком, в пространство пикселей (с большим

разрешением), для получения плотной классификации. Декодер состоит из блока повышающей дискретизации и конкатенации, за которыми следуют обычные операции свертки.

Как только мы доходим до аспекта декодера, мы замечаем, что количество фильтров в сверточных слоях начинает уменьшаться вместе с постепенным повышением дискретизации в следующих слоях вплоть до самого верха.

В последнем блоке свертки у нас есть пара сверточных слоев, за которыми следует последний сверточный слой. Этот слой имеет фильтр 2×2 с соответствующей функцией для отображения результирующего вывода. Этот последний слой можно изменить в соответствии с желаемой целью проекта, который вы пытаетесь выполнить [35].

2.7 Вывод

В данном разделе мы рассмотрели различные методы удаления артефактов на сгенерированных изображениях. Артефакты, такие как зернистость и размытые структуры, могут возникать в результате применения алгоритмов суперразрешения и существенно снижать качество восстановленных изображений.

Были рассмотрены методы, основанные на фильтрации и постобработке при помощи полносвязной нейросети и сети U-Net, которые направлены на снижение артефактов и улучшение визуальной чистоты изображений. Такие подходы включают использование фильтров, регуляризации и других техник для устранения артефактов и повышения детализации.

Однако следует отметить, что каждый метод имеет свои ограничения и может быть эффективен только в определенных ситуациях. Подбор наиболее подходящего метода зависит от типа артефактов, особенностей исходного изображения и требований к конечному результату.

Методы удаления артефактов на сгенерированных изображениях продолжают активно развиваться, стремясь улучшить качество реконструкции и сделать суперразрешение еще более применимым на практике. Исследования в этой области включают в себя разработку новых алгоритмов, улучшение существующих методов и исследование комбинированных подходов.

В целом, раздел "Методы удаления артефактов на сгенерированных изображениях" позволяет нам ознакомиться с различными техниками и подходами, которые помогают повысить качество сгенерированных изображений путем устранения артефактов. Данный подход повысит и упростит практическую применимость суперразрешения в различных областях, включая медицину, развлекательную индустрию и автомобильную промышленность.

3 РЕАЛИЗАЦИЯ ГЕНЕРАТИВНО-СОСТЯЗАТЕЛЬНОЙ СЕТИ

3.1 Генеративно состязательная сеть

Ниже представлена общая схема работы генеративно-состязательной сети.

Она состоит из двух сетей, сети генератора, которая будет учиться создавать изображения, и сети дискриминатора, которая будет учиться определять настоящее ли изображение или это результат работы генератора.




Рисунок 13 – Генеративно-состязательная сеть

Таким образом, задачей работы заключается в том, чтобы генеративная сеть обучилась для входного изображения низкого разрешения создавать соответствующее изображение высокого разрешения. Для этого обучаем генеративно-состязательную сеть как сверточную нейронную сеть.

Сеть дискриминатора пытается обучиться распознавать настоящее изображение от сгенерированного сетью генератора. А сеть генератора в свою очередь учится создавать такое изображение, которое дискриминатор бы не смог определить как сгенерированное.

На вход дискриминатора подается изображение и метка, фейковое или реальное изображение. После чего дискриминатор при помощи свертки на основе карт признаков пытается определить реальное ли изображение или сгенерированное.

На вход генератора подается изображение низкого разрешения, после чего генератор при помощи свертки учится генерировать изображение высокого разрешения.

3.2 Загрузка данных

В качестве данных были взяты данные DIV2K. DIV2K [26] — это популярный набор данных с одним изображением сверхвысокого разрешения, который содержит 1000 изображений с различными сценами и разделен на 800 для обучения.

Pytorch предлагает решение для параллелизма процесса загрузки данных. Это DataLoader класс, присутствующий в Torch.utils.data. Загрузка данных происходит путем создания объектов класса ImageDataset, где преобразования в целом сложены вместе с использованием композитной функции и применяются к изображениям в наборе данных, с последующим преобразованием их в тензор. В результате считывания изображения высокого разрешения, создается изображение низкого разрешения. После чего получается пара — изображение низкого разрешения-изображение высокого разрешения. С кодом можно ознакомиться в приложении Б.

3.3 Архитектура генератора А

Генератор А представляет из себя сверточную нейронную сеть в основе которой находятся остаточные блоки с пакетной нормализацией. Ниже представлена архитектура сети генератора (Рисунок 14).




Рисунок 14 – Модель генератора

Генеративная сеть состоит из слоя свертки с ядром 3x3 и 64 картами признаков, и с функцией активации PReLU. Далее идет набор из 16

остаточных блоков, каждый блок состоит из двух слоев свертки с ядрами 3x3 и 64 картами признаков, выход которых передается в слой пакетной нормализации. В блоках используется функция активации PReLU. Далее идет снова слой свертки, после чего изображение увеличивается попиксельно с помощью двух свёрточных слоев. Последним идет слой свертки с тангенциальной функцией активации. С кодом можно ознакомиться в приложении Б.

3.4 Архитектура генератора В

Генератор В представляет из себя сверточную нейронную сеть в основе которой лежит идея остаточных блоков внутри остаточных блоков. Заметим, что в отличие от генератора А в данной модели не используется пакетная нормализация. Ниже представлена архитектура сети генератора (Рисунок 15).




Рисунок 15 – Модель генератора

Генеративная сеть состоит из входного сверточного слоя, выход которого передается далее в последовательно идущие остаточные блоки. Остаточные блоки в свою очередь представляют из себя систему слоев свертки с функцией активации LReLU, выход каждой последовательности суммируется с выходом, полученным на предыдущем этапе, после прохождения всей последовательности выход суммируется с входом в остаточный блок и передает результат на вход следующему остаточному блоку. После системы остаточных блоков идет слой свертки, после чего

изображение увеличивается попиксельно с помощью двух свёрточных слоев. С кодом можно ознакомиться в приложении Б.

3.5 Архитектура дискриминатора

Дискриминатор – это сверточная нейронная сеть, которая учится распознавать исходные и сгенерированные изображения. Ниже представлена архитектура сети дискриминатора (Рисунок 16).




Рисунок 16 – Модель дискриминатора

Сеть-дискриминатора представляет из себя сверточную нейронную сеть с фильтром размерностью 3x3 и увеличивающимся числом ядер (64, 128, 256, 512). Карты признаков проходят по двум полносвязным слоям с сигмоидной функцией активации для получения вероятности классификации изображений. Для выделения признаков изображения используется готовая модель сверточной нейронной сети VGG19 [27]. С кодом можно ознакомиться в приложении Б.

3.6 Вывод

В данном разделе мы рассмотрели вопросы, связанные с реализацией генеративно-состязательных сетей (GAN) в контексте задачи суперразрешения. Реализация GAN является сложным процессом, требующим глубокого понимания архитектуры и оптимизации модели.

Были изучены и реализованы основные компоненты GAN, включая генератор и дискриминатор, их взаимодействие в процессе обучения и оптимизации с использованием метода обратного распространения ошибки.

Важной частью реализации GAN является выбор и предварительная обработка обучающего набора данных. Для задачи суперразрешения это может включать пары изображений низкого разрешения и высокого разрешения, на которых модель будет обучаться. Поэтому для обучения выбран набор данных DIV2K, который содержит 1000 изображений высокого разрешения с различными сценами.

Также были рассмотрены методы улучшения стабильности обучения GAN при помощи нормализации данных. Тем самым было предложено две архитектуры генератора, первый основан на остаточных блоках с нормализацией входных данных, а вторая основывается на более глубокой архитектуре остаточных блоков внутри остаточных блоков, но при этом не используется пакетная нормализация данных.

В заключение, раздел "Реализация генеративно-состязательной сети" позволяет нам понять основные аспекты и сложности, связанные с реализацией GAN для задачи суперразрешения. Разработка и оптимизация таких моделей требуют тщательного исследования и экспериментов.

4 ОБУЧЕНИЕ МОДЕЛИ И РЕЗУЛЬТАТЫ

4.1 Параметры обучения

Обучение проводилось на 800 изображениях высокого разрешения, с параметром скорости обучения 0.0001, обучение проведено для 400 эпох, на каждую эпоху требуется 4 минуты (26-27 часов).

Обучение производилось на ноутбуке:

- Процессор: AMD Ryzen 7 5800H with Radeon Graphics 3.20 GHz;
- Оперативная память 16,0 ГБ;
- Графический процессор NVIDIA GeForce RTX 3060 Laptop 6 ГБ.

Следовательно, обучение проводилось с последующим сохранением состояний сетей дискриминатора и генератора.

4.2 Результаты генератора A

real(hr) – исходное реальное изображение высокого разрешения, lr – изображение низкого разрешения, gen(hr) – результат работы сети генератора.



Рисунок 17 –Результат работы сети



Рисунок 18 –Результат работы сети



Рисунок 19 –Результат работы сети



Рисунок 20 –Результат работы сети

В таблице 1 представлены результаты хода обучения сети.

Таблица 1 – Результаты обучения генератора A

Epoch	D_loss	G_loss
0	0.0317	1.34
99	$6.98 \cdot 10(-5)$	0.972
199	$2.09 \cdot 10(-5)$	0.887
299	$9.66 \cdot 10(-6)$	0.82
399	$4.05 \cdot 10(-6)$	0.79

Рассчитаем средние значения метрик PSNR и SSIM для полученных изображений. (Таблица 2).

Таблица 2 – Средние значения метрик PSNR и SSIM

Модель	PSNR	SSIM
SRGAN	26	0,87
GAN - A	27	0,70

По результатам сети можно сделать вывод, что генератор сумел научиться создавать изображения, но при этом качество изображения еще далеко от оригинала. В сравнении с альтернативной генеративной сетью значения метрик PSNR и SSIM достаточно неплохи.

4.3 Результаты генератора В

$real(hr)$ – исходное реальное изображение высокого разрешения, lr – изображение низкого разрешения, $gen(hr)$ – результат работы сети генератора.



Рисунок 21 –Результат работы сети



Рисунок 22 –Результат работы сети



Рисунок 23 –Результат работы сети



Рисунок 24 –Результат работы сети

В таблице 3 представлены результаты хода обучения сети.

Таблица 3 – Результаты обучения генератора В

Epoch	D_loss	G_loss
0	0.073	1.06
99	$6.98 \cdot 10(-5)$	0.92
199	$2.09 \cdot 10(-5)$	0.83
299	$9.66 \cdot 10(-6)$	0.72
399	$4.05 \cdot 10(-6)$	0.63

Рассчитаем средние значения метрик PSNR и SSIM для полученных изображений. (Таблица 4).

Таблица 4 – Средние значения метрик PSNR и SSIM

Модель	PSNR	SSIM
SRGAN	26	0,87
GAN - A	27	0,70
GAN - B	28	0,73

По результатам сети можно сделать вывод, что генератор В сумел обучиться создавать изображения лучше, чем генератор А, к тому же можем заметить, что полученные результаты практически не содержат артефактов в сравнении с генератором А. В сравнении с альтернативной генеративной сетью значения метрик PSNR и SSIM получились соизмеримы.

4.4 Вывод

В данном разделе мы рассмотрели процесс обучения модели суперразрешения и представили полученные результаты. Обучение модели

для задачи суперразрешения является сложным и вычислительно интенсивным процессом, требующим больших объемов данных и высокой вычислительной мощности.

Представленные результаты демонстрируют эффективность и применимость моделей суперразрешения. Представленные модели способны повышать разрешение изображений и улучшать их визуальное качество, улучшая детализацию и реалистичность. Метрики, такие как PSNR и SSIM, использовались для количественной оценки качества восстановления, позволяя сравнивать различные методы и оптимизации модели.

Таким образом по показателям PSNR и SSIM можем сделать вывод, что модель с генератором В сумела обучиться лучше, чем модель с генератором А. Показатели метрик PSNR и SSIM у GAN-B получились выше, чем у GAN-A. К тому же, сгенерированные изображения у модели GAN-A получились более зернистыми.

Однако стоит отметить, что результаты обучения модели суперразрешения могут зависеть от множества факторов, включая размер и качество обучающего набора данных, выбранные архитектуры модели, оптимизатора и гиперпараметров. Настройка этих параметров требует тщательных экспериментов и подбора оптимальных значений.

5 РЕЗУЛЬТАТЫ ПРИМЕНЕНИЯ МЕТОДОВ УДАЛЕНИЯ АРТЕФАКТОВ НА СГЕНЕРИРОВАННЫХ ИЗОБРАЖЕНИЯХ

5.1 Примеры сгенерированных изображений

Как говорилось ранее на сгенерированных изображениях присутствуют различные артефакты. Следовательно, в этой главе к данным изображениям будут применены различные методы удаления артефактов для визуального улучшения качества изображения.



Рисунок 25 – Пример изображения высокого качества




Рисунок 26 – Сгенерированное изображение




Рисунок 27 – Примеры сгенерированных изображений

Как можно заметить на сгенерированные изображения выглядят зернистыми, поэтому в рамках данной работы необходимо визуально улучшить качество данных изображений.

5.2 Результаты медианного фильтра

Далее будут представлены результаты применения медианного фильтра на сгенерированное изображение.



Рисунок 28 – Результат медианного фильтра с ядром 3x3, 5x5, 7x7

На рисунке 28 видно, что при ядре 3x3 результат стал значительно лучше, чем исходное сгенерированное изображение. На лице девушки более не наблюдается постоянной зернистости. При ядре 5x5 видно, что зернистости на изображении уже не наблюдается и все переходы стали плавными. Ну и при ядре равным 7x7 Полученный результат получился чересчур сглаженным. Поэтому нельзя сказать, что полученный результат можно отнести к удачному.

