

Школа ИШИТР

Направление подготовки 09.03.02 Информационные системы и технологии

Отделение школы (НОЦ) ОИТ

БАКАЛАВРСКАЯ РАБОТА

Тема работы
Детектирование с помощью свёрточных нейронных сетей поврежденных уссурийским полиграфом деревьев пихты на фотоснимках с беспилотных летательных аппаратов.

УДК 004.492.3.032.26:004.932:633.877

Студент

Группа	ФИО	Подпись	Дата
8И6Б	Порошкин Константин Сергеевич		

Руководитель ВКР

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор ОИТ	Марков Н.Г.	д.т.н.		

КОНСУЛЬТАНТЫ ПО РАЗДЕЛАМ:

По разделу «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение»

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОСГН	Рыжакина Т.Г.	к.э.н.		

По разделу «Социальная ответственность»

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ООД ШБИП	Белоенко Е.В.	к.т.н.		

ДОПУСТИТЬ К ЗАЩИТЕ:

Руководитель ООП	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОИТ	Цапко И.В.	к.т.н.		

Результаты обучения

Код результатов	Результат обучения (выпускник должен быть готов)
<i>Профессиональные и общепрофессиональные компетенции</i>	
P1	Применять базовые и специальные естественнонаучные и математические знания для комплексной инженерной деятельности по созданию, внедрению и эксплуатации геоинформационных систем и технологий, а также информационных систем и технологий в бизнесе.
P2	Применять базовые и специальные знания в области современных информационных технологий для решения инженерных задач
P3	Ставить и решать задачи комплексного анализа, связанные с созданием геоинформационных систем и технологий, информационных систем в бизнесе, с использованием базовых и специальных знаний, современных аналитических методов и моделей.
P4	Выполнять комплексные инженерные проекты по созданию информационных систем и технологий, а также средств их реализации (информационных, методических, математических, алгоритмических, технических и программных).
P5	Проводить теоретические и экспериментальные исследования, включающие поиск и изучение необходимой научно-технической информации, математическое моделирование, проведение эксперимента, анализ и интерпретация полученных данных, в области создания геоинформационных систем и технологий, а также информационных систем и технологий в бизнесе.
P6	Внедрять, эксплуатировать и обслуживать современные геоинформационные системы и технологии, информационные системы и технологии в бизнесе, обеспечивать их высокую эффективность, соблюдать правила охраны здоровья, безопасность труда, выполнять требования по защите окружающей среды.
<i>Универсальные (общекультурные) компетенции</i>	
P7	Использовать базовые и специальные знания в области проектного менеджмента для ведения комплексной инженерной деятельности.
P8	Осуществлять коммуникации в профессиональной среде и в обществе в целом. Владеть иностранным языком (углублённый английский язык), позволяющем работать в иноязычной среде, разрабатывать документацию, презентовать и защищать результаты комплексной инженерной деятельности.
P9	Эффективно работать индивидуально и в качестве члена команды, состоящей из специалистов различных направлений и квалификаций,
P10	Демонстрировать личную ответственность за результаты работы и готовность следовать профессиональной этике и нормам ведения комплексной инженерной деятельности.
P11	Демонстрировать знания правовых, социальных, экологических и культурных аспектов комплексной инженерной деятельности, а также готовность к достижению должного уровня физической подготовленности для обеспечения полноценной социальной и профессиональной деятельности.

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

Школа ИШИТР

Направление подготовки 09.03.02 Информационные системы и технологии

Отделение школы (НОЦ) ОИТ

УТВЕРЖДАЮ:

Руководитель ООП

_____ _____ Цапко И.В.
 (Подпись) (Дата) (Ф.И.О.)

ЗАДАНИЕ

на выполнение выпускной квалификационной работы

В форме:

Бакалаврской работы

(бакалаврской работы, дипломного проекта/работы, магистерской диссертации)

Студенту:

Группа	ФИО
8И6Б	Порошкину Константину Сергеевичу

Тема работы:

Утверждена приказом директора (дата, номер)	№5966/с от 28.02.2020

Срок сдачи студентом выполненной работы:

--	--

ТЕХНИЧЕСКОЕ ЗАДАНИЕ:

Исходные данные к работе	Объектом исследования данной работы являются свёрточные нейронные сети класса RetinaNet. В качестве исходных данных выступали снимки лесных массивов Томской области с беспилотных летательных аппаратов. Исследуемые свёрточные нейронные сети (СНС) должны соответствовать следующим требованиям: <ul style="list-style-type: none"> • СНС должны детектировать деревья пихты четырех классов повреждения уссурийским полиграфом; • СНС должны функционировать в режиме реального времени
---------------------------------	---

Перечень подлежащих исследованию, проектированию и разработке вопросов	<ul style="list-style-type: none"> • Анализ предметной области • Подготовка данных • Обучение СНС • Анализ полученных данных • Экономическая часть • Социальная ответственность
Перечень графического материала	<ul style="list-style-type: none"> • Снимки с беспилотного летательного аппарата • Результаты детектирования пихт с помощью сверточных нейронных сетей
Консультанты по разделам выпускной квалификационной работы <i>(с указанием разделов)</i>	
Раздел	Консультант
Социальная ответственность	Доцент ООД ШБИП Белоенко Елена Владимировна
Финансовый менеджмент, ресурсоэффективность и ресурсосбережение	Доцент ОСГН Рыжакина Татьяна Гавриловна
Названия разделов, которые должны быть написаны на русском и иностранном языках:	

Дата выдачи задания на выполнение выпускной квалификационной работы по линейному графику	27.02.2020
---	------------

Задание выдал руководитель:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор ОИТ	Марков Н.Г.	д.т.н.		

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
8И6Б	Порошкин Константин Сергеевич		

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

Школа ИШИТР

Направление подготовки 09.03.02 Информационные системы и технологии

Уровень образования бакалавриат

Отделение школы (НОЦ) ОИТ

Период выполнения весенний семестр 2019 /2020 учебного года

Форма представления работы:

Бакалаврская работа

(бакалаврская работа, дипломный проект/работа, магистерская диссертация)

**КАЛЕНДАРНЫЙ РЕЙТИНГ-ПЛАН
выполнения выпускной квалификационной работы**

Срок сдачи студентом выполненной работы:	15.06.2020
--	------------

Дата контроля	Название раздела (модуля) / вид работы (исследования)	Максимальный балл раздела (модуля)
02.03.2020	Анализ предметной области	15
09.03.2020	Подготовка данных	15
25.05.2020	Обучение СНС	30
31.05.2020	Анализ полученных результатов	20
31.05.2020	Экономическая часть	10
03.06.2020	Социальная ответственность	10

СОСТАВИЛ:

Руководитель ВКР

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор ОИТ	Марков Н.Г.	д.т.н		

СОГЛАСОВАНО:

Руководитель ООП

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОИТ	Цапко И.В.	к.т.н.		

ЗАДАНИЕ ДЛЯ РАЗДЕЛА «СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ»

Студенту:

Группа	ФИО
8И6Б	Порошкину Константину Сергеевичу

Школа	ИШИТР	Отделение (НОЦ)	ОИТ
Уровень образования	Бакалавриат	Направление/специальность	09.03.02 Информационные системы и технологии

Тема ВКР: Детектирование с помощью свёрточных нейронных сетей поврежденных уссурийским полиграфом деревьев пихты на фотоснимках с беспилотных летательных аппаратов.

Исходные данные к разделу «Социальная ответственность»:

1. Характеристика объекта исследования (вещество, материал, прибор, алгоритм, методика, рабочая зона) и области его применения	Разработанные и программно-реализованные архитектуры сверточных нейронных сетей, позволяющие детектировать на фотоснимках поврежденные деревья разной степени деградации. Область применения разработанной нейронной сети – решение лесохозяйственных задач.
--	--

Перечень вопросов, подлежащих исследованию, проектированию и разработке:

1. Правовые и организационные вопросы обеспечения безопасности: – специальные (характерные при эксплуатации объекта исследования, проектируемой рабочей зоны) правовые нормы трудового законодательства; – организационные мероприятия при компоновке рабочей зоны.	Используемая нормативно-техническая документация: - ГОСТ 12.2.032-78 - СанПиН 2.2.4.548-96
2. Производственная безопасность: 2.1. Анализ выявленных вредных и опасных факторов 2.2. Обоснование мероприятий по снижению воздействия	Анализ выявленных вредных и опасных факторов: - Недостаточная освещенность рабочей зоны - Отклонение параметров микроклимата - Превышение уровня шума - Повышенное значение напряжения в электрической цепи, замыкание которой может пройти через тело человека
3. Экологическая безопасность:	В процессе разработки и эксплуатации системы идентификации возможно образование следующих видов отходов: <ul style="list-style-type: none"> • Твердые отходы: бумага, канцелярские принадлежности, комплектующие; • Жидкие отходы: сточные воды; • Люминесцентные лампы.
4. Безопасность в чрезвычайных ситуациях:	Наиболее типичная чрезвычайная ситуация при работе в офисе – пожар. Превентивные меры включают инструктаж по пожарной безопасности, контроль состояния проводки и электрических приборов, своевременное профилактическое обслуживание.

Дата выдачи задания для раздела по линейному графику	01.03.2020
--	------------

Задание выдал консультант:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ООД ШБИП	Белоенко Е.В.	К.Т.Н.		

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
8И6Б	Порошкин К.С.		

ЗАДАНИЕ ДЛЯ РАЗДЕЛА «ФИНАНСОВЫЙ МЕНЕДЖМЕНТ, РЕСУРСООБЪЕКТИВНОСТЬ И РЕСУРСОСБЕРЕЖЕНИЕ»

Студенту:

Группа	ФИО
8И6Б	Порошкину Константину Сергеевичу

Школа	ИШИТР	Отделение (НОЦ)	ОИТ
Уровень образования	Бакалавриат	Направление/специальность	09.03.02 Информационные системы и технологии

Исходные данные к разделу «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение»:	
1.Стоимость ресурсов научного исследования (НИ): материально-технических, энергетических, финансовых, информационных и человеческих	- Оклад студента – 21760 руб. в месяц; - Оклад руководителя проекта – 33664 руб. в месяц. - Человеческие ресурсы – 2 человека (руководитель и студент-дипломник).
2.Нормы и нормативы расходования ресурсов	- Тариф на электроэнергию – 5,26 руб./кВт·ч; - Годовая норма амортизации составляет 40 %
3.Используемая система налогообложения, ставки налогов, отчислений, дисконтирования и кредитования	На основании пункта 1 ст.58 закона №212-ФЗ для учреждений осуществляющих образовательную и научную деятельность вводится пониженная ставка – 27,1%
Перечень вопросов, подлежащих исследованию, проектированию и разработке:	
1.Оценка коммерческого потенциала, перспективности и альтернатив проведения НИ с позиции ресурсоэффективности и ресурсосбережения	- Методы коммерциализации результатов инженерных решений; - Морфологический анализ проекта.
2.Планирование и формирование бюджета научных исследований	- Определение трудоемкости выполнения работ; - Расчет материальных затрат НИИ; - Основная и дополнительная зарплата исполнителей темы; - Отчисления во внебюджетные фонды; - Накладные расходы
3.Определение ресурсной (ресурсосберегающей), финансовой, бюджетной, социальной и экономической эффективности исследования	Проведение оценки ресурсной (ресурсосберегающей), финансовой, бюджетной, социальной и экономической эффективности исследования
Перечень графического материала (с точным указанием обязательных чертежей):	

1. Оценка конкурентоспособности технических решений	
2. Матрица SWOT	
3. Альтернативы проведения НИ	
4. График проведения и бюджет НИ	
5. Оценка ресурсной, финансовой и экономической эффективности НИ	
Дата выдачи задания для раздела по линейному графику	01.03.2020

Задание выдал консультант:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОСГН	Рыжакина Т.Г.	к.э.н.		

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
8И6Б	Порошкин Константин Сергеевич		

Реферат

Выпускная квалификационная работа содержит 98 страниц, 31 рисунок, 32 таблицы, 29 источников.

Ключевые слова: свёрточные нейронные сети, RetinaNet, EfficientNet, детектирование объектов на снимках, деревья пихты, уссурийский полиграф, беспилотный летательный аппарат.

Объектом исследования являются свёрточные нейронные сети (СНС) для детектирования на снимках с беспилотных летательных аппаратов (БПЛА) поврежденных уссурийским полиграфом деревьев пихты.

Область применения: решение лесохозяйственных задач по данным мониторинга лесов с помощью БПЛА.

Цель работы – разработать, программно-реализовать и исследовать СНС, позволяющую детектировать на снимках с БПЛА поврежденные уссурийским полиграфом деревья пихты разной степени деградации.

В процессе исследования проводились: обоснование актуальности разработки, обзор и сравнение различных архитектур СНС для решения задач детектирования объектов на изображениях, обучение и исследование СНС RetinaNet.

В результате была разработана СНС, позволяющая детектировать поврежденные уссурийским полиграфом деревья пихты на снимках с БПЛА с весьма высокой точностью.

Результаты детектирования на снимках деревьев пихты будут востребованы при решении практически важных лесохозяйственных задач, включая задачи оценки различных характеристик пихтовых лесов.

.

Список сокращений

БПЛА – беспилотный летательный аппарат

СНС – свёрточная нейронная сеть

ИМКЭС СО РАН – Институт мониторинга климатических и экологических систем Сибирского Отделения Российской Академии Наук

ФЗ – федеральный закон

СанПиН – санитарные правила и нормы

ГОСТ – государственный стандарт

QuaD – Quality Advisor

SWOT – Strengths Weaknesses Opportunities Threats

Содержание

Введение.....	15
1 Проблема мониторинга пихтовых лесов.....	17
1.1. Оценка состояния древостоев пихты сибирской	17
1.2 Использование беспилотных летательных аппаратов для мониторинга пихтовых лесов, поврежденных уссурийским полиграфом	20
1.3 Постановка задачи.....	23
2 Свёрточные нейронные сети для решения задач детектирования объектов на изображениях	25
2.1 Задача детектирования объектов на изображениях.....	25
2.2 Метрики оценивания нейронных сетей	26
3 Выбор архитектуры СНС.....	30
3.1 Механизмы детектирования СНС	30
3.2 Сравнение архитектур СНС	31
4 Описание выбранной архитектуры СНС	34
4.1 Базовая часть сети RetinaNet.....	35
4.2 Пирамида признаков	37
4.3 Подсети классификации и регрессии	39
4.4 Якорные рамки	40
4.5 Функции потерь.....	41
5 Снимки с БПЛА и их подготовка.....	44
5.1 Получение и разметка данных	44
5.2 Подготовка данных	46
6 Обучение нейронной сети RetinaNet и исследование её эффективности	49
6.1 Выбор backbone сети EfficientNet.....	49

6.2	Подбор гиперпараметров.....	51
6.2.1	Якорные рамки	51
6.2.2	Гиперпараметры функций потерь	51
6.3	Эксперименты с размером изображений и размером сдвига	52
6.4	Расширение датасета с помощью наложения шума на снимки	53
6.5	Вариационные автокодировщики.....	54
6.6	Анализ полученных результатов	58
7.	Социальная ответственность	59
	Введение.....	59
7.1	Правовые и организационные вопросы обеспечения безопасности..	59
7.1.1	Правовые и организационные мероприятия по обеспечению безопасности	59
7.1.2	Общие правовые нормы трудового законодательства	60
7.1.3	Организационные мероприятия при компоновке рабочей зоны.....	61
7.2	Производственная безопасность.....	61
7.2.1	Недостаточная освещенность рабочей зоны и отсутствие или недостаток естественного света.....	62
7.2.2	Превышение уровня шума	63
7.2.3	Отклонение параметров микроклимата	64
7.2.4	Повышенное значение напряжения в электрической цепи	65
7.3	Экологическая безопасность.....	67
7.4	Безопасность в чрезвычайных ситуациях.....	68
8.	Финансовый менеджмент, ресурсоэффективность и ресурсосбережение	71
	Введение.....	71

8.1	Оценка коммерческого потенциала и перспективности проведения научных исследований с позиции ресурсоэффективности и ресурсосбережения.	71
8.1.1	Потенциальные потребители результатов исследования	71
8.1.2	Анализ конкурентных технических решений	72
8.1.3	Технология QuaD	74
8.1.4	SWOT-анализ	76
8.1.5	Морфологический анализ	77
8.2	Планирование научно-исследовательских работ	78
8.2.1	Структура работ в рамках научного исследования	78
8.2.2	Определение трудоемкости выполнения работ	79
8.2.3	Разработка графика проведения научного исследования	83
8.2.4	Бюджет научно-технического исследования	85
8.2.5	Расчет материальных затрат НТИ	85
8.2.6	Расчет затрат на специальное оборудование для научных работ	86
8.2.7	Основная заработная плата исполнителям темы	87
8.2.8	Дополнительная заработная плата	88
8.2.9	Отчисления во внебюджетные фонды (страховые отчисления)	89
8.2.10	Накладные расходы	89
8.2.11	Контрагентные расходы	90
8.2.12	Формирование бюджета затрат проекта	90
8.2.13	Определение ресурсной, финансовой и экономической эффективности ресурсов	91
	Заключение	94
	Список источников	95

Введение

В современном мире технологии искусственного интеллекта играют огромную роль в жизни человечества. С их помощью люди значительно упрощают обработку больших данных, автоматизируют сложные процессы, предсказывают события, которые могут нанести вред человеку, делают новые открытия в области медицины, и решают множество других задач, важных для человека.

Отдельной областью интеллектуальной обработки данных является технология машинного зрения, позволяющая обрабатывать изображения или видео и на основе их анализа делать определенные заключения с помощью свёрточных нейронных сетей. Применение данной технологии значительно сокращает время на обработку данных, избавляет человека от трудозатратных действий, и часто приводит к более качественному выполнению задачи по сравнению с обработкой таких данных человеком.

Одной из областей применения машинного зрения является решение экологических проблем. Большинство проблем, связанных с экологией, анализируют на основе снимков, полученных с помощью беспилотных летательных аппаратов. Использование технологии свёрточных нейронных сетей позволяет автоматизировать процесс обработки снимков, тем самым позволяя быстрее реагировать на неблагоприятные изменения.

Исследование, описанное в данной работе, является показательным примером применения свёрточных нейронных сетей при решении экологических проблем. В данном случае – задача заключается в детектировании деревьев пихт, пораженных уссурийским полиграфом, на снимках БПЛА. На данный момент мониторинг лесных массивов проводится специалистами трудоёмкими методами. Использование свёрточной нейронной сети способно в короткие сроки и меньшими трудозатратами оценить состояние лесных массивов и правильно отреагировать на возникшую экологическую проблему.

Цель данной работы – исследование различных архитектур СНС, решающих задачу детектирования пихтовых деревьев, находящихся в различных состояниях при поражении уссурийским полиграфом на снимках, полученных с помощью БПЛА. В разделе 1 раскрывается проблема распространения уссурийского полиграфа и методы мониторинга пихтовых лесов. В разделе 2 описаны механизм работы свёрточных нейронных сетей и метрики их оценивания. В разделе 3 проводится сравнение различных архитектур свёрточных нейронных сетей, на основе которого была выбрана архитектура RetinaNet. В разделе 4 подробно описана архитектура RetinaNet. В разделе 5 изложен процесс подготовки данных для обучения нейронной сети RetinaNet. В разделе 6 описан процесс обучения RetinaNet и проведён анализ результатов. В разделе 7 проведён анализ производственной безопасности и гигиене труда, соблюдению санитарных норм и защиты сотрудников от негативного воздействия среды. В разделе 8 проведён детальный анализ проекта по критериям конкурентоспособности и ресурсоэффективности.

