

Министерство науки и высшего образования Российской Федерации
Федеральное государственное автономное образовательное учреждение высшего
образования «Пермский государственный национальный
исследовательский университет»

На правах рукописи



Тарасов Андрей Владимирович

Оперативное картографирование нарушений
лесного покрова на основе спутниковых данных
с высоким пространственно-временным разрешением

Специальность 25.00.33 – Картография

Диссертация на соискание ученой степени кандидата
технических наук

Научный руководитель –
доктор географических наук, профессор
Пьянков Сергей Васильевич

Пермь – 2021

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ	5
1 СОВРЕМЕННЫЕ МЕТОДЫ ОПЕРАТИВНОГО КАРТОГРАФИРОВАНИЯ НАРУШЕНИЙ ЛЕСНОГО ПОКРОВА	12
1.1 Оперативное картографирование и его место в современной картографии.....	12
1.2 Нарушения лесного покрова и организация их мониторинга в РФ	15
1.2.1 Классификация нарушений лесного покрова	15
1.2.2 Организация мониторинга нарушений лесного покрова в России	17
1.3 Дешифровочные признаки нарушений лесного покрова	19
1.4 Традиционные методы автоматизированного выявления нарушений лесного покрова по мультиспектральным спутниковым данным, их возможности и ограничения	22
1.5 Возможности методов машинного обучения при обработке материалов ДЗЗ для обнаружений нарушений лесного покрова	27
1.5.1 Основные модели машинного обучения, применяемые для обработки данных ДЗЗ	27
1.5.2 Опыт применения методов машинного обучения для мониторинга нарушений лесного покрова	30
1.6 Информационные системы дистанционного мониторинга и картографирования лесов	33
Выводы по первому разделу.....	36
2 ОЦЕНКА ТОЧНОСТИ АВТОМАТИЗИРОВАННЫХ АЛГОРИТМОВ МАСКИРОВАНИЯ ОБЛАЧНОСТИ	38
2.1 Получение исходных данных и их характеристики	38
2.2 Выбор оптимального алгоритма маскирования облачности	43
2.3 Оценка точности алгоритмов маскирования облачности	55
Выводы по второму разделу.....	59

3 РАЗРАБОТКА АЛГОРИТМА ДЛЯ ВЫЯВЛЕНИЯ НАРУШЕНИЙ ЛЕСНОГО ПОКРОВА С ПОМОЩЬЮ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ	60
3.1 Базовые методы выделения нарушений лесного покрова	60
3.2 Детектирование вырубок с помощью алгоритма YOLO.....	61
3.3 Создание обучающей выборки для выделения нарушений лесного покрова методом семантической сегментации.....	65
3.4 Семантическая сегментация нарушений лесного покрова с помощью нейронных сверточных сетей	69
3.5 Оценка эффективности разработанного алгоритма в сравнении с традиционными методами.....	79
Выводы по третьему разделу.....	87
4 ОПЕРАТИВНОЕ КАРТОГРАФИРОВАНИЕ НАРУШЕНИЙ ЛЕСНОГО ПОКРОВА.....	89
4.1 Основные принципы применения оперативного картографирования в лесохозяйственной деятельности	89
4.2 Аппаратно-программная структура	90
4.3 Функциональные возможности сервиса	92
Выводы по четвертому разделу.....	98
ЗАКЛЮЧЕНИЕ	99
СПИСОК СОКРАЩЕНИЙ И УСЛОВНЫХ ОБОЗНАЧЕНИЙ	102
СПИСОК ЛИТЕРАТУРЫ.....	103
ПРИЛОЖЕНИЕ А (обязательное) ДЕШИФРОВОЧНЫЕ ПРИЗНАКИ НАРУШЕНИЙ ЛЕСНОГО ПОКРОВА.....	121
ПРИЛОЖЕНИЕ Б (обязательное) СРАВНЕНИЕ ОСНОВНЫХ АРХИТЕКТУР СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ	123
ПРИЛОЖЕНИЕ В (обязательное) БАЗОВАЯ КЛАССИФИКАЦИЯ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ	125
ПРИЛОЖЕНИЕ Г (обязательное) РАСПРЕДЕЛЕНИЕ ВЫБОРКИ ПО ГРУППАМ ИЗМЕНЕНИЙ.....	126

ПРИЛОЖЕНИЕ Д (обязательное) КОЛИЧЕСТВО ВЫДЕЛЕННЫХ АЛГОРИТМАМИ ОБЪЕКТОВ ДЛЯ ОДНОГО КОНТРОЛЬНОГО	129
ПРИЛОЖЕНИЕ Е (обязательное) БАЗОВАЯ ФОРМА ДЛЯ ФОРМИРОВАНИЯ КАРТЫ С НАРУШЕНИЕМ ЛЕСНОГО ПОКРОВА	131
ПРИЛОЖЕНИЕ Ж (обязательное) КОЛИЧЕСТВО ВЫЯВЛЕННЫХ И ПРОПУЩЕННЫХ ОБЪЕКТОВ В РАЗРЕЗЕ ЗОН ПРОВЕРКИ.....	132
ПРИЛОЖЕНИЕ И (обязательное) РАЗМЕЩЕНИЕ ТЕРРИТОРИИ ПРОВЕРОЧНЫХ ЗОН	133
ПРИЛОЖЕНИЕ К (обязательное) СПИСОК ИСПОЛЬЗОВАННЫХ ПРИЗНАКОВ ПРИ ОБУЧЕНИИ МОДЕЛИ	134
ПРИЛОЖЕНИЕ Л (обязательное) СПРАВКА О ВНЕДРЕНИИ В ПРОИЗВОДСТВЕННУЮ ДЕЯТЕЛЬНОСТЬ РЕЗУЛЬТАТОВ ДИССЕРТАЦИОННОГО ИССЛЕДОВАНИЯ.....	135

ВВЕДЕНИЕ

Актуальность темы исследования. На сегодняшний день остро стоит вопрос об оперативном предоставлении актуальной и наиболее полной пространственной информации для принятия оптимальных управленческих решений в лесной отрасли. Наиболее эффективным инструментом для решения многих задач в данной области являются данные дистанционного зондирования Земли (ДЗЗ). Современный этап развития ДЗЗ из космоса характеризуется стремительным ростом числа действующих на орбите спутников и одновременным увеличением пространственного и временного разрешения данных, что приводит к взрывному росту их объема. С одной стороны, это позволяет существенно расширить круг задач, решаемых на основе данных ДЗЗ, в том числе для мониторинга лесного хозяйства, а с другой стороны, возникает необходимость в разработке новых алгоритмов, обеспечивающих автоматизированное распознавание объектов на спутниковых снимках.

Спутниковые снимки и результаты их автоматизированной обработки (тематические продукты) являются одним из основных источников данных для оперативного картографирования, роль которого в последние годы непрерывно возрастает. Оперативное картографирование — это относительно новое направление в картографии, которое разрабатывается с конца 1990-х гг. Разработке этой тематики в России посвящены работы и труды Берлянта А. М., Богданова В. Н., Воронова А. Е., Кузьминых С. А., Салищева К. А., Рублева И. В., Сухих В. И., Ступина В. П., Чупиной Д. А., Щербакова Ю. С. и др.

Оперативное картографирование нарушений лесного покрова, связанных как с лесозаготовкой, так и с другими природными и антропогенными факторами, является одной из важнейших сфер применения данных ДЗЗ. Ранее разработанные методы распознавания нарушений лесного покрова по спутниковым снимкам, основанные на расчете различных вегетационных индексов и других преобразованиях спектральных каналов, уже не отвечают современным требованиям к точности и степени автоматизации систем мониторинга. В частности, по мере повыше-

ния пространственного разрешения снимков растёт значимость текстурных и геометрических признаков, которые вообще не учитываются этими методами. Следовательно, требуется разработка новых алгоритмов, адаптируемых к современным спутниковым данным. Перспективным подходом является применение сверточных нейронных сетей, которые в последние годы оцениваются как наиболее эффективные алгоритмы анализа изображений.

Степень разработанности темы исследования. Данные спутниковой съемки применяются для обнаружения и оперативного картографирования нарушений лесного покрова с 1970-х гг., когда был запущен первый спутник серии Landsat. За последующие годы было разработано множество методов, основанных на вегетационных индексах, анализе главных компонент, анализе векторов изменений, одноканальном и многоканальном обнаружении изменений, деревьях решений и др. Стоит отметить работы Аллена Т. Р., Нильсена А. А., Хансена М. С. и др.

Алгоритмы на основе сверточных нейронных сетей были разработаны и стали использоваться для сегментации спутниковых снимков в середине прошлого десятилетия. В настоящее время они применяются для маскирования облачности, классификации типов землепользования и решения ряда других задач. Это показано в работах Андреева Д. Н., Исаенкова К., Лараби М., Ронненберга О., Сирриса В., Хеткоата М. Г. и др. Однако опыт оперативного картографирования нарушений лесного покрова с применением этих методов пока весьма ограничен. Большинство работ посвящены мониторингу экваториальных лесов. Лишь в последний год были опубликованы работы по распознаванию вырубок и ветровалов в лесах умеренного пояса по общедоступным спутниковым снимкам Sentinel-2, которые показали высокую перспективность этих алгоритмов.

В России, несмотря на имеющийся значительный опыт в области создания систем дистанционного мониторинга лесов, пока не существует готовых алгоритмов и сервисов по распознаванию нарушений лесного покрова с применением сверточных нейронных сетей. Между тем, создание подобных алгоритмов и сервисов мониторинга на основе технологий веб-картографирования исключительно акту-

ально, в том числе в связи со значительным объемом незаконных рубок леса. Разработкой алгоритмов выявления нарушений лесного покрова по спутниковым снимкам и систем их мониторинга посвящены работы авторов Алексаниной А. И., Баргалева С. А., Владимировой Н. А., Крылова А. М., Лабутиной И. А., Лупяна Е. А., Потапова П. В. и др.

Цель и задачи исследования. Цель исследования состоит в разработке и валидации нового метода оперативного картографирования нарушений лесного покрова с применением сверточных нейронных сетей.

Для достижения поставленной цели решены следующие задачи:

– рассмотреть и обобщить российский и зарубежный опыт мониторинга и оперативного картографирования нарушений лесного покрова по спутниковым снимкам оптического диапазона, выявить основные преимущества и недостатки традиционных и новых (основанных на технологиях машинного обучения) методов;

– оценить возможность применения методов машинного обучения для маскирования облачности на снимках оптического диапазона;

– подготовить обучающую выборку и разработать методику выявления нарушений лесного покрова по спутниковым снимкам с применением сверточных нейронных сетей для целей оперативного картографирования;

– оценить применимость разработанной методики для выявления нарушений лесного покрова с учетом сезонного фактора и особенностей лесопользования;

– разработать прототип картографического веб-сервиса для оперативного картографирования нарушений лесного покрова;

Объект и предмет исследования. Объектом исследования являются нарушения лесного покрова.

Предметом исследования являются новые методы мониторинга и оперативного картографирования по снимкам оптического диапазона.

Научная новизна диссертационного исследования заключается в следующем:

– впервые выявлены преимущества и недостатки алгоритмов машинного обучения для целей маскирования облачности по спутниковым снимкам Sentinel-2 и PlanetScore, в сравнении с традиционными алгоритмами в разрезе разных сезонов и типов облачности;

– разработаны новые алгоритмы для идентификации нарушений лесного покрова на основе сверточных нейронных сетей по спутниковым снимкам Sentinel-2, в том числе для осеннего и весеннего периода, рассчитана точность их распознавания;

– установлено, что точность распознавания нарушений лесного покрова по снимкам Sentinel-2 с применением разработанного метода более чем в два раза превышает аналогичный показатель для традиционных пороговых методов, учитывающих только спектральные признаки;

– доказано увеличение качества и эффективности обнаружения выборочных рубок по спутниковым снимкам Sentinel-2 с применением созданных моделей машинного обучения, и получены соответствующие оценки точности.

Теоретическая и практическая значимость работы. Теоретическая значимость состоит в усовершенствовании методов оперативного картографирования нарушений лесного покрова по спутниковым данным на основе одного из наиболее эффективных алгоритмов анализа изображений – сверточных нейронных сетей архитектуры U-net. Выполненная оценка точности распознавания вырубок в зависимости от сезона съемки и типов лесопользования позволила получить новые знания о преимуществах и ограничениях данного алгоритма.

Диссертационное исследование выполнено при поддержке РФФИ в рамках проекта № 19-35-90005 «Оперативное картографирование нарушений лесного покрова на основе спутниковых данных с высоким пространственно-временным разрешением».

Практическая значимость полученных результатов очевидна в связи с тем, что оперативное получение информации о нарушениях лесного покрова как антропо-

погенного, так и природного происхождения является одной из ключевых задач современного лесного хозяйства. В настоящее время разрабатывается множество систем дистанционного мониторинга лесов различного территориального охвата. Разработанные автором алгоритмы потенциально могут быть либо встроены в работу одной из таких систем, либо стать основой для создания новой системы мониторинга. Также результаты работы использовались при реализации проекта по дистанционному мониторингу лесов Добрянского и Вайского лесничеств Пермского края на основе данных Sentinel-2 и PlanetScope в 2018–2019 гг. и при формировании отчетов крупных и средних лесопользователей в рамках исполнения приказа № 451 Министерства природных ресурсов и экологии РФ.

Методология и методы исследования. Методологической основой диссертационной работы являются научные публикации российских и зарубежных авторов, посвященные проблемам мониторинга и оперативного картографирования нарушенных лесного покрова на основе данных ДЗЗ и применению алгоритмов машинного обучения для автоматизации обработки спутниковых снимков.

Для решения задач диссертационного исследования использованы следующие методы: сегментация изображений с применением сверточных нейронных сетей, традиционные методы мультивременного анализа спутниковых снимков, статистические методы для оценки точности распознавания, геоинформационное картографирование для представления полученных результатов. Создание обучающих наборов данных основано на визуально-интерактивном дешифрировании спутниковых снимков. Для реализации алгоритмов обработки изображений разработаны программные инструменты на языке программирования Python с применением библиотеки с алгоритмами машинного обучения TensorFlow. Картографический веб-сервис разработан с помощью технологий Vue и Leaflet.

Положения, выносимые на защиту:

– применение алгоритмов машинного обучения повышает качество маскирования облачности на спутниковых снимках Sentinel-2, а также на снимках

PlanetScore с наличием снежного покрова, что позволяет повысить точность картографирования нарушений лесного покрова;

– в сравнении с традиционными методами, основанными только на спектральных признаках, использование сверточных нейронных сетей архитектуры U-net обеспечивает существенное повышение точности обнаружения и оперативного картографирования нарушений лесного покрова по разновременным снимкам Sentinel-2 в любой сезон года;

– алгоритмы на основе сверточных сетей позволяют выделять выборочные и проходные рубки как целостный объект, в отличие от традиционных методов, основанных на спектральных признаках, что увеличивает оперативность картографирования за счет снижения затрат на проведение генерализации;

– разработанный прототип картографического веб-сервиса обеспечивает высокую оперативность картографирования нарушений лесного покрова с предоставлением пользователям информации в оптимальном для них формате.

Соответствие диссертации паспорту научной специальности. Тематика диссертации соответствует областям исследований: 9 – Геоинформационное картографирование и компьютерные технологии и пункта 10 – Тематическое дешифрирование и методы дистанционного (аэрокосмического) зондирования паспорта научной специальности 25.00.33 – Картография, разработанного экспертным советом ВАК Минобрнауки России.

Личный вклад автора в диссертационное исследование заключается в выборе методов, создании обучающей выборки, проведении экспериментов с моделями машинного обучения для маскирования облачности и идентификации нарушений лесного покрова, оценке результатов экспериментов. Автором также разработан веб-сервис для оперативного картографирования нарушений лесного покрова. Подготовка к печати научных работ, отражающих результаты исследований, осуществлялась как самостоятельно, так и при участии соавторов.

Степень достоверности и апробация результатов исследования обеспечивается значительным объемом выборки для обучения нейронной сети, а также со-

поставлением результатов автоматического распознавания с проверочными наборами данных, созданными на основе визуально-интерактивного дешифрирования снимков, а также непосредственных измерений на местности, полученных из приложений к лесным декларациям лесопользователей. При оценке достоверности распознавания объектов на снимках использовались общепринятые метрики на основе матрицы ошибок.

Основные результаты исследований докладывались на научно-практических конференциях различного уровня:

- на Всероссийской открытой конференции «Современные проблемы дистанционного зондирования Земли из космоса» (г. Москва, 2018 г.);
- XVI Международном научном конгрессе «Интерэкспо ГЕО-Сибирь» (г. Новосибирск, 2020 г.);
- Всероссийской научно-практической конференции с международным участием «Цифровая география» (г. Пермь, 2020 г.);
- III, VI Международных конференциях «Региональные проблемы дистанционного зондирования Земли» (г. Красноярск, 2016, 2019 гг.).

Публикации по теме диссертации. Основные теоретические положения и результаты исследований представлены в 12 научных статьях, из которых три – в изданиях, входящих в перечень российских рецензируемых научных изданий, в которых должны быть опубликованы основные научные результаты диссертаций на соискание ученой степени кандидата наук, четыре – в изданиях, входящих в международную реферативную базу данных и систему цитирования Scopus. Получено одно свидетельство о регистрации программы для ЭВМ.

Структура диссертации. Диссертационная работа состоит из введения, 4 разделов, заключения, списка литературы из 150 наименований. Материал работы изложен на 135 страницах машинописного текста и включает в себя 13 таблиц, 46 рисунков, 10 приложений.

1 СОВРЕМЕННЫЕ МЕТОДЫ ОПЕРАТИВНОГО КАРТОГРАФИРОВАНИЯ НАРУШЕНИЙ ЛЕСНОГО ПОКРОВА

1.1 Оперативное картографирование и его место в современной картографии

Оперативное картографирование подразумевает создание и использование карт в реальном или близком к реальному масштабу времени с целью быстрого (своевременного) информирования пользователей и воздействия на ход процесса. При этом реальный масштаб времени понимается как характеристика скорости создания и использования карт, т. е. темпа, обеспечивающего немедленную обработку поступающей информации, ее картографическую визуализацию для оценки, мониторинга, управления, контроля каких-либо процессов и явлений, изменяющихся в том же темпе [3].

В России теория оперативного картографирования разрабатывается с 90-х гг. XX в. Оперативно-хозяйственные карты впервые выделены в классификации карт, предложенной в работе [23]. Берлянт А. М. предложил классификацию карт по оперативности, в которой выделены два типа карт: оперативные и базовые [3]. Реализация оперативного картографирования на практике стала возможна по мере развития ГИС-технологий и регулярно обновляемых источников пространственных данных, в том числе данных ДЗЗ. В настоящее время оперативное картографирование стало одним из направлений геоинформационного картографирования.

Положение оперативного картографирования в структуре картографии представлено на рисунке 1.1.

Оперативные карты предназначены для решения широкого спектра задач, прежде всего, для инвентаризации объектов, предупреждения (сигнализации) о неблагоприятных или опасных процессах, слежения за их развитием, составления рекомендаций и прогнозов, выбора вариантов контроля, стабилизации или изменения хода процесса в самых разных сферах — от экологических ситуаций до политических событий. При этом следует различать оперативные карты двух типов: одни рассчитаны на долговременное последующее использование и анализ (например, карты итогов го-

лосования избирателей), а другие — на кратковременное использование для незамедлительной оценки какой-либо ситуации (например, карты созревания сельскохозяйственных посевов) [3]. Также стоит учитывать и характер динамики картографируемых явлений. По классификации [3] выделяется четыре группы явлений:

- медленные;
- быстрые;
- циклические и периодические процессы;
- эпизодические и скачкообразные изменения.

Основные свойства, которыми должны обладать оперативные карты, для максимальной эффективности оперативного картографирования:

- читаемость;
- воспринимаемость;
- простота внешнего оформления;
- адекватный подбор условных обозначений (знаков и шкал).




Рисунок 1.1 – Положение оперативного картографирования в структуре картографии [3]

Берлянт А. М. отмечает основные факторы, которые определяют эффективность оперативного картографирования [2]:

– надежность автоматической системы, которая, в свою очередь, зависит от скорости ввода и обработки данных, организации баз данных и системы доступа к ним, быстродействия вычислительных систем;

– хорошую читаемость и воспринимаемость самих оперативных карт, простоту их внешнего оформления, адекватный подбор знаков и шкал, обеспечивающие эффективное зрительное восприятие в условиях оперативного анализа ситуаций;

– оперативность распространения карт и доставки их потребителям, в том числе, с использованием для этого телекоммуникационных сетей.

В зарубежной литературе термин, точно соответствующий используемому в России понятию оперативного картографирования, отсутствует. Наиболее близким аналогом является картографирование в режиме, близком к реальному времени (*near real-time mapping*). Соответствующее направление картографии активно развивается в последние десятилетия и внедряется в практическую деятельность [35]. Наибольшее количество публикаций посвящено оперативному картографированию чрезвычайных ситуаций природного и техногенного характера, в частности наводнений [132, 109], последствий землетрясений и др.

В настоящее время развитию оперативного картографирования способствуют два ключевых фактора:

– появление новых источников, оперативно обновляемых пространственных данных (космической съемки с высоким временным разрешением, съемки с беспилотных летательных аппаратов (БПЛА), информации из социальных сетей) [47];

– интенсивное развитие технологий веб-картографии, обеспечивающих оперативную публикацию данных и их широкую доступность.

В современных условиях возможна реализация оперативного картографирования в новых областях, в которых до недавнего времени это было невозможно по

причине отсутствия необходимых данных. К таким областям относится лесное хозяйство и, в частности, мониторинг нарушений лесного покрова.

1.2 Нарушения лесного покрова и организация их мониторинга в РФ

1.2.1 Классификация нарушений лесного покрова

Своевременное и оперативное выявление нарушений в лесном фонде – важная задача в структуре лесного хозяйства. Раннее выявление участков растительности, поврежденной вредителями, антропогенными или другими факторами, позволяет быстро принимать необходимые меры.

Нарушения лесного покрова традиционно классифицируют на природные (в англоязычной терминологии – natural forest disturbances) и антропогенные (human-induced disturbances). В свою очередь, природные нарушения могут быть вызваны абиотическими и биотическими факторами. Среди первых наиболее значимыми являются лесные пожары, засухи и ветровалы, а среди вторых – повреждения, вызванные насекомыми-вредителями, а также болезни леса [107]. Приведенная классификация с некоторыми изменениями используется в большинстве исследований по оценке различных факторов, вызывающих нарушения лесного покрова. Более детальная классификация нарушений лесного покрова, принятая в России, приведена в таблице 1.1.

Таблица 1.1 – Классификация нарушений лесного покрова [19]

Нарушения лесного покрова		
имеющие лесопатологический характер	связанные с лесохозяйственной деятельностью	вызванные иными факторами
<ul style="list-style-type: none"> – повреждения пожарами; – повреждения ветрами; – повреждения хвое-листогрызущими насекомыми; – повреждения стволовыми вредителями; – поражения болезнями леса [19] 	<ul style="list-style-type: none"> – рубки главного пользования; – рубки ухода за лесом; – санитарные рубки; – прочие рубки [13] 	<ul style="list-style-type: none"> – незаконный захват земель; – несанкционированные свалки; – гибель вследствие загрязнения окружающей среды

Также широко используется классификация нарушений лесного покрова по характеру повреждения лесов. Выделяются сплошные нарушения (резкая гибель насаждений на значительной площади), а также несплошные (мозаичные) нарушения с разной степенью повреждения древостоя. В англоязычной литературе им соответствует понятия *stand-replacing disturbances* и *non-stand replacing disturbances* [121]. Характер повреждения древостоя имеет решающее влияние на выбор данных ДЗЗ, используемых для мониторинга, а также на возможность автоматизации распознавания нарушений по снимкам [11].

