

Федеральное государственное автономное образовательное учреждение
высшего образования

**«НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ТОМСКИЙ
ПОЛИТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ»**

На правах рукописи



Мачука Мендоса Кристиан Родриго

**НЕЙРОСЕТЕВОЙ АНАЛИЗ ИЗОБРАЖЕНИЙ ДЕРЕВЬЕВ ПРИ
ДИСТАНЦИОННОМ МОНИТОРИНГЕ ХВОЙНЫХ ЛЕСОВ**

Специальность 2.3.1 – Системный анализ, управление и обработка информации,
статистика

Диссертация на соискание ученой степени кандидата
технических наук

Научный руководитель:
Доктор технических наук, профессор
Марков Николай Григорьевич

Томск – 2026

СОДЕРЖАНИЕ

ВВЕДЕНИЕ.....	5
1 ПРОБЛЕМА ЛЕСОПАТОЛОГИЧЕСКОГО МОНИТОРИНГА ХВОЙНЫХ ЛЕСОВ.....	13
1.1 Лесные ресурсы России в условиях биотических угроз	13
1.2 Основные задачи лесопатологического мониторинга хвойных лесов...	16
1.3 Современные инструменты дистанционного мониторинга лесов	17
1.4 Задачи мультиклассификации хвойных деревьев на изображениях	19
1.5 Модели и методы анализа изображений деревьев, полученных при дистанционном лесопатологическом мониторинге хвойных лесов	22
1.5.1 Классические методы компьютерного зрения	22
1.5.2 Методы и алгоритмы традиционного машинного обучения.....	24
1.5.3 Современные модели и методы глубокого обучения.....	26
1.6 Цель и задачи диссертационного исследования.....	30
1.7 Основные результаты и выводы по разделу	33
2 МОДЕЛИ И МЕТОДЫ РЕШЕНИЯ ОСНОВНЫХ ЗАДАЧ ЛЕСОПАТОЛОГИЧЕСКОГО МОНИТОРИНГА ХВОЙНЫХ ЛЕСОВ.....	35
2.1 Модели полносверточных нейронных сетей	35
2.1.1 Модель Mo-U-Net	35
2.1.2 Модель Res-Mo-U-Net.....	40
2.1.3 Гибридная модель At-Mo-U-Net.....	43
2.2 Модель Segformer+.....	48
2.3 Постобработка масок сегментации.....	52
2.4 Метод дистанционного обнаружения очагов размножения вредителей пихтовых лесов.....	54
2.5 Метод анализа динамики жизненных состояний хвойных деревьев в очагах размножения вредителей.....	60
2.6 Подходы и модели для решения задачи оценки запасов фитомассы и потоков углерода при лесопатологическом мониторинге хвойных лесов	70
2.7 Основные результаты и выводы по разделу	72
3 ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ ПРЕДЛОЖЕННЫХ МОДЕЛЕЙ НЕЙРОННЫХ СЕТЕЙ И МЕТОДОВ РЕШЕНИЯ ЗАДАЧ ЛЕСОПАТОЛОГИЧЕСКОГО МОНИТОРИНГА.....	74
3.1 Формирование наборов данных для проведения исследований.....	74
3.1.1 Исходные данные.....	74

3.1.2	Формирование наборов данных для решения задачи мультиклассификации изображений пораженных деревьев пихты	79
3.1.3	Формирование наборов данных для решения задачи мультиклассификации изображений пораженных деревьев кедра	81
3.2	Разведочный анализ обучающих выборок	83
3.2.1	Разведочный анализ обучающих выборок для мультиклассификации изображений деревьев пихты	83
3.2.2	Разведочный анализ обучающих выборок для мультиклассификации изображений деревьев кедра	85
3.3	Обучение и валидация разработанных моделей нейронных сетей	87
3.4	Результаты исследований моделей нейронных сетей при решении задачи мультиклассификации изображений пораженных деревьев пихты	91
3.5	Результаты исследований моделей нейронных сетей при решении задачи мультиклассификации изображений пораженных деревьев кедра	99
3.6	Результаты исследования скорости вычисления предложенных моделей нейронных сетей	106
3.7	Исследования эффективности метода обнаружения очагов размножения уссурийского полиграфа	110
3.8	Исследование метода анализа динамики жизненных состояний хвойных деревьев в очагах размножения вредителей	115
3.9	Основные результаты и выводы по разделу	127
4	СИСТЕМА КОМПЬЮТЕРНОГО ЗРЕНИЯ И НЕЙРОСЕТЕВЫЕ ТЕХНОЛОГИИ НА ЕЕ ОСНОВЕ	130
4.1	Концепция разработки системы компьютерного зрения для решения основных лесопатологических задач	130
4.1.1	Основные принципы создания СКЗ	130
4.1.2	Основные требования к СКЗ	132
4.2	SOA – архитектура программного обеспечения СКЗ	134
4.3	Программное обеспечение СКЗ	135
4.4	Интерфейс пользователей СКЗ	140
4.5	Модель базы данных СКЗ	142
4.6	Нейросетевые технологии на основе СКЗ	144
4.6.1	Технологии мультиклассификации жизненных состояний хвойных деревьев	144
4.6.2	Технология обнаружения очагов размножения уссурийского полиграфа	148

4.6.3	Технология анализа динамики жизненных состояний хвойных деревьев в очагах размножения вредителей.....	151
4.6.4	Технология оценки фитомассы сухостоя и углерода в ней	153
4.7	Апробация нейросетевых технологий при решении лесопатологических задач	156
4.7.1	Апробация технологий мультиклассификации изображений.....	156
4.7.2	Апробация технологий анализа динамики жизненных состояний хвойных деревьев	160
4.7.3	Апробация технологии оценки фитомассы сухостоя и углерода в ней	164
4.8	Рекомендации по применению нейросетевых технологий	166
4.8.1	Требования к съемке хвойных лесов и к исходным изображениям	167
4.8.2	Рекомендации по подготовке изображений к мультиклассификации .	168
4.8.3	Рекомендации по аппаратному обеспечению технологий.....	169
4.8.4	Рекомендации по использованию моделей глубокого обучения ...	170
4.9	Основные результаты и выводы по разделу	172
ЗАКЛЮЧЕНИЕ.....		174
СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ.....		176
Приложение А. Классическая модель U-Net.....		190
Приложение Б. Акт о внедрении результатов диссертации в Институте мониторинга климатических и экологических систем СО РАН.....		192
Приложение В. Акт о внедрении результатов диссертации в учебный процесс Томского политехнического университета.....		194

ВВЕДЕНИЕ

Актуальность темы. Обеспечение устойчивости и сохранности лесных экосистем, в особенности хвойных лесов, представляет собой одну из ключевых задач современного лесного хозяйства. Эти экосистемы подвергаются всё возрастающему воздействию негативных факторов, среди которых особую опасность представляют биотические стрессоры, в первую очередь – насекомые-вредители. Массовые вспышки их размножения приводят к образованию обширных зон усыхания деревьев, вызывая значительные экологические и экономические потери [1]. Мировая практика лесного хозяйства свидетельствует о нарастающей угрозе значительного перечня нерешенных лесопатологических проблем. Согласно данным Продовольственной и сельскохозяйственной организации ООН, ежегодно миллионы гектаров лесов повреждаются насекомыми-вредителями, что оказывает существенное влияние на биоразнообразие и устойчивость глобальных экосистем [1–3]. Наиболее уязвимыми в этом отношении являются бореальные хвойные леса [4–6].

В Российской Федерации особую актуальность приобрела проблема распространения таких опасных видов насекомых-вредителей как уссурийский полиграф *Polygraphus proximus* Blandford (далее – *P. proximus*) и инвазивный союзный короед *Ips amitinus* Eichhoff (далее – *I. amitinus*), впервые обнаруженный в 2019 году в древостоях кедра *Pinus sibirica* Du Tour (далее – *P. sibirica*) на юге Западной Сибири [7,8]. Массовые вспышки уссурийского полиграфа *P. proximus* привели к масштабному усыханию деревьев пихты *Abies sibirica* Ledeb (далее – *A. sibirica*) на территории от Удмуртии до Сибири и Прибайкалья, что в ряде регионов приобрело характер экологической катастрофы [9–11]. Аналогичные риски в случае союзного короеда *I. amitinus*, отмечаются для ценных кедровых насаждений [8,12,13].

При этом важной становится проблема организации оперативного лесопатологического мониторинга, в первую очередь, хвойных лесов, направленного на решение трёх ключевых задач: оперативное выявление на ранних стадиях очагов размножения насекомых-вредителей, отслеживание

динамики жизненных состояний (состояний здоровья) деревьев в таких очагах, а также выделения сухостойных деревьев для определения запасов древесной фитомассы и углерода в ней [14,15–18]. Однако, традиционные методы наземного лесопатологического мониторинга имеют ряд существенных ограничений: требуют значительных временных, трудовых и финансовых затрат, особенно в условиях труднодоступной территории тайги, и поэтому позволяют выявить очаги только на поздних стадиях поражения деревьев, когда их восстановление невозможно [17].

В последние годы интенсивно развиваются технологии дистанционного зондирования Земли (ДЗЗ). При этом в качестве носителей аппаратуры для съемки применяются различные космические аппараты (КА), авиационные носители (самолеты и вертолеты) и беспилотные летательные аппараты (БПЛА). Наиболее перспективным направлением при съемке лесов является использование БПЛА, которые оснащены современными фото или видео камерами и поэтому обеспечивают получение изображений высокого и сверхвысокого пространственного разрешения, причем с требуемой частотой и гибкостью полётов [17,18]. Однако получение изображений при лесопатологическом мониторинге – это только первый этап мониторинга. Наиболее ресурсоемкой задачей остается их дешифрование (часто говорят, интерпретация или анализ изображений). Традиционные методы анализа изображений, основанные на ручной или полуручной интерпретации их экспертами, становятся неэффективными в условиях увеличения объема полученных при мониторинге изображений. Для анализа большого массива изображений требуется применение технологий, позволяющих автоматически и оперативно решать задачу классификации деревьев на изображениях. Для этого сегодня продолжают использовать известные методы классификации и традиционные методы машинного обучения, однако более перспективными считаются модели и методы глубокого обучения [12,19–21].

Среди моделей и методов глубокого обучения особое место занимают модели сверточных нейронных сетей (СНС), продемонстрировавшие высокую

эффективность при решении задач классификации изображений в задачах мониторинга растительного покрова, в том числе лесов [22–25]. Такие модели позволяют решать не только задачи бинарной классификации, но и более сложные задачи мультиклассификации, когда по ряду признаков на снимке дерево надо отнести к одному из нескольких классов [26]. Например, в случае поражения деревьев пихты *A. sibirica* уссурийским полиграфом *P. proximus* надо распознать пять классов: четыре жизненных состояния деревьев пихты разной степени поражения вредителем и фон.

Всё это указывает на актуальность разработки автоматизированных систем анализа изображений, полученных с КА и БПЛА, на основе новых нейросетевых моделей и методов анализа. Такие модели и системы компьютерного зрения должны не только повысить точность оценки жизненного состояния лесных насаждений, но и сократить время реагирования на вспышки численности насекомых-вредителей и, в итоге, оптимизировать мероприятия по защите лесов.

Степень изученности проблемы. В настоящее время активно применяются известные методы и средства ДЗЗ при мониторинге состояния лесных экосистем. Результаты исследований, в том числе приведенные в работах [27,28] Токаревой О.С. по тематическому дешифрованию изображений деревьев кедра с КА Landsat с использованием традиционных методов классификации, демонстрируют возможности таких методов для оценки жизненного состояния хвойных деревьев. В последние годы для анализа изображений деревьев, полученных при дистанционном мониторинге хвойных лесов, всё чаще начинают применяться модели глубокого обучения, что позволяет значительно повысить точность классификации пораженных вредителями деревьев. Перспективность таких моделей подтверждается рядом исследований. Так в работах [12,29] Safonova A. с соавторами, Onishi M. и Ise T. для мультиклассификации деревьев впервые были применены модели СНС, показавшие более высокую точность по сравнению с традиционными методами машинного обучения. Сегодня для решения этих задач используются различные модели СНС, включая Mask R-CNN, Faster R-CNN и модели семейства YOLO [30–33].

Вопрос выбора оптимальной модели СНС является предметом научных дискуссий. В работах Керчева И.А., Маркова Н.Г. и других [34–36] показано, что при решении задач попиксельной мультиклассификации поражённых хвойных деревьев на изображениях по критерию «точность-скорость» предпочтение следует отдавать полносверточным нейронным сетям, в частности, модели U-Net. Однако этими же авторами показано на примерах анализа изображений поражённых вредителями деревьев пихты *A. sibirica* и кедра *P. sibirica*, что такие модели не всегда позволяют распознавать с требуемой точностью деревья в промежуточных жизненных состояниях, то есть деревья с промежуточными степенями поражения вредителями. Таким образом, сохраняется потребность в разработке новых моделей СНС. Следовательно, проблема состоит в необходимости повышения точности классификации состояний хвойных деревьев на изображениях с КА и БПЛА, находящихся на различных стадиях поражения насекомыми-вредителями. Для ее решения требуется создание новых моделей глубокого обучения. Кроме того, сегодня отсутствуют высокоточные методы и алгоритмы решения указанных выше трех основных (ключевых) задач лесопатологического мониторинга хвойных лесов.

Цель работы – создание и комплексное исследование моделей глубокого обучения для анализа изображений хвойных деревьев и разработка методов и нейросетевых технологий для решения основных задач лесопатологического мониторинга хвойных лесов.

Область исследований в диссертации соответствует специальности 2.3.1 «Системный анализ, управление и обработка информации, статистика» по пунктам:

2. Формализация и постановка задач системного анализа, оптимизации, управления, принятия решений, обработки информации и искусственного интеллекта.
3. Разработка критериев и моделей описания и оценки эффективности решения задач системного анализа, оптимизации, управления, принятия решений, обработки информации и искусственного интеллекта.

4. Разработка методов и алгоритмов решения задач системного анализа, оптимизации, управления, принятия решений, обработки информации и искусственного интеллекта.
9. Разработка проблемно-ориентированных систем управления, принятия решений и оптимизации технических объектов.
12. Визуализация, трансформация и анализ информации на основе компьютерных методов обработки информации.

Объект исследования – данные мониторинга хвойных лесов в виде изображений высокого и сверхвысокого разрешения с КА и БПЛА.

Предмет исследования – новые модели, методы и нейросетевые технологии, применяемые для мультиклассификации хвойных деревьев на изображениях высокого и сверхвысокого разрешения с КА и БПЛА и решения основных задач лесопатологического мониторинга хвойных лесов.

Научная новизна полученных результатов.

1. Разработаны гибридная модель полносвёрточной нейронной сети At-Mo-U-Net, отличающаяся от известных аналогов интеграцией блоков внимания в модель Mo-U-Net, и модель полносвёрточной нейронной сети Res-Mo-U-Net, в которой стандартные свёрточные слои модели Mo-U-Net заменены на остаточные блоки, что позволило с помощью таких моделей повысить точность классификации жизненных состояний хвойных деревьев на изображениях по сравнению с классической полносвёрточной моделью U-Net при небольшом снижении скорости их вычисления.
2. Разработана модель Segformer+, отличающаяся от известного трансформера Segformer введением механизма кросс-уровневого внимания и заменой многослойных перцептронов на пространственные блоки с управляющими элементами, что позволило значительно улучшить точность классификации жизненных состояний хвойных деревьев на изображениях по сравнению с использованием классической полносвёрточной модели U-Net.
3. Разработан метод дистанционного обнаружения очагов размножения уссурийского полиграфа в пихтовых лесах без необходимости проведения трудоёмких

наземных измерений как в других методах, что позволяет значительно ускорить процесс обнаружения и картографирования очагов размножения уссурийского полиграфа в таких лесах.

4. Разработан метод анализа динамики (изменений) жизненных состояний хвойных деревьев в очагах размножения вредителей, позволяющий формировать матрицы переходов этих состояний по результатам мультиклассификации разновременных изображений. В отличие от существующих методов, этот метод выявляет с высокой точностью направления и скорость переходов состояний деревьев между классами.

Практическая значимость работы. Практическая ценность исследований определяется, во-первых, разработанным программным обеспечением (ПО) системы компьютерного зрения (СКЗ), в котором реализованы предложенные модели для решения задач мультиклассификации на изображениях пораженных хвойных деревьев, а также методы и алгоритмы для решения трех лесопатологических задач. Разработанное ПО позволяет с практически приемлемой скоростью и высокой точностью классифицировать на изображениях состояния хвойных деревьев, пораженных насекомыми-вредителями, в том числе промежуточные состояния, и решать основные лесопатологические задачи, имеющие важное значение при управлении лесными ресурсами и защите экосистем. Во-вторых, практически значимыми являются разработанные на основе СКЗ нейросетевые технологии и сформулированные рекомендации по их применению, что позволяет улучшить практики управления лесами.

Реализация и внедрение результатов работы. Результаты исследований внедрены в Институте мониторинга климатических и экологических систем (ИМКЭС) СО РАН. Отдельные результаты диссертации используются в учебном процессе Отделения информационных технологий Томского политехнического университета, что также подтверждено актом внедрения.

Достоверность полученных результатов и сделанных выводов обусловлена корректным применением и развитием моделей глубокого обучения

при дистанционном мониторинге хвойных лесов, а также количественным сравнением показателей, полученных с использованием предложенных моделей нейронных сетей и методов решения лесопатологических задач, с показателями, достигнутыми известными методами. Достоверность разработанных моделей и методов подтверждается результатами их комплексных исследований на реальных изображениях деревьев пихты *A. sibirica* и кедра *P. sibirica*, полученных с помощью БПЛА, а также успешной апробацией созданных нейросетевых технологий на таких изображениях.

Положения, выносимые на защиту.

1. Гибридная модель глубокого обучения At-Mo-U-Net с интегрированными в полносверточную модель Mo-U-Net блоками внимания и модель полносвёрточной нейронной сети Res-Mo-U-Net, в которой стандартные свёрточные слои модели Mo-U-Net заменены на остаточные блоки, позволяют повысить на 12–24% точность классификации жизненных состояний хвойных деревьев на изображениях по сравнению с классической полносверточной моделью U-Net при незначительном снижении скорости вычислений.
2. Модель Segformer+ за счёт введения в базовую модель-трансформер Segformer механизма кросс-уровневого внимания и пространственных блоков с управляющими элементами вместо многослойных перцептронов эффективна для решения задач мультиклассификации изображений хвойных деревьев, обеспечивая на 24–29% более точную классификацию жизненных состояний деревьев на изображениях относительно классической модели U-Net.
3. Метод дистанционного обнаружения очагов размножения уссурийского полиграфа в пихтовых лесах по результатам мультиклассификации изображений деревьев пихты является альтернативой традиционным наземным методам и позволяет в 7,1–7,3 раза сократить временные затраты на обнаружение таких очагов при сохранении высокой достоверности результатов обнаружения.
4. Метод анализа динамики жизненных состояний хвойных деревьев в очагах размножения вредителей, позволяющий формировать матрицы переходов

этих состояний по результатам мультиклассификации одновременных изображений, выявляет в отличие от существующих методов направления и с погрешностью не более 10% скорость переходов жизненных состояний хвойных деревьев между классами.

Публикации. Основные результаты исследований отражены в 17 публикациях: 4 статьи в ведущих научных журналах и изданиях, рекомендуемых ВАК, из них 3 – в изданиях, индексируемых в базах данных Scopus и WoS; 13 статей в сборниках трудов международных и российских конференций.

Структура и объем диссертации. Диссертационная работа состоит из введения, четырех разделов, заключения, списка литературы из 131 наименования. Работа содержит 194 страницы текста, включая 35 рисунков и 30 таблиц.

Первый раздел диссертации содержит анализ существующего состояния проблемы лесопатологического мониторинга хвойных лесов на основе данных ДЗЗ, включая результаты аналитического обзора известных на сегодняшний день моделей, методов и алгоритмов анализа изображений хвойных деревьев. Во втором разделе изложены разработанные модели глубокого обучения для решения задач мультиклассификации пораженных хвойных деревьев на изображениях и методы и алгоритмы решения основных задач лесопатологического мониторинга хвойных лесов. В третьем разделе показаны результаты комплексных исследований этих моделей и методов. Четвертый раздел посвящён описанию разработанного программного обеспечения СКЗ, а также созданных на основе СКЗ нейросетевых технологий и результатов их апробации. Приведены рекомендации по использованию полученных результатов исследований.

Автор выражает глубокую благодарность научному руководителю д.т.н., профессору Маркову Н.Г. за помощь при написании диссертационной работы. Автор также благодарит к.б.н., заведующего лабораторией ИМКЭС СО РАН Керчева И.А. за предоставленные изображения участков хвойных лесов.

1 ПРОБЛЕМА ЛЕСОПАТОЛОГИЧЕСКОГО МОНИТОРИНГА ХВОЙНЫХ ЛЕСОВ

Обеспечение сохранности и устойчивого роста хвойных лесов, являющихся основой лесных ресурсов России и важным компонентом глобальной экосистемы, сопряжено с необходимостью оперативного решения задач по выявлению и оценке патологий жизненных состояний (состояний здоровья) хвойных деревьев, возникающих из-за вспышек массового размножения насекомых-вредителей. Ниже анализируется состояние решения проблемы лесопатологического мониторинга хвойных лесов.

1.1 Лесные ресурсы России в условиях биотических угроз

Лесные ресурсы РФ, занимающие наибольшую площадь в мире, являются ключевым компонентом глобальной экосистемы и выполняют важные климаторегулирующие, водоохранные и социально-экономические функции [1]. Управление таким лесным фондом сопряжено с рядом вызовов, обусловленных масштабами территорий, занимаемых лесами, их труднодоступностью, а также воздействием негативных факторов, среди которых выделяются биотические угрозы [38]. Основу управления лесами составляет сложная система классификации земель [39]. Земли лесного фонда делятся на две категории:

1. Лесные земли, к которым относятся территории, покрытые лесной растительностью, а также предназначенные для ее восстановления.
2. Нелесные земли, включающие территории, используемые для нужд лесного хозяйства (просеки, дороги), и иные участки в границах фонда.

К лесным землям, покрытым лесной растительностью, относят участки с насаждениями естественного или искусственного происхождения, соответствующие критериям по полноте древостоя [40]. Данные официальной статистики, представленные Рослесинфоргом (таблица 1.1), показывают масштаб ресурса: общая площадь земель с лесом составляет 1183,2 млн га, из которых на лесопокрытые территории приходится 794,51 млн га, с

преобладанием хвойных пород (538,56 млн га). Оценка состояния этих ресурсов связана с рядом проблем. Во-первых, существуют расхождения между данными государственного кадастра и оценками, полученными методами ДЗЗ. Космические снимки фиксируют фактический лесной покров без привязки к категориям земель. Исследования на основе таких снимков указывают на площадь лесов в 757,7 млн га по результатам из [41] и 725,5 млн га по результатам из [42], что меньше по сравнению с официальными данными, изложенными в [39]. Во-вторых, актуальность данных вызывает вопросы. По оценкам Рослесинфорга, около 50% российских лесов инвентаризировались около 30 лет назад, что не позволяет учитывать текущую динамику площади лесов [39,42].

Таблица 1.1 – Площадь основных категорий лесного покрова России по данным Рослесинфорга [39]

Земли с лесом в Российской Федерации, учтенные официальной статистикой	Площадь земли с лесами, млн. га				
	Сумма	Лесная земля	Лесная площадь на лесной земле		
			Сумма	Хвойные	Лиственные
Земли лесного фонда	1146,30	864,54	770,12	524,69	18,24
Леса в городских районах	1,44	1,20	1,13	0,39	0,97
Леса на охраняемых природных территориях	26,68	17,77	16,76	11,14	0,76
Лесные угодья других категорий	8,76	7,34	6,51	2,34	0,51
Итого	1183,2	890,86	794,51	538,56	19,61

Значительную проблему представляет рост биотических угроз, особенно в контексте изменения климата и недостаточной актуальности лесоинвентаризационных данных. Наряду с традиционными вредителями – такими как сибирский шелкопряд (*Dendrolimus sibiricus* Tschetv.) – всё большее значение приобретают чужеродные для тёмнохвойной тайги стволовые насекомые-вредители [4], в частности уссурийский полиграф *P. proximus* и союзный короед *I. amitinus* [43]. Уссурийский полиграф *P. proximus*, основной вид которого имеет дальневосточное происхождение, за последние десятилетия распространился на громадные лесные территории. Многочисленные очаги его массового размножения различной интенсивности обнаружены в России, начиная с 2007 г., не только в пихтовых лесах Сибири, но и в лесах ряда центральных регионов России, например, в Московской области, а в последнее время – в пихтовых лесах Удмуртии и Прибайкалья [6,11]. При этом

сформировалось большое число очагов массового усыхания пихтовых деревьев *A. sibirica*. Высокая агрессивность уссурийского полиграфа объясняется его коротким жизненным циклом, трофической гибкостью и наличием специфического комплекса феромонов, обеспечивающих синхронные атаки на деревья [43]. Подобные вспышки приводят к масштабной гибели древостоев, что влечет за собой изменение микроклимата и усиление пожарной опасности в поражённых регионах.

Не менее значимым стало распространение союзного короеда *I. amitinus* – вида вредителя центральноевропейского происхождения, впервые выявленного в 2019 году в кедровниках юга Западной Сибири [8]. Вредитель поражает деревья *P. sibirica* и *Picea obovata*, нанося ущерб ключевым лесообразующим породам тайги. Короткий период развития и способность образовывать до двух генераций за сезон делают процесс его распространения чрезвычайно быстрым. Хотя площадь поражения пока ограничена, потенциал разрушения экосистем чрезвычайно высок. Современные исследования [4,8,43] указывают, что союзный короед *I. amitinus* формирует устойчивые популяции, демонстрируя значительную адаптацию к континентальному климату Западной Сибири.

Массовое распространение уссурийского полиграфа *P. proximus* и союзного короеда *I. amitinus* стало важнейшим фактором дестабилизации хвойных экосистем России. Опираясь на эти примеры и на большое число подобных случаев в мировой практике, ряд ученых и известных в мире специалистов лесной отрасли сегодня делают выводы о наличии необратимых экономических и экологических последствий от массового размножения насекомых-вредителей хвойных лесов, если не принимать соответствующие меры [4,8,43]. Более того, проведенный ими анализ указывает на противоречие между масштабами лесных ресурсов и дефицитом оперативной информации об их состоянии в условиях биотических угроз. Все это подчеркивает необходимость решения проблемы оперативного лесопатологического мониторинга хвойных лесов с целью раннего выявления очагов размножения таких вредителей и последующего решения проблемы борьбы с ними.

1.2 Основные задачи лесопатологического мониторинга хвойных лесов

Кратко рассмотрим основные, часто говорят ключевые, задачи, решаемые при лесопатологическом мониторинге хвойных лесов. Первой основной задачей является оперативное обнаружение на ранних стадиях очагов размножения насекомых-вредителей. Вторая задача возникает по следующей причине. Одной из важных особенностей поражения хвойных лесов насекомыми-вредителями являются резкие колебания их численности, обусловленные тем, что в системе взаимодействия чужеродного вида с сообществом не сразу устанавливается баланс. После латентной фазы в период акклиматизации таких насекомых на новой территории, когда этот вид имеет низкую численность, следует вспышка, а за ней резкий спад численности, за которой может вновь последовать резкий подъем [7,11,43]. Поэтому кроме важной задачи оперативного выявления очагов размножения вредителей необходимо решать вторую задачу – проведения постоянного и оперативного мониторинга хвойных деревьев в выявленных очагах с помощью специальных средств оценки жизненного состояния (состояния здоровья или степени поражения) заселенных вредителями деревьев. Выявление деревьев на ранней стадии поражения вредителями имеет большое практическое значение для сохранения хвойных лесов, поскольку для таких деревьев своевременно могут быть проведены эффективные фитосанитарные мероприятия вплоть до уничтожения пораженных деревьев. Итак, в связи с высокой динамичностью популяций стволовых вредителей существует необходимость решения двух основных задач лесопатологического мониторинга хвойных лесов: оперативного выявления на ранних стадиях очагов размножения вредителей и отслеживания динамики жизненного состояния пораженных деревьев, находящихся в этих очагах.

Практически важной третьей основной задачей такого мониторинга является выявление среди них сухостойных деревьев (далее – сухостоя). Сухостой появляется в результате болезни деревьев или является следствием изменений климата. Например, усыхание ельников имеет место из-за резких

изменений температуры и недостаточности влаги в определенные периоды года. Необходимо осуществлять мониторинг лесов и выявлять сухостой, что позволит определять запасы древесной фитомассы сухостоя и углерода в ней на обследуемых участках леса. В итоге это позволит оценить вклад выбросов углерода таких участков в бюджет выбросов углерода в атмосферу региона и, соответственно, оценить их негативное влияние на окружающую среду (вклад сухостоя в так называемую «карбоновую проблему» региона).

Отметим, что сложность задач выявления очагов вредителей и получения достоверных оценок жизненных состояний хвойных деревьев, а также выявления сухостоя обусловлены не только большой площадью подлежащих мониторингу лесов, но и разнообразием пород деревьев и их лесопатологических состояний. Все это подчеркивает актуальность научной проблемы создания современных методологии и инструментария для оперативного проведения мониторинга пораженных вредителями лесов.

1.3 Современные инструменты дистанционного мониторинга лесов

Современные методы мониторинга лесных экосистем претерпели существенные изменения по сравнению с традиционными (классическими) методами и подходами. Классические методы мониторинга лесов основываются преимущественно на наземных полевых обследованиях, таксационных измерениях и инвентаризационных работах. Они обеспечивают высокую точность на локальном уровне, однако отличаются значительными временными и трудовыми затратами, а также не позволяют оперативно осуществлять регулярный и масштабный мониторинг состояния больших лесных массивов [44]. Кроме того, такие методы и подходы характеризуются ограниченной репрезентативностью данных и невозможностью оперативного выявления изменений лесных массивов.

На фоне этих ограничений использование методов и технологий ДЗЗ представляет собой качественно новый этап в развитии мониторинга лесов. Технологии ДЗЗ обеспечивают получение объективной, количественно

воспроизводимой и пространственно непрерывной информации о состоянии лесных экосистем в широком диапазоне пространственных масштабов [45,46]. Использование данных ДЗЗ в виде изображений лесных участков позволяет повысить оперативность наблюдений, минимизировать субъективность оценок при комплексном анализе процессов, происходящих в лесных экосистемах. Общеизвестно, что современный дистанционный мониторинг лесных экосистем обеспечивает оперативное получение объективной и актуальной информации, в том числе о состоянии лесов, пораженных насекомыми-вредителями [4,7,43,47].

Сегодня инструментарий ДЗЗ для решения задач оперативного лесопатологического мониторинга лесов включает несколько технологических платформ, каждая из которых обладает определенными возможностями и ограничениями. Наиболее оперативным и дешевым по сравнению с используемыми для аэрофотосъемки самолетами и вертолетами инструментом для мониторинга локальных территорий являются беспилотные летательные аппараты (БПЛА). Их ключевое преимущество заключается в возможности получения с помощью установленной на них фото или видео аппаратуры изображений высокого (0,1–1,0 м/пиксель, иногда диапазон расширяют до нескольких метров) и сверхвысокого пространственного разрешения (0,02–0,1 м/пиксель) независимо от облачности и угла освещенности [7,12,17,34]. Такое разрешение позволяет идентифицировать не только отдельные деревья, но и детали их крон. Дополнительными преимуществами БПЛА являются гибкость планирования маршрутов съемки и возможность быстрого реагирования на возникновение неблагоприятных факторов в лесных массивах.

Для мониторинга обширных лесных территорий применяются космические аппараты (КА), обеспечивающие регулярное покрытие значительных площадей. Современные спутниковые платформы, включая серии КА Landsat и Sentinel, позволяют получать изображения довольно высокого пространственного разрешения (2–30 м/пиксель). Ключевым преимуществом спутниковых систем является возможность систематического и долговременного

наблюдения, обеспечивающего анализ динамики изменений лесного покрова на больших территориях [48,49]. Однако оперативность получения изображений ограничивается периодичностью съемки и зависимостью от атмосферных условий, в частности от облачности.

Перспективным направлением является использование лидарных технологий (LiDAR), устанавливаемых на борту самолетов, вертолетов или БПЛА. Лидарное сканирование обеспечивает получение трехмерной модели лесного полога, что позволяет с высокой точностью определять таксационные показатели – высоту деревьев, диаметр крон, плотность древостоя, вертикальную структуру насаждений [50–53]. Особое значение данные лидарного сканирования имеют для построения цифровых моделей рельефа (ЦМР) и цифровых моделей поверхности (ЦМП), необходимых для анализа пространственной неоднородности лесов и количественной оценки их биомассы.

Таким образом, современный инструментарий ДЗЗ, включающий фото или видеокамеры, устанавливаемые на БПЛА и КА, и лидарные системы, создает технологическую основу для оперативного решения комплекса задач лесопатологического мониторинга лесов. Выбор конкретной технологии или их комбинации определяется масштабом работ, требуемой детальностью исследований и экономической эффективностью работ. Однако получение изображений при таком мониторинге с помощью инструментария ДЗЗ – это только первый этап работ. На втором этапе мониторинга комплексной и ресурсоемкой задачей является дешифрование (часто говорят, интерпретация или анализ) полученных на первом этапе изображений.

1.4 Задачи мультиклассификации хвойных деревьев на изображениях

Проведенный анализ современного состояния проблемы лесопатологического мониторинга хвойных лесов свидетельствует о необходимости перехода от упрощенной бинарной классификации изображений деревьев на обследуемом участке, например на хвойные и лиственные, к сложной классификации хвойных деревьев, находящихся в различных жизненных состояниях (различная степень

повреждения вредителями). Иными словами, сначала необходимо провести мультиклассификацию, когда по ряду признаков на изображении дерево, находящееся в определенном состоянии, надо отнести к одному из нескольких классов жизненных состояний, а затем решать соответствующую основную лесопатологическую задачу. Так, для решения первой задачи лесопатологического мониторинга – задачи оперативного выявления на ранних стадиях очагов размножения насекомых – вредителей перед применением отраслевой методики принятия решения о наличии очага требуется классифицировать хвойные деревья изучаемой породы на несколько классов: «Здоровое», «Заселенное вредителями», «Свежеотработанное» и т.п. Мультиклассификацию хвойных деревьев на разновременных изображениях обследуемого участка также необходимо проводить перед решением задачи анализа изменений (динамики) их жизненных состояний в очаге размножения вредителя (вторая лесопатологическая задача). Так, например, при поражении деревьев пихты *A. sibirica* уссурийским полиграфом при мультиклассификации необходимо различать пять классов состояний: четыре жизненных состояния деревьев пихты, отражающих степень их повреждения вредителем, и фон (деревья других пород и иные объекты земной поверхности). Аналогично, при поражении деревьев кедра *P. sibirica* союзным короедом требуется идентификация шести классов: пяти жизненных состояний деревьев кедра и фон. Наконец, для решения третьей лесопатологической задачи исходными данными также должны являться результаты мультиклассификации хвойных деревьев на изображениях, позволяющие отделить сухостой от хвойных деревьев в других жизненных состояниях и разделить его на два класса: «Свежий сухостой» и «Старый сухостой». Учитывая все сказанное, можно сделать вывод о том, что получение результатов мультиклассификации хвойных деревьев на изображениях в качестве исходных данных для решения основных лесопатологических задач является обязательным этапом. Более того, при решении ряда других задач анализа (интерпретации) изображений, полученных при лесопатологическом мониторинге хвойных лесов, на первом этапе решаются задачи мультиклассификации деревьев.

Будем решать задачи мультиклассификации изображений как задачи семантической сегментации (попиксельной классификации), направленные на попиксельное определение большого числа жизненных состояний (несколько классов – мультиклассов) хвойных деревьев на изображениях высокого и сверхвысокого разрешения, полученных с КА или БПЛА. Чем точнее используемый для мультиклассификации метод или модель позволит распознать на изображениях кроны деревьев в различных жизненных состояниях, тем точнее будет в последующем решен весь комплекс задач лесопатологического мониторинга хвойных деревьев.

Рассмотрим формальную постановку задачи мультиклассификации жизненных состояний хвойных деревьев на изображениях. Будем рассматривать исходное изображение лесного участка, полученное с БПЛА или КА, как трёхканальный двумерный массив, представленный тензором I размера $H \times W \times 3$, где H – высота изображения в пикселях, W – ширина изображения в пикселях, а три канала соответствуют цветовым компонентам R (красный), G (зеленый) и B (синий), т.е. RGB-изображению. Каждый пиксель $p_{ij} = (r, g, b)$ изображения принимает значение интенсивности цвета в диапазоне от 0 до 255.

Задача мультиклассификации жизненных состояний хвойных деревьев формулируется как задача семантической сегментации изображения лесного участка, решение которой позволит присвоить каждому пикселю p_{ij} исходного изображения I метки одного из C классов жизненных состояний деревьев. Множество классов включает в себя состояния деревьев целевой хвойной породы и фон: $\Omega = \{\omega_1, \omega_2, \dots, \omega_C\}$. Например, для деревьев пихты *A. sibirica* $C = 5$ (ω_1 – «Живое», ω_2 – «Отмирающее», ω_3 – «Свежий сухостой», ω_4 – «Старый сухостой», ω_5 – «Фон»), а для деревьев кедра *P. sibirica* $C = 6$ (ω_1 – «Условно здоровое», ω_2 – «Свежезаселенное», ω_3 – «С усохшей вершиной», ω_4 – «Свежий сухостой», ω_5 – «Старый сухостой», ω_6 – «Фон»). Результатом сегментации является выходная карта (маска) семантической сегментации M размера $H \times W$, где каждый элемент $m_{ij} \in \Omega$.

1.5 Модели и методы анализа изображений деревьев, полученных при дистанционном лесопатологическом мониторинге хвойных лесов

Современные тенденции при мультиклассификации пораженных деревьев на изображениях высокого и сверхвысокого разрешения заключаются в переходе от визуального дешифрования и использования классических статистических методов к высокоинтеллектуальным методам мультиклассификации таких изображений. При этом наблюдается поступательное развитие от классических методов и алгоритмов обработки и анализа изображений к появившимся в последние два–три года сложным моделям глубокого обучения. В этой связи нами выделяются три ключевых этапа развития и использования моделей и методов анализа изображений при мониторинге лесов: классические методы компьютерного зрения, методы и алгоритмы традиционного машинного обучения и современные методы и модели глубокого обучения.

1.5.1 Классические методы компьютерного зрения

Первые подходы к автоматизации процессов дешифрования лесных изображений основаны на использовании методов и алгоритмов классического компьютерного зрения. Эти методы опираются на математический анализ формы и текстуры крон деревьев на изображениях. Методы выделения признаков объектов на изображениях основывались на алгоритмах обнаружения границ, углов, анализа текстуры, а также анализа форм таких объектов. В контексте мониторинга лесов классические методы компьютерного зрения применяются для количественной оценки структуры и состояния насаждений на изображениях. Наиболее часто используется анализ текстурных признаков, отражающих пространственную неоднородность кроны.

Использование матриц совместных встречаемостей яркостей по Харалику, как это предложено в [54] при вычислении текстурных признаков Харалика, позволяет формализовать описание текстуры изображений, выделяя показатели энтропии, контрастности и однородности, которые коррелируют с

морфологическим разнообразием лесных участков. Ранние системы анализа лесных изображений лесов также используют методы контурного и объектно-ориентированного анализа. Классические алгоритмы выделения и векторизации объектов по границам яркости позволяют проводить оценку геометрических характеристик – формы и площади крон, угла наклона стволов и сомкнутости полога. Так в работе [55] показано, что сочетание формальных признаков контуров и текстурных метрик позволяет различать породный состав насаждений даже на разнородных изображениях, полученных при ДЗЗ. Авторы работы [56] демонстрируют применение классических алгоритмов выделения контуров, бинаризации и аппроксимации окружностей для оценки диаметра стволов деревьев и площади их крон на фотоснимках. Такие методы стали прототипом для первых автоматизированных систем полевой инвентаризации, обеспечивая расчет параметров древостоя без физического измерения параметров деревьев. Таким образом, традиционные методы компьютерного зрения сформировали фундамент для понимания как вести автоматизированный анализ изображений лесных участков, объединяя детерминированные алгоритмы анализа формы, текстуры и геометрии деревьев. Несмотря на это, их применение сопряжено с рядом ограничений: необходим ручной подбор признаков и параметров алгоритмов, такие методы и алгоритмы чувствительны к шуму и теням, что снижает точность выделения контуров крон деревьев при высокой плотности растительности. Более того, точность таких методов и алгоритмов существенно зависит от качества входных данных и условий съёмки.

В настоящее время для решения задач автоматической классификации деревьев на изображениях с КА и с БПЛА продолжают применять традиционные классификаторы, используемые при решении других прикладных задач анализа данных ДЗЗ [57]. Среди них хорошо известные методы параметрической и непараметрической статистической классификации [58]. К сожалению, они дают невысокую точность распознавания пораженных вредителями деревьев [35,57,58].

1.5.2 Методы и алгоритмы традиционного машинного обучения

Переход к использованию моделей, методов и алгоритмов машинного обучения для анализа получаемых с КА и БПЛА изображений обозначает новый этап развития методов и инструментальных средств оперативного лесопатологического мониторинга лесов. Применение таких методов при решении задач мультиклассификации изображений лесов позволяет перейти от простых процедур компьютерного зрения к более сложным вероятностным моделям и решающим правилам, обеспечивая более высокую устойчивость и точность классификации изображений лесов, получаемых при ДЗЗ.

Методы на основе деревьев решений применяются для классификации породного состава и обнаружения поражённых вредителями деревьев, при этом используется интеграция спектральных и текстурных признаков деревьев. В работе [59] для классификации пород и оценки структурных изменений древостоев был использован алгоритм случайного леса, показавший стабильную эффективность в условиях спектральной изменчивости и зарекомендовавший себя как инструмент для раннего обнаружения деградации деревьев. Аналогично, в [60] алгоритм случайного леса в комбинации с текстурными признаками был применён для картографирования участков усыхания деревьев в бореальных лесах.

Алгоритмы опорных векторов позволяют строить нелинейные границы между классами при решении задач классификации деревьев. Их преимущество заметно при работе с ограниченными по объёму, но качественно размеченными наборами данных, что типично для лесопатологических исследований. Так в работе [61] такие алгоритмы применялись для классификации типов лесного покрова по спутниковым данным, продемонстрировав способность к дифференциации лесных и нелесных категорий объектов, а в работе [62] алгоритм опорных векторов в сочетании с морфологическими фильтрами использовался для гиперспектральной классификации растительности. Этот подход позволил проводить сегментацию крон деревьев и идентифицировать

породы в условиях сложной пространственной структуры насаждений. Сравнительное исследование из [63] также подтверждает, что алгоритмы опорных векторов обеспечивают одно из лучших соотношений по точности классификации и вычислительной устойчивости среди классических алгоритмов при малом объеме обучающих данных.

Ансамблевые методы, такие как бустинг и бэггинг, объединяют несколько алгоритмов машинного обучения для повышения устойчивости результирующей модели к шуму и вариативности данных. Это позволяет достичь более высокой точности классификации деревьев и воспроизводимости результатов по сравнению с одиночными моделями [64,65]. В частности, в работе [66] рассматривается использование ансамблевых моделей для решения задач классификации, обнаружения изменений и количественной оценки биофизических параметров на дистанционных изображениях лесных экосистем. Особого внимания заслуживают методы градиентного бустинга, которые находят применение в анализе мультиспектральных данных. Авторы работы [66] отмечают преимущество этих методов в задачах бинарной классификации, а иногда и мультиклассификации, поскольку они способны выявлять сложные, скрытые зависимости между спектральными и текстурными признаками.

Используются и другие традиционные методы машинного обучения, включая неконтролируемые нейросетевые классификаторы [58]. При этом для определения породного состава лесов путем решения задачи мультиклассификации чаще всего исходными данными для них являются многоспектральные изображения [57], а для выявления сухостойных деревьев путем решения задачи бинарной классификации – RGB-изображения [47]. Среди используемых классических методов машинного обучения иногда встречаются комбинированные методы. Например, в работе [35] для классификации деревьев пихты, пораженных *P. proximus*, на изображениях применялся метод градиентного бустинга в комбинации с методом деревьев принятия решений, причем учитывались как спектральные признаки крон деревьев, так и текстурные признаки Харалика.

Несмотря на некоторые выявленные преимущества по сравнению с классическими методами компьютерного зрения, применение методов и алгоритмов традиционного машинного обучения при анализе изображений деревьев сопровождается рядом методологических ограничений. Среди них – трудность интерпретации результатов моделей, основанных на принципе «чёрного ящика» (например, методы градиентного бустинга и опорных векторов); зависимость качества результатов от полноты и репрезентативности обучающих данных и т.п. Кроме того, классические методы машинного обучения при мультиклассификации деревьев на изображениях обеспечивают невысокую точность [35,57,67], что ограничивает их применимость в лесной отрасли.

1.5.3 Современные модели и методы глубокого обучения

В последние годы при мультиклассификации деревьев на изображениях лесов с БПЛА и с КА начали применять более эффективные модели и методы глубокого обучения. Так, в работе [29], видимо, впервые предложено классифицировать деревья различных пород с использованием методов глубокого обучения, а в статье [12] при решении задачи классификации пораженных вредителями деревьев пихты *A. sibirica* на RGB-изображениях с БПЛА исследуются различные модели СНС. Авторы [12] для классификации пораженных деревьев *A. sibirica*, находящихся в четырех жизненных состояниях, применили двухэтапный подход: сначала на изображении с помощью разработанного ими алгоритма ведется поиск регионов-кандидатов, содержащих кроны деревьев, а затем проводится их классификация с помощью предложенной новой модели СНС. Показано, что эта модель дает более высокую точность классификации пораженных деревьев, чем известные модели СНС Xception, VGG-16, VGG-19, ResNet-50, Inception-V3, Inception ResNet-V2, DenseNet-121, DenseNet-169 и DenseNet-201. Однако реализация предложенного двухэтапного подхода весьма сложна и поэтому предлагаемая модель СНС применения на практике не нашла.

Некоторые исследователи для распознавания деревьев на изображениях используют модели СНС класса YOLO, предназначенные для решения задач обнаружения объектов на изображениях. Так в [68] применялась модель YOLOv5 для анализа многоспектральных изображений пораженных деревьев сосны. Точность классификации деревьев оказалась невысокой, но скорость вычисления модели очень высока. В статье [69] изложены результаты исследований по классификации многоспектральных изображений с БПЛА пораженных вредителями деревьев сосны: три класса жизненного состояния сосны (начально зараженные деревья, средне зараженные деревья и погибшие деревья) и класс деревьев других пород. Анализ изображений проводился с использованием моделей СНС Faster R-CNN и YOLOv4, а также двух методов традиционного машинного обучения: опорных векторов и случайного леса. По точности классификации лучшие результаты показали модель СНС Faster R-CNN, осуществляющая семантическую сегментацию (попиксельную классификацию) изображений, и методы опорных векторов и случайного леса, а самая низкая точность у модели YOLOv4. В [70] приведены результаты решения задачи обнаружения на изображениях с БПЛА раннего увядания деревьев сосны из-за болезни, называемой древесная нематода сосны. Для исследования использовались различные модели СНС из класса YOLO, однако даже лучшие результаты по точности классификации увядающих деревьев сосны, полученные с помощью модели YOLOv5m, не являются практически приемлемыми. В итоге был сделан вывод, что модели класса YOLO в условиях высоких требований по точности мультиклассификации деревьев не могут применяться на практике.

В последние годы для классификации деревьев на изображениях с помощью моделей СНС все чаще применяют полносверточные нейронные сети U-Net [71] и подобные им модели, позволяющие решать задачи семантической сегментации (попиксельной классификации) изображений. В работе [72] при исследовании точности классификации деревьев разных пород на изображениях с КА Sentinel-2 использовались четыре модели полносверточных нейронных сетей, при этом показано, что наиболее высокую точность дает модель U-Net. В

[33,69] при распознавании состояний пораженных вредителями деревьев сосны на RGB-изображениях, полученных с БПЛА, решалась задача классификации с помощью моделей СНС Mask R-CNN и Faster R-CNN с большим числом сверточных слоев. При этом выявлено, что эти модели обеспечивают довольно высокую точность классификации деревьев, но скорость их вычисления весьма низка, что делает их не конкурентными с полносверточными нейронными сетями при практическом применении моделей. С помощью классической модели U-Net [71] получены обнадеживающие результаты мультиклассификации пораженных уссурийским полиграфом *P. proximus* деревьев пихты *A. sibirica* и пораженных союзным короедом *I. amitinus* деревьев кедра *P. sibirica*, описанные в [34,36]. Точность классификации на тестовых выборках по усредненной по всем классам деревьев метрике *mIoU* для деревьев *A. sibirica* составила 0,66, а для деревьев *P. sibirica* – 0,61 (значения этой метрики, превышающие 0,5, соответствуют высокой точности классификации). Однако наряду с высокими результатами по точности классификации для большинства классов жизненных состояний хвойных деревьев наблюдается невысокая точность классификации одного (случай деревьев *A. sibirica*) или двух (случай деревьев *P. sibirica*) промежуточных классов жизненных состояний деревьев. Распознавание деревьев в промежуточных состояниях (состояния между здоровым деревом и старым сухостоем), особенно на ранней стадии их поражения вредителями, имеет большое практическое значение для их сохранения, поскольку выявленные деревья своевременно могут быть подвергнуты эффективным фитосанитарным мероприятиям. Невысокая точность распознавания деревьев в промежуточных состояниях не устраивает специалистов лесной отрасли. Результаты классификации пораженных деревьев *A. sibirica*, полученные в [34] с помощью классической модели U-Net на датасете, который также использовался в работе [35], значительно лучше, чем при использовании метода градиентного бустинга в комбинации с методом деревьев принятия решений (значение метрики *mIoU* для модели U-Net равно 0,66 против 0,49 для метода градиентного бустинга в комбинации с методом деревьев принятия решений). Это позволяет считать, что

полносверточные нейронные сети при мультиклассификации пораженных деревьев на изображениях с БПЛА и КА показывают более высокие результаты, чем традиционные методы машинного обучения.

Сегодня перспективным направлением развития моделей глубокого обучения является создание моделей трансформеров [73]. Среди них выделяется модель Segformer, которая показала весьма высокое качество семантической сегментации изображений при решении ряда практических задач [74,75]. Имеет смысл адаптировать и применить эту модель к решению задач мультиклассификации пораженных хвойных деревьев на изображениях.