1 Проблема мониторинга пихтовых лесов

1.1. Оценка состояния древостоев пихты сибирской

Уссурийский полиграф *Polygraphus proximus* (далее – *P. proximus*) – эндемичный дальневосточный короед, проникший в темнохвойные экосистемы Южной Сибири, по-видимому, в результате завоза с древесиной по Транссибирской магистрали. В последнее десятилетие этот вид стал массовым дендрофагом пихты сибирской, одного из основных лесообразователей сибирской тайги, и новым фактором деградации темнохвойных лесов в 7 регионах Сибирского федерального округа Российской Федерации: Томской, Кемеровской, Новосибирской областях, Алтайском и Красноярском краях, республиках Алтай и Хакасия [1].

Широкое распространение уссурийского полиграфа в Сибири, продолжающееся и в настоящее время, наличие многочисленных очагов его массового размножения, высокий инвазионный статус вида как трансформера темнохвойных экосистем, влияющего на различные компоненты лесного биоразнообразия, включение *P. proximus* в Единый перечень карантинных объектов Евразийского экономического союза – все это требует разработки эффективных методов слежения за состоянием пихтарников в районах инвазии с целью снижения экономического и экологического ущерба.

Основное значение в оценке состояния пихтарников, поврежденных уссурийским полиграфом, имеет наземный мониторинг. В рамках разработанной в ИМКЭС СО РАН технологии используется макроскопический уровень описания экосистем. В качестве индикаторов состояния приняты параметры, позволяющие выявить наиболее существенные изменения компонентов лесной экосистемы под воздействием внешних факторов, вместе с тем удовлетворяющие общим базовым свойствам индикаторов: чувствительность, способность к агрегативности, простота интерпретации, научная обоснованность [1].

Комплексный анализ позволил разработать и предложить для оперативного мониторинга поврежденных уссурийским полиграфом лесов оценочную шкалу текущего жизненного состояния деревьев пихты в очагах *P. proximus*. В табл. 1 приведены отличительные признаки деревьев различной категории состояния, а на рис. 1 представлен внешний вид деревьев каждой из категорий.

Таблица 1 – Категории состояния деревьев пихты сибирской в очагах уссурийского полиграфа

Категория дерева	Признаки
I. Здоровое, без признаков ослабления. Не атаковано полиграфом	Крона густая, протяженная, хвоя зеленая, блестящая
II. Ослабленное. Атаковано полиграфом, но не заселено	Крона может быть как у здорового дерева, или изреженная, флагообразная, несколько ветвей могут нести на концах хвою ярко-рыжего цвета.
III. Сильно ослабленное. Атаковано полиграфом, но не заселено	Крона, в зависимости от времени и интенсивности заселения, может быть как у здорового дерева, но чаще изреженная, хвоя бледно-зеленая либо более половины ветвей несут усыхающую хвою.
IV. Усыхающее. Заселено полиграфом	Хвоя в верхней части кроны еще зеленая, ниже – ярко-рыжего цвета
V. Свежий сухостой (дерево в процессе отработки стволовыми насекомыми)	Хвоя в кроне полностью мертвая, красная

<p>VI. Старый сухостой (дерево полностью отработано стволовыми насекомыми)</p>	<p>Крона мертвая, серая, хвоя осыпалась. В зависимости от года усыхания дерева осыпаются ветки разного порядка</p>
--	--



I категория



II категория



III категория



IV категория



V категория



VI категория

Рисунок 1 – Кроны деревьев, соответствующие каждой из категорий

1.2 Использование беспилотных летательных аппаратов для мониторинга пихтовых лесов, поврежденных уссурийским полиграфом

До настоящего времени мониторинг состояния пихтовых лесов в зоне инвазии *P. proximus* осуществлялся в ходе периодических наземных наблюдений, что особенно важно в случае обнаружения очагов вредителя и назначения санитарно-оздоровительных мероприятий. Однако, подобные исследования, в связи с обширностью и труднодоступностью таежных территорий Сибири, не дают полной информации о распространении инвазионного процесса в регионе. Частично данную проблему могло бы решить использование космических снимков и проведение авиационного надзора, но эти методы имеют обширный список ограничений по детализации информации, и, что немаловажно, по стоимости.

Одним из преимуществ использования современных БПЛА является привязка снимков к системе глобального позиционирования GPS (англ. Global Positioning System), что создает возможность оперативной точной оценки лесопатологической ситуации, использования результатов для планирования локальных фитосанитарных мероприятий.

Оптимальные условия для проведения дистанционного зондирования лесных насаждений с использованием БПЛА обуславливаются кругом решаемых задач и, следовательно, типом устройства, его техническими характеристиками и рекомендациями фирмы-производителя. Для выбора времени проведения аэрофотосъемки первостепенное значение имеет хорошая видимость с минимальной нижней границей облачности около 300 метров при условии равномерного освещения. Переменная облачность или низкие углы утреннего или вечернего солнечного освещения не рекомендуются, так как куртины поврежденных деревьев могут быть плохо различимы в тених. Наиболее оптимальные сроки для проведения аэрофотосъемки с использованием БПЛА обычно совпадают с периодами наземных

обследований очагов стволовых вредителей с середины апреля до начала октября.

Квадрокоптер, один из типов БПЛА, выбранный для изучения снимков в данном исследовании, позволяет проводить оперативный осмотр участков лесного фонда в режиме фотографирования и видеосъемки. Поврежденные уссурийским полиграфом деревья пихты выявляются на снимках по изменению окраски кроны по сравнению с неповрежденными деревьями, что позволяет легко дифференцировать живые и погибшие деревья и по их доле в древостое приблизительно оценивать его санитарное состояние и уровень деградации[1].

На снимках, полученных с помощью квадрокоптера, кроны деревьев пихты имеют 4 различных вида окраса: зеленые (здоровые или немного ослабленные), желтые (ослабленные, атакованные/заселены уссурийским полиграфом), красные (свежий сухостой) и серые (старый сухостой). Некоторые из 6 категорий, указанных ранее на рис. 1, при таком способе мониторинга становятся слабо различимы между собой, поэтому для упрощения интерпретации снимков, выделяются 4 категории деревьев. На рис. 2 вверху приведен вид кроны этих категорий деревьев.



Рисунок 2 – Четыре категории хвойных деревьев, выделенные для решения задачи с помощью БПЛА (слева направо: здоровое дерево, усыхающее дерево, свежий сухостой, сухостой прошлых лет)

Снимки, полученные с помощью БПЛА, необходимо интерпретировать для определения состояния лесных массивов, но решение этой задачи человеком вручную очень трудозатратно, и не исключает возникновение ошибок вследствие человеческого фактора, что указывает на необходимость в автоматизации процессов интерпретации снимков.

В последние годы для решения задач автоматизации интерпретации аэрофотоснимков наилучшие результаты продемонстрировали нейросетевые технологии, в частности, свёрточные нейронные сети. Так, например, в одном из исследований, посвященных анализу снимков лесных массивов Красноярского края, авторы [2] решили подобную задачу, реализовав нейросетевой алгоритм для детектирования групп деревьев, принадлежащих разным категориям. Результат работы данного алгоритма представлен на рис. 3.

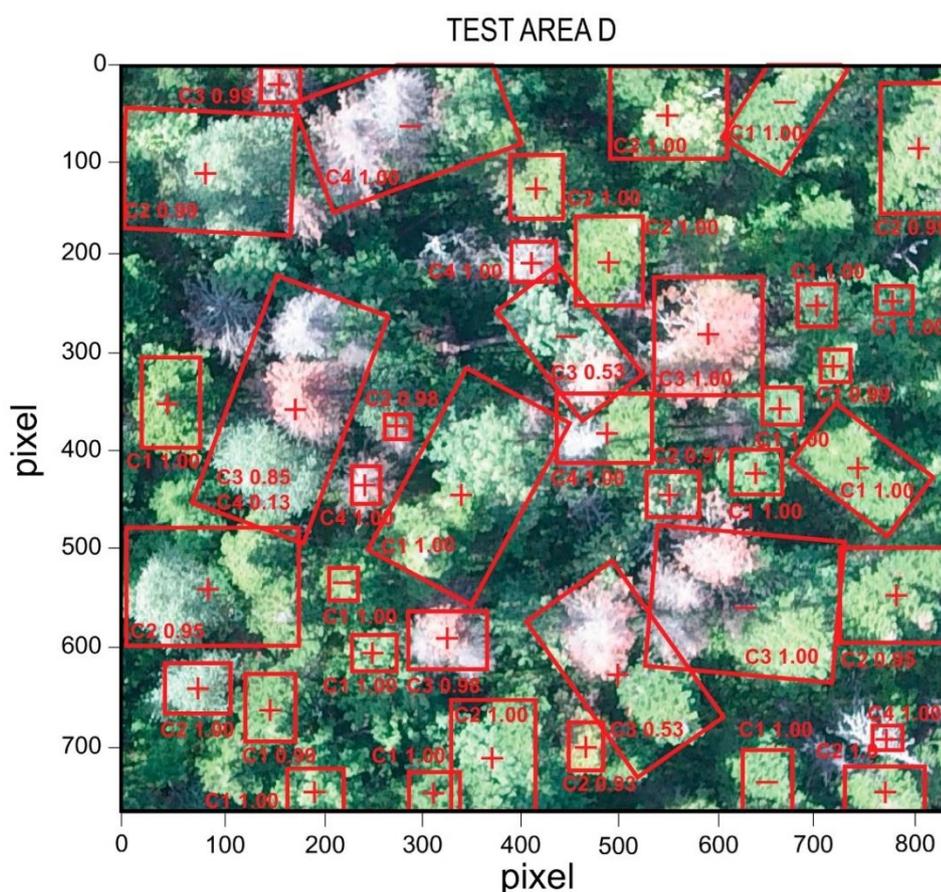


Рисунок 3 – Результат работы нейросетевого алгоритма, разработанного в исследовании [2]

Упомянутое выше исследование, имея результаты с высокими показателями точности, всё же заставляет усомниться в правильной интерпретации снимков. Как можно увидеть на приведённом выше рис. 3, алгоритм часто воспринимает группу деревьев (область, выделенная в красный прямоугольник) как одно дерево, и классифицирует её, хотя классифицируемая группа деревьев может состоять из растений разных категорий.

В другом исследовании [3] с помощью нейросети была решена задача выделения лесов и больших кустарников от других областей на снимках, полученных со спутника. Использование нейросетевой технологии позволило автоматизировать процесс интерпретации снимков территории площадью 1.73 млн км² с точностью около 90%. Особенно важно, что для обучения нейросети в данном исследовании вручную потребовалось обработать лишь малую часть доступных снимков (0,05% от всей площади).

Таким образом, применение технологии искусственных нейронных сетей имеет большой потенциал для автоматизации интерпретации аэрофотоснимков, так как значительно упрощает работу для специалистов и способно значительно повысить качество выполнения поставленной задачи.

1.3 Постановка задачи

Целью данной работы является исследование различных архитектур СНС, решающих задачу детектирования пихтовых деревьев, находящихся в различных состояниях при поражении уссурийским полиграфом на снимках, полученных с помощью БПЛА.

При исследовании применяются 2 критерия: точность используемого алгоритма и скорость решения задачи автоматической интерпретации снимков.

Скорость алгоритма детектирования объектов должна позволять обрабатывать снимки в режиме квази-реального времени, то есть в масштабе времени, близком к темпу поступления данных с БПЛА.

Для реализации поставленной цели необходимо решить следующие задачи:

- Провести анализ существующих архитектур СНС, пригодных для решения задачи детектирования пихтовых деревьев, и выбрать архитектуру модели СНС для исследования;
- Подготовить данные для обучения;
- Обучить модель выбранной архитектуры.

2 Свёрточные нейронные сети для решения задач детектирования объектов на изображениях

2.1 Задача детектирования объектов на изображениях

Детектирование – задача нахождения одного или нескольких объектов на изображении и определение класса каждого из этих объектов. Таким образом, решаются сразу несколько задач – регрессия и классификация. Задача регрессии – определение координат каждого объекта, задача классификации – определение класса каждого найденного объекта.

Координатами объекта являются координаты ограничивающего прямоугольника (англ. bounding box), внутри которого находится объект. Пример результата детектирования представлен на рис. 4 [4], где каждый обнаруженный нейросетью объект ограничен в bounding box, с указанием класса объекта (в приведенном примере “car”, “person” или “truck”) и вероятности, с которой объект соответствует этому классу.

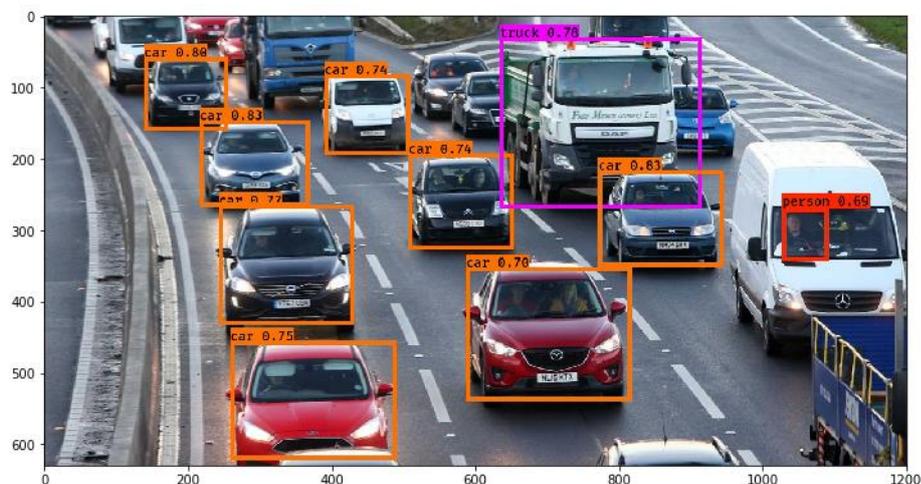


Рисунок 4 – Пример работы детектора [4]

2.2 Метрики оценивания нейронных сетей

Для того, чтобы понять, как оценивается работа моделей для задач детектирования, следует сначала разобраться с основными метриками бинарной классификации.

Самой распространённой метрикой является доля правильных ответов (accuracy):

$$accuracy = \frac{P}{N}$$

где P – количество экземпляров, по которым классификатор принял правильное решение, а N – размер обучающей выборки. Но у такой метрики есть большой недостаток. Допустим, обучающая выборка состоит из 10 элементов, и 8 из них соответствуют классу 0, остальные – классу 1. Тогда, если плохо обученная модель будет относить все элементы к классу 0, то её точность будет равна 80%, что не отражает её неспособность различать представителей класса 1.

Следующими метриками качества являются: точность (Precision) и полнота (Recall), которые используются при оценке большей части алгоритмов извлечения информации. Precision – это доля элементов, действительно принадлежащих классу, относительно всех элементов, которые модель отнесла к этому классу. Recall – доля элементов, действительно принадлежащих классу, относительно всех элементов этого класса в выборке. Эти показатели можно рассчитать с помощью таблицы контингентности, которая составляется для каждого класса отдельно (табл. 2).

Таблица 2 – Таблица контингентности

Определение класса		Правильный ответ	
		Класс 1	Класс 0
Ответ модели	Класс 1	TP	FP
	Класс 0	FN	TN

Таблица 2 таблица показывает сколько правильных и неправильных ответов дала модель по каждому из классов, а именно:

- TP – количество истинно-положительных решений;
- TN – количество отрицательных решений;
- FP – количество ложно-положительных решений;
- FN – количество ложно-отрицательных решений.

На основании полученных значений, точность и полнота вычисляются следующим образом:

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

Ещё одной распространённой метрикой является Average Precision (AP), геометрический смысл которой является площадь под PR-кривой. Для построения кривой все ответы сети сортируются по вероятности принадлежности к классу, и начиная с первого ответа с наибольшим значением, считаем общую точность и полноту выбранных ответов, добавляя затем следующий ответ и получая новые значения. Таким образом, количество пар точность-полнота будет равно количеству ответов сети, значение точности в первой паре будет максимальным, а в последней – наименьшей (если все ответы правильные – значение точности во всех парах будет одинаковым). После этого строится PR-кривая (рис. 5), где по оси абсцисс расположены значения полноты, по оси ординат – соответствующие значения точности. Площадь под кривой является значением средней точности (AP). Статистический смысл метрики Average Precision практически такой же, как и у Precision, но теперь на показатель влияет насколько модель была уверена в ошибочном варианте.

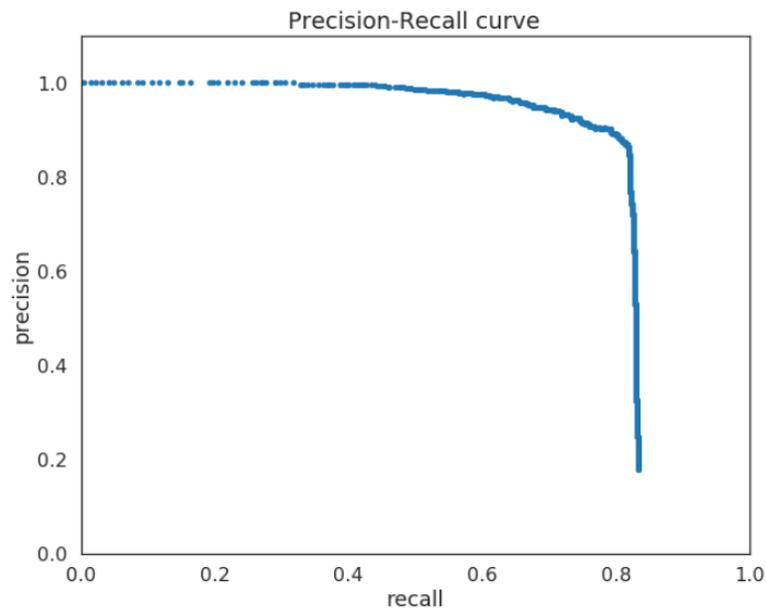


Рисунок 5 – Пример PR-кривой

Модели для задач детектирования принято оценивать с помощью метрики mAP (mean average precision), которая является средним значением AP для каждого класса, но так как AP, в своём первоначальном смысле, для множественной классификации используется крайне редко, то указывая значения AP подразумевают mAP отождествляя эти понятия.

Ещё одной важной характеристикой является значение IoU (Intersection over Union) – отношение площади пересечения истинных и предсказанных ограничивающих рамок к их объединению (рис. 6). Принято устанавливать граничное значение этого показателя равным 0.5, то есть если IoU для предсказанной рамки меньше этого значения, то выделенный объект игнорируется (считается фоном).

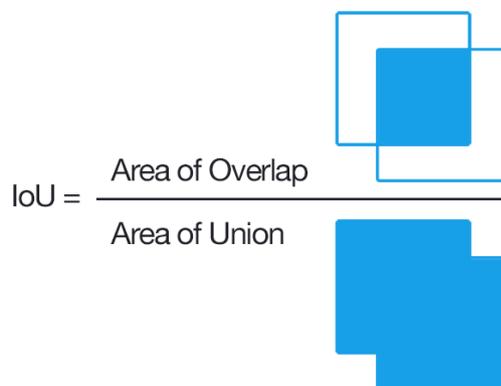


Рисунок 6 – Определение IoU [5]

Для проведения соревнований, таких как COCO [6], по детектированию объектов на изображениях, установлены основные метрики оценивания моделей, которые детально передают возможности модели. Список и значение этих метрик представлен на табл. 3.