Вклад различных типов нарушений в общую площадь потерь лесного покрова существенно различается для разных регионов России и мира. Так, по данным [121], в целом по России за 2002–2011 гг. 65,5 % площади потерь лесного покрова были вызваны пожарами, а около 30 % связаны с лесозаготовкой (рисунок 1.2). При этом средняя площадь лесозаготовок оценивалась в 0,8 млн га/год. На другие нарушения приходится всего 4,5 % площади потерь лесов. В Восточной Европе, включая также Европейскую территорию России, вклад естественных нарушений составляет меньше 10 % от общей площади потерь лесов [77]. Лишь в отдельные годы он может достигать 30–50 %, главным образом за счет крупных лесных пожаров.




Рисунок 1.2 – Соотношение площади различных типов нарушений лесного покрова в России

1.2.2 Организация мониторинга нарушений лесного покрова в России

В России согласно нормативным документам [18] все нарушения лесного покрова природного характера, а также некоторые антропогенные нарушения являются объектом лесопатологического мониторинга. Его целью является наблюдение за состоянием лесов, нарушением их устойчивости, повреждениями (поражениями) лесонасаждений вредителями, болезнями и другими природными и антропогенными факторами среды, а также за динамикой этих процессов.

Также актуальна задача своевременного обнаружения и мониторинга мероприятий по заготовке древесины и иных лесохозяйственных мероприятий, связанных с рубкой деревьев. Это позволяет контролировать устойчивое лесопользование, выявлять и предотвращать нарушения лесного законодательства.

За решение задач по оценке, выявлению нарушений в Российской Федерации отвечает Федеральное агентство лесного хозяйства (Рослесхоз) – организация, подведомственная Министерству природных ресурсов и экологии Российской Федерации. Агентство осуществляет реализацию государственной политики в сфере лесного хозяйства.

В составе ведомства выделяются несколько управлений (рисунок 1.3), которые отвечают за отдельные виды нарушений. Контроль за использованием лесов (рубками леса) производится в управлении лесного надзора и контроля за переданными полномочиями, а также в ФГБУ «Рослесинфорг» в рамках государственной инвентаризации лесов (ГИЛ). При проведении ГИЛ закреплено выделение следующих нарушений:

- рубка лесных насаждений без правоустанавливающих документов;
- рубка с превышением эксплуатационной площади лесосек;
- рубка за пределами отвода лесосек;
- рубка неэксплуатационных участков леса, в том числе семенных полос, групп и куртин;
- рубка лесных насаждений в различных категориях защитных лесов и особо защитных участков лесов, где рубки запрещены или ограничены;

- нарушения основных организационно-технических элементов рубок (превышение разрешенной ширины лесосеки, превышение разрешенной площади лесосеки, несоблюдение сроков и способов примыкания лесосек, несоблюдение направления лесосеки, несоблюдение количества зарубов (лесосек) в расчете на 1 км);
- незаконное использование лесов.




Рисунок 1.3 – Управления и подведомственные организации Рослесхоза, ответственные за мониторинг лесов

Лесопатологический мониторинг находится в ведении специализированного управления охраны, защиты и воспроизводства лесов. Аналогичные задачи решает также ФБУ «Рослесозащита». Для защиты лесов от пожаров в структуре Рослесхоза выделяется ФБУ «Авиалесоохрана».

Оценка лесохозяйственных, лесопатологических нарушений производится и при таксации лесов. Под таксацией понимается оценка количественных и качественных характеристик лесных насаждений [16]. По материалам ДЗЗ производится выявление изменений, произошедших в результате рубок, пожаров и других природных и антропогенных воздействий, приведших к трансформации покрытых лесной растительностью земель в не покрытые лесом земли и нелесные земли.

1.3 Дешифровочные признаки нарушений лесного покрова

Для отслеживания и обнаружения негативных изменений в лесах активно используются данные ДЗЗ. Анализ возможностей снимков разного пространственного и временного разрешения для решения этих задач представлен в таблицах 1.2, 1.3.

Выявление нарушений базируется на нескольких дешифровочных признаках. Они позволяют отделить интересующий объект от других. Выделяются прямые и косвенные дешифровочные признаки. Прямыми признаками называются свойства объекта, которые непосредственно находят свое отображение на снимках [7, 42, 43]. Для нарушений лесного покрова главными признаками являются: *форма и площадь, спектральный образ, текстура и структура*. Косвенные дешифровочные признаки характеризуют объект опосредованно через какой-либо другой природный или искусственный компонент окружающей среды. Такие признаки используются при экспертном дешифрировании, и их анализ сложно поддается автоматизации. Примеры спутниковых снимков разных типов нарушений лесного покрова с описанием их дешифровочных признаков приведены в приложении А.

Форма – наиболее надежный, т. е. не зависящий от условий съемки, признак [7]. Данный признак может быть использован при идентификации лесохозяйственных изменений. Границы вырубки (делянки) прямые, их форма часто близка к прямоугольнику или многоугольнику, что нетипично для природных объектов. Выборочные и проходные рубки могут быть в форме прямых параллельных линий (волока), с одной выделяющейся линией (центральный волок). Для гарей характерны резко изорванные границы, наличие куртин здоровых деревьев около водотоков, балок или других понижений. Изорванность границ гарей определяется в основном рельефом местности: на повышенных местах пожар проникает в лесные массивы на более значительную глубину [30]. Форма ветровалов всегда вытянута в соответствии с преобладающим направлением ветра. Она напоминает веер либо сильно линейно вытянута.

Площадь может служить важным дешифровочным признаком, она варьируется в зависимости от группы изменений. Лесохозяйственные изменения (за исключением сплошных санитарных рубок) варьируются в диапазоне 1–200 га. Лесопатологические изменения становятся заметными на космическом снимке при высокой концентрации погибших деревьев или при массовом распространении патогенного явления. Очаги вредителей, ветровалы, гари могут иметь площадь до сотен и даже тысяч км².

Одним из основных дешифровочных признаков нарушений лесной растительности является *спектральный образ*. Особенностью растительности является относительно малое отражение в красной области спектра и большее в ближней инфракрасной (ИК). При повреждении растений и снижении фотосинтеза отражение в красной области спектра увеличивается, а в ближней инфракрасной зоне падает. Кроме того, значительно возрастает отражательная способность в среднем ИК, что связано с падением содержания влаги в поврежденных деревьях. Чем более значительны изменения спектральной отражательной способности, тем легче выявляются поврежденные насаждения [7, 11].

На спектральные характеристики нарушений лесного покрова влияет ряд факторов, образуя *структуру* и *текстуру*. Крона одного дерева меньше размера пикселя на снимке среднего разрешения, поэтому часто происходит смешение спектральных характеристик здоровых и поврежденных деревьев, что может существенно снижать контрастность изменений. Таким образом, чем выше мозаичность, неоднородность повреждений, тем выше требования к разрешению снимков. Кроме того, следует иметь в виду, что сезонные изменения спектральной отражательной способности сельхозугодий, лугов, пойм гораздо более контрастны, чем изменения леса при повреждении. После повреждения насаждений хвоелистогрызущими насекомыми часто сразу же начинается процесс восстановления листвы (хвои). В этой ситуации оценить степень повреждения можно только по снимкам на пике объедания [11]. Благодаря структуре на космических снимках хорошо выделяются захламленные гари: в виде штрихов заметны беспорядочно поваленные

деревья и корневые вывороты с землей, следы разработки гарей (штабеля бревен, кучи хвороста, трелевочные волокни, лесовозные дороги). Различие во внутренней структуре позволяет отделить ветровалы от гарей. У ветровалов наблюдается одинаковое направление вывала деревьев, совпадающее с общим направлением [30].

Таблица 1.2 – Возможность обнаружения нарушений лесного покрова по данным ДЗЗ различного пространственного разрешения

Задача мониторинга	Критерии сравнения	Пространственное разрешение снимков			
		сверхвысокое (< 1 м/пиксель)	высокое (1–10 м/пиксель)	среднее (10–30 м/пиксель)	низкое (> 30 м/пиксель)
1	2	3	4	5	6
Нарушения, связанные с рубками леса	1 Возможность оценки правильности контура	возможно	возможно	невозможно	невозможно
	2 Направление вырубок, сроки и способы примыкания, число зарубов в квартале	возможно	возможно	возможно	невозможно
	3 Выделение недорубов, перерубов	возможно	возможно	невозможно	невозможно
Лесопатологические нарушения	1 Минимальная область поражения, выделяемая на снимке	отдельные деревья	группы деревьев (> 0,5 га)	области от нескольких га	очень крупные области (сотни и тысячи га)
	2 Возможность оценки степени поврежденности (сильная, слабая и т. д.)	выделяют три-четыре категории повреждений (погибшие, сильно-, средне- и слабоповрежденные насаждения, повреждения на уровне крон)	выделяют три-четыре категории повреждений (погибшие, сильно-, средне- и слабоповрежденные насаждения)	выделяют сильные и средние повреждения	выделяют сильные и средние повреждения
Нарушения, связанные с иными факторами	1 Минимальная область поражения, выделяемая на снимке	отдельные деревья	группы деревьев (> 0,5 га)	области от нескольких га	очень крупные области (сотни и тысячи га)

Таблица 1.3 – Выделение нарушений лесного покрова по данным ДЗЗ различного временного разрешения

Задача мониторинга	Временное разрешение (частота повторной съемки)			
	ежедневно (PlanetScope)	от 1 дня до недели (Sentinel)	от недели до месяца (Landsat)	больше месяца (коммерческая съемка)
Нарушения, связанные с рубками леса	Оперативное выявление	Оперативное выявление	Оценка уже завершенных мероприятий	Оценка уже завершенных мероприятий
Лесопатологические нарушения	Возможно, включая оценку степени повреждения (при пожарах, ветровалах)	Возможно, включая оценку степени повреждения (при пожарах, ветровалах)	Возможно (при пожарах, ветровалах), факт поражения вредителями	Возможно (при пожарах, ветровалах). При поражении вредителями – степень повреждения
Нарушения, связанные с иными факторами	Выявление нарушений в день нарушения	Выявление нарушений после совершения нарушения	Выявление после совершения нарушения	Выявление после совершения нарушения

Исходя из таблицы 1.3, можно отметить, что для мониторинга нарушений в лесном покрове лучше всего подходят данные высокого и сверхвысокого пространственного разрешения. Однако, учитывая высокую стоимость снимков с разрешением меньше 1 м/пиксель и небольшую площадь покрытия одной сценой, практика их применения для мониторинга ограничена. Наиболее подходящими данными в большинстве случаев являются снимки со спутников PlanetScope (3 м) и Sentinel – 2 (10 м). Они имеют наилучшее соотношение между временным и пространственным разрешением, что является основным фактором для успешного применения в оперативном картографировании нарушений лесного покрова.

1.4 Традиционные методы автоматизированного выявления нарушений лесного покрова по мультиспектральным спутниковым данным, их возможности и ограничения

Нарушения лесного покрова имеют свой набор дешифровочных признаков, который позволяет выделять их на космических снимках. Однако, по мере роста площади мониторинга и количества снимков, возникает необходимость автоматизиро-

вать этот процесс. Методы автоматизации выявления нарушений на основе этих признаков разрабатываются на протяжении нескольких десятилетий, практически с момента запуска первых спутников серии Landsat и появления первых цифровых снимков Земли из космоса. Так, еще в работе [147] было предложено использовать мультитременные синтезы из различных каналов съемочной системы MSS/Landsat для идентификации участков гибели (дефолиации) лесов в результате вспышек насекомых-вредителей. В исследовании [129] впервые применены снимки Landsat для определения площади гибели лесов, вызванной пожарами и ветровалами.

С запуском в 1984 г. спутника Landsat-4 с сенсором TM (шесть спектральных каналов с пространственным разрешением 30 м) возможности космического мониторинга лесов по разновременным снимкам значительно расширились. При повреждении растений и снижении фотосинтеза отражение в красной области спектра увеличивается, а в ближней ИК падает, а также значительно возрастает отражательная способность в среднем ИК канале, что связано с падением содержания влаги в поврежденных деревьях. На этих свойствах основаны разнообразные вегетационные индексы, используемые для выявления нарушений лесного покрова. Наиболее известными из них являются нормализованный разностный вегетационный индекс NDVI, нормализованный индекс инфракрасной разности NDII (в русскоязычной литературе он же – коротковолновой вегетационный индекс SWVI) и нормализованный разностный индекс гарей NBR. Идентификация нарушений лесного покрова производится по разности этих индексов, вычисленной по разновременным снимкам.

В дальнейшем была показана высокая эффективность индекса NDII [88] для выявления вырубок, ветровалов и участков повреждения лесов вредителями [11, 117]. В этих же работах подтверждено, что индекс NDII более эффективен для выявления нарушений лесного покрова, чем широко известный NDVI. В свою очередь, разностный индекс NBR весьма эффективен для выявления выгоревших территорий и имеет высокую корреляцию со степенью повреждения лесов пожарами [56].

В ряде работ рассматривалось применение более сложных индексов, чем простые нормализованные разности, для обнаружения нарушений лесного покрова.

К ним относятся как индексы, основанные на видимом и ближнем ИК диапазонах спектра (SAVI и др.), так и с использованием среднего ИК, а также результаты преобразования Tasseled Cap [63]. Это преобразование представляет собой линейное изменение яркости мультиспектральных изображений, которое позволяет снизить размерность входных данных и упрощает для человека процесс дешифрирования снимков. По сути, этот метод является частным случаем метода главных компонент, который позволяет сократить число входных признаков и использовать только самые важные из них. Отличием от метода главных компонент является возможность расчета коэффициентов для линейного преобразования для одного сенсора без привязки к какой-то конкретной сцене, полученной с этого сенсора.

В работе [145] проведен сравнительный анализ эффективности различных вегетационных индексов и ряда других методов обнаружения изменений по снимкам Landsat на примере ущерба от урагана Катрина в США и установлено, что наибольшую точность обеспечивает преобразование TCW (Tasseled Cap Wetness), в котором используется одна из компонент преобразования Tasseled Cap – так называемая «влажность» (wetness). Она представляет из себя сумму значений яркости видимого диапазона ближнего инфракрасного и средних инфракрасных каналов Landsat.

Помимо вегетационных индексов, для картографирования нарушений лесного покрова по снимкам оптического диапазона успешно применяется ряд других методов: одномерное и многомерное обнаружение изменений, анализ векторов изменений, сравнение результатов классификации, деревья решений.

Метод многомерного обнаружения изменений (Multivariate alteration detection, MAD), основан на построении многомерной корреляции между снимками (каноническом корреляционном анализе). Его преимуществом является сниженная чувствительность к настройкам сенсора, а также схемам радиометрической и атмосферной коррекции [112]. Метод MAD реализован в программном пакете Scanex Image Processor, разработанном ИТЦ СканЭкс, а в руководстве пользователя [130] приведено его описание.

Выборочный анализ главных компонент (selective PCA) основан на использовании двух входных переменных – по одному каналу снимков, полученных до и после события, или их производных (NDVI или результатов преобразования Tasseled Cap) [62].

Метод анализа векторов изменений (change vector analysis, CVA), предложенный в работе [48], позволяет определить две компоненты изменений – магнитуду и направление. Он обеспечивает, во-первых, разделение реально произошедших изменений на местности и фоновых (связанных, например, с появлением атмосферной дымки), а также в ряде случаев определение характера изменений (положительные/отрицательные изменения и их возможная причина), что не позволяет определить метод MAD.

Сравнение результатов классификации разновременных снимков (post-classification comparison, PCC) также может использоваться для выявления нарушений лесного покрова с высокой точностью [145]. Недостатком данного метода является низкая степень автоматизации и сложность настройки параметров классификатора для множества снимков.

Современным и эффективным методом обнаружения изменений лесного покрова является построение «деревьев решений» (decision tree). Именно построение дерева решений на основе многолетнего ряда снимков Landsat, полученных за вегетационный период, было использовано в проекте Global Forest Change для создания ежегодно обновляемых данных о нарушениях лесного покрова Земли. Для лесов умеренной зоны данные о площади потерь имеют точность свыше 90 % [89].

В России разработку методов обнаружения нарушений лесного покрова длительное время ведут Институт космических исследований Российской академии наук (ИКИ РАН) и Российский центр защиты леса. В ИКИ РАН до недавнего времени основное внимание уделялось оценке повреждения лесов пожарами, для чего также успешно применяются разностные и относительные индексы, основанные на среднем ИК (см. напр. [6]). Обзор российского опыта мониторинга нарушений лесного покрова и существующих проблем в данной области приведен в работе [11].

Кроме того, в данной работе предложены методические рекомендации и представлены результаты мониторинга ветровалов в лесах Европейской части России [9] и оценки повреждения лесов вследствие вспышек размножения вредителей [10]. Большой интерес представляет работа [8], в которой были оценены предельные возможности съемочной системы Landsat для выявления нарушений лесного покрова. Аналогичная методика может быть применена, например, для оценки точности автоматизированного выделения вырубок (в том числе незаконных) по снимкам среднего и высокого разрешения.

Основным ограничением всех перечисленных методов, основанных на спектральных признаках, является невозможность автоматизированного распознавания типов нарушений лесного покрова (вырубки, гари, ветровалы, повреждения вредителями и болезнями). Для решения этой задачи требуется дополнительный анализ геометрических и текстурных признаков, без которого точность разделения будет невысока. Так, в работе [97] была предпринята попытка разделения по спектральным признакам вырубок и ветровалов, точность разделения составила 76–77 %, что недостаточно для практического применения. Еще один подобный эксперимент выполнен для разделения всех типов нарушений лесного покрова на территории США с применением современного и эффективного классификатора RandomForest [91]. Однако точность также оказалась невысокой (ошибки до 32 %). Для более точного выделения нарушений необходимо рассматривать не только спектральные характеристики отдельно, а совместно с текстурой, и, главное, геометрией объекта.

В последние годы возникло еще одно существенное ограничение – новые группировки спутников, обеспечивающие оперативный мониторинг с высокой повторяемостью и детальностью, либо ведут съемку в среднем ИК канале с более низким пространственным разрешением (Sentinel-2), либо не имеют его вовсе (PlanetScope). Таким образом, алгоритмы обнаружения изменений, разработанные для данных Landsat, часто оказываются неприменимы для данных Sentinel-2 и PlanetScope. Следовательно, требуется разработка новых алгоритмов, использующих данные только видимого и ближнего ИК диапазона спектра, а также текстурные и геометрические признаки (зна-

чимось которых растет с повышением пространственного разрешения данных). Лучше всего для этого подходят методы машинного обучения (МО).

1.5 Возможности методов машинного обучения при обработке материалов ДЗЗ для обнаружений нарушений лесного покрова

1.5.1 Основные модели машинного обучения, применяемые для обработки данных ДЗЗ

Исследования по разработке алгоритмов машинного обучения проводятся уже с середины прошлого века. В 1940–1960-х гг. данное научное направление называлась кибернетикой, затем в 1980–1990-х гг. коннекционизмом. В сегодняшнем понимании термин МО развивается с 2006 г. [85]. В 1959 г. МО было определено «как научная дисциплина, которая наделяет компьютеры способностью учиться, не будучи явно запрограммированными» [128], а в 1997 г. было сформулировано более «техническое» определение: «Говорят, что компьютерная программа обучается на основе опыта E по отношению к некоторой задаче T и некоторой оценке производительности R , если ее производительность на T , измеренная посредством R , улучшается с опытом E » [106].

За более чем 50 лет разработки создано множество алгоритмов машинного обучения (приложение Б), но единой, общепринятой классификации не существует. Наиболее общая представлена на рисунке 1.4, а более детальный вариант представлен в приложении В.

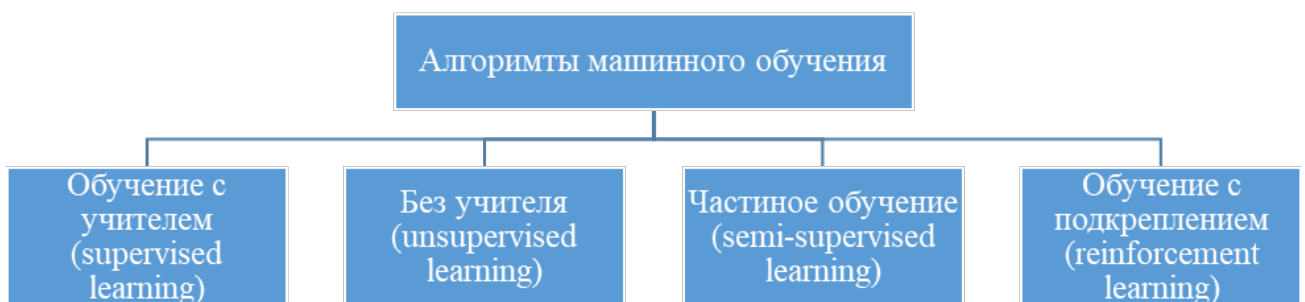


Рисунок 1.4 – Базовая классификация алгоритмов машинного обучения

Но именно в последние десятилетия наблюдается появление все более сложных архитектур для применения в различных областях. Так, внедрение технологий МО при переводе текстов существенно улучшило качество получаемого результата [86]. Методы МО позволили по-новому подойти к решению классических задач компьютерного зрения: классификации и сегментации изображений. С того момента, как в 2012 г. на ImageNet Large Scale Visual Recognition Competition (ILSVRC) [96] лучший результат показали исследователи, которые использовали сверточные сети, именно такой тип архитектуры чаще всего используется для обработки изображений.

Обработка данных ДЗЗ представляет собой частный случай задачи обработки изображений. Поэтому для решения этих задач также применяются сверточная нейронная сеть (СНС). Главное их отличие от традиционных сетей – это наличие сверточных слоев. Принцип работы сверточного слоя [96] представлен на рисунке 1.5.

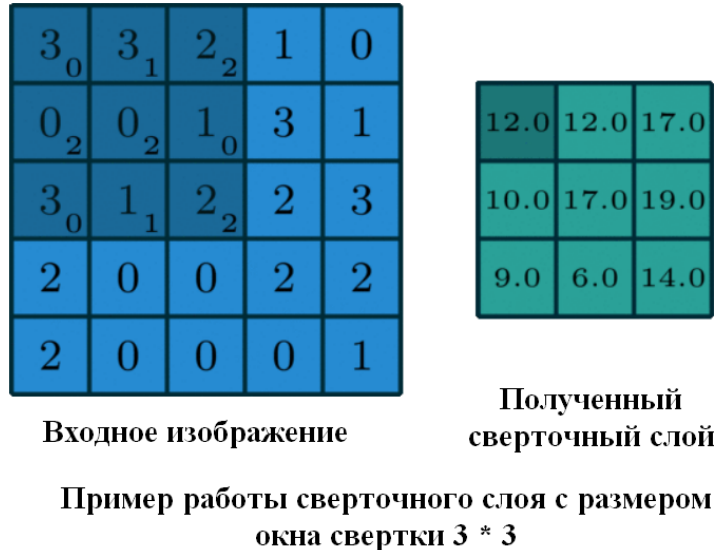


Рисунок 1.5 – Принцип работы сверточного слоя

Слои нейронной сети, полученные после обработки входного, называются сверточными (convolution layers). На первых сверточных слоях выделяются самые простые свойства объекта (углы, границы, форма и т. д.). С каждым новым уровнем

на основе ранее выделенных свойств получают признаки объекта более высокого порядка. Наряду со сверточными слоями, в СНС есть полносвязные слои (fully connected layers) и слои пуллинга (pooling layers). Первый тип позволяет получить итоговые предсказания модели, взвешивая между собой все полученные СНС признаки. Второй тип позволяет сжать входное изображение для сокращения вычислительной нагрузки, расхода памяти и количества параметров, тем самым ограничивая риск переобучения (потери способности к обобщению закономерностей в данных). Можно получить множество различных архитектур, комбинируя различным способом эти слои, меняя порядок, количество слоев и т. п. (см. приложение Б). Существует множество модификаций представленных архитектур (например, ResNet50), где исследователи добавляют больше слоев или используют разные параметры при обучении и т. д.