Проведенный аналитический обзор современных моделей и методов глубокого обучения для решения задач мультиклассификации хвойных деревьев на изображениях, полученных с КА и БПЛА, позволил сделать ряд выводов. Во-первых, сегодня формируется новое научное направление по решению задач автоматической мультиклассификации деревьев на изображениях с помощью различных моделей глубокого обучения, в первую очередь моделей СНС. Во-вторых, следует согласиться с мнением авторов работ [12,29,35,69] о том, что модели и методы глубокого обучения при решении задач мультиклассификации хвойных деревьев на изображениях позволяют получать более точные результаты, чем при использовании традиционных методов классификации, включая известные методы классического машинного обучения. В-третьих, в рамках обозначенного научного направления среди моделей СНС для решения задач мультиклассификации деревьев на изображениях по критериям точность классификации – скорость вычислений предпочтение следует отдать полносверточным нейронным сетям, хотя они тоже не всегда позволяют распознавать с требуемой точностью пораженные деревья в промежуточных жизненных состояниях. Иными словами, перспективно создавать новые модели полносверточных сетей, лишенные такого недостатка. Кроме того, следует развивать модели трансформеров, позволяющие с высокой точностью решать задачи мультиклассификации хвойных деревьев на изображениях.

1.6 Цель и задачи диссертационного исследования

Опираясь на результаты проведенного выше анализа проблемы лесопатологического мониторинга хвойных лесов и детального анализа используемых в настоящее время моделей, методов и алгоритмов классификации хвойных деревьев на изображениях, можно сделать вывод об актуальности разработки и исследования моделей глубокого обучения, способных с высокой точностью решать задачи автоматической мультиклассификации деревьев хвойных пород на изображениях высокого и сверхвысокого разрешения с КА и БПЛА. При этом перспективно разрабатывать новые модели полносверточных нейронных сетей на основе довольно эффективной классической модели U-Net и создавать модель трансформера с использованием модели Segformer, позволяющей с высокой точностью решать задачи семантической сегментации изображений.

Другим направлением работы над диссертацией является создание новых методов и алгоритмов решения трех основных задач лесопатологического мониторинга хвойных лес и исследование их эффективности. При этом, в соответствии с п.1.4, в качестве входных данных для этих методов должны выступать результаты мультиклассификации изображений хвойных деревьев, полученные с помощью предложенных моделей глубокого обучения.

Целью диссертационной работы является создание и комплексное исследование моделей глубокого обучения для анализа изображений хвойных деревьев и разработка методов и нейросетевых технологий для решения основных задач лесопатологического мониторинга хвойных лесов.

Для достижения поставленной цели необходимо решить следующие **задачи**:

1. Провести анализ современного состояния технологий дистанционного мониторинга лесных ресурсов и анализ моделей, методов и алгоритмов автоматизированной и автоматической мультиклассификации получаемых при лесопатологическом мониторинге изображений хвойных деревьев.

2. Разработать новые модели глубокого обучения на основе полносверточной нейронной сети архитектуры U-Net и трансформера Segformer. Модели должны решать задачу мультиклассификации жизненных состояний пораженных насекомыми-вредителями хвойных деревьев на изображениях.
3. Программно реализовать разработанные модели и сформировать наборы данных (датасеты) по изображениям пораженных насекомыми-вредителями пихтовых и кедровых лесов. Провести обучение и валидацию этих моделей на подготовленных наборах данных.
4. Выполнить комплексные исследования эффективности предложенных и обученных моделей глубокого обучения.
5. Разработать и исследовать методы решения трех основных задач лесопатологического мониторинга хвойных лесов.
6. Создать программное обеспечение системы компьютерного зрения (СКЗ) и разработать на основе СКЗ и апробировать нейросетевые технологии для решения основных задач лесопатологического мониторинга хвойных лесов.

Отметим, что комплексные исследования эффективности предложенных моделей глубокого обучения включают исследования этих моделей по точности классификации и скорости их вычислений, причем исследования должны проводиться для двух пород хвойных деревьев и при различных размерах входных изображений (фрагментов изображений).

Для оценки точности классификации деревьев на изображениях (качества семантической сегментации изображений) можно использовать различные известные метрики: *Precision*, *Recall*, *F1* и т.д. Однако здесь будем применять метрику *Intersection over Union (IoU)*. Она также называется «коэффициент Жаккара» и считается общепринятой метрикой эффективности при решении задач семантической сегментации цифровых изображений [76]. Метрика *IoU_c* для каждого класса *c* жизненного состояния хвойных деревьев может быть вычислена по формуле [76,77]:

$$IoU_c = \frac{TP_c}{TP_c + FP_c + FN_c}, \quad (1.1)$$

где TP_c , FP_c и FN_c – количество, соответственно, истинно-положительных, ложно-положительных и ложно-отрицательных решений для деревьев класса c .

Наряду с формулой (1.1) применяется также формула (1.2) для вычисления метрики *mean Intersection over Union* ($mIoU$). Эта метрика рассчитывается как среднее значение метрики IoU_c по всем C классам:

$$mIoU = \frac{1}{C} \sum_{c=1}^C IoU_c, \quad (1.2)$$

Значения IoU_c и $mIoU$, превышающие 0,5, соответствуют высокой точности классификации жизненных состояний деревьев на изображениях и указывают на то, что модели, обеспечивающие такую точность классификации, могут применяться в лесной отрасли. Далее использование выражения «мультиклассификация хвойных деревьев с высокой точностью» подразумевает, что значения этих метрик превышают 0,5 для всех классов жизненных состояний таких деревьев.

Необходимо учитывать важное требование к создаваемым моделям и методам, к СКЗ и нейросетевым технологиям на ее основе по скорости вычислений: реализующее их программное обеспечение должно выполняться на персональных компьютерах, имеющихся сегодня в лесничествах и центрах защиты леса Рослесхоза и позволяющих обрабатывать и анализировать изображения лесных участков в квазиреальном времени (в зависимости от размера изображений и конфигурации компьютера от нескольких долей секунды до первых десятков секунд), а также позволяющих выполняться нейросетевым технологиям за 2–5 минут. Например, на мультиклассификацию фрагмента RGB-изображения размером $256 \times 256 \times 3$ пикселей при использовании компьютера с графическим процессором (англ. GPU) должно отводиться от 0,3 с до 1с, а при отсутствии GPU – от 12 с до 20 с. Технологии решения первой или второй лесопатологической задачи для участка хвойных деревьев размером 10000 м^2 (1га)

должны выполняться на компьютере без GPU не более чем за 4–5 минут. Только при выполнении требования по скорости вычислений становится возможным использование разрабатываемых СКЗ и нейросетевых технологий в организациях и на предприятиях лесной отрасли России.

Требования высокой точности классификации и значительной скорости вычисления моделей глубокого обучения являются взаимоисключающими, поэтому необходимы их обширные комплексные исследования, по результатам которых будут найдены наиболее эффективные модели.

1.7 Основные результаты и выводы по разделу

Анализ проблемы оперативного лесопатологического мониторинга хвойных лесов и аналитический обзор моделей, методов и инструментальных средств для ее решения позволил получить следующие результаты и сделать выводы.

1. Проанализировано состояние проблемы лесопатологического мониторинга хвойных лесов. Показано, что при мониторинге необходимо решать три основные (ключевые) задачи. Первая из них – оперативное выявление на ранних стадиях очагов размножения вредителей, вторая задача – отслеживание динамики (изменений) жизненных состояний (состояния здоровья) хвойных деревьев, находящихся в этих очагах. Третья задача – выявление сухостойных деревьев и определение запасов фитомассы и углерода в них для оценки вклада сухостоя в карбоновую проблему региона.
2. Показано, что оперативное проведение лесопатологического мониторинга хвойных лесов должно осуществляться дистанционно и основываться на использовании современных методов и средств ДЗЗ. Сделан вывод, что наиболее оперативным инструментом для мониторинга локальных лесных участков являются БПЛА с размещенными на них фото или видео камерами высокого или сверхвысокого разрешения. Сделан вывод о том, что получаемые при мониторинге изображения должны анализироваться с помощью современных моделей и методов интеллектуального анализа

данных, а получаемые при этом результаты мультиклассификации жизненных состояний хвойных деревьев на изображениях являются исходными данными для решения основных задач лесопатологического мониторинга.

3. Выделены три ключевых этапа развития и использования моделей, методов и алгоритмов анализа изображений, получаемых при мониторинге лесов. Показано, что многие известные модели, методы и алгоритмы анализа изображений, развитые на первом и втором этапах, при решении различных задач классификации деревьев на изображениях дают невысокую точность и поэтому сегодня востребованы все реже. Проведенный аналитический обзор современных моделей и методов глубокого обучения, развиваемых на третьем этапе для решения задач мультиклассификации деревьев на изображениях, позволил сделать вывод о перспективности создания новых моделей полносверточных нейронных сетей и моделей трансформеров, решающих с высокой точностью задачи мультиклассификации жизненных состояний хвойных деревьев на изображениях высокого и сверхвысокого разрешения.
4. Сформулированы цель и задачи диссертационного исследования, направленные на разработку и комплексные исследования новых моделей глубокого обучения для мультиклассификации пораженных вредителями хвойных деревьев на изображениях с КА и БПЛА и на разработку методов и нейросетевых технологий для решения основных задач лесопатологического мониторинга хвойных лесов. Отметим, что развиваемое в диссертационной работе научное направление соответствует глобальному тренду цифровизации лесного хозяйства и созданию интеллектуальных систем экологического мониторинга лесов, основанных на данных ДЗЗ и передовых моделях и методах глубокого обучения.

2 МОДЕЛИ И МЕТОДЫ РЕШЕНИЯ ОСНОВНЫХ ЗАДАЧ ЛЕСОПАТОЛОГИЧЕСКОГО МОНИТОРИНГА ХВОЙНЫХ ЛЕСОВ

2.1 Модели полносверточных нейронных сетей

Модели СНС сегодня представляют собой большой и наиболее развитый класс моделей глубокого обучения. Они позволяют с высокой точностью распознавать объекты на изображениях и, что особенно важно для настоящего исследования, некоторые из них решают задачи семантической сегментации (попиксельной классификации) [78,79]. В п.п.1.5 и 1.6 показана перспективность развития среди моделей СНС полносверточных нейронных сетей класса U-Net и использования их при решении основных лесопатологических задач. Ниже описаны разработанные на основе классической модели U-Net новые модели полносверточных сетей.

2.1.1 Модель Mo-U-Net

Первая предложенная модель, названная Modified U-Net (далее – Mo-U-Net), является модификацией известной классической полносверточной сети U-Net для решения задачи семантической сегментации изображений [71]. Более подробно классическая модель U-Net описана в Приложении А, поэтому здесь рассмотрим только основные ее характеристики. Отличительной чертой этой модели является наличие соединений пропуска, объединяющих наборы карт признаков кодера с наборами карт признаков декодера с целью повышения детальности результирующей карты сегментации [71].

Ядром модели U-Net является операция свертки Conv (рисунок 2.1). Для входного изображения или карты признаков I размера $H \times W \times D$ (H – высота, W – ширина изображения и D – количество каналов) и фильтра K размера $F_h \times F_w \times d$, результат свертки O в точке (i, j) вычисляется как:

$$O(i, j) = \sigma \left(\sum_{m=0}^{F_h-1} \sum_{n=0}^{F_w-1} \sum_{d=0}^{D-1} K(m, n, d) \cdot I(i + m, j + n, d) + b \right), \quad (2.1)$$

где σ – нелинейная функция активации ReLU (англ. rectified linear unit – ReLU); b – скалярный параметр смещения (англ. bias).

Для вычисления функции активации ReLU используется формула [80]:

$$\sigma(x) = \max(0, x), \quad (2.2)$$

Суммирование в выражении (2.1) ведется по всем элементам фильтра K и всем входным каналам d . Операция применяется ко всем возможным позициям фильтра K на входной карте (в начале на входном изображении) с заданным шагом s (англ. stride). Для сохранения пространственных размеров или их контролируемого изменения часто используется дополнение нулями по краям изображения (англ. padding).



Рисунок. 2.1 – Принцип работы сверточного слоя

На рисунке 2.1 показан принцип выполнения сверточного слоя. Фильтр скользит по входному изображению, вычисляя значения выходной карты признаков I . В качестве примера показано применение фильтра размером 3×3 (соответственно свертка Conv3x3) к входному изображению в виде матрицы 4×4 с получением выходной карты признаков I размером 2×2 . Для снижения пространственной размерности и повышения инвариантности к локальным сдвигам после сверточного слоя применяется субдискретизация – обычно операция выбора максимального значения (англ. MaxPooling) в скользящем окне (например, размером 2×2 пикселя), которая уменьшает карту признаков 2×2 до

1×1 без потери ключевой информации. В приведенном примере результат после применения MaxPooling равен 3.

Параметры модели U-Net (веса фильтров K и смещения b) изменяются при ее обучении путем минимизации функции потерь L , измеряющей расхождение между предсказаниями модели и истинными метками на обучающем наборе данных. Оптимизация выполняется итеративно с помощью вариантов алгоритма стохастического градиентного спуска или его адаптивных модификаций Adam, RMSProp и т.п. [78,79,81,82]. В настоящей работе для обучения моделей использовался оптимизатор Adam. Ключевой этап обучения модели – это применение метода (часто говорят – алгоритма) обратного распространения ошибки [83], по которому вычисляется градиент функции потерь L по всем параметрам модели относительно выходного слоя, используя цепное правило дифференцирования. Эти градиенты затем используются для обновления весов модели в направлении, уменьшающем потери.

На рисунке 2.2 приведена архитектура предложенной модели Mo-U-Net. В качестве входного изображения для модели здесь и далее для других моделей СНС используется фрагмент RGB-изображения размером $H \times W \times 3$, где H – высота, W – ширина изображения в пикселях, а количество входных каналов равно 3. Прямоугольники соответствуют тензорам, или многомерным массивам, представляющим наборы карт признаков, числами указаны размеры соответствующих тензоров, стрелками обозначены следующие операции:

1. свертки (Conv3x3, Conv1x1);
2. вычисление функции активации ELU (англ. exponential linear unit – ELU), описываемой выражением [84]:

$$ELU(x) = \begin{cases} x, & \text{если } x \geq 0 \\ \alpha(e^x - 1), & \text{если } x < 0 \end{cases} \quad (2.3)$$

где α – гиперпараметр, принимающий положительное значение ($\alpha > 0$), обычно задают $\alpha = 1$.

3. пакетная нормализация (англ. Batch Normalization – BN) [85];

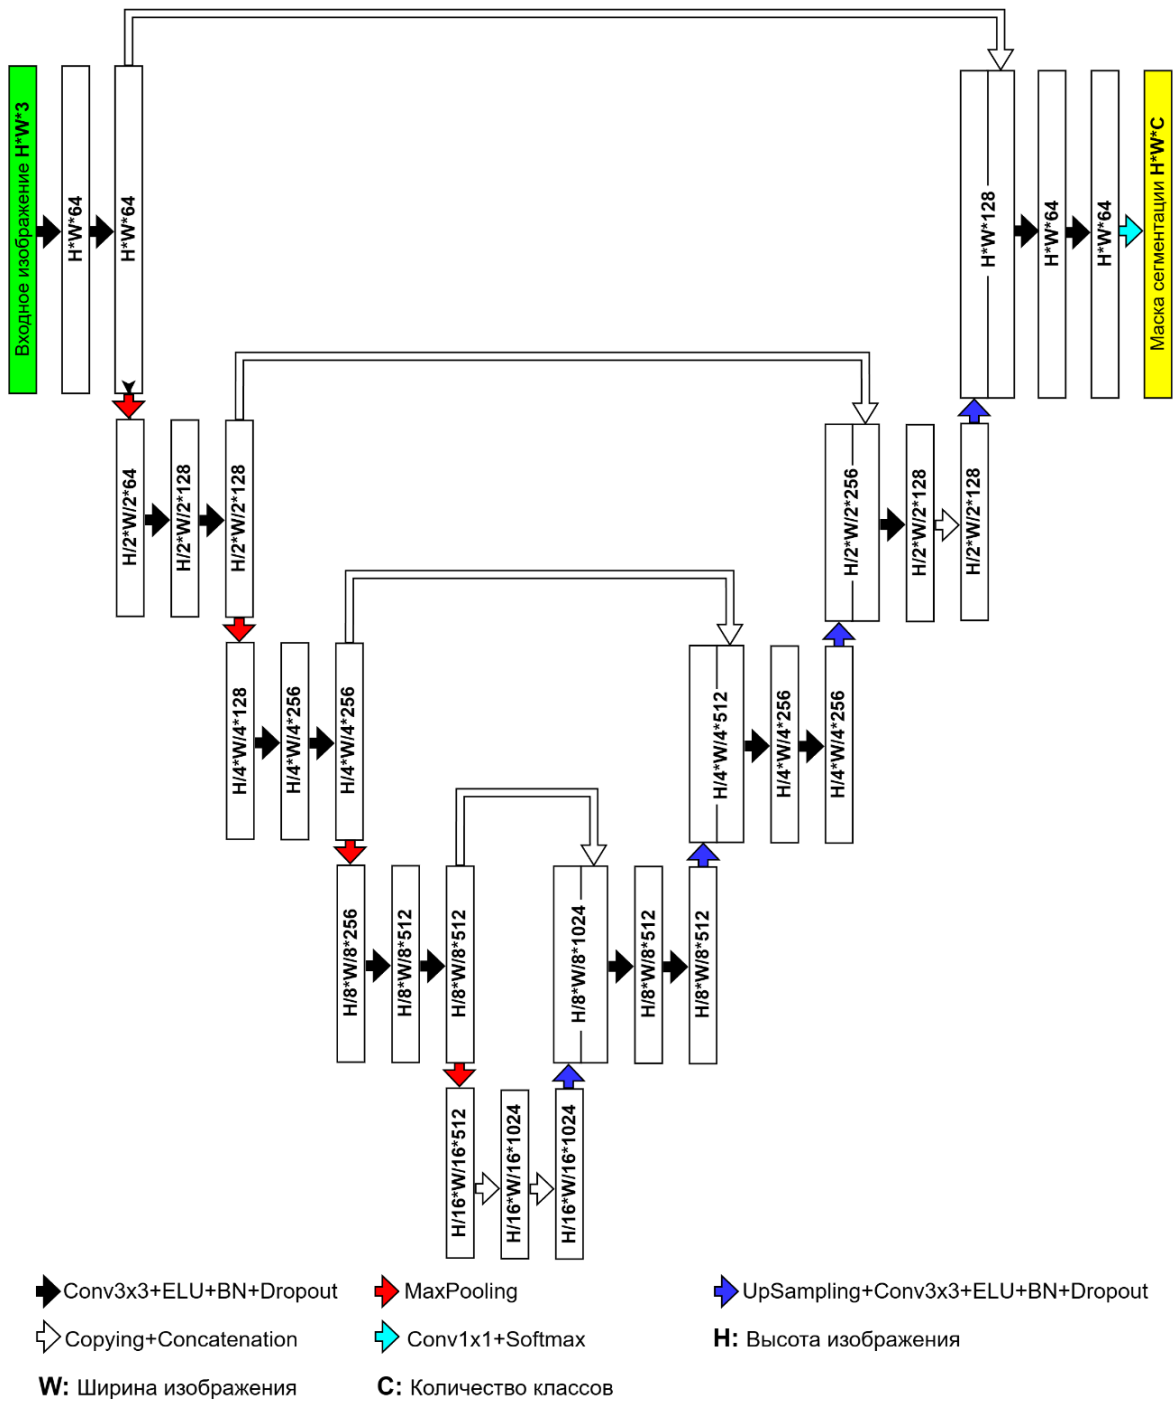


Рисунок 2.2 – Архитектура предложенной модели Mo-U-Net

4. субдискретизация, причем она выполняется путем выбора максимального значения (MaxPooling) в выходной карте признаков, то есть в матрице 2×2 пикселей;
5. увеличение масштаба (англ. UpSampling), осуществляется методом ближайшего соседа (англ. K-Nearest Neighbors – KNN);

6. копирование тензора и его конкатенация с другим тензором (англ. Copying + Concatenation);
7. для решения проблемы переобучения модели используется метод исключения (англ. Dropout) случайным образом выбранных нейронов в сверточных слоях [86]; здесь метод реализован в виде процедуры Dropout, в которой такие нейроны при исключении приравниваются к нулю и не вносят вклад в процесс обучения модели ни на одном из последующих этапов алгоритма обратного распространения ошибки.

Категориальное распределение на выходе декодера моделируется для каждого пикселя путем применения обобщения логистической функции для многомерного случая Softmax. Другими словами, в нашем случае функция Softmax нормализует выходные каналы (классы) c , преобразуя их в распределение вероятностей для формирования окончательной маски сегментации.

В архитектуру предложенной модели по сравнению с классической моделью U-Net (Приложение А) были внесены следующие изменения [87,88]:

1. входное изображение для модели представлено тензором $H \times W \times 3$ пикселей, соответствующим фрагменту RGB-изображения;
2. свертки не уменьшают размер карт признаков;
3. обрезка карт признаков не используется для соединений пропуска;
4. BN применяется после каждой нелинейности;
5. функция активации ReLU из-за отсутствия корректировки весов нейронов на ее горизонтальной части заменена на хорошо себя зарекомендовавшую нелинейную функцию ELU;

Сравнение рисунка 2.2 с рисунком А.1 из Приложения А позволяет видеть часть этих изменений.

Выходной тензор вычисляется, как и в случае модели U-Net, C свертками с фильтрами размером 1×1 , позволяя классифицировать пиксели сразу C классов, например, четыре класса деревьев *A. sibirica* и «Фон» ($C = 5$) или пять классов деревьев *P. sibirica* и «Фон» ($C = 6$).

2.1.2 Модель Res-Mo-U-Net

У некоторых моделей СНС по мере увеличения глубины, то есть количества сверточных слоев, возникает критическая проблема: деградация модели. Проявляется она так: точность насыщается, то есть эффективность модели СНС на валидационном наборе данных перестает улучшаться или даже начинает снижаться вопреки увеличению количества слоев [89]; во-вторых, возникает проблема исчезающих градиентов: градиенты, вычисляемые в процессе обратного распространения ошибки через множество слоев, экспоненциально затухают, что делает обучение глубоких сетей крайне неэффективным или невозможным, а стандартные методы инициализации весов и пакетной нормализации смягчают, но не решают эту проблему для очень глубоких моделей [90].

Для преодоления проблемы деградации градиентов в моделях полносверточных сетей нами предложено использовать остаточные соединения или остаточные блоки. Их ключевая идея заключается во введении механизма обходного пути, позволяющего информации от входа блока слоев передаваться непосредственно к его выходу, минуя основное преобразование [89]. Рассмотрим элементарный остаточный блок. Пусть x – входные данные блока и пусть $H(x)$ – искомая, но сложная для прямого описания (приближения), целевая функция-отображение, которое представляет собой стек из нескольких слоев (например, два или три сверточных слоя с нелинейностями). Вместо того чтобы заставлять стек слоев $F(x)$ напрямую аппроксимировать функцию $H(x)$, то есть стремиться, чтобы $F(x) \approx H(x)$, введем остаточный блок, дающий возможность переформулировать эту задачу. Блок позволяет слоям аппроксимировать остаточную функцию:

$$F(x) = H(x) - x, \quad (2.4)$$

Тогда исходное целевое отображение $H(x)$ преобразуется к виду:

$$H(x) = F(x) + x, \quad (2.5)$$

Реализация остаточного блока в модели сети следующая.

1. Вход x подается параллельно на два пути:

- основной путь: последовательность слоев, реализующих функцию $F(x)$ (часто это 2 или 3 сверточных слоя с пакетной нормализацией и функциями активации, в нашем случае – функция ELU).
 - обходной путь: прямая передача входного сигнала x (или, при необходимости, его линейное преобразование $W_s \times x$ для согласования размерностей, где W_s – матрица сверточных фильтров).
2. Осуществляется сложение: выходы обоих путей поэлементно суммируются:

$$y = F(x, \{W_i\}) + W_s \cdot x, \quad (2.6)$$

где $\{W_i\}$ – параметры слоев на основном пути.

Существуют два варианта расположения функций активации и BN внутри блока:

1. Оригинальный вариант: $\text{BN} \rightarrow \text{ELU} \rightarrow \text{Conv}$ перед сложением. В этом случае активация применяется перед сложением.
2. Более эффективный вариант: $\text{Conv} \rightarrow \text{BN} \rightarrow \text{ELU}$. Для модели СНС ResNetv2 было показано, что перенос функции активации перед сверточными слоями ($\text{BN} \rightarrow \text{ELU} \rightarrow \text{Conv}$) и отсутствие функции активации после сложения ($y = F(x) + x$, без ELU после суммы) упрощает оптимизацию и часто дает лучшие результаты [89].

Поэтому в нашей работе использовался второй вариант расположения функций активации и BN внутри блока.

Хотя концепция построения остаточных блоков является общей, конкретная структура стека слоев $F(x)$ может варьироваться. Наиболее распространены блоки с двумя ($\text{Conv}3 \times 3 \rightarrow \text{Conv}3 \times 3$) или тремя ($\text{Conv}1 \times 1 \rightarrow \text{Conv}3 \times 3 \rightarrow \text{Conv}1 \times 1$ – «бутылочное горлышко») сверточными слоями.

Учитывая вышеизложенные преимущества остаточных блоков, связанные с повышением эффективности обучения глубоких СНС и обеспечением устойчивости к эффекту исчезающих градиентов, было решено внедрить их в архитектуру модели Mo-U-Net вместо части стандартных сверточных блоков в энкодере и декодере. При этом в каждом сверточном блоке энкодера заменили

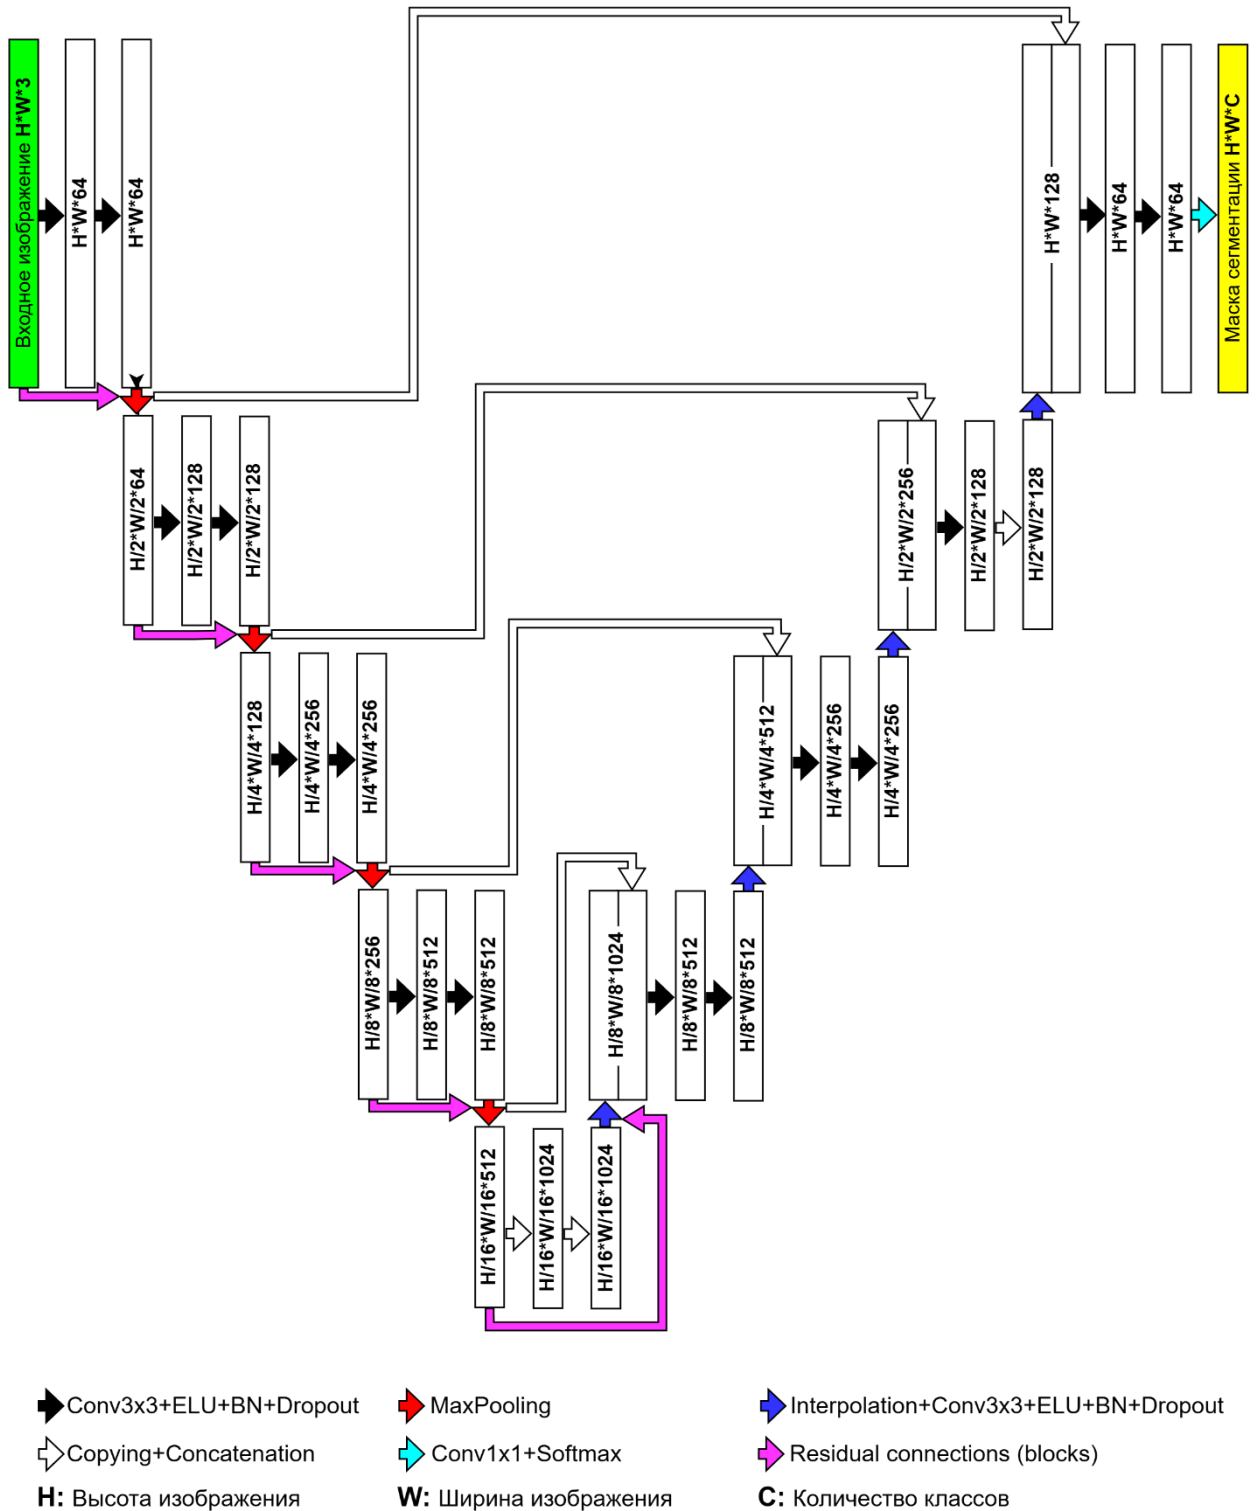


Рисунок 2.3 – Архитектура предложенной модели Res-Mo-U-Net

стандартные сверточные слои на остаточные блоки. Аналогично, в декодере использовали остаточные блоки для обработки карт признаков перед увеличением разрешения, что должно помочь сохранить важные детали крон деревьев. Каждый остаточный блок состоит из двух сверточных слоев с ядром 3×3 . Результат

работы двух сверточных слоев складывается с исходным входом блока (или его проекцией, если размеры не совпадают). Это позволяет модели сохранять информацию о низкоуровневых признаках крон деревьев при передаче их через нейросеть, что важно при решении задач семантической сегментации. В итоге была разработана еще одна модель полносверточных сетей, названная Residual-Modified U-Net (далее Res-Mo-U-Net). Она основана на модели Mo-U-Net, но имеет следующие существенные изменения ее архитектуры: замену ряда стандартных сверточных слоев в энкодере и декодере на остаточные блоки и введение пространственной процедуры SpatialDropout вместо процедуры Dropout [91].

На рисунке 2.3 приведена архитектура модели Res-Mo-U-Net в случае входного фрагмента RGB-изображения размером $H \times W \times 3$ пикселей, где H – высота фрагмента, W – ширина фрагмента, а количество входных каналов равно 3. Важно отметить, что операции проецирования (Conv1x1) в главных ветвях остаточных блоков этой модели не включают нелинейностей и смещений. Поэтому можно ожидать, что такие остаточные блоки могут привести к более стабильному процессу обучения модели Res-Mo-U-Net и позволят упростить обратное распространение градиента при ее обучении. В итоге это должно способствовать лучшему выявлению тонких признаков крон деревьев при решении сложной задачи мультиклассификации изображений пораженных насекомыми-вредителями хвойных деревьев, в частности, уссурийским полиграфом деревьев *A. sibirica* и союзным короедом деревьев *P. sibirica*.

2.1.3 Гибридная модель At-Mo-U-Net

В последнее время перспективным направлением в теории глубокого обучения является создание моделей СНС, в которых реализованы те или иные механизмы внимания (англ. attention mechanism). Они обеспечивают динамическое выделение вычислительных ресурсов на наиболее значимых элементах входного изображения или на картах признаков при формировании выходного отклика для каждого элемента анализируемого изображения [92,93]. Ядро механизма внимания можно формализовать как функцию отображения

запроса и набора ключ-значений пар во взвешенную сумму значений признаков пространственных элементов входного изображения. При этом веса определяются степенью совместимости между запросом и соответствующим ключом [94,95]. Кратко рассмотрим формальное описание механизма внимания. Пусть имеем следующие входные данные:

1. Исходные векторы: $S = [s_1, s_2, \dots, s_N]$, где $s_i \in \mathbb{R}^{d_{\text{model}}}$ (элементы последовательности, соответствующие регионам признаков изображения).
2. Проекционные матрицы: W_k, W_v, W_q – матрицы весов, которые линейно отображают векторы признаков отдельных пространственных элементов изображения (пикселей или патчей карты признаков) в пространства ключей, значений и запросов соответственно.

Вычисление компонентов внимания (для каждого исходного вектора s_i вычисляются три проекции) осуществляется следующим образом:

$$k_i = W_k s_i, \quad (2.7)$$

где k_i – вектор ключа, описывающий этот пространственный элемент в «пространстве поиска релевантных регионов»;

$$v_i = W_v s_i, \quad (2.8)$$

где v_i – вектор значения, содержащий информацию о тех же локальных признаках изображения (того же пикселя/патча), но в специально спроецированном пространстве, из которого затем формируется взвешенная сумма при агрегировании контекста;

$$q_j = W_q s_j, \quad (2.9)$$

где q_j – вектор запроса для целевой позиции j , то есть для того пространственного элемента карты признаков (пикселя или патча), для которого в данный момент вычисляется взвешенная комбинация контекстных признаков из других регионов изображения.

Механизмы внимания не заменяют, а дополняют и усиливают возможности модели СНС. Их интеграция в модель реализуется двумя путями:

1. Последовательная интеграция, когда блоки внимания добавляются поверх сверточных слоев энкодера для моделирования глобального контекста перед декодированием [96,97].
2. Параллельная интеграция, когда потоки обработки с помощью сверток и механизмов внимания выполняются параллельно, а их выходы объединяются (например, конкатенацией или суммированием) [98].

Предложенная нами гибридная модель также, как и модель Res-Mo-U-Net, основана на модели Mo-U-Net, но в ней реализован механизм внимания. Из рассмотренных выше способов интеграции сверточных слоев и блоков механизма внимания выбран первый: последовательная интеграция. Это обеспечивает баланс между локальной детализацией и глобальным пониманием, важным для семантической сегментации изображений хвойных лесов. Новая модель получила название At-Mo-U-Net, а ее архитектура включает энкодер и декодер (рисунок 2.4), причем каждый из них имеет блоки механизма внимания [94]. Кратко опишем модель At-Mo-U-Net, опираясь на рисунок 2.4 и используя указанные в нем обозначения [91].

Энкодер состоит из серии сверточных блоков, за которыми следуют слои MaxPooling. Каждый блок увеличивает количество фильтров при уменьшении пространственных размеров, что позволяет модели изучать иерархические признаки крон деревьев из входного фрагмента RGB-изображения. В свою очередь, каждый сверточный блок включает два последовательных сверточных слоя с функцией активации ELU и нормализацию по мини-пакетам, а также Dropout для повышения обобщающей способности модели. На уровне энкодера механизм внимания усиливает значимость определенных признаков крон деревьев, позволяя модели сфокусироваться и выделять важные детали и игнорировать менее значимые детали крон. Декодер зеркально отражает структуру энкодера и включает слои увеличения разрешения и конкатенации.

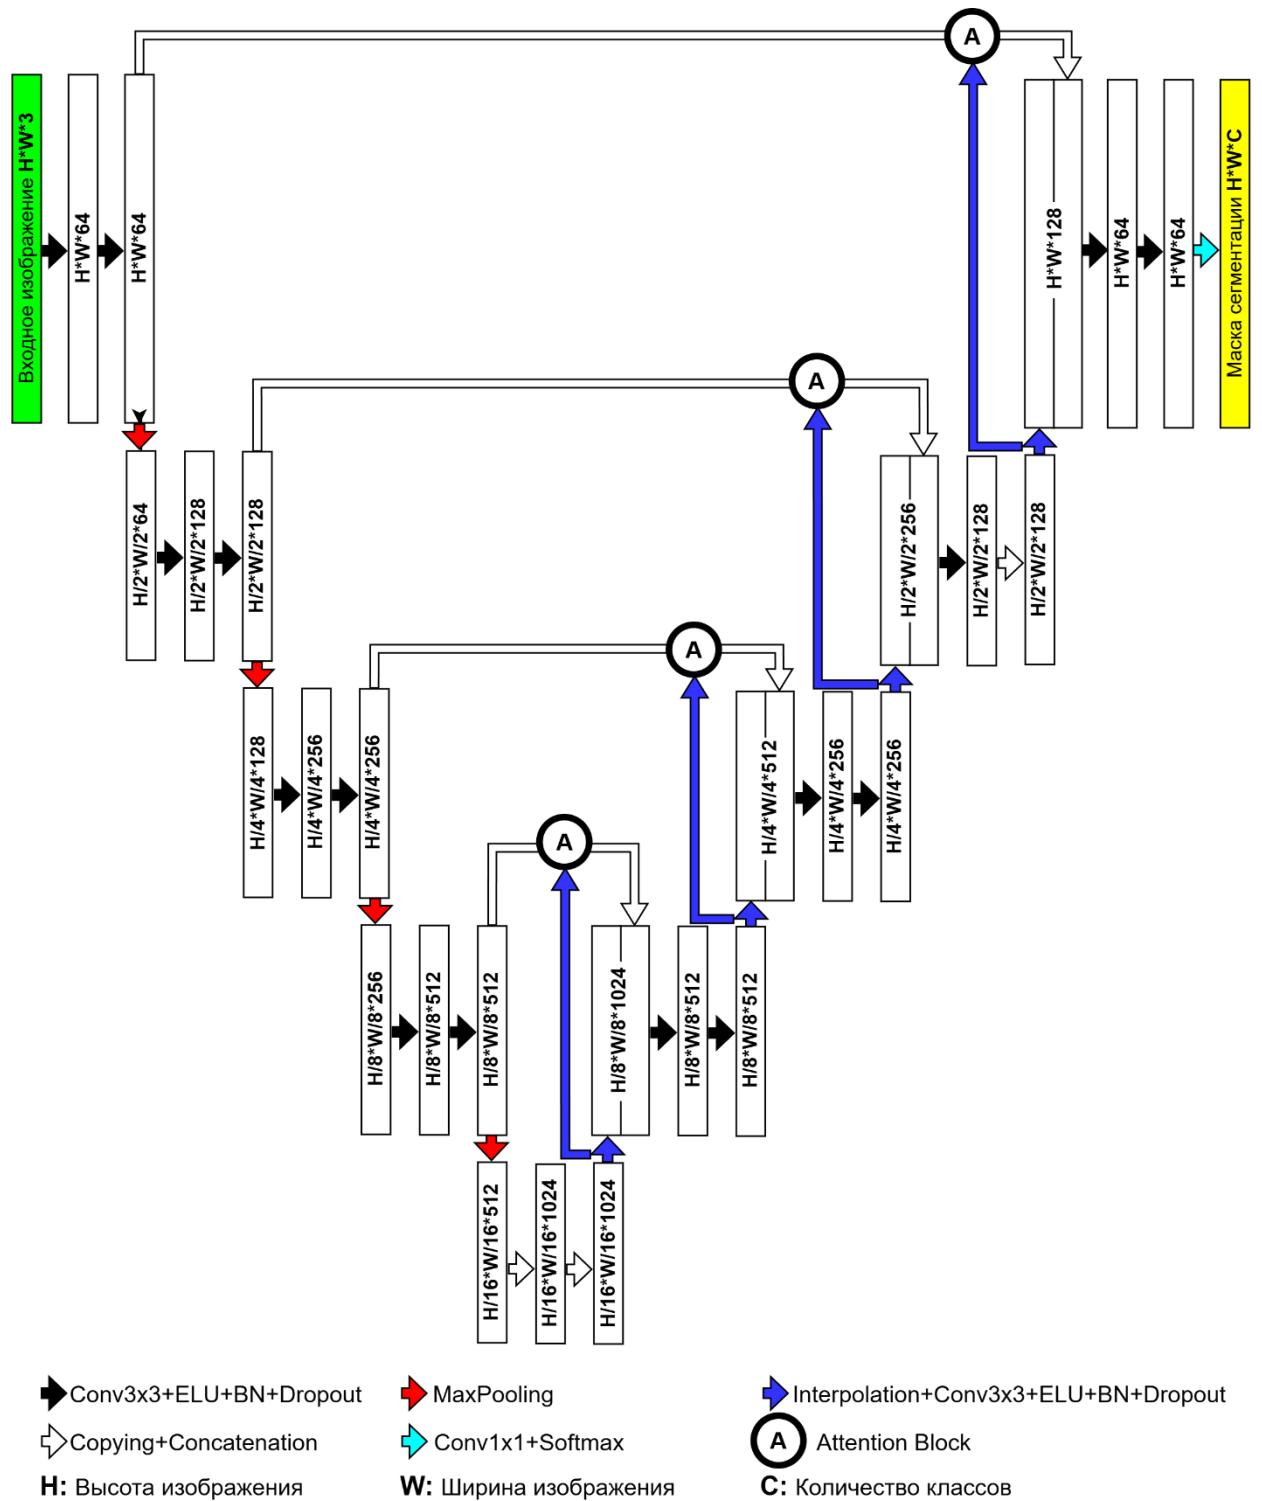


Рисунок 2.4 – Архитектура гибридной модели At-Mo-U-Net

Слои увеличения разрешения восстанавливают пространственное разрешение карт признаков. Это достигается с помощью интерполяции методом KNN, за которым следует сверточный слой. Пропускные соединения конкатенируют карты признаков из пути уменьшения разрешения с

соответствующими картами из пути увеличения разрешения. В декодере механизм внимания также применяется для улучшения качества выходной маски сегментации. Он помогает более точно восстанавливать пространственную информацию, акцентируя внимание на ключевых областях изображения при объединении признаков из разных уровней.

Остановимся более детально на реализации механизма внимания. В разработанной модели At-Mo-U-Net он улучшает способность полносверточной нейронной сети Mo-U-Net фокусироваться на наиболее значимых признаках крон деревьев, динамически определяя важность различных пространственных позиций на картах признаков. Блок механизма внимания реализуется путем использования трех слоев: вычисления весов, умножения и слияния признаков. На вход слоя вычисления весов поступают карты признаков, полученные из энкодера или с помощью предыдущих слоев. Слой вычисляет весовые коэффициенты для каждой пространственной позиции на карте признаков. Для этого используется функция активации Sigmoid [99], которая задаёт значения в диапазоне $[0, 1]$, отражающие относительную важность каждой позиции. На выходе слоя формируется матрица весов, в которой каждое значение соответствует уровню внимания для соответствующей позиции на карте признаков. На вход слоя умножения подаются исходные карты признаков и вычисленная матрица весов и в нем происходит поэлементное умножение карт признаков на матрицу весов. Эта операция усиливает более важные признаки (с высокими весами) и подавляет менее значимые (с низкими весами). На выходе слоя будут уточнённые карты признаков, где ключевые признаки акцентированы. На вход слоя слияния признаков поступают уточнённые карты признаков после применения механизма внимания и дополнительные карты признаков из декодера. Затем происходит слияние путем конкатенации карт признаков, прошедших через блок механизма внимания, с другими картами признаков в декодере. Это объединение позволяет сохранить важные детали с предыдущих этапов и осуществить их вклад в финальный результат сегментации фрагмента.

В итоге появляется финальная карта признаков, используемая для построения маски сегментации.

Хотя механизмы внимания уже изучались исследователями и внедрялись в различные модели глубокого обучения, предложенная конкретная комбинация операций, реализующих механизм внимания в рамках исходной модели Mo-U-Net, учитывает особенности семантической сегментации крон пораженных хвойных деревьев и является новой. Поэтому интеграция оригинальных блоков внимания в модель Mo-U-Net позволяет считать, что разработанная гибридная модель At-Mo-U-Net является новой и повысит эффективность решения основных лесопатологических задач.

2.2 Модель Segformer+

В п.п.1.5 и 1.6 показано, что перспективным направлением развития моделей глубокого обучения для решения основных лесопатологических задач является создание моделей на основе принципов трансформеров. Более того, необходим сравнительный анализ эффективности предложенных и описанных в п.2.1 новых моделей полносверточных сетей с другими перспективными моделями глубокого обучения. Учитывая все это, нами разработана модель Segformer+, являющаяся модификацией одного из перспективных трансформеров [74].

Ключевым отличием трансформеров от моделей СНС является отказ от операций свёртки в пользу механизма самовнимания (англ. self-attention), который позволяет учитывать глобальные зависимости между различными областями изображения независимо от расстояния между ними [100]. В трансформерах изображение рассматривается как последовательность фрагментов (патчей). Энкодер состоит из M одинаковых слоёв, каждый из которых включает два основных блока: блок многоголового самовнимания (СМГС) и блок полносвязной нейронной сети в многослойного персептрона (МСП). Оба блока используют нормализацию слоя и остаточные соединения.

Механизм самовнимания позволяет каждому патчу учитывать информацию от всех остальных патчей изображения. В отличие от традиционных задач классификации, где требуется получить один вектор признаков для всего изображения, задачи семантической сегментации требуют попиксельной классификации. Поэтому выходная последовательность патчей энкодера должна быть преобразована обратно в пространственную карту признаков. Для этого необходимо преобразовать последовательность выходных патчей энкодера обратно в карту признаков с пространственным разрешением, сопоставимым с разрешением исходного изображения. Общие подходы к такому преобразованию включают следующее: использование промежуточных карт признаков, при этом выходные токены патчей пересобираются обратно в 2D карту признаков, и использование специализированных декодеров.

Архитектура декодера варьируется и сегодня является активной областью исследований [74]. Ключевая идея – использовать мощное глобальное контекстное представление, извлеченное энкодером трансформера, и эффективно проецировать его на плотную пространственную карту сегментации.

Сегодня достаточно известна модель Segformer, в которой сочетаются преимущества моделей с использованием трансформеров в энкодере с легкими МСП в декодере [74]. Известно, что модель Segformer с успехом применялась при решении нескольких прикладных задач семантической сегментации изображений, поэтому важно адаптировать (модифицировать) ее и применить при решении задачи семантической сегментации (попиксельной мультиклассификации) изображений пораженных насекомыми-вредителями хвойных деревьев. Кратко опишем эту модель. Во-первых, отметим иерархическую архитектуру трансформера в энкодере модели Segformer, известную как MiT (англ. Mix Transformer – MiT) [74]. Она позволяет энкодеру генерировать признаки нескольких масштабов, что важно для точной сегментации объектов различного размера на изображении. В отличие от традиционных архитектур трансформеров, в модели Segformer не требуется позиционный энкодер. Это упрощает ее архитектуру и предотвращает ухудшение

эффективности, которое может возникнуть при несоответствии между разрешениями изображений обучающей и тестовой выборок. Наконец, используется агрегация слоев, что способствует агрегации информации из различных слоев энкодера и в итоге позволяет модели эффективно использовать механизмы как локального, так и глобального внимания. Во-вторых, структурно энкодер состоит из нескольких компонентов, каждый из которых включает в себя следующие элементы: слой Overlap Patch Embedding (разбивает изображение на перекрывающиеся патчи, что позволяет улучшить взаимодействие между ними) и блок трансформера, состоящий из:

- слоя внимания для обработки входных данных с использованием механизмов внимания с целью выделения значимых признаков; каждый блок включает в себя механизм эффективного самовнимания (англ. efficient self-attention mechanism) и смешанную сеть прямой передачи Mix-FNN (англ. Mix Feed Forward Network – Mix-FNN);
- процедуры Overlap Patch Merging, которая реализует операцию слияния патчей обратно в карты признаков; этот процесс также включает слои нормализации для улучшения стабильности модели при обучении.

В-третьих, легкий МСП-декодер в модели Segformer представляет собой ключевой компонент архитектуры, который отвечает за преобразование многомасштабных признаков, полученных от иерархического трансформер-энкодера, в окончательную маску сегментации.

В модель Segformer нами был внесен ряд значительных изменений с целью повышения качества сегментации изображений хвойных деревьев. Модифицированная модель получила название Segformer+, а ее архитектура приведена на рисунке 2.5 [91]. Основными изменениями базовой модели Segformer являются следующие.

1. Вместо стандартного механизма самовнимания в блок каждого из четырех трансформеров модели интегрирован механизм кросс-уровневого внимания (англ. cross-level attention mechanism). Этот механизм обеспечивает обмен

информацией между признаками различных масштабов – от низкоуровневых детализированных текстур хвои (листвы) и ветвей (высокое разрешение) до высокоуровневых семантических представлений общей структуры кроны дерева и её границ (низкое разрешение). Таким образом, усиливается захват многоуровневых пространственных зависимостей [101].

- Вместо стандартных МСП в декодере модели интегрированы пространственные гейты с управляющими элементами SGU (англ. Spatial Gating Units – SGU), интегрированные в специализированный SGU-блок, что усиливает взаимодействие пространственных признаков (взаимосвязи между всеми различными частями изображения) за счёт динамического модулирования внимания к локальным и глобальным контекстам. SGU используют гейтинг-механизм для селективного усиления релевантных пространственных зависимостей между пикселями, минимизируя потерю информации при обработке высокоразмерных карт признаков. Это важно для задач семантической сегментации кроны деревьев, где требуется точное различение границ кроны [102].