Таблица 3 – Основные метрики оценки моделей детектирования. AP – среднее значение AP при разных порогах IoU от 0.50 до 0.95 с шагом 0.05. AP@.50 – значение AP при пороге IoU=0.50. AP@.75 – значение AP при пороге IoU=0.75 [6].

Average Precision (AP):	
AP	% AP at IoU=.50:.05:.95 (primary challenge metric)
AP ^{IoU=.50}	% AP at IoU=.50 (PASCAL VOC metric)
AP ^{IoU=.75}	% AP at IoU=.75 (strict metric)

В данном исследовании будут приводиться значения AP при пороге IoU=0.50.

Также, важной характеристикой нейросети является её скорость обработки данных. Для оценки скорости алгоритма используется метрика – количества операций с плавающей запятой в секунду (FLOPS, англ. FLoating-point Operations Per Second), показывающая, сколько операций с плавающей запятой в секунду выполняет данная вычислительная система при работе данного алгоритма.

Более упрощённой метрикой для оценки скорости модели является кадровая частота (англ. Frames per Second (FPS)), которая означает количество кадров, обработанных за секунду данным алгоритмом.

3 Выбор архитектуры СНС

3.1 Механизмы детектирования СНС

Нейросети для задач детектирования по принципам работы делятся на два типа: one-stage и two-stage [7].

Two-stage подход содержит в себе два этапа обработки изображений: поиск областей, которые соответствуют объектам, и применение классификатора для определения класса выделенного объекта. К такой группе моделей детектирования относится семейство архитектур Region-Based Convolutional Neural Network (R-CNN). В R-CNN на первом этапе генерируются области-кандидаты с помощью алгоритма селективного поиска. Полученные области подаются на вход нейронной сети классической архитектуры, например, AlexNet [8].

One-stage подход выдвигает предсказание сразу, опираясь на признаки, выделенные СНС классической архитектуры. К такой группе СНС относят такие семейства архитектур, как YOLO, RetinaNet и некоторые другие. Модели такого типа состоят из базовой нейросети, например ResNet, за ней следуют различные свёрточные слои, преобразующие выделенные признаки, эти слои далее обрабатывают две отдельные подсети: классификационная и регрессионная, которые также представляют собой СНС. В итоге модели имеют монолитную структуру [7].

Оба метода имеют свои превосходства и недостатки: two-stage модели имеют высокую точность, но занимают значительно больше времени на обработку данных; one-stage модели имеют менее высокую точность, но обработка данных занимает меньшее время. Однако, one-stage архитектуры последних нескольких лет перестают уступать в точности, например RetinaNet. На таблице 4 представлены показатели AP архитектур различного типа на датасете COCO [9].

Таблица 4 – Сравнение показателей AP архитектур СНС различного типа [10]

	backbone	AP	AP ₅₀	AP ₇₅	AP _S	AP _M	AP _L
<i>Two-stage methods</i>							
Faster R-CNN+++ [16]	ResNet-101-C4	34.9	55.7	37.4	15.6	38.7	50.9
Faster R-CNN w FPN [20]	ResNet-101-FPN	36.2	59.1	39.0	18.2	39.0	48.2
Faster R-CNN by G-RMI [17]	Inception-ResNet-v2 [34]	34.7	55.5	36.7	13.5	38.1	52.0
Faster R-CNN w TDM [32]	Inception-ResNet-v2-TDM	36.8	57.7	39.2	16.2	39.8	52.1
<i>One-stage methods</i>							
YOLOv2 [27]	DarkNet-19 [27]	21.6	44.0	19.2	5.0	22.4	35.5
SSD513 [22, 9]	ResNet-101-SSD	31.2	50.4	33.3	10.2	34.5	49.8
DSSD513 [9]	ResNet-101-DSSD	33.2	53.3	35.2	13.0	35.4	51.1
RetinaNet (ours)	ResNet-101-FPN	39.1	59.1	42.3	21.8	42.7	50.2
RetinaNet (ours)	ResNeXt-101-FPN	40.8	61.1	44.1	24.1	44.2	51.2

Исходя из данной таблицы можно сделать вывод о том, что one-stage нейросети семейства RetinaNet показывают значительно лучшие результаты по сравнению с другими наиболее популярными сетями типа two-stage. Поэтому в данном исследовании предпочтение отдаётся one-stage сетям, в частности архитектуре RetinaNet.

3.2 Сравнение архитектур СНС

Модели для задач детектирования имеют широкий круг применения, и обработка снимков, полученных с помощью дистанционного зондирования земли – не исключение. Так, например, команда проекта Lastus решала задачу поиска потерявшихся людей с помощью квадрокоптера. При решении данной задачи исследователям было важно не упустить обнаружение значимых объектов на фото при минимальных ложных обнаружениях. Поступающий видеопоток с камеры БПЛА обрабатывался нейросетью RetinaNet, которая давала лучшие показатели mAP по сравнению с другими архитектурами [11]. Показатели оценки архитектур представлены в табл. 5.

Таблица 5 – Оценки архитектур для решения задачи поиска людей на снимках БПЛА

Тип	mAP (зима)	mAP (лето)
SSD	0.56	-
YOLOv3	0.72	0.23
DarkNet (ResNeXt18)	0.89	0.21
RetinaNet (mobileNetv2)	0.67	0.22
RetinaNet (ResNet50)	0.91	0.68

Ещё одним примером может послужить исследование [12], которое доказывает преимущество архитектуры RetinaNet над другими современными архитектурами для решения задач детектирования объектов на снимках БПЛА. Ниже, на табл. 6, представлены оценки архитектур, полученных в ходе данного исследования на датасете SDD (Stanford Drone Dataset), в который входит около 1 млн снимков сделанных с помощью БПЛА [13].

Таблица 6 – Оценки архитектур на датасете SDD

Метод	Категория	FPS	mAP
SSD(ResNet-50)	one-stage	23.26	80.42
Faster R-CNN (ResNet-50)	two-stage	13.18	83.64
RetinaNet(ResNet-50)	one-stage	24.45	85.17
SSD(ResNet-101)	one-stage	21.52	81.92

Faster R-CNN (ResNet-101)	two-stage	11.27	85.33
RetinaNet(ResNet-101)	one-stage	22.31	86.58

Результаты данного исследования хорошо раскрывают преимущества нейросети RetinaNet, которая превзошла в точности сеть Faster R-CNN типа two-stage и в показателе FPS сеть SSD типа one-stage.

Исходя из результатов вышеупомянутых исследований можно сделать вывод, что архитектура RetinaNet имеет наибольшую скорость обработки данных при высоких показателях точности относительно других архитектур для решения задач интерпретации снимков БПЛА. Поэтому было принято решение использовать данную архитектуру для решения задачи детектирования поврежденных деревьев пихты уссурийским полиграфом и оценки их состояния.

4 Описание выбранной архитектуры СНС

Выбранная для данного исследования архитектура СНС RetinaNet состоит из 4 основных частей, каждая из которых имеет своё назначение:

а) Backbone – основная (базовая) сеть, служащая для извлечения признаков из поступающего на вход изображения. Данная часть сети является вариативной и в её основу могут входить классификационные нейросети, такие как ResNet, VGG, EfficientNet и другие;

б) Feature Pyramid Net (FPN) – свёрточная нейронная сеть, построенная в виде пирамиды, служащая для объединения достоинств карт признаков нижних и верхних уровней сети, первые имеют высокое разрешение, но низкую семантическую, обобщающую способность; вторые — наоборот;

в) Classification Subnet – подсеть, извлекающая из FPN информацию о классах объектов, решая задачу классификации;

г) Regression Subnet – подсеть, извлекающая из FPN информацию о координатах объектов на изображении, решая задачу регрессии

На рис. 7 изображена архитектура RetinaNet с ResNet сетью в качестве backbone.

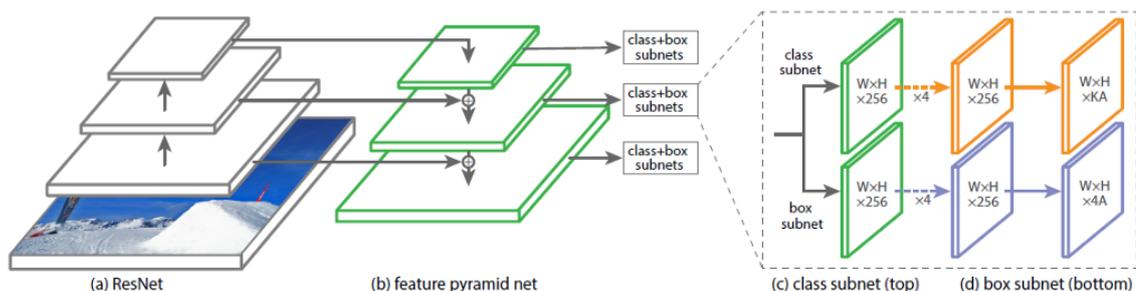


Рисунок 7 – Архитектура RetinaNet с backbone-сетью ResNet

Разберём подробно каждую из частей RetinaNet, представленных на рис. 7 и определимся с их параметрами для решения задачи интерпретации снимков БПЛА с целью детектирования поражённых деревьев.

4.1 Базовая часть сети RetinaNet

Учитывая, что часть архитектуры RetinaNet, которая принимает на вход изображение и выделяет важные признаки, является вариативной и извлеченная из этой части информация будет обрабатываться на следующих этапах, то важно выбрать подходящую backbone-сеть для лучших результатов.

Недавние исследования по оптимизации СНС позволили разработать классификационные модели, которые опередили все ранее разработанные архитектуры с лучшими показателями точности на датасете ImageNet [14] при улучшении эффективности в 10 раз. Данные сети получили название EfficientNet-B(0-7) [15]. Показатели семейства новых сетей представлены на рис. 8, 9.

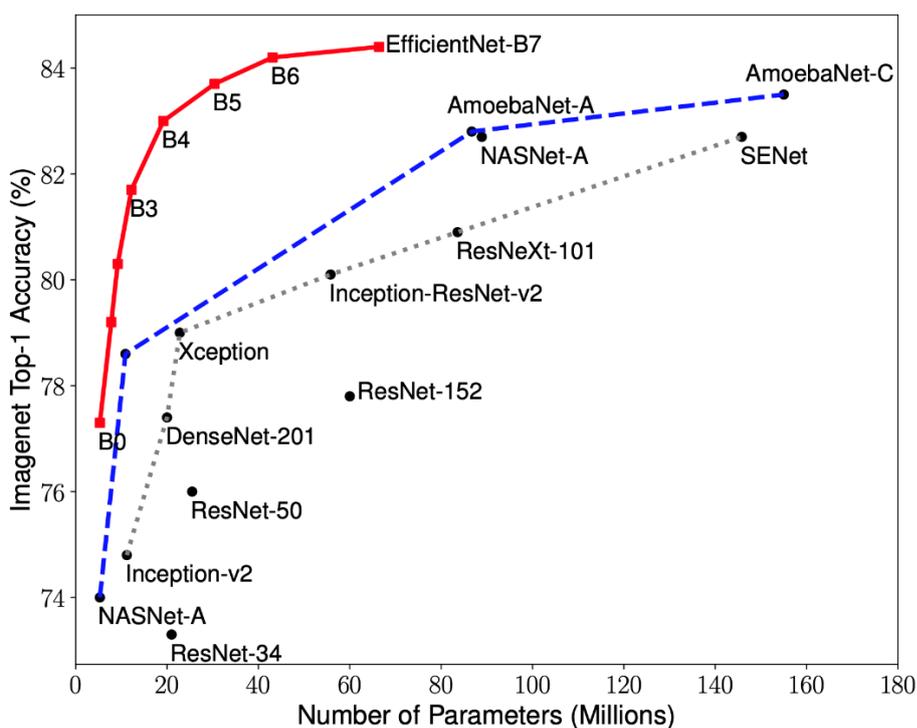


Рисунок 8 – График зависимости наибольшего показателя точности от количества весов сети для различных архитектур

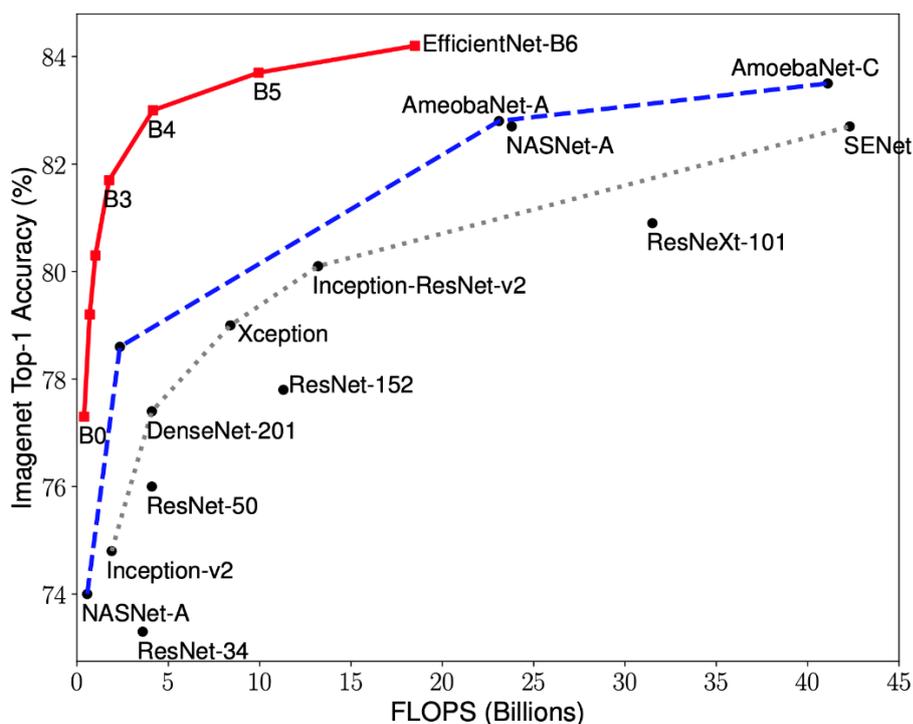


Рисунок 9 – График зависимости наибольшего показателя точности от показателя FLOPS сети для различных архитектур

Архитектура данной сети была разработана методом всестороннего масштабирования – равномерного изменения ширины сети (количество параметров в слое), глубины (количество слоёв в сети) и изменения разрешения входного изображения (рис. 10) с определенными коэффициентами масштабирования.

Семейство сетей EfficientNet было получено масштабированием MBConv [16] сети. Архитектура EfficientNet-B0 представлена на рис. 11.

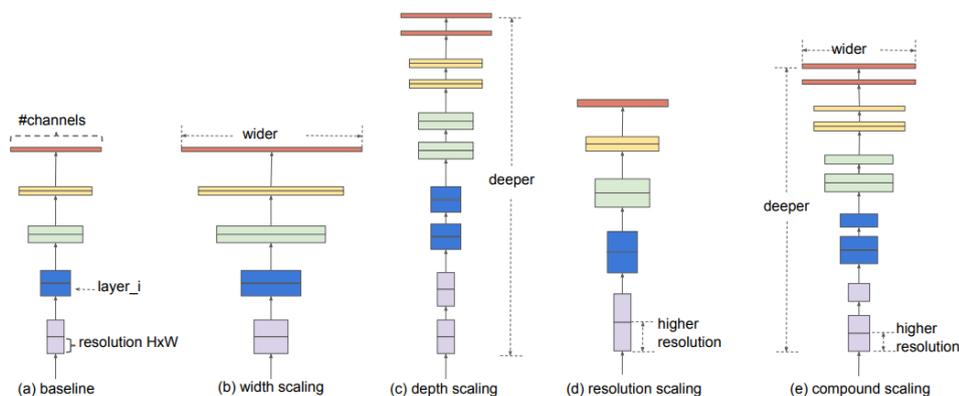


Рисунок 10 – Всестороннее масштабирование сети [15]

Stage i	Operator \mathcal{F}_i	Resolution $\hat{H}_i \times \hat{W}_i$	#Channels \hat{C}_i	#Layers \hat{L}_i
1	Conv3x3	224×224	32	1
2	MBCConv1, k3x3	112×112	16	1
3	MBCConv6, k3x3	112×112	24	2
4	MBCConv6, k5x5	56×56	40	2
5	MBCConv6, k3x3	28×28	80	3
6	MBCConv6, k5x5	14×14	112	3
7	MBCConv6, k5x5	14×14	192	4
8	MBCConv6, k3x3	7×7	320	1
9	Conv1x1 & Pooling & FC	7×7	1280	1

Рисунок 11 – Архитектура сети EfficientNet-B0 [15]

Таким образом, EfficientNet-B(0-7) в качестве backbone в архитектуре RetinaNet имеют большой потенциал для решения поставленной задачи и достижения высокой точности при минимальных затратах времени обработки, и будут исследованы в следующих разделах данной работы.

4.2 Пирамида признаков

Feature Pyramid Network состоит из трёх основных частей: восходящий путь (bottom-up pathway), нисходящий путь (top-down pathway) и боковые соединения (lateral connections).

Восходящий путь представляет собой некую иерархическую «пирамиду» – последовательность свёрточных слоёв с уменьшающейся размерностью, в нашем случае – backbone сеть. Верхние слои свёрточной сети имеют большее семантическое значение, но меньшее разрешение, а нижние наоборот (рис. 12). Bottom-up pathway имеет уязвимость при извлечении признаков – потеря важной информации об объекте, например из-за зашумления небольшого, но значимого, объекта фоном, так как к концу сети информация сильно сжата и обобщена.

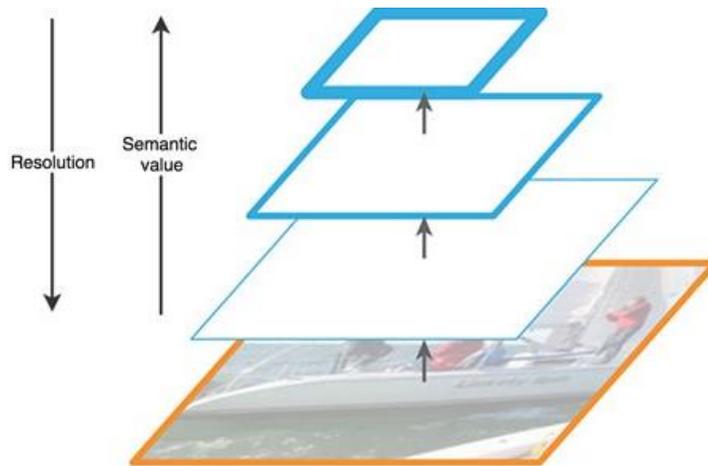


Рисунок 12 – Особенности карт признаков на разных уровнях нейросети

Нисходящий путь также представляет собой «пирамиду». Карты признаков верхнего слоя этой пирамиды имеют размер карт признаков верхнего слоя bottom-up пирамиды и увеличиваются вдвое методом ближайшего соседа (рис. 13) по направлению вниз.

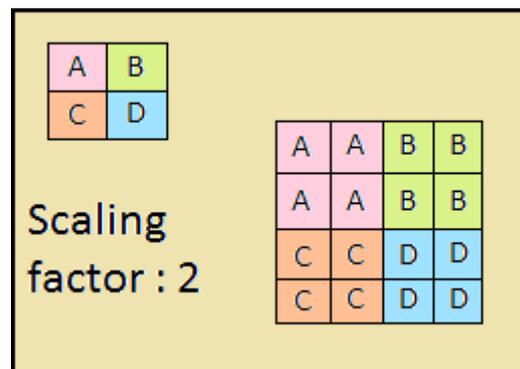


Рисунок 13 – Увеличение разрешения изображения методом ближайшего соседа [17]

Таким образом в top-down сети каждая карта признаков вышележащего слоя увеличивается до размеров карты нижележащего.