Другой часто используемый для анализа данных ДЗЗ алгоритм МО – RandomForest. Этот алгоритм основан на усреднении значений множества деревьев решений. Деревья – это простой, но мощный алгоритм машинного обучения. С помощью различных алгоритмов (например, CART [70]) данные делятся на максимально «чистые, однородные» классы. Однородность классов определяется разными метриками (например, Gini impurity [74]). Для классификации в каждом конкретном узле используется один признак, а для обучения случайно выбирается поднабор из всего обучающего набора. Именно предсказания множества таких деревьев использует алгоритм RandomForest. Для получения итогового решения учитываются прогнозы всех индивидуальных деревьев и предсказывается класс, который стал обладателем «большинства» голосов [52].

Совместное использование нескольких методов машинного обучения для решения одной задачи называется ансамблевым методом (ensemble methods). К такому типу относится RandomForest, а также методы бустинга (boosting), стэкинга (stacking), бэггинга (bagging). Первоначально называемый усилением гипотезы (hypothesis boosting), к бустингу относится любой ансамблевый метод, который способен комбинировать нескольких «слабых» учеников в одного «сильного» уче-

ника. Основная идея большинства методов бустинга предусматривает последовательное обучение нескольких моделей, причем каждая из них старается «исправить» или улучшить своего предшественника. Так повторяется до того момента, пока не получится «идеальная модель», либо закончится число итераций. Результатом в данном случае будет взвешенное значение между предсказанием каждой отдельной модели и ее веса (насколько правильно данная модель предсказывает примеры из обучающей выборки) [82].

Другой вид бустинга – градиентный, в котором каждый новый элемент ансамбля обучается на ошибках предыдущего элемента ансамбля. Итоговый прогноз формируется аналогично предыдущим методам бустинга (т. е. взвешиванием предсказаний от всех моделей). При бэггинге объединяются несколько моделей, которые обучены на разных поднаборах одной обучающей выборки, причем одна модель может несколько раз обучаться на разных поднаборах. Итоговый прогноз обычно вырабатывается как статистическая мода (т. е. самый частый прогноз от всех отдельных моделей в ансамбле).

Метод стэкинга отличается использованием еще одной модели (blender, смеситель) для предсказания итогового результата. Для этого специально выделяется «удерживающий» (hold-out) набор из имеющейся обучающей выборки, который не использует ни одна из составляющих ансамбля. Используя результаты отдельных моделей, смеситель предсказывает значения из удерживающего набора [60].

1.5.2 Опыт применения методов машинного обучения для мониторинга нарушений лесного покрова

Современные алгоритмы машинного обучения, основанные на сверточных нейронных сетях, были разработаны в середине прошлого десятилетия. Однако уже накоплен значительный опыт их применения в задачах сегментации спутниковых снимков, в частности для маскирования облачности [1, 65, 146] или классификации типов землепользования [78]. Но к настоящему времени опубликовано сравнительно немного работ, где рассматривается применимость этих алгоритмов для об-

нарушения нарушений лесного покрова [31, 36]. Следовательно, задача обнаружения нарушений лесного покрова с применением этих алгоритмов обладает высоким уровнем новизны.

Среди различных архитектур СНС, разработанных в последние годы, одной из наиболее перспективных для анализа изображений, в том числе космических снимков, является архитектура Unet [125]. Данная архитектура широко применялась для решения различных задач сегментации космических снимков, в том числе для мониторинга экваториальных лесов в Амазонии [44, 54].

В 2020 г. были опубликованы результаты работ по распознаванию ветровалов в лесах Западной Европы [131] и вырубок на территории Украины [67] с применением сверточных нейронных сетей архитектуры U-net. Точность выявления последствий ветровалов составила 40–50 %, для вырубок точность оказалась чуть выше – порядка 50–55 %.

Из других алгоритмов, основанных на машинном обучении, имеется опыт применения классификатора RandomForest для распознавания выборочных рубок по снимкам Landsat [44]. Точность обнаружения составила около 90 % при этом пропуск объектов – около 8 %, доля ложных срабатываний – 20 %, что можно считать успешным результатом.

В работе [102] рассматриваются возможности картографического сервиса Silvisense для комплексного мониторинга лесов Европы, в том числе обнаружения вырубок, гарей, ветровалов. Отмечается, что для этой задачи используются модели «глубокого обучения» (deep learning), однако оценки точности не приведены.

Еще меньше публикаций посвящено использованию спутниковых данных PlanetScore для решения этих задач. Вероятно, это объясняется тем, что данные появились только в 2017 г. и с 2018 г. распространяются на коммерческой основе. Можно отметить описание технологии мониторинга тропических лесов с высокой периодичностью [140]. Данная технология предполагает выявление нарушений лесного покрова в два этапа: на первом этапе производится семантическая сегментация снимков на несколько классов (лес, водная поверхность, открытая почва, об-

лака и их тени) на основе сверточной нейронной сети архитектуры U-net. На втором этапе анализируется изменение вероятности каждого класса по серии разновременных снимков, в результате чего выявляются участки вырубок и других нарушений лесного покрова.

Ограничения методов машинного обучения

Решение задачи обработки данных ДЗЗ с помощью задач машинного обучения имеет и ограничения. Прежде всего, для создания хорошей модели необходима большая обучающая выборка (dataset). С увеличением количества образцов все методы машинного обучения будут показывать схожие результаты (рисунок 1.6). Существующие обучающие выборки не всегда подходят для решения новых задач, а создавать новые очень трудозатратно.




Рисунок 1.6 – Зависимость точности предсказаний разных алгоритмов МО от размера обучающей выборки [51]

Операции обучения модели и дальнейшие предсказания отличаются высокой вычислительной сложностью и требуют наличия соответствующего технического обеспечения. Лучше всего с этими задачами справляются graphical processing unit

(GPU). Обработка материалов ДЗЗ еще более увеличивает требования к техническим средствам, так как обрабатываемые данные имеют большой объем.

В работе [58] отмечается, что проблемой при обработке спутниковых изображений с помощью нейронных сетей является пространственный экстенд объектов, т. е. их размер. В одном из крупнейших обучающих наборов с изображениями (ImageNet [94]) размеченные объекты имеют большой размер в несколько десятков пикселей. На космических снимках даже крупные объекты (например, автомобиль), могут занимать только несколько пикселей (в зависимости от пространственного разрешения снимков).

Однако это ограничения можно преодолеть (например, используя методы бустинга для сокращения размера обучающей выборки). Нейронные сети могут находить структуру в существующих данных и при правильном обучении делать предположения о данных, которые не были использованы в обучении.

1.6 Информационные системы дистанционного мониторинга и картографирования лесов

В последние годы основным трендом в развитии космического мониторинга (в том числе нарушений лесного покрова) является создание автоматизированных систем дистанционного мониторинга (СДМ). Соответственно, алгоритмы распознавания нарушений лесного покрова должны быть встраиваемыми в эти системы [37]. В настоящее время ведется активная разработка автоматизированных СДМ лесного покрова, прежде всего на основе данных Sentinel-2 и Landsat. Основные характеристики существующих СДМ приведены в таблице 1.4.

Уже с 1997 г. Всемирный институт ресурсов (WRI) ведет систему Global Forest Watch. На сегодняшний день в этот проект вовлечено множество стран. Однако именно с 2016 г. система, благодаря внедрению новых методов обработки данных ДЗЗ, предоставляет возможность выявления нарушений лесной растительности ежемесячно и даже еженедельно. Кроме инструментов анализа нарушений лесного покрова, сервис интегрирует множество данных для визуализации (например,

особо охраняемые природные территории и др.), в том числе есть данные о причинах нарушений лесного покрова. В качестве основных данных используются различные тематические продукты на основе Landsat [89]. Доступ предоставляется в виде открытого картографического веб-сервиса.

Таблица 1.4 – Основные характеристики существующих информационных систем дистанционного мониторинга

Название системы/алгоритма	Пространственное разрешение	Временное разрешение
Global Forest Watch	10–30 м/пиксель	неделя – месяц
Modis + Fusion Landsat	250–1000 м	день
ВЕГА-лесопатолог	5 (30)-1000 (высокое пространственное разрешение доступно для части территории)	день – несколько лет (в зависимости от функций)
ВЕГА-Приморье	10–30 м/пиксель	год
Кедр	10–30 м/пиксель	день – неделя
NextGIS (Система оперативного обнаружения зимних рубок)	15–30 м/пиксель	день – неделя
ИСДМ Рослесхоза	250–1 000 м/пиксель	день – несколько дней

В работе [93] рассматривается методика выявления нарушений лесного покрова по данным MODIS/Landsat. Данные MODIS имеют высокую повторяемость съемки, но низкое пространственное разрешение, в отличие от снимков Landsat. Авторы получают серию снимков Landsat, MODIS, объединяют их с помощью собственного разработанного алгоритма и получают «прогнозируемую» сцену Modis. После этого она сравнивается со снимком, который был реально получен съемочной системой. Нарушения лесного покрова – это разница между «прогнозируемым» и реальным снимком.

В России наибольший опыт в этом отношении имеется в Институте космических исследований Российской академии наук (ИКИ РАН) [4]. Так, еще в 2012 г.

был разработан проект создания системы мониторинга нарушений лесного покрова и санитарного состояния лесов «ВЕГА-Лесопатолог». Однако к настоящему времени такие системы разработаны только для регионального уровня, причем в основном для Дальнего Востока.

В Приморском крае действует система комплексного дистанционного мониторинга лесных ресурсов «Вега-Приморье», разработанная ИКИ РАН и ООО «ИКИЗ» [5]. В данной системе реализованы алгоритмы распознавания вырубок, гарей и ветровалов по данным Landsat и Sentinel-2 с шагом в год в режиме «скользящего временного окна» т. е. для анализа используются снимки, полученные в условиях приблизительно равной освещенности и условий вегетации. Также для мониторинга лесов Дальнего Востока России разработана система мониторинга лесоизменений «Кедр». Основной целью ее создания является обнаружение незаконных вырубок леса по оперативным данным Landsat-8 и Sentinel-2.

Для этого же региона создана система оперативного обнаружения зимних рубок леса по данным Sentinel-2 [25]. Система работает в автоматическом режиме, включает возможности загрузки снимков, фильтрации облачности, нормализации снимков с учетом годового хода спектральной отражательной способности и собственно поиска изменений. Для решения этой задачи использована нейронная сеть типа многослойный перцептрон [126]. Данная система обеспечивает обнаружение нарушений лесного покрова, произошедших только в зимний период (вырубок).

Информационная система дистанционного мониторинга Рослесхоза (ИСДМ Рослесхоза) обеспечивает получение оперативных данных о повреждении лесов пожарами на всей территории России. Кроме того, система обладает следующими возможностями и преимуществами [6]:

- получение информации о состоянии лесов несколько раз в день по всей территории России (поэтому система должна быть рассчитана на работу с различными центрами приема спутниковых данных) для решения оперативных задач;

- возможность работы с информацией, поступающей от различных спутниковых систем;

- достаточно высокий уровень оперативности и автоматизации сбора, обработки данных и представления информационных продуктов пользователям;
- интеграция информации, полученной в результате обработки спутниковых данных, с другими видами информации, используемой в ИСДМ МПР РФ;
- наличие удобного инструментария работы и схем доступа к оперативной информации для пользователей (в том числе и удаленных);
- высокий уровень автоматизации работы системы, простоту ее управления и контроль работоспособности;
- устойчивость и, по возможности, независимость реализованных в системе процедур обработки и анализа данных от условий и районов наблюдений;
- достаточная гибкость и удобные возможности модификации и расширения системы;
- низкая стоимость эксплуатации системы.

Выводы по первому разделу

1 Оперативное картографирование – относительно новое направление в картографии, оно подразумевает создание и использование карт в реальном или близком к реальному масштабу времени с целью быстрого (своевременного) информирования пользователей и воздействия на ход процесса. С учетом появления новых источников данных дистанционного зондирования Земли, которые обладают высоким пространственным и временным разрешением (PlanetScope, Sentinel-2), становится возможным применять методы оперативного картографирования в новых областях, в которых до недавнего времени это было невозможно по причине отсутствия необходимых данных. К таким областям относится лесное хозяйство, и в частности мониторинг нарушений лесного покрова.

2 На сегодняшний день государственные организации Российской Федерации (Федеральное агентство лесного хозяйства и его подведомственные структуры (ФБУ «Рослесозащита», ФБУ «Авиалесохрана)), ответственные за проведение мероприятий по охране, защите, контролю пользования лесов, заинтересованы

в улучшении качества, оперативности, точности оценки нарушений лесного покрова, с применением новых данных ДЗЗ.

3 Спутниковые снимки обладают большой информационной ценностью для выявления нарушений лесного покрова. Нарушения лесного покрова имеют свои отличительные дешифровочные признаки, которые позволяют выделять их на снимках. С появлением данных с новых спутников, которые отличаются сочетанием высокого пространственного и временного разрешения, повышается роль текстурных и геометрических признаков, которые не учитываются в традиционных методах выявления нарушений лесного покрова. Новые методы МО способны включать эту группу признаков в анализ. Применение новых методов машинного обучения позволит увеличить качество и точность идентификации нарушений лесного покрова, что важно для оперативного картографирования.

4 На сегодняшний день в России и в мире существует значительный опыт применения систем дистанционного мониторинга лесов. Разработка систем оперативного картографирования лесов на основе применения новых методов машинного обучения и новых данных ДЗЗ с использованием web-сервисов имеет большую перспективу интеграции в эти системы мониторинга при следовании принципам эффективного оперативного картографирования.

2 ОЦЕНКА ТОЧНОСТИ АВТОМАТИЗИРОВАННЫХ АЛГОРИТМОВ МАСКИРОВАНИЯ ОБЛАЧНОСТИ

2.1 Получение исходных данных и их характеристики

Как следует из выводов по разделу 1, для оперативного выявления и картографирования нарушений лесного покрова наиболее подходящими являются данные со спутников PlanetScope и Sentinel-2, поскольку они обладают необходимым сочетанием высокого пространственного и временного разрешения.

Крупнейшая в мире группировка PlanetScope компании Planet Labs позволяет получать снимки любой части территории земного шара с высоким пространственным разрешением (до 3 м). Большое количество спутников (больше 120, каждый весом 4,7 кг), равномерно распределены по орбите, а их простая конструкция и технологии производства с низким уровнем затрат позволяют существенно снизить стоимость снимков. Съемка ведется в четырех спектральных каналах: красный, зеленый, голубой, ближний инфракрасный. Повторяемость съемки – ежедневно (возможно получение снимков несколько раз в день). Ширина полосы съемки – от 24 до 32 км. Архив доступен с 2016 г. (в зависимости от территории) [61]. Точность геопривязки данных составляет около 10 м. В большинстве случаев снимки совмещены попиксельно, что позволяет избежать процедуры геометрической коррекции (коррегистрации) перед выявлением изменений. Снимки распространяются на коммерческой основе.

Данные распространяются в нескольких форматах: PlanetScope Basic Scene Product, PlanetScope Ortho Scene Product (использовался в рамках данного исследования), PlanetScope Ortho Tile Product. PlanetScope Ortho Scene Product доступен в виде сцен размером от 24×8 км до 32×16 км в зависимости от конкретного спутника. В состав продукта входят снимки, для которых проведены ортотрансформирование, радиометрическая калибровка, геометрическая коррекция, атмосферная коррекция, произведено слияние каналов, а также конвертирование в формат GeoTiff. Результат проведенной атмосферной коррекции поставляется отдельным файлом

в составе продукта и помечается буквами SR. Полное описание всех алгоритмов обработки и спецификации поставляемых продуктов Planet приведено в [115].

Космические аппараты Sentinel-2 (A/B) оснащены оптико-электронным мультиспектральным сенсором MSI (Multi-Spectral Imager) для съемок с разрешением от 10 до 60 м в 13 спектральных каналах в видимой, ближней ИК (VNIR) и коротковолновой ИК (SWIR) зонах спектра. Это обеспечивает отображение различий в состоянии растительности, в том числе и временных изменений, а также сводит к минимуму влияние атмосферы на качество съемки. Орбита высотой в среднем 785 км, наличие в миссии двух спутников позволяют проводить повторные съемки каждые 5 дней на экваторе и каждые 2–3 дня в средних широтах. Ширина полосы съемки – 290 км. Первый спутник был запущен в 2015 г. Увеличение ширины полосы обзора наряду с высокой повторяемостью съемок позволяет отслеживать быстро изменяющиеся процессы, например, изменение характера растительности в течение вегетационного периода. Данные Sentinel-2 обеспечивают сервисы GMES, связанные с управлением земельными ресурсами, сельскохозяйственным производством и лесным хозяйством, а также мониторингом стихийных бедствий и гуманитарных операций. Уникальность миссии Sentinel-2 связана с сочетанием большого территориального охвата, частых повторных съемок и, как следствие, систематическим получением полного покрытия всей Земли мультиспектральной съемкой высокого разрешения. Снимки с этого аппарата распространяются бесплатно [15].

Данные со спутника Sentinel-2 доступны с разным уровнем обработки: Level 1C и Level 2A. Первый уровень обработки содержит значения альбедо на верхней границе атмосферы (Top-Of-Atmosphere Reflectance, TOA) с выполненной радиометрической и геометрической коррекцией. Второй уровень обработки подразумевает пересчет значений в коэффициенты отражения на поверхности Земли. При необходимости ее можно выполнить самостоятельно. Сами снимки распространяются в виде тайлов размером $\approx 100 \times 100$ км, которые получаются объединением нескольких последовательных снимков и их дальнейшей обрезкой по границе

тайла с формированием единого изображения. Полное описание спецификаций продуктов Sentinel-2 представлено в [136].

Первым этапом в процессе выявления нарушений лесного покрова является выбор и загрузка снимков, которые покрывают необходимую территорию. Для получения материалов дистанционного зондирования Земли подавляющее большинство операторов создают специальные интернет-ресурсы для доступа к своим продуктам. На этих сервисах реализованы функции поиска необходимых сцен, их фильтрация по облачности и другим условиям. Основным источником получения снимков Sentinel является сервис [61], разработанный при участии Европейского космического агентства. Помимо него, есть и другие источники, которые аналогично предоставляют данные со спутников Sentinel-2. Например, интернет-ресурс геологической службы США [76], французская платформа распространения данных Sentinel [113] и др. Они могут быть полезны при недоступности сервиса [61] или его высокой нагрузке. Однако при этом они не содержат полный архив снимков, новые данные со спутников поступают на них не так оперативно, а с задержкой в несколько часов или дней.

Компанией Planet также разработана платформа для доступа к данным [114]. Через нее можно получить доступ к данным со спутников PlanetScope, SkySat, RapidEye и производным продуктам (например, безоблачному покрытию за выбранный месяц).

Преимуществами таких сервисов является доступность, кроссплатформенность, оперативность получения снимков конечными потребителями и т. д. Пользователь может непосредственно открыть страницу в браузере и выбрать необходимые снимки, отфильтровать их по проценту облачности, по дате получения и при необходимости загрузить. Другим важным преимуществом таких ресурсов является возможность программного взаимодействия с ними с помощью специальных запросов. Это позволяет автоматизировать весь процесс поиска и загрузки снимков, в том числе и для целей данного исследования. Основные этапы автоматизации загрузки и предварительной обработки снимков, реализованные в рамках разрабатываемой технологии, показаны на рисунке 2.1 и ниже рассмотрены более подробно.




Рисунок 2.1 – Схема процесса предварительной обработки данных

*Реализация автоматической загрузки снимков
с помощью языка программирования Python*

Для автоматической загрузки снимков Sentinel-2, с помощью языка программирования Python 2 был разработан скрипт, интегрированный в программную среду ArcGIS. Параметры инструмента представлены на рисунке 2.2. Перед запуском инструмента необходимо получить логин и пароль на сайте [61]. Объект интереса – это область (точка, линия или полигон), которую необходимо покрыть снимками, она должна быть в формате shp. После задания необходимых параметров скрипт загружает все выбранные снимки. По сравнению с аналогичным инструментом, доступным в модуле QGIS SCP [60], разработанный инструмент быстрее загружает снимки.

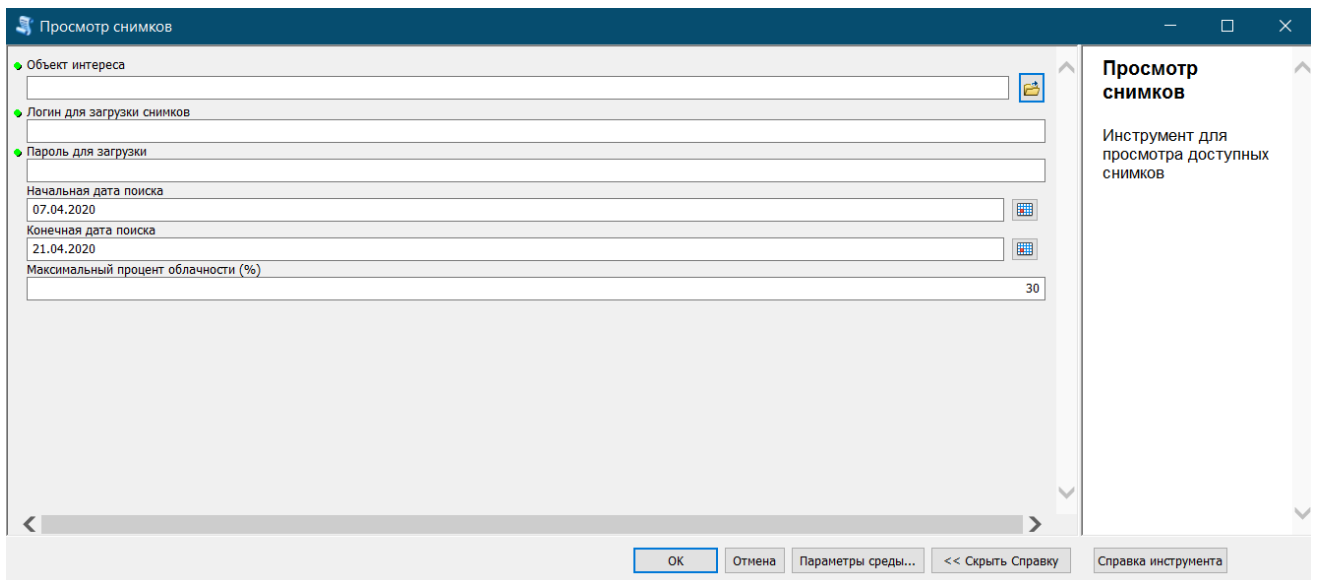


Рисунок 2.2 – Параметры разработанного инструмента
для загрузки снимков Sentinel-2

Стоит отметить, что реальный процент облачности загруженных снимков не всегда может соответствовать заданному из-за ошибок определения процента облачности на исходных снимках.