Далее будут приведены другие результаты работы медианного фильтра с ядрами 3x3, 5x5, 7x7.



Рисунок 29 – Результат медианного фильтра с ядром 3x3, 5x5, 7x7



Рисунок 30 – Результат медианного фильтра с ядром 3x3, 5x5, 7x7



Рисунок 31 – Результат медианного фильтра с ядром 3x3, 5x5, 7x7

На всех приведенных примерах наиболее лучшим результатом можно выделить медианный фильтр с ядром 5x5.

5.3 Результаты фильтра Gaussian blur

Далее будут представлены результаты применения фильтра Gaussian Blur на сгенерированное изображение.

Рассмотрим в этот раз другое сгенерированное изображение.



Рисунок 32 – Результат гауссовского фильтра с ядром 3x3, 5x5, 7x7

На рисунке 32 видно, что при ядре 3x3 изображение стало немного гладким, но все равно наблюдается резкая зернистость в области головы и перьев. При ядре 5x5 полученный результат получился достаточно хорошим, но также можно наблюдать небольшую зернистость в области шеи курицы. Далее при ядре 7x7 можно видеть, что результат сложно отличить от предыдущего, но стоит отметить, что в данном опыте остаточное искаженное пятно, в левом нижнем углу стало меньше, то есть сглажено чуть лучше.

Далее будут приведены некоторые результаты гауссовского фильтра на других изображениях, приведенных ранее.



Рисунок 33 – Результат гауссовского фильтра с ядром 3x3, 5x5, 7x7




Рисунок 34 – Результат гауссовского фильтра с ядром 3x3, 5x5, 7x7



Рисунок 35 – Результат гауссовского фильтра с ядром 3x3, 5x5, 7x7

На всех приведенных примерах наиболее лучшим результатом можно выделить гауссовский фильтр с ядром 5x5.

5.4 Результаты двустороннего фильтра

Далее будут представлены результаты применения двустороннего фильтра на сгенерированное изображение.



Рисунок 36 – Результат двусторонней фильтрации с ядром 3x3, 5x5, 7x7

На рисунке 36 видно, что после применения двусторонней фильтрации с ядром 3x3 итоговое изображение осталось зернистым. с ядром 5x5, как можем заметить изображение не сильно изменилось от предыдущего, но тем не менее немного сгладилось, это заметно в области глаз собаки. С ядром 7x7 данное изображение получилось более сглаженным по отношению к предыдущим опытам, тем самым можно сделать вывод, что полученный результат двусторонней фильтрации визуально улучшил сгенерированное изображение.

Далее будут приведены пару результатов двусторонней фильтрации на других изображениях.



Рисунок 37 – Результат двусторонней фильтрации с ядром 3x3, 5x5, 7x7



Рисунок 38 – Результат двусторонней фильтрации с ядром 3x3, 5x5, 7x7



Рисунок 39 – Результат двусторонней фильтрации с ядром 3x3, 5x5, 7x7

На всех приведенных примерах наиболее лучшим результатом можно выделить гауссовский фильтр с ядром 7x7.

5.5 Результаты полносвязной нейронной сети

Далее рассмотрим результат работы полносвязной нейронной сети, которая обучалась улучшать качество изображения на фрагментах исходного изображения, которые были получены методом скользящего окна размером 3x3.




Рисунок 40 – Результаты обучения сети




Рисунок 41 – Результаты обучения сети



Рисунок 42 – Результаты обучения сети



Рисунок 43 – Результаты обучения сети

Как можно заметить, полученные результаты получились достаточно неплохими. На результатах выхода сети получились хорошо сглаженные изображения, на которых не заметны зернистые артефакты.

5.6 Результаты U-Net

В данном разделе будут представлены результаты работы нейронной сети U-Net.

На вход сети подавалось сгенерированное изображение, а в качестве желаемого выхода подавалось изображение высокого разрешения.



Рисунок 44 – Изображение высокого разрешения

На рисунке 44 представлено исходное изображение высокого разрешения, которое подавалось в качестве желаемого результата.



Рисунок 45 – Сгенерированное изображение

На рисунке 45 представлено сгенерированное изображение, которое подавалось на вход сети U-Net.

Далее рассмотрим результат работы сети, которая обучалась на 88 сгенерированных изображениях в течение 100 эпох.



Рисунок 46 – Результат сети U-Net

На рисунке 46 представлен результат работы сети U-Net, целью которой было научиться визуально улучшать сгенерированное изображение.

Как мы можем заметить, результат получился достаточно неплохим. С задачей устранения артефактов сеть U-Net справилась.

Далее будут представлены результаты работы сети U-Net.




Рисунок 47 – Результат сети U-Net




Рисунок 48 – Результат сети U-Net

По результатам мы можем заметить, что результаты сети U-Net получились достаточно неплохими, но появилась небольшая двойственность объектов. Это скорее всего связано с тем, что сеть недостаточно обучилась (всего 100 эпох), поэтому необходимо провести обучение на большем числе эпох.

Рассчитаем средние значения метрик PSNR и SSIM для изображений, полученных в результате обработки фильтрами и сетями улучшения качества изображений. (Таблица 5).

Таблица 5 – Средние значения метрик PSNR и SSIM

Модель	PSNR	SSIM
SRGAN	26	0,87
GAN - A	27	0,70
GAN - B	28	0,73
Медианный фильтр 3x3	13,8	0,70
Медианный фильтр 5x5	13,97	0,73
Медианный фильтр 7x7	13,93	0,68
Фильтр Гаусса 3x3	13,99	0,68
Фильтр Гаусса 5x5	14,09	0,76
Фильтр Гаусса 7x7	14,08	0,70
Двусторонний фильтр 3x3	13,6	0,70
Двусторонний фильтр 5x5	13,75	0,76
Двусторонний фильтр 7x7	13,84	0,69
Полносвязная нейросеть	28	0,85
U-Net	27	0,90

Как мы можем заметить применение сглаживающих фильтров позволило улучшить показатель структурного сходства изображений (SSIM), но при этом показатель отношения сигнала к шуму (PSNR) стал ниже это связано с тем, что сглаживание изображение привело к росту среднеквадратичной ошибки между сгенерированным и исходным изображением.

Также стоит отметить, что полносвязная нейронная сеть и U-Net показали очень хорошие результаты, а именно: показатель PSNR в обоих случаях не стал хуже, а показатель SSIM вырос на 15% в случае полносвязной сети, а результат U-Net стал лучше на 20%.

5.7 Вывод

В данном разделе мы исследовали результаты применения различных методов удаления артефактов на сгенерированных изображениях, полученных в результате процесса суперразрешения.

Были реализованы различные методами удаления артефактов, включая фильтрацию(медианный, гауссовский, двусторонний), постобработку при помощи полносвязной нейросети и сети U-Net. Использовались метрики, такие как PSNR и SSIM, для количественной оценки качества восстановленных изображений.

Представленные результаты показывают, что применение методов удаления артефактов может значительно улучшить визуальное качество сгенерированных изображений. Артефакты, такие как блоки и размытость, были успешно снижены, и восстановленные изображения стали более визуально приятными. Это подтверждается как качественной оценкой визуальных результатов, так и количественной оценкой метриками PSNR и SSIM.

При применении сглаживающих фильтров, очевидно, что показатель PSNR будет снижен, но при этом можно заметить прирост показателя SSIM.

Это связано с тем, что PSNR основывается на среднеквадратичной ошибке, которая растет при применении сглаживающих фильтров.

При это наилучшие показатели выдали полносвязная нейросеть и сеть U-Net, которые сумели повысить значение метрики PSNR, но и метрику SSIM. показатель SSIM вырос на 15% в случае полносвязной сети, а результат U-Net стал лучше на 20%.

Однако следует отметить, что каждый метод имеет свои ограничения и может быть эффективен только в определенных ситуациях. Выбор наиболее подходящего метода удаления артефактов зависит от типа артефактов, особенностей изображения и требований к конечному результату. Некоторые методы могут быть более эффективны при удалении определенных типов артефактов, в то время как другие методы могут быть более универсальными и применимыми к различным ситуациям.

**ЗАДАНИЕ ДЛЯ РАЗДЕЛА
«ФИНАНСОВЫЙ МЕНЕДЖМЕНТ, РЕСУРСОЭФФЕКТИВНОСТЬ И
РЕСУРСОСБЕРЕЖЕНИЕ»**

Студенту:

Группа	ФИО
8BM13	Монгуш Темир Валерьевич

Школа	ИШИТР	Отделение школы (НОЦ)	Отделение информационных технологий
Уровень образования	Магистратура	Направление/специальность	09.04.01 «Информатика и вычислительная техника»

Исходные данные к разделу «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение»:

1. <i>Стоимость ресурсов научного исследования (НИ): материально-технических, энергетических, финансовых, информационных и человеческих</i>	Стоимость ресурсов определялась по средней рыночной стоимости, в соответствии с окладами сотрудников организации.
2. <i>Нормы и нормативы расходования ресурсов</i>	Тариф электроэнергии 2,73 руб. за кВт/ч., 30% районный коэффициент.
3. <i>Используемая система налогообложения, ставки налогов, отчислений, дисконтирования и кредитования</i>	Коэффициент отчислений на уплату во внебюджетные фонды 30%

Перечень вопросов, подлежащих исследованию, проектированию и разработке:

1. <i>Оценка коммерческого и инновационного потенциала НТИ</i>	Провести предпроектный анализ
2. <i>Разработка устава научно-технического проекта</i>	Представить Устав научного проекта магистерской работы
3. <i>Планирование процесса управления НТИ: структура и график проведения, бюджет, риски и организация закупок</i>	Разработать план управления НТИ
4. <i>Определение ресурсной, финансовой, экономической эффективности</i>	Рассчитать сравнительную эффективность исследования

Перечень графического материала (с точным указанием обязательных чертежей):

1. Матрица сегментации рынка
2. Оценка конкурентоспособности технических решений
3. Матрица SWOT
4. Диаграмма Ганта
5. График проведения и бюджет НТИ
6. Реестр рисков проекта
7. Оценка ресурсной, финансовой эффективности НТИ

Дата выдачи задания для раздела по линейному графику

Задание выдал консультант:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОСГН ШБИП	Былова Татьяна Васильевна	К.Э.Н.		.

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
8BM13	Монгуш Темир Валерьевич		

6 ФИНАНСОВЫЙ МЕНЕДЖМЕНТ, РЕСУРСОЭФФЕКТИВНОСТЬ И РЕСУРСОСБЕРЕЖЕНИЕ

Разрабатываемый алгоритм направлен на увеличение разрешения изображения путем генерации нового изображения на основе изображения низкого разрешения. Целевым рынком для алгоритмов являются предприятия и компании, целью которых является получение высококачественных изображений. В качестве таких предприятий могут выступать больницы, геологи, разработчики игр и т.д.

Таким, образом целью раздела «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение» является определение перспективности и успешности научно-исследовательского проекта, разработка механизма управления и сопровождения конкретных проектных решений на этапе реализации.

Чтобы достичь поставленной цели необходимо решить задачи по организации работы над проектным решением, по планированию этапов разработки, оценить перспективность и коммерческий потенциал проекта, рассчитать бюджет, необходимый для реализации проекта, оценить финансовую и ресурсоэффективность проекта.

6.1 Оценка коммерческого потенциала и перспективности проведения научных исследований с позиции ресурсоэффективности и ресурсосбережения

6.1.1. Потенциальные потребители результатов исследования

На сегодняшний день цифровое изображение является самым популярным видом контента в мире. Цифровое изображение используется практически в любой сфере деятельности человека, поэтому вопрос качества получаемых изображений является первостепенным.

Разрабатываемый алгоритм — это технология, которая позволяет улучшать качество изображений, повышая их разрешение и детализацию.

Суперразрешение может быть полезно для печати изображений в крупном формате, отображения их на больших экранах или увеличения разрешения после обрезки или восстановления старинных изображений.

Технология суперразрешения также может пригодиться в разных сферах, где требуется улучшить качество изображений или видео. Например:

- **Наблюдение и безопасность:** суперразрешение может помочь обнаружить, идентифицировать и провести распознавание лиц на низкокачественных изображениях, полученных с камер видеонаблюдения.
- **Медицина:** получение высококачественных МРТ-изображений может быть сложным с точки зрения времени сканирования, пространственного охвата и отношения сигнал/шум. Суперразрешение может помочь улучшить эти параметры и повысить точность диагностики.
- **СМИ:** суперразрешение может помочь снизить затраты на сервера, так как медиаконтент может быть отправлен в низком разрешении и увеличен на лету.
- **Дистанционное зондирование Земли:** суперразрешение может помочь повысить разрешение спутниковых снимков и получить более детальную информацию о поверхности Земли, растительности, почвах, водных ресурсах.
- **Искусство и культура:** суперразрешение может помочь восстановить старые или поврежденные фотографии, картины, фильмы и игры.

Таблица 6 – Матрица сегментации рынка

Сегмент	Размер и сфера деятельности	Уровень осведомленности и заинтересованности	Готовность к оплате
1	Наблюдение и безопасность	Высокий	Высокая
2	Медицина	Высокий	Средняя
3	Зондирование Земли	Высокий	Средний
4	Искусство и культура	Высокий	Высокая
5	Частные лица	Средний	Низкий

В данном случае, наиболее прибыльными сегментами являются 1 и 4, так как они имеют большой объем рынка, высокий уровень осведомленности и заинтересованности в технологиях увеличения разрешения изображений и высокую готовность к оплате за нее.