Помимо этого, в FPN присутствуют боковые соединения, это означает, что карты признаков соответствующих слоёв bottom-up и top-down пирамид поэлементно складываются, причём карты из bottom-up проходят свёртку 1×1 . Этот процесс схематично представлен на рис. 14.

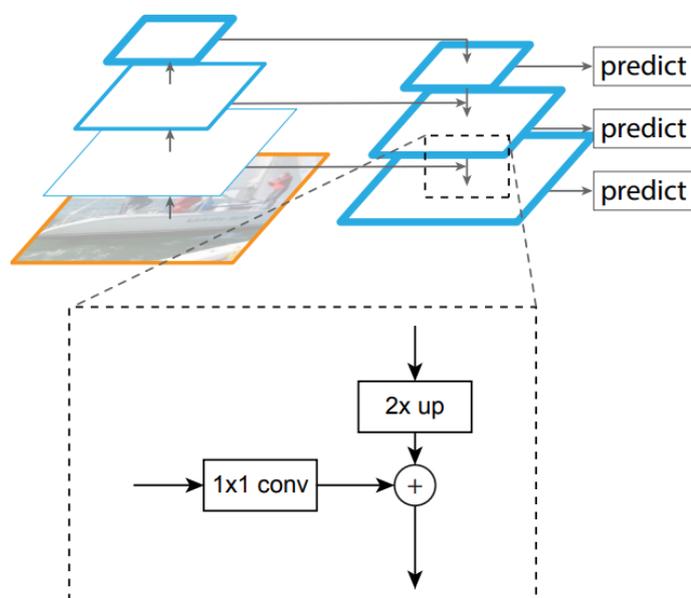


Рисунок 14 – Устройство пирамиды признаков

Боковые соединения решают проблему затухания важных сигналов в процессе прохода по слоям, совмещая семантически важную информацию, полученную к концу первой пирамиды и более детальную информацию, полученную в ней ранее.

Далее, каждый из полученных слоёв в top-down пирамиде обрабатывается двумя подсетями.

4.3 Подсети классификации и регрессии

Третьей частью архитектуры RetinaNet являются две подсети: классификационная и регрессионная (рис. 15). Каждая из этих подсетей образует на выходе ответ о классе объекта и его расположении на изображении. Рассмотрим принцип работы каждой из них.

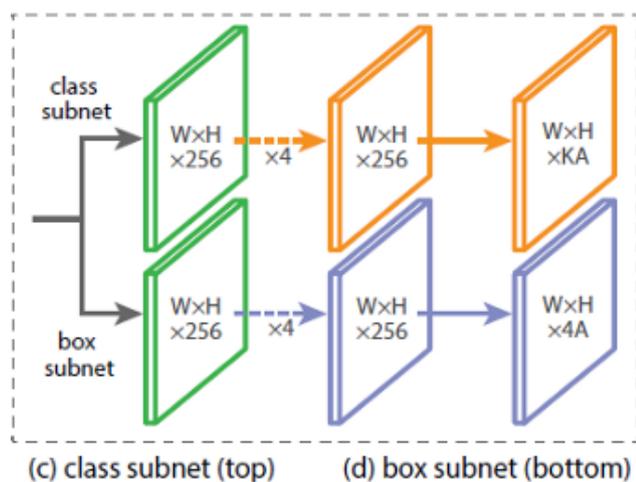


Рисунок 15 – Подсети RetinaNet

Разница в принципах работы рассматриваемых блоков (подсетей) не отличается до последнего слоя. Каждый из них состоит из 4 слоёв свёрточных сетей. В слое формируются 256 карт признаков. На пятом слое количество карт признаков изменяется: регрессионная подсеть имеет $4 \cdot A$ карт признаков, классификационная – $K \cdot A$ карт признаков, где A – количество якорных рамок (подробное описание якорных рамок в следующем подразделе), K – количество классов объектов.

В последнем шестом слое каждая карта признаков преобразуется в набор векторов. Регрессионная модель на выходе имеет для каждой якорной рамки вектор из 4 значений, указывающих смещение целевой рамки (англ. ground-truth box) относительно якорной. Классификационная модель имеет на выходе для каждой якорной рамки one-hot вектор длиной K , в котором индекс со значением 1 соответствует номеру класса, который нейросеть присвоила объекту.

4.4 Якорные рамки

В прошлом подразделе был использован термин якорных рамок. Якорная рамка (англ. anchor box) – гиперпараметр нейросетей-детекторов, заранее определенный ограничивающий прямоугольник, относительно которого работает сеть.

Допустим, сеть имеет на выходе карту признаков размером 3*3. В RetinaNet каждая из ячеек имеет 9 якорных рамок, каждая из которых имеет разный размер и соотношение сторон (рис. 16). Во время обучения каждой целевой рамке подбираются в соответствие якорные рамки. Если их показатель IoU имеет значение от 0.5, то якорная рамка назначается целевой, если значение меньше 0.4, то она считается фоном, в других случаях якорная рамка будет проигнорирована для обучения. Классификационная сеть обучается относительно выполненного назначения (класс объекта или фон), регрессионная сеть обучается относительно координат якорной рамки (важно отметить, что ошибка вычисляется относительно якорной, но не целевой рамки).

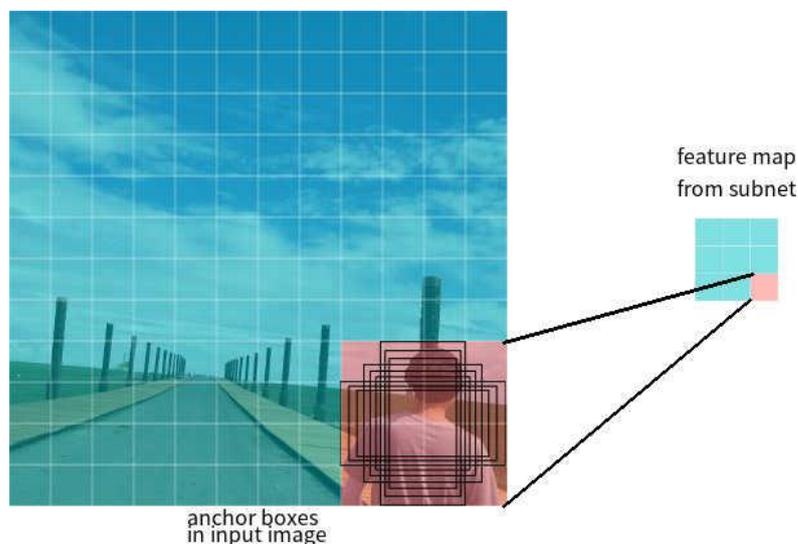


Рисунок 16 – Якорные рамки для одной ячейки карты признаков с размером 3*3 [18]

4.5 Функции потерь

Потери RetinaNet являются составными, их составляют два значения: ошибка регрессии, или локализации (ниже обозначено как L_{loc}), и ошибка классификации (ниже обозначено как L_{cls}). Общая функция потерь может быть записана как:

$$L = \lambda L_{loc} + L_{cls} \quad (1)$$

Где λ является гиперпараметром, который контролирует баланс между двумя потерями.

Рассмотрим подробнее вычисление каждой из потерь.

Как было описано ранее, каждой целевой рамке назначается якорная. Обозначим эти пары как $(A_i, G_i)_{i=1, \dots, N}$, где A представляет якорь, G – целевую рамку, а N количество сопоставленных пар.

Для каждого якоря регрессионная сеть предсказывает 4 числа, которые можно обозначить как $P_i = (P_{ix}, P_{iy}, P_{iw}, P_{ih})$. Первые две пары означают предсказанную разницу между координатами центров якорной A_i и целевой рамки G_i , а последние две – предсказанную разницу между их шириной и высотой. Соответственно, для каждой целевой рамки вычисляется T_i , как разница между якорной и целевой рамкой:

$$L_{loc} = \sum_{j \in \{x, y, w, h\}} \text{smooth}_{L1}(P_{ij} - T_{ij}) \quad (2)$$

Где $\text{smooth}_{L1}(x)$ определяется формулой ниже:

$$\text{smooth}_{L1}(x) = \begin{cases} 0.5x^2, & |x| < 0 \\ |x| - 0.5, & |x| \geq 0 \end{cases} \quad (3)$$

Потери задачи классификации в сети RetinaNet вычисляются с помощью функции Focal loss (формула 4).

$$L_{cls} = - \sum_{i=1}^K \alpha_i y_i \log(p_i) (1 - p_i)^\gamma \quad (4)$$

, где K – количество классов, y_i – целевое значение класса, p – вероятность предсказания i -го класса, γ – параметр фокуса, α – коэффициент смещения. Данная функция является усовершенствованной функцией кросс-энтропии. Отличие заключается в добавлении параметра $\gamma \in (0, +\infty)$, который решает проблему несбалансированности классов. Во время обучения, большая часть объектов, обрабатываемых классификатором, является фоном, который является отдельным классом. Поэтому может

возникнуть проблема, когда нейросеть обучится определять фон лучше, чем другие объекты. Добавление нового параметра решило данную проблему, уменьшив значение ошибки для легко классифицируемых объектов. Графики функций focal и cross entropy представлены на рис.17.

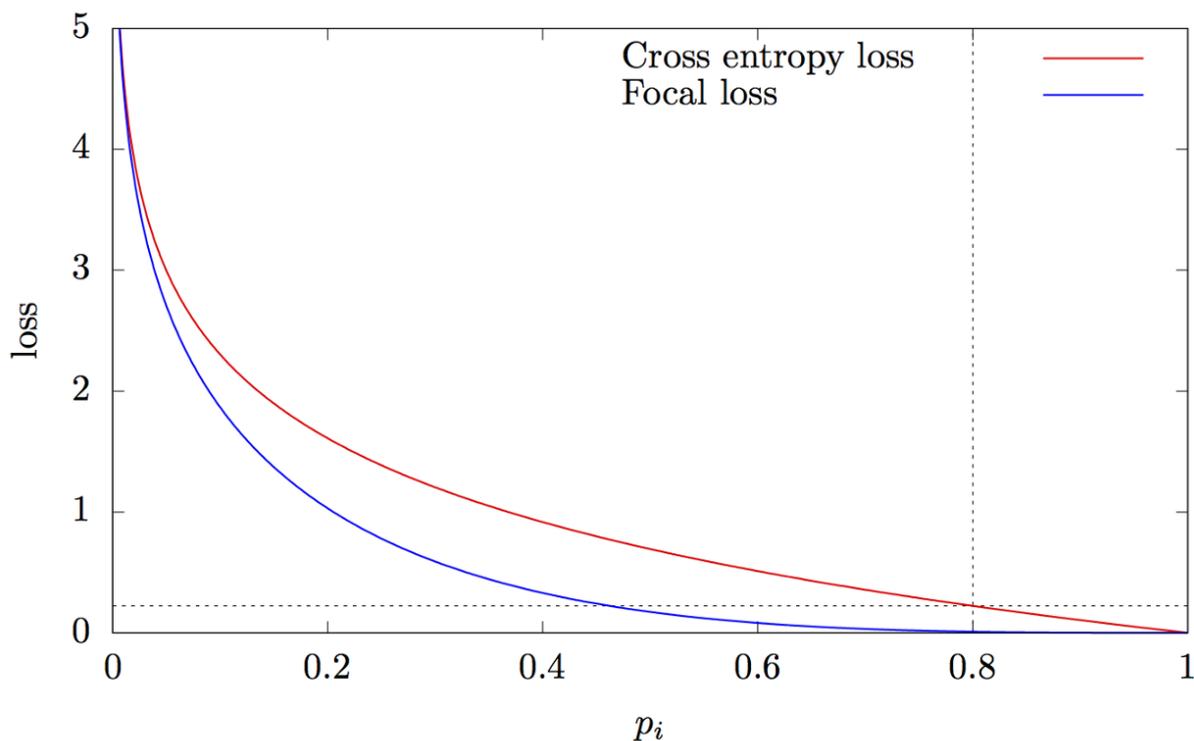


Рисунок 17 – Графики focal и cross entropy функций

5 Снимки с БПЛА и их подготовка

5.1 Получение и разметка данных

Как было сказано ранее, задача заключается в детектировании поврежденных пихт, которые разделяются на 4 класса: здоровые, ослабленные, отмирающие и сухостой.

Институт мониторинга климатических и экологических систем СО РАН предоставил 6 снимков, сделанных при различных погодных условиях и высоте полёта. Разрешение снимков: 4000*3000px. Специалисты нанесли на каждый снимок метки, где изображена пихта, с указанием класса, к которому она относится. Пример нанесения разметки изображен на рисунке 18.

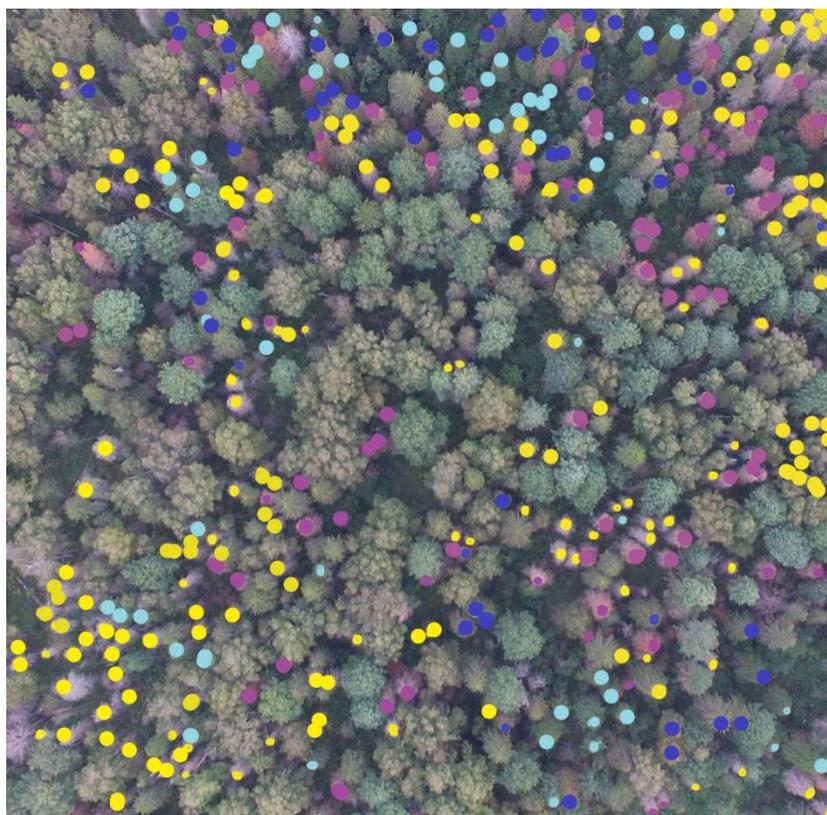


Рисунок 18 – Разметка, проведённая специалистами (значение меток: бирюзовый – здоровое дерево, синий – ослабленное дерево, фиолетовый – отмирающее дерево, желтый - сухостой)

Затем была проведена повторная разметка, опираясь на имеющуюся, с помощью приложения HyperLabel [19] для получения координат

ограничивающих рамок и меток класса в готовом для обучения нейросети виде. Результат разметки представлен на рисунках 19 и 20.



Рисунок 19 – Фрагмент повторной разметки

```
/2_25_90_hsv.png,192,209,236,242,0ld dead wood  
/2_25_90_hsv.png,559,24,599,61,New dead wood  
/2_25_90_hsv.png,134,259,180,294,New dead wood  
/2_25_90_hsv.png,200,268,255,294,New dead wood  
/2_25_90_hsv.png,88,202,124,237,New dead wood  
/2_25_90_hsv.png,120,276,158,310,New dead wood  
/2_25_90_hsv.png,523,415,546,448,New dead wood  
/2_25_90_hsv.png,543,456,593,487,New dead wood  
/2_25_90_hsv.png,473,185,526,225,0ld dead wood  
/2_25_90_hsv.png,457,444,497,481,New dead wood  
/2_25_90_hsv.png,191,77,247,111,New dead wood  
/2_25_90_hsv.png,36,231,77,269,New dead wood  
/2_25_90_hsv.png,257,151,308,183,0ld dead wood  
/2_25_90_hsv.png,479,245,535,290,Healthy 1  
/2_25_90_hsv.png,380,244,435,279,New dead wood  
/2_25_90_hsv.png,222,136,261,172,0ld dead wood  
/2_26_180.png,409,534,440,567,Healthy 2  
/2_26_180.png,285,228,314,259,New dead wood
```

Рисунок 20 – Фрагмент файла для обучения с информацией о названии файла изображения, координатах ограничивающей рамки объекта и классе объекта

В итоге был получен размеченный набор данных из 6 изображений, готовый к обучению нейросети. Количество имеющихся объектов деревьев по классам представлено в таблице 7.

Таблица 7 – Количество объектов в наборе данных

Класс объекта	Количество
Здоровые	1382
Усыхающие	589
Свежий сухостой	727
Старый сухостой	1031
Итого:	3729

5.2 Подготовка данных

Для того, чтобы обучать нейросеть, необходимо разделять выборку на тренировочную, участвующую непосредственно в обучении, валидационную, по которой будет измеряться точность во время обучения, и тестовую, которая будет использована для получения итогового результата после экспериментов.

Так как каждый из 6 снимков имеет свои особенности (погодные условия, высота полёта БПЛА, густота лесного массива), было принято решение на начальном этапе разбить каждое изображение на множество фрагментов размером 600*600px, чтобы фрагменты в нижней половине изображения относились к тренировочной выборке, а фрагменты верхней разделялись на равные части на проверочную и валидационную.

При вырезании фрагментов некоторые ограничивающие рамки выходят за границы. Такие объекты игнорируются, то есть информация о их нахождении во фрагменте не записывается. Также, учитывая, что средняя ширина ограничивающих рамок составляет примерно 50*50px, то для сохранения в обучении всех возможных объектов было принято решение о вырезании фрагментов со сдвигом 100px по высоте и ширине. На рисунке 21 представлен пример фрагмента, участвующего в обучении.



Рисунок 21 – Пример входного изображения

Для предотвращения эффекта переобучения (переобучение нейронной сети – эффект, при котором нейросеть имеет высокие показатели точности на обучающей выборке, но низкие на новых данных) обучающая выборка была расширена поворотом каждого фрагмента на 90, 180 и 270 градусов. Затем изображения дополнительно аугментировались с помощью библиотеки `DataAugmentationForObjectDetection` [20] несколькими методами:

- Поворот на случайный угол от 0 до 90 градусов;
- Зеркальное отражение по горизонтали;
- Цветокоррекция со случайным изменением показателей насыщенности и яркости цвета.

Таким образом, было получено 784, 136 и 72 изображений в тренировочной, валидационной и тестовой выборке соответственно. Количество объектов по каждому классу представлено в таблице 8.

Таблица 8 – Количество объектов в наборе данных

Класс объекта	Количество объектов (train/val/test)	Всего объектов
Здоровые	12112/2220/1468	15800
Усыхающие	3136/1372/556	5064
Свежий сухостой	4112/1328/552	5992
Старый сухостой	9888/1072/888	11848
Итого:	29248/5992/3464	38704

6 Обучение нейронной сети RetinaNet и исследование её эффективности

6.1 Выбор backbone сети EfficientNet

Как было сказано ранее, в архитектуру RetinaNet входит backbone часть, которая является классификатором. Наилучшие результаты в задаче классификации показывают сети семейства EfficientNet.