Данный инструмент может быть модифицирован и для получения снимков со спутников Planet, так как компания PlanetScore разработала библиотеки для автоматизации запросов для многих языков программирования, в том числе и Python. Ограничением для получения данных Planet является их распространение на коммерческой основе. В работе использовались загруженные архивы снимков PlanetScore на территорию Пермского края за 2017–2018 гг. Общая площадь доступных снимков составляет $\approx 100\,000\text{ км}^2$, в архиве представлены разносезонные снимки.

Создание единого покрытия

После загрузки всех необходимых снимков можно переходить к выбору спектральных каналов и созданию единого покрытия интересующей территории.

Данные PlanetScore распространяются в формате GeoTIFF. Каждая сцена представляет собой многоканальный растр, включающий четыре спектральных канала (голубой, зеленый, красный и ближний ИК). Для сбора всех загруженных снимков на базе программы ArcMap был создан специальный инструмент, который позволяет указать входную папку, где будет проходить поиск снимков (рекурсивно), и тип снимков для поиска (прошедшие атмосферную коррекцию или нет). В каждом снимке уже содержатся все необходимые каналы, включая ближний ИК, поэтому слияния отдельных каналов не требуется. Собрав все снимки, можно создать единое четырех канальное покрытие интересующей территории. Такое покрытие позволяет выполнить маскирование облачности сразу на всю территорию и исключить повторную обработку пересекающихся областей исходных снимков.

Данные Sentinel-2 распространяются в формате JP2, и каждый растр представляет собой отдельный канал. Поэтому для каждого снимка дополнительно производилось объединение каналов, после чего собиралось единое многоканальное покрытие для определения корректности исходной оценки процента облачности и

необходимости проведения дополнительной операции маскирования облачности. Логика работы модели следующая:

- 1 Находим синий канал в папке со снимком.
- 2 На основе найденного синего канала вычисляем расположение красного, зеленого и ближнего ИК каналов.
- 3 Используем инструмент слияния каналов в один растр.
- 4 Создаем единое покрытие (мозаику) из полученных многоканальных растров на интересующую территорию.

Последовательно запуская две модели после загрузки всех снимков, получим полное покрытие интересующей территории.

2.2 Выбор оптимального алгоритма маскирования облачности

Облачность — основной фактор, ограничивающий применимость данных космической съемки Земли в оптическом диапазоне спектра. Наличие облаков и сопутствующих им теней влияет на информационную емкость снимков [33, 34, 37]. Качественное маскирование облачности на снимках имеет все большее значение по мере роста объемов данных с различных спутников, увеличения площади мониторинга за природными и техногенными объектами, развития информационных СДМ, в частности для решения задач лесного и сельского хозяйства.

Традиционные методы маскирования облачности основаны на последовательном применении нескольких фильтров, в том числе с использованием средних и дальних ИК. Наиболее известны алгоритмы Fmask [149], разработанный для данных Landsat и впоследствии адаптированный к данным Sentinel-2 [118], и Sen2cor, разработанный для данных Sentinel-2 [134].

Однако в последние годы возникло существенное ограничение: новые группировки спутников, обеспечивающие оперативный мониторинг с высокой повторяемостью и детальностью, либо ведут съемку в среднем ИК-канале с более низким пространственным разрешением (Sentinel-2), либо не имеют такого канала вовсе (PlanetScope). Таким образом, традиционные алгоритмы маскирования облачности

имеют ограничения для данных Sentinel-2 и вообще не применимы для данных PlanetScore. Следовательно, требуется разработка новых алгоритмов, использующих только видимый и ближний инфракрасный диапазоны спектра, а также текстурные и геометрические признаки, значимость которых растёт с повышением пространственного разрешения данных. Лучше всего для этого подходят методы МО.

В рамках данного исследования рассматривались и оценивались два традиционных алгоритма маскирования облачности, основанные на пороговых значениях Fmask, Sen2Cor, а также алгоритмы с применением машинного обучения s2cloudless [150] и метод на основе СНС [Shendryk].

Fmask – алгоритм детектирования облачности, который изначально был разработан для съёмочной системы Landsat, а в последней версии адаптирован для Sentinel-2 [118]. В основе метода – дерево принятия решений, которое учитывает яркости в спектральных каналах (2, 3, 4, 7, 8, 8A, 10, 11, 12) Sentinel-2 и их производных значений (например, индекс NDVI), а все каналы приводятся к пространственному разрешению 20 м. Последовательно применяя правила дерева решения к входному снимку, выделяются несколько классов – облачность, тень, вода, снег и безоблачная территория.

Sen2Cor – набор инструментов для предварительной обработки снимков Sentinel-2 (атмосферной коррекции и маскирования облачности), разработанный совместно несколькими университетами Германии при участии Европейского космического агентства [134].

В составе набора есть классификатор, который выделяет на снимке 11 классов, в том числе несколько классов облачности: облачность с высокой вероятностью (cloud high probability), облачность со средней вероятностью (cloud medium probability), перистые облака (thin cirrus), тени от облаков (cloud shadows). Алгоритм основан на последовательном применении определенных пороговых значений к значениям спектральных каналов Sentinel-2, а также к расчетным показателям (индексам), таким как NDVI и NDSI. На выходе алгоритм формирует карту вероятности принадлежности пикселя к определенному классу.

Множество работ также посвящено решению проблемы маскирования облачности с помощью методов машинного обучения (см., например, работы [55, 79, 80].

Алгоритм *s2cloudless* разработан Европейским космическим агентством. В его основе лежит метод градиентного бустинга, который называется *LightGBM* (от англ. *Light Gradient Boosting Machines*) [100]. Метод *LightGBM* также отличается скоростью работы (в два раза быстрее своего аналога *XGBoost* (сокр. англ. *EXtreme Gradient Boosting*)) [87]. Алгоритм *s2cloudless* попиксельно классифицирует изображения и рассчитывает вероятность отнесения пикселя к облачности на основе нормированных значений яркости в различных каналах (либо во всех 13 каналах, либо в 10 каналах *Sentinel-2*: 1, 2, 4, 5, 8, 8A, 9, 10, 11, 12). По данным авторов алгоритма, модель была обучена на масках облачности (количество образцов — 14140), выделенных алгоритмом *MAJA* [101], который рассчитывает маску на основе последовательных снимков одной и той же территории (*time-series analysis*). Для обучения были отобраны только сцены, классифицированные алгоритмом *MAJA* с точностью выше 90 %, а процент облачности на исходном снимке составлял от 5 до 90. Заявленная точность алгоритма — 91–99 %.

Метод, описанный в работе [66] (далее по тексту — *CCNN*), отличается от вышеприведенных. Во-первых, он не получает точную маску облаков, а определяет наличие или отсутствие облачности в тайлах размером 400×400 м, что может быть обосновано невозможностью абсолютно четкого выделения границ облачности разного типа. Во-вторых, в качестве входных признаков для данного метода используются только четыре спектральных канала: ближний инфракрасный, красный, зеленый, голубой, а также вегетационные индексы *NDVI* и *GNDVI* (аналогичный *NDVI*, но с использованием зеленого канала вместо красного). Таким образом, метод *CCNN*, в отличие от всех вышеперечисленных, может быть применен для снимков *PlanetScope*.

Авторы алгоритма *CCNN* используют ансамбль из глубоких сверточных нейронных сетей *DenseNet*, *ResNet50*, *VGG10* [139], а после объединяют их предсказания, применяя гребневую регрессию (*ridge regression*) [90]. Авторы комбини-

ровали несколько обучающих наборов, созданный ими экспертно по снимкам PlanetScore и Sentinel-2, а также набор, доступный на площадке Kaggle [116]. Заявленная точность алгоритма — 78–80 %.

Обработка снимков

Для сравнительной оценки точности были выбраны 12 разносезонных снимков Sentinel-2 на территорию Пермского края (рисунок 2.3). Процент облачности на выбранных снимках составлял от 0 до 60. Запуск алгоритмов выполнялся со стандартными параметрами. Даты снимков представлены в таблице 2.1.




Рисунок 2.3 – Схема размещения снимков

Таблица 2.1 – Даты выбранных снимков Sentinel-2

Идентификатор тайла Sentinel-2	Сезон съемки			
	зима	весна	лето	осень
40VDM	22.01.2019	-	05.08.2020	-
40VCL	17.01.2020	12.05.2019	26.07.2019	04.10.2019
40VDK	05.12.2019	-	-	-
40VEK	-	26.05.2018	-	-
40VDH	29.01.2019	09.04.2019	25.06.2018	03.09.2018

Результатом работы алгоритмов стали классифицированные растры. Число классов варьируется: алгоритм Sen2Cor выделяет девять классов, Fmask – четыре класса, s2cloudless – два класса. Для запуска алгоритмов Fmask и Sen2Cor требуется только загрузить и разархивировать данные со спутника Sentinel-2 уровня обработки L1C. Для алгоритма s2cloudless необходимо перевести данные Sentinel-2 в массив размером $n \times m \times k$, где n – число каналов, а $m \times k$ – размеры сцены Sentinel-2 по широте и долготе в пикселях. Такое преобразование было выполнено с помощью библиотеки gdal [83]. Полученные результаты классификации переводились в векторный вид (формат shp), параллельно удалялись все классы, которые не относятся к облачности.

Адаптация алгоритмов маскирования облачности для снимков PlanetScope

При анализе литературы было выделено относительно немного работ, которые посвящены маскированию облачности на снимках PlanetScope и при этом находятся в открытом доступе [64]. Вероятно, это связано с тем, что период активной эксплуатации спутников PlanetScope составляет всего около трех лет.

Традиционные алгоритмы маскирования облачности Fmask и Sen2Cor не могут быть адаптированы под данные PlanetScope, поскольку эти данные не содержат необходимых спектральных каналов, а при запуске требуется использовать метаданные съемки Sentinel-2. К данным PlanetScope может быть адаптирован только алгоритм s2cloudless.

Такая адаптация возможна благодаря способности алгоритмов машинного обучения переносить полученный опыт на новые задачи, которые связаны с исходной задачей (transfer learning). Для этого средствами языка программирования Python и библиотеки gdal [83] снимки PlanetScope были конвертированы в формат 12-канальных растров, причем на место соответствующих каналов Sentinel были подставлены каналы PlanetScope (таблица 2.2). Значения яркости пикселей в остальных каналах были заполнены нулями.

Таблица 2.2 – Соответствующие каналы съемочных систем Sentinel-2, PlanetScope

Канал	Длина волны Sentinel-2, нм	Длина волны PlanetScope, нм
Голубой (Blue)	448–546	455–515
Зеленый (Green)	537–583	500–590
Красный (Red)	545–583	590–670
Ближний ИК	763–909	780–860

Следующим этапом подготовки данных был пересчет исходных значений яркости в диапазон значений от 0 до 1, для чего производилось нормирование. Реализованы три способа нормирования: деление на постоянное значение 10 000 (как указано в документации алгоритма s2cloudless, на максимальное значение в канале и на среднее значение яркости в канале). Полученный результат передавался на вход алгоритму s2cloudless. Первый запуск алгоритма показал, что точность маскирования облачности по снимкам, не прошедшим предварительную атмосферную коррекцию (без префикса SR в имени файла), была значительно ниже, чем по откорректированным изображениям. Поэтому далее использовались только снимки, предварительно прошедшие атмосферную коррекцию.

Алгоритм показал хороший результат на снимках PlanetScope с нормировкой по максимальному значению (рисунки 2.4, 2.5). К сожалению, произвести оценку по сезонам года или получить большую выборку по данным PlanetScope не удалось, так как большинство загруженных снимков были безоблачными, а в настоящее время данные распространяются на коммерческой основе. Для 10-летних снимков PlanetScope было выполнено сравнение точности между маской облачности, выделенной алгоритмом s2cloudless, и стандартной маской облаков PlanetScope. В качестве эталона использовались результаты экспертного (ручного) выделения облачности на этих снимках. В результате установлено, что процент совпадения с фактически выделенной облачностью для результатов, полученных с помощью алгоритма s2cloudless (*F-мера* – 75 %) оказался ниже, чем для стандартной маски (90 %), при этом на отдельных снимках результат сопоставим со стандартной маской [32].

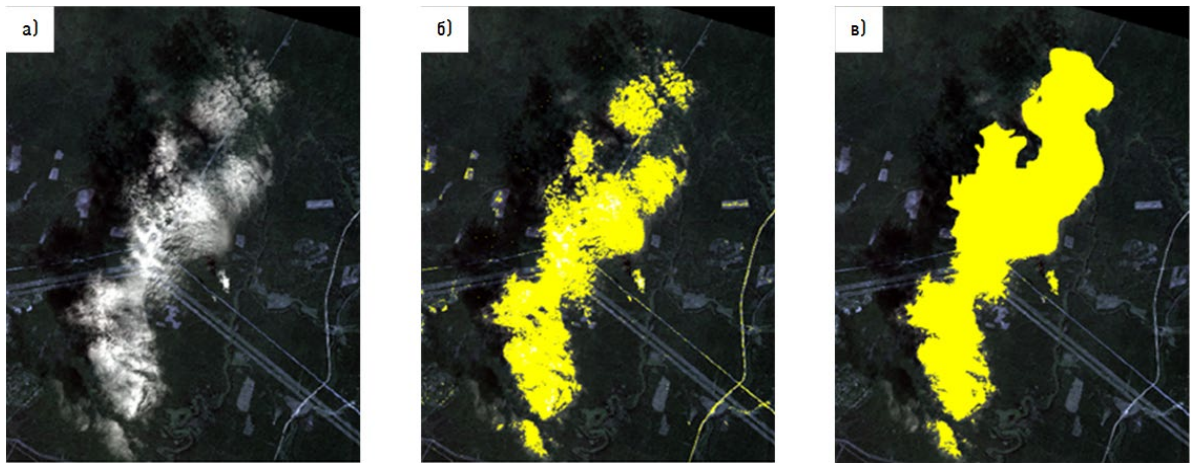


Рисунок 2.4 – Пример выделения маски облачности на летнем снимке PlanetScore с помощью алгоритма s2cloudless: *а)* исходное изображение в синтезе RGB; *б)* – маска облачности (выделена желтым); *в)* стандартная маска облачности (выделена желтым)




Рисунок 2.5 – Пример выделения маски облачности на снимках PlanetScore с присутствием снежного покрова алгоритмом s2cloudless: *а)* исходное изображение в синтезе RGB; *б)* ниже желтым цветом выделенная маска облаков (желтый цвет)

Апробация работы алгоритма была произведена и на зимних снимках PlanetScore. На представленном зимнем снимке (рисунок 2.6) точность (F -мера) составила 70 %, в то время как стандартная маска облачности, которую можно получить вместе со снимком, показала точность чуть выше 50 %.




Рисунок 2.6 – Пример выделения маски облачности на зимнем снимке PlanetScore алгоритмом s2cloudless: *a)* исходное изображение в синтезе RGB; *б)* маска облачности, выделенная алгоритмом s2cloudless (выделена желтым); *в)* стандартная маска облачности (выделена желтым)

Второй подход подразумевает дообучение метода CCNN на зимних снимках, т. е. трансформирование уже созданного набора данных с летними снимками в набор с зимними снимками. Обучающая выборка для метода CCNN представляет

собой тайлы размеров 128×128 пикселей со снимков Sentinel-2, PlanetScope. Каждому тайлу присвоен один (например, сплошная облачность) или несколько классов (например, лес, частичная облачность). Образец из обучающей выборки представлен на рисунке 2.7.




Рисунок 2.7 – Образец из обучающей выборки
(данному образцу присвоены классы безоблачный, лес, незатененный)

Идея заключается в сохранении присвоенных классов, при этом изменяя сам образец обучающей выборки. Другими словами, необходимо «превратить» летний снимок в зимний, после этого дообучить сеть на созданном наборе данных. Это позволит вдвое увеличить обучающую выборку и настроить сеть для выделения облаков на зимних снимках. Подобная задача успешно решается сегодня, в том числе и с помощью применений технологий МО, а именно генеративно-сопоставительными сетями (GAN) [62]. Впервые они были предложены в 2014 г. По сути они состоят из двух частей: генератора и дискриминатора. Первый генерирует изображения максимально похожие на входные, а дискриминатору необходимо отличить, настоящее ли это изображение или сгенерированное. Совместное обучение позволяет моделировать необ-

ходимое распределение с помощью примеров из этого распределения. Одной из сфер применения таких сетей является трансформация исходных изображений в необходимый стиль, в том числе и преобразование из летнего в зимнее. В 2018 г. инженерами из компании NVIDIA, а также сотрудниками Корнелльского университета была разработана нейронная сеть, которая способна выполнять подобное преобразование. Для этого необходимо подать на вход пары изображений «лето – зима» одной и той же территории. Готовой сети для использования нет в открытом доступе, поэтому ее необходимо было предварительно обучить. Для этого авторами алгоритма предлагается использовать открытый обучающий набор данных, в котором находятся снимки Йосимитского национального парка зимой и летом. Пример трансформации изображений из летних в зимние показан на рисунке 2.8.



Рисунок 2.8 – Пример трансформации изображений из летних в зимние:

а) исходные изображения; б) результат преобразования

Обучение проводилось с помощью облачной платформы Google Colab. Настройка алгоритма производилась через специальный файл конфигурации `yaml`, в котором основные настройки были сохранены по умолчанию. Был изменен параметр, который определяет размеры входного изображения на значение 128×128 пикселей.

Это соответствует размерам изображений, который подавались на вход при обучении алгоритма CCNN. В процессе обучения модель, через заданное число итераций, генерирует примеры трансформации изображений, что позволяет экспертно отследить качество преобразования и принять решение о необходимости дальнейшего обучения. На 200 000 итераций было выполнено тестовое трансформирование исходных летних изображений. Для того, чтобы выполнить эту операцию для исходных снимков, необходимо было выполнить предварительные преобразования. Они включали в себя конвертирование в формат jpeg и удаление ближнего инфракрасного канала, так как в обучающем наборе данных изображения представлены только в трех каналах: красный, зеленый и голубой. Пример трансформаций представлен на рисунке 2.9.



Рисунок 2.9 – Пример трансформации летнего снимка в зимний:

а) PlanetScope; б) Sentinel-2

После трансформации всех снимков они вместе с исходными классами подавались на вход предобученной исходной сети. Первый подход заключался в полном дообучении модели на основе вновь полученных данных, второй подход заключался в фиксировании весов начальных слоев и дообучении только последних слоев сети. В качестве метрики оценки точности использовалась функция, аналогичная той, которая использовалась при обучении метода CCNN. К сожалению, такой подход не принес результата.

На графиках (рисунки 2.10, 2.11) заметен эффект переобучения сети, который заключается в том, что модель очень хорошо описывает структуру и признаки тренировочного набора, но плохо предсказывает результаты по примерах, которых не было в обучающем наборе. На обоих графиках общая точность не превышает 40 %. Такое значение не позволяет использовать данный подход при маскировании облачности на зимних снимках PlanetScore. Проблема низкой точности данного подхода обусловлена недостаточным качеством трансформирования летнего снимка в зимний.




Рисунок 2.10 – График точности сети при дообучении всех слоев

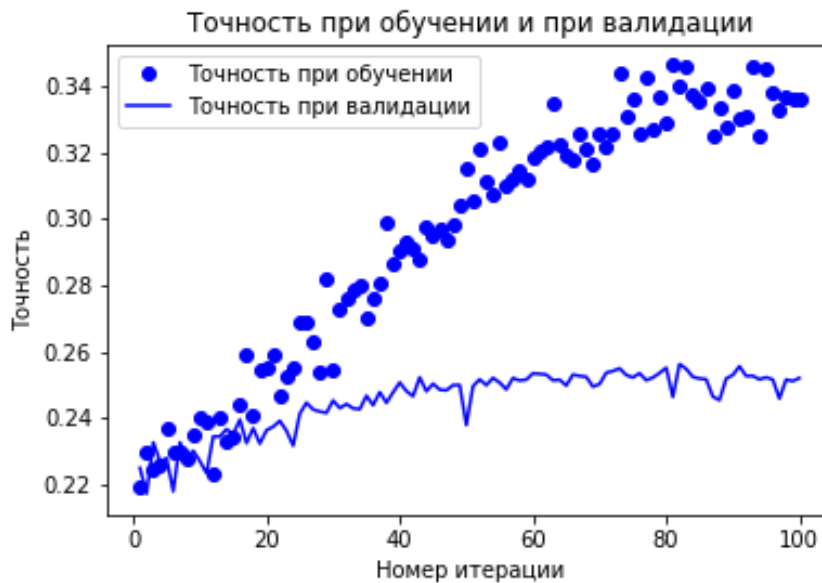


Рисунок 2.11 – График обучения сети при фиксировании весов начальных слоев

Последний подход для выделения облачности на зимних снимках PlanetScore – это создание новой выборки для дообучения модели на зимних снимках. Для создания был написан специальный инструмент, который позволяет присваивать классы заранее созданным тайлам из снимков PlanetScore и Sentinel-2. При создании выборки такие параметры, как размер и число каналов, совпадали с теми, которые использовали авторы CCNN для обеспечения однотипности входных данных. К сожалению, точность этого подхода не превышает точности стандартной маски облачности.

2.3 Оценка точности алгоритмов маскирования облачности

Для оценки точности работы алгоритмов на загруженных снимках экспертно были выделены контура облачности (проверочный набор). При создании объектов каждому был присвоен один из классов: сплошная облачность (1-й класс) и полупрозрачная облачность (2-й класс) (рисунок 2.12). Критерием отнесения объекта к тому или иному классу была видимость поверхности Земли и наличие тени от объекта. Всего было оцифровано 5 340 объектов, включая 5 100 объектов класса «сплошная облачность» и 240 объектов класса «полупрозрачная облачность».




Рисунок 2.12 – Примеры типов выделяемой облачности в контрольном наборе: а) полупрозрачная; б) сплошная. Границы объектов выделены черным цветом

Для оценки точности была построена матрица ошибок результатов автоматизированного выделения облачности в сравнении с результатами экспертного выделения. На ее основе рассчитана основная метрика для оценки точности – *F-мера* ($F_{measure}$), а также ее составляющие – точность (*precision*) и полнота (*recall*). Метрика *precision* позволяет оценить, какая доля объектов, распознанных как объекты положительного класса (в данном случае – облачности), в действительности является таковыми, а *recall* показывает, какую долю объектов положительного класса из всех объектов положительного класса нашел алгоритм:

$$F_{measure} = \frac{2 \times precision \times recall}{precision + recall}; \quad (2.1)$$

$$precision = \frac{TP}{TP + FP}; \quad (2.2)$$

$$recall = \frac{TP}{TP + FN}, \quad (2.3)$$

где TP – объекты, правильно отнесенные к нужному классу;

FP – неправильно отнесенные к нужному классу (ошибка I рода);

FN – не отнесенные к нужному классу (ошибка II рода).

На первом этапе оценивалась точность выделения всей облачности без разделения на типы. Расчеты производились с помощью инструментов пространственного анализа. Использование этих методов позволило разделить объекты на несколько классов (TP , FP , FN). Для каждого полученного объекта была рассчитана площадь, а потом она суммировалась для каждого класса (TP , FP , FN). В качестве итоговой оценки использовалось среднее значение F -меры по всем сценам. На рисунке 2.13 представлена точность маскирования облачности, в таблице 2.3 приведены показатели точности маскирования облачности.