6.1.2. Анализ конкурентных технических решений с позиции ресурсоэффективности и ресурсосбережения

Для оценки конкурентоспособности разработки проводится анализ существующих решений, по увеличению разрешения изображений. Для сравнительного анализа были выбраны:

- Adobe Super Resolution - простой инструмент, который позволяет удвоить линейное разрешение изображений (ширину и высоту) с помощью одного переключателя. Он работает только с RAW-файлами и сохраняет результаты в формате DNG. Adobe Super Resolution - входит в состав Adobe Camera Raw и Adobe Lightroom, которые доступны по подписке на Adobe Creative Cloud. Стоимость подписки зависит от плана и региона
- ON1 Resize AI - инструмент, который позволяет выбрать один из трех режимов: стандартный, AI или Genuine Fractals. Он работает с любыми форматами файлов и сохраняет результаты в том же формате. ON1 Resize AI - стоит 79,99 долларов США за постоянную лицензию или 149,99 долларов США за годовую подписку на ON1 Photo RAW, которая включает в себя Resize AI и другие продукты ON1.

Сравнение технических и экономических характеристик этих продуктов представлено в таблице 7. «Adobe Super Resolution» обозначен K1, а «ON1 Resize AI» - K2, собственная реализация – Ф.

Таблица 7 – Оценка конкурентных технических решений

Критерий оценки	Вес критерия	Баллы			Конкурентно-способность		
		Б _ф	Б _{к1}	Б _{к2}	К _ф	К _{к1}	К _{к2}
Технические критерии оценки ресурсоэффективности							
1. Удобство в эксплуатации	0,2	4	3	5	0,8	0,6	1
2. Цена	0,15	5	1	4	0,75	0,15	0,6
3. Потребность в ресурсах	0,2	5	5	5	1	1	1
4. Функциональные возможности	0,1	3	2	3	0,3	0,2	0,3
5. Быстродействие	0,1	5	5	4	0,5	0,5	0,4
6. Возможность доработки	0,15	5	2	4	0,75	0,3	0,6
7. Обслуживание после продажи	0,05	3	1	3	0,15	0,05	0,15
8. Предполагаемый срок эксплуатации	0,05	5	3	3	0,25	0,15	0,15
Итого	1	34	22	32	4,5	2,95	4,2

В результате выявленных знаний о конкурентах, необходимо обратить внимание на сильные стороны разрабатываемой технологии: цена, быстродействие, возможность доработки, предполагаемый срок эксплуатации.

Недостатками системы являются: функциональные возможности, обслуживание после продажи.

В результате анализа было установлено, что разрабатываемая технология является конкурентноспособной.

6.1.3. SWOT-анализ

В рамках данного анализа выявлены сильные и слабые стороны проекта, а также его возможности и угрозы (Таблица 8).

Таблица 8 – SWOT-анализ

	Сильные стороны проекта: С1. Уникальность С2. Функциональность С3. Большое количество отраслей для применения	Слабые стороны проекта: Сл1. Значительные временные и интеллектуальные затраты на реализацию; Сл2. Неопределенный срок выхода на рынок Сл3. Несовершенство технологий
--	---	---

Продолжение таблицы 8

Возможности: В1. Увеличение разрешения изображений; В2. Большой спрос на разработку; В3. Увеличение масштабов проекта.	Проект востребован и его необходимо предлагать большому количеству отраслей: здравоохранение, геология и разведка, наука, культура и искусство, отрасль кибер индустрии (игры, моделирование), IT-отрасль (блоги, статьи, СМИ).	С развитием вычислительных систем (видеокарт) на обработку изображений будет тратиться гораздо меньше времени, что позволяет ускорить процесс возможного выхода продукта на рынок; с повышением скорости обработки изображения снизится время, затрачиваемое на ожидание и анализ выходных данных, что позволяет снизить нагрузку на интеллектуальные ресурсы.
Угрозы: У1. Непредвиденные сбои в работы; У2. Отсутствие спроса на расширение разработки проекта в будущем; У3. Снижения конкурентоспособности на рынке; У4. Отказ от технической поддержки проекта после внедрения.	1. Сбои в работе можно исключить с помощью квалифицированного разработчика и предоставления лучших инструментов для решения проблемы; 2. Регулярный анализ рынка, ориентированный на технологии, позволяет удовлетворять потребности и требования клиентов.	1. Необходимо проводить разработку информационной технологии таким образом, чтобы технологии были более гибкими и легко восприимчивыми к изменениям. 2. Исследование новых технологий для дальнейшего расширения способов проектирования и разработки новых проектов по улучшению разрешения изображений.

6.1.4. Оценка готовности проекта к коммерциализации

Для оценки готовности проекта были определены показатели по вопросам в таблице 9. Оценка проводится по пятибалльной шкале. При оценке научного проекта: 1 балл – не проработано, 2 балла – проработка слабая, 3 балла – выполнено, качество посредственное, 4 балла – удовлетворительное качество, 5 баллов – качество подтверждено сторонним специалистом. При оценке знаний разработчика: 1 балл – не знаю, 2 балла – только теоретические знания, 3 балла – теоретические знания с практическими примерами, 4 балла – умею, практикую, 5 баллов – могу консультировать по вопросу.

Таблица 9 – Таблица оценки готовности научного проекта к коммерциализации

№ п/п	Наименование	Степень проработанности научного проекта	Уровень имеющихся знаний у разработчика
1	Определён имеющийся научно-технический задел	4	4
2	Определены перспективные направления коммерциализации научно-технического задела	3	3
3	Определены отрасли и технологии (товары, услуги) для представления на рынок	4	5
4	Определена товарная форма научно-технического задела для представления на рынок	2	2
5	Определены авторы и осуществлена охрана их прав	4	4
6	Проведена оценка стоимости интеллектуальной собственности	3	3
7	Проведены маркетинговые исследования рынков сбыта	3	3
8	Разработан бизнес-план коммерциализации научной разработки	3	3
9	Определены пути продвижения научной разработки на рынок	2	2
10	Разработана стратегия реализации научной разработки	4	4
11	Проработаны вопросы международного сотрудничества и выхода на зарубежный рынок	2	2
12	Проработаны вопросы использования инфраструктуры поддержки, получения льгот	1	1
13	Проработаны вопросы финансирования коммерциализации научной разработки	2	3
14	Имеется команда для коммерциализации научной разработки	3	3
15	Проработан механизм реализации научной разработки	4	4
ИТОГО		44	46

Таким образом, готовность научного проекта к коммерциализации средняя. Уровень имеющихся знаний у разработчика немного выше, но также находится в категории выше среднего. В дальнейшем необходимо проработать международное сотрудничества и выхода на зарубежный

рынок, вопросы использования инфраструктуры поддержки и получения льгот, вопросы финансирования коммерциализации научной разработки.

6.1.5. Методы коммерциализации результатов научно-технического исследования

Для коммерциализации объекта исследования и обоснования его целесообразности, были проработаны следующие методы коммерциализации научной разработки:

1) Реализация лицензий патента.

Передача интеллектуальной собственности в уставной капитал предприятия.

Выбраны два менее затратных метода коммерциализации.

6.2 Инициация проекта

Устав проекта:

1) Цели и результаты проекта

Целью проекта является реализация технологии увеличения разрешения изображения путем генерации изображения высокого разрешения на основе изображения низкого разрешения.

Для проекта были определены заинтересованные стороны. Заинтересованные стороны – это лица или организации, которые активно заинтересованы и/или могут быть как положительно, так и отрицательно затронуты в результате проекта. Заинтересованными сторонами проекта являются различные сферы деятельности:

- Разработчики
 - НИ ТПУ
 - Организации, занимающиеся изображениями высокого разрешения
- Организационная структура проекта

В таблице 10 отражена организационная структура, роль и функции каждого члена команды.

Таблица 10 – Рабочая группа

№ п/п	ФИО, основное место работы, должность	Роль в проекте	Функции	Трудозатраты, час.
1	Иванова Юлия Александровна, Томский политехнический университет, доцент	Руководитель	Заверение документов, определение направления развития проекта.	36
2	Монгуш Темир Валерьевич, Томский политехнический университет, магистр	Исполнитель	Разработка ПО, документирование результатов.	540

6.3 Планирование научно-исследовательских работ

6.3.1. План проекта

Для осуществления разработки, был сформирован ряд работ и назначены должности исполнителей для каждого этапа работы (Таблица 11).

Таблица 11 – Перечень этапов, работ и распределение исполнителей

Основные этапы	№ раб.	Содержание работ	Должность исполнителя
Формирование темы и цели разработки	1	Продумать идею и записать основные данные	Руководитель, Студент
Разработка технического задания	2	Подробное описание идеи	Руководитель, Студент
	3	Выявление функциональных блоков	Руководитель, Студент
	4	Определения содержания блоков	Руководитель, Студент
	5	Календарное планирование работ	Руководитель
Поиски подходов для решения	6	Поиск решения по каждому функциональному блоку	Студент
	7	Реализация найденного решения	Студент
	8	Тестирование	Студент
	9	Отладка: устранение ошибок и повторное тестирование блоков проекта	Студент

Продолжение таблицы 11

Обобщение и оценка результатов	10	Оценка эффективности полученных результатов	Руководитель, Студент
	11	Определение целесообразности проведения ОКР	Руководитель, Студент
Разработка технической документации и проектирование	12	Разработка графического материала по проекту	Студент
	13	Выбор проектируемой технологии	Руководитель, Студент
	14	Оценка эффективности информационной технологии	Руководитель, Студент
Тестирование	15	Тестирование	Студент
	16	Доработка	Студент
Оформление отчета по НИР	17	Составление пояснительной записки	Руководитель, Студент

Линейный график представляется в виде таблицы. (Таблица 12).

Таблица 12 – Временные показатели проведения научного исследования

Перечень работ	Исполнители работы	Длительность работ, дни
		T _{ki}
Придумать идею и записать основные данные, Р,С	Руководитель	3
	Студент	4
Подробное описание идеи. Р,С	Руководитель	4
	Студент	8
Выявление функциональных блоков. Р,С	Руководитель	3
	Студент	5
Определение содержания блоков. Р,С	Руководитель	4
	Студент	7
Календарное планирование работ. Р	Руководитель	3
Поиск решения по каждому функциональному блоку. С	Студент	18
Реализация найденного решения. С	Студент	41
Тестирование. С	Студент	10
Отладка: устранение ошибок и повторное тестирование проекта. С	Студент	10
Оценка эффективности полученных результатов. Р,С	Руководитель	3
	Студент	6
Определение целесообразности проведения ОКР. Р,С	Руководитель	4
	Студент	7
разработка диаграмм по проекту. С	Студент	4
Выбор проектируемой технологии. Р,С	Руководитель	2
	Студент	3
Оценка эффективности информационной технологии. Р,С	Руководитель	4
	Студент	7
Тестирование. С	Студент	7

Продолжение таблицы 12

Исправление ошибок, доработка интерфейса. С	Студент	8
Составление пояснительной записки. Р,С	Руководитель	4
	Студент	4
ИТОГО студент		147
ИТОГО Руководитель		31
ИТОГО		178

В виде диаграммы Ганта был составлен линейный график работ по проекту, в котором отражены даты начала и окончания, длительность и ответственных лиц по каждому этапу работ. График строился для максимального по длительности исполнения работ в рамках научно-исследовательского проекта с разбивкой по месяцам и декадам (10 дней) за период времени дипломирования. При этом работы на графике выделены различной штриховкой в зависимости от исполнителей, ответственных за ту или иную работу.



Рисунок 49 – Диаграмма Ганта

6.3.2. Бюджет научного исследования

Статьи, рассчитанные в предыдущих пунктах, сведены в таблице 13.

Таблица 13 – Итоговый бюджет НТИ

Статьи					
Варианты исполнения	Сырье и материалы, руб.	Специальное оборудование, руб.	Основная заработная плата, руб.	Отчисления на социальные нужды, руб.	Итого
1	6000	133000	375333,27	112600	626933,27
2	6000	151000	375333,27	112600	644933,27

Сырьё и материалы

Сырьем и материалами в нашем случае являются оплата за электричество и интернет. Тарифный план за свет 2 рубля 73 копейки за кВт, по приблизительным усредненным показателям, компьютер потребляет около 200 Вт. Оплата за интернет составляет 350 рублей. Траты на сырье и материалы за год составят **6 тысяч рублей.**

Специальное оборудование

Таблица 14 – Социальное оборудование

Вариант исполнения	Наименование	Общая стоимость, руб.
1	ПК	125000
	Операционная система Windows	8000
	Среда разработки	0
Итог:		133000
2	ПК	125000
	Операционная система Linux	0
	Среда разработки	26000
Итог:		151000

Основная заработная плата

Основная заработная плата ($Z_{\text{осн}}$) руководителя (лаборанта, инженера) от предприятия (при наличии руководителя от предприятия) рассчитывается по следующей формуле:

$$Z_{\text{осн}} = Z_{\text{дн}} \cdot T_p \quad (10)$$

где $Z_{\text{осн}}$ – основная заработная плата одного работника, руб.;

T_p – продолжительность работ, выполняемых научно-техническим работником, раб. дн. (таблица);

$Z_{\text{дн}}$ – среднедневная заработная плата работника, руб.

Среднедневная заработная плата рассчитывается по формуле:

$$Z_{\text{дн}} = \frac{Z_{\text{м}} \cdot M}{F_{\text{д}}} \quad (11)$$

где $Z_{\text{м}}$ – месячный должностной оклад работника, руб.;

M – количество месяцев работы без отпуска в течение года: 6-дневная неделя;

$F_{\text{д}}$ – действительный годовой фонд рабочего времени научно-технического персонала, рабочие дни (таблица 15).