Было проведено исследование семейства EfficientNet в качестве backbone RetinaNet применительно к поставленной задаче. На имеющихся данных проводилось обучение в 100 эпох с остановкой обучения после 10 эпох без улучшения показателя mAP.

После исследования первых 4-х архитектур от EfficientNet-B0 до EfficientNet-B3 на графике зависимости показателя mAP от эпохи обучения (рис. 22) был замечен спад достигаемого показателя точности с увеличением количества параметров (напомним, что B0 имеет наименьшее количество параметров, B7 – максимальное в семействе архитектур EfficientNet-B*), поэтому классификаторы EfficientNet-B(4-8) не рассматривались. Наилучшие результаты были получены при использовании EfficientNet-B0 сети в качестве backbone.

На графике зависимости потерь от эпохи обучения (рис. 23) этого же эксперимента заметно прекращение уменьшения ошибки на валидационных данных после 10й эпохи при продолжающемся спаде потерь на тренировочных данных. Наблюдаемый эффект является эффектом переобучения, который приводит к ошибочным ответам сети на новых данных, при точных ответах на тренировочных данных.

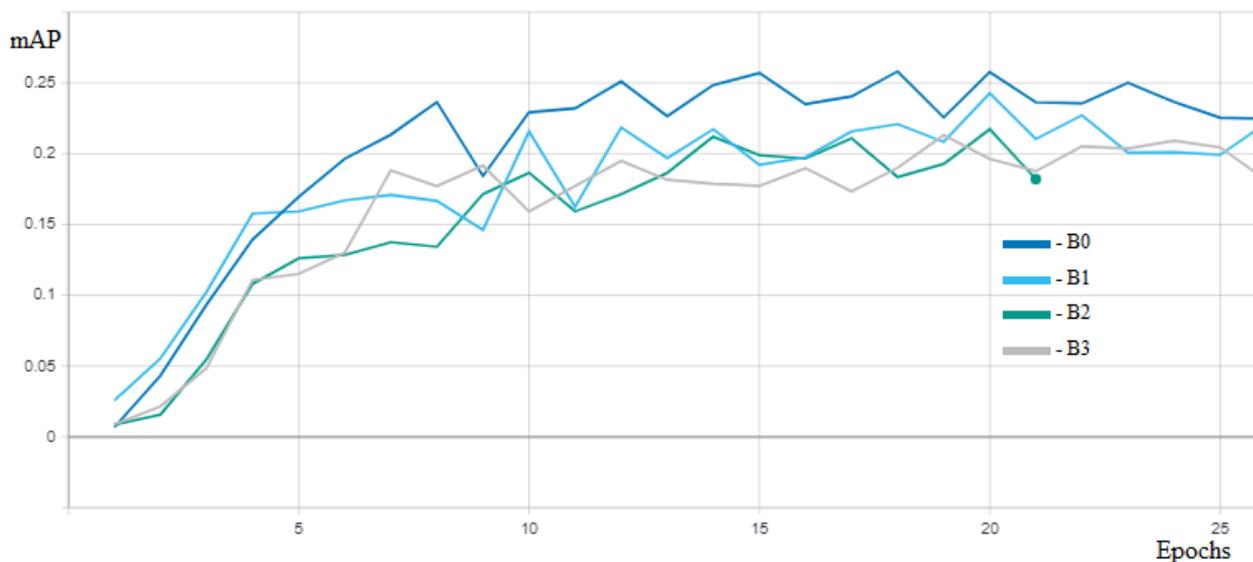


Рисунок 22 – График зависимости показателя mAP от эпохи обучения

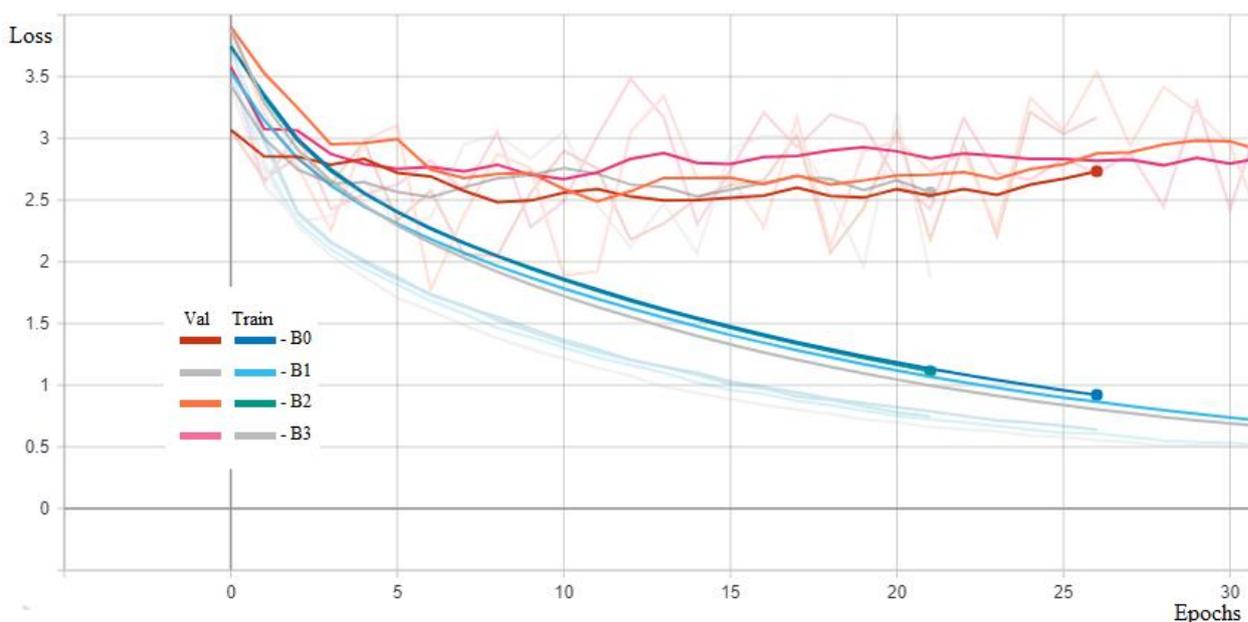


Рисунок 23 – График зависимости потерь сети от эпохи обучения

На основании полученных графиков приходим к выводу, что при увеличении размера backbone наблюдается снижение показателей точности и усиление эффекта переобучения, поэтому для решения задачи детектирования пораженных деревьев пихт на снимках БПЛА будет использована нейросеть EfficientNet-B0 в качестве backbone.

6.2 Подбор гиперпараметров

6.2.1 Якорные рамки

Важным гиперпараметром нейросетей-детекторов являются якорные рамки, их размеры должны быть максимально приближены к размерам ограничивающих рамок, указанных в разметке. У якорных рамок есть четыре настраиваемых параметра: размер стороны рамки (sizes) и величина сдвига рамки (strides) по одному значению на один уровень FPN, и соотношение сторон (ratios) и коэффициенты масштабирования (scales) по три значения на одну рамку.

Настройка проводилась для коэффициентов соотношения сторон и масштабирования. Подбор значений производился с помощью anchor-optimization [21]. В таблице 9 представлены параметры по умолчанию и новые значения.

Таблица 9 – Настройка якорных рамок

Параметр	По умолчанию	Новое значение
sizes	32, 64, 128, 256, 512	32, 64, 128, 256, 512
strides	8, 16, 32, 64, 128	8, 16, 32, 64, 128
ratios	0.5, 1, 2	0.602, 1.0, 1.66
scales	1, 1.26, 1.59	0.685, 0.858, 1.127

6.2.2 Гиперпараметры функций потерь

RetinaNet имеет две функции потерь. Функция потерь классификатора имеет два параметра: α и γ . По умолчанию эти параметры равны 0.25 и 2 соответственно. Функция потерь регрессора имеет единственный параметр σ . По умолчанию значение этого параметра равно 3. Для нахождения

оптимального набора коэффициентов был определен набор различных значений для каждого из коэффициентов и запущен метод Grid Search [22] на обучение в течение 20 эпох. Наилучшие показатели за 20 эпох представлены в таблицах 10, 11.

Таблица 10 – Результат метода Grid Search для функции потерь классификации

	$\alpha=0.1$	$\alpha=0.25$	$\alpha=0.5$	$\alpha=0.75$
$\gamma=0.5$	0.12 mAP	0.18 mAP	0.26 mAP	0.24 mAP
$\gamma=1.0$	0.15 mAP	0.22 mAP	0.20 mAP	0.18 mAP
$\gamma=2.0$	0.08 mAP	0.14 mAP	0.20 mAP	0.08 mAP
$\gamma=4.0$	0.09 mAP	0.13 mAP	0.17 mAP	0.09 mAP

Таблица 11 – Результат метода Grid Search для функции потерь регрессии при $\alpha=0.5$ и $\gamma=0.5$

σ	mAP
1	0.21
3	0.26
5	0.22

6.3 Эксперименты с размером изображений и размером сдвига

После подбора гиперпараметров был проведен эксперимент, заключающийся в подборе метода подготовки изображений. В ходе эксперимента использовались два параметра. Первый параметр: размер фрагмента, подаваемого на вход нейросети. Второй параметр: пересечение фрагментов при подготовке тренировочной выборки (в тестовой и

валидационной выборке два соседних фрагмента всегда пересекаются на 100px). Результат эксперимента представлен в таблице 12.

Эксперимент показал, что наилучший результат достигается при размере изображений 400*400px, а создание фрагментов для обучающей выборки с меньшим сдвигом повышает точность.

Таблица 12 – Показатели точности при различных размерах фрагментов и их пересечений

Размер фрагмента (px) \ Пересечение (px)	400 (mAP, %)	600 (mAP, %)	800 (mAP, %)
100	30,81	21,92	17,66
200	29,95	22,30	21,92
300	33,21	26,95	22,06
400	–	28,39	25,12
500	–	28,50	25,16
600	–	–	22,53
700	–	–	23,84

6.4 Расширение датасета с помощью наложения шума на снимки

Для повышения точности сети было принято решение расширить тренировочную выборку с помощью наложения шума. Для генерации шума были применены преобразования Лапласа. Пример изображений исходного и полученного изображений представлен на рисунке 24.

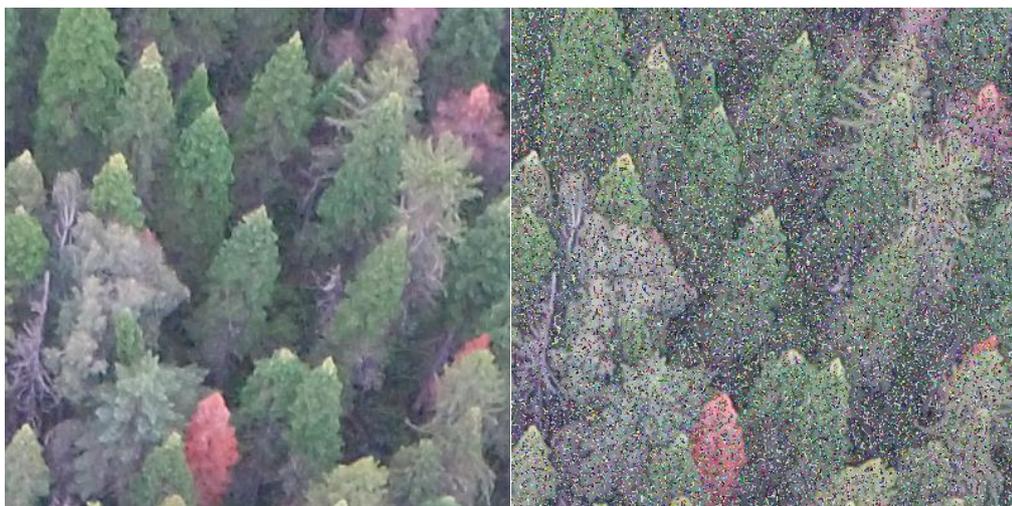


Рисунок 24 – Результат наложения шума

Данный подход позволил улучшить показатель точности mAP до 40,5% на валидационной выборке, увеличивая результат более чем на 7% .

6.5 Вариационные автокодировщики

Следующим шагом для аугментации изображений были применены вариационные автокодировщики для генерации новых объектов.

Сперва были получены изображения всех ограничивающих рамок. Затем для каждого из классов были разработаны и обучены вариационные автокодировщик. Каждая полученная генеративная модель создавала из скрытого пространства изображения деревьев. На рисунках 25-28 представлены изображения деревьев, сгенерированных вариационными автокодировщиками. Каждое из изображений представляет собой визуализацию распределения скрытого двумерного пространства автокодировщика.

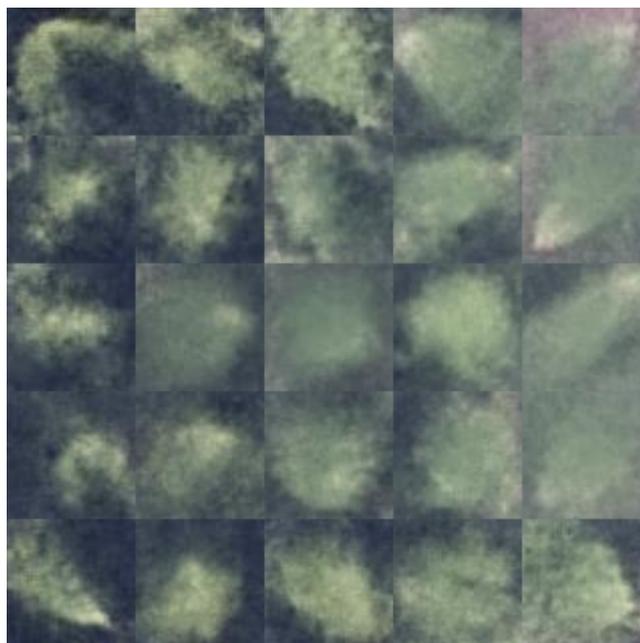


Рисунок 25 – Сгенерированные здоровые деревья

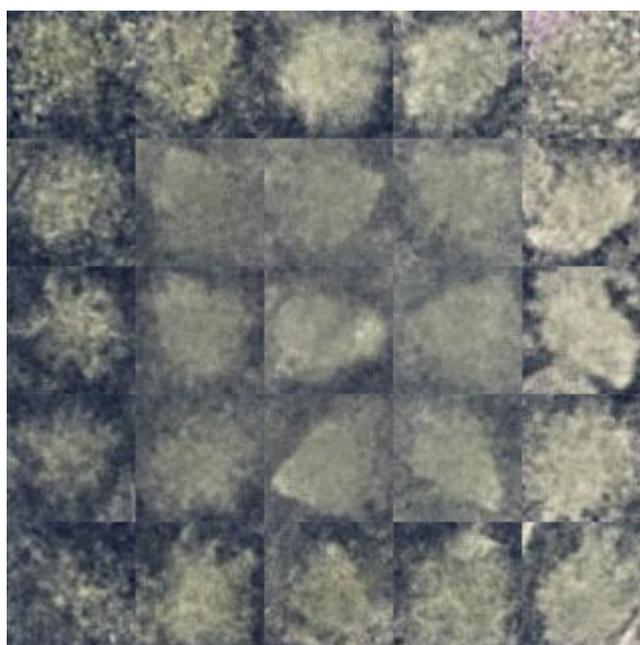


Рисунок 26 – Сгенерированные ослабленные деревья

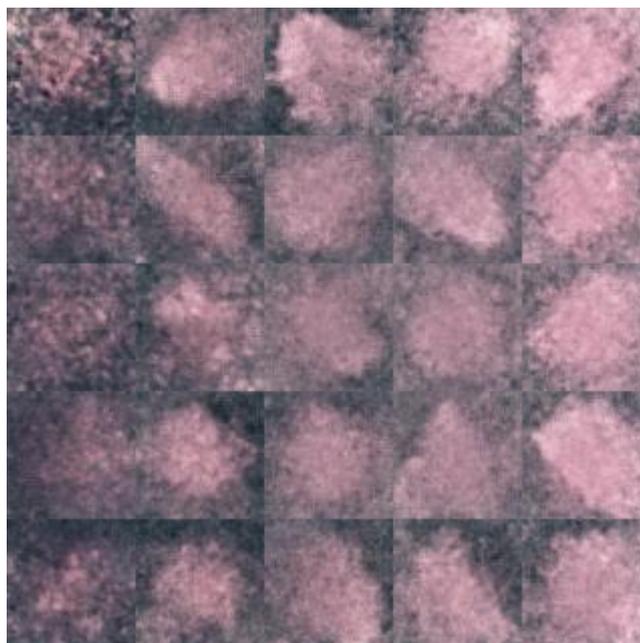


Рисунок 27 – Сгенерированный свежий сухостой

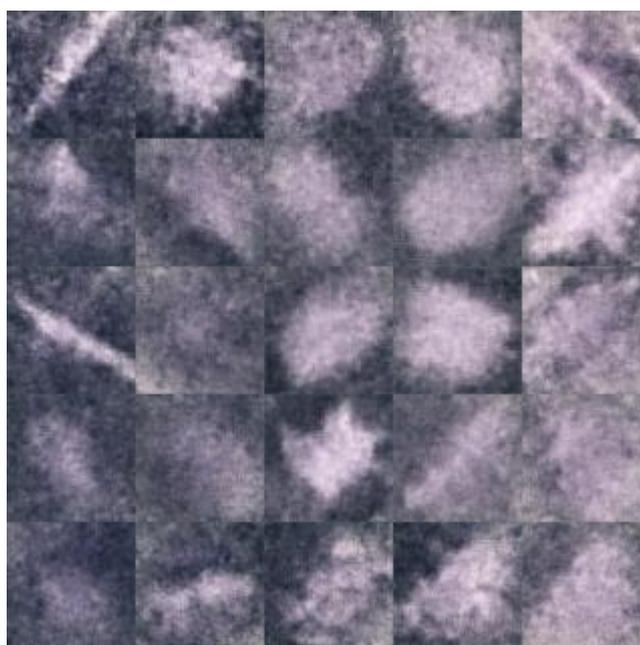


Рисунок 28 – Сгенерированный сухостой прошлых лет

Теперь при подготовке тренировочной выборки на фрагменты накладывались сгенерированные изображения каждого из 4 классов случайного размера (от 32*32 пикселя до 64*64 с равным соотношением сторон) таким образом, чтобы они не пересекались с уже имеющимися ограничивающими рамками.

Пример полученного изображения представлен на рисунке 29.