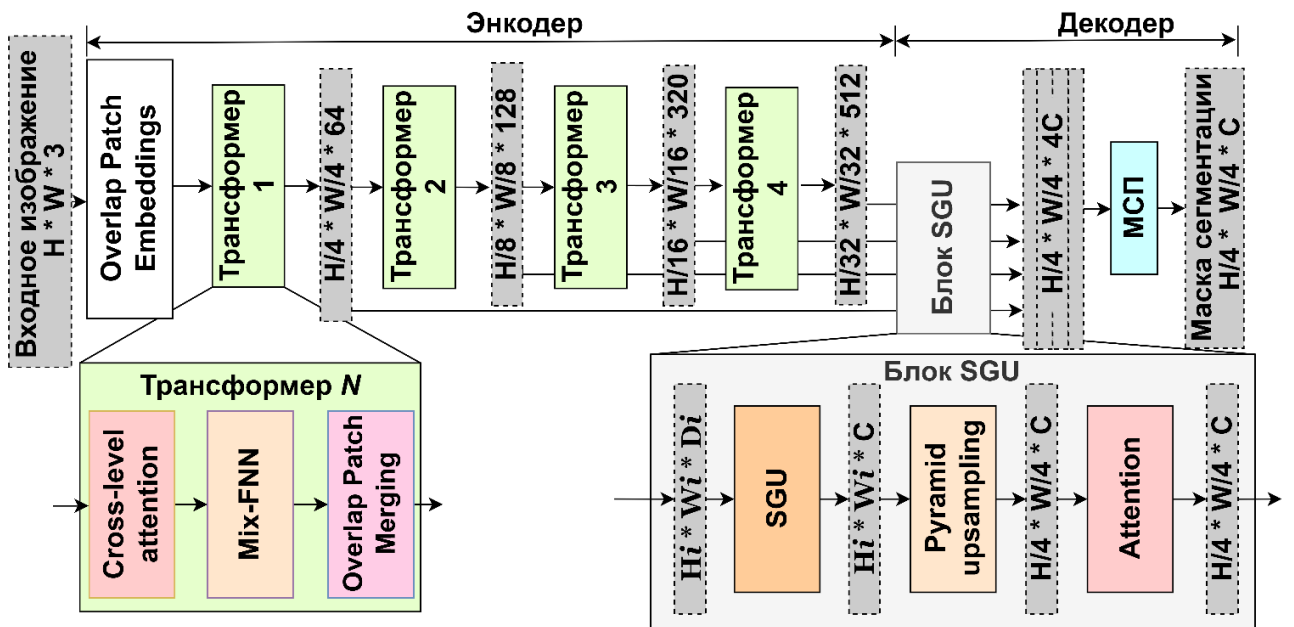


Рисунок 2.5 – Архитектура предложенной модели Segformer+. Обозначения: H – высота изображения; W – ширина изображения; D – число каналов выходной карты признаков; C – количество классов жизненных состояний деревьев

3. После применения SGU вместо простого увеличения размера карт признаков, применено многоуровневое пирамидальное увеличение пространственного разрешения (англ. pyramid upsampling) позволяющее поэтапно восстанавливать детали объектов при переходе от сжатых представлений энкодера к более детализированным картам декодера. На следующем этапе осуществлена конкатенация карт признаков декодера с признаками соответствующего уровня энкодера, что обеспечивает сохранение как глобального контекста, так и локальных пространственных деталей. Далее в SGU-блоке применён слой пространственного внимания, который выполняет дополнительную контекстно-зависимую фильтрацию объединённых признаков, усиливая информативные области, связанные с текстурами листвы, ветвями и границами крон. Финальная конкатенация выходных признаков SGU-блока позволяет стабилизировать восстановление пространственной структуры объектов и улучшает сегментацию перекрывающихся и частично окклюзированных крон деревьев на изображениях лесных массивов [103].

2.3 Постобработка масок сегментации

Даже при использовании современных нейросетевых моделей для семантической сегментации изображений выходные маски сегментации могут содержать мелкие шумовые области, фрагментированные участки крон деревьев и искажённые границы между смежными кронами, что обусловлено вариабельностью спектральных характеристик растительности, неоднородным освещением и частичным перекрытием крон хвойных деревьев. Поэтому для повышения точности решения задач лесопатологического мониторинга результаты семантической сегментации в виде пиксельных масок требуют обязательной постобработки. Она включает фильтрацию крон деревьев по критерию минимальной площади, а также уточнение границ крон с применением морфологических операций и алгоритмов сглаживания [104,105]. Это позволит

исключить незначимые детали и обеспечит чёткое разделение смежных крон деревьев, что, в итоге, значительно улучшит качество маски.

Пусть $M : \Omega \rightarrow \{1, 2, \dots, C\}$ – маска сегментации, где $\Omega \subset \mathbb{Z}^2$ – область изображения, C – количество классов жизненных состояний хвойных деревьев. Для каждого класса $c \in \{1, 2, \dots, C\}$ в маске выделяется множество связанных компонентов:

$$O_c = \{O_{c,i}\}_{i=1}^{N_c}, \quad (2.10)$$

где $O_{c,i}$ – i -й связный компонент класса c , интерпретируемый как отдельная крона; N_c – количество связанных компонентов (отдельных крон) в классе c .

На первом этапе постобработки выполняется фильтрация связанных компонентов по критерию минимальной площади. Для этого вводится пороговое значение площади S_{\min} , определяющее минимально допустимую площадь кроны в пикселях, и рассчитывается по формуле [106]:

$$S_{\min} = \frac{\pi \left(\frac{D_{\min}}{2}\right)^2}{GSD^2}, \quad (2.11)$$

где D_{\min} – минимальный диаметр кроны (м); GSD – пространственное разрешение (м/пиксель).

Минимальный диаметр кроны для деревьев *A. sibirica* и *P. sibirica* составляет $D_{\min} = 1$ м [107], что при пространственном разрешении $GSD = 0,1$ м/пиксель соответствует минимальной площади $S_{\min} \approx 78$ пикселей. Данное значение позволяет исключить шумовые артефакты, сохраняя при этом реальные кроны деревьев. Площадь каждого компонента вычисляется:

$$S(O_{c,i}) = \sum_{(x,y) \in \Omega} \mathbb{I}((x,y) \in O_{c,i}), \quad (2.12)$$

где $\mathbb{I}(\cdot)$ – индикаторная функция, равная 1, если условие выполняется, и 0 – в противном случае; x, y – координаты пикселя в области изображения Ω .

Компоненты, для которых выполняется условие $S(O_{c,i}) < S_{\min}$, переназначаются в класс Фон, поскольку они, как правило, соответствуют шуму, теням или ошибочным классификациям:

$$O_{c,i} = \begin{cases} O_{c,i}, & S(O_{c,i}) \geq S_{\min}, \\ \emptyset, & S(O_{c,i}) < S_{\min}, \end{cases} \quad (2.13)$$

На втором этапе постобработки осуществляется уточнение границ крон деревьев в маске. Для каждого класса c формируется промежуточная бинарная маска M_c , которая содержит только те пиксели исходной маски M , которые принадлежат данному классу, в то время как все остальные пиксели устанавливаются в ноль. К полученной бинарной маске M_c применяются операции математической морфологии – открытие и закрытие [105]. Операция открытия удаляет мелкие выступы и изолированные артефакты на границах крон, а операция закрытия заполняет небольшие разрывы и впадины внутри объектов, обеспечивая целостность выделенных крон деревьев.

После морфологической обработки маски сегментации выполняется третий этап – сглаживание границ крон деревьев с целью уменьшения локальных неровностей контуров, обусловленных пиксельной дискретизацией и ошибками классификации.

Сглаживание границы каждой кроны осуществляется методом скользящего среднего координат [104]:

$$\tilde{x}_j = \frac{x_{j-1} + x_j + x_{j+1}}{3}, \tilde{y}_j = \frac{y_{j-1} + y_j + y_{j+1}}{3}, \quad (2.14)$$

где $(\tilde{x}_j, \tilde{y}_j)$ – координаты сглаженного контура.

Применение данного сглаживания границы позволяет сохранить общую форму кроны при одновременном устранении мелких изломов границ, что повышает геометрическую согласованность сегментированных объектов и качество последующего анализа маски.

2.4 Метод дистанционного обнаружения очагов размножения вредителей пихтовых лесов

Главная цель оперативного лесопатологического мониторинга лесов – обнаружить очаг насекомых-вредителей в начальной фазе его развития, что позволит провести соответствующие санитарно – оздоровительные мероприятия

с минимальными потерями деревьев. Сегодня принятие решения специалистами лесного хозяйства о наличии очага стволовых вредителей в хвойных лесах основывается на результатах наземного мониторинга и осуществляется по отраслевым решающим правилам, изложенным в известной методике [108]. Согласно этой методике действующим очагом стволовых вредителей считается участок хвойного леса площадью 10000 м² (1 гектар, га), в котором количество заселенных (первый вариант) или свежеотработанных (второй вариант) вредителями хвойных деревьев (суммарный отпад деревьев в каждом из этих вариантов) превышает норму естественного отпада, причем эти деревья относятся к основному пологу древостоя (I-III классы Крафта). В решающих правилах выявления очага в методике учитывается деление хвойных деревьев по возрасту на три категории: молодые деревья (первая категория), средневозрастные деревья (вторая категория) и третья категория – это приспевающие, спелые и перестойные деревья. Поэтому решающие правила таковы: участок леса в возрасте молодняка относится к очагу, если в нем заселено вредителем не менее 5–7% всех деревьев этой породы на одном гектаре, в средневозрастных участках – не менее 3–5% деревьев и участок – очаг с деревьями третьей категории, если заселено не менее 2–3% всех деревьев этой породы этого возраста. Иными словами, для каждого возраста деревьев (для каждой категории деревьев по возрасту) есть свой порог отпада, превышение которого позволяет принять решение о наличии очага размножения стволового вредителя, поэтому правил принятия решений три. Более того, эти правила действуют как в случае заселенных, так и свежеотработанных вредителями хвойных деревьев. Отметим, что в случае деревьев пихты *A. sibirica* роль указанных в методике заселенных (первый вариант) вредителями хвойных деревьев выполняют деревья пихты второго класса жизненного состояния («Отмирающие»), а роль свежеотработанных (второй вариант в методике) вредителями деревьев играют деревья пихты третьего класса («Свежий сухостой»).

С учетом этой методики был предложен метод обнаружения очага уссурийского полиграфа *P. proximus* на анализируемых изображениях высокого и сверхвысокого разрешения деревьев пихты *A. sibirica*, полученных при монито-

ринге пихтовых лесов с КА или БПЛА. Суть метода в следующем. На основе полученных с помощью одной из предложенных моделей СНС или модели Segformer+ результатов мультиклассификации таких изображений в виде прошедшей постобработку маски сегментации для изучаемого участка площадью 1 га сначала выявляются пораженные деревья пихты второго (класс «Отмирающие») или третьего (класс «Свежий сухостой») классов жизненного состояния (степени повреждения вредителем). Затем с использованием данных о возрасте таких деревьев, полученных путем дополнительного анализа маски сегментации, проводится расчет фактического значения отпада для каждой категории возраста деревьев. После этого полученные значения сравниваются с пороговыми значениями отпада, зависящими от категории возраста деревьев, и принимается решение о наличии очага уссурийского полиграфа. В основе метода лежит обычно подтверждаемая на практике гипотеза о высокой корреляционной зависимости площади кроны хвойного дерева от его возраста. Используемые в методе данные о возрасте каждого дерева *A. sibirica* получают путем вычисления на маске сегментации площади его кроны. Для точного расчета площади кроны при частичном перекрытии крон недостающая часть контура кроны перекрытого дерева пихты достраивается с помощью сплайн-интерполяции. Интервалы значений площади крон деревьев пихты каждой из трех категорий возраста предварительно получают для каждого региона или биотопа путем совместного анализа результатов наземного и дистанционного мониторинга опытного участка пихтового леса.

Итак, предлагаемый метод реализуется в два последовательно выполняемых ключевых этапа. Входными данными для метода являются результаты мультиклассификации пораженных деревьев пихты на изображении исследуемого участка пихтового леса площадью 1 га в виде маски сегментации, прошедшей постобработку. На первом этапе сначала происходит вычисление по полученной при мультиклассификации маске сегментации площади кроны каждого дерева пихты на участке, а затем выполняется отнесение каждого дерева в зависимости от площади его кроны к одной из трех возрастных категорий. На

втором этапе по результатам выполнения первого этапа принимается решение о наличии очага уссурийского полиграфа на исследуемом участке леса. Оно формируется в соответствии с рассмотренными выше порогами отпада для каждой возрастной категории деревьев пихты и решающими правилами.

Метод реализован в виде разработанного алгоритма принятия решения о наличии очага уссурийского полиграфа по данным мониторинга исследуемого участка деревьев пихты *A. sibirica*. В алгоритме для деревьев первой категории по возрасту выбран порог отпада 5% и более пораженных деревьев второго или третьего классов от общего числа молодых деревьев на обследуемом участке, для второй категории – порог отпада 3% и более от общего числа средневозрастных деревьев на участке, а для третьей категории деревьев – порог 2% и более от общего числа приспевающих, спелых и перестойных деревьев на участке. В алгоритме решение о наличии очага может приниматься как в первом варианте в результате анализа числа пораженных деревьев пихты второго класса (класс «Отмирающие»), так и во втором варианте, когда анализируется число пораженных деревьев пихты третьего класса (класс «Свежий сухостой»). Иными словами, можно использовать результаты любого из двух вариантов вычислений при поиске очага уссурийского полиграфа по этому алгоритму. Приведем пошаговое описание алгоритма.

Начало

Шаг 1. Выбор исследуемого участка пихты площадью 1 га (10000 м²) на панораме и ввод его координат;

Шаг 2. Ввод результатов мультиклассификации деревьев пихты на изображении выбранного участка, полученных с помощью одной из разработанных моделей глубокого обучения (маска сегментации после постобработки, класс c каждого дерева, M – общее число деревьев пихты на участке); ввод N – значения относительного естественного отпада деревьев пихты в %, присущих данной лесной экосистеме или региону;

Шаг 3. Ввод интервальных значений площади крон пихты (в пикселях): S_0 – нижняя граница площади крон молодых деревьев (деревьев первой категории по

возрасту), S_1 – верхняя граница площади крон молодых деревьев, S_2 – верхняя граница площади крон средневозрастных деревьев (деревьев второй категории по возрасту); если деревья пихты приспевающие, спелые или перестойные (деревья третьей категории по возрасту), то площадь их крон должна быть более S_2 ;

Шаг 4. Цикл по i -ому дереву пихты участка, $i = 1, 2, \dots, M$;

$i = 1$

Шаг 4.1. Вычисление в пикселях площади S_i кроны i -го дерева на маске сегментации; процедура вычисления площади позволяет при перекрытии на изображении части кроны дерева вышележащей кроной древесного полога провести сплайн-интерполяцию недостающей части контура кроны этого дерева и в итоге более точно вычислить площадь перекрытой части кроны.

Шаг 4.2. Если S_i больше или равно S_0 , но меньше или равно S_1 , то это дерево первой категории и переход на **Шаг 5**, иначе на **Шаг 4.3**.

Шаг 4.3. Если S_i больше S_1 , но меньше или равно S_2 , то это дерево второй категории и переход на **Шаг 6**, иначе на **Шаг 4.4**.

Шаг 4.4. Если S_i больше S_2 , то это дерево третьей категории и переход на **Шаг 7**, иначе на **Шаг 8**.

Шаг 5. Формирование списка с номером 1 деревьев первой категории по возрасту и подсчет количества деревьев L_1 в списке. Переход на **Шаг 8**.

Шаг 6. Формирование списка с номером 2 деревьев второй категории по возрасту и подсчет количества деревьев L_2 в списке. Переход на **Шаг 8**.

Шаг 7. Формирование списка с номером 3 деревьев третьей категории по возрасту и подсчет количества деревьев L_3 в списке. Переход на **Шаг 8**.

Шаг 8. $i = i + 1$, если $i \leq M$, то на **Шаг 4.1**, иначе на **Шаг 9**.

Шаг 9. Цикл по текущему номеру j сформированного списка деревьев соответствующей категории возраста, $j = 1, 2, 3$;

$j = 1$ (номер списка деревьев первой категории)

Шаг 9.1. Начало реализации первого варианта – подсчет в j -ом списке количества K_{j2} деревьев второго класса состояния здоровья (класс «Отмирающие»); переход на **Шаг 9.2**.

Шаг 9.2. Начало реализации второго варианта – подсчет в j -ом списке количества K_{j3} деревьев третьего класса состояния здоровья (класс «Свежий сухостой»); переход на *Шаг 9.3.*

Шаг 9.3. Если $[(K_{j2} / L_j) \times 100 - N]\%$ больше или равно 5%, то принятие решения о наличии очага вредителей деревьев первой категории и выдача сообщения «Очаг вредителей молодых деревьев по первому варианту»; переход на *Шаг 9.4.*

Шаг 9.4. Если $[(K_{j3} / L_j) \times 100 - N]\%$ больше или равно 5%, то принятие решения о наличии очага вредителей деревьев первой категории и выдача сообщения «Очаг вредителей молодых деревьев по второму варианту»; переход на *Шаг 9.5.*

Шаг 9.5. $j = j + 1$, если $j \leq 3$, то на *Шаг 9.6*, иначе на *Конец.*

Шаг 9.6. Начало реализации первого варианта – подсчет в j -ом списке количества K_{j2} деревьев второго класса состояния здоровья (класс «Отмирающие»); переход на *Шаг 9.7.*

Шаг 9.7. Начало реализации второго варианта – подсчет в j -ом списке количества K_{j3} деревьев третьего класса состояния здоровья (класс «Свежий сухостой»); переход на *Шаг 9.8.*

Шаг 9.8. Если $[(K_{j2} / L_j) \times 100 - N]\%$ больше или равно 3%, то принятие решения о наличии очага вредителей деревьев второй категории и выдача сообщения «Очаг вредителей средневозрастных деревьев по первому варианту»; переход на *Шаг 9.9.*

Шаг 9.9. Если $[(K_{j3} / L_j) \times 100 - N]\%$ больше или равно 3%, то принятие решения о наличии очага вредителей деревьев второй категории и выдача сообщения «Очаг вредителей средневозрастных деревьев по второму варианту»; переход на *Шаг 9.10.*

Шаг 9.10. $j = j + 1$, если $j \leq 3$, то на *Шаг 9.11*, иначе на *Конец.*

Шаг 9.11. Начало реализации первого варианта – подсчет в j -ом списке количества K_{j2} деревьев второго класса состояния здоровья (класс «Отмирающие»); переход на *Шаг 9.12.*

Шаг 9.12. Начало реализации второго варианта - подсчет в j -ом списке количества K_{j3} деревьев третьего класса состояния здоровья (класс «Свежий сухостой»); переход на *Шаг 9.13.*

Шаг 9.13. Если $[(K_{j2} / L_j) \times 100 - N]\%$ больше или равно 2%, то принятие решения о наличии очага вредителей деревьев третьей категории и выдача сообщения «Очаг вредителей приспевающих, спелых и перестойных деревьев по первому варианту»; переход на *Шаг 9.14.*

Шаг 9.14. Если $[(K_{j3} / L_j) \times 100 - N]\%$ больше или равно 2%, то принятие решения о наличии очага вредителей деревьев третьей категории и выдача сообщения «Очаг вредителей приспевающих, спелых и перестойных деревьев по второму варианту»; переход на *Конец.*

Конец

На выходе алгоритма появляются сообщения – выводы о наличии очага размножения уссурийского полиграфа на исследуемом участке для каждой возрастной категории деревьев пихты.

Отметим, что разработанный метод дистанционного обнаружения очагов размножения уссурийского полиграфа по изображениям пихтовых лесов будет использоваться без проведения трудоёмких наземных измерений как это делается в других традиционных методах обнаружения таких очагов. Метод должен значительно ускорить процесс обнаружения и картографирования очагов. Для подтверждения этого тезиса будет проведено исследование эффективности предложенных метода и алгоритма.

2.5 Метод анализа динамики жизненных состояний хвойных деревьев в очагах размножения вредителей

Кроме задачи оперативного обнаружения очагов размножения вредителей хвойных лесов необходимо решать вторую задачу, также возникающую при лесопатологическом мониторинге хвойных лесов. Она сводится к проведению периодического и оперативного мониторинга выявленных очагов размножения вредителей с помощью специальных средств отслеживания динамики

(изменений) жизненных состояний (степени поражения) заселенных вредителями деревьев. Выявление деревьев на ранней стадии поражения вредителями и отслеживание динамики их жизненных состояний в очагах имеют важное значение для сохранения хвойных лесов, поскольку позволяют своевременно проводить эффективные санитарно-оздоровительные мероприятия. Особенно это важно для хвойных деревьев, находящихся в промежуточных жизненных состояниях. Например, для деревьев кедра, пораженных союзным короедом, особый интерес представляют промежуточные состояния деревьев, входящие в классы «Свежезаселенное», «С усохшей вершиной» и «Свежий сухостой». Все это указывает на то, что для решения второй лесопатологической задачи необходим метод отслеживания (анализа) динамики жизненных состояний хвойных деревьев в очагах поражения вредителями, который позволяет идентифицировать деревья в различных жизненных состояниях и отслеживать во времени переходы между классами состояний каждого хвойного дерева. Выполнение этих требований позволит обеспечить по результатам разновременного мониторинга изучаемого очага точный (до каждого интересующего дерева хвойной породы) анализ динамики жизненных состояний хвойных деревьев, входящих в контур этого очага.

При решении второй лесопатологической задачи в качестве исходных данных для разрабатываемого метода используются данные дистанционного мониторинга хвойных лесов в виде RGB-изображений высокого и сверхвысокого разрешения выявленных очагов размножения вредителей и результаты последующей мультиклассификации таких изображений в виде масок сегментации. Уточним условия, при которых должен использоваться разрабатываемый метод. Пусть имеем не менее двух изображений участка леса площадью 1 га с хвойными деревьями заданной породы, находящимися в очаге размножения вредителя. Желательно, чтобы эти изображения были получены при мониторинге участка в одно и то же время года и через одинаковый интервал времени, например, через год. При выборе исследуемой породы хвойных деревьев участка должно быть задано также число классов S их жизненного

состояния и перечень этих состояний, что важно при решении задачи мультиклассификации изображений. Мультиклассификация должна осуществляться с помощью наиболее эффективной из описанных в п.2.1 моделей полносверточных сетей или модели Segformer+ из п.2.2. Результаты мультиклассификации этих изображений в виде масок сегментации и являются входными данными для предлагаемого метода. Для повышения точности анализа динамики полученные маски сегментации обязательно должны подвергаться постобработке в виде фильтрации по минимальному размеру объектов для удаления после мультиклассификации мелких артефактов и шума и уточнения границ крон хвойных деревьев с использованием морфологических операций и алгоритма сглаживания [104,105]. Это позволит исключить незначимые детали и обеспечит чёткое разделение смежных крон деревьев, что, в итоге, значительно улучшит качество каждой маски.

Суть предлагаемого метода анализа динамики жизненного состояния хвойных деревьев заключается в интерпретации и сравнительном анализе масок сегментации разновременных изображений (полученных за не менее чем два разнесенных по времени сеанса мониторинга) пораженных вредителями деревьев, выполняемых в виде четырех ключевых этапов. На первом из них осуществляется идентификация кроны каждого хвойного дерева с определением следующих параметров: координат центроида (местоположение геометрического центра кроны на маске), площади кроны и уникального идентификатора. На втором этапе осуществляется сопоставление крон деревьев, идентифицированных на каждой из масок. Уникальный идентификатор позволяет однозначно идентифицировать и сопоставлять каждое дерево на двух масках, что затем обеспечивает точный мониторинг переходов между классами состояния отдельных деревьев. При этом центроиды крон используются для пространственного сопоставления крон деревьев между двумя масками. Возможны расхождения в положении центроидов крон, обусловленные несколькими факторами: различиями в GPS-координатах БПЛА при выполнении разных полетов (погрешность до 1–3 м) [109], а также изменениями формы и

площади крон, приводящими к смещению их геометрических центров. Поэтому сопоставление крон деревьев на масках разновременных изображений выполняется по центроидам, но с использованием метода KNN с параметром $k = 1$ (один из ближайших соседей). Данный подход обеспечивает более точное соответствие между кронами деревьев.

На третьем этапе метода ведется анализ переходов жизненных состояний каждого дерева, а на четвертом этапе по результатам третьего этапа формируется матрица переходов жизненных состояний всех хвойных деревьев интересующей нас породы на изучаемом участке площадью 1 га. Полученная матрица переходов жизненных состояний деревьев показывает изменения количества деревьев по классам жизненного состояния. В ней строки «Предыдущее состояние» показывают деревья по классам в исходных состояниях (на первой маске сегментации). Столбцы «Текущее состояние» показывают деревья по классам в конечных (текущих) состояниях (на второй маске сегментации). Значения в ячейках матрицы указывают на количество деревьев, перешедших из определенного класса исходного состояния в соответствующий класс конечного состояния. Значения по диагонали матрицы показывают, сколько деревьев из класса сохранили свое жизненное состояние. В матрицу введена строка «Вновь появившиеся деревья (Фон)», в которой показано количество деревьев, зафиксированных на второй маске, но они отсутствовали на первой маске (на этих местах первого изображения был Фон).

Предложенный метод позволяет, в первую очередь, выявить переходы (направления деградации) пораженных хвойных деревьев между различными жизненными состояниями в течение анализируемого промежутка времени между двумя сеансами мониторинга очага, отражая динамику (изменения) состояний каждого дерева. На основе этих данных выявляются деревья, изменившие жизненное состояние, и определяется количество деревьев в каждом классе состояния. Сравнение количества деревьев в классах между сеансами мониторинга дает возможность оценить направления деградации и масштаб изменений состояний деревьев в очаге за определенный промежуток времени.

В качестве модификации разработанного метода анализа динамики состояний хвойных деревьев в очаге размножения вредителей предлагается для оценки изменений жизненных состояний деревьев проводить анализ динамики площадей их крон. Поскольку результаты мультиклассификации разновременных изображений в виде масок сегментации содержат информацию о контурах крон отдельных деревьев, а исходные изображения имеют известное пространственное разрешение, то появляется возможность расчета площади кроны каждого дерева в пикселях, а с учетом масштаба изображения – и в квадратных метрах. Затем определяется суммарная площадь, занимаемая хвойными деревьями каждого класса на маске сегментации. Сравнение изменений площадей, занятых различными классами деревьев на двух масках, позволяет количественно оценить динамику жизненных состояний хвойных деревьев в очаге поражения. Эта модификация разработанного метода обеспечивает построение матрицы переходов состояний деревьев на основе расчета площадей крон отдельных деревьев и площадей, занимаемых каждым классом деревьев. Можно считать, что модификация метода является самостоятельным методом или вспомогательным методом, поскольку позволяет дополнить результаты анализа динамики, проведенного разработанным методом на основе подсчета количества деревьев в разных жизненных состояниях, сведениями по динамике площадей, занимаемых кронами таких деревьев.

Приведем описание разработанного Алгоритма 1, реализующего предложенный метод анализа динамики жизненных состояний хвойных деревьев (по изменениям количества деревьев в классах состояний).

Начало Алгоритма 1

Шаг 1. Ввод результатов мультиклассификации разновременных изображений пораженных хвойных деревьев заданной породы (пусть это будет кедр) на участке площадью 1га, полученных в виде масок сегментации, прошедших постобработку. Для первого сеанса мониторинга такой результат – *Маска1*, а для второго сеанса – *Маска2*.

Шаг 2. Ввод параметров анализа: D_{\max} – максимальное расстояние в пикселях для сопоставления крон деревьев в разных сеансах.

Шаг 3. Цикл по номерам сеансов мониторинга $k = 1, 2$ (для масок сегментации *Маска1* и *Маска2*):

$k = 1$

Шаг 3.1. Поиск связных компонентов (крон деревьев) для каждого из классов кроме класса «Фон» в маске сегментации *Маска_к*.

Шаг 3.2. Присвоение каждой валидной кроне дерева уникального идентификатора ID и формирование списка крон для сеанса k (*Крона_к*).

Шаг 3.3. Для каждой кроны из списка *Крона_к* вычисление центроида (координат x, y) и определение класса состояния.

Шаг 3.4. $k = k + 1$. Если $k \leq 2$, то на **Шаг 3.1**, иначе на **Шаг 4**.

Шаг 4. Инициализация матрицы переходов M . Строки матрицы – классы состояний деревьев в первом сеансе [1, 2, 3, 4, 5, 999], столбцы – классы состояний – во втором сеансе [0, 1, 2, 3, 4, 5]. 0 – «Фон» (исчезновение дерева, т.е. переход в «Фон»), 999 - вновь появившееся дерево (т.е. дерево отсутствовало в первом сеансе, но присутствует во втором).

Шаг 5. Цикл по i -ой кроне из списка *Крона₁*, $i = 1, 2, \dots, L_1$ (L_1 – общее число крон в списке *Крона₁*):

$i = 1$

Шаг 5.1. Цикл по j -ой кроне из списка *Крона₂*, $j = 1, 2, \dots, L_2$ (L_2 – общее число крон в списке *Крона₂*):

$j = 1$

Шаг 5.1.1. Вычисление расстояний D_{ij} от центроида i -ой кроны в списке *Крона₁* до центроида j -ой кроны в списке *Крона₂*.

Шаг 5.1.2. $j = j + 1$. Если $j \leq L_2$, то на **Шаг 5.1**, иначе на **Шаг 5.2**

Шаг 5.2. По множеству расстояний D_{ij} определение минимального расстояния $D_{\min}(i)$ и соответствующей j -ой кроны из списка *Крона₂*.

Шаг 5.3. Если $D_{\min}(i) \leq D_{\max}$ и выбранная j -я крона из списка *Крона₂* ещё не сопоставлена, то:

- Определение перехода жизненного состояния i -ой кроны ($Класс_A \rightarrow Класс_B$): $Класс_{i-я\ крона} \rightarrow Класс_{j-я\ выбранная\ крона}$.
- Увеличение значения элемента матрицы $M_{Класс_A, Класс_B}$ на 1.
- Пометка j -ой выбранной кроны как сопоставленной.
- Переход на *Шаг 5.4*.

Иначе:

- Определение перехода i -ой кроны в «Фон» (исчезновение, $Класс_A \rightarrow 0$): $Класс_{i-ой\ кроны} \rightarrow 0$.
- Увеличение значения элемента матрицы $M_{(Класс_A, 0)}$ на 1.
- Переход на *Шаг 5.4*.

Шаг 5.4. $i = i + 1$. Если $i \leq L_1$, то на *Шаг 5.1*, иначе на *Шаг 6*.

Шаг 6. Цикл по j -ой кроне из списка $Крона_2, j = 1, 2, \dots, L_2$ (L_2 - общее число кроны в списке $Крона_2$):

$j = 1$

Шаг 6.1. Если j -я крона из списка $Крона_2$ не была помечена как сопоставленная в *Шаге 5*, то:

- Определение перехода ($999 \rightarrow Класс_B$): $999 \rightarrow Класс_{j-ой\ кроны}$.
- Увеличение значения элемента матрицы $M_{(999, Класс_B)}$ на 1.
- Переход на *Шаг 6.2*.

Иначе:

Переход на *Шаг 6.2*.

Шаг 6.2. $j = j + 1$. Если $j \leq L_2$, то на *Шаг 6.1*, иначе на *Шаг 7*.

Шаг 7. Вывод матрицы переходов M в виде таблицы, где строки «Предыдущее состояние» соответствуют классам состояний деревьев в первом сеансе, а столбцы «Текущее состояние» - классам состояния во втором сеансе, а значения в ячейках матрицы представляют количество деревьев, перешедших из соответствующего класса состояния в первом сеансе мониторинга (исходное состояние) в класс во втором сеансе (конечное состояние).

Конец Алгоритма 1

Для анализа динамики жизненных состояний деревьев путем оценки площади крон деревьев по классам, то есть для модификации метода также разработан соответствующий алгоритм.

Начало Алгоритма 2

Шаг 1. Ввод результатов мультиклассификации одновременных изображений пораженных хвойных деревьев заданной породы (пусть это будет кедр) на участке площадью 1га , полученных в виде масок сегментации. Для первого сеанса мониторинга результат – *Маска1*, а для второго сеанса – *Маска2*.

Шаг 2. Ввод параметров анализа: P – пространственное разрешение исходных изображений. Вычисление площади одного пикселя: $S_{\text{pix}} = P^2$ (площадь S_{pix} используется для перевода количества пикселей в площадь кроны в м^2).

Шаг 3. Цикл по номерам сеансов мониторинга $k = 1, 2$ (для масок сегментации *Маска1* и *Маска2*):

$k = 1$

Шаг 3.1. Поиск связных компонентов (крон деревьев) для каждого из классов кроме класса «Фон» в маске сегментации *Маска_к*.

Шаг 3.2. $k = k + 1$. Если $k \leq 2$, то на **Шаг 3.1**, иначе на **Шаг 4**.

Шаг 4. Инициализация матриц переходов по пикселям M^{pix} и по площади M^S . Строки матрицы - классы жизненных состояний деревьев в первом сеансе [0, 1, 2, 3, 4, 5], столбцы - классы жизненных состояний деревьев во втором сеансе [0, 1, 2, 3, 4, 5].

Шаг 5. Цикл по i -ому классу первого сеанса:

$i = 1$

Шаг 5.1. Формирование бинарной маски *Бмаска_и*, где $Бмаска_i(x, y) = 1$, если $Маска1(x, y) = i$, иначе $Бмаска_i(x, y) = 0$.

Шаг 5.2. Цикл по j -ому классу второго сеанса:

$j = 1$

Шаг 5.2.1. Формирование бинарной маски *Бмаска_ж*, где $Бмаска_j(x, y) = 1$, если $Маска2(x, y) = j$, иначе $Бмаска_j(x, y) = 0$.

Шаг 5.2.2. Вычисление числа пикселей перекрытия классов i и j между сеансами в бинарных масках: $N = \sum_{x,y} (\text{Бмаска}_i(x, y) \cap \text{Бмаска}_j(x, y))$.

Шаг 5.2.3. Если $N > 0$, то:

- Определение значения элемента матрицы: $M_{ij}^{\text{pix}} = N$.
- Определение значения элемента матрицы: $M_{ij}^S = N \times S_{\text{pix}}$.

Иначе:

- $M_{ij}^{\text{pix}} = 0$ и $M_{ij}^S = 0$.

Шаг 5.2.4. $j = j + 1$. Если $j \leq 5$, то на *Шаг 5.2.1*, иначе на *Шаг 5.2.5*.

Шаг 5.2.5. $i = i + 1$. Если $i \leq 5$, то на *Шаг 6.1*, иначе на *Шаг 7*.

Шаг 6. Вывод матрицы переходов M^{pix} в виде таблицы, где строки «Предыдущее состояние» соответствуют классам жизненных состояний деревьев в исходном состоянии (первый сеанс мониторинга), столбцы «Текущее состояние» - классам конечного состояния (второй сеанс), а значения в ячейках таблицы представляют количество пикселей, перешедших из соответствующего класса исходного состояния в класс конечного состояния.

Шаг 7. Вывод матрицы переходов M^S в виде таблицы, где строки «Предыдущее состояние» соответствуют классам жизненных состояний деревьев в исходном состоянии, столбцы «Текущее состояние» - классам конечного состояния, а значения в ячейках таблицы представляют площади крон деревьев по классам, перешедших из соответствующего класса исходного состояния в класс конечного состояния.

Конец Алгоритма 2

Нетрудно видеть, что разработанные метод и его модификация позволяют на основе первой или второй матрицы переходов не только выявлять направления деградации хвойных деревьев в очаге размножения вредителя, но и вычислять скорость переходов их жизненных состояний между классами состояний. По сути, скорость переходов жизненных состояний хвойных деревьев характеризует темп (интенсивность) изменения их состояний. Расчет скорости переходов состояний предлагается проводить следующим образом. Сначала вычисляется

доля переходов D_{ij} (обычно в процентах) как количество хвойных деревьев N_{ij} (или площади их крон, если используется матрица переходов на основе расчетов площадей крон деревьев), перешедших из одного класса i состояний в другой класс j , отнесенное к общему количеству деревьев N_i исходного класса i :

$$D_{ij} = \frac{N_{ij}}{N_i} \times 100, \quad (2.15)$$

Доля переходов D_{ij} в процентах показывает распределение количества деревьев исходного класса по всем возможным направлениям изменения их жизненных состояний. Этот показатель отражает структуру переходов по направлениям деградации за весь период наблюдения.

Далее вычисляется скорость переходов V_{ij} как среднегодовая скорость перехода хвойных деревьев между классами состояний в каждом из направлений изменений:

$$V_{ij} = \frac{D_{ij}}{T \times 100}, \quad (2.16)$$

где T – период наблюдения, лет.

Из выражения (2.16) следует, что скорость переходов характеризует интенсивность процесса деградации хвойных деревьев в пересчете на один год.

Иногда в лесной отрасли используют индекс деградации популяции – интегральный показатель скорости ухудшения состояния деревьев [110]:

$$I = \frac{\sum_{i < j} N_{ij}}{\sum_i N_i} \times \frac{1}{T} \times 100, \quad (2.17)$$

где суммирование ведется только по переходам состояний в сторону ухудшения состояний (от более здоровых деревьев к более поврежденным вредителем деревьев). Индекс деградации популяции в процентах является обобщенной характеристикой жизненных состояний всего древостоя и показывает общую скорость ухудшения жизненных состояний деревьев по всем направлениям деградации.

2.6 Подходы и модели для решения задачи оценки запасов фитомассы и потоков углерода при лесопатологическом мониторинге хвойных лесов

Известно, что наземные экосистемы, включая хвойные леса, являются очень крупными хранилищами и поглотителями углерода и оказывают важное влияние на климатическую систему Земли. С другой стороны, после окончания жизни деревьев углерод остается внутри на всех этапах их деструкции и, в итоге, при гниении деревьев выбрасывается в атмосферу [111,112]. Поэтому практически важной третьей задачей лесопатологического мониторинга хвойных лесов является выявление сухостойных деревьев и получение оценки их вклада в бюджет последующих выбросов углерода в атмосферу.

Рассмотрим подходы к решению этой задачи в случае сухостоя, который появляется в результате болезней хвойных деревьев при поражении их насекомыми-вредителями. Первый подход к решению задачи заключается в высокоточной идентификации (выявлении) на изображениях, полученных при лесопатологическом мониторинге исследуемого участка хвойного леса, двух классов сухостоя: свежего сухостоя (сухостой текущего года) и старого сухостоя (сухостой прошлых лет). Отметим, что оперативное и точное разделение деревьев на свежий и старый сухостой на изображениях хвойных лесов является далеко не тривиальной задачей. Как показано выше в п.1.4, это можно сделать путем решения задачи мультиклассификации изображений с той или иной точностью с помощью одной из разработанных и описанных в п.2.1 моделей СНС или с помощью модели Segformer+ из п.2.2. Более того, анализ полученных при мультиклассификации и прошедших постобработку масок сегментации позволит выявить пространственное распределение сухостоя (занимаемая площадь, одиночные или группы деревьев) и т.п.

Далее, опираясь на результаты мультиклассификации изображений обследуемого участка леса с сухостоем в виде масок сегментации, необходимо определить запасы древесной фитомассы и углерода в нем на этом участке. В

первую очередь это даст возможность оценить вклад гниющего старого сухостоя в выбросы углерода на таком участке леса, то есть оценить вклад в бюджет выбросов углерода в атмосферу региона. Иными словами, такой расчет позволит оценить негативное влияние старого сухостоя на окружающую среду через его вклад в так называемую «углеродную проблему» региона. Во-вторых, выявление объема фитомассы свежего сухостоя позволит сделать прогноз по выбросам углерода в атмосферу региона на последующие годы. В случае больших объемов предполагаемых выбросов следует принять меры по вырубке таких деревьев.

Оценку запасов живой и мертвой фитомассы и потоков углерода в лесных экосистемах обычно осуществляют с помощью весьма сложных математических и часто дополнительных имитационных моделей. Среди них наиболее известные модели CBM-CFS3 (используется Лесной службой Канады), FORCARB2 (применяется в Лесной службе США) и известные модели и системы моделирования EFIMOD + ROMUL, FORRUS-S и т.п., используемые в России [111,112]. В качестве входных данных для получения адекватных результатов с помощью этих моделей необходимо задать значения большого числа показателей (иногда говорят, параметров или характеристик) на разных уровнях моделирования: локальном (изучаемый участок леса или лесотаксационный выдел), региональном и национальном (на уровне отдельной страны). При выборе модели для решения рассматриваемой лесопатологической задачи будем ориентироваться на модели локального уровня моделирования и использовать следующий подход: число параметров модели должно быть минимально возможным и их несложно измерить или рассчитать на основе других (косвенных) измерений. Анализ большого числа моделей и систем моделирования показал, что модель, реализованная в системе FORRUS-S и первоначально ориентированная на проведение расчетов на локальном уровне, требует задания несколько меньшего числа параметров, чем другие модели для оценки запасов фитомассы и углерода в ней на локальном уровне. Основные из этих параметров: породный состав леса на участке, возраст деревьев, высота ствола и диаметр на уровне груди для каждого дерева и т.п. [112,113]. Поэтому

модель, реализованная в системе FORRUS-S, и была выбрана в нашем случае для решения третьей задачи лесопатологического мониторинга.

2.7 Основные результаты и выводы по разделу

В соответствии с целью и задачами диссертационной работы разрабатывались модели глубокого обучения для решения задач мультиклассификации изображений хвойных деревьев и методы решения основных задач лесопатологического мониторинга хвойных лесов. Ниже приведены полученные при этом основные результаты и сделанные выводы.

1. На основе классической модели полносверточной сети U-Net, хорошо себя зарекомендовавшей при решении задач семантической сегментации (попиксельной классификации) изображений, разработана ее модификация – модель Mo-U-Net.
2. Разработаны гибридная модель полносверточной нейронной сети At-Mo-U-Net, отличающаяся от известных аналогов интеграцией блоков внимания в модель Mo-U-Net, и модель полносверточной нейронной сети Res-Mo-U-Net, в которой стандартные сверточные слои модели Mo-U-Net заменены на остаточные блоки. Сделаны выводы об оригинальности этих моделей и необходимости комплексных исследований их эффективности.
3. Разработана модель-трансформер Segformer+, отличающаяся от базовой модели Segformer, в которой используются трансформеры в энкодере и многослойные перцептроны в декодере, введением механизма кросс-уровневого внимания и заменой этих перцептронов на пространственные блоки с управляющими элементами. Такие изменения должны позволить модели Segformer+ значительно улучшить точность мультиклассификации хвойных деревьев на изображениях. Для подтверждения этого вывода потребуются соответствующие комплексные исследования.
4. Предложен метод дистанционного обнаружения очагов размножения уссурийского полиграфа по изображениям пихтовых лесов без необходимости проведения трудоёмких наземных измерений как в других методах.

Разработан алгоритм принятия решения о наличии таких очагов, реализующий этот метод.

5. Разработаны метод и реализующий его алгоритм анализа динамики жизненных состояний хвойных деревьев в очагах размножения вредителей, основанные на построении матрицы переходов этих состояний по маскам сегментации, полученным при мультиклассификации одновременных изображений хвойных деревьев. Разработаны также модификация метода и реализующий ее алгоритм, обеспечивающие построение матрицы переходов состояний деревьев на основе расчета площадей крон деревьев. В отличие от существующих методов, эти методы позволяют выявлять направления деградации деревьев и скорость переходов между классами жизненных состояний деревьев.
6. Предложены подходы к решению лесопатологической задачи оценки вклада сухостойных хвойных деревьев в бюджет выбросов углерода на основе идентификации состояний деревьев классов «Свежий сухостой» и «Старый сухостой» и последующего расчета запасов древесной фитомассы. Для решения этой задачи рекомендовано использовать специализированные модели круговорота углерода в лесных экосистемах, адаптированные к условиям локальных участков. Анализ большого числа моделей показал, что для решения такой задачи в нашем случае предпочтение следует отдать модели, реализованной в системе FORRUS-S.

3 ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ ПРЕДЛОЖЕННЫХ МОДЕЛЕЙ НЕЙРОННЫХ СЕТЕЙ И МЕТОДОВ РЕШЕНИЯ ЗАДАЧ ЛЕСОПАТОЛОГИЧЕСКОГО МОНИТОРИНГА

3.1 Формирование наборов данных для проведения исследований

3.1.1 Исходные данные

Рассмотрим исходные данные, получаемые при мониторинге хвойных лесов с очагами размножения вредителей путем съемки лесных массивов с помощью КА или БПЛА. Эти изображения высокого и сверхвысокого разрешения далее используются нами при подготовке наборов данных (часто говорят датасетов от англ. datasets) для решения двух задач мультиклассификации хвойных деревьев, пораженных вредителями. Первая из этих задач решается в случае деревьев пихты *A. sibirica*, пораженных уссурийским полиграфом *P. proximus*, а вторая задача – в случае деревьев кедра *P. sibirica*, пораженных союзным короедом *I. amitinus*.

Мониторинг пихтовых лесов с очагами размножения уссурийского полиграфа *P. proximus* проводился вблизи поселка Парбиг, находящегося в Томской области. Для анализа жизненных состояний деревьев пихты *A. sibirica*, пораженных *P. proximus*, использовались пять панорам (рисунок 3.1), сформированных из изображений пихтарников вблизи этих поселков. Изображения с пространственным разрешением около 0,1 м были получены с помощью БПЛА DJI Phantom 3 Standart с установленной на нем фотокамерой, ведущей съемку в видимом диапазоне электромагнитного спектра (RGB) с высоты 365 и 388 м в период с 7 по 28 августа 2017 г. Проведение съемки сопровождалось наземными обследованиями и подтверждением наличия очагов размножения уссурийского полиграфа *P. proximus*. Размеры полученных панорам (в пикселях):

- А – 1046×1912×3
- Б – 1536×768×3
- В – 1536×1048×3

- Г – 1792×768×3
- Д – 1046×1912×3




Рисунок 3.1 – Панорамы деревьев *A. sibirica*, полученные при мониторинге пихтовых лесов с очагами размножения вредителей путем съемки с помощью БПЛА

Для проведения оперативного мониторинга поврежденных вредителем *P. proximus* деревьев пихты *A. sibirica* в Институте мониторинга климатических и экологических систем (ИМКЭС) СО РАН разработана оценочная шкала их жизненного состояния (состояния здоровья) и методика применения этой шкалы [114]. В силу того, что при визуальной разметке (дешифровании) панорам экспертам часто не удавалось отделить некоторые жизненные состояния деревьев друг от друга, методика была модифицирована путем объединения близких состояний деревьев в один класс. В результате в методике описаны следующие четыре класса жизненных состояний деревьев *A. sibirica*:

- 1 класс – «Живые» (здоровое, без признаков ослабления): крона густая, протяженная, хвоя зеленая, блестящая.
- 2 класс – «Отмирающие» (сильно ослабленные, усыхающие): крона может быть как у здорового дерева или изреженная, флагообразная, несколько ветвей (до 10) могут нести на концах хвою ярко-рыжего цвета; могут быть признаки ржавчинного рака пихты (ведьмины метлы, наросты на ветвях); хвоя в верхней части кроны еще зеленая, ниже – ярко-рыжего цвета.
- 3 класс – «Свежий сухостой» (дерево в процессе отработки стволовыми насекомыми): хвоя в кроне полностью мертвая, красная.
- 4 класс – «Старый сухостой» (дерево полностью отработано стволовыми насекомыми): крона мертвая, серая, хвоя осыпалась; в зависимости от года усыхания дерева осыпаются ветки разного порядка.

Пятым классом на изображениях является «Фон» – деревья других пород и иные объекты земной поверхности. На рисунке 3.2 приведен пример фрагментов изображения с кронами деревьев перечисленных классов жизненного состояния.




Рисунок 3.2 – Примеры крон деревьев *A. sibirica* классов: (а) Живые; (б) Отмирающие; (в) Свежий сухостой; (г) Старый сухостой

Остановимся на особенностях исходных данных для решения второй задачи мультиклассификации изображений, пораженных союзным короедом *I. amitinus* деревьев кедра *P. sibirica*. RGB-изображения крон деревьев кедра были получены вблизи поселков Белоусово, Протопопово и Аксеново, находящихся в Томской области с помощью фотокамеры, установленной на БПЛА DJI Phantom 4 Pro. Далее изображения были собраны в панорамы, а затем из них получены четыре ортофотоплана. Изображения для первого из них были сделаны с БПЛА 11 июля 2019 г., а для второго, третьего и четвертого ортофотопланов сделаны 23 июля 2019 г. с высоты 350м, что обеспечило их пространственное разрешение около 0,1 м. Ортофотопланы обозначены, соответственно, А, Б, В и Г (рисунок 3.3). Их размеры (в пикселях):

- А – 5849×4515×3
- Б – 2454×4249×3
- В – 1863×3500×3
- Г – 1684×2951×3




Рисунок 3.3 – Ортофотопланы деревьев *P. sibirica*, полученные при мониторинге кедровых лесов с очагами размножения союзного короеда с помощью БПЛА

При визуальном анализе крон пораженных деревьев кедра на ортофотопланах экспертами по методике из работы [43] выделяется пять классов их жизненного состояния (степени поражения союзным короедом). Среди этих классов следующие:

- 1 класс – «Условно здоровое»: имеет темно-зеленую крону без признаков дехромации или пожелтения.
- 2 класс – «Свежезаселенное»: крона зеленая, но вершинные ветви начинают приобретать бледный зелено-желтый оттенок; на этом этапе летом жуки под корой завершают свое развитие; в весенний период и позднеосенний период жуки находятся в подстилке и частично в ветвях.
- 3 класс – «С усохшей вершиной»: верхушка имеет выраженный желто-бурый оттенок, нижняя часть кроны темно- или бледно-зеленая; ствол этих деревьев может осваиваться также сопутствующими видами вредителей, например, в позднеосенний - ранневесенний периоды в подстилке под проекцией кроны зимующими имаго.




Рисунок 3.4 – Примеры крон деревьев *P. sibirica* классов: (а) Условно здоровое; (б) Свежезаселенное; (в) С усохшей вершиной; (г) Свежий сухостой; (д) Старый сухостой

- 4 класс – «Свежий сухостой»: вся крона буро-рыжего цвета, а макушка дерева может нести ветви без хвои; дерево покинуто вредителем *I. amitinus*.
- 5 класс – «Старый сухостой»: крона не несет хвои или имеются остатки недосыпавшейся серой или рыже-бурой хвои на самых нижних ветках, вредитель *I. amitinus* покинул дерево в предыдущем вегетационном сезоне.

Шестым классом на изображениях является «Фон» – деревья других пород и иные объекты земной поверхности. На рисунке 3.4 представлены кроны деревьев кедра *P. sibirica* перечисленных классов жизненных состояний.

Отметим, что число жизненных состояний (классов) пораженных вредителями деревьев *A. sibirica* и *P. sibirica* различно, поскольку обе породы деревьев имеют значительные отличия по форме крон и физиологии. Такие отличия в сумме со специфической специализацией двух вредителей, соответственно, *P. proximus* и *I. amitinus* приводят к различному протеканию в деревьях патофизиологических изменений, дающих разные характерные визуальные признаки крон деревьев при различной степени поражения вредителями.