Таблица 15 – Баланс рабочего времени

Показатели рабочего времени	Руководитель	Студент
Календарное число дней	365	365
Количество нерабочих дней		
- выходные дни	118	118
- праздничные дни		
Действительный годовой фонд рабочего времени	247	247

Месячный должностной оклад работника:

$$Z_{\text{м}} = Z_{\text{тс}} \cdot (1 + k_{\text{пр}} + k_{\text{д}}) \cdot k_{\text{р}} \quad (12)$$

где $Z_{\text{тс}}$ – заработная плата по тарифной ставке, руб.;

$k_{\text{пр}}$ – премиальный коэффициент, равный 0,3 (т.е. 30% от $Z_{\text{тс}}$);

$k_{\text{д}}$ – коэффициент доплат и надбавок составляет примерно 0,2 – 0,5 (в НИИ и на промышленных предприятиях – за расширение сфер обслуживания, за профессиональное мастерство, за вредные условия: 15-20 % от $Z_{\text{тс}}$);

$k_{\text{р}}$ – районный коэффициент, равный 1,3 (для Томска).

Для предприятий, не относящихся к бюджетной сфере, тарифная заработная плата (оклад) рассчитывается по тарифной сетке, принятой на данном предприятии. Расчёт основной заработной платы приведён в таблице 16.

Величина отчислений во внебюджетные фонды определяется исходя из следующей формулы:

$$Z_{\text{внеб}} = k_{\text{внеб}} \cdot (Z_{\text{осн}} + Z_{\text{доп}}) \quad (13)$$

где $k_{\text{внеб}}$ – коэффициент отчислений на уплату во внебюджетные фонды 30% (пенсионный фонд, фонд обязательного медицинского страхования и пр.).

Таблица 16 – Расчёт основной заработной платы

Исполнители	З _{тс} , руб	k _{нр}	k _д	k _р	З _м , руб	З _{дв} , руб	Т _р , раб. дн.	З _{осп} , руб	Отчисления в социальные внебюджетные фонды
Руководитель	34000	0,3	0,15	1,3	64090	2698,53	31	83654,32	25096,3
Студент	25000	0,3	0,15	1,3	47125	1984,21	147	291678,95	87503,7
Итого								375333,27	112600

6.3.3. Реестр рисков проекта

Риски проекта включают в себя различные неопределенные события, которые могут возникнуть в проекте и вызвать негативные последствия. Риски представлены в таблице 17.

Таблица 17 – Реестр рисков проекта

№	Риск	Потенциальное воздействие	Вероятность наступления (1-5)	Влияние риска (1-5)	Уровень риска*	Способы смягчения риска	Условия наступления
1	Несоответствие модели реальным показателям	Увеличение сроков разработки	2	4	Средний	Составление плана реализации проекта	Неверное планирование времени
2	Недостаток знаний не позволит создать продукт, отвечающий требованиям	Продукт ненадлежащего качества	2	5	Средний	Изучение специализированной литературы	Недостаток знаний у разработчика
3	Создание продукта, не соответствующего ожиданиям заказчика	Не востребованность системы	2	2	Низкий	Тщательное изучение требований и проектирование системы	Изменение требований к системе

6.4 Определение ресурсной, финансовой, бюджетной, социальной и экономической эффективности исследования

Сравнительная эффективность разработки выражается в интегральном показателе эффективности. Этот показатель состоит из двух средневзвешенных величин:

Определение интегральных показателей эффективности проведём в сравнении со вариантом исполнения 2.

Интегральный финансовый показатель разработки определяется как:

$$I_{\text{финр}}^{\text{исп.}i} = \frac{\Phi_{pi}}{\Phi_{\text{max}}} \quad (14)$$

где $I_{\text{финр}}^{\text{исп.}i}$ – интегральный финансовый показатель разработки;

Φ_{pi} – стоимость i -го варианта исполнения;

Φ_{max} – максимальная стоимость исполнения научно-исследовательского проекта.

Результаты вычислений приведены в таблице 18.

Таблица 18 – Расчёт интегрального финансового показателя

Вариант исполнения	Φ_{pi}	Φ_{max}	$I_{\text{финр}}^{\text{исп.}i}$
1	626933,27	644933,27	0,97
2	644933,27		1

Интегральный показатель ресурсоэффективности вариантов исполнения объекта исследования можно определить следующим образом:

$$I_{pi} = \sum a_i \cdot b_i \quad (15)$$

где I_{pi} – интегральный показатель ресурсоэффективности для i -го варианта исполнения разработки;

a_i – весовой коэффициент i -го варианта исполнения разработки;

b_i – бальная оценка i -го варианта исполнения разработки, устанавливается экспертным путем по выбранной шкале оценивания;

n – число параметров сравнения.

Расчёт показателя приведён в таблице 19.

Таблица 19 – Сравнительная оценка характеристик продуктов

Категория	Весовой коэффициент параметра	1 вариант	2 вариант
1. Надежность алгоритмов	0,3	4	5
2. Быстродействие	0,3	4	3
3. Удобство	0,1	4	4
4. Функциональность	0,2	3	4
5. Интерфейс	0,1	4	4
ИТОГО	1	3,8	4

Интегральный показатель эффективности вариантов исполнения разработки ($I_{исп.i.}$) определяется на основании интегрального показателя ресурсоэффективности и интегрального финансового показателя по формуле:

$$I_{исп.1} = \frac{I_{p-исп1}}{I_{финр}^{исп.1}}, \quad I_{исп.1} = \frac{I_{p-исп1}}{I_{финр}^{исп.1}} \text{ и т.д.} \quad (16)$$

Сравнение интегрального показателя эффективности вариантов исполнения разработки позволит определить сравнительную эффективность проекта (Таблица 20) и выбрать наиболее целесообразный вариант из предложенных.

Таблица 20 – Расчёт интегрального показателя эффективности

	$I_{финр}^{исп.i}$	$I_{p-исп}$	$I_{исп}$
1 вариант	0,97	3,8	3,9
2 вариант	1	4	4

Сравнительную эффективность проекта определим по следующей формуле:

$$\mathcal{E}_{cp} = \frac{I_{исп.1}}{I_{исп.2}} \text{.} \quad (17)$$

где $\mathcal{E}_{cp}$ – сравнительная эффективность проекта;

$I_{исп.1}$ – интегральный показатель первого варианта исполнения разработки, описанной в ВКР;

$I_{исп.2}$ – интегральный показатель второго варианта исполнения, описанной в ВКР.

$$\mathcal{E}_{cp} = \frac{3,9}{4} = 0.975$$

Таким образом сравнительная эффективность проекта с вариантом разработки номер 2 составила 0.975. Отсюда следует что вариант разработки номер 2 является предпочтительным в плане эффективности, но разрабатываемая технология не сильно уступает в эффективности.

6.5 Вывод

Для определения эффективности были выполнены следующие задачи:

- определен целевой рынок проекта;
- построена карта сегментирования;
- выявлены ниши на рынке услуг, незанятые конкурентами или где уровень конкуренции низок;
- произведен SWOT-анализа, в ходе которого были рассмотрены слабые и сильные стороны разработки инструментария;
- выявлены возможные перспективы его создания и рассмотрены варианты минимизации влияния угроз, которые могут этому помешать.

Для повышения эффективности работы необходимо минимизировать ошибки, контролировать процесс создания и проверять работу информационной технологии в соответствии с поставленными требованиями.

Также была определена трудоемкость проекта, которая составила 147 дней для студента. На основании трудоемкости была построена диаграмма Ганта.

Была рассчитана сравнительная эффективность проекта с вариантом разработки номер 2, которая составила 0.975. Отсюда следует что вариант разработки номер 2 является предпочтительным в плане эффективности, но разрабатываемая технология не сильно уступает в эффективности

ЗАДАНИЕ ДЛЯ РАЗДЕЛА «СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ»

Студенту:

Группа	ФИО
8BM13	Монгуш Темир Валерьевич

Тема магистерской диссертации: «Алгоритм повышения пространственного разрешения изображений на основе генеративно-состязательной сети»

Школа	ИШИТР	Отделение школы (НОЦ)	Отделение информационных технологий
Уровень образования	Магистратура	Направление/специальность	09.04.01 «Информатика и вычислительная техника»

Исходные данные к разделу «Социальная ответственность»

1. Характеристика объекта исследования (вещество, материал, прибор, алгоритм, методика, рабочая зона) и области его применения

Увеличение пространственного разрешения изображения с использованием методов глубокого обучения. Увеличение разрешения изображения путем генерации изображения высокого разрешения на основе изображения низкого разрешения.

Перечень вопросов, подлежащих исследованию, проектированию и разработке:

1. Производственная безопасность:

1.1. Анализ выявленных вредных факторов

- Природа воздействия
- Действие на организм человека
- Нормы воздействия и нормативные документы (для вредных факторов)
- СИЗ коллективные и индивидуальные

1.2. Анализ выявленных опасных факторов

- Термические источники опасности
- Электробезопасность
- Пожаробезопасности

1. Вредные факторы:

- 1.1. Нарушения микроклимата, оптимальные и допустимые параметры;
- 1.2. Шум, ПДУ, СКЗ, СИЗ;
- 1.3. Повышенный уровень электромагнитного излучения, ПДУ, СКЗ, СИЗ;
- 1.4. Недостаточная освещенность; Проведен расчет освещения рабочего места; представлен рисунок размещения светильников на потолке с размерами в системе СИ;
2. Опасные факторы:
- 2.1. Электроопасность; класс электроопасности помещения, безопасные номиналы I, U, R_{заземления}, СКЗ, СИЗ;
- 2.2. Пожароопасность, категория пожароопасности помещения, марки огнетушителей, их назначение и ограничение применения; Приведена схема эвакуации.

1. Экологическая безопасность: - Выбросы в окружающую среду - Решения по обеспечению экологической безопасности	Наличие промышленных отходов (бумага-черновики, перегоревшие люминесцентные лампы, оргтехника) и способы их утилизации;
3. Безопасность в чрезвычайных ситуациях: 1.перечень возможных ЧС при разработке и эксплуатации проектируемого решения; 2.разработка превентивных мер по предупреждению ЧС; 3.разработка действий в результате возникшей ЧС и мер по ликвидации её последствий.	Рассмотрены 2 ситуации ЧС: 1) природная – сильные морозы зимой, (аварии на электро-, тепло-коммуникациях, водоканале, транспорте); 2) техногенная – несанкционированное проникновение посторонних на рабочее место (возможны проявления вандализма, диверсии, промышленного шпионажа), представлены мероприятия по обеспечению устойчивой работы производства в том и другом случае.
4.Перечень нормативно-технической документации.	– ГОСТы, СанПиНы, СНиПы

Дата выдачи задания для раздела по линейному графику	
--	--

Задание выдал консультант:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор ООД ШБИП	Федорчук Юрий Митрофанович.	д.т.н.		

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
8ВМ13	Монгуш Темир Валерьевич		

7 СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ

Проект, разработанный в рамках исследовательской работы, направлен на увеличение пространственного разрешения изображения с использованием методов глубокого обучения, а именно увеличение разрешения изображения путем генерации изображения высокого разрешения на основе изображения низкого разрешения. Сферы применения разработки: от нужд обычных пользователей до специализированных задач. Взаимодействие пользователя с разработанной программой производится с помощью программных и аппаратных средств ПЭВМ, а также с помощью периферийных устройств, подключенных к ПЭВМ.

Данный раздел посвящен анализу вредных и опасных факторов производственной среды для операторов ПЭВМ, а также разработке программ по минимизации воздействия вредоносного и опасного влияния, снижению вредных воздействий на окружающую среду и защите в чрезвычайных ситуациях.

Выпускная квалификационная работа студента выполнялась в домашних условиях, по месту проживания.

7.1 Производственная безопасность

7.1.1. Вредные производственные факторы

7.1.1.1. Отклонение показателей микроклимата в помещении

Проанализируем микроклимат в помещении, где находится рабочее место. Микроклимат производственных помещений определяют следующие параметры: температура, относительная влажность, скорость движения воздуха. Эти факторы влияют на организм человека, определяя его самочувствие.

Оптимальные параметры микроклимата на рабочих местах должны соответствовать величинам, приведенным в таблице 21 и таблице 22.

Таблица 21 – Оптимальные нормы микроклимата

Период года	Температура воздуха, С°	Относительная влажность воздуха, %	Скорость движения воздуха, м/с
Холодный	19-23	40-60	0.1
Теплый	23-25		0.2

Таблица 22 – Допустимые нормы микроклимата

Период года	Температура воздуха, С°		Относительная влажность воздуха, %	Скорость движения воздуха, м/с
	Нижняя допустимая граница	Верхняя допустимая граница		
Холодный	15	24	20-80	<0.5
Теплый	22	28	20-80	<0.5

Общая площадь рабочего помещения составляет 21м², объем составляет 74,5м³. По СанПиН 2.2.2/2.4.1340-03 санитарные нормы составляют 6,5 м² и 20 м³ объема на одного человека. Исходя из приведенных выше данных, можно сказать, что количество рабочих мест соответствует размерам помещения по санитарным нормам.

После анализа габаритных размеров рассмотрим микроклимат в этой комнате. В качестве параметров микроклимата рассмотрим температуру, влажность воздуха, скорость ветра.