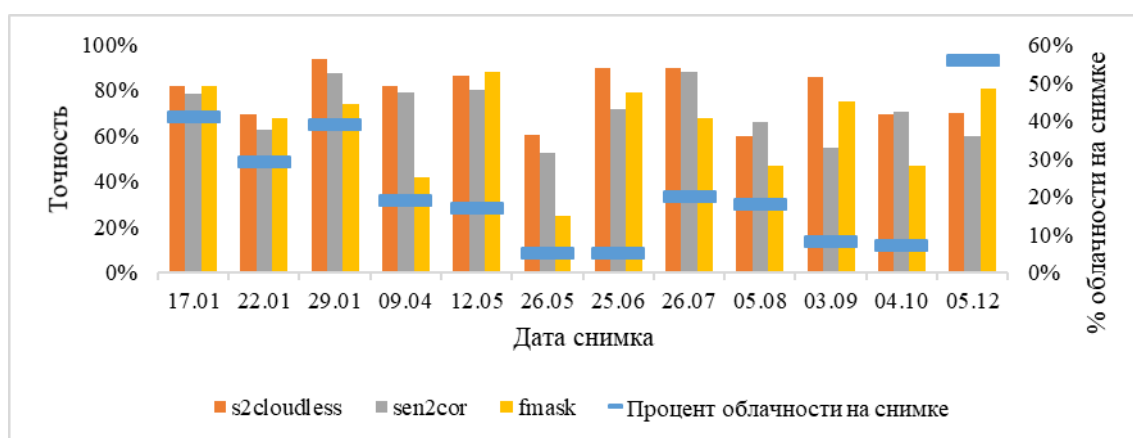


Рисунок 2.13 – Точность маскирования облачности с учетом процента облачности на снимках

Таблица 2.3 – Показатели точности (значения F -меры) маскирования облачности с применением различных алгоритмов

Название алгоритма	Точность (F -мера)			
	среднее	медиана	мин	макс
fmask	0,70	0,71	0,25	0,88
sen2cor	0,75	0,71	0,52	0,88
s2cloudless	0,83	0,82	0,60	0,94

Наилучший результат показал алгоритм s2cloudless (средняя точность 83 %), на втором месте алгоритм Sen2Cor (средняя точность 75 %), а самый низкий показатель точности у алгоритма Fmask – 70 %. Низкая точность алгоритма Fmask формируется в основном за счет большого объема ложного детектирования. Во-первых, на это оказывают влияние настройки буфера вокруг облачности, поскольку основная часть ошибочно выделенных объектов относится именно к буферным зонам. Также точность данного алгоритма снижается до 40–50 % по снимкам осеннего и весеннего сезонов (апрель, октябрь) за счет большого числа ошибочно выделенных объектов.

Полученные оценки точности также были агрегированы по сезонам года. Как и ожидалось, самые низкие показатели точности получены в переходные сезоны: весной и осенью. Это связано с наличием частичного снежного покрова на апрельском снимке и частичным покрытием осеннего снимка полупрозрачной облачностью. В среднем снижение точности составляет не более 6 %, а характер ее изменения по сезонам года совпадает у всех алгоритмов.

После общей оценки точности была проведена оценка в разрезе типов облачности (сплошной и полупрозрачной). Сплошная облачность была представлена на всех снимках. Для полупрозрачной облачности такой расчет производился только для трех снимков, где присутствует этот тип, а ее площадь превышала 1 км². В качестве общей оценки были вычислены средние значения для 12 сцен по каждому типу облачности.

Самый высокий процент совпадения для сплошной облачности (98 %) показал алгоритм Fmask. Таким образом, алгоритм практически не пропускает объекты этого класса. Алгоритмы s2cloudless и Sen2Cor дают значительно более низкий процент совпадения – 82 и 72 % соответственно.

При выделении полупрозрачной облачности также самый высокий процент выделения показал алгоритм Fmask, однако он дает большой объем ложных срабатываний. Алгоритм s2cloudless выделяет 55 % полупрозрачной облачности, а Sen2Cor – только 1 %, поскольку полупрозрачная облачность попадает в класс

Clouds Low Probability, который не учитывался при оценке. Данный класс содержит много ложных объектов (участков дорог и открытого грунта).

Выводы по второму разделу

1 Разработанные инструменты автоматизированного создания безоблачного покрытия снимками высокого пространственного разрешения интересующей области с помощью языка программирования Python и инструмента ModelBuilder программы ArcGIS обеспечивают рост производительности предварительной обработки данных для дальнейшего оперативного картографирования нарушений лесного покрова.

2 На основе проведенных экспериментов по маскированию облачности на разносезонных снимках Sentinel-2 с применением традиционных алгоритмов (Fmask, Sen2Cor) и метода, основанного на МО (s2cloudless), установлено, что наилучший результат при оценке общей точности (F-меры) показал алгоритм s2cloudless (среднее значение F-меры 83 %). Точность распознавания по алгоритмам Sen2Cor и Fmask составила соответственно 75 и 70 %. Для сплошной облачности самый высокий показатель точности у алгоритма Fmask (98 %), алгоритмы s2cloudless и Sen2Cor дают точность 82 и 72 % соответственно. Для полупрозрачной облачности также самую высокую точность показал алгоритм Fmask – 87 %. Таким образом, использование алгоритма s2cloudless увеличивает качество предварительной обработки снимков в течение всего года, что позволяет повысить точность оперативного картографирования нарушений лесного покрова.

3 Для алгоритма s2cloudless, который показал самые высокие значения точности, была изучена возможность его применения для снимков PlanetScope. Такой эксперимент оказался удачным для зимних снимков. Алгоритм успешно выделяет облачность на зимних снимках (F-мера $\approx 70\%$), что на 20 % лучше, чем стандартная маска облачности. Что касается летних снимков, точность выделения облачности оказалась меньше, чем у стандартной маски облачности. Адаптированный алгоритм позволит увеличить точность картографирования нарушений лесного покрова в зимний период при использовании снимков PlanetScope.

3 РАЗРАБОТКА АЛГОРИТМА ДЛЯ ВЫЯВЛЕНИЯ НАРУШЕНИЙ ЛЕСНОГО ПОКРОВА С ПОМОЩЬЮ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

3.1 Базовые методы выделения нарушений лесного покрова

На данный момент существует несколько подходов к выявлению нарушений лесного покрова [44], основанных на использовании алгоритмов – детекторов и семантических классификаторов.

Не существует строгого определения этих двух видов алгоритмов. Детектор определяет наличие интересующего объекта на изображении, его класс, а также область, где он находится. Семантический классификатор решает те же задачи, но еще и выделяет точную границу объекта (рисунок 3.1).




Рисунок 3.1 – Пример выделения нарушения лесного покрова с помощью сегментации (г) от детектирования (в); (а, б) – исходная пара снимков

В рамках данного исследования были использованы алгоритмы на основе детектирования и семантической классификации нарушений лесного покрова. Эксперименты с использованием детектора рассмотрены в разделе 3.2, а на основе семантического классификатора – в разделах 3.3, 3.4.

3.2 Детектирование вырубок с помощью алгоритма YOLO

В рамках данного эксперимента планировалось последовательное использование детектора и семантического классификатора для выделения вырубок. Такой подход подразумевает разделение процесса на две составляющих: на первом этапе детектор определяет возможную область наличия вырубки, а семантический классификатор, используя ранее полученные границы от детектора, выделяет точные границы объекта. При неудовлетворительном выявлении границ детектором, он будет исключен из процесса.

На первом этапе изучалась возможность применения алгоритма YOLO (You Only Look Once) в качестве детектора. Это очень популярная на текущий момент архитектура СНС, которая используется для распознавания различных типов объектов на изображении. Более полную информацию о ней можно получить на официальном сайте (YOLO: Real-Time object detection), там же можно найти публикации [120], в которых подробно описана теория и математическая составляющая этой сети, описан процесс ее обучения. Главная особенность ее архитектуры по сравнению с другими состоит в том, что большинство систем применяют СНС несколько раз к разным регионам изображения, в YOLO фильтры применяется один раз ко всему изображению сразу. Сеть делит изображение на своеобразную сетку и предсказывает положение и вероятность того, что в каждой ячейке сетки есть искомый объект. Плюсы данного подхода состоят в том, что сеть анализирует все изображение сразу и учитывает контекст при детектировании и распознавании объекта. Другая особенность YOLO состоит в том, что на выходе есть три слоя, каждый из которых рассчитан на обнаружение объектов разного размера.

Для того чтобы обучить модель, необходимо представить данные в формате Pascal VOC Annotation [57], которые состоят непосредственно из изображения и координат прямоугольника, и ограничивают интересующий объект. Для каждого объекта дополнительно можно присвоить класс, который будет учитываться при обучении (например, сплошная или выборочная рубка). В качестве обучающих изображений были выбраны фрагменты разносезонных снимков Sentinel-2 размером 416 на 416 пикселей в синтезе RGB (натуральные цвета), преобразованные к значениям в диапазоне 0–255, полученные с помощью библиотеки gdal [83]. Разметка производилась с помощью специального инструмента, который имеет графический интерфейс и автоматически сохраняет полученную разметку в формате VOC (рисунок 3.2). Разметка производилась экспертно, а после завершения разметки проводился повторный контроль, при котором проверялась правильность определения типа объектов и выделенных контуров.



Рисунок 3.2 – Пример размеченных данных для алгоритма YOLO

В таком формате было создано две выборки. Первая – без разделения на классы, но с небольшим количеством объектов (несколько сотен). Вторая выборка содержит 1 000 образцов, а для каждого объекта присвоен один из классов (таблица 3.1).

Таблица 3.1 – Названия классов в размеченной выборке для алгоритма YOLO

Название класса	Код
Незаконченная рубка	unended_fell
Сплошная рубка	fell
Рубка в облаках	cloud_fell
Выборочная или проходная рубка	selective_fell
Рубка в тени	shadow_fell

Обучение алгоритма длилось до тех пор, пока увеличивалась точность его работы. При улучшении точности на каждой итерации модель сохранялась. После обучения модель запускалась на случайно выбранных участках снимков Sentinel-2 в синтезе RGB. На рисунке 3.3 показан пример детектирования вырубок с помощью алгоритма YOLO на снимке Sentinel-2, на рисунке 3.4 – на снимке PlanetScore.




Рисунок 3.3 – Пример детектирования вырубок с помощью алгоритма YOLO на снимке Sentinel-2: *а)* исходный фрагмент снимка Sentinel-2 в синтезе RGB; *б)* результат детектирования (красный цвет)

Запуск производился и для снимков PlanetScore в синтезе RGB. Тестовый запуск показал необходимость создания выборки по снимкам PlanetScore.




Рисунок 3.4 – Пример детектирования вырубок с помощью алгоритма YOLO на снимке PlanetScope: *a)* исходный фрагмент снимка PlanetScope в синтезе RGB; *б)* результат детектирования (красный цвет)

В целом подход не обеспечил необходимой точности для использования в качестве предварительного метода обработки снимков. Алгоритм пропускает много объектов, а также плохо отличается новые рубки от старых.




Рисунок 3.5 – Пример пропуска объектов: *a)* на зимнем снимке; *б)* летнем снимке (контуры выделенных объектов отмечены цветными прямоугольниками).

Синтез естественные цвета (RGB)

Сеть теряет свои обобщающие свойства и становится неспособной выделять объекты вырубок на новых участках снимков, которые не участвовали в обучении. Это отражается в неспособности сети завершить обучение в рамках одного цикла из-за затухающего градиента. Таким образом дальнейшая часть исследования посвящена созданию модели для выполнения семантической сегментации без предварительного использования детектора

3.3 Создание обучающей выборки для выделения нарушений лесного покрова методом семантической сегментации

Для эффективного построения моделей МО требуется соответствующий набор обучающих данных. Алгоритмы МО относятся к группе алгоритмов с учителем (supervised learning), поэтому для них требуется обучающая выборка с размеченными контурами интересующих объектов и соответствующий этой маске набор признаков. Модель строится для проведения, прежде всего, ежемесячного мониторинга, поэтому необходимо было получить данные об изменениях лесного покрова по паре снимков с разницей не более, чем несколько месяцев. С другой стороны, мониторинг необходимо проводить в течение всего года, поэтому нужно получить выборку по всем сезонам года. Подходящие обучающие наборы в открытом доступе отсутствуют, поэтому был создан собственный обучающий набор данных.

Для создания выборки использовались снимки со спутника Sentinel-2, которые предоставляются в формате тайлов размером $\approx 100 \times 100$ км. Всего для создания выборки было загружено 98 снимков Sentinel-2 уровня обработки L1C [137]. На рисунке 3.6 представлено их пространственное распределение.

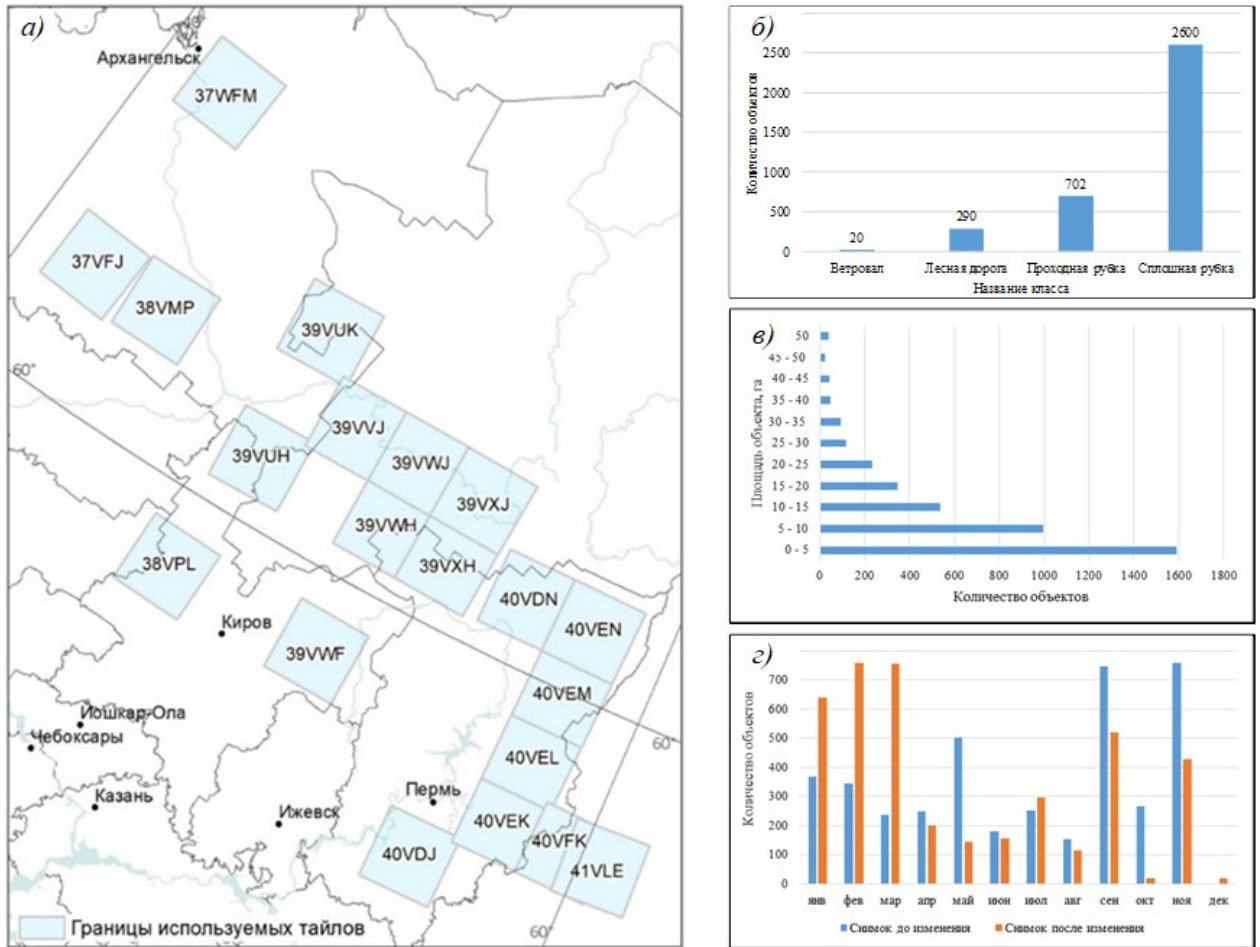


Рисунок 3.6 – Территория создания обучающей выборки (а) и ее базовые характеристики: б) распределение по типам; в) распределение по диапазонам площадей; з) распределение по месяцам

Для этих участков загружались несколько пар малооблачных (облачность не более 20 %) снимков в течение всего года, с разницей в один месяц. По каждой паре снимков были векторизованы все нарушения лесного покрова, которые были классифицированы на пять типов: сплошная рубка, проходная рубка, лесная дорога, ветровал, гарь. Для каждого объекта в выборке сохранялись идентификаторы двух снимков: до произошедшего изменения и после, в формате Vendor Product ID. Если процесс вырубki был обнаружен на нескольких парах снимков, то каждое произошедшее изменение создавалось как отдельный объект. В таблице 3.2 представлена структура атрибутивных данных.

Таблица 3.2 – Структура атрибутивных данных в полученном векторном слое

Имя поля	Тип поля	Описание поля
OBJECTID	OID	Уникальный идентификатор объекта
Shape	Geometry	Геометрия объекта
firstimg	String	Vendor Product ID снимка первого снимка
secondimg	String	Vendor Product ID снимка второго снимка
type	String	Тип объекта (сплошная рубка, проходная и т. д.)
typeobj	SmallInteger	Тип объекта в числовом представлении
tileid	String	Идентификатор текущего снимка в система разграфки тайлов Sentinel-2
firstimgdate	Date	Дата первого снимка
secondimgdate	Date	Дата второго снимка
season	String	Сезон, к которому относится объект (summerChange, transitionChange, winterChange)

Если на вырубке оставались отдельные деревья или участки лесной растительности, они не исключались из объекта. Также сохранялись тени от деревьев на границе объекта. При отсутствии безоблачных снимков допускалось увеличение временного интервала между снимками в паре, но он не должен был превышать 6 месяцев. Полученные таким образом слои для каждой пары снимков объединялись в один векторный слой. При этом проводилась проверка однотипности названий классов, корректность идентификаторов снимков и т. д.

Итоговая обучающая выборка представляет из себя векторный слой с нарушениями лесного покрова (3 612 объектов), включая 2 600 сплошных вырубок, 702 выборочные вырубки, 290 участков лесных дорог, 20 ветровалов. Для формирования выборки использовано 98 снимков Sentinel-2. Примеры разных типов объектов в выборке представлены на рисунке 3.7.

Благодаря наличию исходных снимков и векторного слоя с изменениями возможно создавать обучающие выборки с произвольным размером образцов и с различным набором спектральных признаков (разные комбинации исходных каналов, расчет вегетационных индексов, различные разновременные значения и т. д.).




Рисунок 3.7 – Примеры разных типов объектов из обучающей выборки на снимках Sentinel-2: а) сплошная рубка; б) выборочная рубка; в) лесная дорога

Далее представлены некоторые базовые характеристики полученной выборки (см. рисунок 3.6, б, в, г). Преобладающим типом объектов в выборке являются сплошные рубки, поскольку в пределах рассматриваемой территории (см. рисунок 3.6, а) они существенно преобладают над проходными и выборочными рубками. Отсутствие в выборке таких объектов, как гары, связано с малой повторяемостью пожаров на изучаемой территории; кроме того, выделение гарей не входило в перечень задач данного

исследования. Количество ветровалов в выборке также невелико и в целом соответствует соотношению площади ветровалов и вырубок для данной территории, приведенному, в частности, в работе [77]. Распределение объектов в выборке по площади в целом соответствует характерному для вырубок на данной территории. Наибольшее количество изменений было выявлено в периоды сентябрь, октябрь – январь, февраль, что связано с большим количеством безоблачных снимков в это время, а также с тем, что основной объем лесозаготовительных работ на выбранной территории производится в зимний период. Наибольшее число объектов выявлено в зимние месяцы (январь, февраль), а также в осенние (сентябрь, ноябрь) (см. рисунок 3.6, в).

3.4 Семантическая сегментация нарушений лесного покрова с помощью нейронных сверточных сетей

Предварительная обработка изображений

Для обучения нейронной сети необходимо было представить полученную обучающую выборку в виде тайлов – небольших растровых изображений (чаще всего размером 256×256 или 512×512 пикселей), где содержатся целевая маска и набор входных признаков. Чтобы иметь возможность при обучении моделей рассчитывать различные производные признаки (например, вегетационные индексы), в тайлах были сохранены исходные значения яркости всех каналов обоих снимков. Для каждой пары снимков в обучающем наборе каналы первого и второго изображения приводились к пространственному разрешению 10 м и объединялись в один 26-канальный растр. Далее соответствующий этой паре слой нарушений конвертировался в растровый формат и добавлялся в качестве дополнительного канала к созданному растру. Таким образом, для каждой пары снимков был получен 27-канальный растр, который содержит маску нарушений и значения яркости в 13 каналах снимков, полученных до и после появления нарушения).

Такой растр послужил основой для непосредственного формирования тайлов для обучения. Для этого был разработан авторский алгоритм, который формирует их с учетом максимизации площади целевой маски на одном тайле, а также исклю-

чает возможные перекрытия между тайлами. После формирования тайлов с маской изменений, генерировались фрагменты без целевой маски методом случайной выборки, при этом пересечение с уже созданными тайлами не допускалось.

Результатом работы на этом этапе стало два обучающих набора данных. Первый представляет собой картинки размеров 512 на 512 пикселей с 27 каналами, где первый канал - это бинарная маска произошедших изменений, а остальные 26 значения пикселей по всем каналам спутника Sentinel-2 до и после произошедших изменений. Второй набор данных аналогичен первому, а отличается только размером отдельного обучающего образца – 256 на 256 пикселей. Пространственное разрешение всех каналов было приведено к значению 10 метров. Общая схема процесса предварительной обработки изображений приведена на рисунке 3.8.



Рисунок 3.8 – Общая схема процесса предварительной обработки снимков

Характеристика моделей машинного обучения

В данной работе использовались алгоритмы, которые не учитывают временной аспект, а анализируют только пару снимков для выявления нарушений лесного покрова. В качестве основного алгоритма была выбрана архитектура Unet, которая относится к группе автоэнкодеров (autoencoders). Такая группа сетей позволяет сначала разбить все изображение на базовые признаки, на основе которых выделяются более высокоуровневые признаки. Более того, подобная архитектура позво-

ляет на выходе сохранить размер входного сегментируемого изображения без дополнительных преобразований. Поэтому результаты сегментации легко совмещать с начальными данными. Прямая связь, которая существует между конечными и начальными слоями, обеспечивает лучшее распространение градиента по всей сети, что, по сути, позволяет производить более быстрое обучение, а также комбинировать низкоуровневые и высокоуровневые признаки (Larabi et al., 2016).

В виде дополнения на первом этапе архитектура Unet была использована совместно с «предобработчиком» (backbone) VGG16 [139]. Этот подход заключается в использовании весов уже существующей модели (transfer learning), которая обучена на миллионах изображений и позволяет выделять базовые геометрические признаки на изображениях. Такая сеть используется как «предобработчик» изображений, выделяя на нем геометрические признаки низких порядков. В качестве такого предобработчика (backbone) использовалась сеть VGG16 с уже обученными весами на наборе ImageNet [94]. Эти веса находятся в открытом доступе. Результат такой предобработки подавался на вход сети Unet, которая выполняла непосредственно сегментацию изображения.