3.1.2 Формирование наборов данных для решения задачи мультиклассификации изображений пораженных деревьев пихты

Рассмотрим формирование наборов данных (датасетов) для обучения, валидации и исследования эффективности (тестирования) разработанных и описанных в п.п.2.1 и 2.2 моделей полносверточных сетей и модели Segformer+, применяемых для решения первой задачи мультиклассификации изображений деревьев пихты. Исходные данные для этого в виде пяти панорам приведены в п.3.1.1. Кроны деревьев пихты на панорамах были размечены экспертами с учетом класса жизненного состояния деревьев (степени их повреждения вредителем). Пример такой разметки крон деревьев пихты в соответствии с методикой [114] деления их по классам на фрагменте одной из панорам приведен на рисунке 3.5а, классы отмечены цифрами. Далее в соответствии с первичной

разметкой эксперта на панорамах другой эксперт проводил оконтуривание крон деревьев. В итоге были выделены эталонные сегменты (полигоны), представляющие кроны деревьев *A. sibirica* четырех классов и «Фон». Пример эталонной карты сегментации (маски сегментации), соответствующей размеченному по классам деревьев фрагменту панорамы на рисунке 3.5а, приведен на рисунке 3.5б.

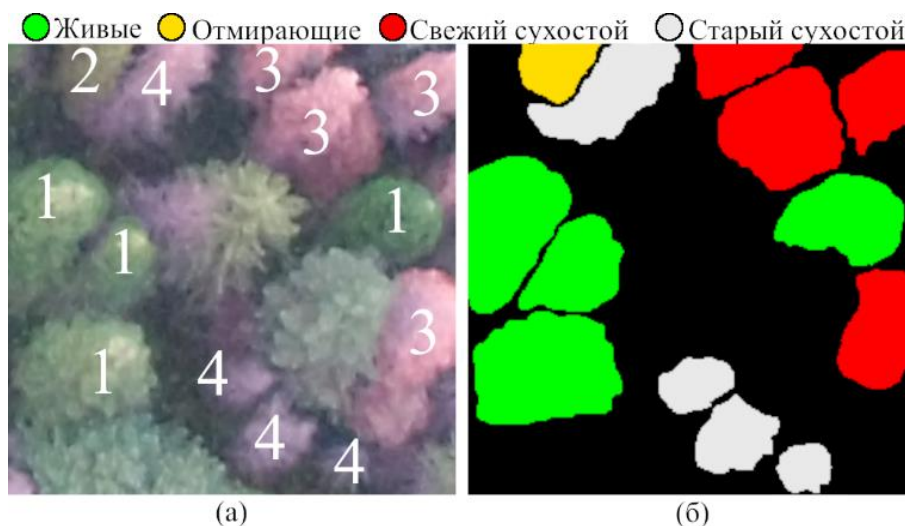


Рисунок 3.5 – Фрагмент панорамы деревьев *A. sibirica*: (а) размеченный по классам деревьев и (б) соответствующая фрагменту маска сегментации

На одной из панорам был выбран тестовый участок. Он не участвовал в обучении и валидации моделей нейронных сетей, а использовался в исследованиях их эффективности. По размеченным экспертами панорамам и соответствующим им эталонным картам сегментации были сформированы обучающая, валидационная и тестовая выборки, составляющие первый набор данных (первый датасет) для решения первой задачи мультиклассификации. При формировании обучающей и валидационной выборок, панорамы и эталонные карты сегментации были нарезаны на фрагменты размером $256 \times 256 \times 3$ пикселей со сдвигом в 128 пикселей при получении последующего фрагмента. Утечка данных из валидационной выборки устранялась путем наложения булевых масок (двумерных массивов, элементы которых принимают значения «ложь» или «истина») на исходные панорамы и блокирования возможности попадания соответствующих пикселей в обучающую выборку. Именно так гарантировалось,

что признаки крон деревьев на валидационных фрагментах не дублировались среди признаков обучающих фрагментов. Всего было получено 2004 обучающих и 672 валидационных фрагмента. Тестовая выборка, созданная по тестовому участку, составила 96 фрагментов размером $256 \times 256 \times 3$ пикселей. Аналогичным образом был создан второй набор данных (датасет) на основе этих экспертно-интерпретированных (дешифрованных) панорам и полученных при этом соответствующих масок сегментации. Панорамы и маски в этом наборе данных были нарезаны на фрагменты размером $480 \times 480 \times 3$ пикселей со сдвигом в 240 пикселей. Всего было получено 502 обучающих фрагмента, 180 валидационных фрагментов и 24 тестовых фрагмента по тестовому участку.

3.1.3 Формирование наборов данных для решения задачи мультиклассификации изображений пораженных деревьев кедр

Рассмотрим создание наборов данных (датасетов), применяемых при решении задачи мультиклассификации изображений, пораженных союзным короедом *I. amitinus* деревьев кедр *P. sibirica*. Исходные данные для этой второй задачи в виде четырех ортофотопланов описаны в п.3.1.1. Сначала перед экспертами, ведущими дешифрование ортофотопланов, ставилась задача оценки по ним жизненного состояния деревьев *P. sibirica*, имеющих разную степень повреждения союзным короедом *I. amitinus*, соответствующую одному из пяти перечисленных в п.3.1.1 классов. Шестым классом являлся «Фон». Каждое из деревьев на ортофотоплане путем визуального дешифрования относилось к одному из классов экспертом (рисунок 3.6а), участвовавшим также в наземном обследовании этих участков леса. Затем второй эксперт производил проверку результатов разметки изображений первым экспертом и осуществлял оконтуривание крон деревьев на размеченных ортофотопланах. Итоговым результатом такого дешифрования стали эталонные карты сегментации (маски сегментации). Пример такой маски для фрагмента ортофотоплана показан на рисунке 3.6б.

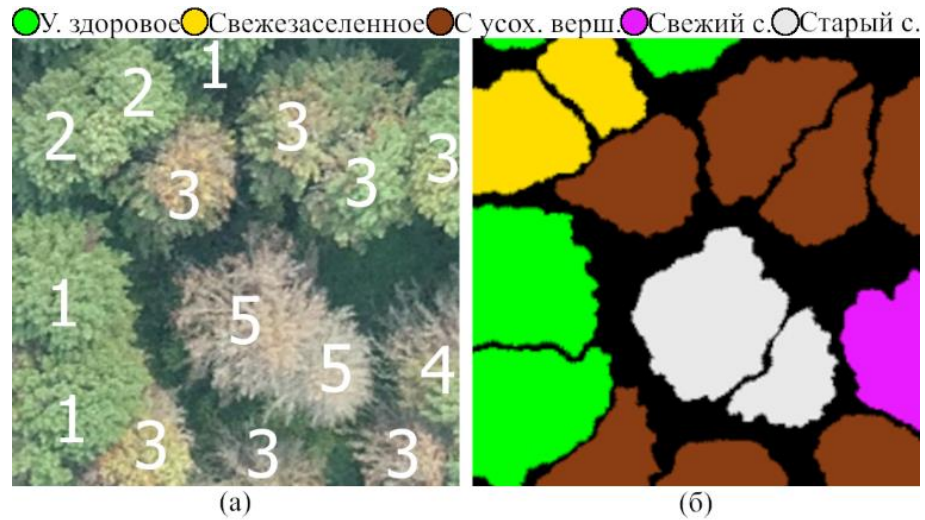


Рисунок 3.6 – Фрагмент ортофотоплана деревьев *P. sibirica*: (а) размеченного по классам и (б) соответствующая фрагменту маска сегментации

Затем четыре ортофотоплана и соответствующие им маски сегментации (эталонные карты сегментации) использовались для формирования третьего и четвертого наборов данных (датасетов). Нарезка ортофотопланов и карт сегментации, как и в случае панорам деревьев *A. sibirica*, осуществлялась на фрагменты размером $256 \times 256 \times 3$ пикселей со сдвигом в 128 пикселей при получении последующего фрагмента. Для формирования обучающей и валидационной выборок использовались ортофотопланы А, Б и В и соответствующие им эталонные карты сегментации. Четвертый ортофотоплан Г (рисунок 3.3) и его эталонная карта сегментации применялись для подготовки тестовой выборки путем нарезки их на фрагменты размером $256 \times 256 \times 3$ пикселей. Утечка данных из валидационной выборки устранялась, как и в случае подготовки валидационных выборок первого и второго датасетов, использованием булевых масок. Всего было получено 10455 обучающих и 2880 валидационных фрагментов. Объем тестовой выборки составил 84 фрагмента. Аналогичным образом был создан четвертый датасет по ортофотопланам деревьев *P. sibirica* и по соответствующим им маскам сегментации. Фрагменты и маски для обучающей и валидационной выборок в этом датасете имеют размер $480 \times 480 \times 3$ пикселей и были нарезаны со сдвигом в 240 пикселей при получении последующего фрагмента. Всего для четвертого датасета было получено 1842 обучающих фрагмента, 224 валидационных фрагмента и 46 тестовых фрагментов.

3.2 Разведочный анализ обучающих выборок

3.2.1 Разведочный анализ обучающих выборок для мультиклассификации изображений деревьев пихты

Сначала был проведен разведочный анализ исходных изображений: определено количество деревьев *A. sibirica* каждого класса в выборках первого и второго датасетов. Отметим, что поскольку для формирования этих датасетов с фрагментами $256 \times 256 \times 3$ и $480 \times 480 \times 3$ пикселей использовались одни и те же исходные изображения деревьев *A. sibirica*, то оба датасета имеют близкое количество деревьев в обучающих, валидационных и тестовых выборках.

В таблице 3.1 приведены результаты такого анализа для первого датасета. Из нее следует, что наблюдается значительная несбалансированность количества деревьев по классам: наименее представленными в датасетах оказались деревья промежуточных классов «Отмирающее» и «Свежий сухостой». Такой дисбаланс в количестве деревьев по классам, особенно в обучающих выборках, может отрицательно сказаться на точности классификации пораженных деревьев пихты.

Таблица 3.1 – Количество деревьев пихты *A. sibirica* по классам в выборках первого датасета

Выборка	Живое	Отмирающее	Свежий сухостой	Старый сухостой
Обучающая	319	44	147	290
Валидационная	107	14	63	110
Тестовая	148	22	64	91
Итого	574	80	274	491

Затем для оценки разделимости крон деревьев *A. sibirica* по классам в обучающих выборках был проведен анализ UMAP-вложений (англ. Uniform Manifold Approximation and Projection – UMAP) и коэффициентов силуэта (англ. Silhouette Coefficient). Для этого были рассмотрены спектральные характеристики сегментов, ограничивающих кроны. В качестве признаков сегментов использовались гистограммы яркостей в RGB каналах изображений: для каждого из трех каналов была построена гистограмма яркостей с 15 интервалами разбиения, поэтому вектор признаков для каждого сегмента представлял собой упорядоченный набор из 45 чисел.

Идея метода UMAP заключается в поиске такого представления данных в пространстве меньшей размерности, чтобы топологическая структура искомого представления была схожа с исходной. При построении UMAP-вложений для гистограмм яркостей сегментов в случае первой обучающей выборки (рисунок 3.7а и рисунок 3.7б) варьировались два параметра алгоритма: количество ближайших соседей в топологической структуре исходных данных (n_n) и минимальное расстояние между точками в результирующем представлении меньшей размерности (min_dist). Коэффициенты силуэта позволяют оценивать разделимость классов, основываясь на вычислении относительных расстояний между векторами признаков. Близкие к единице значения коэффициента указывают на хорошо отделенные от ближайшего соседнего класса экземпляры, отрицательные – на наиболее вероятно относящиеся к ближайшему соседнему классу, близкие к нулю – на близость экземпляра к границе принятия решения. Внутри каждого класса экземпляры сортируются по значению коэффициента силуэта и наносятся на диаграмму силуэтов, где вдоль вертикальной оси отображаются классы, а вдоль горизонтальной – значения коэффициентов силуэта для сегментов.

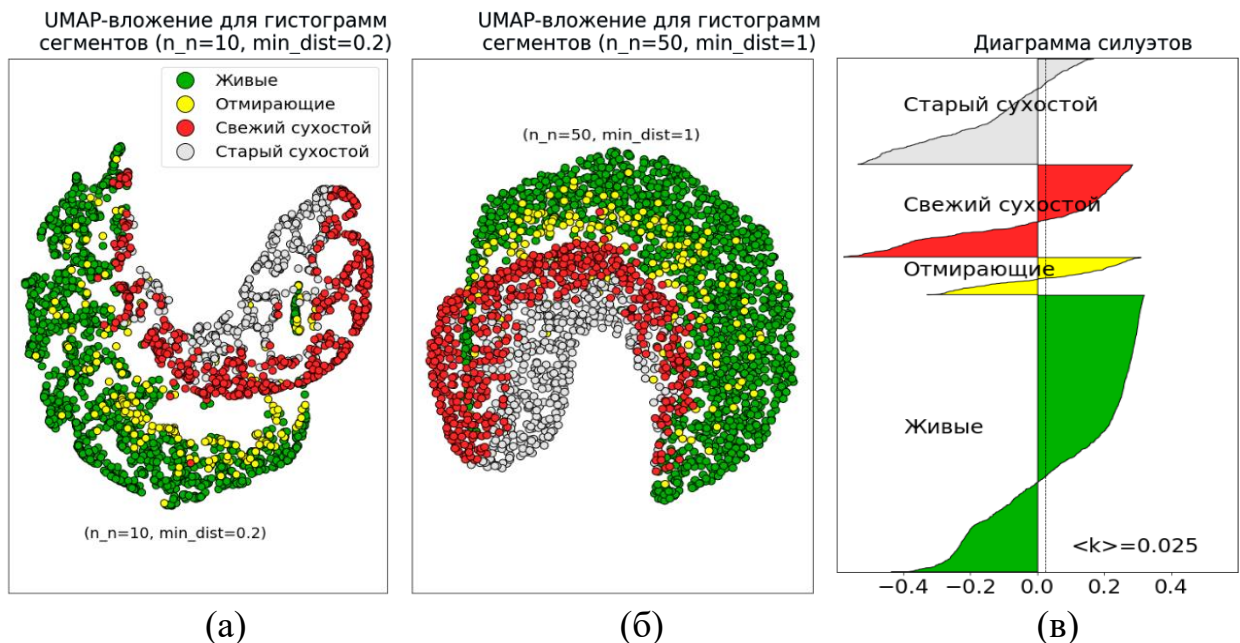


Рисунок 3.7 – UMAP-вложения для гистограмм яркостей (а и б) и диаграмма силуэтов для гистограмм яркостей (в) сегментов деревьев *A. sibirica*, пунктирной линией показано среднее значение коэффициента силуэта

Анализируя локальные особенности распределения гистограмм яркости (рисунок 3.7а), можно сказать о наличии двух крупных кластеров, один из которых состоит преимущественно из точек, относящихся к классам «Живые» и «Отмирающие», а другой – из точек классов «Свежий сухостой» и «Старый сухостой», при этом сложно построить границы решений для разделения классов уже внутри этих кластеров. На рисунке 3.7б, показывающем глобальные особенности распределения, наблюдается переход между классами в порядке улучшения состояния деревьев *A. sibirica*. Анализ диаграммы силуэтов (рисунок 3.7в) позволяет сделать вывод о низкой разделимости классов деревьев в первой обучающей выборке в общем, так как среднее значение коэффициента силуэта составило 0,025. Значительной доле сегментов классов «Отмирающие», «Свежий сухостой» и «Старый сухостой» соответствуют отрицательные значения коэффициентов силуэта. Отметим, что близкие результаты анализа UMAP-вложений и значений коэффициента силуэта получены в случае второй обучающей выборки. Это позволило сделать аналогичный вывод о низкой разделимости классов жизненных состояний деревьев во второй обучающей выборке.

3.2.2 Разведочный анализ обучающих выборок для мультиклассификации изображений деревьев кедра

Также был проведен разведочный анализ исходных изображений деревьев *P. sibirica*. В таблице 3.2 приведены его результаты, показывающие количество деревьев различных классов жизненного состояния в выборках третьего датасета. Важно отметить, что поскольку для формирования третьего и четвертого датасетов, соответственно, с фрагментами $256 \times 256 \times 3$ и $480 \times 480 \times 3$ пикселей использовались одни и те же исходные изображения деревьев *P. sibirica*, то оба датасета имеют примерно одинаковое количество деревьев в обучающих, валидационных и тестовых выборках.

Из таблицы 3.2 следует, что имеет место, как и в случае датасетов для мультиклассификации изображений деревьев *A. sibirica*, следующая проблема: слабая представленность промежуточных классов деревьев кедра, в данном случае клас-

сов «Свежезаселенное» и «Свежий сухостой». Такой дисбаланс по классам, особенно в обучающих выборках, может отрицательно сказаться на точности классификации изображений деревьев кедр *P. sibirica* этих классов.

Таблица 3.2 – Количество деревьев кедр *P. sibirica* по классам в выборках третьего датасета

Выборка	Условно здоровое	Свежезаселенное	С усохшей вершиной	Свежий сухостой	Старый сухостой
Обучающая	659	320	424	197	641
Валидационная	283	120	100	60	181
Тестовая	205	48	63	74	123
Итого	1147	488	587	331	945

Далее для оценки разделимости крон деревьев *P. sibirica* по классам в обучающих выборках был проведен анализ UMAP-вложений и коэффициентов силуэта.

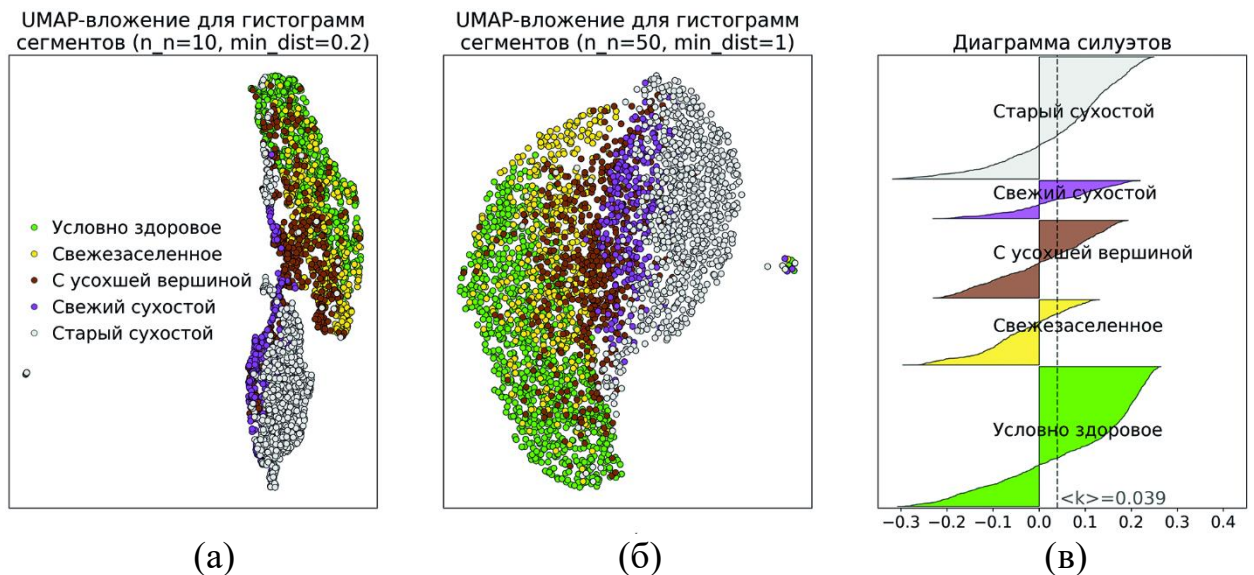


Рисунок 3.8 – UMAP-вложения для гистограмм яркостей (а и б) и диаграмма силуэтов для гистограмм яркостей (в) сегментов деревьев *P. sibirica*, пунктирной линией показано среднее значение коэффициента силуэта

Анализ локальных особенностей UMAP-вложений (рисунок 3.8а) в обучающей выборке третьего датасета показал наличие двух различных кластеров: один преимущественно содержит сегменты крон деревьев классов «Условно здоровое» и «Свежезаселённое», другой – классов «Свежий сухостой» и «Старый сухостой». При этом сегменты класса «С усохшей вершиной» расположились в пространстве между выделенными кластерами. На UMAP-вложении, показывающем глобальные особенности (рисунок 3.8б), можно видеть непрерывный пе-

реход между классами деревьев в порядке ухудшения их жизненного состояния. Сегментам соответствует низкое среднее значение коэффициента силуэта, показанное на рисунке 3.8в пунктиром и равное 0,039. При этом из рисунка 3.8в следует, что существенные доли отрицательных значений коэффициента наблюдаются для классов «Свежезаселённое» и «С усохшей вершиной». Близкие результаты анализа UMAP–вложений и значений коэффициента силуэта получены в случае обучающей выборки четвертого датасета. Это позволило сделать вывод о низкой разделимости классов деревьев *P. sibirica* в обучающих выборках третьего и четвертого датасетов.

Таким образом, с учетом этого вывода о низкой разделимости классов жизненных состояний деревьев *P. sibirica*, а также выводов о низкой разделимости классов деревьев *A. sibirica* из п.3.2.1, разведочный анализ обучающих выборок показал, что поставленная задача мультиклассификации изображений пораженных вредителями деревьев *A. sibirica* и *P. sibirica* не является тривиальной, поскольку учет только цветовых характеристик пикселей, составляющих сегменты, не позволяет достичь высокой разделимости классов таких хвойных деревьев. Все эти результаты разведочного анализа указывают на необходимость использования весьма сложных моделей СНС или трансформеров, поскольку именно такие нейронные сети способны учитывать кроме спектральных характеристик также текстуры крон и их формы и автоматически извлекать соответствующие признаки крон деревьев на изображениях.

3.3 Обучение и валидация разработанных моделей нейронных сетей

Предложенные и описанные в разделе 2. модели полносверточных сетей и модель Segformer+ программно реализованы на языке Python 3 с использованием фреймворка PyTorch [115].

Качество обучения и валидации предложенных моделей полносверточных сетей и модели Segformer+ для решения задач семантической сегментации (попиксельной мультиклассификации) изображений деревьев *A. sibirica* и *P. sibirica* оценивалось по метрикам *IoUc* и *mIoU*, описанным в п.1.6. Значения метрик *IoUc*

и $mIoU$, превышающие 0,5, соответствуют высокой точности мультиклассификации деревьев на изображениях и указывают на то, что модели, обеспечивающие такую точность при обучении и валидации, готовы для дальнейшего использования (тестирования, исследования).

Обучение и валидация этих моделей выполнялись в два этапа с использованием датасетов с фрагментами различных размеров. На первом этапе они проводились с помощью обучающих и валидационных выборок первого датасета (изображения деревьев пихты) и третьего датасета (изображения деревьев кедра) с фрагментами изображений размером $256 \times 256 \times 3$ пикселей. На втором этапе для обучения и валидации моделей использовались соответствующие выборки второго датасета (изображения деревьев пихты) и четвертого датасета (изображения деревьев кедра) с фрагментами изображений размером $480 \times 480 \times 3$ пикселей. После завершения первого этапа его результаты использовались на втором этапе, при этом был применен метод трансферного обучения для тонкой настройки моделей на обучающих и валидационных выборках второго и четвертого датасетов. На практике это означало, что веса модели, предварительно обученной на фрагментах размером $256 \times 256 \times 3$ пикселей для выбранной породы деревьев (пихты или кедра), загружались в модель, которая была для этой породы деревьев адаптирована под больший размер входного фрагмента – $480 \times 480 \times 3$ пикселей. Последующее дообучение таких моделей на втором этапе на фрагментах размером $480 \times 480 \times 3$ пикселей позволило моделям, уже обладающим основными «знаниями» о кронах хвойных деревьев, полученными на первом этапе, этапе, учитывать более тонкие детали (признаки) крон и точнее определять границы сегментируемых крон. Это должно способствовать повышению точности классификации хвойных деревьев на изображениях. Более того, результаты первого этапа позволили значительно снизить вычислительные затраты и, в итоге, ускорить процесс обучения моделей на втором этапе.

В целях улучшения обобщающей способности каждой из обучаемых моделей использовалась техника аугментации «на лету» (англ. online augmentation), позволяющая расширить обучающую выборку синтезированными примерами

непосредственно во время обучения [116]. Аугментация «на лету» в нашем случае включала выполняемые случайным образом следующие преобразования фрагментов: изменения масштаба изображений, их яркости и изменения их контраста, а также отражения по вертикальной оси и эластические преобразования.

Поиск при обучении и валидации оптимальных весовых коэффициентов каждой из предложенных моделей сетей осуществлялся для известной функции потерь Focal Loss [117]:

$$FL(p) = -\alpha(1 - p)^\gamma \log(p), \quad (3.1)$$

где p – вероятность, предсказанная моделью для правильного класса; α – коэффициент балансировки классов (вес класса); γ – параметр фокусировки, который уменьшает вклад легко классифицируемых примеров в общую функцию потерь.

Функция Focal Loss является модификацией стандартной функции перекрестной энтропии, разработанной для решения проблемы дисбаланса классов в задачах мультиклассификации объектов. Эта функция потерь эффективна в случаях, когда требуется распознавать классы объектов с незначительными различиями в признаках. Основным механизмом действия функции Focal Loss основан на введении модулирующего коэффициента $(1 - p)^\gamma$, который уменьшает вклад в общую функцию потерь для объектов, классифицируемых с высокой степенью уверенности. Это позволяет модели сконцентрировать внимание на сложных для классификации объектах, к которым относятся в нашем случае пораженные деревья в промежуточных состояниях.

Минимизация функции потерь Focal Loss проводилась с использованием алгоритма оптимизации Adam [118]. Для определения оптимальных гиперпараметров всех моделей использовался расширенный метод байесовской оптимизации. В рамках этого процесса оптимизации каждая модель обучалась суммарно 100 раз, что позволяло целенаправленно и эффективно исследовать пространство гиперпараметров. В их число, помимо стандартных (таких как, например, скорость обучения), входили параметры аугментации данных. Кроме того, отдельно оптимизировались параметры α и γ функции потерь Focal Loss. Для предотвра-

щения переобучения в процессе оптимизации был задействован механизм ранней остановки (англ. *early stopping*), который отслеживал эффективность модели на валидационной выборке и останавливал обучение, когда улучшение метрики *mIoU* прекращалось. В итоге для каждой предложенной модели были определены такие значения весовых коэффициентов и гиперпараметров, при которых метрики качества семантической сегментации, рассчитанные на валидационной выборке каждого датасета, достигли своих наивысших значений.

Отметим, что наряду с обучением и валидацией разработанных моделей нами на обучающих и валидационных выборках этих же датасетов проведено обучение классической модели U-Net, описанной в [71]. Это необходимо для проведения сравнения эффективности по точности классификации и скорости вычислений разработанных моделей с этой классической моделью.

Таблица 3.3 – Качество семантической сегментации изображения деревьев *A. sibirica*, полученное с помощью моделей на валидационной выборке с фрагментами размером $256 \times 256 \times 3$ пикселей

Модель	<i>IoUc</i>					<i>mIoU</i>
	Фон	Живое	Отмирающее	Свежий сухостой	Старый сухостой	
Segformer+	0,90	0,77	0,59	0,82	0,73	0,76
U-Net	0,87	0,74	0,45	0,79	0,69	0,71
Mo-U-Net	0,87	0,76	0,53	0,76	0,67	0,72
At-Mo-U-Net	0,88	0,76	0,52	0,80	0,68	0,73
Res-Mo-U-Net	0,87	0,75	0,54	0,75	0,67	0,72

В таблице 3.3 в качестве примера приведены результаты обучения и валидации разработанных моделей по точности мультиклассификации в случае деревьев *A. sibirica* на валидационной выборке из первого датасета. Сюда включены также полученные нами на этих же выборках результаты обучения и валидации классической модели U-Net, описанной в [71] и в Приложении А. Это было сделано с целью проведения сравнительного анализа с результатами, полученными для предложенных моделей. Видим, что значения метрик *IoUc* и *mIoU* превышают пороговое значение 0,5, кроме случая деревьев, находящихся в промежуточном состоянии «Отмирающее» при использовании модели U-Net.

Подобные результаты обучения и валидации разработанных моделей и модели U-Net получены при использовании обучающих и валидационных выборок из трех других датасетов.

3.4 Результаты исследований моделей нейронных сетей при решении задачи мультиклассификации изображений пораженных деревьев пихты

Важной задачей диссертационного исследования является задача проведения комплексных исследований предложенных и обученных моделей нейронных сетей по точности классификации (по качеству семантической сегментации) изображений пораженных вредителями хвойных деревьев и по скорости вычислений этих моделей. Сначала рассмотрим особенности исследований и полученные при этом результаты изучения эффективности обученных моделей по точности классификации изображений.

При проведении исследований (тестировании) обученных моделей нейронных сетей по точности классификации изображений пораженных деревьев пихты *A. sibirica* использовались тестовые выборки из первого и второго датасетов. Точность попиксельной классификации изображений деревьев *A. sibirica* оценивалась по метрикам *IoUc* и *mIoU*, описанным в п.1.6. Значения этих метрик, превышающие 0,5, соответствуют высокой точности мультиклассификации деревьев на изображениях.

На рисунке 3.9 приведены результаты исследования обученных моделей при решении задачи мультиклассификации пораженных деревьев пихты *A. sibirica* в случае использования тестовой выборки с фрагментами размером $256 \times 256 \times 3$ пикселей из первого датасета. Совместный визуальный анализ изображения тестового участка (рисунок 3.9а), его эталонной маски сегментации (рисунок 3.9б), полученной при дешифровании изображения этого участка экспертами, и результирующих выходных карт сегментации при использовании каждой из моделей (рисунок 3.9в,г,д,е) показал, что эти модели способны воспро-

изводить границы крон деревьев пихты и правильно классифицировать значительную долю крон деревьев.




Рисунок 3.9 – Результаты семантической сегментации изображения тестового участка *A. sibirica* с использованием фрагментов размером $256 \times 256 \times 3$ пикселей:

(а) Изображение тестового участка; (б) Эталонная карта сегментации; (в) Модель Segformer+; (г) Модель Mo-U-Net; (д) Модель At-Mo-U Net; (е) Модель Res-Mo-U-Net




Рисунок 3.10 – Результаты семантической сегментации изображения тестового участка *A. sibirica* с использованием фрагментов размером $480 \times 480 \times 3$ пикселей: (а) Изображение тестового участка; (б) Эталонная карта сегментации; (в) Модель Segformer+; (г) Модель Mo-U-Net; (д) Модель At-Mo-U Net; (е) Модель Res-Mo-U-Net

Аналогичные результаты исследований обученных моделей получены при использовании тестовой выборки с фрагментами размером $480 \times 480 \times 3$ пикселей

из второго датасета (рисунок 3.10). Совместный визуальный анализ результатов мультиклассификации этого изображения экспертами и моделями нейронных сетей позволил сделать тот же вывод о способности моделей воспроизводить границы крон деревьев пихты и правильно классифицировать значительную долю этих крон. Более того, сравнительный визуальный анализ результатов на рисунках 3.9 и 3.10 показал, что в случае тестовой выборки из второго датасета модели дают для отдельных областей изображения более хорошие результаты, чем в случае выборки из первого датасета.

В таблице 3.4 приведены количественные результаты исследований разработанных и обученных моделей по точности классификации в виде значений метрики $IoUc$ для каждого класса c деревьев *A. sibirica* и значений интегрированной метрики $mIoU$ в случае тестовой выборки из первого датасета с фрагментами размером $256 \times 256 \times 3$ пикселей. Сравнивая результаты семантической сегментации изображений в таблице 3.3 с результатами в таблице 3.4, видим, что в случае тестовой выборки часть результатов несколько хуже, чем для валидационной выборки, но они превышают пороговое значение 0,5. Такое незначительное ухудшение результатов на неизвестной моделям тестовой выборке является ожидаемым и соответствует известному положению теории нейронных сетей.

Таблица 3.4 – Качество семантической сегментации изображения деревьев *A. sibirica* тестового участка, полученное с помощью моделей на тестовой выборке с фрагментами размером $256 \times 256 \times 3$ пикселей

Модель	$IoUc$					$mIoU$
	Фон	Живое	Отмирающее	Свежий сухостой	Старый сухостой	
Segformer+	0,87	0,76	0,56	0,80	0,70	0,74
U-Net	0,87	0,73	0,45	0,79	0,68	0,70
Mo-U-Net	0,86	0,74	0,51	0,75	0,65	0,71
At-Mo-U-Net	0,86	0,74	0,51	0,79	0,68	0,72
Res-Mo-U-Net	0,85	0,72	0,51	0,75	0,66	0,70

В таблице 3.5 показаны количественные результаты исследований разработанных моделей по точности классификации в виде значений метрик $IoUc$ и $mIoU$ в случае тестовой выборки из второго датасета с фрагментами размером $480 \times 480 \times 3$ пикселей. Отметим, что в таблицы 3.4 и 3.5 включены также получен-

ные нами на этих же тестовых выборках результаты исследований по точности классификации классической модели U-Net.

Таблица 3.5 – Качество семантической сегментации изображения деревьев *A. sibirica* тестового участка, полученное с помощью моделей на тестовой выборке с фрагментами размером $480 \times 480 \times 3$ пикселей.

Модель	<i>IoUc</i>					<i>mIoU</i>
	Фон	Живое	Отмирающее	Свежий сухой	Старый сухой	
Segformer+	0,88	0,77	0,58	0,81	0,71	0,75
U-Net	0,87	0,73	0,46	0,79	0,69	0,71
Mo-U-Net	0,86	0,75	0,52	0,78	0,70	0,72
At-Mo-U-Net	0,86	0,76	0,52	0,80	0,70	0,73
Res-Mo-U-Net	0,86	0,76	0,57	0,80	0,70	0,74

На рисунках 3.11 и 3.12 в качестве примера показаны матрицы ошибок, возникающих при попиксельной мультиклассификации деревьев *A. sibirica* на изображении тестового участка в случае использования модели Res-Mo-U-Net.




Рисунок 3.11 – Матрица ошибок при попиксельной мультиклассификации изображения тестового участка деревьев *A. sibirica* с использованием модели Res-Mo-U-Net и фрагментов размером $256 \times 256 \times 3$ пикселей

На рисунке 3.11 представлена матрица ошибок в случае тестовой выборки с фрагментами размером $256 \times 256 \times 3$ пикселей, а на рисунке 3.12 – матрица ошибок в случае тестовой выборки с фрагментами размером $480 \times 480 \times 3$

пикселей. В каждую ячейку матриц помещены как абсолютные значения ошибок (количество пикселей), так и значения относительных ошибок в процентах. Элементы матриц, стоящие на пересечении одноименных столбца и строки (диагональные элементы), показывают точность классификации изображения тестового участка с помощью модели Res-Mo-U-Net для выбранного класса деревьев пихты. Элементы, находящиеся в одной строке с диагональным элементом, содержат ошибки, сформированные за счет пикселей класса диагонального элемента, отнесенных моделью к другим классам.

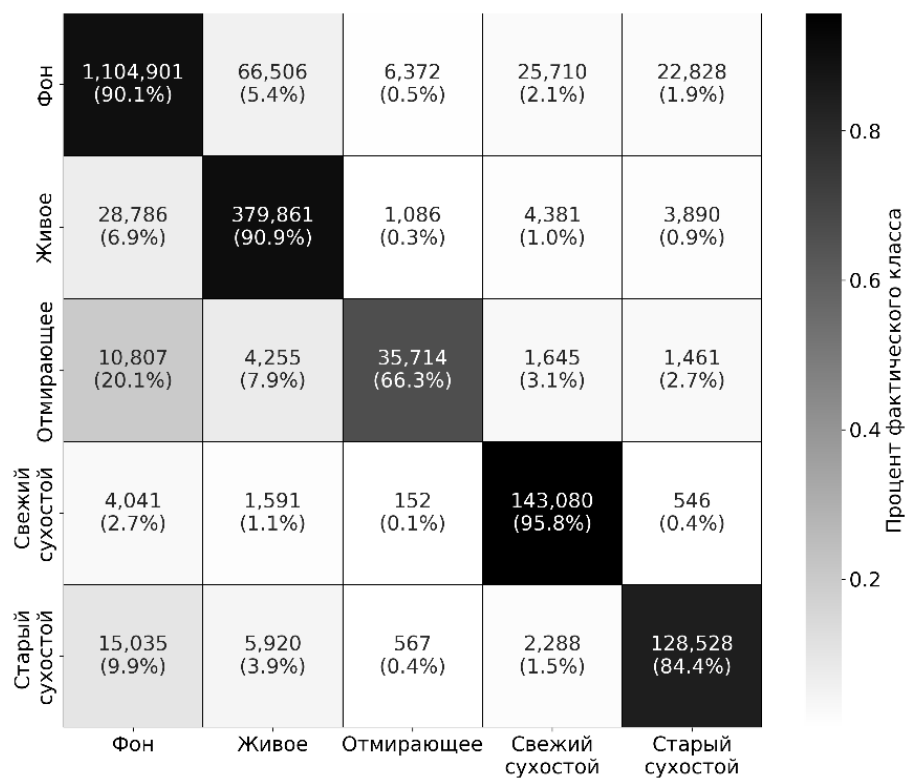


Рисунок 3.12 – Матрица ошибок при попиксельной мультиклассификации изображения тестового участка деревьев *A. sibirica* с использованием модели Res-Mo-U-Net и фрагментов размером $480 \times 480 \times 3$ пикселей

Заметим, что аналогичные три пары матриц ошибок получены в случаях решения этой задачи мультиклассификации деревьев *A. sibirica* на изображении тестового участка с использованием других исследуемых моделей. Первая матрица ошибок из пары вычислялась в случае тестовой выборки с фрагментами размером $256 \times 256 \times 3$ пикселей, а вторая матрица ошибок – в случае тестовой

выборки с фрагментами размером $480 \times 480 \times 3$ пикселей. Всего было сформировано четыре пары матриц ошибок.

Проведем детальный анализ всех полученных результатов исследований моделей по точности классификации на изображениях пораженных деревьев *A. sibirica*. Результаты исследований, приведенные в таблице 3.4, показывают, что модель Segformer+ дает наибольшую точность классификации по всем классам деревьев пихты по метрикам *IoUc* и *mIoU*, значительно превышающую пороговое значение 0,5. На наш взгляд, такие высокие результаты этой модели обусловлены наличием в ее энкодере иерархической архитектуры трансформера MiT, а также введенными нами модификациями исходной модели Segformer. Именно они позволяют энкодеру генерировать признаки нескольких масштабов для точной сегментации крон деревьев различного размера. На втором месте по метрике *mIoU* находится модель с механизмом внимания At-Mo-U-Net, а на третьем месте – модель Mo-U-Net. Для деревьев промежуточного класса «Отмирающее» модели Mo-U-Net, At-Mo-U-Net и Res-Mo-U-Net показывают одинаковые результаты, только незначительно превышающие пороговое значение 0,5 по метрике *IoUc*. Модель U-Net для этого класса жизненного состояния деревьев показывает значение метрики *IoUc*, равное 0,45, что значительно ниже порогового значения, поэтому она сильно отстает по точности классификации от этих трех моделей. На наш взгляд, использование функции активации ELU у разработанных моделей вместо функции активации ReLU у модели U-Net помогает этим моделям извлекать из изображения более сложные признаки крон пораженных деревьев. Отметим, что этот результат по метрике *IoUc* для модели U-Net несколько превышает точность классификации деревьев пихты класса «Отмирающее», полученную в работе [34] для этой же модели U-Net. Для других классов деревьев и класса «Фон» значения метрики *IoUc* для всех полносверточных моделей превышают пороговое значение 0,5 и отличаются незначительно.

Анализ результатов из таблицы 3.5 показывает, что все значения метрик *IoUc* и *mIoU* увеличились для всех моделей и для большинства классов деревьев по сравнению с результатами из таблицы 3.4. Также согласно рисункам 3.11 и

3.12 с ростом размера фрагментов тестовой выборки ошибки классификации были уменьшены для всех классов состояния деревьев. Это объясняется тем, что фрагменты из второй тестовой выборки с размером $480 \times 480 \times 3$ пикселей содержат большее число деревьев пихты с полноценными (не обрезанными на краях фрагментов) контурами, чем фрагменты из тестовой выборки из первого датасета с размером $256 \times 256 \times 3$ пикселей, и это приводит к повышению точности классификации деревьев. Модель Segformer+ продолжает оставаться лидером среди всех моделей, однако модель Res-Mo-U-Net значительно добавила, особенно для класса состояний деревьев «Отмирающее», по точности классификации по метрикам $IoUc$ и $mIoU$ и вплотную приблизилась к ней. На третьем месте по метрике $mIoU$ находится модель At-Mo-U-Net, бывшая в случае тестовой выборки из первого датасета на втором месте (таблица 3.4).

Анализ матриц ошибок, приведенных на рисунках 3.11 и 3.12, показывает, что модель Res-Mo-U-Net чаще всего ошибочно относит к классу «Фон» деревья классов (в порядке убывания количества ошибок): «Отмирающее», «Старый сухой» и «Живое». Деревья класса «Отмирающее» модель также довольно часто ошибочно относит к классу «Живое». Из сравнения элементов матриц ошибок следует, что ошибки классификации с ростом размера фрагментов тестовой выборки уменьшились для всех классов состояний деревьев пихты. При этом фактическая точность распознавания состояний класса «Фон» выросла с увеличением размера фрагментов тестовой выборки, в том числе за счет уменьшения ошибок при классификации крон деревьев *A. sibirica*. Отметим, что аналогичные тенденции были выявлены при анализе матриц ошибок, полученных при исследовании других трех разработанных моделей нейронных сетей.

Проведенный анализ результатов исследований, показанных в таблицах 3.4 и 3.5 и на рисунках 3.11 и 3.12, позволяет сделать следующие выводы. Во-первых, для решения задачи мультиклассификации пораженных деревьев пихты *A. sibirica* с заданным пороговым значением 0,5 по метрикам $IoUc$ и $mIoU$ точности классификации наряду с моделью Segformer+, показывающей наилучшие результаты, на практике можно использовать все три предложенные полносверточные

модели. Однако вслед за моделью Segformer+, в зависимости от размера фрагментов используемых датасетов предпочтение следует отдать модели с механизмом внимания At-Mo-U-Net, либо гибридной модели с остаточными блоками Res-Mo-U-Net. Во-вторых, классическую модель U-Net, дающую низкую точность классификации состояния промежуточного класса «Отмирающее» вне зависимости от размера фрагментов датасетов, на практике использовать не следует. Наконец, для повышения точности классификации пораженных деревьев пихты на изображениях следует при формировании датасетов по возможности готовить фрагменты больших размеров.

3.5 Результаты исследований моделей нейронных сетей при решении задачи мультиклассификации изображений пораженных деревьев кедра

При проведении исследований (тестировании) обученных моделей нейронных сетей по точности классификации изображений пораженных деревьев кедра *P. sibirica* использовались тестовые выборки из третьего и четвертого датасетов. Точность попиксельной мультиклассификации изображений деревьев *P. sibirica* оценивалась по метрикам *IoUc* и *mIoU*, описанным в п.1.6. Значения этих метрик, превышающие порог 0,5, соответствуют высокой точности классификации таких деревьев.

На рисунке 3.13 приведены результаты исследования обученных моделей при решении задачи мультиклассификации состояний пораженных деревьев кедра в случае использования тестовой выборки с фрагментами размером $256 \times 256 \times 3$ пикселей из третьего датасета. Совместный визуальный анализ изображения тестового участка (рисунок 3.13а), его эталонной маски сегментации (рисунок 3.13б), полученной при дешифровании экспертами, и результирующих выходных карт сегментации при использовании каждой из моделей (рисунок 3.13в,г,д,е) показал, что эти модели способны воспроизводить границы крон деревьев кедра *P. sibirica* и правильно классифицировать значительную долю крон таких деревьев.




Рисунок 3.13 – Результаты семантической сегментации изображения тестового участка *P. sibirica* с использованием фрагментов размером $256 \times 256 \times 3$ пикселей:

(а) Изображение тестового участка; (б) Эталонная карта сегментации; (в) Модель Segformer+; (г) Модель Mo-U-Net; (д) Модель At-Mo-U-Net; (е) Модель Res-Mo-U-Net




Рисунок 3.14 – Результаты семантической сегментации изображения тестового участка *P. sibirica* с использованием фрагментов размером $480 \times 480 \times 3$ пикселей:

(а) Изображение тестового участка; (б) Эталонная карта сегментации; (в) Модель Segformer+; (г) Модель Mo-U-Net; (д) Модель At-Mo-U Net; (е) Модель Res-Mo-U-Net

Аналогичные результаты исследований обученных моделей получены в случае решения этой же задачи мультиклассификации при использовании тестовой выборки с фрагментами размером $480 \times 480 \times 3$ пикселей из четвертого датасета. Визуальный анализ результирующих выходных карт сегментации, полученных при использовании каждой из моделей (рисунок 3.14в,г,д,е), и сравнение их с эталонной картой сегментации (рисунок 3.14б) показали, что эти модели способны воспроизводить границы крон деревьев кедров *P. sibirica* и правильно классифицировать значительную долю этих крон. Сравнительный визуальный анализ результатов на рисунках 3.13 и 3.14, полученных с помощью исследуемых моделей, показал, что в случае тестовой выборки с фрагментами размером $480 \times 480 \times 3$ пикселей модели дают для отдельных областей изображения тестового участка более хорошие результаты, чем в случае использования выборки с фрагментами размером $256 \times 256 \times 3$ пикселей. Этот вывод аналогичен выводу, сделанному в п.3.4 по результатам исследований при решении задачи мультиклассификации пораженных деревьев *A. sibirica* на изображениях.

В таблице 3.6 показаны количественные результаты исследований разработанных моделей по точности классификации в виде значений метрик *IoUc* и *mIoU* в случае тестовой выборки из третьего датасета с фрагментами размером $256 \times 256 \times 3$ пикселей, а в таблице 3.7 – в случае тестовой выборки из четвертого датасета с фрагментами размером $480 \times 480 \times 3$ пикселей. В таблицы 3.6 и 3.7 включены также полученные нами на этих же датасетах результаты исследований обученной классической модели U-Net. Эти результаты нужны для проведения сравнения с результатами исследования разработанных моделей.

Таблица 3.6 – Качество семантической сегментации изображения деревьев *P. sibirica* тестового участка, полученное с помощью моделей на тестовой выборке с фрагментами размером $256 \times 256 \times 3$ пикселей

Модель	<i>IoUc</i>						<i>mIoU</i>
	Фон	Условно здоровое	Свежеселенное	С усохшей вершиной	Свежий сухостой	Старый сухостой	
Segformer+	0,87	0,76	0,54	0,53	0,63	0,74	0,68
U-Net	0,82	0,71	0,46	0,47	0,57	0,72	0,63
Mo-U-Net	0,85	0,74	0,51	0,52	0,62	0,72	0,66
At-Mo-U-Net	0,85	0,75	0,53	0,53	0,62	0,73	0,67
Res-Mo-U-Net	0,84	0,75	0,52	0,51	0,61	0,73	0,66

Таблица 3.7 – Качество семантической сегментации изображения деревьев *P. sibirica* тестового участка, полученное с помощью моделей на тестовой выборке с фрагментами размером $480 \times 480 \times 3$ пикселей

Модель	IoUc						mIoU
	Фон	Условно здоровое	Свежеза-селененное	С усохшей вершиной	Свежий сухостой	Старый сухостой	
Segformer+	0,88	0,77	0,56	0,56	0,65	0,75	0,70
U-Net	0,85	0,72	0,50	0,50	0,58	0,72	0,65
Mo-U-Net	0,87	0,75	0,53	0,55	0,64	0,74	0,68
At-Mo-U-Net	0,87	0,76	0,55	0,55	0,64	0,74	0,69
Res-Mo-U-Net	0,88	0,76	0,56	0,55	0,63	0,75	0,69

На рисунках 3.15 и 3.16 представлены матрицы ошибок попиксельной мультиклассификации деревьев *P. sibirica* для модели Res-Mo-U-Net, выбранной в качестве примера, при использовании тестовых фрагментов размером $256 \times 256 \times 3$ и $480 \times 480 \times 3$ пикселей соответственно. Аналогичные три пары матриц ошибок получены в случаях решения задачи мультиклассификации деревьев *P. sibirica* на изображении тестового участка с помощью трех других исследуемых моделей нейронных сетей.




Рисунок 3.15 – Матрица ошибок при попиксельной мультиклассификации изображения тестового участка деревьев *P. sibirica* с использованием модели Res-Mo-U-Net и фрагментов размером $256 \times 256 \times 3$ пикселей

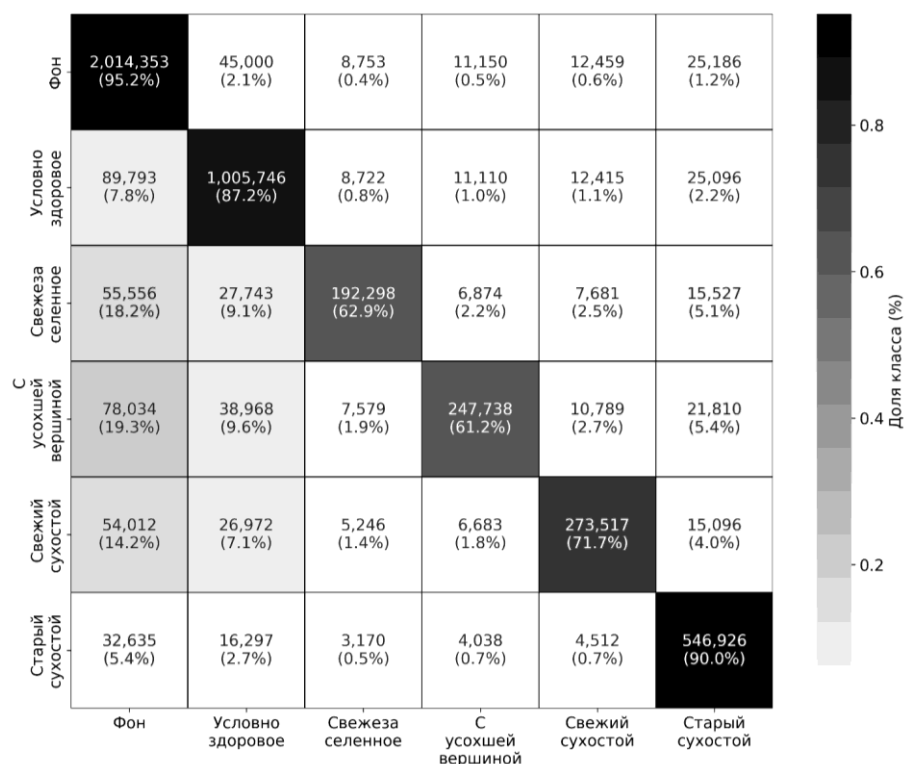


Рисунок 3.16 – Матрица ошибок при попиксельной мультиклассификации изображения тестового участка деревьев *P. sibirica* с использованием модели Res-Mo-U-Net и фрагментов размером $480 \times 480 \times 3$ пикселей

Проведем анализ всех полученных результатов исследований моделей по точности классификации на изображениях пораженных деревьев кедра *P. sibirica*. Результаты, приведенные в таблице 3.6, показывают, что модель Segformer+ демонстрирует наивысшую точность классификации по метрикам $IoUc$ и $mIoU$ по всем классам деревьев кедра и классу «Фон», значительно превышая пороговое значение 0,5. Этот результат аналогичен результату решения с помощью такой модели задачи мультиклассификации пораженных деревьев пихты *A. sibirica*. Второе место по метрике $mIoU$ занимает гибридная модель с механизмом внимания At-Mo-U-Net, лишь немного уступая модели Segformer+. Для проблемных промежуточных классов «Свежезаселенное» и «С усохшей вершиной» модель с механизмом внимания At-Mo-U-Net по метрике $IoUc$ показывает близкие результаты к результатам для этих классов деревьев, полученных с помощью модели Segformer+. Модели Res-Mo-U-Net и Mo-U-Net, показывающие схожие результаты по метрикам $IoUc$ и $mIoU$, занимают третье место. Классическая модель U-Net, несмотря на приемлемые значения метрики $IoUc$ для некото-

рых классов, заметно отстаёт по ней от остальных моделей по ряду классов, а по значениям метрики *IoUc* для классов состояний «Свежезаселённое» и «С усохшей вершиной» не может преодолеть порог 0,5.