В помещении осуществляется естественная вентиляция посредством наличия легко открываемого оконного проема (форточки), а также дверного проема. По зоне действия такая вентиляция является общеобменной. Основным недостаток – приточный воздух поступает в помещение без предварительной очистки и нагревания. Согласно нормам, СанПиН 2.2.2/2.4.1340-03 объем воздуха необходимый на одного человека в помещении без дополнительной вентиляции должен быть более 40м³. В

нашем случае объем воздуха на одного человека составляет $37,25\text{м}^3$, из этого следует, что дополнительная вентиляция требуется. Параметры микроклимата поддерживаются в холодное время года за счет систем водяного отопления с нагревом воды до 100°C , а в теплое время года – за счет кондиционирования, с параметрами согласно. Нормируемые параметры микроклимата, ионного состава воздуха, содержания вредных веществ должны соответствовать требованиям.

7.1.1.2. Превышение уровней шума

Одним из наиболее распространенных в производстве вредных факторов является шум. Он создается вентиляционным и рабочим оборудованием, преобразователями напряжения, рабочими лампами дневного света, а также проникает снаружи. Шум вызывает головную боль, усталость, бессонницу или сонливость, ослабляет внимание, память ухудшается, реакция уменьшается.

Основным источником шума в комнате являются компьютерные охлаждающие вентиляторы и. Уровень шума варьируется от 35 до 42 дБА. Согласно СанПиН 2.2.2 / 2.4.1340-03, при выполнении основных работ на ПЭВМ уровень шума на рабочем месте не должен превышать 80 дБА.

При значениях выше допустимого уровня необходимо предусмотреть средства индивидуальной защиты (СИЗ) и средства коллективной защиты (СКЗ) от шума.

Средства коллективной защиты:

1. устранение причин шума или существенное его ослабление в источнике образования;
2. изоляция источников шума от окружающей среды (применение глушителей, экранов, звукопоглощающих строительных материалов, например любой пористый материал – шамотный кирпич, микропористая резина, поролон и др.);

3. применение средств, снижающих шум и вибрацию на пути их распространения;

Средства индивидуальной защиты;

1. применение спецодежды и защитных средств органов слуха: наушники, беруши, антифоны.

7.1.1.3. Повышенный уровень электромагнитных излучений

Источником электромагнитных излучений в нашем случае являются дисплеи ПЭВМ. Монитор компьютера включает в себя излучения рентгеновской, ультрафиолетовой и инфракрасной области, а также широкий диапазон электромагнитных волн других частот.

Согласно СанПиН 2.2.2/2.4.1340-03 напряженность электромагнитного поля по электрической составляющей на расстоянии 50 см вокруг ВДТ не должна превышать 25В/м в диапазоне от 5Гц до 2кГц, 2,5В/м в диапазоне от 2 до 400кГц [38]. Плотность магнитного потока не должна превышать в диапазоне от 5 Гц до 2 кГц 250нТл, и 25нТл в диапазоне от 2 до 400кГц. Поверхностный электростатический потенциал не должен превышать 500В [38].

В ходе работы использовалась ПЭВМ типа ASUS GL703VD со следующими характеристиками: напряженность электромагнитного поля 3В/м; поверхностный потенциал составляет 560 В (основы противопожарной защиты предприятий ГОСТ 12.1.004 и ГОСТ 12.1.010 – 76.)[37].

При длительном постоянном воздействии электромагнитного поля (ЭМП) радиочастотного диапазона при работе на ПЭВМ у человеческого организма сердечно-сосудистые, респираторные и нервные расстройства, головные боли, усталость, ухудшение состояния здоровья, гипотония, изменения сердечной мышцы проводимости. Тепловой эффект ЭМП характеризуется увеличением температуры тела, локальным селективным нагревом тканей, органов, клеток за счет перехода ЭМП на теплую энергию.

Предельно допустимые уровни (ПДУ) облучения (по ОСТ 54 30013-83):

- а) до 10 мкВт./см², время работы (8 часов);
- б) от 10 до 100 мкВт/см², время работы не более 2 часов;
- в) от 100 до 1000 мкВт/см², время работы не более 20 мин. при условии пользования защитными очками;
- г) для населения в целом ППМ не должен превышать 1 мкВт/см².

Защита человека от опасного воздействия электромагнитного излучения осуществляется следующими способами:

Средства коллективной защиты (СКЗ):

1. защита временем;
2. защита расстоянием;
3. снижение интенсивности излучения непосредственно в самом источнике излучения;
4. заземление экрана вокруг источника;
5. защита рабочего места от излучения.

Средства индивидуальной защиты (СИЗ):

1. Очки и специальная одежда, выполненная из металлизированной ткани (кольчуга). При этом следует отметить, что использование СИЗ возможно при кратковременных работах и является мерой аварийного характера. Ежедневная защита обслуживающего персонала должна обеспечиваться другими средствами.
2. Вместо обычных стекол используют стекла, покрытые тонким слоем золота или диоксида олова (SnO₂).

7.1.1.4. Недостаточная освещенность рабочей зоны

Для обеспечения требуемой освещенности необходимо использовать совмещенное освещение, создаваемое сочетанием естественного и искусственного освещения. При данном этапе развития осветительной техники целесообразно использовать люминесцентные лампы, которые по сравнению с лампами накаливания имеют большую светотдачу на ватт потребляемой мощности и более естественный спектр.

Минимальный уровень средней освещенности на рабочих местах с постоянным пребыванием людей должен быть не менее 200 лк.

В расчётном задании должны быть решены следующие вопросы:

- выбор системы освещения;
- выбор источников света;
- выбор светильников и их размещение;
- выбор нормируемой освещённости;
- расчёт освещения методом светового потока.

В данном расчётном задании для всех помещений рассчитывается общее равномерное освещение.

Таблица 23 – Параметры помещения

Параметр	Обозначение	Значение, м
Длина	A	7
Ширина	B	3
Высота помещения	H	3,5
Свес	h_c	0,4
Высота Р.П.	h_{rp}	0,8
Высота от светильника до Р.П.	h	$H - h_{rp} - h_c$
Коэффициент отражения стен	$\rho_{ст}$	70 %
Коэффициент отражения потолка	$\rho_{п}$	70
Коэффициент запаса	Kз	1.5
Коэффициент неравномерности	Z	1.1

Расчёт общего равномерного искусственного освещения горизонтальной рабочей поверхности выполняется методом коэффициента светового потока, учитывающим световой поток, отражённый от потолка и стен.

Световой поток лампы определяется по формуле:

$$\Phi_{\text{рас}} = \frac{E_{\text{н}} * S * K_3 * Z}{N * \eta} \quad (18)$$

Где $E_{\text{н}}$ – нормируемая минимальная освещённость по СНиП 23-05-95, лк; S – площадь освещаемого помещения, м^2 ; K_3 – коэффициент запаса, учитывающий загрязнение светильника (источника света, светотехнической арматуры, стен и пр., т. е. отражающих поверхностей), наличие в атмосфере цеха дыма, пыли; Z – коэффициент неравномерности освещения, отношение $E_{\text{ср}}/E_{\text{min}}$. Для люминесцентных ламп при расчётах берётся равным 1,1; N – число ламп в помещении; η – коэффициент использования светового потока.

Коэффициент использования светового потока показывает, какая часть светового потока ламп попадает на рабочую поверхность. Он зависит от индекса помещения i , типа светильника, высоты светильников над рабочей поверхностью h и коэффициентов отражения стен $\rho_{\text{с}}$ и потолка $\rho_{\text{п}}$.

Индекс помещения определяется по формуле:

$$i = S / h (A + B) \quad (19)$$

Проведем расчет индекса помещения:

Площадь помещения:

$$S = A * B = 7 * 3 = 21 \text{ м}^2$$

Индекс:

$$i = \frac{S}{h * (A + B)} = \frac{21}{(3,5 - 0,8 - 0,4) * (7 + 3)} = 0,91$$

Согласно этим данным, коэффициент использования светового потока будет равен 43 % или в долях = 0,43.

Коэффициенты отражения оцениваются субъективно (табл. 4.10) [БЖД Практикум 2009-2020].

Согласно указанной методике, выбираем тип источника света.

Наиболее подходящим вариантом является 40 ваттная лампа ЛБ, у которой $\Phi=2800$ лм. Для выбранного типа лампы подходит светильник ОД-2-40 с размерами: длина = 1230 мм, ширина = 266 мм.

Количество ламп для помещения:

$$N = \frac{E_H * S * K_3 * Z}{\Phi * \eta} = \frac{200 * 21 * 1,5 * 1,1}{2800 * 0,43} = 5,2$$

Принимаем $N=6$ ламп или 3 светильника.

Размещаем светильники в 1 ряд в ряду с соблюдением условий: L – расстояние между соседними светильниками или рядами (если по длине (А) и ширине (В) помещения расстояния различны, то они обозначаются L_A и L_B), l – расстояние от крайних светильников или рядов до стены.

Оптимальное расстояние l от крайнего ряда светильников до стены рекомендуется принимать равным $L/3$.

Сначала определим световой поток расчетный.

$$\Phi = \frac{E_H * S * K_3 * Z}{N * \eta} = \frac{200 * 21 * 1,5 * 1,1}{6 * 0,43} = 2686 \text{ лм}$$

$$\Phi = \frac{E_H * S * K_3 * Z}{N * \eta} = \frac{200 * 42 * 1,5 * 1,1}{12 * 0,48} = 2406 \text{ лм};$$

Теперь определим расстояния между светильниками по длине помещения.

$$7000 = 2 * L_A + 3 * 1230 + \frac{2}{3} * L_A;$$

$$L_A = (7000 - 3690) * \frac{3}{8} = 1241 \text{ мм};$$

$$\frac{L_A}{3} = 414 \text{ мм};$$

Так как у нас всего один ряд светильников, то установим их по середине ширины.

$$3000 = 2l + 266;$$

$$l = (3000 - 266) * \frac{1}{2} = 1367 \text{ мм};$$

Рисуем схему размещения светильников на потолке для обеспечения общего равномерного освещения.




Рисунок 50 – План размещения светильников на потолке

Проведем проверку выполнения условия соответствия:

$$-10\% \leq \frac{\Phi_{\text{л.станд}} - \Phi_{\text{л.расч}}}{\Phi_{\text{л.станд}}} * 100\% \leq 20\%$$

$$-10\% \leq \frac{2800 - 2686}{2800} * 100\% \leq 20\%$$

$$-10\% \leq 14\% \leq 20\%$$

Результат расчета укладывается в поле допуска.

Определим мощность осветительной установки:

$$P = N * P_i = 6 * 40 = 240 \text{ Вт}$$

7.1.2. Опасные производственные факторы

7.1.2.1. Поражение электрическим током

К опасным факторам можно отнести наличие в помещении большого количества аппаратуры, использующей однофазный электрический ток напряжением 220 В и частотой 50Гц. По опасности электропоражения комната относится к помещениям без повышенной опасности, так как отсутствует повышенная влажность, высокая температура, токопроводящая пыль и возможность одновременного соприкосновения токоведущих элементов с заземленными металлическими корпусами оборудования [38].

Лаборатория относится к помещению без повышенной опасности поражения электрическим током. Безопасными номиналами являются: $I < 0,1$ А; $U < (6-42)$ В; $R_{\text{зазем}} < 4$ Ом.

Для защиты от поражения электрическим током используют СКЗ и СИЗ.

Средства коллективной защиты:

1. защитное заземление, зануление;
2. малое напряжение;
3. электрическое разделение сетей;
4. защитное отключение;
5. изоляция токоведущих частей;
6. оградительные устройства.

Использование щитов, барьеров, клеток, ширм, а также заземляющих и шунтирующих штанг, специальных знаков и плакатов.

Средства индивидуальной защиты:

1. диэлектрические перчатки, изолирующие клещи и штанги;
2. слесарные инструменты с изолированными рукоятками;
3. указатели величины напряжения, калоши, боты, подставки и коврики.

7.1.2.2. Пожароопасность

По взрывопожарной и пожарной опасности помещения подразделяются на категории А, Б, В1-В4, Г и Д.

Согласно НПБ 105-03 учебная комната относится к категории В – горючие и трудно горючие жидкости, твердые горючие и трудно горючие вещества и материалы, вещества и материалы, способные при взаимодействии с водой, кислородом воздуха или друг с другом только гореть, при условии, что помещения, в которых находится, не относятся к категории наиболее опасных А или Б.

По степени огнестойкости данное помещение относится к 1-й степени огнестойкости по СНиП 2.01.02-85 (выполнено из кирпича, которое относится к трудносгораемым материалам).

Возникновение пожара при работе с электронной аппаратурой может быть по причинам как электрического, так и неэлектрического характера.

Причины возникновения пожара неэлектрического характера:

а) халатное неосторожное обращение с огнем (курение, оставленные без присмотра нагревательные приборы, использование открытого огня);

Причины возникновения пожара электрического характера: короткое замыкание, перегрузки по току, искрение и электрические дуги, статическое электричество и т. п.

Для локализации или ликвидации загорания на начальной стадии используются первичные средства пожаротушения. Первичные средства пожаротушения обычно применяют до прибытия пожарной команды.

Огнетушители водо-пенные (ОХВП-10) используют для тушения очагов пожара без наличия электроэнергии. Углекислотные (ОУ-2) и порошковые огнетушители предназначены для тушения электроустановок, находящихся под напряжением до 1000В. Для тушения токоведущих частей

и электроустановок применяется переносной порошковый огнетушитель, например ОП-5.

В общественных зданиях и сооружениях на каждом этаже должно размещаться не менее двух переносных огнетушителей. Огнетушители следует располагать на видных местах вблизи от выходов из помещений на высоте не более 1,35 м. Размещение первичных средств пожаротушения в коридорах, переходах не должно препятствовать безопасной эвакуации людей.