При обучении таким способом важную роль играет шаг обучения. Для того чтобы алгоритм с такой сложной архитектурой не потерял способность выявлять низкоуровневые признаки (отдельные линии, углы и т. д.), обучение проводилось при низком значении шага обучения 0,00001 и 0,001 (рисунки 3.9, 3.10). Также он снижался при каждой 20-й итерации.




Рисунок 3.9 – График обучения сети с предобработчиком при начальном значении шага обучения 0,001




Рисунок 3.10 – График обучения сети
при начальном значении шага обучения 0,00001

Более низкое значение шага обучения позволило сети дольше обучаться с сохранением исходных признаков. Несмотря на переобучение, которое наблюдалось при обучении всех групп изменений, результат предсказания сети оказался высок (более 50 %). Примеры предсказания моделей представлены на рисунке 3.11.

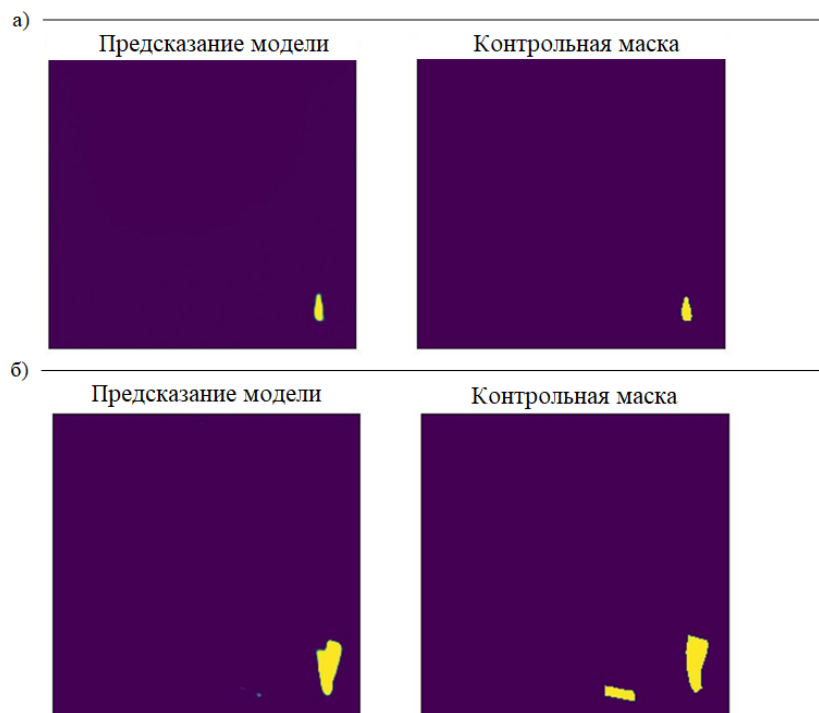


Рисунок 3.11 – Пример предсказания с использованием предобработчика VGG16
на летней группе изменений (а) и зимней группе изменений(б)

Наблюдавшееся переобучение также может говорить о том, что выбранная сеть слишком сложна для решаемой задачи, поэтому в дальнейших экспериментах использовалась только архитектура Unet без дополнительного предобработчика с различной вариацией параметров (рисунок 3.12).

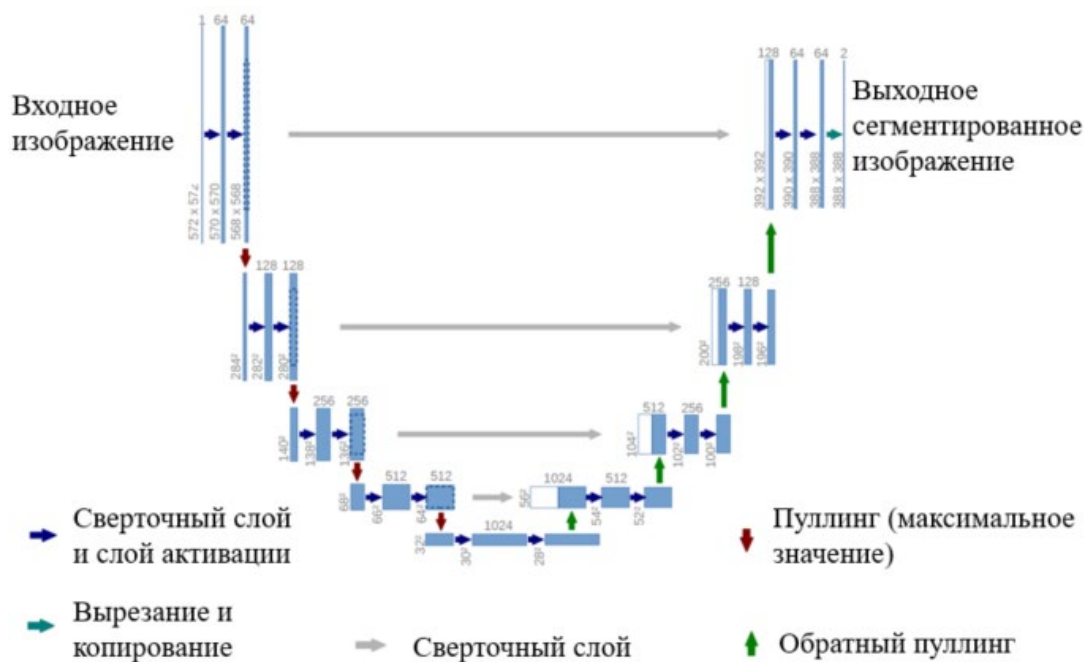


Рисунок 3.12 – Базовая архитектура Unet, использованная при экспериментах

Базовая архитектура сети была реализована с помощью библиотеки TensorFlow 2.0 [141], которая написана на языке программирования Python. Она содержит в себе базовые конструкции для построения нейронных сетей, различные функции активации и другие виды слоев нейронной сети, что позволяет создавать сложные модели машинного обучения. Также эта библиотека позволяет производить вычисления на графических процессорах, что существенно снижает время на расчет. В целом данная нейронная сеть состоит из двух блоков: энкодера (левая часть) (encoder) и декодера (правая часть) (decoder). Левая часть работает как классическая нейронная сеть. Каждый блок состоит из сверточного слоя с фильтром 3×3 , которые следуют друг за другом, активационной функции ReLU [46] после каждого слоя свертки и операции пуллинга с размером 2×2 . После применения одного

блока энкодера число каналов изображения удваивается. Декодер состоит из такого же числа блоков, как и энкодер, однако, в противоположность сверточному слою, содержит операцию повышения размерности изображения (upsampling, deconvolution). Дополнительно к соответствующему блоку декодера добавляются выделенные признаки с соответствующего слоя энкодера. После каждого слоя в блоке используется сверточный слой размером 2×2 , активационная функция ReLU. Последний слой нейронной сети использует сверточный слой для установления соответствия полученной карты признаков целевым классам.

Для предотвращения переобучения использовалась аугментация изображений, а именно геометрические преобразования (поворот, зеркальное отображение и др.) (рисунок 3.13).




Рисунок 3.13 – Пример операций аугментации из группы геометрических преобразований

С этой же целью были добавлены слои дропаута (dropout) [75]. Несколько сцен из каждой группы изменений были исключены из обучения для использования в качестве контрольных данных (тестовые данные). Оставшаяся часть использовалась при обучении, при этом она была разделена в пропорции 75 и 25 % для обучения и валидации соответственно.

На вход модели подается фрагмент двух последовательных изображений и их разница. Для обучения использовался оптимизатор Adam с функцией потерь бинарная кросс-энтропия (Binary Cross Entropy) [53]. Также после каждого сверточного слоя использовался слой Batch Normalization [143]. В качестве метрики оценки качества использовался коэффициент Дайса [72]. При обучении каждые 20 итера-

ций (эпох) шаг обучения снижался в 10 раз. Это является важным моментом, так как при обучении модели изменения весов производятся с наличием константы, которая называется шаг обучения (learning rate). На первых эпохах модель учится довольно быстро, оптимизатор быстро находит направление к минимуму потерь. Однако, в середине обучения высокий шаг обучения может привести к тому, что функция потерь перестанет снижаться, что останавливает дальнейший рост точности модели. Слишком высокий шаг обучения может привести к тому, что предсказания модели будут сильно отличаться с каждой новой эпохой. Типичные ситуации поведения графика функции потерь приведены на рисунке 3.14. Поэтому этому параметру уделялось особое внимание при экспериментах.



Рисунок 3.14 – Зависимость функции потерь от итерации (эпохи) обучения и размера начального шага обучения

Вышеописанная структура и настройки использовались при обучении всех моделей. В процессе исследования менялась в первую очередь комбинация входных признаков (приложение К). Для обучения алгоритма использовались наиболее информативные каналы для оценки состояния лесной растительности.

Вторая группа параметров, которая изменялась в процессе экспериментов, относилась к так называемым гиперпараметрам. Гиперпараметры – это параметры, которые устанавливаются в начале обучения и напрямую влияют на процесс даль-

нейшего обучения. Изменялись значение начального шага обучения (learning rate) и размер подвыборки (batch size) для обучения.

Изначально была использована вся обучающая выборка. Массив тайлов перемешивался и последовательно подавался на вход сети. Помимо этого, были проведены эксперименты с обучением отдельных моделей по каждому сезону года. Обучающая выборка разделялась на три группы: «летние», «зимние» и «переходные» изменения. Под «летними» изменениями подразумеваются нарушения лесного покрова, которые произошли в период, когда не сформировалось устойчивого снежного покрова, причем как на снимке до изменения, так и на снимке после изменения. К группе «зимних» изменений были отнесены нарушения лесного покрова, которые произошли в момент наличия устойчивого снежного покрова. Все остальные нарушения лесного покрова были отнесены к группе «переходные». Причем к ним были отнесены изменения, произошедшие как весной, так и осенью. Все объекты были проверены экспертно, чтобы не отнести группу изменений к неправильной группе. Итоговую таблицу с разделением по группам можно найти в приложении Г. Пример изменений разных групп представлен на рисунке 3.15.

Для группы «переходных» изменений разницы между каналами были рассчитаны как в «прямом», так и «обратном» направлении. Под «прямым» направлением понимается вычитание значений старого снимка из значений нового, а под «обратным» – вычитание значений нового снимка из старого. Это было сделано с учетом того, что характер нарушений весной и осенью остается один и тот же, только в первом случае снежный покров исчезает, а во втором появляется.

Всего проведено порядка 50 различных экспериментов с базовой архитектурой. Наилучшую точность показали модели, в которых при обучении использовались спектральные каналы RED, NIR, SWIR и их разности. Графики обучения моделей (зависимости функции потерь и точности от эпохи обучения), которые достигли наибольшей точности, представлены на рисунке 3.16.

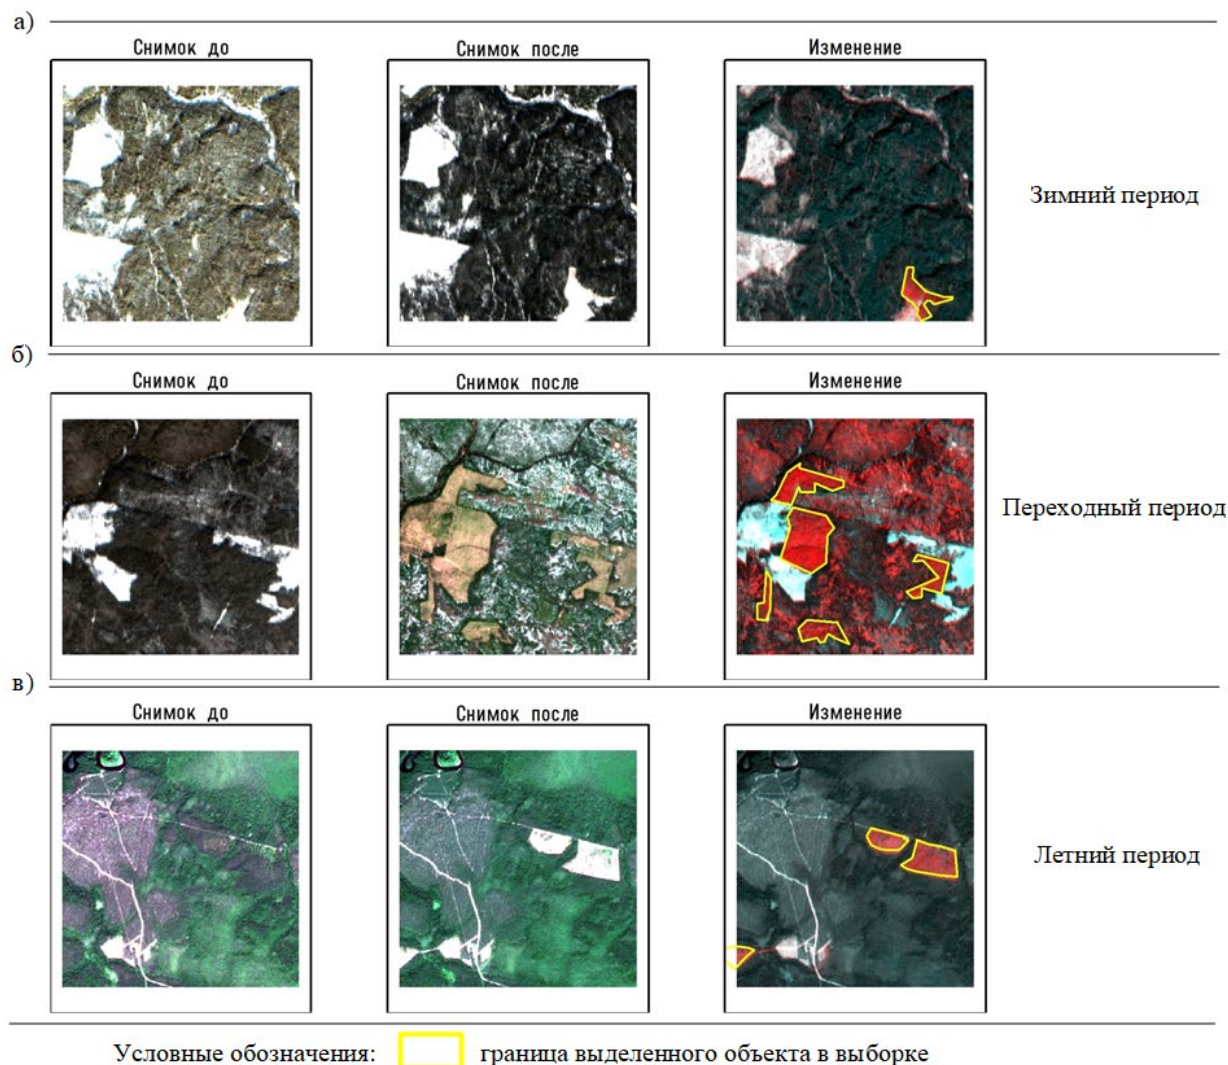


Рисунок 3.15 – Пример объектов из разных групп изменений

Наибольшая точность распознавания нарушений лесного покрова получена с помощью модели, обученной по данным только за бесснежный период (см. рисунок 3.16, б). В свою очередь, наименьшая точность получена по модели, обученной на данных переходного периода (см. рисунок 3.16, г). Как и ожидалось, нарушения лесного покрова, произошедшие в переходные сезоны, являются наиболее сложными для распознавания. Стоит отметить, что модель, обученная на изменениях всех сезонов, также показала высокую точность (свыше 60 %). Такая модель наиболее удобна для применения в системах мониторинга. Возможно использование и отдельных моделей, но в этом случае необходимо разработать инструмент автоматического определения сезона или выбирать нужную модель экспертно.

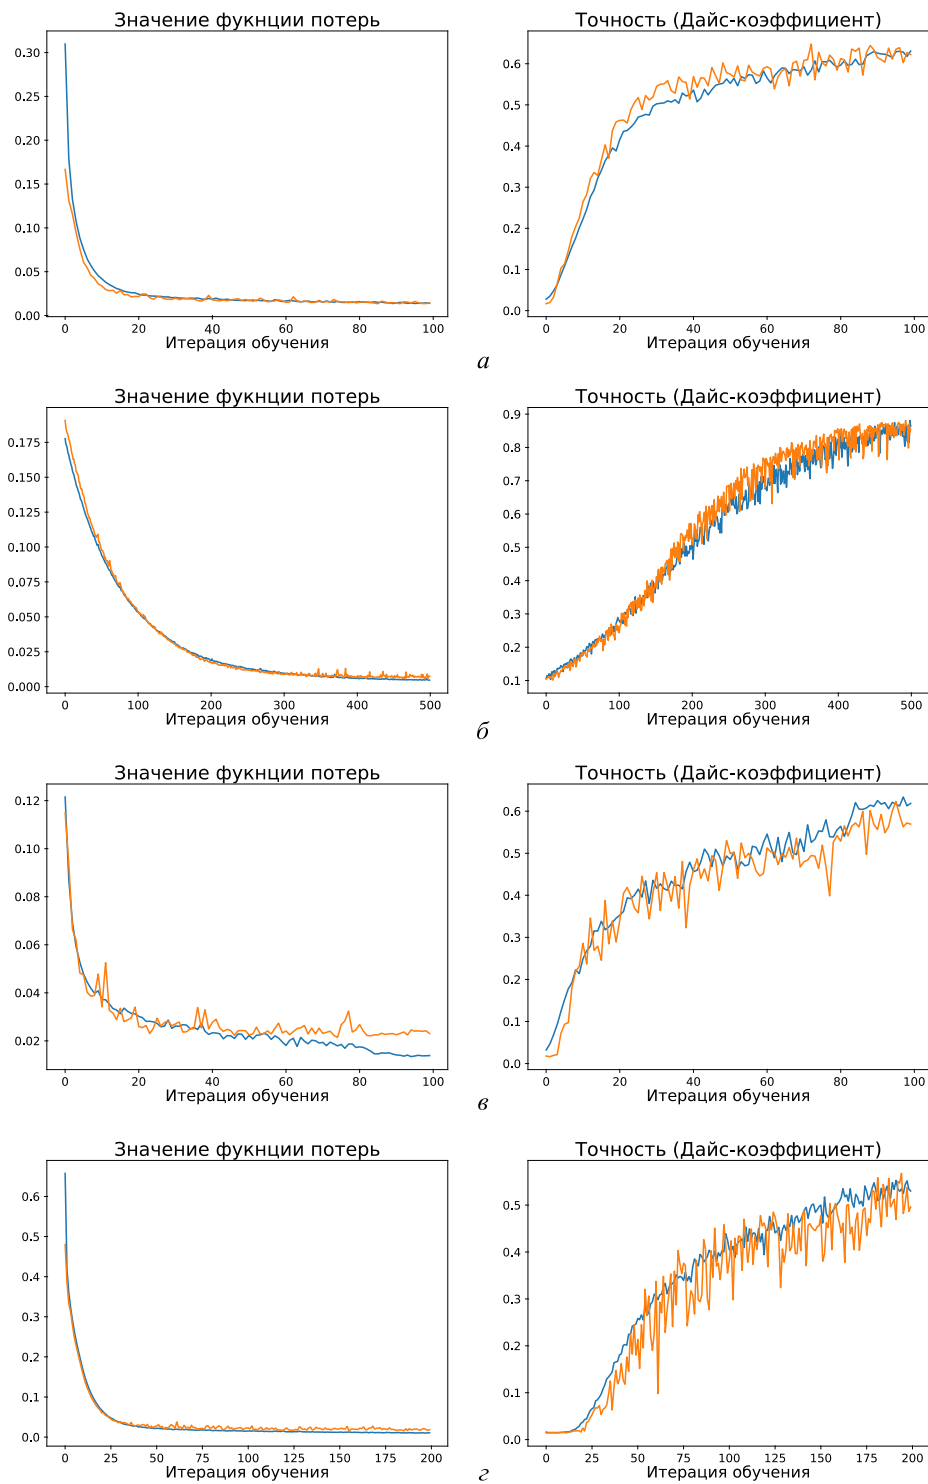


Рисунок 3.16 – Основные показатели обучения лучших моделей: *а*) при обучении по всем группам изменений; *б*) при обучении на летней группе изменений; *в*) при обучении на зимней группе изменений; *г*) при обучении на переходной группе изменений

3.5 Оценка эффективности разработанного алгоритма в сравнении с традиционными методами

В качестве контрольных данных был выбран поднабор из исходной выборки, который не участвовал в обучении (см. рисунок 3.6). Для летнего сезона было выбрано четыре сцены, для зимнего и переходного периода – по две сцены. Также выявленные контуры нарушений лесного покрова сравнивались с аналогичными, но полученными с использованием традиционных пороговых методов обнаружения изменений. Из всего многообразия традиционных методов были выбраны метод одноканального обнаружения изменений по красному каналу – для зимней группы изменений – и разность индекса NBR [56] для летнего и переходного периодов. Пороговые значения устанавливались экспертно. После выделения изменений слой конвертировался в векторный формат.

Результат работы модели представляет из себя растр, где в пикселах содержится значения вероятность произошедшего изменения (от 0 до 1). Порог вероятности для преобразования выявленных изменений в векторный формат был принят равным 0,1, на основе анализа соотношения пропусков объектов и ложных срабатываний.

При оценке точности использовался векторный слой с предварительной фильтрацией по площади (площадь объекта $> 0,1$ га). Никакие другие фильтры не использовались. Точность распознавания нарушений лесного покрова, полученная с помощью разработанной модели и традиционных методов, сравнивалась с контрольными данными с помощью показателя *F-меры* (см. формулы (2.1)–(2.3)). Значение *F-меры* для контрольных данных приведены в таблице 3.3.

В среднем по восьми проанализированным сценам точность распознавания нарушений лесного покрова по разработанной модели составила 0,48, а традиционными методами – 0,23. В зимний период повышение точности распознавания по разработанной модели достигается за счет устойчивости к наличию теней. Наименьшая точность наблюдается в переходный период, что объясняется сильным изменением значений яркости между изображениями (при наличии снежного покрова на одном из двух снимков).

Таблица 3.3 – Значения *F-меры* для контрольных данных

Тайл Sentinel-2	Дата первого снимка	Дата второго снимка	Период изменений	Точность традиционных методов, %	Алгоритм машинного обучения с самой высокой точностью			
					обученный на всех сезонах, %	обученный на зимнем сезоне, %	обученные на переходном сезоне, %	обученный на летнем сезоне, %
T40VEM	20.11.2019	24.03.2020	зимний	06	51	56	-	-
T40VEM	2017.11.25	13.02.2018	зимний	33	67	65	-	-
T37VFJ	08.03.2018	31.07.2018	переходный	09	41	-	41	-
T38VMP	22.03.2020	22.06.2020	переходный	43	39	-	42	-
T39VWF	25.05.2017	23.08.2017	летний	16	38	-	-	49
T39VXH	29.06.2018	04.09.2018	летний	62	60	-	-	59
T37WFM	18.07.2020	04.10.2020	летний	13	56	-	-	36
T38VPL	17.06.2018	01.08.2018	летний	05	27	-	-	61

* зеленым цветом отмечены алгоритмы, которые показали самую высокую точность, для контрольной сцены.

- значение не рассчитывалось.

Принципиальным отличием в результатах является то, что разработанные модели выделяют нарушение лесного покрова как целостный объект, что хорошо проявляется при детектировании выборочных рубок. Поэтому для всех выборочных рубок из контрольного набора было рассчитано количество объектов, которые пересекаются с ними в слоях, полученных с помощью разработанных моделей и традиционных методов (таблица 3.4, приложение Д).