Из анализа результатов в таблице 3.7 следует, что все значения метрик *IoUc* и *mIoU* для всех моделей и большинства классов жизненного состояния деревьев кедра выросли по сравнению с показанными в таблице 3.6 результатами по точности классификации в случае тестовой выборки с фрагментами меньшего размера – $256 \times 256 \times 3$ пикселей. При этом сравнительный анализ элементов матриц ошибок на рисунках 3.15 и 3.16 показал, что ошибки классификации с ростом размера фрагментов тестовой выборки уменьшились для всех классов состояний деревьев кедра. Такие результаты объясняются тем, что фрагменты размером $480 \times 480 \times 3$ пикселей содержат более полноценные контуры деревьев кедра, что способствует повышению точности семантической сегментации (попиксельной мультиклассификации) изображений. Модель Segformer+ остаётся лидером по всем значениям метрик, однако модели Res-Mo-U-Net и At-Mo-U-Net значительно приблизились к ней по значениям метрики *mIoU*. По значениям метрики *IoUc* для четырех классов состояний деревьев кедра эти модели приблизились или сравнялись с точностью классификации изображений моделью Segformer+. Модель U-Net, несмотря на рост точности классификации состояний деревьев, всё же уступает остальным моделям, а для промежуточных классов состояний «Свежезаселённое» и «С усохшей вершиной» так и не преодолела порог 0,5.

Анализ матриц ошибок, приведенных на рисунках 3.15 и 3.16, показывает, что модель Res-Mo-U-Net чаще всего ошибается при распознавании состояний деревьев кедра классов «Свежезаселённое» и «С усохшей вершиной». При этом она чаще всего относит деревья этих классов к классу «Фон». Так, например, относительная ошибка для деревьев класса «Свежезаселённое», когда модель относит их к классу «Фон», составляет от 18,2% (случай фрагментов тестовой выборки размером $480 \times 480 \times 3$ пикселей) до 20,1% (случай фрагментов размером $256 \times 256 \times 3$ пикселей). Сравнительный анализ элементов этих матриц также по-

казал, что ошибки классификации с ростом размера фрагментов тестовой выборки уменьшились для всех классов состояний деревьев кедр. Дальнейший анализ матриц ошибок позволил сделать еще ряд выводов, аналогичных тем, что описаны в п.3.4 при анализе матриц ошибок, возникающих при классификации крон деревьев *A. sibirica*. Отметим, что подобные результаты анализа и сделанные по ним выводы были также получены нами при рассмотрении матриц ошибок в случаях других трех разработанных моделей.

Проведенный анализ результатов исследований, показанных в таблицах 3.6 и 3.7 и на рисунках 3.15 и 3.16, позволил сделать следующие выводы. Во-первых, для решения задачи мультиклассификации изображений пораженных деревьев кедр с заданным пороговым значением 0,5 по точности классификации наряду с моделью Segformer+, показывающей наилучшие результаты, в принципе можно использовать все три предложенные полносверточные модели. При этом, в зависимости от размера фрагментов используемых датасетов предпочтение следует отдать гибридной модели с механизмом внимания At-Mo-U-Net, либо модели с остаточными блоками Res-Mo-U-Net. Во-вторых, классическую модель U-Net, дающую низкую точность классификации деревьев кедр в промежуточных состояниях «Свежезаселенное» и «С усохшей вершиной», не превышающую порог 0,5 вне зависимости от размера фрагментов датасетов, на практике использовать не следует. В-третьих, для повышения точности классификации состояний пораженных деревьев кедр следует при формировании датасетов по возможности готовить фрагменты больших размеров.

3.6 Результаты исследования скорости вычисления предложенных моделей нейронных сетей

Комплексность исследований эффективности предложенных и описанных в разделе 2 моделей предполагает кроме исследований их по точности мультиклассификации получение ряда оценок скорости их вычислений. Для этого была проведена еще одна серия экспериментов. Часто вместо термина «скорость вычислений» модели используют термин «время вычислений». Под ним понима-

ется время, необходимое модели на нейросетевой анализ изображения выбранного размера. Эксперименты проведены на персональном компьютере с центральным процессором (англ. CPU) Intel Xeon 2.4 GHz, с ОЗУ 16GB и графическим процессором (англ. GPU) NVIDIA RTX 3080 10GB.

В таблице 3.8 приведены затраты времени в миллисекундах (мс) на вычисление каждой из моделей при использовании тестовой выборки из первого дата-сета с фрагментами изображений деревьев *A. sibirica* размером $256 \times 256 \times 3$ пикселей. Во втором столбце этой таблицы, названном «1 фрагмент», показаны усредненные затраты времени каждой модели на анализ одного фрагмента размером $256 \times 256 \times 3$ пикселей, полученные экспериментально. При этом время на анализ фрагмента включает загрузку и собственно его анализ с помощью модели, а также время на вывод и постобработку фрагмента для его визуализации. В третьем столбце «Все фрагменты» для справки приведены значения времени на анализ всей тестовой выборки, содержащей 96 фрагментов, то есть значения времени, необходимые для анализа изображения всего тестового участка. При мониторинге лесов единицей обследуемой площади является 1га (10000 м^2) специалистов лесной отрасли обычно интересует время, затрачиваемое на вычисление модели при анализе изображения лесного участка площадью 1 га. Поэтому в четвертом столбце таблицы 3.8, названном «1га», для каждой модели приведены значения времени T_{ha} на анализ изображения участка пихтового леса площадью 1га. Вычисления его проведены по следующей формуле:

$$T_{ha} = T_f \frac{W_{ha} \times H_{ha}}{W_f \times H_f} \quad (3.2)$$

где T_f – экспериментально определенное среднее время анализа одного фрагмента с использованием выбранной модели (значения времени T_f взяты из второго столбца таблицы 3.8); W_{ha} , H_{ha} – ширина и высота изображения лесного участка площадью 1 га (размер изображения составляет 1000×1000 пикселей, поскольку изображение имеет пространственное разрешение 0,1 м); W_f , H_f – ширина и высота фрагмента, принимают значение 256 пикселей или 480 пикселей; для расчета значений времени T_{ha} в таблице 3.8 было принято $W_f = H_f = 256$ пикселей.

Таблица 3.8 – Результаты исследований разработанных моделей по времени их вычисления в случае тестовой выборки из первого датасета с фрагментами изображений деревьев *A. sibirica* размером $256 \times 256 \times 3$ пикселей

Модель	1 фрагмент, мс	Все фрагменты, мс	1 га, мс
Segformer+	33,8	3242,2	515,5
U-Net	16,9	1620,9	257,7
Mo-U-Net	17,3	1660,5	263,8
At-Mo-U-Net	28,5	2740,0	434,6
Res-Mo-U-Net	19,0	1823,5	289,8

Таблица 3.9 – Результаты исследований разработанных моделей по времени их вычисления в случае тестовой выборки из второго датасета с фрагментами изображений деревьев *A. sibirica* размером $480 \times 480 \times 3$ пикселей

Модель	1 фрагмент, мс	Все фрагменты, мс	1 га, мс
Segformer+	71,8	1720,4	311,2
U-Net	38,0	912,6	164,9
Mo-U-Net	38,3	918,4	166,2
At-Mo-U-Net	58,3	1398,9	253,0
Res-Mo-U-Net	41,6	999,3	180,5

В таблице 3.9 (столбцы 2 и 3) показаны затраты времени на проведение вычислений каждой из этих же моделей, полученные экспериментально при использовании тестовой выборки второго датасета с фрагментами изображений деревьев *A. sibirica*. Тестовая выборка содержит 24 фрагмента размером $480 \times 480 \times 3$ пикселей. Для расчета значений времени $T_{\text{га}}$ в четвертом столбце таблицы 3.9 по формуле (3.2) было принято $W_f = H_f = 480$ пикселей.

Анализ результатов, приведенных в таблицах 3.8 и 3.9, показывает, что затраты времени на вычисление модели Segformer+ значительно превышают затраты времени, которые требуются на вычисления любой из других моделей, причем этот вывод не зависит от размера анализируемого фрагмента. На втором месте по затратам времени находится гибридная модель At-Mo-U-Net. Эти результаты для моделей Segformer+ и At-Mo-U-Net позволяют сделать вывод о том, что реализация механизма внимания в моделях является алгоритмически сложной процедурой и требует дополнительных затрат времени. По затратам времени на вычисление модель Res-Mo-U-Net находится на третьем месте, немного уступая по скорости вычислений моделям Mo-U-Net и U-Net.

Затраты времени на вычисление моделей при мультиклассификации деревьев кедр *P. sibirica*, приведенные в таблицах 3.10 и 3.11, лишь незначительно выше времени вычислений моделей в случае деревьев пихты (таблицы 3.8 и 3.9).

Это объяснимо, поскольку архитектура моделей сохраняется, но распознается только один дополнительный класс жизненного состояния деревьев кедра. Распределение мест по скорости вычисления моделей остается таким же, как и в случае деревьев пихты.

Таблица 3.10 – Результаты исследований разработанных моделей по времени их вычисления в случае тестовой выборки из третьего датасета с фрагментами изображений деревьев *P. sibirica* размером 256×256×3 пикселей

Модель	1 фрагмент, мс	Все фрагменты, мс	1 га, мс
Segformer+	34,0	2856,0	518,5
U-Net	17,0	1428,0	259,3
Mo-U-Net	17,5	1470,0	266,9
At-Mo-U-Net	28,6	2402,4	436,2
Res-Mo-U-Net	19,2	1612,8	292,8

Таблица 3.11 – Результаты исследований разработанных моделей по времени их вычисления в случае тестовой выборки из четвёртого датасета с фрагментами изображений деревьев *P. sibirica* размером 480×480×3 пикселей

Модель	1 фрагмент, мс	Все фрагменты, мс	1 га, мс
Segformer+	71,9	3307,4	312,0
U-Net	38,1	1752,6	165,4
Mo-U-Net	38,5	1771,0	167,1
At-Mo-U-Net	58,5	2691,0	253,9
Res-Mo-U-Net	41,9	1927,4	181,9

Сравнение затрат времени, необходимых для анализа изображений участков пихтового или кедрового лесов площадью 1га, указывает на то, что для любой из рассматриваемых моделей в случае фрагментов размером 480×480×3 пикселей затраты значительно меньше, чем в случае фрагментов размером 256×256×3 пикселей. Такой вывод является практически важным при осуществлении нейросетевого анализа результатов лесопатологического мониторинга хвойных деревьев в производственных масштабах, когда надо выполнить анализ изображений в больших объемах за весьма короткий промежуток времени. Напомним, из результатов исследований, изложенных в п.п.3.4 и 3.5, следует вывод о том, что как для деревьев пихты, так и для деревьев кедра использование фрагментов размером 480×480×3 пикселей позволяет улучшить точность классификации по сравнению со случаем фрагментов размером 256×256×3 пикселей.

Опираясь на все приведенные в п.п.3.4–3.6 результаты комплексных исследований разработанных моделей по точности классификации изображений пора-

женных вредителями хвойных деревьев и по затратам времени на вычисление каждой из них, можно сформулировать два вывода. Во-первых, модель Segformer+ демонстрирует наивысшую точность классификации по метрикам $IoUc$ и $mIoU$ по всем классам состояний деревьев пихты и кедра, значительно превышая пороговое значение 0,5. Однако затраты времени на ее вычисление значительно превышают затраты времени, которые требуются на вычисление любой другой модели. Во-вторых, компромиссным вариантом при удовлетворении взаимоисключающим требованиям высокой точности классификации и значительной скорости вычисления модели, изложенным в п.1.6, является модель Res-Mo-U-Net.

3.7 Исследования эффективности метода обнаружения очагов размножения уссурийского полиграфа

В п.2.3 описан предложенный для решения первой лесопатологической задачи метод дистанционного обнаружения очагов размножения уссурийского полиграфа в пихтовых лесах. Входными данными для него являются результаты мультиклассификации пораженных деревьев пихты на изображении. На основе метода разработан алгоритм, описанный в п.2.3 и программно-реализованный на языке Python 3 в среде фреймворка PyTorch. Для исследования эффективности этих метода и алгоритма был выбран участок пихтового леса площадью 1 га, на котором имеются деревья пихты, пораженные уссурийским полиграфом (рисунок 3.17а). Этот экспериментальный участок входит в состав ранее обследованного лесопатологами большого участка пихтового древостоя, расположенного в Бакчарском районе Томской области, Бакчарское лесничество. Местоположение большого участка: Парбигское участковое лесничество, окрестности поселка Парбиг, квартал 72, выдел 23 ($57^{\circ}16'35,2''\text{C}$ $81^{\circ}30'18,7''\text{B}$). Основные характеристики деревьев пихты на этом участке, обследованном в августе 2017 г. и детально описанном в [114], таковы: состав древостоя – 9П1Б+К, средний диаметр ствола – $(20,9 \pm 0,8)$ см, средняя высота деревьев – $(20,1 \pm 1,2)$ м, средний возраст – $(71,8 \pm 4,0)$ лет, полнота – 1,0. Как следует из [4,34,114], в 2016-2017 гг. Бакчарский район Томской области характеризовался как действующий фронт инвазии уссу-

рийского полиграфа, поэтому на участке древостоя, включая интересующий нас участок пихтового леса площадью 1 га, наблюдалась активная стадия освоения деревьев пихты этим вредителем. Это показали и результаты наземного обследования вышеописанного участка, которое проводилось в августе 2017 г. группой специалистов – лесопатологов ИМКЭС СО РАН и Центра защиты леса Томской области. Ключевой задачей группы было выявление распространения этого инвазионного вредителя и оценка повреждений им деревьев пихты. При наземном обследовании этого участка леса было установлено, что встречаемость дальневосточного короеда на деревьях пихты довольно высока и составила 87,4%, в том числе 43,2% деревьев обработано уссурийским полиграфом единолично, еще 29,5% совместно с черным пихтовым усачом, а остальные 14,7 % – в комплексе с разными видами усачей и рогахвостами. Все это позволило специалистам охарактеризовать данный участок как очаг размножения именно уссурийского полиграфа. Эти результаты наземного обследования изложены в работах [4,114].

Кроме наземного обследования исследуемый нами участок был дополнительно отснят с помощью фотокамеры, установленной на БПЛА DJI Phantom 3 Standart. Съемка проводилась в видимом диапазоне электромагнитного спектра (RGB) в августе 2017 г. Ее результат приведен на рисунке 3.17а. Полученное RGB-изображение имеет пространственное разрешение 0,1м. Визуальный анализ этого изображения также позволяет считать данный участок пихтового древостоя очагом размножения уссурийского полиграфа, так как на изображении видны красные кроны деревьев пихты (признак сохранения мертвой и красной хвои после обработки дерева пихты уссурийским полиграфом; деревья относятся к классу «Свежий сухостой») [34]. Перед проведением мультиклассификации этого изображения оно было разрезано в соответствии с рекомендацией из п.3.6 на фрагменты размером 480×480×3 пикселей, которые затем подавались для анализа на вход модели полносверточной сети Res-Мо-U-Net. Эта модель была выбрана по результатам комплексных исследований из п.п.3.4–3.6 как компромиссный вариант модели, удовлетворяющей взаимоисключающим требованиям к точности классификации и скорости вычисления модели из п.1.6.

Обучение модели Res-Mo-U-Net проводилось с использованием обучающей и валидационной выборок второго датасета, описанного в п.3.1.2. Исходные RGB-изображения для подготовки этих выборок показаны в п.3.1.1. Они были получены при съемке участков пихтового леса в Томской области с помощью БПЛА и установленной на нем той же фотокамеры, что использовалась для съемки исследуемого участка площадью 1 га. В результате мультиклассификации изображения изучаемого участка с помощью модели Res-Mo-U-Net получена маска сегментации (рисунок 3.17б).

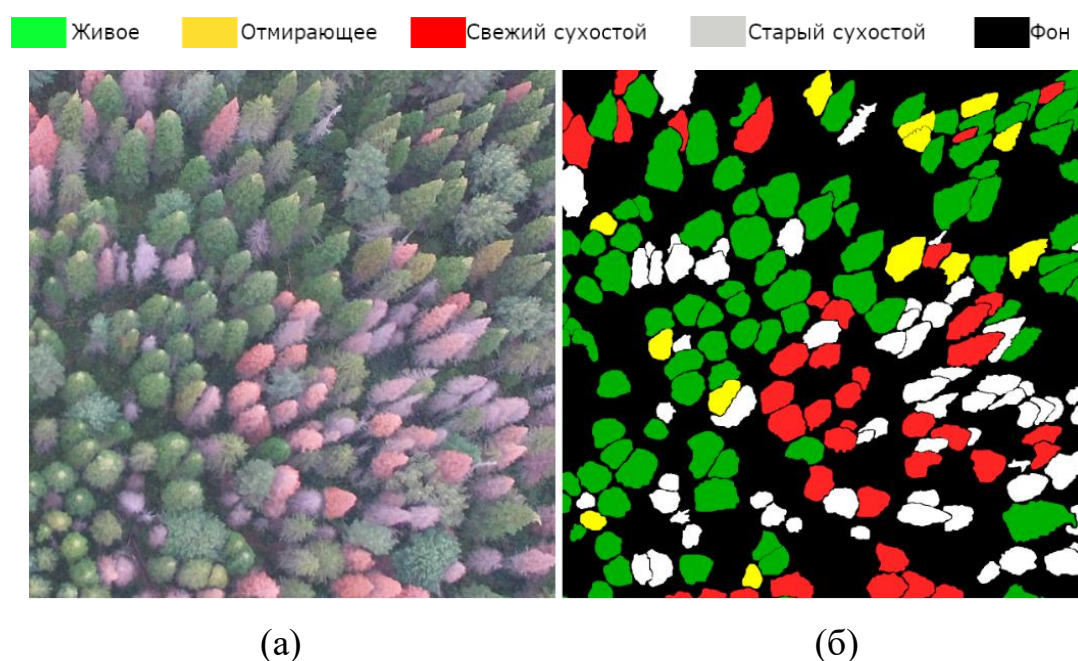


Рисунок 3.17 – Результаты съемки с БПЛА и мультиклассификации изображения изучаемого участка: (а) Исходное изображение участка; (б) Маска сегментации изображения, полученная с помощью модели Res-Mo-U-Net

На первом этапе метода из 209 обнаруженных с помощью модели на маске сегментации и классифицированных по степени поражения уссурийским полиграфом деревьев пихты анализировались 207, поскольку два дерева не относятся к основному пологу. Затем была рассчитана площадь кроны каждого дерева пихты. Для Томской области ранее выявлены и показаны в [114] следующие интервалы площади крон пихты: молодые деревья (первая категория) – [80,1310] пикселей, средневозрастные (вторая категория) – [1311,3914] пикселей и приспевающие/спелые/перестойные (третья категория) – более 3914 пикселей. При этом

для этого региона естественный отпад деревьев пихты $N = 1\%$. Это позволило в соответствии с приведенным в п.2.3 алгоритмом отнести каждое дерево к той или иной категории по возрасту. На втором этапе метода в соответствии с разработанным алгоритмом сделаны расчеты по отпаду деревьев каждой категории возраста и применены соответствующие решающие правила.

Таблица 3.12 – Результаты выявления очага уссурийского полиграфа на изучаемом участке пихтового леса площадью 1га

Категория деревьев пихты по возрасту	Количество деревьев пихты по классам жизненного состояния				Всего деревьев по категориям	$\frac{Kj_2}{Lj} * 100 - N$ (%)	$\frac{Kj_3}{Lj} * 100 - N$ (%)
	Живое	Отмирающее	Свежий сухостой	Старый сухостой			
Первая	18	4	11	8	41	8.8	25.8
Вторая	60	8	23	45	136	4.9	15.9
Третья	14	1	5	10	30	2.3	15.7
Всего	92	13	39	63	-	-	-

В таблице 3.12 приведены итоговые результаты исследования предложенного метода. Обозначения соответствуют принятым в п.2.4. В последней строке таблицы в левой части для справки приведено количество деревьев пихты на участке площадью 1 га по классам жизненных состояний деревьев пихты. Из таблицы 3.12 с учетом пороговых значений отпада следует, что получено превышение естественного отпада ($N = 1\%$) по всем трем возрастным категориям деревьев пихты и в случае каждого из вариантов расчетов (последние два столбца). Так, в предпоследнем столбце таблицы показано, что при учете деревьев пихты только класса «Отмирающее» (первый вариант расчета) фактический отпад составил: 8,8% для молодых деревьев (пороговое значение 5%), 4,9% для средневозрастных деревьев (порог 3%) и 2,3% для приспевающих, спелых и перестойных деревьев (порог 2%). Видим, что фактический отпад для каждой возрастной категории деревьев превышает соответствующее пороговое значение, тем самым подтверждая наличие очага. Из последнего столбца таблицы 3.12 следует, что результаты вычислений фактического отпада по второму варианту (случай деревьев пихты класса «Свежий сухостой») для всех категорий деревьев по возрасту значительно превышают соответствующие пороговые значения и значения фактического отпада, вычисленные в первом варианте расчетов. Это только подтверждает

правильность выводов о наличии очага, сделанных по результатам расчетов в случае деревьев класса «Отмирающее».

Выше были приведены основные результаты наземного обследования изучаемого нами участка, полученные также в августе 2017 г. специалистами ИМКЭС СО РАН и Центра защиты леса Томской области [34,114]. По этим результатам специалисты указали, что в то время на участке имелся очаг размножения уссурийского полиграфа. Это подтверждает сделанные нами выводы о наличии такого очага, полученные с помощью предложенного метода.

Выполним оценку затрат времени, необходимого для проведения наземных лесопатологических обследований (ЛПО) участка площадью 1 га инструментальным (детальным) способом в соответствии с нормативами согласно приказу Минприроды от 09.11.2020 г. N 910 «Об утверждении Порядка проведения ЛПО и составления акта обследований». Расчет показал, что по этим нормативам на проведение ЛПО участка необходимо до 8,5 часа и 2,5 часа на камеральную обработку полученных материалов (составление ведомости перечета деревьев пихты с их картографированием, акта ЛПО и т.д.), то есть требуется 11 часов. Затраты времени на дистанционное обнаружение очага уссурийского полиграфа предложенным методом следующие. Время на подготовку и проведение съемки с помощью БПЛА участка площадью 1 га - не более 1,5 часа. Оценки затрат времени на предварительную обработку и мультиклассификацию с помощью модели Res-Мо-U-Net, а также на реализацию алгоритма обнаружения очага и построения отчета были выполнены для двух вариантов конфигурации компьютера: с центральным процессором Intel Xeon 2.4 GHz , оперативной памятью DDR5 16GB и с графическим процессором GPU NVIDIA RTX 3080 10GB (первый вариант) и второй вариант – без GPU. Выявлено, что в первом варианте на времяемкую мультиклассификацию требуется всего 0,18 с (совпадает с затратами времени в случае этой же модели в таблице 3.9), а на весь процесс вычислений необходимо 20,33 с. Во втором варианте мультиклассификация выполняется за 10,18 с, а весь процесс – за 181,47 с. В итоге съемка и анализ изображения

занимают от 5420,33 с до 5581,47 с. Отсюда следует, что дистанционный метод дает выигрыш во времени по сравнению с наземным ЛПО в 7,1–7,3 раза.

Следует подчеркнуть, что при реализации метода обнаружения очагов уссурийского полиграфа по полученным дистанционно изображениям пораженных деревьев пихты не используются данные наземного мониторинга деревьев. Используются только результаты предыдущих исследований в виде интервалов площадей крон деревьев пихты, характерных для той или иной возрастной категории деревьев этой породы в Томской области. Учитывая, что в разработанном методе применяются решающие правила, описанные в отраслевой методике выявления очагов вредителей хвойных деревьев различных пород, этот метод можно после минимальной адаптации применять при проведении лесопатологического мониторинга хвойных деревьев других пород с целью оперативного выявления очагов размножения других вредителей. Такой минимальной адаптацией является изменение задаваемых в разработанных методе и алгоритме значений интервалов площади крон деревьев другой породы, зависящих от категории их возраста.

3.8 Исследование метода анализа динамики жизненных состояний хвойных деревьев в очагах размножения вредителей

В п.2.5 описан метод и его модификация для анализа динамики жизненных состояний хвойных деревьев в очагах размножения вредителей. Для выполнения этих методов разработаны два алгоритма, которые были программно-реализованы на языке Python 3 в среде фреймворка PyTorch. Здесь рассмотрим результаты исследования таких методов на примере решения задачи анализа динамики состояний деревьев кедр, находящихся в очаге размножения союзного короеда. Для проведения исследования был выбран участок кедрового леса площадью 1 га вблизи села Белоусово в Томской области. В сеансе мониторинга 2023 г. на участке был зафиксирован очаг союзного короеда, а в результате наземного лесопатологического обследования участка в 2025 г., проведенного сотрудниками ИМКЭС СО РАН, был обнаружен также очаг рыжего соснового пилильщика (*Neodiprion sertifer*) [119]. Это указывало на комплексное негативное воздействие

вредителей на древостой. Повреждения деревьев кедр пилильщиком характеризуются дефолиацией, поэтому важными для дистанционной диагностики жизненных состояний кедр являются визуальные признаки кроны, вызванные объединением пилильщиком хвои прошлых лет с сохранением зелёных «кисточек» хвои текущего года на концах ветвей. Поскольку союзный короед на начальной стадии заселения не дает значимых внешних изменений кроны кедр, а пилильщик интенсивно осуществляет дефолиацию, то класс состояния «Свежезаселенное» в 2025 г. необходимо заменить на класс «С признаками дефолиации». Следующее состояние деревьев кедр – «С усохшей вершиной» имеет те же визуальные признаки крон, что были у них в 2023 г. Действительно, короед приводит к усыханию и отмиранию вершинного побега, в то время как пилильщик сохраняет его живым. Основные визуальные признаки крон деревьев в состояниях «Свежий сухостой» и «Старый сухостой» остаются прежними, так как на деревьях в этих состояниях кормовая база для пилильщика практически отсутствует.

В августе 2023 г. и в августе 2025 г. сотрудниками ИМКЭС СО РАН с использованием фотокамеры, установленной на БПЛА DJI Phantom 4 Pro, проводилась съемка этого участка. По результатам его мониторинга получены два одновременных (2023 г. и 2025 г.) RGB-изображения сверхвысокого разрешения (0,08 м), приведены на рисунке 3.18а,в. Перед проведением этапа мультиклассификации этих изображений в соответствии с выводами по результатам исследования разработанных моделей из п.3.5 и п.3.6 они были разрезаны на фрагменты размером $480 \times 480 \times 3$ пикселей, которые затем должны подаваться для семантической сегментации (попиксельной мультиклассификации) на вход выбранной модели нейронной сети. В качестве такой модели использовалась модель полносверточной сети Res-Mo-U-Net, являющаяся с учетом результатов исследований из п.п.3.4–3.6 компромиссным вариантом при удовлетворении требований высокой точности классификации и значительной скорости вычисления модели. Ее обучение проводилось ранее с использованием обучающей и валидационной выборки четвертого датасета, описанного в п.3.1.3. Исходные изображения для формирования этих выборок были получены с помощью той же фотокамеры,

В результате мультиклассификации изображений изучаемого участка с помощью модели Res-Mo-U-Net получены маски сегментации (рисунок 3.18б,г). Для повышения их качества была применена программно-реализованная процедура постобработки масок, описанная в п.2.3. Это позволило получить более точные и геометрически корректные маски для последующего анализа. В соответствии с реализующим метод Алгоритмом 1 на первом этапе полученные маски анализировались для идентификации крон деревьев кедра. Анализ выполнялся для каждой выделенной кроны на каждой из масок, при этом для каждого дерева кедра автоматически определены и зафиксированы следующие параметры: класс жизненного состояния дерева, координаты его центроида (геометрического центра) и площадь проекции кроны в пикселях. Каждой кроне также присваивался уникальный идентификатор.

На втором этапе алгоритма осуществлялось сопоставление крон деревьев, идентифицированных на каждой из масок. Уникальный идентификатор позволил однозначно идентифицировать и сопоставить каждую крону деревьев на двух масках, причем окончательное решение о пространственном соответствии центроидов позволило принять метод KNN. На третьем этапе проведен анализ переходов жизненных состояний каждого дерева, что позволило на четвертом этапе сформировать матрицу переходов жизненных состояний деревьев по изменениям количества деревьев в классах состояний. Модификация этого метода (см. п.2.5) позволила получить в соответствии с разработанным Алгоритмом 2 матрицу переходов жизненных состояний деревьев кедра путем оценок изменений площади крон деревьев.

Полученные матрицы переходов жизненных состояний деревьев кедра представлены в таблицах 3.13 и 3.14. Во второй таблице значения площади крон деревьев приведены в м². Значения в ячейках первой матрицы показывают количество деревьев, перешедших из определенного класса предыдущего (2023 г.), иногда говорят исходного состояния, в соответствующий класс последнего (2025 г.) состояния. Значения по диагонали матрицы показывают, сколько деревьев из класса сохранили свое жизненное состояние.

Таблица 3.13 – Матрица переходов жизненных состояний деревьев кедр, построенная по изменениям количества деревьев в классах состояний

Класс предыдущего (2023 г.) состояния	Класс последнего (2025 г.) состояния деревьев						Итого в 2023 г.
	Условно здоровое	С признаками дефолиации	С усохшей вершиной	Свежий сухой	Старый сухой	Фон	
Условно здоровое	1	81	40	4	69	22	217
Свежезаселенное	0	13	4	0	15	7	39
С усохшей вершиной	0	0	0	0	4	0	4
Свежий сухой	0	0	0	0	3	0	3
Старый сухой	0	0	0	0	22	7	29
Вновь появившееся (Фон)	0	9	7	0	13	0	-
Итого в 2025 г.	1	103	51	4	126	-	285/292

Таблица 3.14 – Матрица переходов жизненных состояний деревьев кедр, полученная путем оценки изменений площади кроны деревьев по классам состояний

Класс предыдущего (2023 г.) состояния	Класс последнего (2025 г.) состояния деревьев						Итого в 2023 г.
	Условно здоровое	С признаками дефолиации	С усохшей вершиной	Свежий сухой	Старый сухой	Фон	
Условно здоровое	20,10	1191,49	476,70	36,15	974,63	1635,02	4333,57
Свежезаселенное	0	213,31	47,43	0	305	255,43	821,56
С усохшей вершиной	0	0	0	0	45,52	14,44	59,96
Свежий сухой	0	0	0	0	48,71	22,64	71,35
Старый сухой	0	1,96	5,89	4,81	362,37	156,15	531,18
Фон	3,59	392,29	142,08	9,29	488,63	3146,50	4182,38
Итого в 2025 г.	23,69	1799,05	672,11	50,25	2224,72	5230,18	10000

Представленные в этих таблицах матрицы переходов позволяют детально выявить масштабы и направления динамики (изменения) жизненных состояний деревьев кедр между 2023 г. (предыдущие состояния) и 2025 г. (последние состояния). Матрица, основанная на анализе количества деревьев кедр в классах (таблица 3.13), показывает значительную трансформацию в количественной структуре древостоя изучаемого участка, причем выявленные направления динамики жизненных состояний – это направления, в основном, именно деградации деревьев кедр. Ярким примером служит класс состояния «Условно здоровое», при переходе из которого подавляющее большинство деревьев изменило свое состояние, перераспределившись преимущественно в классы состояний «С признаками дефолиации» и «Старый сухой». При этом некоторая часть деревьев кедр этого класса не была обнаружена на маске, полученной по изображению 2025 г., и оказалась в столбце «Фон». Наличие строки «Вновь появившееся», в

свою очередь, фиксирует процесс появления новых крон, которые не были идентифицированы на маске 2023 г.

Матрица переходов, полученная путем оценки изменений площади крон деревьев по классам (таблица 3.14), дополняет эту картину, количественно оценивая не только факт перехода дерева кедра в другое жизненное состояние, но и его вклад в изменение площади лесного покрова по классам. Например, анализ переходов деревьев из предыдущего класса «Условно здоровое» показывает, что значительная площадь крон деревьев была утрачена (деревья перешли в класс «Фон»), что свидетельствует о масштабном сокращении живой фитомассы. При этом переход деревьев из класса «Условно здоровое» в класс «С признаками дефолиации» будучи большим по количеству деревьев, по суммарной площади уступает переходу деревьев в класс «Старый сухостой», что указывает на разный размер крон деревьев в этих классах. Совместное рассмотрение этих матриц детально показывает комплексные процессы поражения деревьев кедра союзным короедом и рыжим сосновым пилильщиком.

На основе данных из таблиц 3.13 и 3.14 по формулам (2.15) и (2.16) были рассчитаны скорости переходов жизненных состояний деревьев между классами. Результаты этих расчетов указаны, соответственно, в таблице 3.15 и в таблице 3.16. Анализ результатов из таблицы 3.15 показывает, что значительная скорость переходов, равная 0,187/год, отмечена при переходе деревьев кедра из класса состояний «Условно здоровое» в класс «С признаками дефолиации». Иными словами, ежегодный переход составил 18,7% от количества деревьев, находящихся в 2023 г. в состоянии «Условно здоровое». Высокой оказалась также скорость перехода деревьев этого класса в состояние «Старый сухостой» - 0,159/год, что свидетельствует о быстрой деградации в комплексном очаге размножения союзного короеда и рыжего соснового пилильщика значительного количества деревьев кедра класса «Условно здоровое». Для деревьев класса «Свежеселенное» наиболее характерен переход в состояние «Старый сухостой» со скоростью 0,193/год. Деревья классов «С усохшей вершиной» и «Свежий сухостой» полностью перешли в класс «Старый сухостой» за двухлетний период наблюдения со

скоростью перехода 0,500/год. Более того, рассчитанный по формуле (2.17) индекс деградации популяции кедра составил 43,84% в год, что означает ежегодный переход почти половины всех деревьев в более худшие классы жизненного состояния с катастрофической скоростью деградации древостоя.

Таблица 3.15 – Скорость переходов между классами жизненных состояний деревьев кедра (по количеству деревьев), год⁻¹

Класс исходного (2023 г.) состояния	Класс конечного (2025 г.) состояния					
	Условно здоровое	С признаками дефолиации	С усохшей вершиной	Свежий сухостой	Старый сухостой	Фон
Условно здоровое	0,002	0,187	0,092	0,009	0,159	0,051
Свежезаселенное	0,000	0,167	0,051	0,000	0,193	0,090
С усохшей вершиной	0,000	0,000	0,000	0,000	0,500	0,000
Свежий сухостой	0,000	0,000	0,000	0,000	0,500	0,000
Старый сухостой	0,000	0,000	0,000	0,000	0,379	0,121

Таблица 3.16 – Скорость переходов между классами жизненных состояний деревьев кедра (по площади крон), год⁻¹

Класс исходного (2023 г.) состояния	Класс конечного (2025 г.) состояния					
	Условно здоровое	С признаками дефолиации	С усохшей вершиной	Свежий сухостой	Старый сухостой	Фон
Условно здоровое	0,002	0,138	0,061	0,009	0,112	0,189
Свежезаселенное	0,000	0,130	0,029	0,000	0,186	0,155
С усохшей вершиной	0,000	0,000	0,000	0,000	0,380	0,120
Свежий сухостой	0,000	0,000	0,000	0,000	0,341	0,159
Старый сухостой	0,000	0,000	0,000	0,000	0,341	0,147
Фон	0,000	0,049	0,017	0,001	0,058	0,376

Значения скорости переходов, рассчитанной по изменениям площади крон деревьев (таблица 3.16), несколько иные, но в ряде случаев близкие к значениям скорости из таблицы 3.15. Например, для деревьев класса «Условно здоровое» скорость перехода в класс «С признаками дефолиации» составила 0,138/год, а в класс «Старый сухостой» - 0,112/год. Однако деревья класса «Свежезаселенное» характеризовались высокой скоростью перехода в класс «Старый сухостой» (0,186/год), что близко к результатам, полученным для того же направления переходов в таблице 3.15. Отметим, что все результаты в таблицах 3.15 и 3.16 указывают на интенсивную деградацию деревьев кедра на данном участке.

Для сравнения результатов, полученных с помощью предложенных методов, с результатами других методов был проведён анализ динамики жизненных состояний деревьев кедра в том же очаге размножения союзного короеда, а в 2025 г. – и рыжего соснового пилильщика на участке площадью 1 га

с использованием двух известных методов. Во-первых, был применен метод прямого подсчета изменений количества крон деревьев по классам состояний на прошедших постобработку первой и второй масках сегментации. Результаты его использования представлены в таблице 3.17. Получены также результаты анализа динамики состояний деревьев другим методом – оценки изменения площади крон этих деревьев по классам состояний (таблица 3.18). При применении последнего метода сначала, как и в модификации предложенного метода, подсчитывалось количество пикселей каждой кроны деревьев кедр по классам состояний, а затем с учетом пространственного разрешения изображения оценивалась площадь этих крон.

Таблица 3.17 – Изменение количества деревьев кедр по классам жизненных состояний за период 2023-2025 гг.

Класс	Количество деревьев в 2023 г.	Количество деревьев в 2025 г.	Изменение количества деревьев
Условно здоровое	217	1	-216
Свежезаселенное в 2023 г. / С признаками дефолиации 2025 г.	39	103	+64
С усохшей вершиной	4	51	+47
Свежий сухостой	3	4	+1
Старый сухостой	29	126	+97
Итого	292	285	-7

Таблица 3.18 – Изменение суммарной площади крон деревьев кедр по классам жизненных состояний за период 2023-2025 гг.

Класс	Площадь в 2023 г., м ²	Площадь в 2025 г., м ²	Изменение площади, %
Условно здоровое	4333,57	23,69	- 99,5
Свежезаселенное в 2023 г. / С признаками дефолиации 2025 г.	821,56	1799,05	+ 120,3
С усохшей вершиной	59,96	672,11	+ 979,7
Свежий сухостой	71,35	50,25	- 29,6
Старый сухостой	531,18	2224,72	+ 329,2
Фон	4182,38	5230,18	+ 24,1
Итого	10000	10000	0,0

Из таблиц 3.17 и 3.18 следует, что такие методы позволяют оценить конечные (итоговые) изменения числа деревьев кедр по классам состояний на изучаемом участке или площади их крон по классам в 2025г. Однако они не отражают сложную внутреннюю динамику состояний деревьев кедр в очаге размножения союзного короеда и рыжего соснового пилильщика. Например,

такие методы не показывают, являлось ли увеличение числа деревьев класса «Старый сухостой» результатом деградации деревьев класса «Свежезаселенное» или переходом деревьев из класса «С усохшей вершиной», что было бы важно для понимания процессов деградации деревьев в очаге размножения вредителей.

Более глубокий сравнительный анализ представленных в таблицах 3.13 и 3.14 матриц переходов жизненных состояний деревьев кедра и результатов из таблиц 3.17 и 3.18 показывает, что матрицы дают более сложную (более многогранную) динамику состояний деревьев кедра за период с 2023 г. по 2025 г., чем результаты применения методов прямого подсчета количества деревьев и площадей их крон в определенном классе состояний. Так, матрица переходов состояний, построенная по изменению количества деревьев (таблица 3.13) наглядно показывает масштабную деградацию исходно здоровой части древостоя. Действительно, подавляющее большинство деревьев, классифицированных в 2023 году по состоянию «Условно здоровое», изменило свое состояние: наибольшая их часть перешла в классы «С признаками дефолиации» и «Старый сухостой». При этом небольшая доля деревьев кедра этого класса полностью исчезла, перейдя в класс «Фон». Процесс деградации деревьев кедра в очаге затронул не только изначально здоровые деревья, но и деревья других классов состояний, таких как «Свежезаселённое» и «Старый сухостой», из которых также был переход деревьев в класс «Фон». Наличие в матрице строки «Вновь появившиеся» свидетельствует о параллельном процессе омоложения древостоя, поскольку новые деревья, не зафиксированные в 2023 г. из-за малой площади кроны, были идентифицированы в 2025 г. преимущественно в классе «С признаками дефолиации». Матрица, основанная на оценке переходов по площади крон деревьев (таблица 3.14), количественно подтверждает эти тенденции и придаёт им дополнительный вес. В то же время методы прямого подсчета фиксируют лишь итоговые изменения жизненных состояний деревьев. Например, они показывают катастрофическое сокращение количества деревьев класса «Условно здоровое» и их площади, а также общий рост количества деревьев в классах «С признаками дефолиации», «С усохшей

вершиной» и «Старый сухостой». Такой сравнительный анализ подчёркивает ключевые преимущества разработанного метода и его модификации и позволяет сделать следующий вывод. Формирование матриц переходов жизненных состояний деревьев кедр и их анализ раскрывают внутреннюю динамику состояний деревьев кедр, позволяя вычислить направления и скорость переходов между классами состояний деревьев в очаге размножения вредителей.

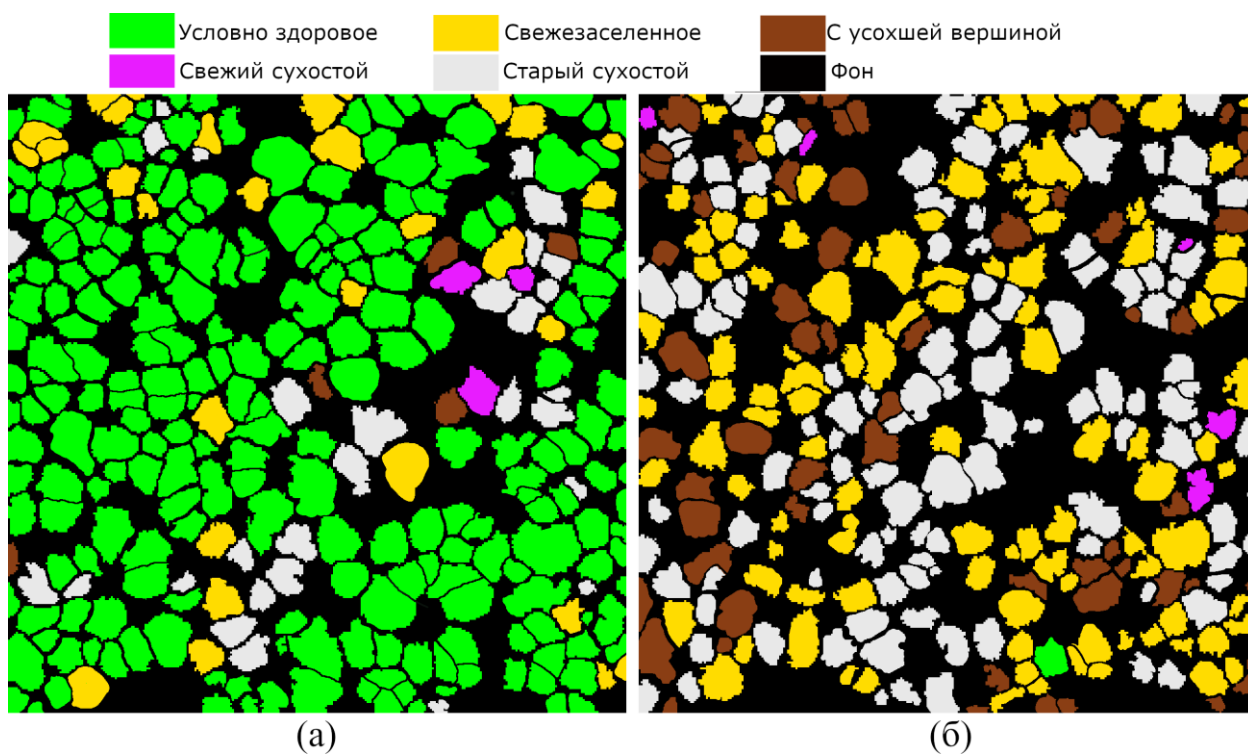


Рисунок 3.19 – Результаты мультиклассификации изображений изучаемого участка деревьев кедр, полученные экспертами: (а) Эталонная маска сегментации для изображения 2023 г.; (б) Эталонная маска сегментации для изображения 2025 г.

Для оценки влияния точности классификации разновременных изображений деревьев кедр на изучаемом участке с помощью модели Res-Mo-U-Net на результаты анализа динамики жизненных состояний деревьев кедр, выполненного с помощью разработанного метода, была решена дополнительная задача. Вместо масок сегментации, полученных с помощью модели Res-Mo-U-Net для изображений 2023-2025 гг., использовались эталонные маски сегментации, выполненные путем дешифрования этих изображений экспертами ИМКЭС СО РАН (рисунок 3.19). Визуальное сравнение масок, полученных с помощью модели

Res-Mo-U-Net (рисунок 3.18б,г) и полученных экспертами (рисунок 3.19) показывает хорошую согласованность контуров и пространственного расположения большинства крон деревьев кедр. Затем к эталонным маскам сегментации был применен разработанный метод анализа динамики жизненных состояний. В итоге была получена матрицы переходов жизненных состояний деревьев кедр, показанная в таблице 3.19. Сравнительный анализ ее с матрицей из таблицы 3.13 выявил, что общее количество идентифицированных на масках сегментации деревьев в 2023 г. отличается незначительно: 292 дерева в случае использования для получения маски модели Res-Mo-U-Net против 293 деревьев в случае работы экспертов, что составляет расхождение менее 0,3%. Аналогичный результат имеет место и для масок в 2025г. Анализ каждой матрицы также показывает доминирующее направление деградации деревьев кедр из класса «Условно здоровое» в классы «С признаками дефолиации» и «Старый сухостой». Однако имеются и количественные различия. Так, переход из класса «Условно здоровое» в класс «С признаками дефолиации» составил 81 дерево кедр при получении масок с помощью модели и 86 деревьев – при экспертной оценке, то есть относительная ошибка +6,2%, а при переходе в класс «Старый сухостой» ошибка -13,0%. Самое значительное расхождение обнаружено при переходе деревьев из класса «Условно здоровое» в класс «С усохшей вершиной»: на масках сегментации, полученных с помощью модели, обнаружены 40 деревьев из класса «Условно здоровое», в то время на масках, полученных экспертами, выявлены 50 деревьев, то есть ошибка +25%. Отметим, что наибольшие расхождения в результатах наблюдаются именно при переходах деревьев в классы промежуточных состояний, таких как «С признаками дефолиации» и «С усохшей вершиной». Эти результаты согласуются с результатами разведочного анализа из п.3.2.2, который показал, что промежуточные состояния являются наиболее сложными для автоматической точной классификации пораженных деревьев кедр, то есть к используемой модели нейронной сети предъявляются повышенные требования.

В итоге из проведенного сравнительного анализа матриц переходов следует, что точность метода анализа динамики жизненных состояний зависит от

точности классификации разновременных изображений, обеспечиваемой моделью Res-Mo-U-Net. Снижение точности классификации произошло, возможно, в том числе из-за того, что модель обучалась на выборке, сформированной на изображениях участка с очагом только союзного кородея, а на изучаемом участке в 2025 г. в очаге наряду с этим вредителем размножился рыжий сосновый пилильщик. Пилильщик изменил признаки крон деревьев, находящихся, по крайней мере, в промежуточном состоянии «С признаками дефолиации». Точность анализа динамики можно повысить, если, следуя результатам исследований из п.3.5, использовать модель Segformer+, дающую более высокую точность классификации.

Таблица 3.19 – Матрица переходов жизненных состояний деревьев кедр, построенная по изменениям количества деревьев в классах деревьев на эталонных масках сегментации

Класс предыдущего (2023 г.) состояния	Класс последнего (2025 г.) состояния деревьев						Итого в 2023 г.
	Условно здоровое	С признаками дефолиации	С усохшей вершиной	Свежий сухостой	Старый сухостой	Фон	
Условно здоровое	1	86	50	4	60	26	227
Свежезаселенное	0	8	4	0	11	6	29
С усохшей вершиной	0	0	0	1	4	0	5
Свежий сухостой	0	0	0	0	3	0	3
Старый сухостой	0	0	0	0	23	6	29
Вновь появившееся (Фон)	0	12	8	0	11	0	-
Итого в 2025 г.	1	106	62	5	112	-	286/293

Также по данным из таблицы 3.19 с использованием формул (2.15) и (2.16) были рассчитаны скорости переходов жизненных состояний деревьев между классами (таблица 3.20). Из таблицы 3.20 следует, что значения скорости переходов между классами состояний весьма различны, но тенденции по интенсивности деградации деревьев такие же, как в таблице 3.15. Для сравнения результатов из таблиц 3.15 и 3.20 подсчитаны разницы скоростей переходов, приведенные в таблице 3.21. Из нее следует, что для ряда переходов скорости одинаковы, а абсолютные изменения скоростей переходов находятся в диапазоне от 0,002 до 0,100 /год. По сути эти значения являются абсолютными погрешностями вычисления скоростей, вносимыми недостаточной точностью классификации изображений с помощью модели Res-Mo-U-Net. Если принять, следуя (2.15), что

количество деревьев любого класса исходного состояния составляет 100%, то погрешность вычисления скорости переходов в таблице 3.21 составит 0,2%–10%.

Таблица 3.20 – Скорость переходов между классами жизненных состояний деревьев кедр (по количеству деревьев), год⁻¹ (на эталонных масках сегментации)

Класс исходного (2023 г.) состояния	Класс конечного (2025 г.) состояния					
	Условно здоровое	С признаками дефолиации	С усохшей вершиной	Свежий сухостой	Старый сухостой	Фон
Условно здоровое	0,002	0,189	0,110	0,009	0,132	0,055
Свежезаселенное	0,000	0,138	0,065	0,000	0,190	0,103
С усохшей вершиной	0,000	0,000	0,000	0,100	0,400	0,000
Свежий сухостой	0,000	0,000	0,000	0,000	0,500	0,000
Старый сухостой	0,000	0,000	0,000	0,000	0,390	0,104

Таблица 3.21– Абсолютные погрешности скоростей переходов между классами жизненных состояний деревьев кедр, год⁻¹

Класс исходного (2023 г.) состояния	Класс конечного (2025 г.) состояния					
	Условно здоровое	С признаками дефолиации	С усохшей вершиной	Свежий сухостой	Старый сухостой	Фон
Условно здоровое	0,000	0,002	0,018	0,000	0,027	0,004
Свежезаселенное	0,000	0,029	0,014	0,000	0,003	0,013
С усохшей вершиной	0,000	0,000	0,000	0,100	0,100	0,000
Свежий сухостой	0,000	0,000	0,000	0,000	0,000	0,000
Старый сухостой	0,000	0,000	0,000	0,000	0,011	0,017

По формуле (2.17) с использованием значений из таблицы 3.19 вычислен индекс деградации популяции кедр (общая скорость ухудшения жизненного состояния деревьев). Он составил 44,54% в год, что на 0,70% больше значения индекса, рассчитанного по матрице переходов из таблицы 3.15, полученной при использовании для вычисления масок сегментации модели Res-Mo-U-Net. То есть, значение погрешности при вычислении этого индекса в случае модели Res-Mo-U-Net равно 0,70% и весьма мало.