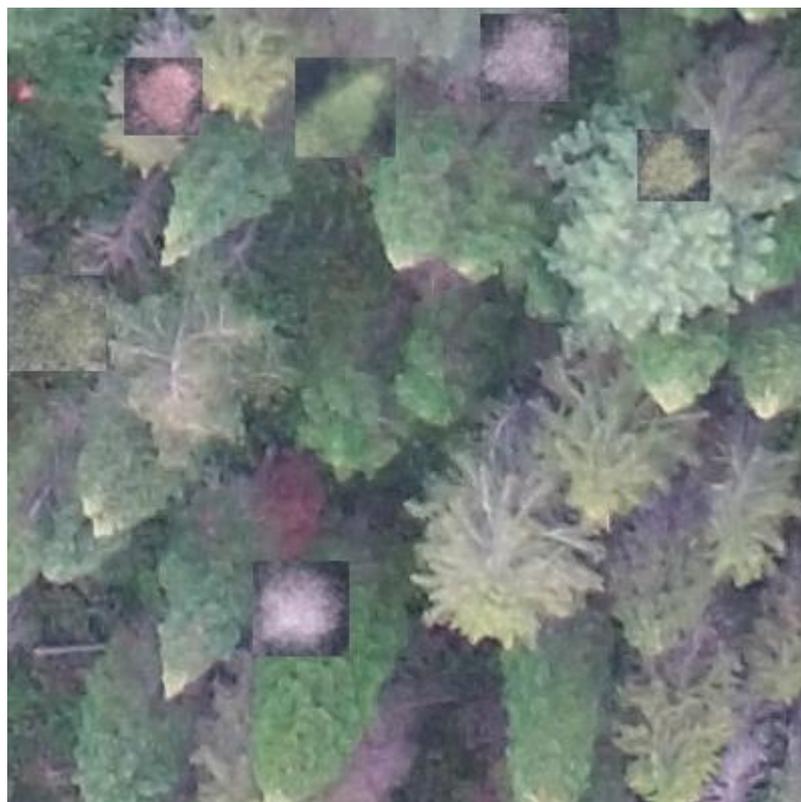


Рисунок 29 – Изображение, содержащее сгенерированные изображения деревьев

Расширение выборки с применением данного метода дало прирост к точности на 2% процента, имея показатель mAP 42,4% на валидационной выборке.

6.6 Анализ полученных результатов

В таблице 13 представлены конечные результаты точности при разных пороговых значениях вероятности принадлежности объекта к классу и скорости интерпретации снимков нейросетью RetinaNet (EfficientNet-B0).

Таблица 13 – Итоговые результаты

	Порог	Тренировочная выборка	Валидационная выборка	Тестовая выборка
Точность, mAP %	0.05	82,80	42,52	41,79
	0.5	78,10	32,10	33,62
	0.75	70,27	27,01	28,53
Точность, precision %	0.05	21,65	21,79	20,5
	0.5	74,48	48,78	50,65
	0.75	91,16	56,53	60,88
Полнота, recall %	0.05	88,63	68,49	69,23
	0.5	77,93	43,25	45,50
	0.75	68,76	34,13	36,45
Скорость, FPS		45,87		

Опираясь на показатели, приведённые в таблице 13, можно сделать вывод о том, что выбранная архитектура RetinaNet(EfficientNet-B0) позволяет интерпретировать снимки БПЛА в режиме реального времени и детектировать деревья пихт разной степени поражения уссурийским полиграфом с показателем mAP до 42,5% и со скоростью обработки 45 кадров в секунду.

Полученные показатели точности являются весьма высокими, но требуют повышения, за счёт применения более сложных методов расширения выборки и использования более новых архитектур, при их появлении.

7. Социальная ответственность

Введение

Объектом исследования данной ВКР является система детектирования с помощью свёрточных нейронных сетей поврежденных уссурийским полиграфом деревьев пихты на фотоснимках с беспилотных летательных аппаратов. Эксплуатация системы планируется происходить в офисном помещении. Офис, а также находящаяся в нем компьютерная и оргтехника, оказывают неблагоприятное воздействие на окружающую среду. Кроме того, при несоблюдении санитарных норм и правил, возможно, негативное влияние на здоровье сотрудников офиса.

Данный раздел посвящен вопросам производственной безопасности и гигиене труда, соблюдению санитарных норм и защиты сотрудников от негативного воздействия среды. Рассматриваются меры по охране окружающей среды и ресурсосбережению. Предлагается ряд решений для исключения возникновения несчастных случаев при разработке и эксплуатации системы детектирования деревьев пихт на фотоснимках.

Также исследуются правовые вопросы обеспечения безопасности, связанные с использованием разработанной системы.

7.1 Правовые и организационные вопросы обеспечения безопасности

7.1.1 Правовые и организационные мероприятия по обеспечению безопасности

Функции государственного надзора и контроля обеспечения безопасности осуществляются специально уполномоченными государственными органами и инспекциями согласно федеральным законам.

Для защиты прав сотрудников на труд в условиях, соответствующих принятым правилам и нормам, на территории Российской Федерации действуют следующие организации:

- Федеральная инспекция труда;
- Государственная экспертиза условий труда Федеральная служба по труду и занятости населения;
- Федеральная служба по надзору в сфере защиты прав потребителей и благополучия человека.

ТК РФ [23] и СанПиН 2.2.2/2.4.1340-03 [24] устанавливаются следующие правила и вводятся рекомендации, касающиеся работы сотрудников всех организаций на территории РФ:

- Нормальная продолжительность рабочего времени не должна превышать 40 часов в неделю.
- Продолжительность непрерывной работы за компьютером без перерыва не должна превышать 1 час;
- Рекомендуется делать перерывы в работе за компьютером продолжительностью 10-15 минут через каждые 45-60 минут работы. Во время перерывов целесообразно выполнять комплексы упражнений, в том числе упражнения для глаз, а также проветривать помещения;
- Не рекомендуется работать за компьютером более 6 часов за смену.

Для того чтобы рабочие места сотрудников соответствовали нормам, должен осуществляться производственный контроль и надзор внутри предприятия. Кроме того, предприятия следят за характеристиками используемой аппаратуры, персональных компьютеров и комплектующих.

7.1.2 Общие правовые нормы трудового законодательства

Государственный надзор и контроль в организациях независимо от организационно-правовых форм и форм собственности осуществляют специально уполномоченные на то государственные органы и инспекции в соответствии с федеральными законами. Согласно трудовому кодексу РФ [23]:

- продолжительность рабочего дня не должна превышать 40 часов в неделю;
- во время регламентированных перерывов целесообразно выполнять комплексы упражнений и осуществлять проветривание помещения.

Существуют также специализированные органы, осуществляющие государственный контроль и надзор в организациях на предмет соблюдения существующих правил и норм.

К таким органам относятся:

- Федеральная инспекция труда;
- Государственная экспертиза условий труда Федеральной службы по труду и занятости населения;
- Федеральная служба по надзору в сфере защиты прав потребителей и благополучия человека и др.

7.1.3 Организационные мероприятия при компоновке рабочей зоны

Рабочее место для выполнения работ по разработке либо эксплуатации нейронной сети, позволяющей детектировать на фотоснимках поврежденные деревья разной степени деградации, организуют при легкой работе, не требующей свободного передвижения работающего.

Конструкция рабочего места и взаимное расположение всех его элементов должны соответствовать антропометрическим, физиологическим и психологическим требованиям, а также характеру работы.

7.2 Производственная безопасность

Вредные и опасные факторы, воздействующие на сотрудника, устанавливаются согласно ГОСТ 12.0.003-2015 «Опасные и вредные производственные факторы. Классификация» [25].

Опасные и вредные факторы при выполнении работ по разработке и эксплуатации нейронной сети для детектирования поврежденных уссурийским полиграфом деревьев пихты на фотоснимках с беспилотных летательных аппаратов:

Таблица 14 – Возможные опасные и вредные факторы

Факторы (ГОСТ 12.0.003-2015 [25])	Этапы работ		Нормативные документы
	Разработка	Эксплуатация	
1.Отклонение параметров микроклимата.	+	+	Освещение, шум, статическое электричество, психофизиологические факторы: СанПиН 2.2.2/2.4.1340-03 [24] ТОИ П-45-084-01 [26] Микроклимат: СанПиН 2.2.4.548-96 [27] СанПиН 2.2.2/2.4.1340-03 [24] Электрический ток, короткое замыкание: ГОСТ 12.1.033-81 «Правила технической эксплуатации электроустановок потребителей» [28]
2.Превышение уровня шума	+		
3.Отсутствие или недостаток естественного света	+	+	
4.Недостаточная освещенность рабочей зоны	+	+	
5.Повышенное значение напряжения в электрической цепи, замыкание которой может пройти через тело человека	+	+	

7.2.1 Недостаточная освещенность рабочей зоны и отсутствие или недостаток естественного света

На время проектирования, а также эксплуатации нейронной сети для детектирования поврежденных уссурийским полиграфом деревьев пихты на фотоснимках с беспилотных летательных аппаратов за персональным компьютером к негативным факторам можно отнести повышенные уровни излучения, а также увеличенную нагрузку на зрительные органы.

Требования к освещению установлены в СП 52.13330.2016 Естественное и искусственное освещение. Актуализированная редакция СНиП 23-05-95* (с Изменением N 1) [29].

Таблица 15 – Требования к освещению на рабочих местах, оборудованных ПЭВМ

Характеристика зрительной работы		очень высокой точности	
Наименьший или эквивалентный размер объекта различия, мм		(0,15 - 0,3)	
Разряд зрительной работы		A	
Подразряд зрительной работы		2	
Относительная продолжительность зрительной работы при направлении зрения на рабочую поверхность, %		менее 70	
Естественное освещение	освещенность на рабочей поверхности от системы общего освещения, лк	(300 – 500)	
	цилиндрическая освещенность, лк	100	
	показатель дискомфорта M	не более 15	
	коэффициент пульсации освещенности K_p , %	10	
Искусственное освещение	КЕО e_n , %, при	верхнем или комбинированном	3,5
		боковом	1,2

7.2.2 Превышение уровня шума

Повышенный уровень шума характерен не только для промышленных предприятий, но и для бытовых приборов. Шумовой фон в современных городах сопоставим с допустимым максимумом.

Интенсивность шума – главная характеристика. Она тождественна громкости и измеряется в децибелах (дБ).

В производственных помещениях при выполнении работ по детектированию с помощью свёрточных нейронных сетей поврежденных уссурийским полиграфом деревьев пихты на фотоснимках с беспилотных летательных аппаратов с использованием ПЭВМ уровни шума на рабочих местах не должны превышать предельно допустимых значений, установленных для данных видов работ в соответствии с действующими санитарно-эпидемиологическими нормативами. СанПиН 2.2.2/2.4.1340-03

[24] установлены допустимые значения уровней звукового давления, создаваемого ПЭВМ.

Таблица 16 – Допустимые значения уровней звукового давления в октавных полосах частот и уровня звука, создаваемого ПЭВМ

Уровни звукового давления в октавных полосах со среднегеометрическими частотами, дБ									Уровни звука в дБА
31,5 Гц	63 Гц	125 Гц	250 Гц	500 Гц	1000 Гц	2000 Гц	4000 Гц	8000 Гц	
86	71	61	54	49	45	42	40	38	50

7.2.3 Отклонение параметров микроклимата

К числу показателей микроклимата, которые измеряют для его оценки, относятся следующие:

- скорость движения воздуха;
- относительная влажность воздуха;
- температура;
- интенсивность теплового облучения.

В производственных помещениях, в которых работа с использованием ПЭВМ является основной и связана с нервно-эмоциональным напряжением, должны обеспечиваться оптимальные параметры микроклимата для категории работ 1а и 1б в соответствии с действующими санитарно-эпидемиологическими нормативами микроклимата производственных помещений.

Содержание вредных химических веществ в производственных помещениях, в которых работа с использованием ПЭВМ является основной, не должно превышать предельно допустимых концентраций загрязняющих веществ в атмосферном воздухе населенных мест в соответствии с действующими гигиеническими нормативами.

Также указывается, что в помещениях с ПЭВМ должна ежедневно проводиться влажная уборка.

Уставленные гигиенические нормативы для помещений с ВДТ и ПЭВМ для категории работы 1б приведены в таблице.

Таблица 17 – Оптимальные величины показателей микроклимата на рабочих местах производственных помещений категории 1б (СанПиН 2.2.4.548-96 [27])

Период года	Категория работ по уровню энергозатрат	Температура воздуха, °С	Температура поверхностей, °С	Относительная влажность воздуха, %	Скорость движения воздуха, м/с
Холодный	1б (140-174 Вт)	(21 – 23)	(20 – 24)	(40 – 60)	0,1
Теплый		(22 – 24)	(21 – 25)	(40 – 60)	0,1

7.2.4 Повышенное значение напряжения в электрической цепи

К опасностям использования электрического тока относятся возможность поражения электрическим током, а также воспламенения электронных устройств из-за воздействия различных условий – попадания влаги или нарушения изоляции. Поражение электрическим током может привести к ожогам, судорогам, повреждению нервной системы, а также смерти. Возникновение пожара может привести к последствиям, описанным в ГОСТ 12.1.033-81 [28].

Во избежание негативных эффектов при разработке нейронной сети, позволяющей детектировать на фотоснимках поврежденные деревья разной степени деградации или при использовании ее по назначению необходимо соблюдать правила пожарной и электрической безопасности. Подготовка к возникновению данных ситуаций должна производиться до начала работы.

Требования безопасности при эксплуатации электрооборудования регламентируются следующими нормативными актами:

- Правилами устройства электроустановок (издание шестое с отдельными разделами и главами в издании седьмом), утвержденными Главтехуправлением, Госэнергонадзором Минэнерго СССР 05.10.19 г.

– Правилами технической эксплуатации электроустановок потребителей, утверждёнными Приказом Минэнерго России от 13.01.2003 г. №6;

Согласно им:

1. Электрооборудование, имеющее контакты для подключения заземления, должно быть заземлено, а помещения, где размещаются рабочие места с ПЭВМ, должны быть оборудованы защитным заземлением (занулением) в соответствии с техническими требованиями по эксплуатации оборудования;

2. Все крышки и защитные панели должны находиться на своих местах (при отсутствии крышки или защитной панели эксплуатация электрооборудования не допускается);

3. При работе с электрооборудованием не допускать попадания влаги на поверхность электрооборудования, а также запрещается работать на электрооборудовании влажными руками;

4. Вентиляционные отверстия электрооборудования не должны быть перекрыты находящимися вплотную стенами, мебелью, посторонними предметами;

5. Подключение и отключение разъемов компьютеров и оргтехники должно производиться при отключенном питании (за исключением подключения и отключения USB-устройств);

6. Удаление пыли с электрооборудования должно производиться в отключенном от электрической цепи состоянии

7. Перед использованием электроприборов необходимо проверить надёжность крепления электророзетки, свериться с номиналом используемого напряжения;

8. Корпуса штепсельных розеток и выключателей не должны содержать трещин, оплавлений и других дефектов, способных снизить защитные свойства или нарушить надёжность контакта;

9. Кабели (шнуры) электропитания не должны содержать повреждений изоляции, сильных изгибов и скручиваний;

Короткое замыкание может стать причиной пожара в помещении, при коротком замыкании от электрического тока могут пострадать люди, находящиеся в непосредственной близости от источника возникновения.

На рабочем месте короткое замыкание может быть вызвано либо неисправностью в проводке, либо при работе с компьютером/паяльным оборудованием, когда внутри корпуса создается разность фаз и ток может так же повредить всю электросеть.

Для защиты электрической сети от короткого замыкания предусмотрены устройства защитного отключения (УЗО), оснащенные устройствами автоматического отключения – автоматами и предохранителями. Кроме того, в помещении установлены датчики дыма, которые при возникновении возгорания, вызванного коротким замыканием, оповещают все здание о начавшемся пожаре. Таким образом, рабочее место полностью защищено от возможного короткого замыкания.

7.3 Экологическая безопасность

Разработка и эксплуатация системы детектирования с помощью свёрточных нейронных сетей поврежденных уссурийским полиграфом деревьев пихты на фотоснимках с беспилотных летательных аппаратов происходит в офисном помещении. Офис является источником следующих видов отходов:

- Твердые отходы: бумага, канцелярские принадлежности, комплектующие;
- Жидкие отходы: сточные воды;
- Люминесцентные лампы.

При использовании компьютера и другой вычислительной техники неизбежно устаревание моделей. В результате этого возникает необходимость замены и обновления оборудования. Чтобы уменьшить негативное

воздействие на экологическую обстановку, утилизировать электронику нужно наиболее безопасным для окружающей среды способом, то есть обратиться в специализированную компанию по утилизации. Такие компании действуют на всей территории Российской Федерации, в том числе и в Томской области.

Бумага может быть переработана и использована в качестве вторсырья. Для сбора макулатуры в России существуют специальные пункты приема. Некоторые из них предоставляют услугу вывоза макулатуры.

Сточные воды – один из источников загрязнения природных водоемов, так как они содержат различные загрязнения, в том числе мусор и примеси. В результате деятельности офисного предприятия происходит образование сточных вод. Для последующей очистки в системах канализации применяются отстаивание и фильтрация. Возможна дополнительная очистка с использованием озонаторов и ультрафиолета.

Отдельного внимания заслуживает вопрос утилизации люминесцентных ламп. Они покрыты люминесцентным веществом, имеют стеклянную оболочку и электроды. Внутри таких ламп находится инертный газ с парами ртути. В случае повреждения корпуса лампы пары ртути попадают в атмосферу. Поэтому после окончания срока службы люминесцентные лампы необходимо сдавать на специальные предприятия по утилизации, имеющие специальную лицензию на данный вид деятельности.

В Томске к таким предприятиям относятся Экотом, Полигон, Утилизация. Необходимо отметить, что в целом при работе с компьютером существенного загрязнения окружающей среды не происходит и вредные выбросы не сравнимы с производственными.

7.4 Безопасность в чрезвычайных ситуациях

Наиболее вероятная чрезвычайная ситуация которая может возникнуть при работе с ПЭВМ во время разработки либо эксплуатации нейронных сетей, позволяющих детектировать на фотоснимках поврежденные деревья разной

степени деградации – пожар, так как в современных ЭВМ очень высокая плотность размещения элементов электронных схем, в непосредственной близости друг от друга располагаются соединительные провода и кабели, при протекании по ним электрического тока выделяется значительное количество теплоты, при этом возможно оплавление изоляции и возникновение возгорания. Возникновение других видов ЧС – маловероятно.

Причинами пожаров могут быть:

- Несоблюдение правил пожарной безопасности;
- Неисправность электропроводки;
- Возгорание электроприборов по причине неисправности или в результате неправильной эксплуатации;
- Курение вне специально отведенных мест.

В качестве противопожарных мероприятий должны быть применены следующие меры:

- В помещении должны находиться средства тушения пожара, средства связи;
- Электрическая проводка электрооборудования и осветительных приборов должна быть исправна;
- Все сотрудники должны знать место нахождения средств пожаротушения и уметь ими воспользоваться, средств связи и номера экстренных служб.

В связи с возможностью возникновения пожара разработан следующий план действий:

- В случае возникновения пожара сообщить о нем руководителю, постараться устранить очаг возгорания имеющимися силами при помощи первичных средств пожаротушения (огнетушитель порошковый, углекислотный О-1П0(з)-АВСЕ);
- Привести в действие ручной извещатель, если очаг возгорания потушить не удастся;

- Сообщить о возгорании в службу пожарной охраны по телефону 01 или 101, сообщить адрес, место и причину возникновения пожара;
- Принять меры по эвакуации людей и материальных ценностей;
- Встретить пожарную охрану, при необходимости сообщить всю необходимую информацию и оказать помощь при выборе наилучшего подхода к очагу возгорания;

Каждый сотрудник должен быть ознакомлен с планом эвакуации из помещения, с расположением выходов из здания. Плановые учебные эвакуации необходимы, чтобы подготовить сотрудников к действиям в чрезвычайной ситуации.

8. Финансовый менеджмент, ресурсоэффективность и ресурсосбережение

Введение

В настоящее время во многие сферы жизни проникают информационные технологии. Автоматизированные системы позволяют более точно и быстро решать огромное количество типов задач.