Для предупреждения пожара и взрыва необходимо предусмотреть:

1. специальные изолированные помещения для хранения и разлива легковоспламеняющихся жидкостей (ЛВЖ), оборудованные приточно-вытяжной вентиляцией во взрывобезопасном исполнении - соответствии с ГОСТ 12.4.021-75 и СНиП 2.04.05-86;
2. специальные помещения (для хранения в таре пылеобразной канифоли), изолированные от нагревательных приборов и нагретых частей оборудования;
3. первичные средства пожаротушения на производственных участках (передвижные углекислые огнетушители ГОСТ 9230-77, пенные огнетушители ТУ 22-4720-80, ящики с песком, войлок, кошма или асбестовое полотно);
4. автоматические сигнализаторы (типа СВК-3 М 1) для сигнализации о присутствии в воздухе помещений предвзрывных концентраций горючих паров растворителей и их смесей.

Лаборатория полностью соответствует требованиям пожарной безопасности, а именно, наличие охранно-пожарной сигнализации, плана эвакуации, изображенного на рисунке 46, порошковых огнетушителей с поверенным клеймом, табличек с указанием направления к запасному (эвакуационному) выходу.



Рисунок 51 – План эвакуации. сплошные линии — основной выход, штриховые линии — запасный выход.

7.2 Экологическая безопасность

В компьютерах огромное количество компонентов, которые содержат токсичные вещества и представляют угрозу, как для человека, так и для окружающей среды.

К таким веществам относятся:

- свинец (накапливается в организме, поражая почки, нервную систему);
- ртуть (поражает мозг и нервную систему);
- никель и цинк (могут вызывать дерматит);
- щелочи (прожигают слизистые оболочки и кожу);

Поэтому компьютер требует специальных комплексных методов утилизации.

Таким образом утилизацию компьютера можно провести следующим образом:

- отделить металлические детали от неметаллов;
- разделить углеродистые металлы от цветмета;

- пластмассовые изделия (крупногабаритные) измельчить для уменьшения объема;
- копир-порошок упаковать в отдельную упаковку, точно также, как и все проклассифицированные и измельченные компоненты оргтехники, и после накопления на складе транспортных количеств отправить предприятиям и фирмам, специализирующимся по переработке отдельных видов материалов.

Люминесцентные лампы утилизируют следующим образом. Не работающие лампы немедленно после удаления из светильника должны быть упакованы в картонную коробку, бумагу или тонкий мягкий картон, предохраняющий лампы от взаимного соприкосновения и случайного механического повреждения. После накопления ламп объемом в 1 транспортную единицу их сдают на переработку на соответствующее предприятие. Недопустимо выбрасывать отработанные энергосберегающие лампы вместе с обычным мусором, превращая его в ртутьсодержащие отходы, которые загрязняют ртутными парами

7.3 Безопасность в чрезвычайных ситуациях

Природная чрезвычайная ситуация – обстановка на определенной территории или акватории, сложившейся в результате возникновения источника природной чрезвычайной ситуации, который может повлечь или повлек за собой человеческие жертвы, ущерб здоровью людей и (или) окружающей природной среде, значительные материальные потери и нарушение условий жизнедеятельности людей.

Производство находится в городе Томске с континентально-циклоническим климатом. Природные явления (землетрясения, наводнения, засухи, ураганы и т. д.), в данном городе отсутствуют.

Возможными ЧС на объекте в данном случае, могут быть сильные морозы и диверсия (вандализм, хулиганство, шпионаж).

Для Сибири в зимнее время года характерны морозы. Достижение критически низких температур приводит к авариям систем тепло- и водоснабжения, сантехнических коммуникаций и электроснабжения, приостановке работы. В этом случае при подготовке к зиме следует предусмотреть

- а) газобаллонные калориферы (запасные обогреватели);
- б) дизель или бензоэлектрогенераторы;
- в) запасы питьевой и технической воды на складе (не менее 30 л на 1 человека);
- г) теплый транспорт для доставки работников на работу и с работы домой в случае отказа муниципального транспорта. Их количества и мощности должно хватать для того, чтобы работа на производстве не прекратилась.

В лаборатории кибернетического центра наиболее вероятно возникновение чрезвычайных ситуаций (ЧС) техногенного характера.

Для предупреждения вероятности осуществления вышесказанных диверсии предприятие необходимо оборудовать системой видеонаблюдения, круглосуточной охраной, пропускной системой, надежной системой связи, а также исключения распространения информации о системе охраны объекта, расположении помещений и оборудования в помещениях, системах охраны, сигнализаторах, их местах установки и количестве. Должностные лица раз в полгода проводят тренировки по отработке действий на случай экстренной эвакуации.

7.4 Вывод

В результате выполнения работы были рассмотрены основные вопросы обеспечения безопасности для оператора, работающего за персональным компьютером.

Также были выявлены факторы, которые влияют на производственную безопасность.

Также необходимо тщательно следить за микроклиматом рабочего пространства, следить за температурой рабочего помещения и своевременно проветривать.

Обеспечить необходимую освещенность, для того чтобы избавиться от повышенной или недостаточной яркости света, бликов и всевозможных мерцаний.

В процессе работы необходимо сортировать и разделять бытовой мусор, который остается после выполнения работ. А отходы, не подлежащие переработке, должны быть утилизированы в соответствии с их требованиями по утилизации, для предотвращения неблагоприятных воздействий на экологическую среду.

В случаях непредвиденных ситуаций следует не паниковать и выполнять все необходимые требования в зависимости от чрезвычайной ситуации.

Для предотвращения возгорания на рабочем месте необходимо своевременно производить проверку качества электрических проводов и совершенно устранять возникающие проблемы.

Таким образом, для внедрения на производство деятельности данного рода не требуется больших затрат. Так как основная производственная деятельность проходит за персональным компьютером.

ЗАКЛЮЧЕНИЕ

В работе приведён обзор методов для получения изображения высокого разрешения и возможность постобработки полученных результатов для улучшения полученного результата. Каждый из методов обладает своими уникальными особенностями. Некоторые методы не требуют, по сути, никаких данных для обучения кроме самого деградировавшего изображения. Все рассмотренные модели обладают высокой производительностью, и хорошо себя показывают в рамках решения задачи увеличения разрешения, показывая отличные результаты при вычислении различных метрик оценки производительности моделей. Наиболее интересным показался подход, связанный с остаточными блоками обработки изображения во множестве пространственных разрешений, способных обмениваться информацией друг с другом.

В работе было реализовано две модели для повышения разрешения изображения при помощи генеративно-сопоставительной сети. Первая модель основана на архитектуре генератора с остаточными блоками с пакетной нормализацией данных, а во второй модели генератор основан на архитектуре остаточных блоков внутри остаточных блоков без пакетной нормализации данных. Результаты показали, что генеративно-сопоставительные сети имеют существенный недостаток – их очень сложно обучать. Поэтому для получения хороших результатов необходимо провести достаточно большее число эпох обучения. Изображения, полученные на выходе двух генераторов, получились, на человечески глаз, достаточно неплохими, хоть и содержат различные артефакты в виде зернистости и пятен. Для оценки качества изображений были рассчитаны метрики PSNR и SSIM, которые показали, что обученные модели конкурентоспособны с аналогом SRGAN.

Также в ходе работы были рассмотрены различные методы по удалению артефактов на сгенерированном изображении. Рассмотрены сглаживающие фильтры: медианный, гауссовский, двусторонний. Также были реализованы нейронные сети: полносвязная сеть, которая обучалась

улучшать изображения по фрагментам сгенерированного изображения и соответствующими фрагментами высококачественного изображения, сеть U-Net, которая должна была обучиться улучшать изображение на подобие высококачественного изображения.

В каждом опыте можно выделить свои конфигурации, которые позволили наилучшим образом улучшить визуальное качество изображения. По полученным результатам наилучший результат показала сеть U-Net.

Был проведен анализ финансовой и ресурсной эффективности рассматриваемого проекта, который показал, что проект конкурентоспособен и эффективен в коммерциализации.

Выявлены возможные негативные факторы, которые могут возникнуть во время производства, и пути их решения.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Yang J., Huang T. Image super-resolution: Historical overview and future challenges // Citeseerx [Электронный ресурс]. URL: <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.309.1145&rep=rep1&type=pdf> (дата обращения: 21.04.2023).
2. Рабаи Ж. М., Чандракасан А., Николич Б. Цифровые интегральные схемы. Методология проектирования = Digital Integrated Circuits / пер. с англ. — 2-е изд. — М.: «Вильямс», 2007. — 912 с. — ISBN 0-13-090996-3.
3. Интерполяция и дискретизация, зачем они нужны при проективном преобразовании изображения? // Habr [Электронный ресурс]. URL: <https://habr.com/ru/company/smartengines/blog/500576/> (дата обращения: 09.01.2022).
4. Chen L.-C., Papandreou G. Rethinking Atrous Convolution for Semantic Image Segmentation // google inc., 2017. — 14 с.
5. Pan X., Zhan X., Dai B., Lin D., Loy C.C., Luo P. Exploiting Deep Generative Prior for Versatile Image Restoration and Manipulation // arxiv [Электронный ресурс]. URL: <https://arxiv.org/abs/2003.13659>. [дата обращения: 22.04.2023].
6. Zamir S.W., Arora A., Khan S., Hayat M., Khan F.S., Yang M.-H., Shao L. Learning Enriched Features for Real Image Restoration and Enhancement // Google Research, 2020. — 20 с.
7. Wang Z., Chen J., Hoi S.C.H. Deep Learning for Image Super-resolution: A Survey // Cornell University archive, 2019. — 24 с.
8. Jo Y., Yang S., Kim S.J., Yonsei University. Investigating Loss Functions for Extreme Super-Resolution // Computer Vision Foundation, 2020. — 8 с.

9. Yoo J., Ahn N., Sohn K.-A. Rethinking Data Augmentation for Image Super-resolution: A Comprehensive Analysis and a New Strategy // Google Research survey, 2020. — 18 c.
10. Johnson J., Alahi A., Fei-Fei L. Perceptual Losses for Real-Time Style Transfer and Super-Resolution // Cornell University archive, 2016. — 18 c.
11. Gatys L.A., Ecker A.S., Bethge M. Image Style Transfer Using Convolutional Neural Networks // Computer Vision Foundation archive, 2014. — 10 c.
12. Ulyanov D., Vedaldi A., Lempitsky V. Deep Image Prior // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018, pp. 9446–9454.
13. Jia X., Li F., Fraser D. Universal HMT based super resolution for remote sensing images // IEEE International Conference on Image Processing, 2008, pp. 333–336.
14. Maintz J., Viergever M. A survey of medical image registration // Medical Image Analysis, 1998, vol. 2, no. 1, pp. 1–36.
15. Tsai R.Y., Huang T.S. Multiple frame image restoration and registration // Advances in Computer Vision and Image Processing, Greenwich, CT: JAI Press Inc., 1984, pp. 317–339.
16. Alam M.S., Bogner J.G., Hardie R.C., Yasuda B.J. Infrared image registration and high-resolution reconstruction using multiple translationally shifted aliased video frames // IEEE Transactions on Instrumentation and Measurement, 2000, vol. 49, no. 5, pp. 915–923.
17. Baker S., Kanade T. Limits on super-resolution and how to break them // IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, vol. 24, no. 9, pp. 1167–1183.

18. Borman S., Stevenson R.L. Super-resolution from image sequences A review // Proceedings of the 1998 Midwest Symposium on Circuits and Systems, 1998, pp. 374–378.
19. Burger H.C., Schuler C.J., Harmeling S. Image denoising: Can plain neural networks compete with bm3d? // CVPR, 2012, pp. 2392–2399.
20. Lefkimmiatis S. Non-local color image denoising with convolutional neural networks // CVPR. IEEE Computer Society, 2016.
21. Gu S., Zuo W., Xie Q., Meng D., Feng X., Zhang L. Convolutional sparse coding for image super-resolution // ICCV, 2015, pp. 1823–1831. IEEE Computer Society.
22. Johnson J., Alahi A., Fei-Fei L. Perceptual losses for real-time style transfer and super-resolution // ECCV, 2016, pp. 694–711. Springer.
23. Zhu J.Y., Krähenbühl P., Shechtman E., Efros A.A. Generative visual manipulation on the natural image manifold // ECCV, 2016.
24. Smith S.M., Brady J.M. SUSAN: a new approach to low level image processing // IJCV, 1997.
25. Nah S., Kim T.H., Lee K.M. Deep multi-scale convolutional neural network for dynamic scene deblurring // CVPR, 2017.
26. DIV2K dataset: DIVERse 2K resolution high quality images as used for the challenges @ NTIRE (CVPR 2017 and CVPR 2018) and @ PIRM (ECCV 2018) [Электронный ресурс]. URL: <https://data.vision.ee.ethz.ch/cvl/DIV2K/> (дата обращения: 22.06.2022).
27. VGG16 and VGG19 [Электронный ресурс]. URL: <https://keras.io/api/applications/vgg/> (дата обращения: 22.06.2022).
28. Медианный фильтр // Википедия [Электронный ресурс]. URL: <https://ru.wikipedia.org/?curid=333968&oldid=122031612> (дата обращения: 03.05.2022).