3.9 Основные результаты и выводы по разделу

При проведении комплексных исследований разработанных моделей, методов и алгоритмов для решения задач лесопатологического мониторинга хвойных лесов получены научные результаты и сделаны следующие выводы.

1. Результаты съёмки участков пораженных вредителями хвойных деревьев пихты *A. sibirica* и кедр *P. sibirica* в виде RGB- изображений были дешифро-

ваны экспертами. По этим изображениям с учетом полученных экспертами масок сегментации сформированы четыре набора данных (датасета).

2. Проведен разведочный анализ обучающих выборок этих датасетов, который выявил значительный дисбаланс классов и низкую разделяемость жизненных состояний хвойных деревьев на основе только спектральных признаков, что указывает на необходимость использования сложных моделей нейронных сетей при решении задачи мультиклассификации изображений.
3. С использованием обучающих и валидационных выборок датасетов проведены обучение и валидация всех четырех разработанных моделей глубокого обучения и классической модели U-Net.
4. На тестовых выборках датасетов проведены комплексные исследования эффективности предложенных и обученных моделей и классической модели U-Net. Модели исследовались как по точности классификации изображений деревьев пихты *A. sibirica* и деревьев кедра *P. sibirica*, так и по скорости вычисления при различных размерах входных фрагментов изображений. Анализ полученных результатов позволил сделать следующие основные выводы. Во-первых, для решения задачи мультиклассификации изображений пораженных вредителями деревьев этих пород с заданным пороговым значением 0,5 метрик *IoUc* и *mIoU* точности классификации наряду с моделью Segformer+, показывающей наилучшие результаты, на практике можно использовать предложенные полносверточные модели. Однако затраты времени на вычисление модели Segformer+ значительно превышают затраты времени, которые требуются на вычисление любой из полносверточных моделей. Компромиссным вариантом для выполнения взаимопротиворечащих требований «точность классификации – скорость вычислений» является модель Res-Mo-U-Net, поскольку она обеспечивает высокую точность классификации при приемлемой скорости вычислений. Во-вторых, классическую модель U-Net, дающую низкую точность классификации деревьев пихты промежуточного класса состояний «Отмирающее» или промежуточных классов «Свежезаселенное» и «С усохшей вершиной» состояний деревьев кедра вне зависимости

от размера фрагментов датасетов, на практике использовать не следует. В-третьих, использование входных фрагментов изображений размером $480 \times 480 \times 3$ пикселей при решении задачи мультиклассификации изображений как деревьев пихты, так и деревьев кедра позволяет улучшить точность классификации деревьев и повысить скорость вычисления моделей по сравнению со случаем входных фрагментов размером $256 \times 256 \times 3$ пикселей.

5. Апробирован разработанный метод дистанционного обнаружения очагов размножения уссурийского полиграфа в пихтовых лесах. Результаты анализа изображения участка с пораженными деревьями пихты, полученные с использованием модели Res-Mo-U-Net, подтвердили наличие очага, что согласуется с данными наземных обследований. При этом метод позволяет в 7,1-7,3 раз сократить временные затраты на обнаружение таких очагов при сохранении высокой достоверности результатов обнаружения. Метод после адаптации можно применять для оперативного выявления очагов размножения других вредителей.
6. Исследованы предложенный метод и его модификация для анализа динамики жизненных состояний хвойных деревьев в очагах размножения вредителей, позволяющие формировать матрицы переходов этих состояний по результатам мультиклассификации разновременных изображений. Исследования таких методов проведены на примере решения задачи анализа динамики состояний деревьев кедра, находящихся в очаге размножения союзного короеда, затем в этом очаге выявлен еще один вредитель – рыжий сосновый пилильщик. При этом показано, что в отличие от известных методов, предложенные методы позволяют выявлять направления и с погрешностью не более 10% скорость переходов жизненных состояний деревьев кедра между классами. Более того, нет противопоказаний к тому, чтобы предложенные методы решения задачи анализа динамики жизненных состояний деревьев кедра применять при решении второй лесопатологической задачи в случаях хвойных деревьев других пород и наличия очагов размножения других насекомых-вредителей.

4 СИСТЕМА КОМПЬЮТЕРНОГО ЗРЕНИЯ И НЕЙРОСЕТЕВЫЕ ТЕХНОЛОГИИ НА ЕЕ ОСНОВЕ

Сегодня во многих отраслях знаний, где ведутся обработка и анализ изображений, для решения крупных задач создаются различные системы компьютерного зрения (СКЗ). Не является исключением и лесная отрасль, где сегодня все чаще для анализа изображений, получаемых при дистанционном мониторинге лесов, начинают применять современные модели нейронных сетей.

Ниже рассматривается СКЗ, разработанная с использованием предложенных и исследованных в разделах 2 и 3 моделей нейронных сетей и методов решения основных задач лесопатологического мониторинга хвойных лесов. Описываются созданные на ее основе нейросетевые технологии.

4.1 Концепция разработки системы компьютерного зрения для решения основных лесопатологических задач

4.1.1 Основные принципы создания СКЗ

Под концепцией создания СКЗ здесь и далее понимается совокупность способов (подходов), принципов создания и требований к интеллектуальной СКЗ для решения основных сформулированных в разделе 1 лесопатологических задач. Концепция создания СКЗ позволит разработать её архитектуру [120] и детализировать задачи исследования её эффективности.

Важным подходом к созданию СКЗ, отличающим её от многих существующих систем, является наличие у нее функционала для семантической сегментации (попиксельной мультиклассификации) изображений высокого и сверхвысокого разрешения, получаемых при мониторинге лесных массивов с помощью КА и БПЛА. Причем этот функционал осуществляется с помощью современных моделей глубокого обучения. Отсюда следует основной принцип создания СКЗ: наличие программного обеспечения (ПО) системы, обеспечивающего такой функционал, что служит основой для решения с помощью СКЗ основных задач лесопатологического мониторинга хвойных деревьев. Поэтому ядро ПО системы

должно представлять из себя совокупность модулей, каждый из которых реализует одну из моделей нейронных сетей, разработанных, исследованных и описанных в разделах 2 и 3. Каждая из моделей позволяет решать с определенной точностью классификации и скоростью задачу мультиклассификации изображений пораженных хвойных деревьев. Предлагается в составе ядра системы программно реализовать три разработанных и исследованных модели – At-Mo-U-Net, Res-Mo-U-Net и Segformer+. Каждая из них, как показали исследования (раздел 3), имеет свои преимущества и определенные недостатки, которые следует учитывать при последующем решении той или иной лесопатологической задачи. По сути, модули ядра должны формировать результаты мультиклассификации изображений хвойных деревьев как информационный фундамент для последующего решения всего комплекса лесопатологических задач.

Другой ключевой принцип указывает на то, что каждая из лесопатологических задач или их подзадач решается с помощью отдельного программного модуля (модулей), входные данные для которого создаются в ядре системы с помощью выбранной модели нейронной сети. Отсюда следует принцип выбора моделей сетей, наиболее полно удовлетворяющих требованиям по точности классификации и скорости вычислений, предъявляемым при решении конкретной лесопатологической задачи с помощью нейросетевой технологии. Поэтому кроме модулей ядра ПО должно включать модули, реализующие разработанные методы и алгоритмы для решения конкретных лесопатологических задач, а также ряд сервисных модулей, например, формирования ортофотопланов, картирования изучаемых лесных участков и т.п. Некоторые требуемые в СКЗ сервисные функции могут быть реализованы во внешних по отношению к ней информационных системах или комплексах программ. Это означает необходимость интеграции СКЗ с внешними системами. Более того, разрабатываемое ПО СКЗ должно легко реконфигурироваться при создании нейросетевых технологий для решения конкретных лесопатологических задач. Все это указывает на необходимость применения при разработке СКЗ принципа гибкой (легко перестраиваемой) и масшта-

бируемой (включение новых модулей) архитектуры, способной на различные изменения, в том числе на интеграцию с внешними системами.

Важным положением концепции является необходимость интеграции СКЗ с геоинформационной системой (ГИС). Интерфейс ГИС должен являться пользовательским интерфейсом для специалиста-лесопатолога. На электронные карты, поддерживаемые ГИС, в автоматическом режиме должны наноситься следующие результаты работы СКЗ: векторные слои с выделенными и классифицированными кронами хвойных деревьями в виде масок сегментации (причем разным классам жизненных состояний деревьев присваивается различная цветовая схема); границы выявленных очагов размножения вредителей; карты динамики жизненных состояний хвойных деревьев, визуализирующие матрицы переходов и т.п. В качестве базовой ГИС предлагается использовать свободно распространяемую систему QGIS [121], что соответствует принципу использования открытых и проверенных решений для снижения затрат на разработку и внедрение СКЗ.

4.1.2 Основные требования к СКЗ

Ниже представлен ряд основных требований, которым должна удовлетворять создаваемая СКЗ. В таблице 4.1 представлены выявленные группы требований к аппаратным и программным средствам СКЗ вместе с соответствующими им обозначениями. Коды важны для проверки связности всех требований. В качестве примера ниже более подробно описана первая группа требований, по остальным группам приведена только общая информация.

Таблица 4.1 - Группы требований к СКЗ

Код группы требований	Группа требований
SW	Требования к аппаратному и программному обеспечению
F	Функциональные требования
I	Требования к интерфейсу пользователя
D	Требования к входным данным
R	Требования к отчетам и выходным данным
M	Требования к моделям, методам и алгоритмам

Требования к аппаратному и программному обеспечению относятся к группе SW и приведены в таблице 4.2. Среди них есть также требования к среде функционирования СКЗ. Ядром пользовательского интерфейса и платформой для

визуализации результатов в системе должна выступать свободно распространяемая ГИС QGIS, как продукт с открытым кодом и развитыми средствами расширения функционала через Python API.

Таблица 4.2 - Требования к аппаратному и программному обеспечению СКЗ

Код требования	Требования	Примечания
SW.01	Требования к аппаратному обеспечению и ОС компьютера специалиста	
SW.01.01	Процессор (Intel/AMD – совместимый x64) с тактовой частотой не менее 2.5 ГГц	
SW.01.02	Оперативная память не менее 16 ГБ	Для работы с моделями глубокого обучения
SW.01.03	GPU с объемом памяти не менее 8 ГБ	Для ускорения вычислений
SW.01.04	ОС Windows 10/11 или Linux Ubuntu 20.04 LTS+	
SW.02	Требования к базовому программному обеспечению	
SW.02.01	Среда выполнения Python 3.8+	
SW.02.02	Фреймворк глубокого обучения PyTorch 1.9+	
SW.02.03	ГИС QGIS 3.16+	С поддержкой Python API

Требования группы F определяют основные функции, выполняемые системой, и их особенности. Реализация функций должна следовать принципу сквозного рабочего процесса, при котором все операции – от загрузки данных до получения отчетов – выполняются в рамках единого интерфейса ГИС. При этом выявлен большой перечень функций СКЗ и требований к ним, начиная с требований к загрузке и предварительной обработке изображений с КА или БПЛА, к семантической сегментации (пиксельной мультиклассификации) изображений деревьев, обнаружения очагов размножения вредителей и заканчивая требованиями к функциям визуализации результатов анализа изображений и масок сегментации. Требования группы M задают целевые показатели эффективности для основных компонентов системы. В первую очередь это требования к реализуемым в СКЗ моделям нейронных систем, методам и алгоритмам решения лесопатологических задач. Требования группы I обеспечивают эргономичность работы СКЗ. Пользовательский интерфейс, реализованный в среде ГИС QGIS, должен предоставлять специалисту специализированные панели инструментов и диалоговые окна для доступа к функциям СКЗ. Система должна информировать пользователя о ходе выполнения ресурсоемких процессов. Атрибутивные таблицы должны поддерживать сортировку, фильтрацию и экспорт. Требования группы D указы-

вают на то, что СКЗ должна принимать данные в распространенных форматах (GeoTIFF, SHP). Минимальное пространственное разрешение исходных снимков – 0.1 см/пиксель. Данные должны иметь корректную пространственную привязку в известной системе (системах) координат. Кроме того, в соответствии с требованиями группы R, система должна обеспечивать генерацию отчетов в формате PDF, включающих тематические карты, статистические выкладки по классам состояний деревьев и параметрам очагов. Экспорт векторных слоев и матриц переходов должен осуществляться в форматах SHP, CSV и XLSX.

4.2 SOA – архитектура программного обеспечения СКЗ

Из рассмотренной выше концепции построения СКЗ следует, что эта система должна позволять решать большое число весьма сложных вычислительных задач, возникающих при анализе данных лесопатологического мониторинга, и при этом быть гибкой, масштабируемой и иметь возможность интеграции с внешними системами, а также адаптации при построении на ее основе нейросетевых технологий и появлении новых технологических задач. Поэтому при разработке СКЗ наряду с описанными выше принципами был использован принцип построения ее ПО в виде сервисно-ориентированной архитектуры (англ. Service-Oriented Architecture – SOA) [122,123]. Он предполагает построение ПО системы в виде набора слабосвязанных модулей-сервисов, что обеспечивает его гибкость, расширяемость и упрощает интеграцию СКЗ с внешними системами. На рисунке 4.1 приведена обобщенная схема ПО СКЗ, построенного на основе SOA. Основными компонентами архитектуры являются сервисы (самостоятельные программные модули), инкапсулирующие определенные функции и разработанные как веб-сервисы, а также еще три ключевых компонента SOA-архитектуры: сервисная шина предприятия ESB (англ. Enterprise Service Bus – ESB), система управления бизнес-процессами (англ. Business Process Management System – BPMS) и реестр сервисов. На рисунке 4.1 также показаны внешние по отношению к СКЗ системы, такие как система управ-

ления базами данных (СУБД), ГИС и т.п. Такие системы взаимодействуют с ESB через соответствующие Адаптеры [124].

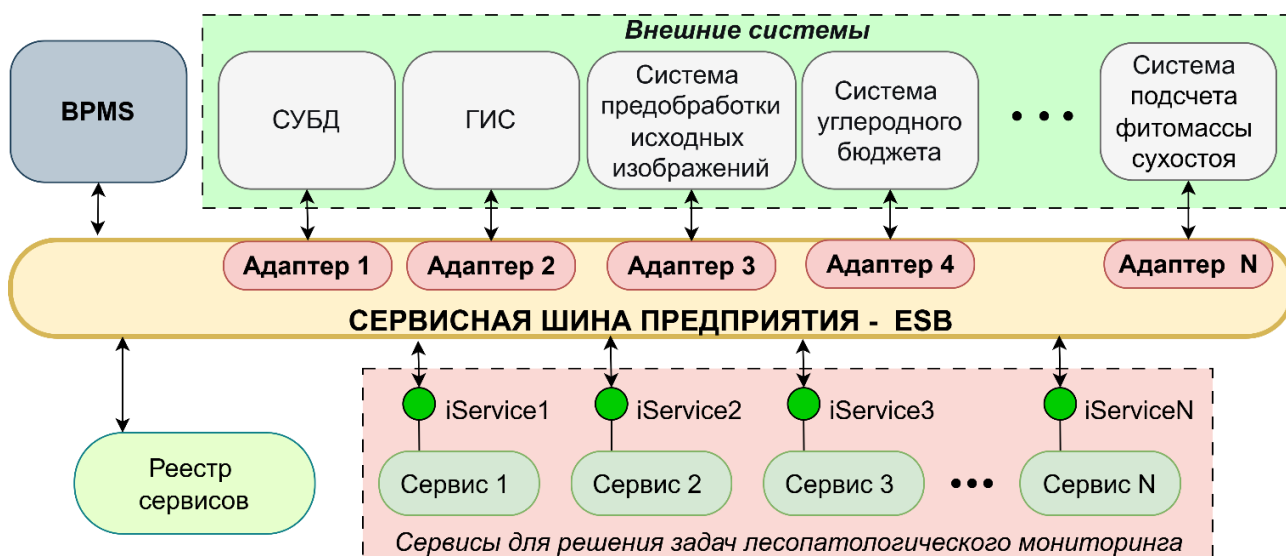


Рисунок 4.1 – Обобщенная схема сервисно-ориентированной архитектуры программного обеспечения СКЗ

ESB обеспечивает маршрутизацию запросов, трансформацию данных и т.д. Использование ESB поддерживает асинхронную обработку запросов, что важно при выполнении ресурсоёмких инференс-задач на больших изображениях. Для управления сложными процессами анализа данных мониторинга применяется BPMS [125], позволяющая формализовать рабочий процесс в виде наглядных схем нотации (англ. Business Process Model and Notation – BPMN) [126]. Для обеспечения динамического выбора и управления сервисами в архитектуру включен реестр сервисов. Он хранит метаинформацию о доступных сервисах, их местоположении, версиях и т.д. При необходимости выполнения определенной функции ESB обращается к реестру для получения актуальной информации о расположении соответствующего сервиса.

4.3 Программное обеспечение СКЗ

ПО разработано с использованием современных языков и инструментальных средств. Сервисы (рисунок 4.2) реализованы на языке Python с применением фреймворков Flask и FastAPI для создания веб-сервисов. Для обучения и валида-

ции предложенных моделей глубокого обучения использованы библиотеки PyTorch и TensorFlow. В качестве ESB выбрана WSO2 ESB [127], а для управления бизнес-процессами используется система ELMA BPM, поддерживающая стандарт BPMN 2.0 [126].

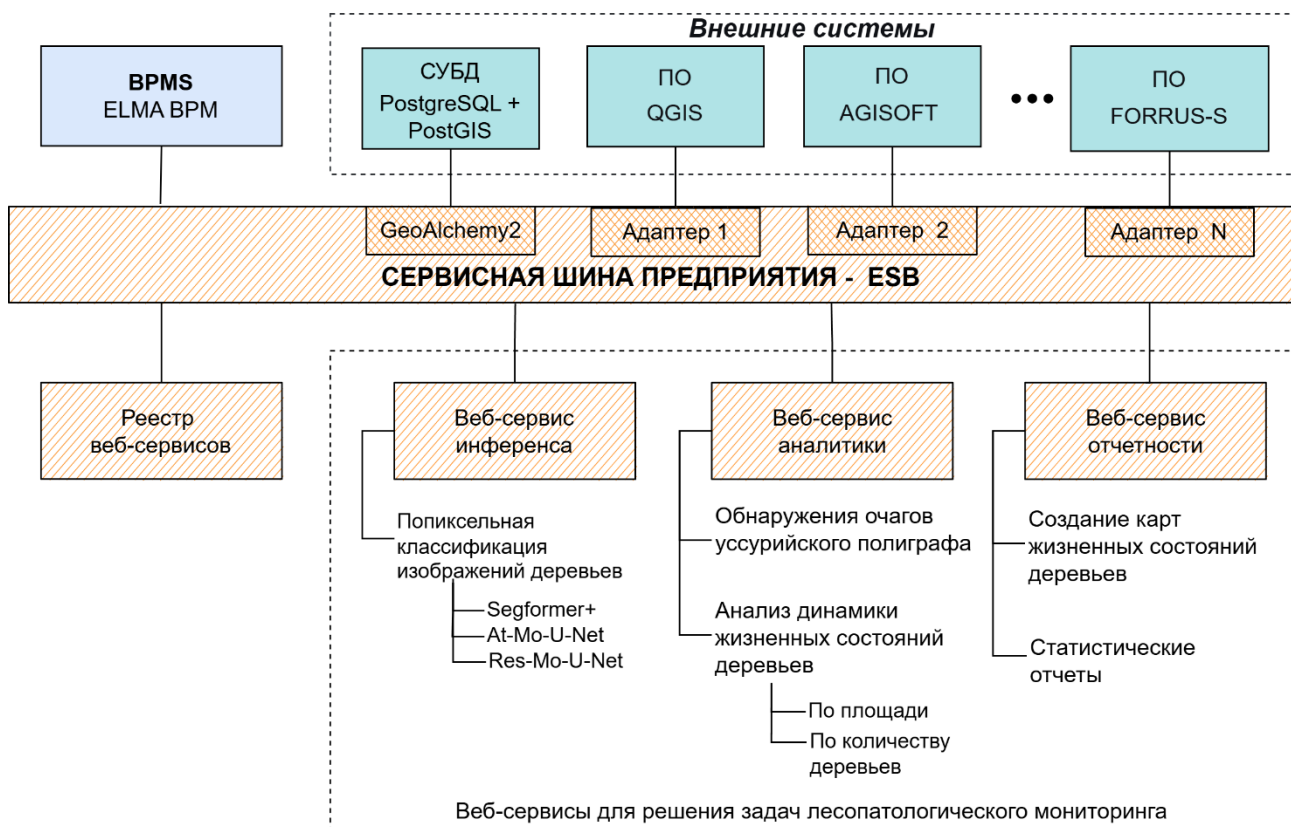


Рисунок 4.2 – SOA-модель программного обеспечения СКЗ

С помощью ELMA BPM определяется последовательность выполнения этапов (операций, подзадач и задач) лесопатологического мониторинга в части анализа полученных данных ДЗЗ: от загрузки исходных изображений и решения задачи их мультиклассификации до аналитической обработки и формирования отчетов. По сути, именно система ELMA BPM позволяет формировать на основе СКЗ и выполнять ту или иную нейросетевую технологию, поскольку она взаимодействует с ESB для инициирования вызовов соответствующих сервисов и внешних систем в нужной последовательности, контролирует состояние выполнения процессов, обрабатывает исключительные ситуации и обеспечивает прозрачность исполнения конкретной нейросетевой технологии.

Рассмотрим более детально ПО разрабатываемой СКЗ. Основными компонентами являются сервисы – самостоятельные программные модули, инкапсулирующие определенные функции. Сервисы составные и разработаны как веб-сервисы в ПО системы (рисунок 4.2) выделены следующие сервисы для решения задач лесопатологического мониторинга.

- Веб-сервис Инференса моделей глубокого обучения обеспечивает выполнение процесса инференса (вызова и исполнения) предварительно обученных моделей At-Mo-U-Net, Res-Mo-U-Net и Segformer+ для семантической сегментации изображений поврежденных хвойных деревьев. Данный сервис принимает на вход подготовленные ортофотоизображения, загружает соответствующую модель в виде сервиса из Реестра сервисов и выполняет попиксельную мультиклассификацию изображений. Поскольку в СКЗ реализован анализ изображений хвойных деревьев двух пород (пихты и кедра), для каждой модели нейронной сети разработано по два специализированных сервиса – один для анализа изображений деревьев пихты, другой - для деревьев кедра. Таким образом, веб-сервис Инференса реализован как составной и включает, с учетом трех моделей, шесть сервисов для попиксельной мультиклассификации .
- Веб-сервис аналитики – реализует разработанные методы решения лесопатологических задач на основе результатов мультиклассификации изображений хвойных деревьев. Этот сервис также является составным и включает сервис обнаружения очагов размножения уссурийского полиграфа, два сервиса, реализующих методы анализа динамики жизненных состояний хвойных деревьев и сервис подсчёта фитомассы сухостоя и оценки его углеродного бюджета.
- Веб-сервис визуализации и отчетности – отвечает за представление результатов анализа в удобной для специалистов форме. Сервис генерирует тематические карты классов жизненных состояний древостоев с цветовым кодированием классов, создает векторные слои выявленных очагов вредителей, формирует статистические отчеты в формате PDF с картографическими материалами, диаграммами распределения классов деревьев и количественными

характеристиками очагов. Кроме того, сервис обеспечивает экспорт аналитических данных (векторных слоев, матриц переходов) в распространенные форматы (SHP, CSV, XLSX) для дальнейшего использования.

Ключевой особенностью предложенной архитектуры является возможность интеграции СКЗ с внешними специализированными системами через адаптеры. Адаптеры представляют собой программные компоненты, обеспечивающие унифицированное взаимодействие разнородных внешних систем с сервисной шиной предприятия. Каждый адаптер инкапсулирует логику взаимодействия с конкретной внешней системой, выполняя при необходимости преобразование форматов данных, протоколов обмена и семантическое согласование информационных моделей. Благодаря использованию адаптеров внешние системы могут быть интегрированы в общий рабочий процесс лесопатологического мониторинга без необходимости модификации их собственных интерфейсов или изменения ядра СКЗ. В контексте задач лесопатологического мониторинга предусмотрена интеграция СКЗ со следующими внешними системами.

- Важным компонентом ПО системы является СУБД. В качестве СУБД выбрана PostgreSQL с пространственным расширением PostGIS, что обусловлено необходимостью хранения и обработки геопространственных данных [128]. Она обеспечивает централизованное хранение метаданных проектов мониторинга, векторных слоев результатов классификации, атрибутивной информации о деревьях и очагах вредителей, а также матриц переходов состояний. PostGIS предоставляет развитые средства пространственного индексирования и выполнения геометрических операций для ускорения обработки запросов при работе с большими лесными участками. Взаимодействие СКЗ с СУБД PostgreSQL/PostGIS обеспечивается через библиотеки SQLAlchemy и GeoAlchemy2 [129].
- ГИС QGIS – основная пользовательская платформа СКЗ. Через специальные Python-плагины QGIS получает доступ к данным СКЗ из PostGIS и к сервисам системы. Это позволяет специалистам визуализировать маски сегментации

(результаты мультиклассификации изображений) и различные тематические карты, редактировать векторные слои с очагами размножения вредителей и т.п., а также проводить дополнительный пространственный анализ полученных изображений и масок. Адаптер QGIS обеспечивает двустороннюю синхронизацию данных между ГИС и СУБД.

- Система предварительной обработки исходных изображений Agisoft Metashare, широко применяемая для фотограмметрической обработки аэрофотоснимков, полученных с БПЛА [130]. С ее помощью выполняются следующие технологические операции: выравнивание и взаимная ориентация исходных снимков, радиометрическая коррекция изображений с учетом характеристик съемочной аппаратуры и условий освещенности. На завершающем этапе осуществляется построение ортофотопланов высокого и сверхвысокого разрешения из множества перекрывающихся изображений. Адаптер передает этой системе исходные изображения с фотокамеры БПЛА и возвращает готовые геопривязанные ортофотопланы для последующей загрузки в сервис Инференса моделей глубокого обучения.
- Система подсчета фитомассы деревьев и оценки углеродного бюджета FORRUS-S [131] - специализированная система, предназначенная для оценки запасов сухостоя и моделирования его вклада в фитомассу и углеродный бюджет лесных экосистем. Она использует результаты мультиклассификации деревьев на изображениях, полученные в СКЗ, включая пространственное распределение усыхающих деревьев, а также их таксационные характеристики. На основе этих данных система выполняет расчёт объёмных запасов древесины сухостоя и их перевод в показатели фитомассы и углерода с использованием ряда аллометрических и эколого-физиологических моделей. Это позволяет получать количественную оценку вклада сухостоя в бюджет последующих выбросов углерода в атмосферу. Интеграция системы FORRUS-S с СКЗ осуществляется через специализированный адаптер, который передает во внешнюю систему векторные слои и атрибутивные данные о

сухостое, а после выполнения расчётов возвращает в СКЗ оценки запасов фитомассы сухостоя и прогнозируемых углеродных выбросов, используемых при формировании аналитических отчётов.

Архитектура СКЗ с использованием адаптеров делает ее открытой и расширяемой системой. По мере появления новых технологий обработки данных ДЗЗ, методов анализа изображений или специализированных информационных систем для лесного хозяйства соответствующие внешние системы могут быть интегрированы в общий рабочий процесс СКЗ путем разработки новых адаптеров без необходимости модификации существующих компонентов СКЗ. Это обеспечивает долгосрочную перспективу развития системы и возможность ее адаптации к изменяющимся требованиям практики лесопатологического мониторинга хвойных лесов.

4.4 Интерфейс пользователей СКЗ

Эффективность использования СКЗ в практике лесопатологического мониторинга в значительной степени будет определяться качеством пользовательского интерфейса. Несмотря на сложность внутренней архитектуры ПО СКЗ и применение сложных современных методов глубокого обучения, конечный пользователь должен иметь возможность работать с СКЗ без глубоких знаний в области программирования или машинного обучения. В соответствии с требованиями группы I в п.4.1.2 и концепцией построения СКЗ на базе ГИС QGIS, пользовательский интерфейс должен обеспечивать:

- интуитивно понятный доступ ко всем функциям системы через единое рабочее пространство;
- визуализацию пространственных данных о местоположении хвойных деревьев и результатов анализа на электронных картах;
- прозрачность выполнения вычислительных процессов с информированием пользователя о ходе выполнения этапов (операций);

- возможность ручной коррекции результатов автоматической обработки и анализа изображений;
- гибкость в настройке параметров анализа изображений и иных данных в зависимости от специфики решаемых задач.

СКЗ лесопатологического мониторинга

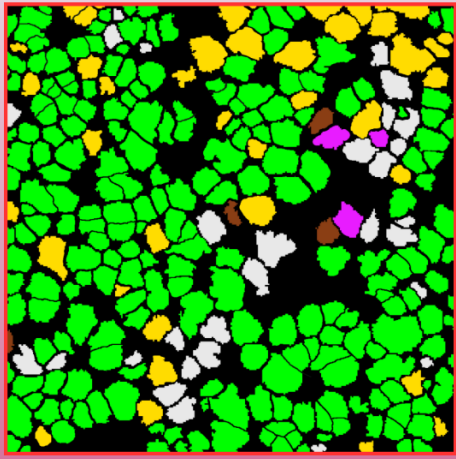
ОСНОВНЫЕ ПРОЦЕССЫ

- Загрузка данных БПЛА
- Мультиклассификация
- Анализ динамики
- Обнаружение очагов
- Фитомасса и Углеродный бюджет
- Формирование отчетов

УПРАВЛЕНИЕ ПРОЕКТАМИ

- Создать проект
- Загрузить проект
- Управление слоями
- Настройки анализа
- Администрирование

РАБОЧАЯ ОБЛАСТЬ



Цвет	Состояние
Зеленый	Условно здоровое
Желтый	Свежезаселенное
Корич.	С усохшей вершиной
Фиолет.	Свежий сухой
Серый	Старый сухой
Черный	Фон

РЕЗУЛЬТАТЫ

Состояние	Количество деревьев	Площадь (м2)
Условно здоровое	217	1333.57
Свежезаселенное	39	821.56
С усохшей вершиной	4	59.96
Свежий сухой	3	71.35
Старый сухой	29	531.18
Фон	-	4182.38
Итого	292	10000

Экспорт результатов
Построить отчет

Рисунок 4.3 – Интерфейс главной страницы СКЗ

В соответствии с этими требованиями на этапе проектирования был разработан концептуальный эскиз пользовательского интерфейса СКЗ. На рисунке 4.3 представлен эскиз интерфейса главной страницы системы, реализованной в виде специализированного плагина для ГИС QGIS. Интерфейс организован по принципу функциональных областей, каждая из которых обеспечивает доступ к определенной группе возможностей системы и включает четыре основных элемента (рисунок 4.3): панель запуска бизнес-процессов или технологий (загрузка и пре-

доработка данных с БПЛА, мультиклассификация изображений, анализ динамики жизненных состояний деревьев и т.д.), панель управления проектами и данными, картографическую рабочую область для визуализации результатов мультиклассификации и панель результатов анализа и статистики с инструментами экспорта данных.

При работе с любыми пространственными объектами (отдельными деревьями, полигонами очагов размножения вредителей, границами участков мониторинга) поддерживаются все базовые операции CRUD (англ. Create, Read, Update, Delete): чтение атрибутивной информации о таких объектах через инструменты идентификации и просмотра таблиц; редактирование результатов мультиклассификации при выявлении ошибок автоматической сегментации с изменением класса жизненного состояния дерева и т.д.

4.5 Модель базы данных СКЗ

При формировании концептуальной модели и последующей структуры базы данных (БД) СКЗ был определен перечень сущностей (объектов), которые следует описать и использовать в модели БД. Среди наиболее значимых из них можно отметить: Пользователь, Проект мониторинга, Лесной участок, Дерево, Класс жизненного состояния, Модель классификации, Очаг размножения вредителя, Матрица переходов состояний. В качестве примера рассмотрим атрибуты некоторых сущностей. Атрибутами сущности Дерево являются следующие данные о каждом хвойном дереве: уникальный идентификатор, координаты в используемой системе координат, порода дерева (*A. sibirica*, *P. sibirica*), код класса жизненного состояния, дата проведения мультиклассификации, идентификатор использованной модели классификации. Для сущности Очаг размножения вредителя предусмотрены атрибуты: уникальный идентификатор очага, геометрический контур зоны поражения, вид вредителя (уссурийский полиграф, союзный короед), площадь очага в м², дата обнаружения, идентификатор пользователя, обнаружившего очаг. Каждый атрибут у сущности имеет определенный домен и тип: целочисленный, числовой с плавающей точкой, дата-время, текстовый, гео-

метрический, логический, JSON для хранения структурированных данных. Также разработаны справочники и классификаторы: справочник пород деревьев, справочник насекомых-вредителей, классификатор жизненных состояний хвойных деревьев.

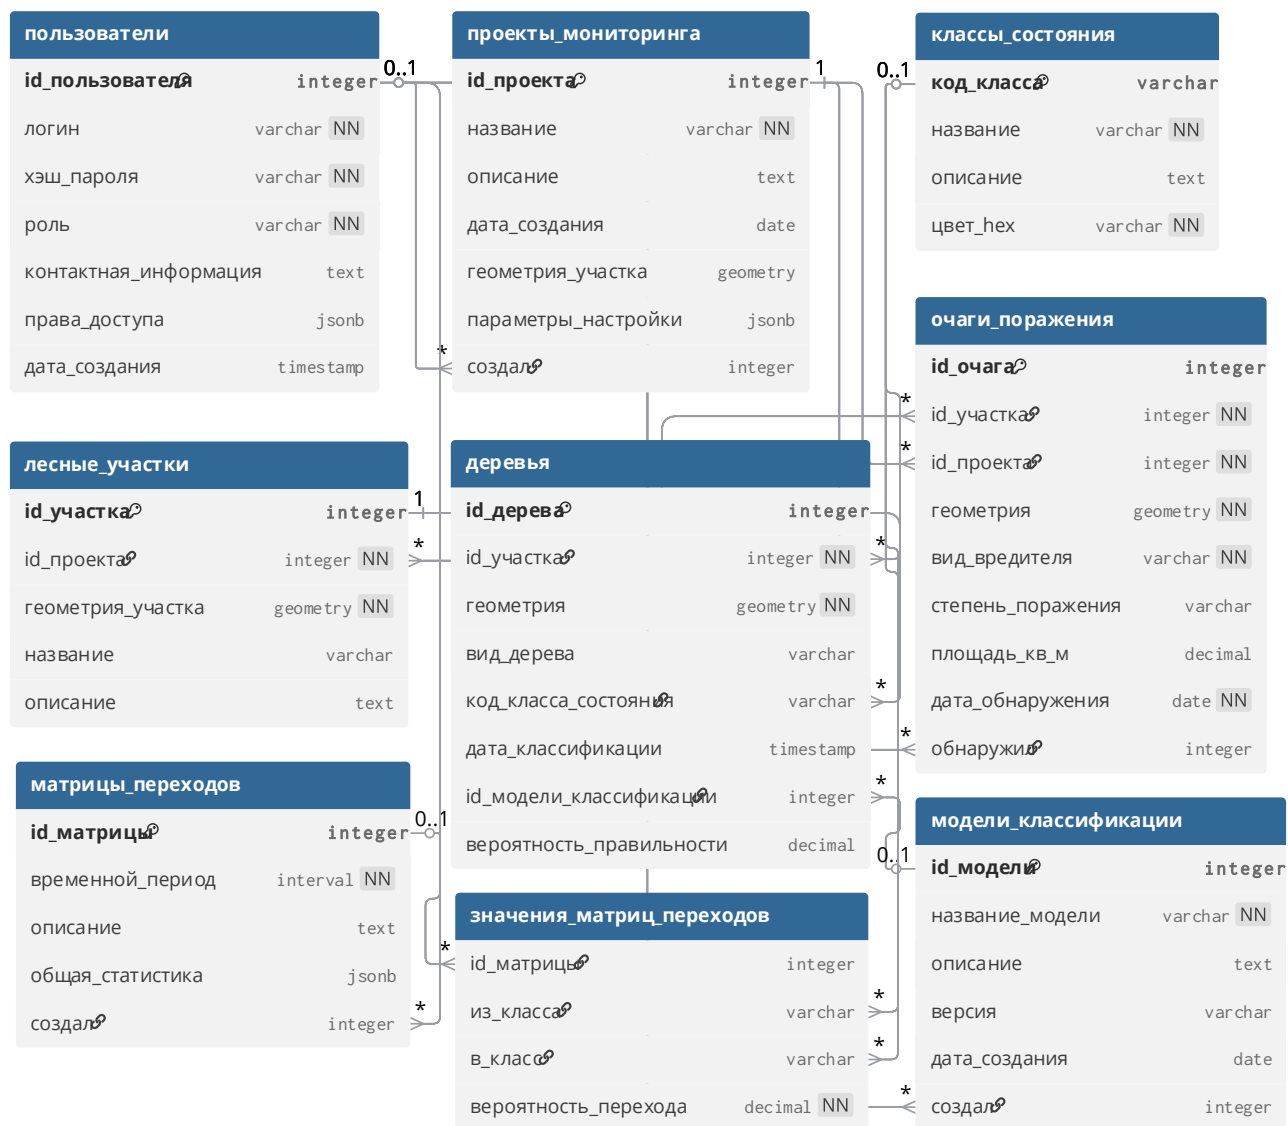


Рисунок 4.4 – Фрагмент концептуальной модели данных БД системы

ER-модель (англ. Entity-Relationship) БД была создана с использованием языка DBML (англ. Database Markup Language). Ее фрагмент представлен на рисунке 4.4. В соответствии с правилами формирования таких схем моделей данных связи между сущностями указываются явным образом через ссылочные ограничения (англ. foreign keys). Связи многие-ко-многим, например, такие как связь между сущностями Матрица переходов состояний и Класс жизненного со-

стояния, преобразуются путем формирования промежуточной сущности «Значения матрицы переходов».

Разработанная концептуальная модель позволила сформировать код SQL (англ. Structured Query Language) и затем развернуть физическую модель данных в среде выбранной СУБД PostgreSQL с пространственным расширением PostGIS.

4.6 Нейросетевые технологии на основе СКЗ

Ниже описываются нейросетевые технологии, разработанные на основе СКЗ и, если это требуется, с использованием внешних информационных систем. Под нейросетевой технологией понимается выполнение формализованной последовательности сервисов и иных программных модулей СКЗ (процедур, операций), реализующей заданный бизнес-процесс (часто говорят, технологический процесс) и дающей требуемый результат.

4.6.1 Технологии мультиклассификации жизненных состояний хвойных деревьев

Эти нейросетевые технологии обеспечивают автоматизированную предобработку исходных изображений хвойных деревьев высокого и сверхвысокого разрешения, получаемых с БПЛА или КА, автоматическую мультиклассификацию предварительно подготовленных и разрезанных на фрагменты изображений хвойных деревьев и постобработку полученных при мультиклассификации масок сегментации. Таких технологий разработано шесть, поскольку используются три модели глубокого обучения (At-Mo-U-Net, Res-Mo-U-Net и Segformer+) и каждая из моделей учитывает породу хвойных деревьев (пихта или кедр) через задание числа классов жизненных состояний деревьев. Для реализации требуемой специалисту технологии используется один из шести сервисов, входящих в составной веб-сервис Инференса моделей. Итак, каждая из шести технологий реализует крупный бизнес-процесс, состоящий из трех подпроцессов: предобработки исходных изображений, мультиклассификации подготовленных изображений и постобработки полученных в результате мультиклассификации масок сегментации.

Формализованное описание технологий в нотации BPMN приведено на рисунке 4.5. Управление этим бизнес-процессом осуществляет система BPMS.

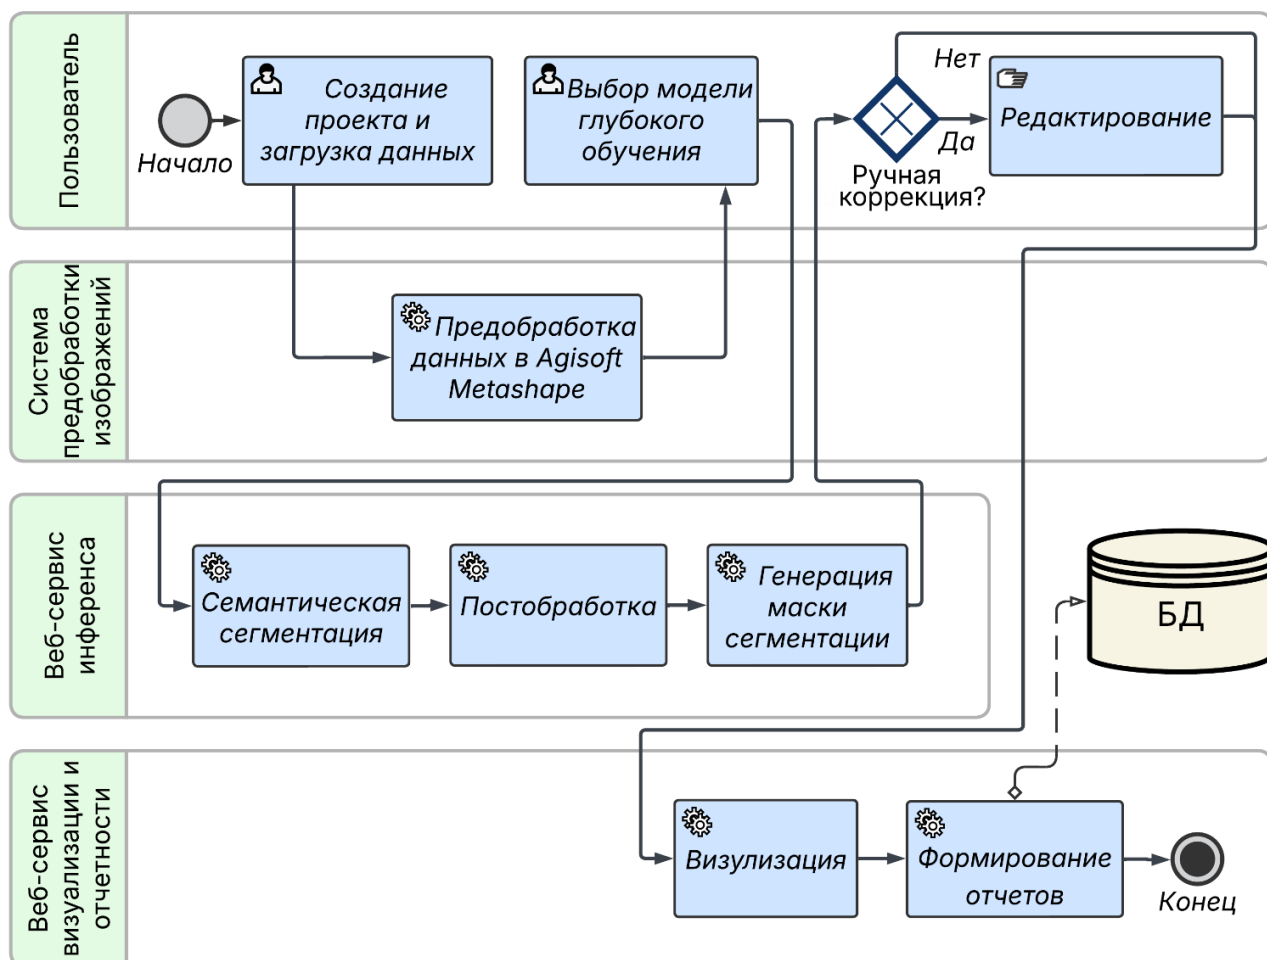


Рисунок 4.5 – BPMN-диаграмма технологии (бизнес-процесса) мультиклассификации жизненных состояний хвойных деревьев

При реализации каждой технологии используются входные данные: RGB-изображения участков хвойного леса, полученные с БПЛА или КА, с пространственным разрешением не хуже 0,1 м/пиксель в формате GeoTIFF с корректной геопривязкой. В результате применения технологии получаем следующие выходные данные: прошедшие постобработку маски сегментации в виде векторных слоев с контурами крон деревьев и атрибутами классов их жизненных состояний (формат Shapefile), растровые маски сегментации (GeoTIFF), статистические отчеты по распределению хвойных деревьев заданной породы по классам жизненных состояний (PDF, CSV, XLSX), тематические карты с цветовым кодированием классов.

Опишем подробнее технологию (бизнес-процесс), следуя BPMN-диаграмме на рисунке 4.5.

1. Загрузка исходных данных. Специалист-лесопатолог через панель управления проектами и данными (см.п.4.4) создает новый проект мониторинга, используя функцию создания нового проекта. В диалоговом окне он задает параметры проекта: название, географические границы исследуемого участка, породу хвойных деревьев и систему координат для описания используемых пространственных данных. После этого он нажимает кнопку «Загрузка данных БПЛА» на панели основных бизнес-процессов, что инициирует процесс импорта исходных изображений. Система сохраняет метаданные проекта в БД, поддерживаемой СУБД.
2. Предварительная обработка изображений. После загрузки изображений сервисная шина ESB автоматически передает их через адаптер во внешнюю систему предобработки Agisoft Metashape. Там выполняются радиометрическая коррекция, выравнивание снимков и построение ортофотопланов. Пользователь может наблюдать за процессом через интерфейс. Подготовленные геопривязанные ортофотопланы возвращаются в СКЗ и становятся доступны в рабочей области на картографическом окне, где специалист может включить/отключить их отображение через инструменты управления слоями карты.
3. Специалист нажимает кнопку «Мультиклассификация» на панели основных бизнес-процессов мониторинга. Открывается диалоговое окно выбора модели глубокого обучения, где представлены три варианта: At-Mo-U-Net, Res-Mo-U-Net или Segformer+ для каждой породы деревьев (пихта, кедр). Система предоставляет справочную информацию о характеристиках каждой из шести моделей (точность, скорость обработки). Специалист выбирает подходящую модель в зависимости от породы деревьев и требований к точности и скорости обработки для текущего проекта.
4. После выбора модели система через ESB инициирует обращение к нужному сервису веб-сервиса Инференс моделей. Сервис загружает выбранную модель

из репозитория, разбивает ортофотоплан на перекрывающиеся фрагменты размером 480×480 пикселей (конкретный размер фрагментов следует выбирать в соответствии с доступными вычислительными ресурсами) и выполняет их попиксельную мультиклассификацию. Пользователь может наблюдать за прогрессом обработки. Результаты сегментации фрагментов объединяются в единую маску с учетом перекрытий методом усреднения вероятностей классов.

5. Постобработка результатов мультиклассификации. Система автоматически применяет к полученной маске в соответствии с п.2.3 фильтрацию крон деревьев по критерию минимальной площади, морфологические операции для сглаживания контуров крон и т.д. Затем выполняется векторизация растровой маски сегментации, при этом создается полигональный объект для кроны каждого дерева. Каждому объекту - полигону присваиваются атрибуты: класс жизненного состояния, площадь кроны и координаты. Результаты становятся доступны как векторный слой.
6. Сервис визуализации на основе ГИС QGIS отображает результаты мультиклассификации и постобработки в рабочей области интерфейса. На интерактивную карту наносятся деревья с цветовым кодированием классов жизненных состояний в соответствии с принятой легендой. Специалист может масштабировать карту для детального изучения отдельных частей исследуемого участка, перемещаться по его территории с помощью стандартных инструментов навигации QGIS, получать подробную атрибутивную информацию об отдельных деревьях через инструмент идентификации объектов. На панели результатов и статистики автоматически формируются количественные показатели: сводная статистика по классам (количество деревьев, занимаемая ими площадь в гектарах и т.п.).
7. Ручная коррекция. При необходимости специалист может внести исправления в результаты автоматической мультиклассификации непосредственно в рабочей области, используя инструменты редактирования векторных слоев QGIS. Доступны операции: изменение класса дерева, добавление пропущенных де-

ревьев или удаление ошибочно идентифицированных объектов. Все изменения автоматически фиксируются в БД с указанием автора и времени модификации.

8. Формирование отчетов. Специалист нажимает кнопку «Построить отчет» на панели результатов и статистики, что инициирует обращение к сервису визуализации и отчетности. Система генерирует комплексный итоговый документ в формате PDF, включающий тематические карты, диаграммы распределения деревьев по классам жизненных состояний, статистические таблицы и текстовые пояснения. Для экспорта данных во внешние системы специалист использует кнопку «Экспорт результатов», которая позволяет сохранить векторные слои в формате Shapefile, а статистические данные – в форматах CSV и XLSX.

4.6.2 Технология обнаружения очагов размножения уссурийского полиграфа

Данная нейросетевая технология обеспечивает автоматизированное выявление очагов размножения уссурийского полиграфа в пихтовых лесах. В технологии используется сервис, реализующий метод обнаружения очагов размножения уссурийского полиграфа. Для запуска технологии необходимы следующие входные данные: результаты мультиклассификации деревьев пихты на изображении исследуемого участка, значение параметра N естественного отпада деревьев (%), интервальные значения площади в m^2 крон для категоризации деревьев пихты по возрасту (S_0, S_1, S_2), координаты исследуемого участка площадью 1 га. В результате исполнения технологии будут получены выходные данные: сообщения-выводы о наличии/отсутствии очага для каждой возрастной категории деревьев, в случае наличия очага векторные слои карты с границами обнаруженного очага размножения уссурийского полиграфа (формат Shapefile) и статистический отчет по обнаруженному очагу (CSV, XLSX) с визуализацией очага на тематической карте.

Кратко опишем технологию (бизнес-процесс), следуя ее BPMN-диаграмме на рисунке 4.6.