Одним из примеров таких задач, информационное решение для которого еще не разработано, является автоматизированная интерпретация снимков беспилотного летательного аппарата с помощью свёрточных нейронных сетей для детектирования поврежденных уссурийским полиграфом деревьев пихты.

В ходе данной работы была создана программа на основе нейронной сети, которая находит на снимке деревья пихты и классифицирует их по степени повреждения.

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

Цель экономического раздела - провести детальный анализ проекта по критериям конкурентоспособности и ресурсоэффективности. Оценить перспективность проекта, определить трудоемкость и график работ, а также рассчитать интегральный показатель ресурсоэффективности.

8.1.1 Потенциальные потребители результатов исследования

В ходе выпускной квалификационной работы были проведены исследования потребности рынка в алгоритме интерпретации снимков, сделанных беспилотным летательным аппаратом, с помощью нейронных сетей.

Для определения потенциальных потребителей требуется определить целевой рынок и произвести его сегментирование. В данном случае целевым рынком являются:

- разработчики ПО;
- экологи, анализирующие снимки вручную;

Конечными потребителями являются программисты и экологи.

8.1.2 Анализ конкурентных технических решений

Алгоритмы интерпретации снимков беспилотных летательных аппаратов являются совокупностью различных методов. Такое ПО является узкоспециализированным, известна только одна коммерчески продающаяся программа – ArcGISPro компании ArcGIS. Данное ПО позиционируется как геоинформационный программный продукт для работы с географическими данными. Программа ArcGISPro позволяет работать с многоканальными изображениями, используя различные методы анализа снимков, значительно упрощая процесс, относительно интерпретации снимков без специального ПО. Данная компания продает ArcGISPro лицензией на 1 год за 8000р.

Недостатком является то, что данное ПО не предназначено для решения задачи детектирования пихт, поражённых уссурийским полиграфом, так как данная задача является узконаправленной и имеет некоторую специфику.

Альтернативным продуктом является ПО, автоматизирующее интерпретацию снимков с помощью четких алгоритмов. Но данный подход имеет обобщенный характер и не способен с большой точностью решать задачи с детектированием поврежденных пихт.

Обработка снимков экологами вручную является трудозатратной и экономически затратной задачей.

Из этого можно сделать вывод, что требуется разработать алгоритм, который будет автоматизировать интерпретацию снимков для решения конкретной задачи.

Проведем анализ конкурентного технического решения с помощью оценочной карты.

Позиция разработки и конкурентов оценивается по каждому показателю экспертным путем по пятибалльной шкале, где 1 – наиболее слабая позиция, а 5 – наиболее сильная. Веса показателей, определяемые экспертным путем, в сумме должны составлять 1.

Таблица 18 – Оценочная карта

Критерии оценки	Вес критерия	Баллы				Конкурентоспособность			
		Бф	Бк1	Бк2	Бк3	Кф	Кк1	Кк2	Кк3
1	2	3	4	5	6	7	8	9	10
Технические критерии оценки ресурсоэффективности									
1. Простота использования системы	0,10	5	5	5	3	0,50	0,50	0,50	0,30
2. Удобный интерфейс пользователя	0,10	4	4	4	4	0,40	0,40	0,40	0,40
1	2	3	4	5	6	7	8	9	10
3. Функциональные возможности	0,30	4	1	2	5	1,20	0,30	0,60	1,50
4. Скорость обработки данных	0,08	4	4	4	4	0,32	0,32	0,32	0,32
5. Потребность в ресурсах памяти	0,08	4	5	5	4	0,32	0,40	0,40	0,32
Экономические критерии оценки эффективности									
6. Цена	0,20	5	5	5	3	1,00	1,00	1,00	0,60
7. Послепродажное обслуживание	0,05	4	4	4	5	0,20	0,20	0,20	0,25
8. Предполагаемый срок эксплуатации	0,09	5	5	5	5	0,45	0,45	0,45	0,45
Итого	1					4,74	3,57	3,87	4,14

Где Б_ф- разрабатываемый алгоритм, Б_{к1} - программа компании ArcGISPro, Б_{к2} –специалисты-экологи, Б_{к3} – ПО с классическими алгоритмами.

Конкурентоспособность рассчитываем по формуле:

$$K = \sum B_i * B_i$$

где K – конкурентоспособность научной разработки, B_i – вес показателя (в долях единицы), B_i – балл i-го показателя.

Преимущество перед конкурентом: низкая цена, помехоустойчивость, надежность ПО, ремонтпригодность (применительно к программному продукту), персонализация. Конкуренты выигрывают в удобстве эксплуатации, и функциональной мощности продукта.

Для улучшения разрабатываемого продукта применены другие технологии для достижения сходной цели.

8.1.3 Технология QuaD

Технология QuaD (QUalityADvisor) это инструмент измерения характеристик, который описывает качество новой разработки, а также ее перспективность на рынке. Технология позволяет принимать решение о целесообразности вложения капитала в НИР. Технология может использоваться при проведении различных маркетинговых исследований, существенно снижая их трудоемкость и повышая точность и достоверность результатов. Оценочная карта представлена в таблице 19.

Таблица 19 – Таблица QuaD

Критерии оценки	Вес критерия	Баллы	Максимальный балл	Относительное значение (3/4)	Средневзвешенное значение (5x2)
1	2	3	4	5	6
Показатели оценки качества разработки					
1. Энергоэффективность	0.12	80	100	0.80	0.096
2. Помехоустойчивость	0.12	80	100	0.80	0.096
3. Надежность	0.08	100	100	1.00	0.08

4. Мобильность	0.05	100	100	1.00	0.05
5. Персонализация	0.05	100	100	1.00	0.05
6. Безопасность	0.00	100	100	1.00	0.00
7. Функциональная мощность (предоставляемые возможности)	0.12	80	100	0.80	0.096
8. Простота эксплуатации	0.12	100	100	1,00	0.12
9. Качество интеллектуального интерфейса	0.12	80	100	0.80	0.096
10. Ремонтопригодность	0.10	80	100	0.80	0.08
Показатели оценки коммерческого потенциала разработки					
11. Перспективность рынка	0.05	60	100	0.60	0.03
12. Цена	0,07	100	100	1.00	0.07
Итого	1			10.6	0,864

Оценка качества и перспективности по технологии QuaD определяется по формуле:

$$P_{\text{ср}} = \sum P_i * 100 = 0.864 * 100 = 86,4$$

где: $P_{\text{ср}}$ – средневзвешенное значение показателей качества и перспективности научной разработки; P – средневзвешенное значение показателя.

Значение $P_{\text{ср}}$ позволяет говорить о перспективах разработки и качестве проведенного исследования. Если значение показателя $P_{\text{ср}}$ получилось от 100 до 80, то такая разработка считается перспективной. Если от 79 до 60 – то перспективность выше среднего. Если от 69 до 40 – то перспективность средняя. Если от 39 до 20 – то перспективность ниже среднего. Если 19 и ниже – то перспективность крайне низкая.

Из таблицы можно сделать вывод, что разработку можно считать перспективной.

8.1.4 SWOT-анализ

SWOT – Strengths (сильные стороны), Weaknesses (слабые стороны), Opportunities (возможности) и Threats (угрозы) – это комплексный анализ научно-исследовательского проекта. Такой анализ применяют для исследования внешней и внутренней среды проекта. Составим матрицу SWOT:

Таблица 20 – SWOT матрица

	Сильные стороны научно-исследовательского проекта: С1. Надежность С2. Мобильность С3. Персонализация С4. Безопасность С5. Простота эксплуатации	Слабые стороны научно-исследовательского проекта: Сл1. Отсутствие прототипа научной разработки Сл2. Отсутствие финансирования Сл3. Повышенные требования к производительности «железа» Сл4. Отсутствие репутации на рынке

<p>Возможности:</p> <p>В1. Использование инновационной инфраструктуры ТПУ</p> <p>В2. Повышение качества детектирования</p> <p>В3. Появление дополнительного спроса на новый продукт</p>	<p>При использовании инфраструктуры ТПУ можно снизить стоимость проекта. Использование новых подходов (глубокое обучение) может повысить качество детектирования пораженных деревьев на снимках.</p>	<p>Появление дополнительного спроса на рынке может способствовать финансированию проекта. Проводя исследования на базе ТПУ, можно разработать прототип и получить известность на рынке</p>
<p>Угрозы:</p> <p>У1. Высокие требования к «железу» разработанного продукта</p> <p>У2. Неудовлетворительное качество работы разработки</p>	<p>Высокие требования к «железу» обусловлены спецификой разрабатываемого алгоритма. Качество работы можно повысить за счет сбора качественной выборки.</p>	<p>Необходимо разработать прототип алгоритма и пройти сертификацию для того, чтобы выйти на рынок и заполучить репутацию.</p>

8.1.5 Морфологический анализ

Морфологический подход основан на систематическом исследовании всех теоретически возможных вариантов, которые вытекают из закономерностей объекта исследования. Анализ охватывает все возможные варианты. Путем комбинирования вариантов можно получить большое количество различных решений, ряд которых представляет практический интерес. Составим таблицу, в которой будут отражены возможные варианты исполнения по различным проблемам разработки.

Таблица 21 – Морфологический анализ

Характеристика	Варианты исполнения		
	1	2	3
Язык программирования	C++	R	Python
Вид нейронных сетей	Сверточные	Капсюльные	Полносвязные
Реализация	Веб-приложение	Десктопприложение	Библиотека

На данный момент на рынке нет программы для детектирования на снимках беспилотного летательного аппарата поражённых деревьев пихт достаточного качества и удобной в использовании для интерпретации снимков.

Использование нейронных сетей позволяет добиться нового уровня качества, однако они не используются в коммерческих решениях на данный момент.

8.2 Планирование научно-исследовательских работ

8.2.1. Структура работ в рамках научного исследования

Трудоемкость выполнения проекта оценивается в человеко-часах и зависит от множества факторов, которые сложно учесть при разработке. Для реализации проекта необходимо 2 исполнителя – научный руководитель (НР), студент (С). Этапы работы проекта представлены в таблице 22.

Таблица 22 – Этапы работы проекта

Основные этапы	№ этапа	Содержание работ	Исполнитель
Разработка задания	1	Постановка задачи	НР, С

Выбор направления исследования	2	Обзор научно-технической базы	НР, С
	3	Разработка и утверждение ТЗ	НР, С
	4	Составление календаря проекта	С
	5	Разработка вариантов исполнения проекта	НР, С
Теоретические исследования	6	Сбор обучающих данных	С
	7	Разработка модуля чтения и предобработки данных	С
	8	Создание модели машинного обучения	С
	9	Обучение и настройка гиперпараметров алгоритма с учетом метрик качества	С
Экспериментальные исследования	10	Проверка работы алгоритма на тестовых данных	НР, С
Оформление отчета по НИР	11	Составление пояснительной записки	С

8.2.2 Определение трудоемкости выполнения работ

Основная часть стоимости разработки зачастую приходится на заработную плату исполнителей, поэтому важно определить трудоемкость каждого из участников. Ожидаемая трудоемкость находится по формуле

$$t_{ожі} = \frac{3 * t_{mini} + 2 * t_{maxi}}{5}$$

где $t_{ожі}$ – ожидаемая трудоемкость выполнения i -ой работы чел.-дн.;

t^{mini} – минимально возможная трудоемкость выполнения заданной i -ой работы (оптимистическая оценка: в предположении наиболее благоприятного стечения обстоятельств), чел.-дн.; t^{maxi} – максимально возможная трудоемкость выполнения заданной i -ой работы (пессимистическая оценка: в предположении наиболее неблагоприятного стечения обстоятельств), чел.-дн.

Исходя из ожидаемой трудоемкости работ, определяется продолжительность каждой работы в рабочих днях T_{pi} , учитывающая параллельность выполнения работ несколькими исполнителями:

$$t_{pi} = \frac{t_{ожi}}{Ч_i}$$

где t_{pi} – продолжительность одной работы, раб.дн., $t_{ожi}$ – ожидаемая трудоемкость выполнения одной работы, чел.-дн, $Ч_i$ – численность исполнителей, выполняющих одновременно одну и ту же работу на данном этапе, чел.

Длительность каждого из этапов работ из рабочих дней следует перевести в календарные дни. Для этого необходимо воспользоваться следующей формулой. Для примера произведём расчёт первого этапа работы руководителя:

$$T_{ki} = T_{pi} * k_{кал}$$

где t_{ki} – продолжительность выполнения i -й работы в календарных днях; t_{pi} – продолжительность выполнения i -й работы в рабочих днях; $k_{кал}$ – коэффициент календарности.

Коэффициент календарности определяется по следующей формуле:

$$k_{кал} = \frac{t_{кал}}{t_{кал} - t_{вых} - t_{пр}} = \frac{365}{365 - 104 - 16} = 1,5$$

где: $t_{\text{кал}}$ – количество календарных дней в году; $t_{\text{вых}}$ – количество выходных дней в году; $t_{\text{пр}}$ – количество праздничных дней в году.

В таблице 23 находятся расчеты этапов отдельных видов работ.

Таблица 23 – Временные показатели проведения научного исследования

Название работы	Трудоёмкость работ						Длительность работ в рабочих днях	Длительность работ в календарных днях		
	t_{min} чел-дни		t_{max} чел-дни		$t_{\text{ож}i}$ чел-дни		t_{pi}	t_{ki}		
	Студент	Научный руководитель	Студент	Научный руководитель	Студент	Научный руководитель	Одновременное выполнение работ		Одновременное выполнение работ	
							Студент	Научный руководитель	Студент	Научный руководитель
Постановка задачи	5	3	8	6	6,2	4,2	3,1	2,1	5	4
Обзор научнотехнической базы	7	2	12	4	9	2,8	4,5	1,4	7	3
Разработка и утверждение ТЗ	7	1	12	2	9	1,4	4,5	0,7	7	2
Составление календаря проекта	3	0	5	0	3,8	0	3,8	0	6	0

Разработка вариантов исполнения проекта	9	4	16	7	11,8	5,2	5,9	2,6	9	4
Сбор обучающих данных	5	0	9	0	6,6	0	6,6	0	10	0
Разработка модуля чтения и предобработки данных	10	0	20	0	14	0	14	0	21	0
Создание модели машинного обучения	10	0	20	0	14	0	14	0	21	0
Обучение и настройка гиперпараметров алгоритма с учетом метрик качества	10	0	20	0	14	0	14	0	21	0
Проверка работы алгоритма на тестовых данных	6	1	14	8	9,2	3,8	4,6	1,9	7	3
Составление пояснительной записки	7	0	14	0	9,8	0	9,8	0	15	0
Итого									129	16

8.2.3 Разработка графика проведения научного исследования

По таблице 23 составим таблицу 24 – продолжительность работ проведения НИОКР.

Таблица 24 – Продолжительность работ проведения НИОКР

№ этапа	Этап	Исполнитель	T_{ki}
1	Постановка задачи	НР	4
		С	5
2	Обзор научно-технической базы	НР	3
		С	7
3	Разработка и утверждение ТЗ	НР	2
		С	7
4	Составление календаря проекта	С	6
5	Разработка вариантов исполнения проекта	НР	4
		С	9
6	Сбор обучающих данных	С	10
7	Разработка модуля чтения и предобработки данных	С	21
8	Создание модели машинного обучения	С	21
9	Обучение и настройка гиперпараметров алгоритма с учетом метрик качества	С	21
10	Проверка работы алгоритма на тестовых данных	НР	3
		С	7
11	Составление пояснительной записки	С	15

По данным из таблицы 24 «Продолжительность работ проведения НИОКР» создадим диаграмму Ганта студента (рисунок 30) и преподавателя

(рисунок 31), которая строилась при максимальном количестве дней каждой работы.

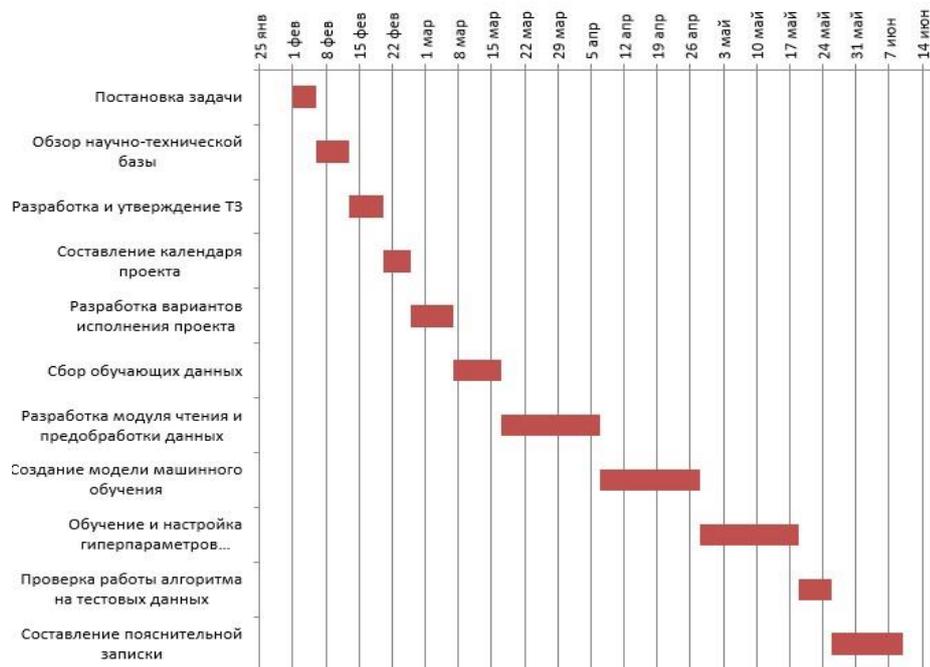


Рисунок 30 – Диаграмма Ганта. График работы студента.

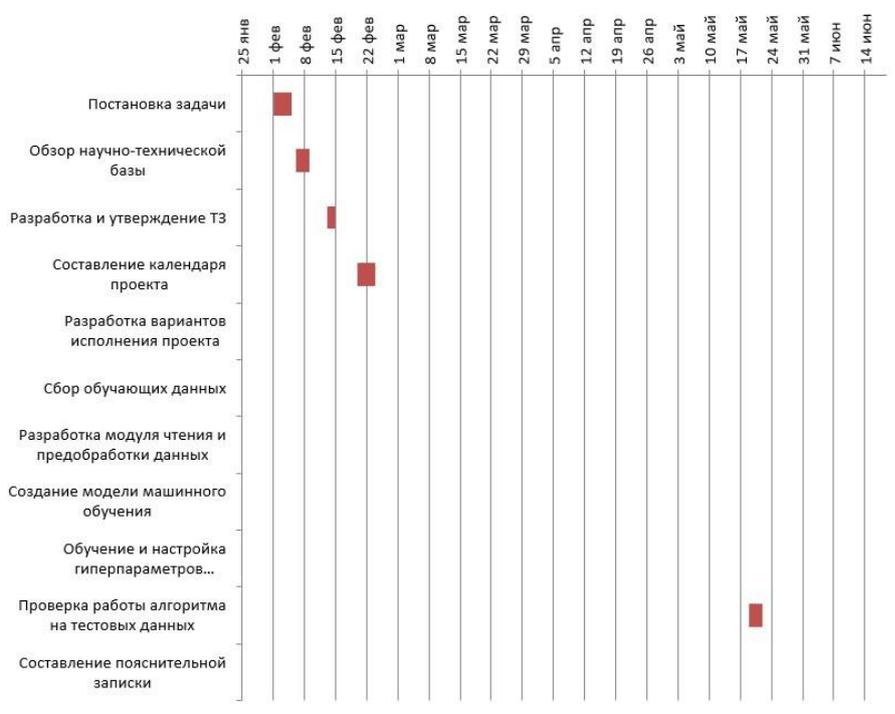


Рисунок 31 – Диаграмма Ганта. График работы научного руководителя

8.2.4 Бюджет научно-технического исследования

Бюджет научно-технического исследования должен быть основан на достоверном отображении всех видов расходов, связанных выполнением проекта. В процессе формирования бюджета разработки используется следующая группировка затрат по статьям:

- материальные затраты НТИ;
- затраты на специальное оборудование для научных работ;
- основная заработная плата исполнителей темы;
- дополнительная заработная плата исполнителей темы;
- отчисления во внебюджетные фонды;
- затраты на научные и производственные командировки (равны нулю для данного проекта);
- контрагентные расходы (равны нулю для данного проекта);
- накладные расходы.