29. Smoothing images // OpenCV [Электронный ресурс]. URL: https://docs.opencv.org/4.x/d4/d13/tutorial_py_filtering.html (дата обращения: 03.05.2022).
30. КАК ДОСТИЧЬ РЕЗКОСТИ ИЗОБРАЖЕНИЙ // CAMBRIDGE in COLOUR [Электронный ресурс]. URL: <https://www.cambridgeincolour.com/ru/tutorials-ru/image-sharpening.htm>. (дата обращения: 03.05.2022).
31. Принцип двустороннего фильтра (двусторонний фильтр) и реализация на C ++ // Русские Блоги [Электронный ресурс]. URL: <https://russianblogs.com/article/56181136262/>. (дата обращения: 03.05.2022).
32. Что такое резкость и как поднимать её в Photoshop, Lightroom и онлайн // Фотосклад [Электронный ресурс]. URL: <https://www.fotosklad.ru/expert/articles/cto-takoe-rezkost-i-kak-podnimat-ee-v-photoshop-lightroom-i-onlajn/>. (дата обращения: 03.05.2022).
33. The Model class // Keras [Электронный ресурс]. URL: <https://keras.io/>. (дата обращения: 03.05.2022).
34. U-NET FOR BRAIN MRI // Pytorch [Электронный ресурс]. URL: https://pytorch.org/hub/mateuszbuda_brain-segmentation-pytorch_unet/.
35. U-Net: A PyTorch Implementation in 60 lines of Code // Github [Электронный ресурс]. URL: <https://amaarora.github.io/2020/09/13/unet.html>. (дата обращения: 03.05.2022).
36. Объяснение размытия по Гауссу // adobe [Электронный ресурс]. URL: <https://www.adobe.com/ru/creativecloud/photography/discover/gaussian-blur.html>. (дата обращения: 03.05.2022).

37. СанПиН 2.2.4.548-96. Гигиенические требования к микроклимату производственных помещений.
38. ГОСТ Р 12.1.019-2009. Электробезопасность. Общие требования и номенклатура видов защиты.
39. ГОСТ 12.4.123-83. Средства коллективной защиты от инфракрасных излучений. Общие технические требования.
40. [8] ГОСТ Р 12.1.019-2009. Электробезопасность. Общие требования и номенклатура видов защиты.
41. ГОСТ 12.1.030-81. Электробезопасность. Защитное заземление. Зануление.
42. ГОСТ 12.1.004-91. Пожарная безопасность. Общие требования.
43. ОСТ 12.2.037-78. Техника пожарная. Требования безопасности.
44. СанПиН 2.1.6.1032-01. Гигиенические требования к качеству атмосферного воздуха.
45. ГОСТ 30775-2001. Ресурсосбережение. Обращение с отходами. Классификация, идентификация и кодирование отходов.
46. СНиП 21-01-97. Противопожарные нормы.
47. ГОСТ 12.4.154. Система стандартов безопасности труда. Устройства, экранирующие для защиты от электрических полей промышленной частоты. Общие технические требования, основные параметры и размеры.

Приложение А
(справочное)

Super-resolution with generative adversarial network

Студент

Группа	ФИО	Подпись	Дата
8BM13	Монгуш Темир Валерьевич		

Руководитель ВКР

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент, ОИТ	Иванова Юлия Александровна	к.т.н.		

Консультант-лингвист отделения иностранных языков ШБИП

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент, ШБИП	Сидоренко Татьяна Валерьевна	к.п.н.		

1 SUPER-RESOLUTION WITH GENERATIVE ADVERSARIAL NETWORK

1.1 Introduction

In the modern world a digital image is one of the most common types of data storage. An image is used in various fields of human activity. Images are used in advertisements and banners, print, entertainment such as Internet blogs, as well as in the gaming industry for creating textures and arts, 3D modelling for creating skins for different objects and characters, media space and art. It is also worth noting that an image is very important for any research to study various phenomena, for example, in medicine for determining diseases, in security for identifying people's identities. Thus, the quality of images plays a very important role for our society, therefore obtaining high-resolution images is an important task for all kinds of human activities.

Unfortunately, it is not always possible to obtain a high-resolution image due to imperfection of technology or adverse weather conditions. Therefore, in our time, the algorithms for increasing the resolution and image quality are under demand. To pursuit high-resolution images, we are motivated by two factors: (a) to improve human interpretation of an image and (b) enhance an automatic machine perception due to the ability of indicating more details.

A digital image resolution can be categorized in various ways, including pixel, spatial, spectral, temporal, and radiometric resolution. A spatial resolution, which measures the density of pixels in an image per unit area, is particularly relevant in this context. A digital image is composed of pixels, and the spatial resolution determines the pixel density [1].




Figure A. 1. Test target

Figure A. 1 illustrates a standard test target used to determine the spatial resolution of an image formation system.

1.2 Super-resolution

The problem of super-resolution has been one of the most active areas of research since the appearance of the work of Cai and Huang in 1984 [2]. Over the past two decades, many methods have been proposed, representing the approaches from the frequency domain to the spatial domain and from signal processing to machine learning. A low-resolution image can be modeled from a high-resolution image using the formula below, where D is the degradation function, I_y is the high-resolution image, I_x is the low-resolution image, and σ is the noise.

$$I_x = D(I_y; \sigma) \quad (1)$$

The degradation parameters D and σ are unknown. We have only the high-resolution image and the corresponding low-resolution image are provided. So, now we can make a definition of the concept of super-resolution.

Super-resolution is the task of restoring a high-resolution (HR) image from a low-resolution (LR) image.

A large number of methods are used to increase the spatial resolution of images. Recently, since the 2010s, methods related to deep learning have become the most used in this field.

To begin with, it is necessary to describe some of the classical methods of increasing discretization, since in some deep learning methods, upsampling blocks using classical methods are often used as building blocks of the model. Interpolation methods such as [3] are used:

- • interpolation by the nearest pixel is the simplest and fastest, but it leads to strong artifacts;
- • bilinear interpolation is better in quality, but requires more calculations and in addition blurs the boundaries of objects;
- • bicubic: even better in continuous areas, but there is a halo effect at the border. To avoid this effect, you need to use a non-negative convolution kernel, for example, a cubic b-spline;
- • B-spline interpolation: the b-spline has a very narrow spectrum, which means a strong “blur” of the image;
- • interpolation based on a cubic Hermitian spline: such a spline requires an estimate of partial derivatives in each pixel of the image.




Figure A. 2. Examples of interpolation filters, a) Nearest pixel interpolation, b) Bilinear interpolation, c) Bicubic interpolation, d) B-spline interpolation, e) Interpolation based on cubic Hermitian spline

Figure A. 2 shows examples of using interpolation filters on the example of interpolating the image of the printed letter "a".

There are many methods used to solve the task of super-resolution. For example:

- Pre-Upsampling Super Resolution
- Post-Upsampling Super Resolution
- Residual Networks
- Multi-Stage Residual Networks
- Recursive Networks
- Progressive Reconstruction Networks
- Multi-Branch Networks
- Attention-Based Networks
- Generative Models

In this paper, we will consider the possibility of solving the task of super-resolution using a generative model, namely a generative adversarial network (GAN).

So, the task of GAN is to find the inverse function of degradation using just the HR and LR image data.

1.3 Generative adversarial network

Generative adversarial network (GAN) is an approach to generative modeling using deep learning methods, such as convolutional neural networks.

Generative modeling is an unsupervised learning task in machine learning that involves automatically discovering and learning the regularities or patterns in input data in such a way that the model can be used to generate or output new examples that plausibly could have been drawn from the original dataset.

GANs represent an intelligent approach to teaching a generative model, which involves dividing the problem into two sub-models: the generator model, which is responsible for creating new examples, and the discriminator model, which attempts to distinguish between real (from the domain) and fake (generated) examples. These two models are trained simultaneously in an adversarial, zero-sum game until the discriminator model is deceived approximately 50% of the time, indicating that the generator model is producing credible examples.

The general architecture of the model is shown in the figure below.




Figure A. 3. Generative adversarial network

As we see in Figure A. 3 The generator-adversarial network consists of two networks, a discriminator network and a generator network [4].

The discriminator network tries to learn to recognize a real image from the one generated by the generator network. And the generator network, in turn, learns to generate such an image, which the discriminator would not be able to identify as a generated image.

The discriminator inputs an image and a label, fake or real image. The discriminator then uses convolution to try to determine if the image is real or a generated image.

A low-resolution image is fed to the input of the generator and then the generator learns to generate a high-resolution image using convolution.

Also quite interesting is the solution of gradual training of GAN blocks, in the process of recreating a high-resolution image. The essence of the idea is that network blocks, while simultaneously configuring parameters, can sometimes skip higher-level semantics at the beginning of training, learning low-level image features, the so-called "information delay" effect.




Figure A. 4. Example of gradual training

As you can see in the Figure A. 4, the generator network gradually, iteratively at each step trains the unit responsible for deeper features stored in the image.

1.4 Generator architecture

As said before the generator is needed to create images that would be as close to the real images. The work of the generator network is that a low-resolution image is fed to its input, and then it learns to generate a high-resolution image (Figure 5).




Figure A. 5. Algorithm of generator network

The generator is a convolutional neural network (Figure A. 6).




Figure A. 6. Generator model

The generator network consists of a convolutional layer with a 3×3 kernel, 64 feature maps, and with a PReLU activation function, then there are 16 residual blocks with an identical layout. Each block contains two convolutional layers with small 3×3 cores and 64 feature maps, followed by batch normalization layers. PReLU is used as the activation function. Next comes the convolution layer again, after which the image is enlarged pixel by pixel with two convolution layers. The last layer is the convolution layer with a tangential activation function.

1.5 Discriminator architecture

The purpose of the discriminator, as mentioned earlier, is to determine whether the image is real or a generated image. The discriminator inputs an image and a label, fake or real image. The discriminator then uses convolution to try to determine whether the image is real or a generated image.

The discriminator is an ultra-precise neural network that learns to recognize the original and generated images (Figure A. 7).




Figure A. 7. Discriminator model

The discriminator network contains 8 convolutional layers with an increasing number of 3×3 filter kernels (from 64 to 512, each time increasing by a factor of 2, like in the VGG network). The stepwise convolutions are used to decrease the resolution of the image each time the number of features doubles.

1.6 Metrics

Various metrics are used to evaluate models. It is necessary to list some of them. A number of image quality assessment methods are used to evaluate different parameters of the generated image. All these metrics can be broadly classified into two categories – subjective and objective.

Subjective metrics are based on the assessment of perception by a human observer, whereas objective metrics are based on computational models that attempt to assess image quality. Subjective metrics are often more "perceptual accurate," however, some of these metrics are inconvenient, time-consuming, or expensive to calculate. Another problem is that these two categories of metrics may not correspond to each other.

One of the commonly used metrics is the PSNR metric – the peak signal-to-noise ratio. It is objective, and is inversely proportional to the logarithm of the mean square error between the present high-resolution image and the generated one [5].


$$MSE = \frac{1}{N} \sum_{i=1}^N \left(I(i) - \hat{I}(i) \right)^2 \quad (2)$$

$$PSNR = 10 * \log_{10} \left(\frac{L^2}{MSE} \right) \quad (3)$$

where L is the maximum possible pixel value. Since PSNR only measures the difference between pixel values, this metric may not accurately assess the perceived image quality.

To get the best high-resolution image in our architecture we use perceptual loss. We do not use embassy loss function, because the super-resolution algorithm focusses on improving the resolution of our image by reducing the mean square

error and by increasing the peak signal noise ratio which focus on pixel wise comparison means pixel-by-pixel comparison of the images. They do not focus on perceptual difference, MSE (mean square error) base loss function focus on pixel-to-pixel comparison of both (generated and real high-resolution) images (Figure A. 8).



FigureA. 8. Equal MSE hypersphere

In Figure 8 we can see different qualities of the same image but if we will try to calculate the MSE, we will see that they have the same value, but visually we can say that top one is having more high quality.

Our GAN uses the perceptual based loss function to reach its goal – find the perceptual relevant characteristics between images.

So, what is the perceptual loss, *perceptual loss* is a combination of both adversarial loss (discriminator loss) and content loss (generator loss). And the sum of these two losses will get a perceptual loss.

Content loss means the generator loss function, so it helps enhance the perceptual similarity rather than improving doing improvement on the pixel space. It is tried to improve the perceptual similarity between the images. This loss

function is preferred over mean square error loss function, because we do not want no do the pixel-by-pixel comparison. We want to improve the quality of the image which is generated by the generator. To improve the image, we want that the structural information a perceptually both the images resemble more [6].

To calculate the content loss, we can compare the high-level features of the generated image and the real high-resolution image. It means that we need to get the feature map of the generated image and feature map of the real image and compare both feature maps for their perceptual difference.

For getting these feature maps we can use a pre-trained model, which creates the feature maps of image, for example, we can use VGG or ResNet, ImageNet and pass our images, and after some layers pick the feature maps, and then compare these feature maps. Thus, the network prefers more natural images, trying to deceive the discriminator.

References

1. Yang J., Huang T. Image super-resolution: Historical overview and future challenges // SiteSeerX [Electronic resource]. URL: <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.309.1145&rep=rep1&type=pdf> – Date of access: 20.05.2023.
2. Tsai R.Y., Huang T.S. Multiple frame image restoration and registration // Advances in Computer Vision and Image Processing, Greenwich, CT: JAI Press Inc., 1984, pp. 317–339.
3. Интерполяция и дискретизация, зачем они нужны при проективном преобразовании изображения? // Habr [Electronic resource]. URL: <https://habr.com/ru/company/smartengines/blog/500576/> – Date of access: 20.05.2023.
4. Wang Z., Chen J., Hoi S.C.H. Deep Learning for Image Super-resolution: A Survey // Cornell University archive, 2019. — 24 с.
5. Alam M.S., Bogner J.G., Hardie R.C., Yasuda B.J. Infrared image registration and high-resolution reconstruction using multiple translationally shifted aliased video frames // IEEE Transactions on Instrumentation and Measurement, 2000, vol. 49, no. 5, pp. 915–923.
6. Dwivedi H. Understanding GAN Loss Functions // Neptune [Electronic resource]. URL: <https://neptune.ai/blog/gan-loss-functions> – Date of access: 20.05.2023.