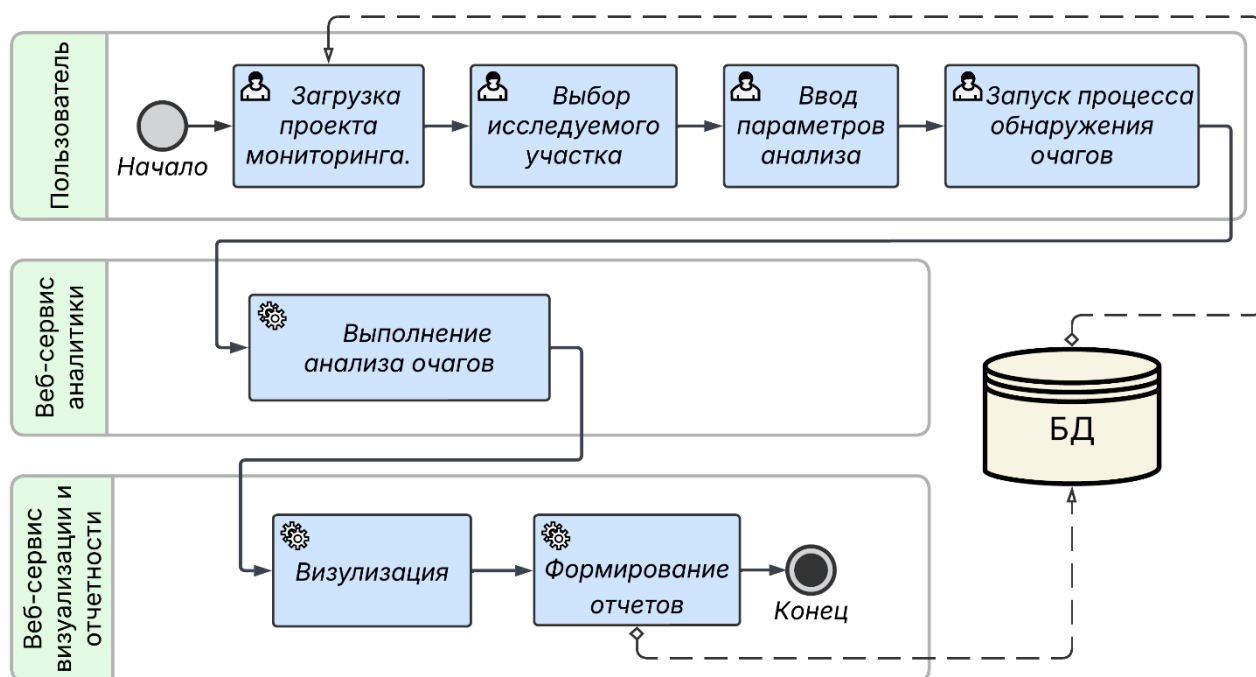


Рисунок 4.6 – BPMN-диаграмма технологии (бизнес-процесса) обнаружения очага размножения уссурийского полиграфа

1. Загрузка проекта мониторинга. Специалист-лесопатолог через панель управления проектами и данными загружает существующий проект мониторинга пихтовых лесов, содержащий также результаты мультиклассификации деревьев пихты на изображениях. Система восстанавливает предыдущую сессию работы нейросетевой технологии мультиклассификации со всеми настройками, загруженными исходными данными и результатами мультиклассификации из базы данных.
2. Выбор исследуемого участка. Специалист на интерактивной карте выбирает исследуемый участок пихтарника площадью 1 га и вводит его координаты через интерфейс системы.
3. Ввод параметров анализа. Специалист для запуска технологии вводит перечисленные выше входные данные: значения параметра N – относительного естественного отпада деревьев пихты в %, присущего данной лесной экосистеме или региону, и интервальные значения площади кроны пихты S_0 , S_1 , S_2 для определения категории возраста деревьев пихты.
4. Запуск процесса обнаружения очагов. Специалист нажимает кнопку «Обнаружение очагов» на панели основных бизнес-процессов мониторинга. Си-

стема через ESB активирует соответствующий сервис обнаружения очагов размножения в веб-сервисе аналитики.

5. Выполнение анализа для обнаружения очагов. Сервис обнаружения очагов размножения загружает результаты мультиклассификации изображения выбранного участка и выполняет анализ маски сегментации для выявления очага размножения уссурийского полиграфа. По его результатам специалист получает сообщения-выводы о наличии/отсутствии очага для каждой возрастной категории деревьев
6. Отображение результатов на карте. В случае наличия очага сервис визуализации на основе ГИС QGIS отображает его в векторном слое выявленных очагов размножения в рабочей области интерфейса. Для этого на интерактивную карту наносятся границы вновь обнаруженного очага. Специалист может управлять отображением векторного слоя очагов поражения через инструменты управления слоями карты (включать/отключать отображение), а также масштабировать карту для детального изучения отдельных участков с обнаруженными очагами и перемещаться по территории исследуемого участка с помощью стандартных инструментов навигации ГИС QGIS.
7. Формирование отчетов. Нажатием кнопки «Построить отчет» на панели результатов и статистики инициируется обращение к сервису визуализации и отчетности. Система генерирует комплексный итоговый документ в формате PDF, включающий тематические карты с визуализацией очагов, таблицы с данными об обнаруженных очагах и текстовые пояснения с выводами о наличии очагов для каждой возрастной категории деревьев пихты. Для экспорта данных во внешние системы специалист использует кнопку «Экспорт результатов». Это позволяет сохранить векторные слои с данными об очагах в формате Shapefile, а статистику – в форматах CSV и XLSX.

4.6.3 Технология анализа динамики жизненных состояний хвойных деревьев в очагах размножения вредителей

Эти две нейросетевые технологии предназначены для выявления и количественной оценки изменений (динамики) жизненных состояний хвойных деревьев в очаге размножения вредителей путем сравнения результатов мультиклассификации разновременных изображений участка, содержащего очаг. Основой технологий являются два сервиса, реализующие метод и его модификацию для анализа динамики жизненных состояний хвойных деревьев. Исходными данными для технологий служат результаты мультиклассификации (маски сегментации в виде векторных слоев) хвойных деревьев на двух и более разновременных изображениях, полученных при проведении нескольких (не менее двух) сеансов мониторинга участка леса с очагом. Получаемые с помощью технологий результаты: матрицы переходов состояний по количеству деревьев (в случае первой технологии) или по площади крон деревьев (вторая технология) в виде таблиц CSV, XLSX; Sankey-диаграммы визуализации переходов (PNG, PDF) и аналитические отчеты с оценками динамики жизненных состояний древостоев.

Кратко опишем технологию (бизнес-процесс), представленную в виде BPMN-диаграммы на рисунке 4.7.

1. Загрузка проекта и запуск анализа динамики. Специалист-лесопатолог через панель управления проектами и данными загружает существующий проект мониторинга, содержащий интересующие его результаты мультиклассификации изображений за несколько сеансов мониторинга участка с очагом размножения вредителей. Система восстанавливает требуемую сессию работы со всеми настройками, загруженными данными и результатами мультиклассификации из БД. Специалист нажимает кнопку «Анализ динамики» на панели основных бизнес-процессов мониторинга и выбирает соответствующий сервис для анализа динамики из веб-сервиса аналитики. СКЗ активирует требуемый сервис (запускает выполнение первой или второй технологии).

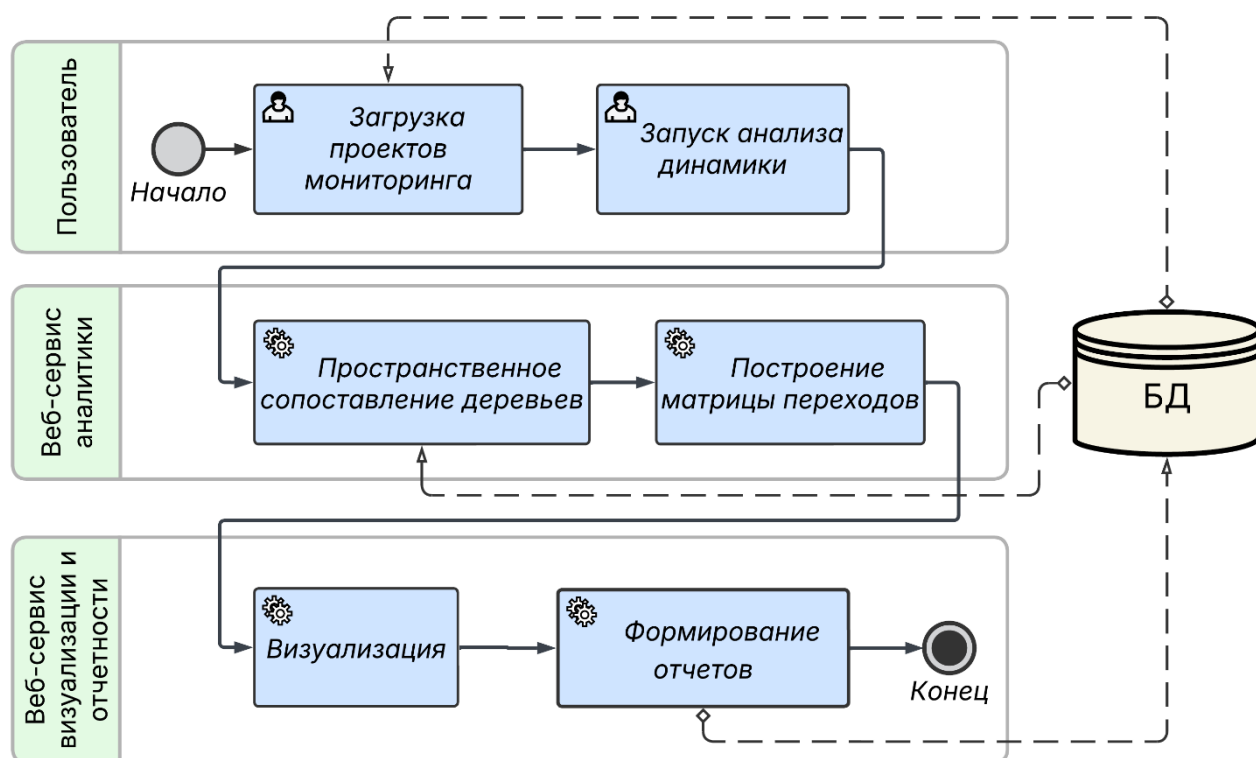


Рисунок 4.7 – BPMN-диаграмма технологии (бизнес-процесса) анализа динамики жизненных состояний хвойных деревьев

2. Пространственное сопоставление деревьев. Сервис извлекает из БД маски сегментации в виде векторных слоев для выбранных ранее сеансов мониторинга и выполняет пространственное сопоставление объектов путем анализа перекрытия их геометрий. Деревья считаются идентичными, если центроиды их крон расположены на расстоянии менее 2 м друг от друга.
3. Построение матрицы переходов. Для каждого хвойного дерева, идентифицированного на обеих масках, сервис определяет предыдущий (исходный) класс жизненного состояния и текущий класс. Подсчитывается количество деревьев для каждой комбинации «предыдущий класс → текущий класс» и в итоге формируется матрица переходов жизненных состояний. Если специалист выбрал сервис, реализующий модификацию метода анализа динамики, то ведется расчет матрицы переходов жизненных состояний путем оценки изменений площади крон деревьев по классам состояний. Затем выбранный сервис вычисляет доли переходов в текущие состояния для каждого исходного класса состояний и определяет скорость переходов состояний между классами.

4. Визуализация результатов. Сервис визуализации строит Sankey-диаграммы, на которых ширина потоков пропорциональна количеству деревьев (для первой технологии) или ширина потоков пропорциональна площади кроны деревьев (для второй технологии), перешедших из исходного класса в различные текущие классы жизненных состояний. На панели результатов и статистики также отображается искомая матрица переходов в табличном виде и таблица скоростей переходов состояний. Специалист может использовать инструмент для просмотра и анализа матрицы переходов и таблицы скоростей. Кроме того, в рабочей области с помощью средств визуализации ГИС QGIS можно включить наложение и совместное отображение результатов классификации разновременных изображений (масок сегментации) через инструменты управления слоями карты для визуального анализа динамики лесопатологической ситуации.
5. Формирование отчетов. Специалист нажимает кнопку «Построить отчет» на панели результатов и статистики, что инициирует обращение к сервису визуализации и отчетности. Система генерирует комплексный отчет в формате PDF, включающий тематические карты, матрицу переходов, Sankey-диаграмму, таблицу скоростей переходов и текстовые интерпретации выявленных закономерностей (если вводились специалистом). Для экспорта данных во внешние системы или передачи заинтересованным организациям специалист использует кнопку «Экспорт результатов», которая позволяет сохранить векторные слои и аналитические данные в стандартных форматах.

4.6.4 Технология оценки фитомассы сухостоя и углерода в ней

Данная технология предназначена для решения третьей задачи лесопатологического мониторинга хвойных насаждений – выявления сухостоя и оценки его фитомассы и вклада в бюджет выбросов углерода в атмосферу. Технология основана на СКЗ, интегрированной с внешней специализированной системой FORRUS-S, предназначенной для расчёта запасов древесной фитомассы и углерода в ней на локальном уровне. Выбор системы FORRUS-S обусловлен требо-

ванием с ее стороны минимального числа входных параметров и возможностью получения их значений при лесотаксационных измерениях и (или) путем косвенной оценки значений на основе данных ДЗЗ.

Входные данные для технологии: результаты мультиклассификации хвойных деревьев по классам жизненных состояний «Свежий сухостой» и «Старый сухостой», таксационные характеристики насаждения (породный состав, объем ствола, средняя фитомасса хвойного дерева каждого класса и т.д.). Выходные данные: оценки запасов древесной фитомассы и углерода в ней для каждого из классов «Свежий сухостой» и «Старый сухостой», оценки годовой эмиссии углерода от разложения сухостоя, аналитические отчеты с прогнозными оценками динамики углеродного баланса (PDF, CSV, XLSX).

Исполнение технологии представлено в виде бизнес-процесса, формализованного в нотации BPMN и управляемого системой BPMS. Кратко опишем технологию (бизнес-процесс), представленную в виде BPMN-диаграммы на рисунке 4.8.

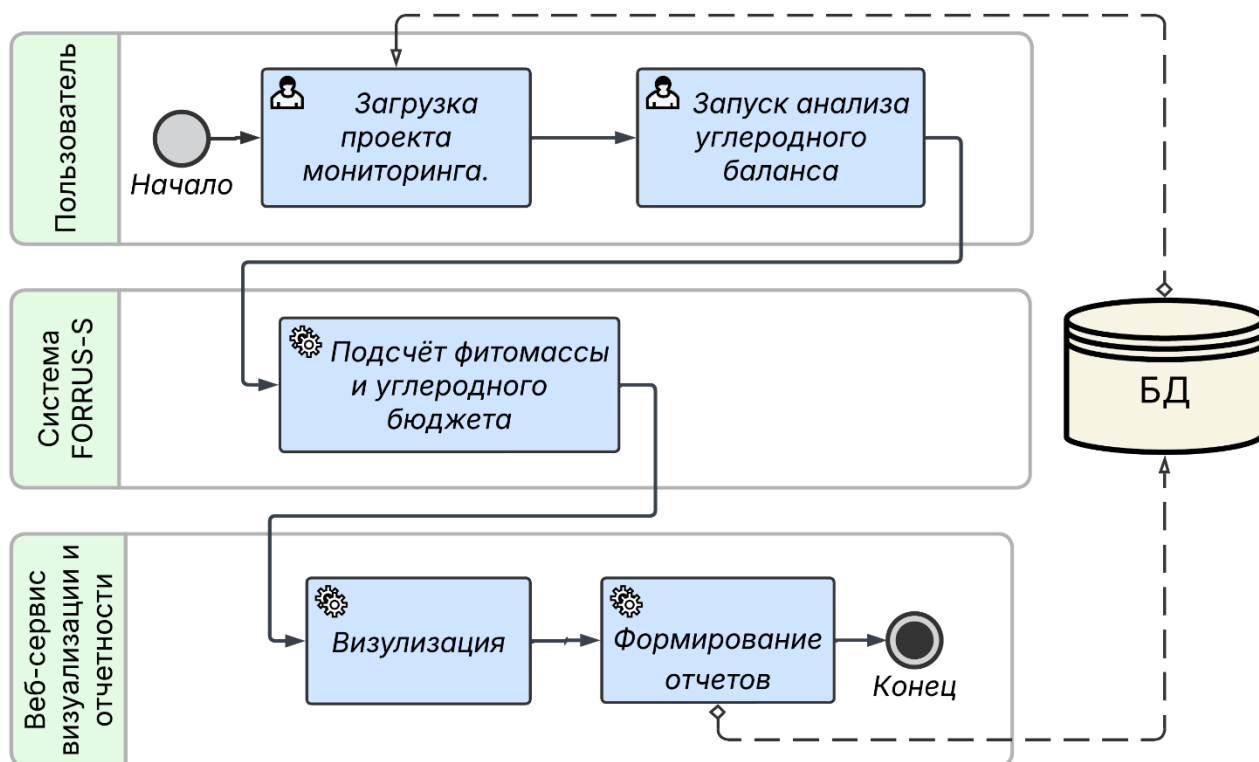


Рисунок 4.8 – BPMN-диаграмма технологии (бизнес-процесса) оценки фитомассы и углерода в ней

1. Специалист-лесопатолог через панель управления проектами загружает существующий проект лесопатологического мониторинга, содержащий результаты мультиклассификации хвойных деревьев на изображении выбранного участка, полученном путем съёмки с помощью БПЛА. Система восстанавливает предыдущую сессию работы со всеми настройками, векторными слоями и иными результатами мультиклассификации.
2. Подготовка данных для передачи во внешнюю систему. После выбора специалистом бизнес-процесса «Фитомасса и углеродный бюджет» СКЗ инициирует обращение к внешней системе FORRUS-S через адаптер интеграции для последующего выполнения с ее помощью оценки запасов фитомассы сухостоя и его вклада в выбросы углерода в атмосферу. После этого адаптер интеграции с системой FORRUS-S извлекает из БД результаты мультиклассификации изображения выбранного участка в виде векторных слоев, содержащих пространственное распределение сухостойных деревьев, классифицированных как «Свежий сухостой» и «Старый сухостой», и иные атрибуты таких деревьев. Далее обеспечивается переход от результатов нейросетевой мультиклассификации изображений к результатам лесотаксационных измерений: для каждого хвойного дерева из этих двух классов из БД извлекаются значения таксационных характеристик, необходимых для выполнения оценки запасов его фитомассы.
3. Передача данных во внешнюю систему FORRUS-S. Подготовленные пространственные и атрибутивные данные по каждому дереву передаются из СКЗ через адаптер во внешнюю систему FORRUS-S.
4. Оценки запасов углерода и эмиссии его при разложении сухостоя. По полученным из СКЗ данным в системе FORRUS-S выполняется расчет запасов углерода отдельно для свежего и старого сухостоя. Запас углерода определяется путем умножения предварительно вычисленной средней сухой фитомассы (биомассы) одного дерева на количество деревьев каждого класса с учетом массовой доли углерода в сухой биомассе, принимаемой равной 0,5 для деревьев хвойных пород. Затем для каждого класса состояний «Свежий сухостой»

и «Старый сухостой» дополнительно рассчитывается годовая эмиссия углерода, обусловленная процессами разложения древесины.

5. Визуализация результатов. Результаты расчетов передаются в СКЗ, сохраняются в ее БД и автоматически отображаются на панели результатов и статистики в табличном и графическом виде. Специалист получает возможность анализировать оценки запасов углерода в свежем и старом сухостое и величины годовой эмиссии углерода от разложения древесины. Дополнительно отображаются диаграммы распределения углерода по классам сухостоя.
6. Формирование отчетов. По запросу специалиста система формирует комплексный аналитический отчет в формате PDF, содержащий оценки запасов фитомассы и углерода в свежем и старом сухостое, величины годовой эмиссии и т.д. Для последующего анализа или передачи данных во внешние информационные системы предусмотрен экспорт расчетных показателей в форматах CSV и XLSX.

4.7 Апробация нейросетевых технологий при решении лесопатологических задач

Разработанная СКЗ и реализованные на ее основе нейросетевые технологии прошли апробацию на реальных данных дистанционного мониторинга хвойных лесов. Целью ее являлась проверка работоспособности технологий и для ряда из них оценка их точности и производительности.

4.7.1 Апробация технологий мультиклассификации изображений

Для апробации технологий мультиклассификации жизненных состояний хвойных деревьев был выбран участок кедрового леса (2 га), расположенный рядом с участком, описанным в п.3.8, вблизи села Белоусово Томской области. Для него имеется RGB-изображение разрешения 0,08 м, полученное летом 2023 г. с использованием фотокамеры, установленной на БПЛА DJI Phantom 4 Pro.

Исходное изображение было загружено в СКЗ, а затем по запросу в соответствии с апробируемой технологией автоматически передано через адаптер во

внешнюю систему предварительной обработки изображений Agisoft Metashape. В ней выполнена его радиометрическая коррекция и построен ортофотоплан. Полученный геопривязанный ортофотоплан (рисунок 4.9а) был импортирован обратно в СКЗ и сохранен в БД.

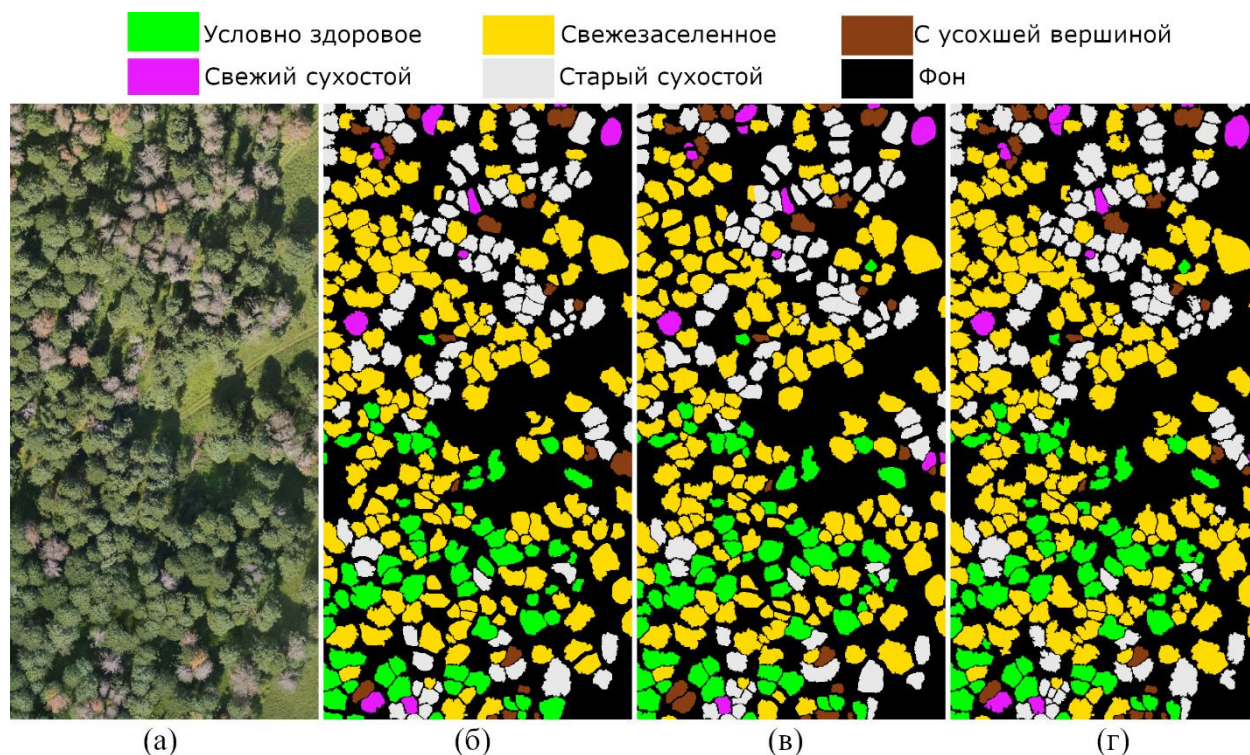


Рисунок 4.9 – Результаты семантической сегментации изображения изучаемого участка *P. sibirica* 2023 г.: (а) Изображение изучаемого участка; (б) Модель At-Mo-U Net; (в) Модель Res-Mo-U-Net; (г) Модель Segformer+

Для выполнения семантической сегментации фрагментов ортофотоплана через интерфейс СКЗ были последовательно применены три технологии, в которых в виде сервисов реализованы модели At-Mo-U-Net, Res-Mo-U-Net и Segformer+. Результаты попиксельной мультиклассификации в виде маски семантической сегментации для каждой из моделей показаны на рисунке 4.9 б,в,г.

Полученные маски сегментации автоматически визуализируются в рабочей области интерфейса СКЗ. Для этого сервис визуализации и отчетности формирует векторные слои с выделенными контурами крон деревьев, которые затем сохраняются в БД. Визуальное сравнение результатов работы трех технологий (рисунок 4.9) показывает высокую степень согласованности в выделении крон и классификации состояний деревьев кедра. При этом наблюдаются некоторые раз-

личия в детализации контуров крон и классификации отдельных крон. В качестве примера выполнения технологий в части количественного анализа результатов сегментации изображения приведем анализ результатов сегментации, полученных с помощью сервиса, реализующего модель Segformer+.

Таблица 4.3 – Результаты анализа маски сегментации

Состояние	Количество деревьев	Площадь (м ²)
Условно здоровое	62	1499,250
Свежезаселенное	168	4893,900
С усохшей вершиной	22	346,540
Свежий сухостой	11	264,990
Старый сухостой	96	2220,990
Фон	-	10774,320
Итого	359	20000




Рисунок 4.10 – Распределение количества деревьев и площади их крон по классам жизненных состояний

Результаты количественного анализа маски сегментации, выполненного сервисом аналитики СКЗ, представлены в таблице 4.3. Эта таблица автоматически отображается на панели результатов и статистики и позволяет специалисту-лесопатологу оперативно оценивать лесопатологическую обстановку на изучаемом участке. На рисунке 4.10 дано графическое представление этих же результатов в виде диаграмм распределения деревьев и площадей их крон по классам.

Получены также результаты по точности классификации жизненных состояний деревьев кедра по метрикам *IoUc* и *mIoU* с помощью каждой из технологий

в случаях использования фрагментов изображения размером $256 \times 256 \times 3$ пикселей и $480 \times 480 \times 3$ пикселей. Показано, что наиболее высокую точность для всех классов состояний дает технология на основе модели Segformer+. Отметим, что этот вывод аналогичен выводу, следующему из таблиц 3.6 и 3.7 в п.3.5, содержащих результаты исследований этих трех моделей в случае деревьев кедра, пораженных союзным короедом.

При апробации технологий мультиклассификации была также проведена оценка их производительности и времени выполнения отдельных этапов обработки и анализа изображения участка площадью 1 га. Для проведения экспериментов использовался персональный компьютер двух конфигураций: рабочая станция с GPU NVIDIA RTX 3080 10 GB, с оперативной памятью DDR5 16 GB и центральным процессором (англ. Central Processor Unit – CPU) Intel Xeon 2.4 GHz, а также компьютер без GPU. Эксперименты охватывали все ключевые этапы каждой технологии. Результаты оценок времени выполнения этапов и каждой технологии в целом получены для каждой конфигурации компьютера (с GPU или только CPU) и для случаев фрагментов изображения размером $256 \times 256 \times 3$ пикселей и $480 \times 480 \times 3$ пикселей и представлены в таблице 4.4.

Анализ результатов из таблицы 4.4 показывает, что каждая из технологий мультиклассификации даже на компьютере без GPU демонстрирует высокую производительность как при обработке и анализе фрагментов размером $256 \times 256 \times 3$ пикселей, так и размером $480 \times 480 \times 3$ пикселей. Наибольшее время выполнения – 203,74 с требуется для технологии на основе модели Segformer+ в случае фрагментов размером $256 \times 256 \times 3$ пикселей. При этом самую значительную часть времени (180 с) занимает этап предварительной обработки изображения. Отметим, что эти результаты апробации подтверждают результаты исследований предложенных моделей глубокого обучения по скорости вычислений (см. п.3.6) и соответствуют требованиям по производительности (скорости выполнения) СКЗ и технологий на ее основе, изложенным в п.1.6. Это указывает на возможность практического применения созданных СКЗ и нейросетевых техноло-

гий в производственных условиях на персональных компьютерах лесничеств и региональных центров защиты леса Рослесхоза.

Таблица 4.4 – Время выполнения этапов технологий мультиклассификации жизненных состояний деревьев кедр на изображении участка площадью 1 га

Этап	GPU 256×256×3 (с)	GPU 480×480×3 (с)	CPU 256×256×3 (с)	CPU 480×480×3 (с)
Загрузка исходных данных	0,500	0,500	0,500	0,500
Предварительная обработка	15,000	14,000	180,000	164,000
Инференс Segformer+	0,518	0,312	18,840	13,450
Инференс At-Mo-U-Net	0,436	0,253	15,700	11,286
Инференс Res-Mo-U-Net	0,292	0,182	10,510	10,380
Постобработка результатов	1,200	1,100	1,200	1,200
Визуализация и статистика	0,800	0,750	2,600	2,390
Формирование отчётов	0,600	0,600	0,600	0,600
ИТОГО (Segformer+), с	18,620	17,260	203,740	182,140
ИТОГО (At-Mo-U-Net), с	18,540	17,200	200,600	180,490
ИТОГО (Res-Mo-U-Net), с	18,390	17,130	195,410	179,070

4.7.2 Апробация технологий анализа динамики жизненных состояний хвойных деревьев

Ниже приведены результаты апробации нейросетевых технологий анализа динамики жизненных состояний хвойных деревьев. В качестве исходных данных были выбраны два изображения 2023 г. и 2025 г. участка кедрового леса площадью 1 га вблизи села Белоусово в Томской области, описанные в п.3.8. На этом участке по результатам мониторинга в 2023 г. зафиксирован очаг союзного коро-еда, а в результате наземного лесопатологического обследования в 2025 г. в очаге был обнаружен еще один вредитель – рыжий сосновый пилильщик. Учитывая комплексное негативное воздействие этих вредителей на деревья кедр, в п.3.8 была обоснована необходимость замены на изображении 2025 г. класса жизненного состояния «Свежеселенное» на класс «С признаками дефолиации».

Через интерфейс СКЗ специалист-лесопатолог инициировал запуск выбранной технологии анализа динамики, нажимая кнопку «Анализ динамики» на панели основных бизнес-процессов. В качестве входных данных при апробации технологий использовались результаты мультиклассификации (маски сегментации в виде векторных слоев) этих изображений. Однако при мультиклассификации изображений в отличие от модели Res-Mo-U-Net, использованной в п.3.8 при

проведении исследований разработанного метода анализа динамики, была применена модель Segformer+, дающая более высокую точность классификации. С такими входными данными запускались обе технологии анализа, и были получены две матрицы переходов. Первая из них построена на основе изменений количества деревьев в каждом классе жизненных состояний деревьев кедр (таблица 4.5), а вторая матрица была получена путем оценки изменений площади крон деревьев по классам состояний (здесь не приведена).

Таблица 4.5 – Матрица переходов жизненных состояний деревьев кедр, построенная по изменениям количества деревьев в классах состояний

Класс предыдущего (2023 г.) состояния	Класс последнего (2025 г.) состояния деревьев						Итого в 2023 г.
	Условно здоровое	С признаками дефолиации	С усохшей вершиной	Свежий сухостой	Старый сухостой	Фон	
Условно здоровое	1	84	46	4	65	24	224
Свежезаселенное	0	10	4	0	13	6	33
С усохшей вершиной	0	0	0	0	4	0	4
Свежий сухостой	0	0	0	0	3	0	3
Старый сухостой	0	0	0	0	22	6	28
Вновь появившееся (Фон)	0	10	7	0	12	0	-
Итого в 2025 г.	1	104	57	4	119	-	285/292

Анализ матрицы переходов в таблице 4.5 позволил выявить направления и скорость переходов между классами жизненных состояний деревьев кедр в очаге размножения вредителей. Например, из 224 деревьев класса «Условно здоровое», зафиксированных в 2023 г., лишь одно (0,4%) сохранило своё состояние к 2025 г., причем наибольшая часть деревьев перешла в классы состояний «С признаками дефолиации», «Старый сухостой» и «С усохшей вершиной», а 24 дерева выпали из учёта, перейдя в класс «Фон».

Для наглядной визуализации и удобства анализа матрицы переходов в технологии предусмотрено обращение к сервису визуализации и отчетности СКЗ. Он позволяет автоматически строить Sankey-диаграмму (рисунок 4.11), которая отображается на панели результатов и статистики пользовательского интерфейса. Например, в случае матрицы из таблицы 4.5 диаграмма указывает на преобладающие направления переходов: от классов «Условно здоровое» и «Свежезаселенное» к классам «С усохшей вершиной» и «Старый сухостой».




Рисунок 4.11 – Sankey-диаграмма переходов состояний деревьев кедр в период с 2023 г. по 2025 г.

Технология позволила на основе данных из таблицы 4.5 оценить скорости переходов между классами жизненных состояний деревьев кедр (таблица 4.6).

Таблица 4.6 – Скорость переходов между классами жизненных состояний деревьев кедр (по количеству деревьев), год⁻¹

Класс исходного (2023 г.) состояния	Класс конечного (2025 г.) состояния					
	Условно здоровое	С признаками дефолиации	С усохшей вершиной	Свежий сухостой	Старый сухостой	Фон
Условно здоровое	0,002	0,188	0,103	0,009	0,145	0,054
Свежезаселенное	0,000	0,152	0,061	0,000	0,197	0,091
С усохшей вершиной	0,000	0,000	0,000	0,000	0,500	0,000
Свежий сухостой	0,000	0,000	0,000	0,000	0,500	0,000
Старый сухостой	0,000	0,000	0,000	0,000	0,393	0,107

Анализ результатов из таблицы 4.6 показывает, что наибольшая скорость переходов, равная 0,500/год, отмечена при переходе деревьев кедр из классов состояний «С усохшей вершиной» и «Свежий сухостой» в класс «Старый сухостой». Кроме того, по результатам из таблицы 4.6 по формуле (2.17) был вычислен индекс деградации популяции кедр, который составил 44,54% в год. Отметим, что это значение равно значению индекса деградации в случае входных данных для анализа динамики в виде результатов мультиклассификации (эталонных масок сегментации), полученных экспертами для разновременных изображений этого же участка кедрового леса (см. п.3.8). В п.3.8 показано, что в случае модели Res-Mo-U-Net значение этого индекса отличается на 0,70 % от случая использования эталонных масок сегментации. Отсюда следует, что применение при

мультиклассификации изображений модели Segformer+ дает более высокую точность классификации и это позволяет технологии более точно вычислять матрицу переходов (таблица 4.5) и скоростей переходов между классами (таблица 4.6), чем в случае использования для вычисления матрицы переходов (таблица 3.13) и скоростей переходов (таблица 3.15) результатов мультиклассификации, полученных с помощью модели Res-Mo-U-Net. Более того, для дальнейшего сравнения результатов в таблицу 4.7 внесены разницы скоростей переходов между соответствующими классами из таблицы 4.6 и таблицы 3.20 для случая эталонных масок сегментации. По сути эти разницы значений являются абсолютными погрешностями вычисления скоростей, вносимыми недостаточной точностью классификации одновременных изображений с помощью модели Segformer+. Из таблицы 4.7 следует, что для ряда переходов скорости одинаковы, а абсолютные погрешности скоростей находятся в диапазоне от 0,001/год до 0,100 /год. Однако из таблицы 3.21 следует, что погрешности в случае использования модели Res-Mo-U-Net составляют от 0,002/год до 0,100 /год, то есть минимальная погрешность в два раза выше, чем в предыдущем случае. Это еще раз подчеркивает перспективность модели Segformer+ для повышения точности метода анализа динамики, и, соответственно, точности реализующих этот метод нейросетевых технологий.

Таблица 4.7 – Погрешности вычисления скоростей переходов между классами жизненных состояний деревьев кедра, год⁻¹

Класс исходного (2023 г.) состояния	Класс конечного (2025 г.) состояния					
	Условно здоровое	С признаками дефолиации	С усохшей вершиной	Свежий сухостой	Старый сухостой	Фон
Условно здоровое	0,000	0,001	0,007	0,000	0,013	0,001
Свежезаселенное	0,000	0,014	0,004	0,000	0,007	0,012
С усохшей вершиной	0,000	0,000	0,000	0,100	0,100	0,000
Свежий сухостой	0,000	0,000	0,000	0,000	0,000	0,000
Старый сухостой	0,000	0,000	0,000	0,000	0,003	0,003

Была также проведена оценка производительности технологий и времени выполнения отдельных их этапов для исследуемого участка площадью 1 га. Оценка выполнялась на том же компьютере, что применялся при апробации технологий мультиклассификации в п.4.7.1. Получено, что даже в конфигурации

компьютера без GPU технология анализа динамики по изменениям количества деревьев выполнялась за 7,2 с, а технология по изменениям площади крон деревьев – за 7,5 с, включая затраты времени на визуализацию результатов и формирование отчётов. Видим, что по производительности эти технологии отвечают со значительным запасом требованиям по скорости вычислений, изложенным в п.1.6.

Полученные результаты апробации подтвердили работоспособность реализованных технологий анализа динамики жизненных состояний хвойных деревьев и позволили выявить перспективность использования модели Segformer+ для повышения точности вычисления матриц переходов жизненных состояний, и, соответственно, скоростей переходов между классами этих состояний.

4.7.3 Апробация технологии оценки фитомассы сухостоя и углерода в ней

Важным направлением апробации разработанных нейросетевых технологий является апробация технологии оценки фитомассы сухостоя и углерода в ней на участке хвойного леса. Эта технология позволяет решать третью из основных задач лесопатологического мониторинга хвойных лесов. Цель апробации технологии не только получить оценки фитомассы и углерода в сухостое на конкретном участке леса, но и оценить работоспособность технологии, в том числе средств интеграции разработанной СКЗ с внешней специализированной системой FORRUS-S.

Для апробации технологии использовался участок деревьев пихты, пораженных уссурийским полиграфом, площадью 1 га. Этот участок входит в состав обследованного лесопатологами в 2017 г. большого участка пихтового леса, расположенного в Бакчарском районе Томской области. Специалисты провели наземные обследования и охарактеризовали большой участок как очаг размножения уссурийского полиграфа. Результаты наземного обследования, включая таксационные данные по деревьям пихты, изложены в работах [4,34,114]. Часть таксационных данных по деревьям пихты интересующего нас участка была введена нами в БД СКЗ. Большой участок также был отснят в августе 2017 г. с помощью

фотокамеры, установленной на БПЛА DJI Phantom 3 Standart. Полученные RGB-изображения имеют пространственное разрешение 0,1 м. Изображение интересующего нас участка площадью 1 га анализировалось с помощью нейросетевой технологии мультиклассификации жизненных состояний деревьев пихты на основе сервиса, реализующего модель Res-Mo-U-Net. При этом на вход подавались фрагменты этого изображения размером $480 \times 480 \times 3$ пикселей. Полученные результаты мультиклассификации были введены в БД СКЗ и служили наряду с таксационными данными входными данными для апробируемой технологии.

Специалист-лесопатолог, нажимая кнопку «Фитомасса и Углеродный баланс» на панели основных бизнес-процессов СКЗ, инициировал запуск апробируемой технологии. При этом передавался запрос адаптеру интеграции СКЗ с системой FORRUS-S. Адаптер извлек из БД результаты мультиклассификации и таксационные данные и передал их во внешнюю систему FORRUS-S. После выполнения расчетов система FORRUS-S через адаптер возвратила в СКЗ полученные оценки фитомассы и углерода на участке, а также среднюю фитомассу дерева пихты каждого из классов состояний «Свежий сухостой» и «Старый сухостой». Эти результаты были автоматически сохранены в БД и отображены на панели результатов и статистики пользовательского интерфейса СКЗ.

Таблица 4.8 – Запасы фитомассы и углерода в ней на участке пихтового леса площадью 1 га.

Показатель	Свежий сухостой	Старый сухостой	ИТОГО
Количество деревьев	39,000	63,000	102,000
Фитомасса, т	19,500	31,500	51,000
Запас углерода, т С	9,750	15,750	25,500
Годовая эмиссия, т С/год	0,097	0,470	0,570

В таблице 4.8 приведены основные результаты оценки фитомассы в тоннах и углерода в ней для деревьев пихты каждого из классов состояний «Свежий сухостой» и «Старый сухостой» и для участка в целом (последний столбец). Анализ их показывает, что на исследуемом участке преобладает класс «Старый сухостой», который составляет более 60% от общего числа сухостойных деревьев. Это свидетельствует о том, что процесс отмирания деревьев начался не менее 2–

3 лет назад, что соответствует характеру инвазии уссурийского полиграфа в пихтарниках Бакчарского района Томской области.

Несмотря на то, что фитомасса деревьев класса «Старый сухостой» составляет 61,8% от общей фитомассы сухостоя, вклад деревьев этого класса в годовую эмиссию углерода значительно выше – 82,9%. Это объясняется более высоким коэффициентом разложения (темпом разложения фитомассы) деревьев класса «Старый сухостой» (3% в год) по сравнению с деревьями класса «Свежий сухостой» (1% в год). Таким образом, деревья класса «Старый сухостой» являются с 2017 г. основным источником выбросов углерода в атмосферу на данном участке. Годовая эмиссия углерода в размере 0,57 т/год с участка пихтарника площадью 1 га указывает на существенный вклад сухостоя в углеродный баланс региона. Накопление мёртвой древесины создаёт не только экологические риски, связанные с выбросами углерода, но и повышает пожароопасность насаждения.

Результаты успешной апробации технологии оценки фитомассы сухостоя и углерода в ней подтверждают работоспособность как предложенной сервисно-ориентированной архитектуры СКЗ в целом, так и средств интеграции СКЗ с внешней системой FORRUS-S. Передача данных мультиклассификации и таксонометрии во внешнюю систему, выполнение с ее помощью расчета фитомассы сухостоя и возврат результатов в СКЗ для последующей визуализации и включения в отчеты соответствуют требованиям к СКЗ функциональной группы F и демонстрируют расширяемость разработанной системы для решения комплексных задач лесопатологического мониторинга.

4.8 Рекомендации по применению нейросетевых технологий

На основе результатов разработки и исследований моделей глубокого обучения, изложенных в разделах 2 и 3, а также результатов апробации нейросетевых технологий сформулирован ряд рекомендаций по эффективному применению этих технологий на практике.

4.8.1 Требования к съемке хвойных лесов и к исходным изображениям

Для достижения наилучшей эффективности нейросетевых технологий необходимо соблюдать ряд требований к съемке хвойных лесов и к предварительной обработке получаемых при этом изображений. Рассмотрим требования к съемке. Во-первых, она должна выполняться в летний период (июнь-август) при полном развитии ассимиляционного аппарата деревьев. Оптимальным временем суток для съемки является период с 11 до 15 часов по местному времени, когда солнце находится высоко над горизонтом и обеспечивается равномерное освещение крон без резких теней. Съемка в утренние или вечерние часы при низком положении солнца приводит к появлению протяженных теней, затрудняющих в последующем точное решение задачи мультиклассификации изображений хвойных деревьев. Съемка в пасмурную погоду с рассеянным освещением является предпочтительной, так как обеспечивает минимальные вариации освещенности в пределах кадра. Следует избегать съемки сразу после дождя при наличии капель воды на хвое, искажающих спектральные характеристики. Во-вторых, при съемке лесов с помощью БПЛА рекомендуется обеспечивать продольное перекрытие снимков не менее 75% и поперечное перекрытие не менее 65%. Это позволит получить качественные ортофотопланы без геометрических искажений и обеспечит более точную привязку изображений в выбранной системе координат.

Качество результатов при применении нейросетевых технологий зависит от качества исходных RGB-изображений. Весьма важным при этом является пространственное разрешение изображений. Минимальное необходимое пространственное разрешение исходных изображений составляет 0,05–0,15 м/пиксель, что достигается использованием типовых цифровых фотокамер с фокусным расстоянием 24–35 мм при высоте полета БПЛА 80–120 м над поверхностью леса. При разрешении изображений хуже 0,15 м/пиксель точность выделения контуров крон и классификации жизненных состояний деревьев существенно снижается. Для изображений хвойных лесов, полученных с КА, рекомендуется разрешение не хуже 0,50 м/пиксель, при этом следует учитывать, что точность классифика-

ции жизненных состояний деревьев в этих случаях будет ниже, чем при использовании изображений с камер БПЛА с указанным выше разрешением.

Все изображения должны проходить радиометрическую коррекцию для компенсации различий в условиях освещенности между отдельными изображениями и сеансами мониторинга. В используемой нами системе предварительной обработки Agisoft Metashape рекомендуется применять автоматическую калибровку цвета с выравниванием гистограмм. Для одновременных изображений, используемых при решении задач анализа динамики переходов состояний, важно обеспечить консистентность радиометрических характеристик изображений разных сеансов мониторинга. Рекомендуется использовать эталонные объекты известной отражательной способности, размещаемые в зоне съемки для нормализации яркостных характеристик.

Получаемые из исходных изображений ортофотопланы должны иметь точность геопривязки не хуже 0,3 м (величина среднеквадратической ошибки в принятой системе координат). При решении задач анализа динамики состояний деревьев требуется более высокая точность взаимной привязки одновременных изображений (не хуже 3 м), что обеспечивает корректное пространственное сопоставление деревьев при построении матриц переходов. Необходимо использовать наземные опорные точки, координаты которых определены методами геодезических измерений, или RTK-GPS. Ортофотопланы должны сохраняться в формате GeoTIFF с метаданными пространственной привязки. Рекомендуется использовать 8-битное представление для RGB-каналов без дополнительного сжатия изображений или с применением сжатия без потерь.

4.8.2 Рекомендации по подготовке изображений к мультиклассификации

При проведении анализа изображений, получаемых при дистанционном лесопатологическом мониторинге хвойных лесов в производственных масштабах, рекомендуется разрезать предварительно обработанные RGB – изображения (ортофотопланы) на фрагменты размером не менее 480×480×3 пикселей и подавать их на вход используемых моделей глубокого обучения. Как показали резуль-

таты исследований моделей глубокого обучения (см. раздел 3) и результаты апробации технологий мультиклассификации в п.4.7, это снижает затраты времени на мультиклассификацию изображений (повышает скорость вычисления моделей) и повышает точность классификации жизненных состояний хвойных деревьев по сравнению с использованием входных фрагментов размером $256 \times 256 \times 3$ пикселей. Общая рекомендация по повышению точности классификации изображений хвойных деревьев: следует готовить фрагменты изображений для мультиклассификации хвойных деревьев как можно больших размеров.

4.8.3 Рекомендации по аппаратному обеспечению технологий

Эффективное функционирование СКЗ и нейросетевых технологий на ее основе существенно зависит от характеристик аппаратных средств компьютера, на котором установлена система. Для достижения оптимальной производительности СКЗ и технологий рекомендуется следующая конфигурация аппаратных средств. В качестве CPU персонального компьютера желательно использовать современные многоядерные процессоры с тактовой частотой не менее 3,0 ГГц и количеством ядер не менее 8. Оптимальными являются CPU Intel Core i7/i9 или AMD Ryzen 7/9. Их высокая производительность важна при предварительной обработке изображений во внешней системе Agisoft Metashape и мультиклассификации изображений хвойных деревьев. Минимальный рекомендуемый объем оперативной памяти составляет 16 ГБ, что позволит работать с проектами мониторинга лесов площадью до 50 га.

Наличие GPU является важным для эффективной работы с моделями глубокого обучения. Рекомендуется, если это возможно, использовать GPU компании NVIDIA с архитектурой Turing или Ampere, поддерживающие технологию CUDA версии 11.0 и выше. Минимальный рекомендуемый объем видеопамати составляет 4 ГБ (оптимально 8 ГБ и более). При отсутствии GPU технологии мультиклассификации могут выполняться в режиме CPU-инференса, однако скорость анализа снижается в 20–35 раз. CPU-режим может быть приемлем для анализа изображений единичных небольших участков, но его не желательно исполь-

зовать при анализе изображений, получаемых при регулярном мониторинге обширных лесных территорий.

Для хранения исходных изображений высокого разрешения, промежуточных и конечных результатов использования нейросетевых технологий рекомендуется использовать твердотельные накопители (англ. SSD) объемом не менее 1 ТБ. Для проектов с большими объемами архивных данных рекомендуется дополнительное использование традиционных жестких дисков (англ. HDD) объемом 4–8 ТБ.

4.8.4 Рекомендации по использованию моделей глубокого обучения

На основе результатов комплексных исследований разработанных моделей глубокого обучения (см. раздел 3) и результатов апробации нейросетевых технологий (см. п.4.7) по точности классификации изображений хвойных деревьев и по скорости вычислений этих моделей можно сформулировать следующие практические рекомендации.

Специалист-лесопатолог, работая с СКЗ и запуская ту или иную нейросетевую технологию, имеет возможность выбора сервиса, реализующего для выбранной породы хвойных деревьев (пихта или кедр) одну из трех моделей глубокого обучения: At-Mo-U-Net, Res-Mo-U-Net и Segformer+. Каждая из этих моделей показывает определенные значения метрик точности классификации изображений хвойных деревьев и скорости вычислений, а также определяет требования к вычислительным ресурсам. Модель Res-Mo-U-Net рекомендуется в качестве основной модели для решения большинства практических задач лесопатологического мониторинга в производственных масштабах при наличии современных вычислительных ресурсов. Как показали наши исследования, эта модель является компромиссным вариантом, удовлетворяющим противоречащим друг другу требованиям высокой точности классификации изображений хвойных деревьев и высокой скорости вычислений модели. Она, как следует из результатов исследований в таблицах 3.8 и 3.9 (см.п.3.6) и из результатов апробации в таблице 4.4 (см. п.4.7.1), по сравнению с моделями At-Mo-U-Net и

Segformer+ в 1,5–1,8 раза выполняется быстрее на персональном компьютере с GPU и в 1,5–1,7 раза быстрее на компьютере этой же конфигурации, но без GPU. Например, на персональном компьютере без GPU с процессором Intel Core i7 и оперативной памятью 16 ГБ мультиклассификация изображения участка кедрового леса площадью 1 га с помощью модели Res-Mo-U-Net выполняется за 10–11 с. Такой высокий результат позволяет считать, что она может осуществлять мультиклассификацию изображений в реальном или квазиреальном масштабе времени в зависимости от скорости съемки при мониторинге лесов. Это указывает на возможность масштабного внедрения СКЗ с реализованной в ней такой моделью на предприятиях лесной отрасли, имеющих персональные компьютеры невысокой производительности, в том числе без GPU .

Модель Segformer+ рекомендуется использовать при решении задач, требующих максимальной точности семантической сегментации (попиксельной мультиклассификации) изображений хвойных деревьев при наличии достаточных вычислительных ресурсов (персональный компьютер с GPU). Использование этой модели возможно при вычислениях на компьютере с производительным процессором Intel Core i7, но без GPU в случаях отсутствия жестких ограничений по времени анализа изображений или при малом объеме последних.

Модель At-Mo-U-Net рекомендуется для применения при решении задач, когда требуется улучшенная точность классификации изображений по сравнению с моделью Res-Mo-U-Net при средних ресурсах компьютера. В этой модели используются механизмы внимания для повышения точности классификации, что требует больше времени на вычисления.

Для работы с разновременными изображениями при решении задач анализа динамики жизненных состояний деревьев рекомендуется использовать одну и ту же модель глубокого обучения для всех сеансов мониторинга. Это обеспечит стабильность результатов мультиклассификации изображений.

4.9 Основные результаты и выводы по разделу

Ниже представлены основные полученные при этом результаты и сделанные выводы.