8.2.5 Расчет материальных затрат НТИ

Расчет материальных затрат осуществляется по следующей формуле:

$$Z_m = (1 + k_T) \cdot \sum_{i=1}^m C_i \cdot N_{расхi},$$

где m – количество видов материальных ресурсов, потребляемых при выполнении научного исследования;

$N_{расхi}$ – количество материальных ресурсов i -го вида, планируемых к использованию при выполнении научного исследования (шт., кг, м, м² и т.д.);

C_i – цена приобретения единицы i -го вида потребляемых материальных ресурсов (руб./шт., руб./кг, руб./м, руб./м² и т.д.); k_T – коэффициент, учитывающий транспортно-заготовительные расходы.

При расчете количества электроэнергии учитывалось, что ноутбук потребляет около 60 Вт в час. Расчет материальных затрат приведен в таблице 25.

Таблица 25 – Материальные затраты

Наименование	Единица измерения	Количество			Цена за ед., руб.			Затраты на материалы, (З _м), руб.		
		Исп. 1	Исп. 2	Исп. 3	Исп. 1	Исп. 2	Исп. 3	Исп. 1	Исп. 2	Исп. 3
Оплата электроэнергии	КВт·ч	60,5	59,0	62,9	2,45			148,2	144,6	154,1
Итого								148,2	144,6	154,1

8.2.6 Расчет затрат на специальное оборудование для научных работ

В таблице 9 приведены значения затрат на специальное оборудование для трех альтернативных вариантов с учетом того, что новое оборудование не покупалось, затраты были вычислены в виде амортизационных отчислений (с учетом срока службы оборудования 5 лет, и использования его 0,5 года).

Сумма амортизации была вычислена по формуле 5.

$$A = \frac{C}{\text{СПИ} \cdot 12} \cdot \text{СИ},$$

где А – итоговая сумма амортизации основных средств, рублей;

С – первоначальная стоимость, рублей;

СПИ – срок полезного использования, лет;

СИ – срок использования для выполнения данной темы, месяцев.

Таблица 26 – Расчет бюджета затрат на приобретение спецоборудования для научных работ

№ п/п	Наименование оборудования			Кол-во единиц оборудования			Цена единицы оборудования, тыс. руб.			Общая стоимость оборудования, тыс. руб.		
	Исп. 1	Исп. 2	Исп. 3	Исп. 1	Исп. 2	Исп. 3	Исп. 1	Исп. 2	Исп. 3	Исп. 1	Исп. 2	Исп. 3
1.	Ноутбук			2	1	2	22,5			45,0	22,5	45,0
2.	Компьютерная мышь			2	1	2	0,2			0,4	0,2	0,4
Итого:										45,4	22,7	45,4

8.2.7 Основная заработная плата исполнителям темы

Статья включает основную заработную плату работников, непосредственно занятых выполнением НИИ, (включая премии, доплаты) и дополнительную заработную плату. Она рассчитывается по формуле

$$Z_{зп} = Z_{осн} + Z_{доп}$$

где $Z_{осн}$ – основная заработная плата;

$Z_{доп}$ – дополнительная заработная плата (12-20 % от $Z_{осн}$).

Среднедневная заработная плата рассчитывается по формуле:

$$Z_{дн} = \frac{Z_{м} * M}{F_{д}}$$

где $Z_{м}$ – месячный должностной оклад работника, руб.; M – количество месяцев работы без отпуска в течение года: при отпуске в 24 раб. дня $M = 11,2$ месяца, 5-дневная неделя; при отпуске в 48 раб. дней $M = 10,4$ месяца, 6-дневная неделя; при отпуске в 72 раб. дней $M = 9,6$. $F_{д}$ – действительный годовой фонд рабочего времени научно- технического персонала, раб. дн.

Таблица 27 – Баланс рабочего времени

Показатели рабочего времени	Руководитель	Студент
Календарное число дней	365	365
Количество нерабочих дней - выходные дни - праздничные дни	120	120
Потери рабочего времени - отпуск - невыходы по болезни	48	72

Действительный годовой фонд рабочего времени	197	173
--	-----	-----

Месячный оклад работника рассчитывается по формуле:

$$Z_m = Z_{тс} * (1 + k_{пр} + k_d) * k_p$$

где $Z_{тс}$ – заработная плата по тарифной ставке, руб.; $k_{пр}$ – премиальный коэффициент, равный 0,3 (т.е. 30% от $Z_{тс}$); k_d – 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 $Z_{тс}$); k_p – районный коэффициент, равный 1,3 (для Томска).

Расчёт основной заработной платы приведён в таблице 28.

Таблица 28 – Расчет основной заработной платы

Исполнители	$Z_{окл}$, руб.	k_p	Z_m , руб.	$Z_{дн}$, руб.	T_p , раб. дн.			$Z_{осн}$, руб.		
					Исп. 1	Исп. 2	Исп. 3	Исп. 1	Исп. 2	Исп. 3
Руководитель	33664,0	1,3	43763,2	1870,8	7	7	7	13095,6	13095,6	13095,6
Студент	21760,0	1,3	28288,0	1167,4	129	123	134	150594,6	143590,2	156431,6
Итого:								163690,2	156685,8	169527,2

8.2.8 Дополнительная заработная плата

Дополнительная заработная плата включает заработную плату за не отработанное рабочее время, но гарантированную действующим законодательством. Расчет дополнительной заработной платы ведется по формуле:

$$Z_{доп} = k_{доп} * Z_{осн}$$

где $k_{доп}$ – коэффициент дополнительной заработной платы (на стадии проектирования принимается равным 0,12 – 0,15). $k_{доп}$ равен 0,12.

8.2.9 Отчисления во внебюджетные фонды (страховые отчисления)

Величина отчислений во внебюджетные фонды определяется исходя из формулы:

$$З_{внеб} = k_{внеб} * (З_{осн} + З_{доп})$$

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

На 2018 г. в соответствии с Федеральным законом от 24.07.2009 №212-ФЗ установлен размер страховых взносов равный 30%. На основании пункта 1 ст.58 закона №212-ФЗ для учреждений, осуществляющих образовательную и научную деятельность в 2018 году пониженная ставка – 27,1%. Отчисления во внебюджетные фонды представлены в таблице 29.

Таблица 29 – Отчисления во внебюджетные фонды

Исполнитель	Основная заработная плата, руб.			Дополнительная заработная плата, руб.		
	Исп. 1	Исп. 2	Исп. 3	Исп. 1	Исп. 2	Исп. 3
Руководитель	13095,6	13095,6	13095,6	1571,5	1571,5	1571,5
Студент	150594,6	143590,2	156431,6	18071,352	17230,824	18771,792
Итого						
Исполнение 1	49683,25					
Исполнение 2	47557,27					
Исполнение 3	51454,9					

8.2.10 Накладные расходы

Накладные расходы учитывают прочие затраты организации, не попавшие в предыдущие статьи расходов: печать и ксерокопирование материалов, оплата услуг связи, электроэнергии и т.д. Расчет накладных расходов определяется по формуле:

$$З_{нак} = \sum C_T * k_{нр}$$

где $k_{нр}$ – коэффициент, учитывающий накладные расходы,

C_T – затраты по статьям накладных расходов.

8.2.11 Контрагентные расходы

Контрагентные расходы включают затраты, связанные с выполнением каких-либо работ по теме сторонними организациями (контрагентами, субподрядчиками)

В данном проекте контрагентные работы отсутствуют.

8.2.12 Формирование бюджета затрат научно-исследовательского проекта

Рассчитанная величина затрат научно-исследовательской работы является основой для формирования бюджета затрат проекта. Определение бюджета затрат на научно-исследовательский проект по каждому варианту исполнения приведен в таблице 30.

Таблица 30 – Расчет бюджета затрат НИИ

Наименование статьи	Сумма, руб.		
	Исп. 1	Исп. 2	Исп. 3
1. Материальные затраты НИИ	148,2	144,6	154,1
2. Затраты на специальное оборудование для научных работ	45400,0	22700,0	45400,0
3. Затраты по основной заработной плате исполнителей темы	163690,2	156685,8	169527,2
4. Затраты по дополнительной заработной плате исполнителей темы	19642,824	18802,296	20343,264
5. Отчисления во внебюджетные фонды	49683,25	47557,27	51454,9
6. Затраты на научные и производственные командировки	0	0	0
7. Контрагентские расходы	0	0	0
8. Накладные расходы	44570,32	39342,39	45900,71
9. Бюджет затрат НИИ	323134,8	285232,4	332780,2

ТПУ частично финансирует проект, предоставляя аудиторию для работы, ПК, заработную плату и иных ресурсов.

8.2.13 Определение ресурсной, финансовой и экономической эффективности ресурсов

Определение эффективности происходит на основе расчета интегрального показателя эффективности научного исследования. Его нахождение связано с определением двух средневзвешенных величин: финансовой эффективности и ресурсоэффективности.

Интегральный финансовый показатель разработки определяется как:

$$I_{\text{финр}}^{\text{исп.}i} = \frac{\Phi_{pi}}{\Phi_{\text{max}}},$$

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. Интегральный показатель ресурсоэффективности вариантов исполнения объекта исследования определяется следующей формулой:

$$I_{pi} = \sum a_i \cdot b_i,$$

где I_{pi} – интегральный показатель ресурсоэффективности для i -го варианта исполнения разработки; a_i – весовой коэффициент i -го варианта исполнения разработки; b_i – балльная оценка i -го варианта исполнения разработки, устанавливается экспертным путем по выбранной шкале оценивания.

Критерии, их весовые коэффициенты и оценки вариантов исполнения разработки, необходимые для расчета, представлены в таблице 31.

Таблица 31 – Сравнительная оценка характеристик вариантов исполнения проекта

Критерии	Весовой коэффициент параметра	Исп.1	Исп.2	Исп.3
1. Простота использования системы	0,2	5	4	4
2. Скорость разработки	0,2	5	2	4
3. Функциональные возможности	0,5	4	4	3
4. Скорость обработки данных	0,1	4	4	3
5. Потребность в ресурсах памяти	0,1	4	3	5
ИТОГО	1			

$$I_{p-исп1} = 5 * 0,2 + 5 * 0,2 + 4 * 0,5 + 4 * 0,1 + 4 * 0,1 = 4,8$$

$$I_{p-исп2} = 4 * 0,2 + 2 * 0,2 + 4 * 0,5 + 4 * 0,1 + 3 * 0,1 = 3,9$$

$$I_{p-исп3} = 4 * 0,2 + 4 * 0,2 + 3 * 0,5 + 3 * 0,1 + 5 * 0,1 = 3,9$$

Интегральный показатель эффективности вариантов исполнения разработки $I_{исп.i}$ определяется по формуле:

$$I_{исп.i} = \frac{I_{p-исп.i}}{I_{финр.i}}$$

Сравнение интегрального показателя эффективности вариантов исполнения разработки позволяет определить сравнительную эффективность проекта, представленную в таблице 31, и выбрать лучший вариант из предложенных. Сравнительная эффективность проекта $\mathcal{E}_{ср}$ рассчитывается по следующей формуле:

$$\mathcal{E}_{ср} = \frac{I_{исп.i}}{I_{исп.max}}$$

Таблица 32 – Сравнительная эффективность разработки

№ п/п	Показатели	Исп. 1	Исп. 2	Исп. 3
1	Интегральный финансовый показатель разработки	0,97	0,87	1,00
2	Интегральный показатель ресурсоэффективности разработки	4,80	3,90	3,90
3	Интегральный показатель эффективности	4,95	4,48	3,90
4	Сравнительная эффективность вариантов исполнения	1,00	0,91	0,79

Согласно значениям интегрального показателя эффективности, наиболее эффективным является вариант исполнения 1.

Первый вариант разработки имеет наивысший интегральный показатель ресурсоэффективности и второй по величине интегральный финансовый показатель. Данный вариант не является самым недорогим, но обеспечивает максимальное удобство разработки и использования, производительности и скорость разработки.

Заключение

В данной работе ставилась и решалась задача детектирования деревьев пихт, пораженных уссурийским полиграфом, на снимках с БПЛА с помощью свёрточных нейронных сетей. При этом были получены следующие результаты:

- Проведён сравнительный анализ существующих архитектур СНС для решения задач детектирования объектов на изображении, в частности на снимках БПЛА, в ходе которого была выбрана архитектура RetinaNet;
- Создана обучающая выборка для обучения RetinaNet из исходных снимков БПЛА;
- Проведено обучение и применены различные методы расширения обучающей выборки для обучения СНС до более высоких показателей точности;
- Получена обученная СНС детектирующая деревья пихт разной категории поражения уссурийским полиграфом с показателем mAP 42,52% и скоростью обработки 45,87 FPS.

Полученная свёрточная нейронная сеть имеет весьма высокий показатель точности mAP, но данный показатель требует повышения для более корректной интерпретации снимков. Повышение показателя точности нейросетевого алгоритма можно достичь, применив более сложные генеративные сети для создания реалистичных снимков, а также расширив обучающую выборку за счёт разметки новых реальных снимков.

Список источников

1. Кривец С.А. и др. Технология мониторинга пихтовых лесов в зоне инвазии уссурийского полиграфа в Сибири / изд. Дюкарев А.Г., Кривец С.А., Томск: УМИУМ, 2018. 74 p.
2. Safonova A. et al. Detection of Fir Trees (*Abies sibirica*) Damaged by the Bark Beetle in Unmanned Aerial Vehicle Images with Deep Learning // *Remote Sens.* 2019. Vol. 11, № 6. P. 643.
3. Flood N., Watson F., Collett L. Using a U-net convolutional neural network to map woody vegetation extent from high resolution satellite imagery across Queensland, Australia // *Int. J. Appl. Earth Obs. Geoinf.* 2019. Vol. 82. P. 101897.
4. Sharma P. A Practical Guide to Object Detection using the Popular YOLO Framework – Part III (with Python codes) [Электронный ресурс]. 2018. URL: <https://www.analyticsvidhya.com/blog/2018/12/practical-guide-object-detection-yolo-framework-python/> (дата обращения 20.02.20)
5. Rosebrock A. Intersection over Union (IoU) for object detection [Электронный ресурс]. 2016. URL: <https://www.pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/> (дата обращения 25.02.20)
6. Common objects in context [Электронный ресурс]. 2019. URL: <http://cocodataset.org/> (дата обращения 15.03.20)
7. Liu L. et al. Deep Learning for Generic Object Detection: A Survey // *Int. J. Comput. Vis.* 2020. Vol. 128, № 2. P. 261–318.
8. Хомякова В.В., Хомяков А.Н. Применение сверточных нейронных сетей для обнаружения дыма по видеопоследовательности // *Решетниковские чтения.* 2018. P. 308–309.
9. COCO Dataset [Электронный ресурс]. URL: <http://cocodataset.org/#overview> (дата обращения 15.03.20)
10. Tsang S.-H. Review: RetinaNet — Focal Loss (Object Detection)

- [Электронный ресурс]. 2019. URL: <https://towardsdatascience.com/review-retinanet-focal-loss-object-detection-38fba6afabe4> (дата обращения 10.03.20)
11. Перевозчиков Г.П., Лабинцев А. Проект Lasmus: как компьютерное зрение помогает спасти потерявшихся людей [Электронный ресурс]. 2020. URL: <https://habr.com/ru/company/ods/blog/483616/> (дата обращения 19.02.20)
 12. Wang X. et al. Fast and Accurate, Convolutional Neural Network Based Approach for Object Detection from UAV // IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society. IEEE, 2018. P. 3171–3175.
 13. Robicquet A. et al. Learning Social Etiquette: Human Trajectory Understanding In Crowded Scenes. 2016. P. 549–565.
 14. Stanford Vision Lab, Stanford University, Princeton University. ImageNet [Электронный ресурс]. 2016. URL: <http://www.image-net.org/> (дата обращения 02.04.20)
 15. Tan M., Le Q. V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. 2019.
 16. Tan M. et al. MnasNet: Platform-Aware Neural Architecture Search for Mobile // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2019. P. 2815–2823.
 17. Rajakaruna A. Image Scaling Methods and MATLAB Implementations [Электронный ресурс]. 2013. URL: <https://aditharajakaruna.wordpress.com/2013/07/12/image-scaling-methods-and-matlab-implementations/> (дата обращения 04.04.20)
 18. Zeng N. RetinaNet Explained and Demystified [Электронный ресурс]. 2018 URL: <https://blog.zenggyu.com/en/post/2018-12-05/retinanet-explained-and-demystified/> (дата обращения 05.03.20)
 19. HyperLabel [Электронный ресурс]. URL: <https://hyperlabel.com/> (дата

- обращения 18.02.20)
20. Paperspace. DataAugmentationForObjectDetection [Электронный ресурс]. 2018. URL: <https://github.com/Paperspace/DataAugmentationForObjectDetection> (дата обращения 23.03.20)
 21. Zlocha M. Anchor-optimization [Электронный ресурс]. 2019. URL: <https://github.com/martinzlocha/anchor-optimization>. (дата обращения 23.03.20)
 22. Scikit-learn. Grid Search [Электронный ресурс]. URL: https://scikit-learn.org/stable/modules/grid_search.html. (дата обращения 09.04.20)
 23. Трудовой кодекс Российской Федерации (с изменениями на 24 апреля 2020 года) // Техноэсперт URL: <http://docs.cntd.ru/document/901807664>
 24. СанПиН 2.2.2/2.4.1340-03 "Гигиенические требования к персональным электронно-вычислительным машинам и организации работы" (с изменениями на 21 июня 2016 года) // Техноэсперт URL: <http://docs.cntd.ru/document/901865498> (дата обращения: 01.05.2020).
 25. ГОСТ 12.0.003-2015 «Опасные и вредные производственные факторы. Классификация». // Техноэсперт URL: <http://docs.cntd.ru/document/1200136071>
 26. ТОИ Р-45-084-01 Типовая инструкция по охране труда при работе на персональном компьютере // Техноэсперт URL: <http://docs.cntd.ru/document/1200030047/> (дата обращения: 01.05.2020).
 27. СанПиН 2.2.4.548-96 Гигиенические требования к микроклимату производственных помещений // Техноэсперт URL: <http://docs.cntd.ru/document/901704046> (дата обращения: 01.05.2020).
 28. ГОСТ 12.1.033-81 Система стандартов безопасности труда (ССБТ). Пожарная безопасность. Термины и определения (с Изменением N 1) // Техноэсперт URL: <http://docs.cntd.ru/document/1200003841/> (дата обращения: 01.05.2020).

29. СП 52.13330.2016 Естественное и искусственное освещение.
Актуализированная редакция СНиП 23-05-95* (с Изменением N 1) //
Техноэксперт URL: <http://docs.cntd.ru/document/456054197>