Таблица 3.4 – Количество выделенных объектов для одного контрольного объекта с типом выборочная рубка

Тайл	Даты первого и второго снимков изменений	Период изменений	Традиционные методы	Алгоритм машинного обучения с самой высокой точностью			
				обученный на всех сезонах	обученный на зимнем сезоне	обученные на переходном сезоне	обученный на летнем сезоне
T40VEM	20.11.2019 – 24.03.2020	зимний	1,60	1,42	1,15	-	-
T37VFJ	08.03.2018 – 31.07.2018	переходный	2,31	2,66	-	1,50	-
T38VMP	22.03.2020 – 22.06.2020	переходный	9,00	1,66	-	1,50	-
T39VWF	25.05.2017 – 23.08.2017	летний	2,00	1,50	-	-	1,00
T38VPL	17.06.2018 – 01.08.2018	летний	5,00	1,00	-	-	1,50

Во всех случаях разработанные модели выявляют меньше объектов для одного контрольного, чем традиционные методы, причем наибольшее различие наблюда-

ется в переходные сезоны. На рисунке 3.17 представлены примеры выделения выборочных рубок моделью, обученной на всех группах изменений. Отметим, что на рисунке 3.17, в объект вообще не был выделен традиционными методами.

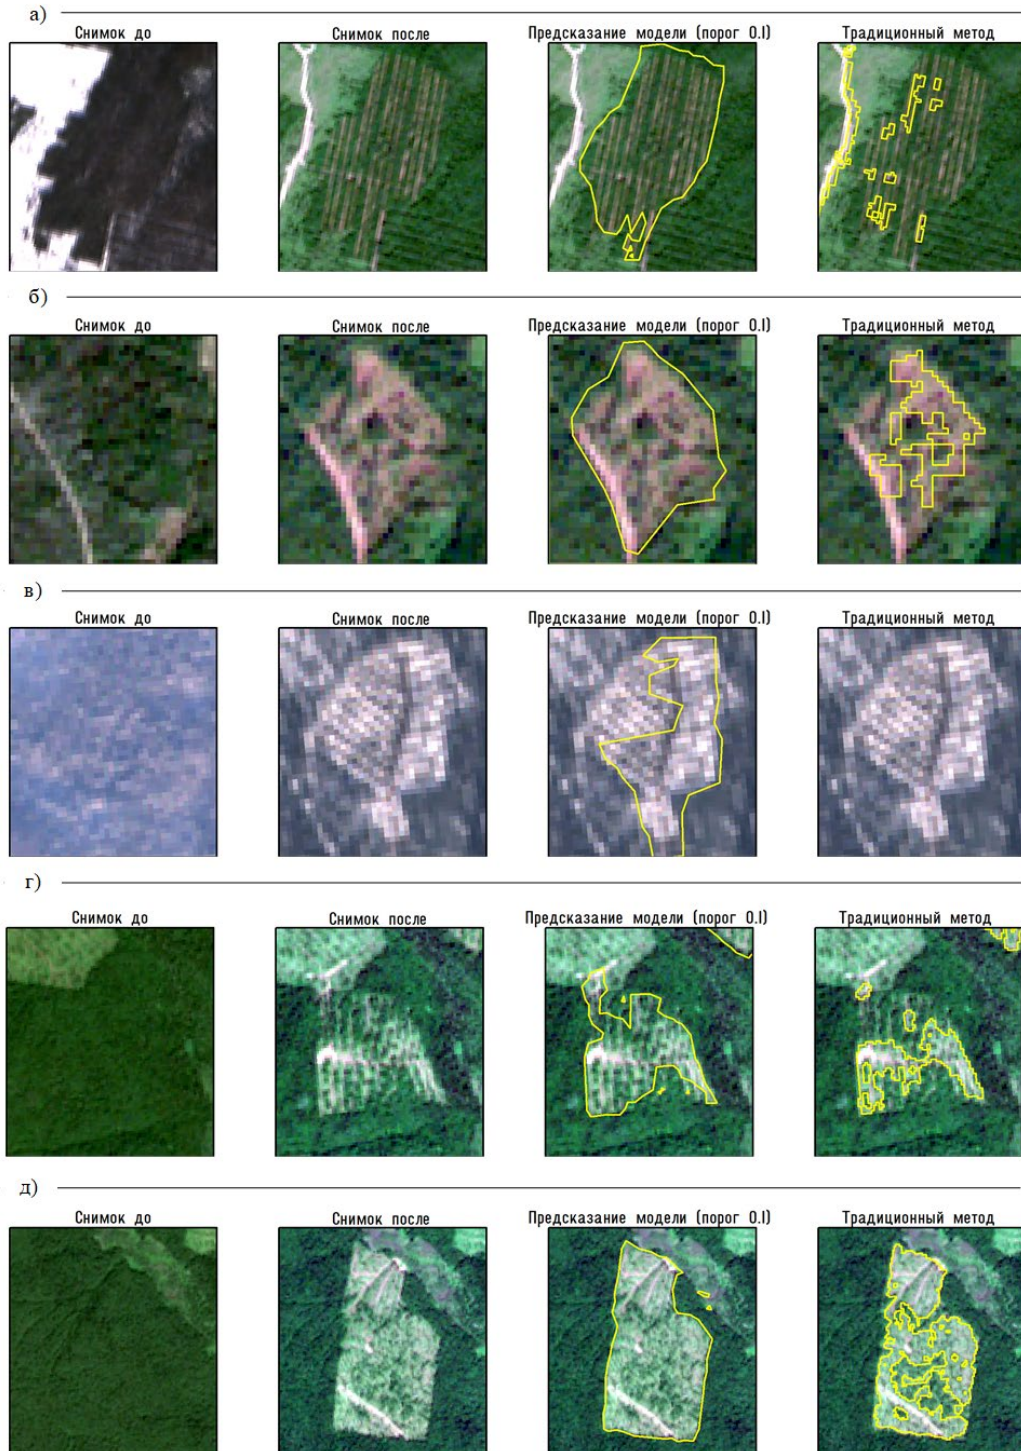


Рисунок 3.17 – Примеры выделения выборочных рубок по снимкам разных периодов: а) переходный; б) летний; в) зимний; г), д) летний период с разницей снимков около одного года

Для объектов с типом выборочная рубка было подсчитано количество выявленных объектов, а также средний процент выявленной площади в разрезе сезонных групп изменений (таблица 3.5).

Таблица 3.5 – Количество выделенных объектов для выборочных рубок

Сезон	Общее количество объектов	Традиционные методы		Алгоритм машинного обучения	
		средний процент выявленной площади	количество выделенных объектов	средний процент выявленной площади	количество выделенных объектов
переходный	63	15,85	32	19,49	22
летний	21	21,40	11	56,94	12
зимний	65	6,51	12	48,66	46

Контрольный объект считался выделенным, если площадь пересечения между ним и выявленным объектом составляла больше 10 % от площади контрольного объекта. Для каждого контрольного объекта был подсчитан процент пересечения с выявленным объектом, а после – отношение этой площади пересечения ко всей площади контрольного объекта. Далее рассчитывалось среднее значение по сезонам, которое и представлено в таблице. Стоит отметить, что процент средней выявленной площади только в переходный период сопоставим между двумя группами методов, а в летний и зимний период алгоритм на основе машинного обучения имеет значения в три и восемь раз выше, чем у традиционных методов. Однако в переходный период нейронная сеть дает чуть больше пропусков, но при этом более точно выделяет площадь контрольного объекта.

В рамках данного исследования также была проведена оценка точности работы модели для участков с разным типом лесопользования на примере территории Пермского края.

Экспертно было выделено три зоны, на которых есть арендованные площади крупных лесопромышленных предприятий, – ОАО «Соликамскбумпром» и ОАО «Пермский целлюлозно-бумажный комбинат»:

- зона с преобладанием выборочных и проходных рубок при значительной площади сельхозугодий (зона 1);
- лесная зона с высокой долей проходных рубок (зона 2);
- лесная зона с преобладанием сплошных рубок (зона 3).

Местоположения зон приведены в приложении И. Породный состав лесов в перечисленных зонах также различается: согласно карте [4] в зонах 1 и 2 преобладают лиственные и смешанные леса, а в зоне 3 значительную площадь занимают темнохвойные леса.

Для каждой зоны был создан контрольный набор данных, который включал в себя границы отводов под рубку леса, которые были официально поданы в 2018 г. арендаторами в Министерство природных ресурсов, лесного хозяйства и экологии Пермского края. Для каждой зоны загружались наиболее безоблачные снимки в течение всего 2018 г., по которым для каждого контрольного объекта устанавливалась дата вырубki. Каждая пара снимков подавалась на вход разработанному алгоритму, а после этого данные сравнивались с контрольными для каждой пары снимков.

Всего было проанализировано 485 контрольных объектов (рубок). На первом этапе для каждого контрольного объекта определялось наличие пересечения между его площадью и участками изменений, выявленных с помощью алгоритма (при этом порог вероятности изменений был принят равным 10 %). Если площадь пересечения между контрольным и выявленным объектом составляла больше 10 % от площади контрольного объекта, то такой контрольный объект считался успешно детектированным, остальные объекты оценивались как недетектированные. После этого все объекты из предсказанного моделью слоя, которые пересекаются с контрольными, удалялись. Оставшиеся объекты (которые не пересекались с контрольными) были проанализированы визуально, с целью определить наличие/отсутствие нарушения лесного покрова в данном месте.

Таким образом, для каждой из трех рассматриваемых зон было получено четыре показателя: общее число контрольных объектов, количество выделенных объ-

ектов из контрольных, пропущенных объектов и ложных срабатываний. Помимо количества объектов, для каждой группы считалась суммарная площадь в гектарах и различные соотношения (приложение Ж, таблица 3.6).

Таблица 3.6 – Процент выявленных объектов в контрольных зонах

Зона	Процент выделенных рубок	Процент невыделенных рубок	Процент ложно выделенных рубок	Средняя площадь ошибочно выделенного	Средняя площадь невыделенного объ-
1	91,4	8,6	6,4	0,4	4,1
2	93,9	6,1	7,0	0,5	2,7
3	94,5	5,5	8,2	0,7	5,3

Во всех случаях доля выявленных объектов моделью составила свыше 90 % (91,4 %), причем как при расчете по площади, так и по количеству. Доля пропусков объектов составила в среднем 6 %, а ложных срабатываний – 7,7 %. Стоит отметить, что при использовании фильтра по площади со значением меньше 1,0 га или других алгоритмов фильтрации долю ложных срабатываний можно сократить до 4 %. Такой вывод сделан на основе средней площади ошибочно выделенного объекта (0,7 га). Стоит отметить, что ложные срабатывания возникают чаще всего в руслах и поймах рек, по причине колебаний уровня воды и связанных с этим резких изменений яркостных характеристик. Исключение этих участков из анализа также позволит значительно сократить частоту ложных тревог.

Что касается пропущенных объектов, то их средняя площадь составила 6,4 га, а в переходные периоды (при сопоставлении снимков со снежным покровом и полученных в бесснежный период) она достигает 13,4 га.

Как и ожидалось, минимальной точностью выделения рубок из контрольного набора (84,5 %) характеризуется зона № 1, значительная часть которой занята сельхозугодьями. На сельхозугодьях высока доля ложных срабатываний модели; также на точность негативно повлияло наличие облачности на некоторых анализируемых снимках.

В рамках эксперимента была проведена оценка способности сети к выявлению и других нарушений лесного покрова, в частности ветровалов, смерчевых треков и

пожаров. В обучающей выборке не было достаточного количества обучающих этих типов, поэтому точность выявления их априори должна быть ниже. Важно в рамках данного эксперимента было оценить потенциал использования этого метода при выявлении таких типов нарушений лесного покрова при наличии соответствующей обучающей выборки. Примеры представлены на рисунках 3.18, 3.19.




Рисунок 3.18 – Пример выделения контура ветровала по снимкам Sentinel-2 на основе разработанного алгоритма для выделения вырубок

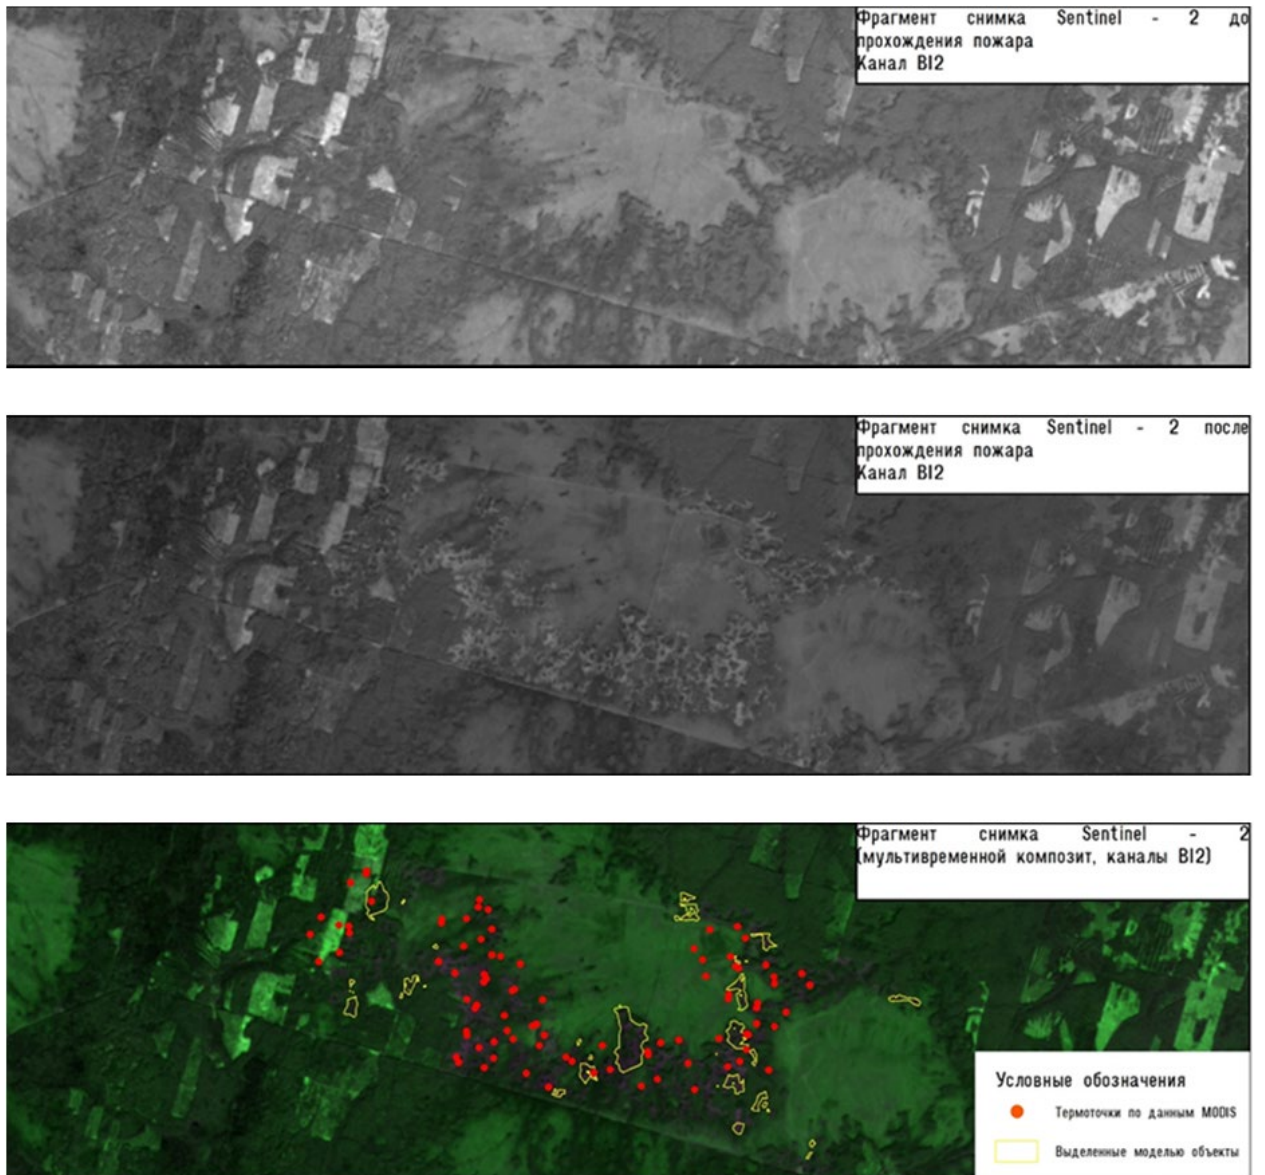


Рисунок 3.19 – Пример выделения контура гари по снимкам Sentinel-2 на основе разработанного алгоритма для выделения вырубок

Алгоритм выделил лишь отдельные участки ветровала и гари, что обусловлено ограниченным полем восприятия модели. При обучении использовались тайлы размером 256×256 пикселей ($2\,560 \times 2\,560$ м), поэтому алгоритму сложно выделить объекты большего размера. Неточное выделение ветровалов и пожаров еще раз подчеркивает, что сверточные сети учитывают геометрию объектов при детектировании, так как в обучающей выборке преобладали вырубки, границы которых более ровные.

Выводы по третьему разделу

1 Создан набор данных для обучения нейронной сети распознаванию нарушений лесного покрова. Он включает свыше 4 тыс. объектов, распределение основных характеристик которых (типов нарушений, площади и пр.) близко к распределению для вырубок в лесной зоне Пермского края и на Европейской зоны России в целом.

2 На основе более 50 различных экспериментов по распознаванию нарушений лесного покрова с помощью СНС архитектуры Unet по снимкам Sentinel-2 установлено, что наиболее информативными признаками являются спектральные каналы Red, NIR, SWIR и их разности. Модели, основанные на этих признаках, показали наилучшую точность распознавания.

3 Проведено сравнение точности распознавания нарушений лесного покрова на основе СНС и традиционных методов, основанных на растровой арифметике. Такое исследование, возможно, является первым для территории России. Установлено, что алгоритм на основе СНС обеспечивает повышение точности распознавания более чем в два раза в сравнении с традиционными методами, причем его существенное преимущество сохраняется для снимков зимнего, летнего и переходных сезонов. Наибольшая точность была достигнута моделью, которая была обучена на снимках летнего периода, наименьшая – на снимках переходных сезонов.

4 Преимущества СНС наиболее очевидны при детектировании выборочных рубок, которые выделяются как целостные объекты, в то время как с помощью традиционных методов удается выделить лишь отдельные пиксели с наибольшими изменениями в яркости.

5 Разработанные модели могут быть использованы в системах мониторинга с различным временным разрешением (еженедельный, ежемесячный, ежеквартальный, ежегодный). Точность распознавания нарушений лесного покрова по модели для всех сезонов составила 48 %, по модели для летней группы изменений – 45 %, по модели для зимней группы изменений – 45 %.

по модели для зимней группы изменений – 59 %, по модели для переходной группы изменений – 40 %.

6 Полученные оценки точности распознавания вырубок сопоставимы с результатами, полученными коллективом автором из Украины также с использованием архитектуры U-net [67]. Преимуществом данного исследования в сравнении с работой [67] является отсутствие эффекта переобучения нейронной сети, что повышает способность алгоритма к обобщению и возможности его адаптации для других территорий.

4 ОПЕРАТИВНОЕ КАРТОГРАФИРОВАНИЕ НАРУШЕНИЙ ЛЕСНОГО ПОКРОВА

4.1 Основные принципы применения оперативного картографирования в лесохозяйственной деятельности

Регулярное выявление и учет текущих изменений в лесах обеспечивает [30]:

- актуализацию данных государственного учета лесов на основе обновления баз данных и лесных карт и материалов лесоинвентаризации в межревизионный период между проведением повторной инвентаризации лесов;

- увеличение в 1,3–1,5 раза продолжительности ревизионного периода лесоинвентаризации и снижение тем самым затрат на проведение повторных лесоустроительных работ;

- совершенствование системы охраны лесов;

- своевременное проведение необходимых лесохозяйственных мероприятий по разработке гарей и ветровалов и предупреждению развития в горельниках и ветровальниках лесопатологических очагов;

- своевременное принятие мер по предотвращению негативного влияния на состояние лесов последствий различных видов хозяйственного воздействия;

- накопление интегральной информации о нарушениях лесного покрова для прогнозирования и оценки их последствий.

Поэтому очень важно оперативно предоставить результаты оперативного картографирования нарушений лесного покрова для пользователей. Как правило, это доступ реализуется при помощи технологий веб-картографирования. В настоящем разделе рассмотрены структура, информационное наполнение и функциональные возможности разработанного картографического веб-сервиса для мониторинга нарушений лесного покрова.

4.2 Аппаратно-программная структура

Функциональная схема разработанного веб-сервиса представлена на рисунке 4.1. Его аппаратно-программная структура традиционно строится на основе архитектуры «клиент-сервер», типичной для обычных веб-приложений, но с добавлением компонентов ГИС, и содержит три логических яруса: данных, логики и представления.

Логический ярус аппаратно-программной структуры картографического веб-сервиса представлен веб-сервером, который обеспечивает связь между пользователем и путем приема и передачи запросов от пользователя к базе данных и ответов в обратном направлении по Интернету посредством протокола HTTP.

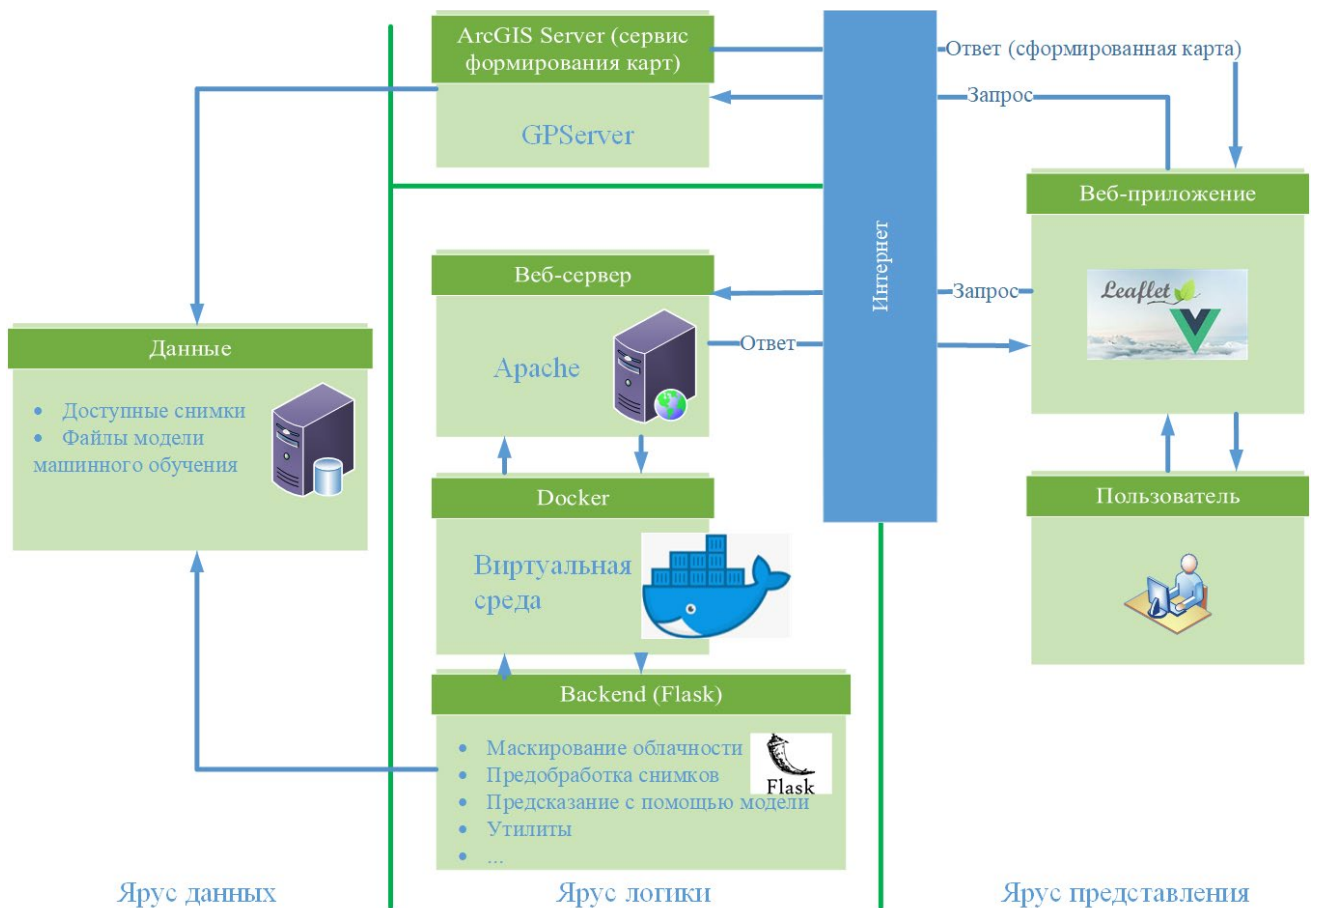


Рисунок 4.1 – Архитектура разработанного веб-приложения

На этом ярусе с помощью технологии виртуализации Docker настроено изолированное приложение в отдельной среде. Такая изоляция позволяет обезопасить сервер от нежелательных действий пользователя, а также легко горизонтально масштабировать приложение. Для данного приложения необходимо было написать логику, которая будет работать на сервере (backend). Для этого существует множество языков: PHP, Golang, Python и др. Для более простой интеграции моделей машинного обучения в приложение был выбран язык Python и библиотека Flask, так как сами модели были реализованы с помощью библиотеки на TensorFlow, а она в свою очередь также реализована на языке программирования Python. Серверная часть написана с помощью REST архитектуры [122]. Такая архитектура подразумевает обращение к данным с помощью различных HTTP запросов.