1. Разработана концепция построения СКЗ для анализа данных лесопатологического мониторинга хвойных лесов.
2. Предложена и реализована сервисно-ориентированная архитектура программного обеспечения СКЗ. Такая архитектура ПО обеспечивает слабую связанность сервисов, масштабируемость СКЗ и возможность интеграции ее с требуемыми для разработки нейросетевых технологий внешними специализированными системами.
3. Разработано ПО СКЗ, включающее основные веб-сервисы для реализации нейросетевых технологий, и создан пользовательский интерфейс системы на базе ГИС QGIS, обеспечивающий интуитивный доступ ко всем функциям системы и визуализацию получаемых результатов.
4. Спроектирована концептуальная модель базы данных СКЗ. На ее основе развернута физическую модель данных в среде выбранной СУБД PostgreSQL с пространственным расширением PostGIS для эффективного хранения и обработки геопространственных данных.
5. Формализованы в нотации BPMN и разработаны на основе СКЗ следующие нейросетевые технологии: шесть технологий мультиклассификации изображений жизненных состояний хвойных деревьев пихты и кедра, технология обнаружения очагов размножения уссурийского полиграфа, две технологии анализа динамики жизненных состояний хвойных деревьев и технология оценки углеродного баланса сухостоя. Каждая технология представляет собой законченный автоматизированный бизнес-процесс, реализуемый при решении конкретной задачи мониторинга.
6. Проведена апробация разработанных технологий на реальных данных дистанционного мониторинга хвойных лесов. Апробация технологий мультиклассификации изображения участка кедрового леса площадью 2 га подтвердила их

работоспособность при использовании всех трех моделей глубокого обучения. При этом результаты по точности классификации этого изображения по метрикам *IoUc* и *mIoU*, полученные с помощью этих технологий, подтвердили результаты исследований по точности этих моделей, изложенные в п. 3.5. Оценки производительности технологий на компьютерах различной конфигурации показали, что выполнение этих технологий возможно на обычных персональных компьютерах даже без GPU, часто встречающихся в лесничествах. Апробация технологий анализа динамики жизненных состояний хвойных деревьев в очаге размножения вредителей проводилась с использованием двух одновременных изображений сверхвысокого разрешения участка кедрового леса площадью 1 га. На участке в 2023 г. был зафиксирован очаг союзного короеда, а в 2025 г. – обнаружен также очаг рыжего соснового пилильщика. Апробация показала работоспособность двух созданных технологий, а также позволила сделать вывод о высокой эффективности предложенного метода анализа динамики и этих технологий в случае использования для мультиклассификации одновременных изображений модели Segformer+. Результаты успешной апробации технологии оценки фитомассы сухостоя и углерода в ней на участке пихтового леса площадью 1 га подтвердили работоспособность технологии, включая средства интеграции СКЗ с внешней системой оценки фитомассы и эмиссии углерода FORRUS-S. По результатам апробации всех перечисленных технологий сделан вывод, что разработанная СКЗ и созданные на ее основе технологии обеспечивают решение основных задач лесопатологического мониторинга хвойных лесов с практически приемлемой точностью и скоростью и поэтому могут широко использоваться в лесничествах и центрах защиты леса России.

7. На основе результатов разработки, исследования и апробации нейросетевых технологий, созданных на основе разработанной СКЗ, сформулированы практические рекомендации по эффективному применению этой системы и нейросетевых технологий.

ЗАКЛЮЧЕНИЕ

Диссертация посвящена созданию моделей, методов и нейросетевых технологий для решения задач лесопатологического мониторинга хвойных лесов. Получены следующие важные научные и практические результаты.

1. Анализ проблемы лесопатологического мониторинга хвойных лесов показал, что оперативное проведение такого мониторинга должно осуществляться дистанционно с использованием фото или видеокамер на БПЛА и КА, а получаемые при этом изображения пораженных насекомыми – вредителями хвойных деревьев должны анализироваться с помощью современных моделей и методов интеллектуального анализа. Более того, на первом этапе решения задач лесопатологического мониторинга необходимо осуществлять автоматическую мультиклассификацию жизненных состояний пораженных деревьев на изображениях. Аналитический обзор моделей и методов мультиклассификации таких изображений позволил сделать вывод о перспективности для этого моделей глубокого обучения.
2. Разработаны гибридная модель полносвёрточной нейронной сети At-Mo-U-Net, отличающаяся от известных аналогов интеграцией блоков внимания в модель Mo-U-Net, и модель полносвёрточной нейронной сети Res-Mo-U-Net, в которой стандартные свёрточные слои модели Mo-U-Net заменены на остаточные блоки. Комплексные исследования этих моделей глубокого обучения на реальных изображениях пораженных насекомыми участков пихтового и кедрового лесов показали, что они позволяют повысить на 12–24% точность классификации хвойных деревьев на изображениях по сравнению с классической моделью U-Net при сохранении или незначительном снижении скорости вычислений.
3. Разработана модель Segformer+, отличающаяся от известного трансформера Segformer введением механизма кросс-уровневого внимания и заменой многослойных перцептронов на пространственные блоки с управляющими элементами. Комплексные исследования этой модели глубокого обучения на реальных изображениях участков пихтового и кедрового лесов показали, что

она обеспечивает на 24–29% более точную классификацию пораженных деревьев на изображениях относительно модели U-Net при некотором повышении затрат времени на ее вычисление.

4. Разработан метод дистанционного обнаружения очагов размножения уссурийского полиграфа в пихтовых лесах без необходимости проведения трудоёмких наземных измерений. Он позволяет в 7,1–7,3 раз сократить затраты времени на обнаружение таких очагов при сохранении высокой достоверности результатов обнаружения.
5. Разработан метод анализа динамики (изменений) жизненных состояний хвойных деревьев в очагах размножения вредителей, позволяющий формировать матрицы переходов этих состояний по результатам мультиклассификации разновременных изображений. Результаты исследований эффективности этого метода на реальных изображениях пораженных союзным короедом и рыжим сосновым пилильщиком деревьев кедра показали, что метод позволяет выявлять в отличие от существующих методов направления и с погрешностью не более 10% скорость переходов жизненных состояний деревьев кедра между классами.
7. Сформирована концепция создания СКЗ для решения основных задач лесопатологического мониторинга. ПО СКЗ построено на принципах SOA.
8. На основе СКЗ разработаны следующие нейросетевые технологии: шесть технологий мультиклассификации изображений хвойных деревьев пихты и кедра, технология обнаружения очагов размножения уссурийского полиграфа, две технологии анализа динамики жизненных состояний хвойных деревьев и технология оценки углеродного баланса сухостоя. Проведена апробация этих технологий на реальных изображениях хвойных лесов. Сделаны выводы о том, что СКЗ и технологии решают задачи лесопатологического мониторинга с практически приемлемой точностью и скоростью вычислений и могут быть тиражированы в лесничествах.
9. На основе результатов исследований моделей и методов и апробации технологий сформулированы рекомендации по их применению.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. The State of the World's Forests 2020: Forests, biodiversity and people. – Rome : FAO and UNEP, 2020. – 214 p.
2. Invasive alien pests threaten the carbon stored in Europe's forests / R. Seidl, G. Klöner, W. Rammer [et al.] // Nature Communications, 2018. – Vol. 9, № 1. – P. 1626. – DOI 10.1038/s41467-018-04096-w.
3. The Consequence of Tree Pests and Diseases for Ecosystem Services / I. L. Boyd, P. H. Freer-Smith, C. A. Gilligan, H. C. J. Godfray. // Science. – 2013. – Vol. 342, № 6160. – DOI: 10.1126/science.1235773.
4. Invasive insect pests of forests and urban trees in Russia: origin, pathways, damage, and management / D. L. Musolin, N. I. Kirichenko, N. N. Karpun [et al.] // Forests. – 2022. – Vol. 13, № 4. – DOI: 10.3390/f13040521.
5. Forest disturbances under climate change / R. Seidl, D. Thom, M. Kautz [et al.] // Nature Climate Change. – 2017. – Vol. 7, No. 6. – P. 395–402.
6. Bystrov S. O. First record of the four-eyed fir bark beetle *Polygraphus proximus* Blandford, 1894 (Coleoptera, Curculionidae: Scolytinae) from Irkutsk Province, Russia / S. O. Bystrov, I. A. Antonov // Entomological Review. – 2019. – Vol. 99, № 1. – P. 54–55. – DOI: 10.1134/S001387381901007X.
7. Распространение уссурийского полиграфа *Polygraphus proximus* Blandf. (Coleoptera, Curculionidae: Scolytinae) в Сибири / С. А. Кривец, И. А. Керчев, Э. М. Бисирова [и др.] // Известия СПГЛУ. – 2015. – № 211. – С. 33–45.
8. Союзный короед *Ips amitinus* (Eichhoff, 1872) (Coleoptera, curculionidae: Scolytinae) - новый чужеродный вид в Западной Сибири / И. А. Керчев, М. Ю. Мандельштам, С. А. Кривец, Ю. Ю. Илинский // Энтомологическое обозрение. – 2019. – Т. 98, № 3. – С. 592–599. – DOI: 10.1134/S0367144519030092.
9. Павлов И. Н. Биотические и абиотические факторы усыхания хвойных лесов Сибири и Дальнего Востока / И. Н. Павлов // Сибирский экологический журнал. – 2015. – Т. 22, № 4. – С. 537–554. – DOI: 10.15372/SEJ20150405.
10. Массовое размножение *Polygraphus proximus* Blandford в пихтовых лесах Сибири, зараженных корневыми и стволовыми патогенами: мониторинг,

- закономерности, перспективы биологического контроля / И. Н. Павлов, Ю. А. Литовка, Д. В. Голубев [и др.] // Сибирский экологический журнал. – 2020. – Т. 27, № 1. – С. 89–106. – DOI: 10.15372/SEJ20200107.
11. Dedyukhin S. V. Finding of the bark beetle *Polygraphus proximus* Blandford, 1894 (Coleoptera, Curculionidae: Scolytinae) in Udmurtia / S. V. Dedyukhin, V. V. Titova // Russian Journal of Biological Invasions. – 2021. – Vol. 12, № 3. – P. 258–263. – DOI: 10.1134/S2075111721030048.
 12. Detection of fir trees (*Abies sibirica*) damaged by the bark beetle in unmanned aerial vehicle images with deep learning / A. Safonova, S. Tabik, D. Alcaraz [et al.] // Remote Sensing. – 2019. – Vol. 11, № 6. – DOI: 10.3390/rs11060643.
 13. The role of remote sensing for the assessment and monitoring of forest health: A systematic evidence synthesis / P. Torres, M. Rodes-Blanco, A. Viana-Soto [et al.] // Forests. – 2021. – Vol. 12, № 8. – P. 1134. – DOI: 10.3390/f12081134.
 14. Senf C. Mapping the forest disturbance regimes of Europe / C. Senf, R. Seidl // Nature Sustainability. – 2021. – Vol. 4. – P. 63–70. – DOI: s41893-020-00609-y.
 15. Gao T. MCMS-STM: An extension of support tensor machine for multiclass multiscale object recognition in remote sensing images / T. Gao, H. Chen, W. Chen // Remote Sensing. – 2022. – Vol. 14, № 1. – P. 196. – DOI: 10.3390/rs14010196.
 16. Aboveground soil supports high levels of biological activity in oil palm plantations / A. M. Potapov, R. Bonnier, D. Sandmann [et al.] // Frontiers in Ecology and the Environment. – 2020. – Vol. 18, № 4. – P. 181–187.
 17. Woodland mapping at single-tree levels using object-oriented classification of unmanned aerial vehicle (UAV) images / A. Chenari, Y. Erfanifard, M. Dehghani, H. R. Pourghasemi // International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. – 2017. – Vol. XLII-4/W4. – P. 43–49. – DOI: 10.5194/isprs-archives-XLII-4-W4-43-2017.
 18. Detecting Pest-Infested Forest Damage through Multispectral Satellite Imagery and Improved UNet++ / J. Zhang, S. Cong, G. Zhang [et al.] // Sensors. – 2022. – Vol. 22, № 19. – P. 7440. – DOI: 10.3390/s22197440.
 19. Evaluation of remote sensing inversion error for the above-ground biomass of alpine meadow grassland based on multisource satellite data / B. Meng, J. Ge, T.

- Liang [et al.] // *Remote Sensing*. – 2017. – Vol. 9, № 4. – DOI: 10.3390/rs9040372.
20. Zhang C. Individual tree segmentation from LiDAR point clouds for urban forest inventory / C. Zhang, Y. Zhou, F. Qiu // *Remote Sensing*. – 2015. – Vol. 7, № 6. – P. 7892–7913. – DOI: 10.3390/rs70607892.
21. Luo Y. Early Monitoring of Forest Wood-Boring Pests with Remote Sensing / Y. Luo, H. Huang, A. Roques // *Annual Review of Entomology*. – 2023. – Vol. 68. – P. 277–298. – DOI: 10.1146/annurev-ento-120220-125410.
22. Recent advances in the application of deep learning methods to forestry / Y. Wang, W. Zhang, R. Gao [et al.] // *Wood Science and Technology*. – 2021. – Vol. 55, № 5. – P. 1171–1202. – DOI: 10.1007/s00226-021-01309-2.
23. Applying deep learning to real-time UAV-based forest monitoring: Leveraging multi-sensor imagery for improved results / T. Marques, S. Carreira, R. Miragaia [et al.] // *Expert Systems with Applications*. – 2024. – Vol. 245. – P. 123107. – DOI: 10.1016/j.eswa.2023.123107.
24. A meta-analysis of convolutional neural networks for remote sensing applications / H. Ghanbari, M. Mahdianpari, S. Homayouni, F. Mohammadimanesh // *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. – 2021. – Vol. 14. – P. 3602–3613. – DOI: 10.1109/JSTARS.2021.3065569.
25. A review of Convolutional Neural Networks in Remote Sensing Image / X. Liu, F. Han, K. H. Ghazali [et al.] // *Proceedings of the 2019 8th International Conference on Software and Computer Applications*. – 2019. – P. 263–267.
26. Status, advancements and prospects of deep learning methods applied in forest studies / T. Yun, J. Li, L. Ma [et al.] // *International Journal of Applied Earth Observation and Geoinformation*. – 2024. – Vol. 131. – P. 103938. – DOI: 10.1016/j.jag.2024.103938.
27. Токарева, О. С. Обработка и интерпретация данных дистанционного зондирования / О. С. Токарева. – Томск : Изд-во ТПУ, 2010. – 148 с.
28. Мониторинг состояния растительного покрова территории Центрального Ирака с использованием спутниковых данных Landsat-8 / О. С. Токарева, О. А. Пасько, С. М. Маджид, П. Кабраль // *Известия ТПУ. Инжиниринг георесурсов*. – 2020. – Т. 331, № 6. – С. 19–31. – DOI:

- 10.18799/24131830/2020/6/2671.
29. Onishi M. Automatic classification of trees using a UAV onboard camera and deep learning / M. Onishi, T. Ise // arXiv preprint. – 2018. – DOI: arxiv.org/abs/1804.10390.
30. Detection of Norway spruce trees (*Picea abies*) infested by bark beetle in UAV images using YOLOs architectures / A. Safonova, Y. Hamad, A. Alekhina, D. Kaplun // IEEE Access. – 2022. – Vol. 10. – DOI: 10.1109/ACCESS.2022.3144433.
31. A lightweight small object detection method for dead trees from shelter forest / X. Wang, Q. Zhao, P. Jiang [et al.] // Computers and Electronics in Agriculture. – 2022. – Vol. 198. – P. 107035. – DOI: 10.1016/j.compag.2022.107035.
32. Automatic detection of standing dead trees based on improved YOLOv7 from airborne remote sensing imagery / H. Zhou, S. Wu, Z. Xu, H. Sun // Frontiers in Plant Science. – 2024. – Vol. 15. – DOI: 10.3389/fpls.2024.1278161.
33. Wu Z. Extraction of Pine Wilt Disease Regions Using UAV RGB Imagery and Improved Mask R-CNN Models Fused with ConvNeXt / Z. Wu, X. Jiang // Forests. – 2023. – Vol. 14, № 8. – P. 1672. – DOI: 10.3390/f14081672.
34. Семантическая сегментация поврежденных деревьев пихты на снимках с беспилотных летательных аппаратов / И. А. Керчев, К. А. Маслов, Н. Г. Марков, О. С. Токарева // Современные проблемы дистанционного зондирования Земли из космоса. – 2021. – Т. 18, № 1. – С. 116–126. – DOI 10.21046/2070-7401-2021-18-1-116-126.
35. Марков, Н. Г. Применение методов машинного и глубокого обучения в задачах семантической сегментации изображений лесного покрова / Н. Г. Марков, К. А. Маслов // Молодежь и современные информационные технологии: Сборник трудов XVIII Международной научно-практической конференции студентов, аспирантов и молодых ученых, Томск, 22–26 марта 2021 года. – Томск: ТПУ, 2021. – С. 55–56.
36. Модели U-Net для семантической сегментации повреждённых деревьев сосны сибирской кедровой на снимках с БПЛА / Н. Г. Марков, К. А. Маслов, И. А. Керчев, О. С. Токарева // Современные проблемы дистанционного зондирования Земли из космоса. – 2022. – Т. 19, № 1. – С. 65-77. – DOI

- 10.21046/2070-7401-2022-19-1-65-77.
37. Наука в авангарде переосмысления роли лесов в третьем тысячелетии: комментарии к проекту концепции федерального закона "лесной кодекс Российской Федерации" / А. М. Макарьева, А. В. Нефедов, В. Е. Морозов [и др.] // Вопросы лесной науки. – 2020. – Т. 3, № 3. – С. 1–25.
38. Биоразнообразие и климаторегулирующие функции лесов: актуальные вопросы и перспективы исследований / Н. В. Лукина, А. П. Гераськина, А. В. Горнов [и др.] // Вопросы лесной науки. – 2020. – Т. 3, № 4. – С. 1–90.
39. Russian forests and climate change / P. Leskinen, M. Lindner, P. Verkerk [et al.] (Eds.). – European Forest Institute. – 2020. – 136 p. – DOI: 10.36333/wsctu11.
40. Об утверждении Лесоустроительной инструкции: Приказ Министерства природных ресурсов и экологии Российской Федерации от 29.03.2022 № 510. – URL: <https://docs.cntd.ru/document/351878696> (дата обращения: 07.06.2025). – Текст : электронный.
41. Площадь лесов России и ее динамика на основе синтеза продуктов дистанционного зондирования / Д. Г. Щепашенко, А. З. Швиденко, М. Ю. Лесив [и др.] // Лесоведение. – 2015. – № 3. – С. 163–171.
42. Land cover map of Russia derived from Proba-V satellite data / V. A. Egorov, S. A. Bartalev, P. A. Kolbudaev [et al.] // Current problems in remote sensing of the Earth from space. – 2018. – Vol. 15, № 2. – P. 282–286. – DOI: 10.21046/2070-7401-2018-15-2-282-286.
43. Distribution of the Small Spruce Bark Beetle *Ips amitinus* (Eichhoff, 1872) in Western Siberia / I. A. Kerchev, S. A. Krivets, E. M. Bisirova, N. A. Smirnov // Russian Journal of Biological Invasions. – 2021. – Vol. 13, № 1. – P. 77–84. – DOI: 10.35885/1996-1499-2021-14-4-77-84.
44. Mitchell A. Current remote sensing approaches to monitoring forest degradation in support of countries measurement, reporting and verification (MRV) systems for REDD+ / A. Mitchell, A. Rosenqvist, B. Mora // Carbon Balance and Management. – 2017. – Vol. 12, № 1. – P. 9. – DOI: 10.1186/s13021-017-0078-9.
45. Тематическое картирование растительного покрова по спутниковым снимкам: валидация и оценка точности / Э. А. Курбанов, О. Н. Воробьев, С.

- А. Лежнин [и др.]. – Йошкар-Ола : ПГТУ, 2015. – 131 с.
46. Дистанционный мониторинг устойчивости лесных экосистем / О. Н. Воробьев, Э. А. Курбанов, Е. Н. Демишева [и др.] ; под общей редакцией профессора Э.А. Курбанова. – Йошкар-Ола : ПГТУ, 2019. – 166 с.
47. Global forest area disturbance from fire, insect pests, diseases and severe weather events / P. van Lierop, E. Lindquist, S. Sathyapala, G. Franceschini // *Forest Ecology and Management*. – 2015. – Vol. 352. – P. 78–88. – DOI: 10.1016/j.foreco.2015.06.010.
48. Monitoring forest cover dynamics using orthophotos and satellite imagery / L. Blaga, D. C. Ilieș, J. A. Wendt [et al.] // *Remote Sensing*. – 2023. – Vol. 15, № 12. – P. 3168. – DOI: 10.3390/rs15123168.
49. The potential of combining satellite and airborne remote sensing data for habitat classification and monitoring in forest landscapes / A. Iglseder, M. Immitzer, A. Dostálová [et al.] // *International Journal of Applied Earth Observation and Geoinformation*. – 2023. – Vol. 117. – DOI: 10.1016/j.jag.2022.103131.
50. Modelling LiDAR-Based Vegetation Geometry for Computational Fluid Dynamics Heat Transfer Models / P. Keerthinathan, M. Winsen, T. Krishnakumar [et al.] // *Remote Sensing*. – 2025. – Vol. 17, № 3. – DOI: 10.3390/rs17030552.
51. Identifying Old-Growth Forests in Complex Landscapes: A New LiDAR-Based Estimation Framework and Conservation Implications / R. Trouvé, R. Jiang, P. J. Baker [et al.] // *Remote Sensing*. – 2024. – Vol. 16, № 1. – P. 147. – DOI: 10.3390/rs16010147.
52. Expanding forest research with terrestrial LiDAR technology / E. E. Maeda, B. Brede, K. Calders [et al.] // *Nature Communications*. – 2025. – Vol. 16, № 1. – P. 8853. – DOI: 10.1038/s41467-025-63946-6.
53. The effectiveness of lidar remote sensing for monitoring forest cover attributes and landscape restoration / D. Almeida, S. Stark, R. Chazdon [et al.] // *Forest Ecology and Management*. – 2019. – Vol. 438. – P. 34–43. – DOI: 10.1016/j.foreco.2019.02.002.
54. Haralick R. M. Textural features for image classification / R. M. Haralick, K. Shanmugam, I. Dinstein // *IEEE Transactions on Systems, Man, and Cybernetics*. –

1973. – Vol. SMC-3, № 6. – P. 610–621. – DOI: 10.1109/TSMC.1973.4309314.
55. Методические подходы к оценке характеристик лесов по данным спутниковой съемки сверхвысокого пространственного разрешения в оптическом диапазоне / С. В. Князева, А. Д. Никитина, Е. И. Белова [и др.] // Лесоведение. – 2021. – № 6. – С. 645–672.
56. Woo H. Computer Vision Techniques in Forest Inventory Assessment: Improving Accuracy of Tree Diameter Measurement Using Smartphone Camera and Photogrammetry / H. Woo, I. Kim, B. Choi // Sensors and Materials. – 2021. – Vol. 33, № 11. – P. 3835–3845. – DOI: 10.18494/SAM.2021.3605.
57. Improving Tree Species Classification Using UAS Multispectral Images and Texture Measures / R. Gini, G. Sona, G. Ronchetti [et al.] // ISPRS International Journal of GeoInformation. – 2018. – Vol. 7, № 8. – DOI: 10.3390/ijgi7080315.
58. Замятин, А. В. Анализ динамики земной поверхности по данным дистанционного зондирования Земли / А. В. Замятин, Н. Г. Марков. – Москва : Физматлит, 2007. – 176 с.
59. Belgiu M. Random Forest in remote sensing: A review of applications and future directions / M. Belgiu, L. Drăguț // ISPRS Journal of Photogrammetry and Remote Sensing. – 2016. – Vol. 114. – P. 24–31. – DOI: 10.1016/j.isprsjprs.2016.01.011.
60. Remote sensing based forest cover classification using machine learning / G. Aziz, N. Minallah, A. Saeed [et al.] // Scientific Reports. – 2024. – Vol. 14. – P. 69. – DOI: 10.1038/s41598-023-50863-1.
61. Winter remote sensing images are more suitable for forest mapping in Jiangxi Province / R. Wang, M. Wang, X. Sun [et al.] // European Journal of Remote Sensing. – 2023. – Vol. 56, № 1.
62. Mountrakis G. Support vector machines in remote sensing: A review / G. Mountrakis, J. Im, C. Ogole // ISPRS Journal of Photogrammetry and Remote Sensing. – 2011. – Vol. 66, № 3. – P. 247–259. – DOI: 10.1016/j.isprsjprs.2010.11.001.
63. Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review / M. Sheykhmousa, M. Mahdianpari, H. Ghanbari [et al.] // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. – 2020. – Vol. 13. – P. 6308–6325. – DOI:

- 10.1109/JSTARS.2020.3026724.
64. Comparative analysis of algorithmic approaches in ensemble learning: bagging vs. boosting / H. Zhao, W. Liu, Y. Wang, L. Wu // *Scientific Reports*. – 2025. – Vol. 15. – P. 34218. – DOI: 10.1038/s41598-025-15971-0.
 65. Bagging and boosting ensemble classifiers for classification of multispectral, hyperspectral and PolSAR data: a comparative evaluation / H. Jafarzadeh, M. Mahdianpari, E. Gill [et al.] // *Remote Sensing*. – 2021. – Vol. 13, № 21. – P. 4405. – DOI: 10.3390/rs13214405.
 66. Ensemble learning in remote sensing applications: Progress and prospects / D. Peijun, M. Haowei, G. Shanchuan [et al.] // *National Remote Sensing Bulletin*. – 2025. – Vol. 29, № 6. – P. 1614–1635. DOI: 10.11834/jrs.20254398.
 67. Lee S. Detection of Damaged Pine Tree by the Pine Wilt Disease Using UAV Image / S. Lee, G. Baek, C.W. Lee // *Korean Journal of Remote Sensing*. – 2019. – Vol. 5, № 3. – P. 359–373.
 68. A detection method for individual infected pine trees with pine wilt disease based on deep learning / Y. Zhou, W. Liu, H. Bi [et al.] // *Forests*. – 2022. – Vol. 13, № 11. – P. 1880. – DOI: 10.3390/f13111880.
 69. Early detection of pine wilt disease using deep learning algorithms and UAV-based multispectral imagery / R. Yu, Y. Luo, Q. Zhou [et al.] // *Forest Ecology and Management*. – 2021. – Vol. 497. – DOI: 10.1016/j.foreco.2021.119493.
 70. Early-Stage pine wilt disease detection via multi-feature fusion in UAV imagery / W. Xie, H. Wang, W. Liu, H. Zang // *Forests*. – 2024. – Vol. 15, № 1. – P. 171. – DOI: 10.3390/f15010171.
 71. Ronneberger O. Convolutional networks for biomedical image segmentation / O. Ronneberger, P. Fischer, T. Brox // *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. – 2015. – P. 234–241. – DOI: 10.1007/978-3-319-24574-4_28.
 72. Kocon K. Comparison of CNN-based segmentation models for forest type classification / K. Kocon, M. Krämer, H. M. Würz // *AGILE GIScience Series*. – 2022. – Vol. 3. – P. 42. – DOI: 10.5194/agile-giss-3-42-2022.
 73. Transformer-based visual segmentation: a survey / X. Li, H. Ding, H. Yuan [et al.]

- // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2024. – Vol. 46, № 12. – P. 10138–10163. – DOI: 10.1109/TPAMI.2024.3434373.
74. Segformer: simple and efficient design for semantic segmentation with transformers / E. Xie, W. Wang, Z. Yu [et al.] // Advances in Neural Information Processing Systems 34. – 2021. – Vol. 34. – P. 12077–12090.
75. Seismic facies segmentation via a Segformer-based specific encoder–decoder–hypercolumns scheme / Z. Wang, Q. Wang, Y. Yang [et al.] // IEEE Transactions on Geoscience and Remote Sensing. – 2023. – Vol. 61. – P. 1–11.
76. Rahman M. A. Optimizing Intersection-Over-Union in Deep Neural Networks for Image Segmentation / M. A. Rahman, Y. Wang // International Symposium on Visual Computing. – 2016. – P. 234–244.
77. Optimization for Medical Image Segmentation: Theory and Practice When Evaluating with Dice Score or Jaccard Index / T. Eelbode, J. Bertels, M. Berman [et al.] // IEEE Transactions on Medical Imaging. – 2020. – Vol. 39, № 11.
78. Gradient-based learning applied to document recognition / Y. LeCun, L. Bottou, Y. Bengio, P. Haffner // Proceedings of the IEEE. – 1998. – Vol. 86, № 11. – P. 2278–2324. – DOI: 10.1109/5.726791.
79. Deep Learning / I. Goodfellow, Y. Bengio, A. Courville. – Cambridge, MA, USA : MIT Press, 2016. – 800 p.
80. Nair V. Rectified Linear Units Improve Restricted Boltzmann Machines / V. Nair, G. E. Hinton // Proceedings of the 27th International Conference on Machine Learning. – 2010. – P. 807–814. – DOI: 10.1145/3104322.3104425.
81. Kingma D. P. Adam: A Method for Stochastic Optimization / D. P. Kingma, J. Ba // Proceedings of the International Conference on Learning Representations. – San Diego, CA, USA, 2015.
82. Bottou L. Large-Scale Machine Learning with Stochastic Gradient Descent / L. Bottou // Proceedings of COMPSTAT'2010. – 2010. – P. 177–186. – DOI: 10.1007/978-3-7908-2604-3_16.
83. Rumelhard D. Learning representations by back-propagating errors / D. E. Rumelhart, G. E. Hinton, R. J. Williams // Nature. – 1986. – Vol. 323, № 6088. – P. 533–536. – DOI: 10.1038/323533a0.

84. Clevert D.A. Fast and accurate deep network learning by exponential linear units (ELUs) / D. A. Clevert, T. Unterthiner, S. Hochreiter // Proceedings of the International Conference on Learning Representations. – 2016.
85. Ioffe S. Batch normalization: accelerating deep network training by reducing internal covariate shift / S. Ioffe, C. Szegedy // Proceedings of the 32nd International Conference on Machine Learning. – 2015. – P. 448–456. – DOI: 10.1145/2783258.2788613.
86. Dropout: a simple way to prevent neural networks from overfitting / N. Srivastava, G. Hinton, A. Krizhevsky [et al.] // Journal of Machine Learning Research. – 2014. – Vol. 15, № 56. – P. 1929–1958.
87. Kerchev I. A. Classification of pest-damaged coniferous trees in unmanned aerial vehicles images using convolutional neural network models / I. A. Kerchev, N. G. Markov, C. R. Machuca // Computer Research and Modelling. – 2024. – Vol. 16, № 5. – P. 1271–1294. DOI: 10.20537/2076-7633-2024-16-5-1271-1294.
88. Марков Н. Г. Модели и методы глубокого обучения для решения задач дистанционного мониторинга лесных ресурсов / Н. Г. Марков, К. Р. Мачука // Известия ТПУ. Инжиниринг георесурсов. – 2024. – Т. 335, № 6. – С. 55–74. DOI: 10.18799/24131830/2024/6/4600
89. Deep residual learning for image recognition / K. He, X. Zhang, S. Ren, J. Sun // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2016. – P. 770–778. – DOI: 10.1109/CVPR.2016.90.
90. Srivastava R. Highway networks / R. K. Srivastava, K. Greff, J. Schmidhuber // arXiv preprint. – 2015. – DOI: 10.48550/arXiv.1505.00387.
91. Machuca C. R. Advanced neural network models for UAV-based image analysis in remote pathology monitoring of coniferous forests / C. R. Machuca, N. G. Markov // Computer Research and Modelling. – 2025. – Vol. 17, № 4. – P. 641–663. – DOI: 10.20537/2076-7633-2025-17-4-641-663.
92. Luong M. T. Effective approaches to attention-based neural machine translation / M. T. Luong, H. Pham, C. D. Manning // Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. – Lisbon, Portugal, 2015. – P. 1412–1421. – DOI: 10.18653/v1/D15-1166.

93. Bahdanau D. Neural machine translation by jointly learning to align and translate / D. Bahdanau, K. Cho, Y. Bengio // Proceedings of the International Conference on Learning Representations. – San Diego, CA, USA, 2015.
94. Attention Is All You Need / A. Vaswani, N. Shazeer, N. Parmar [et al.] // Advances in Neural Information Processing Systems. – 2017. – Vol. 30. – P. 5998–6008. – DOI: 10.48550/arXiv.1706.03762.
95. Attention-based semantic segmentation networks for forest applications / V. Lim, M. A. Zulkifley, A. Saleh [et al.] // Forests. – 2023. – Vol. 14, № 12. – P. 2437. – DOI: 10.3390/f14122437.
96. Non-local neural networks / X. Wang, R. Girshick, A. Gupta, K. He // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. – 2018. – P. 7794–7803. – DOI: 10.1109/C3VPR.2018.00813.
97. Dual attention network for scene segmentation / J. Fu, J. Liu, H. Tian [et al.] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. – 2019. – P. 3146–3154. – DOI: 10.1109/CVPR.2019.00326.
98. CBAM: Convolutional block attention module / S. Woo, J. Park, J.-Y. Lee, I. S. Kweon // Proceedings of the European Conference on Computer Vision. – 2018. – P. 3–19. – DOI: 10.1007/978-3-030-01234-2_1.
99. Narayan S. The generalized sigmoid activation function: competitive supervised learning / S. Narayan // Information Sciences. – 1997. – Vol. 99, № 1. – P. 69–82. – DOI: 10.1016/S0020-0255(96)00200-9.
100. An image is worth 16x16 words: Transformers for image recognition at scale / A. Dosovitskiy, L. Beyer, A. Kolesnikov [et al.] // Proceedings of the International Conference on Learning Representations. – Vienna, Austria, 2021.
101. 3CROSSNet: Cross-Level Cross-Scale Cross-Attention Network for Point Cloud Representation / X. Han, Z. He, J. Chen, G. Xiao // IEEE Robotics and Automation Letters. – 2022. – Vol. 7, № 2. – DOI: 10.1109/LRA.2022.3147907.
102. Pay attention to MLPs / H. Liu, Z. Dai, D. R. So, Q. V. Le // Advances in Neural Information Processing Systems (NeurIPS 2021). – 2021. – P. 9204–9215.
103. Pyramid Attention Network for Semantic Segmentation / H. Li, P. Xiong, J. An, L. Wang // Proceedings of the 29th British Machine Vision Conference. – 2018. –

- P. 285.
104. Gonzalez R. C. Digital image processing / R. C. Gonzalez, R. E. Woods. – 4th ed. – Upper Saddle River, NJ : Pearson, 2018. – 1132 p.
105. Soille P. Morphological Image Analysis / P. Soille. – 2nd ed. – Berlin : Springer-Verlag, 2003. – 284 p.
106. An individual tree crown delineation method based on multi-scale segmentation of imagery / L. Jing, B. Hu, T. L. Noland, J. Li // *ISPRS Journal of Photogrammetry and Remote Sensing*. – 2012. – Vol. 70. – P. 88–98. – DOI: 10.1016/j.isprsjprs.2012.04.003.
107. Farjon A. A handbook of the world's conifers / A. Farjon. – Leiden ; Boston : Brill, 2017. – 1153 p.
108. Маслов А. Д. Методические рекомендации по надзору, учету и прогнозу массовых размножений стволовых вредителей и санитарного состояния лесов / А. Д. Маслов. – Москва : ВНИИЛМ, 2006. – 108 с.
109. Barry P. Accuracy of UAV photogrammetry compared with Network RTK GPS / P. Barry, R. Coakley // *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. – 2013. – Vol. XL-1/W2. – P. 27–31. – DOI: 10.5194/isprsarchives-XL-1-W2-27-2013.
110. Долговременная динамика состава, строения и состояния древостоев северотаежных сосняков на Европейском Северо-Востоке России / И. Н. Кутявин, А. В. Манов, А. Ф. Осипов, К. С. Бобкова // *Сибирский лесной журнал*. – 2023. – № 2. – С. 17-25. – DOI 10.15372/SJFS20230202.
111. Курбатова, А. И. Аналитический обзор по современным исследованиям изменений биотических составляющих углеродного цикла / А. И. Курбатова // *Вестник РУДН. Экология и безопасность жизнедеятельности*. – 2020. – Т. 28, № 4. – С. 428–438. – DOI 10.22363/2313-2310-2020-28-4-428-438.
112. Методы оценки баланса углерода в лесных экосистемах и возможности их использования для расчетов годичного депонирования углерода / Н. В. Малышева, Б. Н. Моисеев, А. Н. Филипчук, Т. А. Золина // *Лесной вестник*. – 2017. – Т. 21, № 1. – С. 4-13. – DOI 10.18698/2542-1468-2017-1-4-13.
113. Эколого-экономическая оценка результативности комплекса лесохо-

- зьяйственных практик в вопросах поддержания углеродного баланса / С. С. Морковина, Н. Н. Харченко, С. С. Шешнищан [и др.] // Лесной вестник. – 2024. – Т. 28, № 5. – С. 104-117. – DOI 10.18698/2542-1468-2024-5-104-117.
114. Технология мониторинга пихтовых лесов в зоне инвазии уссурийского полиграфа в Сибири / С. А. Кривец, Э. М. Бисирова, Е. С. Волкова [и др.]. – Томск : УМИУМ, 2018. – 74 с.
115. Imambi S. Programming with TensorFlow: solution for edge computing applications / K. Bhanu Prakash, G. R. Kanagachidambaresan (eds.). – Cham, Switzerland : Springer Nature, 2021. – 190 p. – DOI: 10.1007/978-3-030-57077-4.
116. Perez L. The effectiveness of data augmentation in image classification using deep learning / L. Perez, J. Wang // arXiv preprint. – 2017. – DOI: 10.48550/arXiv.1712.04621.
117. Focal loss for dense object detection / T.-Y. Lin, P. Goyal, R. Girshick [et al.] // arXiv preprint. – 2017. – DOI: 10.48550/arXiv.1708.02002.
118. Mohd K. Adam optimization algorithm for wide and deep neural network / I. K. Mohd, A. Ritahani, S. Qamrun // Knowledge Engineering and Data Science. – 2019. – Vol. 2, № 1. – P. 41–46. – DOI: 10.17977/um018v2i12019p41-46.
119. Факторы, способствующие появлению очагов массового размножения Союзного короеда *IPS amitinus* (Eichhoff) (Coleoptera: Curculionidae, Scolytinae) в кедровых лесах Западно-сибирской равнины / Д. А. Демидко, И. А. Керчев, Э. М. Бисирова [и др.] // Российский журнал биологических инвазий. – 2025. – Т. 18, № 1. – С. 36–59. – DOI 10.35885/1996-1499-18-1-036-059.
120. Симкин, А. В. Подход к комплексному применению методологий систематизации требований / А. В. Симкин // Прикладная информатика. – 2013. – № 1. – С. 60–75.
121. Mastering QGIS / K. Menke, R. Smith Jr., L. Pirelli, J. Van Hoesen. – Birmingham, UK : Packt Publishing, 2016. – 486 p.
122. Understanding Service-Oriented Architecture (SOA): A systematic literature review and directions for further investigation / N. Niknejad, W. Ismail, I. Ghani [et al.] // Information Systems. – 2020. – Vol. 91. – DOI: 10.1016/j.is.2020.101491.
123. Lawler J. P. Service-oriented architecture: SOA strategy, methodology, and

- technology / J. P. Lawler, H. Howell-Barber. – Boca Raton, USA : Auerbach Publications, 2008. – 288 p.
124. Chappell D. A. Enterprise service bus: theory in practice / D. A. Chappell. – Sebastopol, USA : O'Reilly Media, 2004. – 274 p.
125. Karagiannis D. BPMS: business process management systems / D. Karagiannis, S. Junginger, R. Strobl // SIGOIS Bulletin. – 1995. – Vol. 16, № 1. – P. 10–13.
126. The Complete Business Process Handbook: Body of Knowledge from Process Modeling to BPM / M. von Rosing, S. White, F. Cummins, H. de Man. – Elsevier, 2015. – DOI: 10.1016/B978-0-12-799959-3.00021-5.
127. Prieto F. WSO2 Developer's Guide: SOA and data services with WSO2 Enterprise Integrator / F. Prieto, R. Garrido. – Birmingham, UK : Packt Publishing. – 2017. – 368 p.
128. Obe R. PostGIS in action / R. O. Obe, L. S. Hsu. – Greenwich, USA : Manning Publications, 2011. – 520 p.
129. Ethics, Machine Learning, and Python in Geospatial Analysis / T. D. Bezabih, M. G. Glačty, D. A. Wako, S. G. Worku. – Hershey, PA : IGI Global Scientific Publishing, 2024. – P. 72–93. – DOI: 10.4018/979-8-3693-6381-2.ch004.
130. Researching the optimal combination of UAV equipment for performing surveying measurements and software for processing the results / D. Polishchuk, A. Panasiuk, I. Davydova, V. Bondarchuk // Earth and Environmental Science. – 2024. – Vol. 1415, № 1. – DOI: 10.1088/1755-1315/1415/1/012029.
131. Имитационное моделирование динамики насаждений forrus-s - инструмент выбора стратегии и планирования лесного хозяйства / С. И. Чумаченко, М. М. Паленова, С. В. Починков, Е. В. Кухар // Лесной вестник. – 2007. – № 5. – С. 143-152.

Приложение А. Классическая модель U-Net

Классическая модель U-Net (рисунок А.1) представляет собой последовательность сверточных блоков, каждый из которых обычно включает:

1. Сверточный слой: выполняет основную операцию извлечения признаков с помощью набора обучаемых фильтров (K_1, K_2, \dots, K_N). Каждый фильтр отвечает за обнаружение определенного типа низкоуровневых (края, углы, текстуры) или высокоуровневых (части объектов, целые объекты) признаков. Выход слоя – набор карт признаков, количество которых равно количеству фильтров N .
2. Слой нелинейной активации в виде функции ReLU: вводит нелинейность, позволяя сети аппроксимировать сложные функции. Без нее модель U-Net сводилась бы к линейной модели.

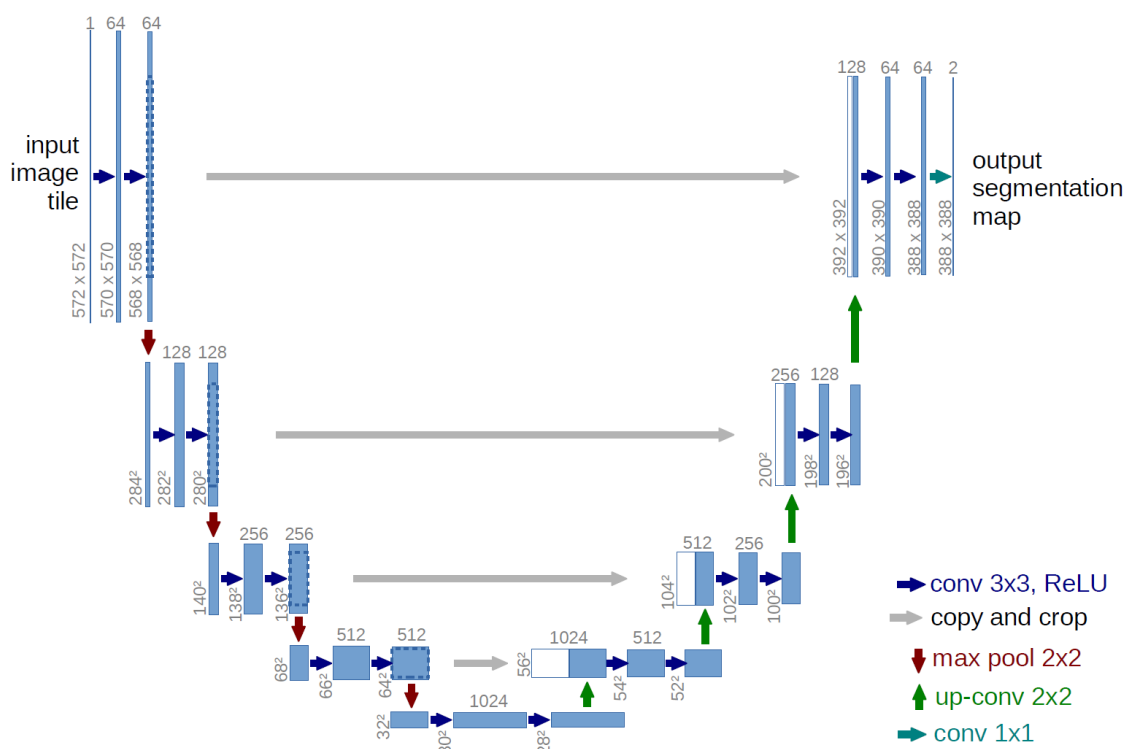


Рисунок А.1 – Архитектура U-Net (пример для разрешения 32×32 пикселя)

3. Слой субдискретизации (максимальное объединение (англ. MaxPooling)): применяется с шагом, уменьшая пространственные размеры карт признаков. Основные функции:

- Увеличение инвариантности к малым пространственным сдвигам и искажениям.

- Уменьшение вычислительной сложности последующих слоев.
- Контролируемое увеличение рецептивного поля нейронов в последующих слоях.

- Выделение наиболее значимых признаков.

В рисунке А.1 каждый синий прямоугольник соответствует многоканальной карте признаков. Количество каналов указано над прямоугольником. Размер по осям x и y приведён в нижнем левом углу прямоугольника. Белые прямоугольники представляют собой скопированные карты признаков. Стрелки обозначают различные операции. Выходной тензор вычисляется C свёртками с фильтрами размером 1×1 , позволяя таким образом классифицировать пиксели сразу C классов.

Модель U-Net относится к классу полносвёрточных сетей (англ. Fully Convolutional Networks, FCN). Такое название обусловлено тем, что в её архитектуре отсутствуют полносвязные слои (анг. fully connected layer), характерные для классических сверточных нейронных сетей, применяемых в задачах классификации. Вместо них U-Net использует только свёрточные операции, объединения (анг. pooling) и транспонированные свёртки (анг. up-convolutions), что позволяет сохранять пространственную структуру изображения на всём протяжении сети.

Приложение Б. Акт о внедрении результатов диссертации в Институте мониторинга климатических и экологических систем СО РАН

Минобрнауки России

Федеральное государственное бюджетное учреждение науки
Институт мониторинга климатических и экологических систем
Сибирского отделения Российской академии наук
(ИМКЭС СО РАН)

Академический пр., 10/3, г. Томск, 634055, Россия
Тел: (382-2) 492-265; Факс (382-2) 491-950 e-mail: post@imces.ru http://www.imces.ru
ОКПД 05534200, ОГРН 1027000880170, ИНН/КПП 7021001400 / 701701001

30.09.2025г. № 15323/01-424

На № _____ от _____



УТВЕРЖДАЮ
Директор ИМКЭС СО РАН
д.б.н., профессор РАН
Е.А. Голованская
» _____ 2025 г.

АКТ

о внедрении результатов диссертационной работы Мачука Мендоса Кристиан Родриго

Настоящим актом подтверждаем, что в Институте мониторинга климатических и экологических систем СО РАН внедрены следующие результаты, полученные Мачука Мендоса Кристиан Родриго при выполнении диссертационного исследования по специальности 2.1.3 – Системный анализ, управление и обработка информации, статистика:

1. Обученные модели глубоких искусственных нейронных сетей At-Mo-U-Net, Res-Mo-U-Net и Segformer для семантической сегментации (пониженной мультиклассификации) пораженных вредителями деревьев хиты сибирской *Abies sibirica* и кедра сибирского *Pinus sibirica* на изображениях высокого и сверхвысокого разрешения.
2. Метод дистанционного обнаружения очагов уссурийского полиграфа в хитовых лесах и метод анализа динамики состояния здоровья пораженных хвойных деревьев.
3. Наборы данных (датасеты), разработанные на основе изображений пораженных вредителями участков хитовых и кедровых лесов в Томской области и предназначенные для обучения, валидации и исследования моделей глубокого обучения.
4. Комплексная система компьютерного зрения (СКЗ), ядром которой является геоинформационная система QGIS. Программное обеспечение СКЗ включает модули, реализующие разработанные модели глубокого обучения и методы решения задач лесопатологического мониторинга хвойных лесов, сервисные модули для загрузки изображений в систему и подготовки их к анализу и модули формирования по результатам нейросетевого анализа отчетов о состоянии здоровья, размерах кроны деревьев и т.п. на обследуемом участке хвойных деревьев.

5. Созданные на основе СКЗ нейросетевые технологии для решения основных задач лесонатологического мониторинга и практические рекомендации по их применению. Указанные результаты используются при анализе данных дистанционного лесонатологического мониторинга лесов сотрудниками Лаборатории мониторинга углеродного баланса наземных экосистем с целью оценки состояния здоровья хвойных посадений.

Керчев Иван Андреевич,
ведущий научный сотрудник,
зав. Лабораторией мониторинга углеродного баланса наземных экосистем
ИМКЭС СО РАН,
пр. Академический, 10/3, 634055, Томск
Телефон: +7 (382-2) 492-265
E-mail: ivankerchev@gmail.com
Сайт: <http://www.imces.ru>

29.09.2025 г.



Подпись <u>Керчева И.А.</u> заверяю.
Ученый секретарь ИМКЭС СО РАН,
к.г.н. <u>С.И.</u> (И.И. Чередыко)

Приложение В. Акт о внедрении результатов диссертации в учебный процесс Томского политехнического университета



УТВЕРЖДАЮ

Директор Инженерной школы информационных технологий и робототехники ТПУ

А.С. Фадеев

2025г.

АКТ О ВНЕДРЕНИИ

результатов диссертационной работы Мачука М.К.Р. в учебный процесс отделения информационных технологий

Настоящим актом подтверждаем, что в отделении информационных технологий Инженерной школы информационных технологий и робототехники Томского политехнического университета использованы при реализации ООП по направлению 09.03.01 «Информатика и вычислительная техника» в рамках дисциплины «Ввод и обработка данных дистанционного зондирования Земли» следующие научные и практические результаты, полученные Мачукой Мендоса Кристианом Родриго при выполнении кандидатской диссертации.

1. Модели полносвёрточных нейронных сетей At-Mo-U-Net и Res-Mo-U-Net и реализующие их программные модули для семантической сегментации (попиксельной мультиклассификации) хвойных деревьев на изображениях с космических аппаратов (КА) и с беспилотных летательных аппаратов (БПЛА).
2. Модель-трансформер Segformer+ и реализующий ее программный модуль для попиксельной мультиклассификации хвойных деревьев на изображениях с КА и БПЛА.
3. Методические рекомендации по обучению моделей нейронных сетей и оценке точности мультиклассификации хвойных деревьев на изображениях с КА и БПЛА.

Освоение студентами разделов по машинному обучению и обработке и анализу данных дистанционного зондирования земной поверхности дисциплины «Ввод и обработка данных дистанционного зондирования Земли» способствует приобретению ими необходимых знаний и компетенций по применению моделей нейронных сетей при решении практических задач анализа данных дистанционного зондирования растительных покровов Земли.

И. о. заведующего кафедрой –
руководителя ОИТ на правах кафедры,
к.т.н.


В.С. Хорев

Руководитель ООП по направлению 09.03.01
«Информатика и вычислительная техника»,
к.т.н., доцент


Е.А. Мыцко