Приложение Б

Загрузка изображений

```
# Load DATA
mean = np.array([0.485, 0.456, 0.406])
std = np.array([0.229, 0.224, 0.225])

class ImageDataset(Dataset):
    def __init__(self, files, hr_shape):
        hr_height, hr_width = hr_shape
        self.lr_transform = transforms.Compose(
            [
                transforms.Resize((hr_height // 4, hr_height // 4), Image.
BICUBIC),
                transforms.ToTensor(),
                transforms.Normalize(mean, std),
            ]
        )
        self.hr_transform = transforms.Compose(
            [
                transforms.Resize((hr_height, hr_height), Image.BICUBIC),
                transforms.ToTensor(),
                transforms.Normalize(mean, std),
            ]
        )
        self.files = files

    def __getitem__(self, index):
        img = Image.open(self.files[index % len(self.files)]).convert('RGB
')

        img_lr = self.lr_transform(img)
        img_hr = self.hr_transform(img)

        return {"lr": img_lr, "hr": img_hr}

    def __len__(self):
        return len(self.files)
train_paths = glob.glob(dataset_path + "DIV2K_train_HR/*.png")
train_dataloader = DataLoader(ImageDataset(train_paths, hr_shape=hr_shape)
, batch_size=batch_size, shuffle=True, num_workers=n_cpu)
```

Generator A

```
class ResidualBlock(nn.Module):
    def __init__(self, in_features):
        super(ResidualBlock, self).__init__()
        self.conv_block = nn.Sequential(
            nn.Conv2d(in_features, in_features, kernel_size=3, stride=1, p
adding=1),
            nn.BatchNorm2d(in_features, 0.8),
            nn.PReLU(),
            nn.Conv2d(in_features, in_features, kernel_size=3, stride=1, p
adding=1),
            nn.BatchNorm2d(in_features, 0.8),
        )
    def forward(self, x):
        return x + self.conv_block(x)

class GeneratorResNet(nn.Module):
    def __init__(self, in_channels=3, out_channels=3, n_residual_blocks=16
):
        super(GeneratorResNet, self).__init__()
```

```

        self.conv1 = nn.Sequential(nn.Conv2d(in_channels, 64, kernel_size=
9, stride=1, padding=4), nn.PReLU())
        # Residual blocks
        res_blocks = []
        for _ in range(n_residual_blocks):
            res_blocks.append(ResidualBlock(64))
        self.res_blocks = nn.Sequential(*res_blocks)
        self.conv2 = nn.Sequential(nn.Conv2d(64, 64, kernel_size=3, stride
=1, padding=1), nn.BatchNorm2d(64, 0.8))
        # Upsampling layers
        upsampling = []
        for out_features in range(2):
            upsampling += [
                # nn.Upsample(scale_factor=2),
                nn.Conv2d(64, 256, 3, 1, 1),
                nn.BatchNorm2d(256),
                nn.PixelShuffle(upscale_factor=2),
                nn.PReLU(),
            ]
        self.upsampling = nn.Sequential(*upsampling)
        # Final output layer
        self.conv3 = nn.Sequential(nn.Conv2d(64, out_channels, kernel_size
=9, stride=1, padding=4), nn.Tanh())
        def forward(self, x):
            out1 = self.conv1(x)
            out = self.res_blocks(out1)
            out2 = self.conv2(out)
            out = torch.add(out1, out2)
            out = self.upsampling(out)
            out = self.conv3(out)
            return out

```

Generator B

```

def make_layer(block, n_layers):
    layers = []
    for _ in range(n_layers):
        layers.append(block())
    return nn.Sequential(*layers)

class ResidualDenseBlock_5C(nn.Module):
    def __init__(self, nf=64, gc=32, bias=True):
        super(ResidualDenseBlock_5C, self).__init__()
        # gc: growth channel, i.e. intermediate channels
        self.conv1 = nn.Conv2d(nf, gc, 3, 1, 1, bias=bias)
        self.conv2 = nn.Conv2d(nf + gc, gc, 3, 1, 1, bias=bias)
        self.conv3 = nn.Conv2d(nf + 2 * gc, gc, 3, 1, 1, bias=bias)
        self.conv4 = nn.Conv2d(nf + 3 * gc, gc, 3, 1, 1, bias=bias)
        self.conv5 = nn.Conv2d(nf + 4 * gc, nf, 3, 1, 1, bias=bias)
        self.lrelu = nn.LeakyReLU(negative_slope=0.2, inplace=True)

    def forward(self, x):
        x1 = self.lrelu(self.conv1(x))
        x2 = self.lrelu(self.conv2(torch.cat((x, x1), 1)))
        x3 = self.lrelu(self.conv3(torch.cat((x, x1, x2), 1)))
        x4 = self.lrelu(self.conv4(torch.cat((x, x1, x2, x3), 1)))
        x5 = self.conv5(torch.cat((x, x1, x2, x3, x4), 1))
        return x5 * 0.2 + x

class RRDB(nn.Module):
    def __init__(self, nf, gc=32):
        super(RRDB, self).__init__()
        self.RDB1 = ResidualDenseBlock_5C(nf, gc)
        self.RDB2 = ResidualDenseBlock_5C(nf, gc)
        self.RDB3 = ResidualDenseBlock_5C(nf, gc)

```

```

def forward(self, x):
    out = self.RDB1(x)
    out = self.RDB2(out)
    out = self.RDB3(out)
    return out * 0.2 + x
class RRDBNet(nn.Module):
    def __init__(self, in_nc, out_nc, nf, nb, gc=32):
        super(RRDBNet, self).__init__()
        RRDB_block_f = functools.partial(RRDB, nf=nf, gc=gc)
        self.conv_first = nn.Conv2d(in_nc, nf, 3, 1, 1, bias=True)
        self.RRDB_trunk = make_layer(RRDB_block_f, nb)
        self.trunk_conv = nn.Conv2d(nf, nf, 3, 1, 1, bias=True)
        self.upconv1 = nn.Conv2d(nf, nf, 3, 1, 1, bias=True)
        self.upconv2 = nn.Conv2d(nf, nf, 3, 1, 1, bias=True)
        self.HRconv = nn.Conv2d(nf, nf, 3, 1, 1, bias=True)
        self.conv_last = nn.Conv2d(nf, out_nc, 3, 1, 1, bias=True)
        self.lrelu = nn.LeakyReLU(negative_slope=0.2, inplace=True)
    def forward(self, x):
        fea = self.conv_first(x)
        trunk = self.trunk_conv(self.RRDB_trunk(fea))
        fea = fea + trunk
        fea = self.lrelu(self.upconv1(F.interpolate(fea, scale_factor=2,
mode='nearest'))))
        fea = self.lrelu(self.upconv2(F.interpolate(fea, scale_factor=2,
mode='nearest'))))
        out = self.conv_last(self.lrelu(self.HRconv(fea)))
        return out

```

Discriminator

```

class Discriminator(nn.Module):
    def __init__(self, input_shape):
        super(Discriminator, self).__init__()
        self.input_shape = input_shape
        in_channels, in_height, in_width = self.input_shape
        patch_h, patch_w = int(in_height / 2 ** 4), int(in_width / 2 ** 4)
        self.output_shape = (1, patch_h, patch_w)
        def discriminator_block(in_filters, out_filters, first_block=False
):
            layers = []
            layers.append(nn.Conv2d(in_filters, out_filters, kernel_size=3
, stride=1, padding=1))
            if not first_block:
                layers.append(nn.BatchNorm2d(out_filters))
                layers.append(nn.LeakyReLU(0.2, inplace=True))
            layers.append(nn.Conv2d(out_filters, out_filters, kernel_size=
3, stride=2, padding=1))
            layers.append(nn.BatchNorm2d(out_filters))
            layers.append(nn.LeakyReLU(0.2, inplace=True))
            return layers
        layers = []
        in_filters = in_channels
        for i, out_filters in enumerate([64, 128, 256, 512]):
            layers.extend(discriminator_block(in_filters, out_filters, fir
st_block=(i == 0)))
            in_filters = out_filters
        layers.append(nn.Conv2d(out_filters, 1, kernel_size=3, stride=1, p
adding=1))
        self.model = nn.Sequential(*layers)
    def forward(self, img):
        return self.model(img)

```

Выделение признаков

```
class FeatureExtractor(nn.Module):
    def __init__(self):
        super(FeatureExtractor, self).__init__()
        vgg19_model = vgg19(pretrained=True)
        self.feature_extractor = nn.Sequential(*list(vgg19_model.features.
children())[:18])
    def forward(self, img):
        return self.feature_extractor(img)
```

Инициализация данных модели.

```
# Initialize generator and discriminator
generator = GeneratorResNet()
discriminator = Discriminator(input_shape=(channels, *hr_shape))
feature_extractor = FeatureExtractor()
# Set feature extractor to inference mode
feature_extractor.eval()
# Losses
criterion_GAN = torch.nn.MSELoss()
criterion_content = torch.nn.L1Loss()
if cuda:
    generator = generator.cuda()
    discriminator = discriminator.cuda()
    feature_extractor = feature_extractor.cuda()
    criterion_GAN = criterion_GAN.cuda()
    criterion_content = criterion_content.cuda()
if load_pretrained_models:
    generator.load_state_dict(torch.load("/content/drive/MyDrive/srgan/pretr
ained/generator.pth"))
    discriminator.load_state_dict(torch.load("/content/drive/MyDrive/srgan/p
retrained/discriminator.pth"))
# Optimizers
optimizer_G = torch.optim.Adam(generator.parameters(), lr=lr, betas=(b1, b
2))
optimizer_D = torch.optim.Adam(discriminator.parameters(), lr=lr, betas=(b
1, b2))
Tensor = torch.cuda.FloatTensor if cuda else torch.Tensor
```

Обучение модели

```
train_gen_losses, train_disc_losses, train_counter = [], [], []
test_gen_losses, test_disc_losses = [], []
test_counter = [idx*len(train_dataloader.dataset) for idx in range(1, n_ep
ochs+1)]
BA = -1000
for epoch in range(300):
    count = 0
    ### Training
    gen_loss, disc_loss = 0, 0
    tqdm_bar = tqdm(train_dataloader, desc=f'Training Epoch {epoch} ', tot
al=int(len(train_dataloader)))
    for batch_idx, imgs in enumerate(tqdm_bar):
        generator.train(); discriminator.train()
        # Configure model input
        imgs_lr = Variable(imgs["lr"].type(Tensor))
        imgs_hr = Variable(imgs["hr"].type(Tensor))
        # Adversarial ground truths
        valid = Variable(Tensor(np.ones((imgs_lr.size(0), *discriminator.o
utput_shape))), requires_grad=False)
        fake = Variable(Tensor(np.zeros((imgs_lr.size(0), *discriminator.o
utput_shape))), requires_grad=False)
        ### Train Generator
```

```

optimizer_G.zero_grad()
# Generate a high resolution image from low resolution input
gen_hr = generator(imgs_lr)
#gen.append(gen_hr)
# Adversarial loss
loss_GAN = criterion_GAN(discriminator(gen_hr), valid)
# Content loss
gen_features = feature_extractor(gen_hr)
real_features = feature_extractor(imgs_hr)
loss_content = criterion_content(gen_features, real_features)
# Total loss
loss_G = loss_content + 1e-3 * loss_GAN
loss_G.backward()
optimizer_G.step()
if(count%9000 == 0):
    plot_train_result(imgs_hr, imgs_lr, gen_hr)
count = count+1
### Train Discriminator
optimizer_D.zero_grad()
# Loss of real and fake images
loss_real = criterion_GAN(discriminator(imgs_hr), valid)
loss_fake = criterion_GAN(discriminator(gen_hr.detach()), fake)
# Total loss
loss_D = (loss_real + loss_fake) / 2
loss_D.backward()
optimizer_D.step()
gen_loss += loss_G.item()
train_gen_losses.append(loss_G.item())
disc_loss += loss_D.item()
train_disc_losses.append(loss_D.item())
train_counter.append(batch_idx*batch_size + imgs_lr.size(0) + epoc
h*len(train_dataloader.dataset))
tqdm_bar.set_postfix(gen_loss=gen_loss/(batch_idx+1), disc_loss=di
sc_loss/(batch_idx+1))
# save_image(gen_hr, f"images/{batch_idx}.png", normalize=False)
# Save image grid with upsampled inputs and SRGAN outputs
if (count%500==0):
    imgs_lr = nn.functional.interpolate(imgs_lr, scale_factor=4)
    imgs_hr = make_grid(imgs_hr, nrow=1, normalize=True)
    gen_hr = make_grid(gen_hr, nrow=1, normalize=True)
    imgs_lr = make_grid(imgs_lr, nrow=1, normalize=True)
    img_grid = torch.cat((imgs_hr, imgs_lr, gen_hr), -1)
    save_image(img_grid, f"images/{batch_idx}.png", normalize=Fals
e)

# Save model checkpoints
if np.argmin(train_gen_losses) == len(train_gen_losses)-1:
    torch.save(generator.state_dict(), "/content/drive/MyDrive/srg
an/pretrained/generator.pth")
    torch.save(discriminator.state_dict(), "/content/drive/MyDrive
/srgan/pretrained/discriminator.pth")

```