Ярус представления картографического веб-сервиса включает в себя приложение, которое предоставляет пользователю интерфейс. Чаще всего в качестве клиента выступают веб-браузеры на различных платформах. Клиентское приложение взаимодействует с пользователем, оно собирает входные данные от пользователя, посылает запросы на сервер и представляет результаты пользователю. Веб-приложение позволяет выполнять операции просмотра данных, формирования запросов, получения ответа и его отображения.

Веб-приложения строятся с использованием языка разметки гипертекста (HTML), оформление внешнего вида веб-страниц осуществляют с помощью каскадных таблиц стилей (CSS). Для придания интерактивности и динамичности веб-приложениям используют интерпретируемый веб-браузерами язык программирования JavaScript.

Для разработки интерактивных веб-приложений картографического сервиса широко используются интерфейсы программирования приложений API, например, такие как Leaflet, OpenLayers, Flex или Silverlight. Благодаря данным API веб-приложение можно наделять многими функциями традиционных ГИС. В последнее время активно начинают использоваться технологии, которые реализуют так называемый принцип «реактивности», когда специально разработанные инструменты эффективно управляют обновлением контента на странице. К такой технологии от-

носится и Vue.js [144], которая была использована при написании клиентской части приложения. В настоящей работе в качестве картографической библиотеки для отображения пространственных данных использовалась библиотека Leaflet [99].

Для разработки инструмента по формированию и выгрузке компоновки карты использовался ArcGIS for Desktop. Для этого был разработан специальный инструмент на языке программирования Python, который использует библиотеку Arcpy и заранее созданную компоновку для последующей автоматической выгрузки карты. Данный инструмент был опубликован на ArcGIS Server как инструмент геобработки GPService. После этого его можно запускать с различных клиентов, передавая необходимые параметры в строке адреса.

В качестве приложения веб-сервера используется Apache, которое является открытым и способно работать в среде операционной системы Linux. В качестве хранилища данных используется файловая система веб-сервера. Это обеспечивает простоту администрирования и использования данных.

4.3 Функциональные возможности сервиса

Непосредственными пользователями оперативных карт нарушений лесного покрова являются в первую очередь лесопользователи (арендаторы лесных участков), поэтому интерфейс приложения должен быть максимально понятным и дружелюбным для них.

Веб-приложение разделено на два семантических блока: карта и блок управления (рисунок 4.2). В блоке управления сосредоточены все главные управляющие элементы, в то время как карта служит для пространственного представления информации.

Управляющие элементы сгруппированы в три вкладки, на каждой из них в нижней части есть информационные сообщения о ее целевом назначении. На вкладке «доступные снимки» можно увидеть снимки Sentinel-2, для которых можно выполнить операции маскирования облачности или выявления нарушений лесного покрова.

В настоящее время, на сервисе можно анализировать только отдельные тайлы снимков Sentinel-2, либо пару снимков за разные даты для одного тайла. С учетом

этого, доступные снимки сгруппированы по тайлам. Для каждого снимка сохранена дата съемки. При выборе одного снимка становится доступным кнопка «рассчитать маску облачности» (рисунок 4.3), которая выполняет выделение маски облачности по выбранному снимку с помощью алгоритма, описанного в разделе 2. При выборе двух снимков из одной группы становится доступной кнопка «запустить расчет для выбранных снимков», которая запускает разработанную модель машинного обучения на выбранных снимках.

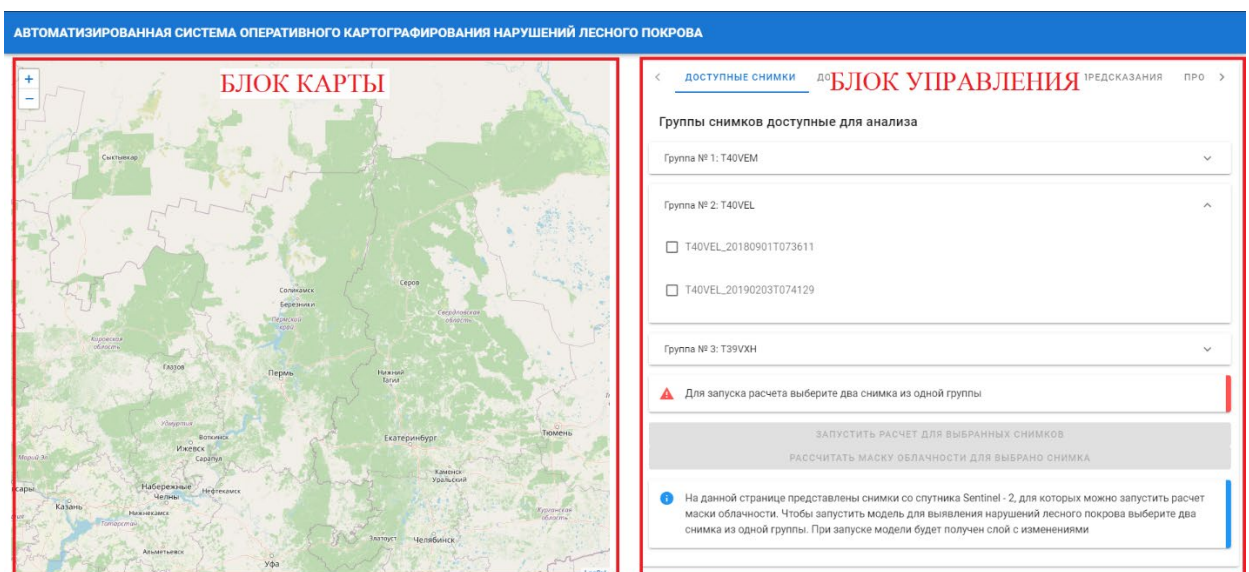


Рисунок 4.2 – Стартовая страница разработанного веб-приложения

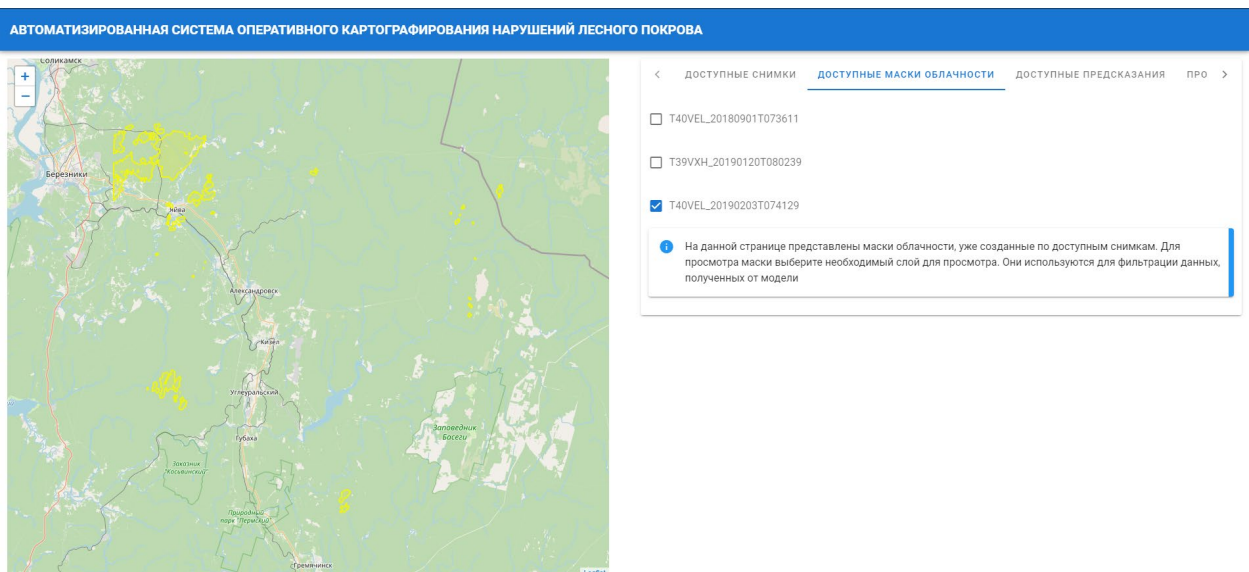


Рисунок 4.3 – Вкладка «Доступные маски облачности» с одним выбранным слоем

На вкладке «доступные маски облачности» можно посмотреть уже созданные маски облачности. При выборе нужного слоя он отображается в окне карты.

Третья вкладка «Доступные предсказания» отображает список уже выполненных предсказаний алгоритма МО по паре снимков, сохраненных в формате GeoJSON (рисунок 4.4). Исходный растр вероятности изменений, которые получаются в результате работе модели, конвертировался по порогу вероятности, равному 0,1, в бинарный растр, а далее преобразовывался в векторный формат. В названии слоя отображается идентификатор тайла, дата первого снимка, дата второго снимка, для которого было выполнен расчет по модели. При выборе одного из слоев он так же, как и маска облачности, отображается на карте. Стоит отметить, что на сайте представлены результаты выявления нарушений лесного покрова с учетом маски облачности, если она не была создана для двух снимков. Маскирование облачности выполняется после предсказания, а результирующая маска учитывается при формировании векторного слоя полученных изменений. Этот слой является интерактивным и при клике на любой объект автоматически открывается третья вкладка с выбранным объектом.

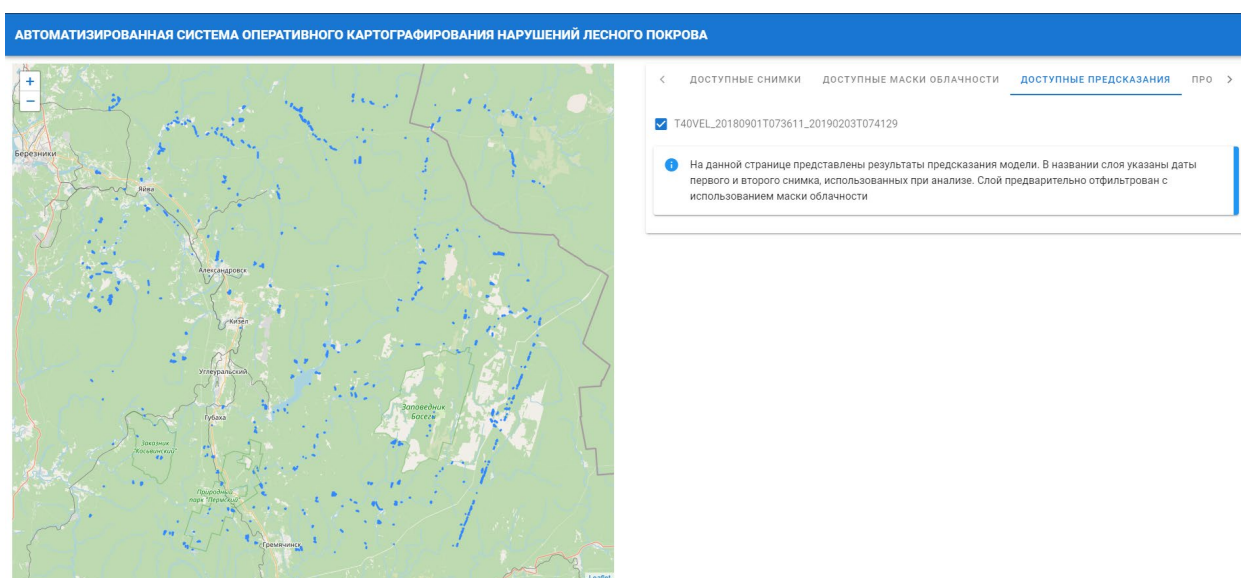


Рисунок 4.4 – Доступные предсказания с одним выбранным слоем

Третья вкладка «Просмотр изменений» (рисунок 4.5) является основной. Она позволяет просмотреть контуры полученных объектов (нарушений лесного покрова), а также фрагмент снимка до изменения и после. Помимо этого, она позволяет сформировать картографический отчет с выбранным объектом.

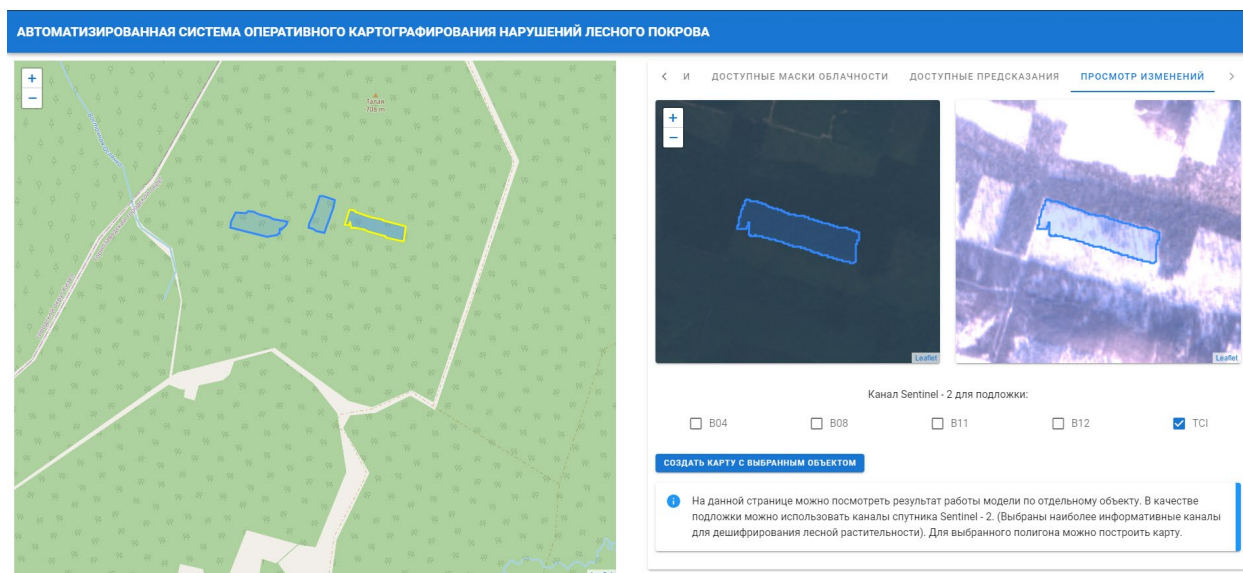


Рисунок 4.5 – Пример отображения информации для одного из объектов

Выбранный объект подсвечивается другим цветом и становится активным. При этом выбранный объект отображается на двух картосхемах, которые синхронизируются между собой. В качестве подложки можно выбрать красный канал (B04), ближний инфракрасный канал (B08), один из средних инфракрасных (B11, B12), а также фрагмент изображения в синтезе естественных цветов (TCI). На первой схеме (рисунок 4.6) отображается фрагмент снимка до изменения, на второй – фрагмент снимка после изменения.

Если выбран какой-нибудь объект из слоя изменений, становится активной кнопка «создать карту с выбранным объектом». Этот инструмент отправляет запрос на специальный сервис ArcGIS Server, и после выполнения запроса позволяет загрузить сформированную карту (рисунок 4.7).

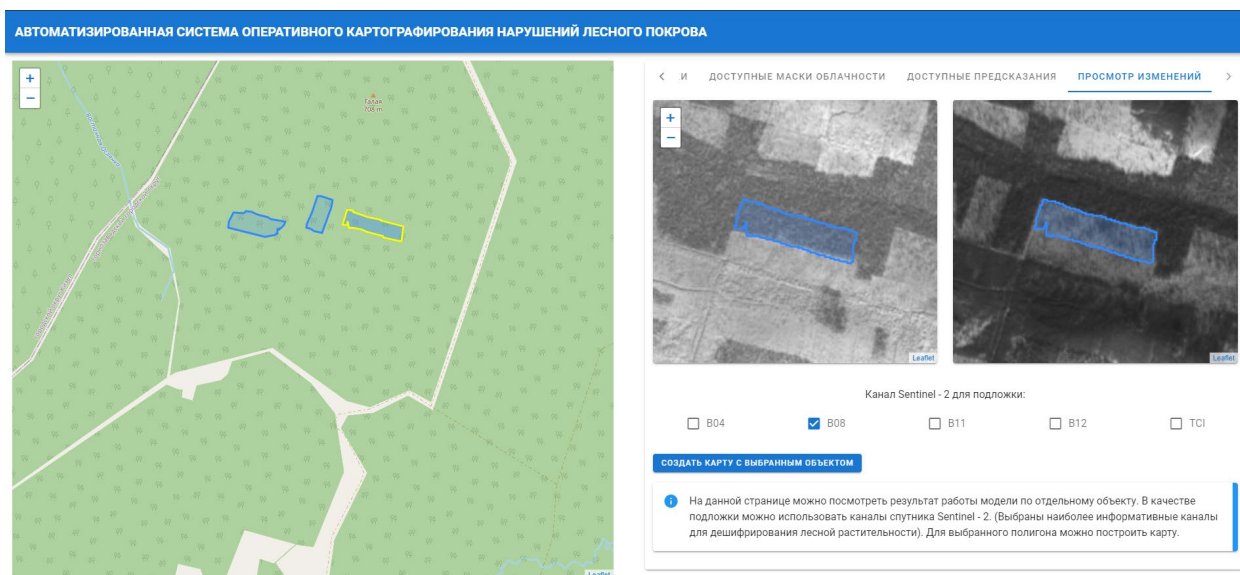


Рисунок 4.6 – Пример выбранного объекта, с выбранным красным каналом (B04) в качестве подложки

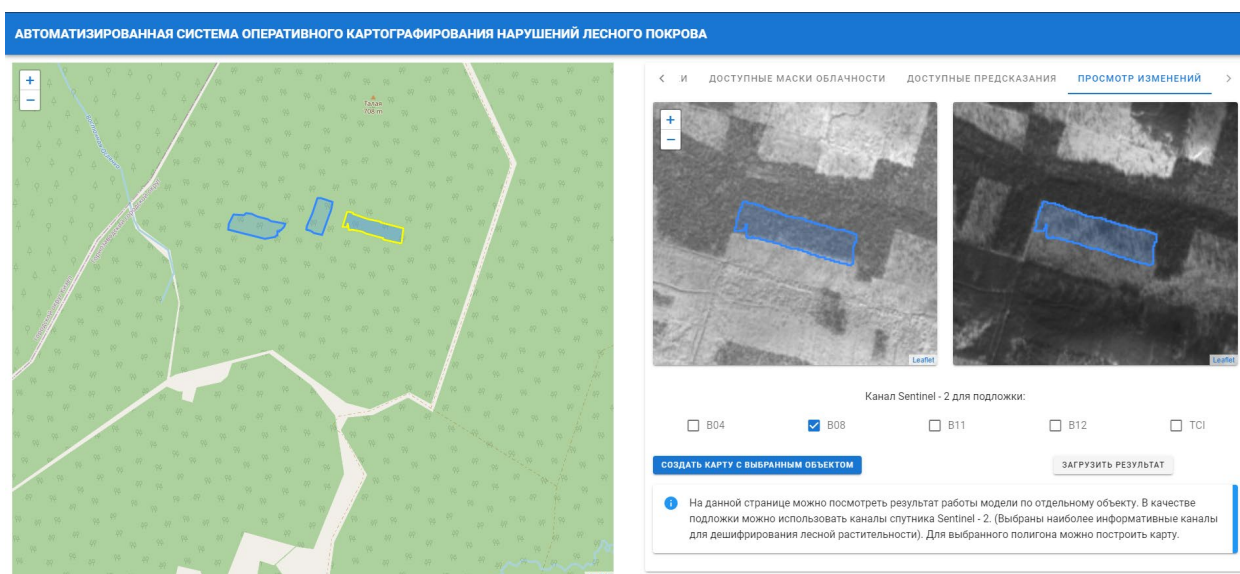


Рисунок 4.7 – Пример страницы с выполненным запросом на ArcGIS Server и возможностью скачать полученный результат

Эта операция позволяет сформировать типовую компоновку карты для выбранного объекта. Шаблон карты представлен в приложении Е. Этот шаблон содержит необходимую для лесопользователей информацию, а именно характеристику площади и местоположения выявленного нарушения лесного покрова. Ана-

логичная компоновка использовалась как отчетная форма в ходе реализации проекта по ежемесячному спутниковому мониторингу лесопользования на территории Добрянского лесничества [34]. Разработанная форма также соответствует требованиям к оформлению приложения к отчету о проведенных лесохозяйственных мероприятиях в рамках приказов МПР РФ [17].

Инструмент, к которому выполняется запрос, на основе пространственного положения объекта определяет его принадлежность лесничеству, участковому лесничеству, кварталу и вставляет данные в компоновку. На сегодняшний день информация о квартальной лесоустроительной сети доступна только по Пермскому краю, поэтому данные о местоположении можно получить, только если выявленное нарушение лесного покрова находится в Пермском крае. Помимо информации о положении определяется дата снимка, рассчитывается площадь объекта, определяется подходящий масштаб. В качестве подложки используется выбранный пользователем канал снимка Sentinel-2. В качестве подложки используется фрагмент более позднего снимка, чтобы можно было оценить соответствие автоматически выделенного контура его фактическим границам на снимке. Полученную карту можно скачать в формате pdf (рисунок 4.8).



Рисунок 4.8 – Пример сформированного картографического материала с подложкой на основе красного канала (B4) снимка Sentinel-2

Выводы по четвертому разделу

1 Использование методов оперативного картографирования позволяет сократить стоимость работ по мониторингу нарушений лесного покрова, а также эффективно управлять текущей обстановкой в лесохозяйственной деятельности. Представление данных на веб-сервисе позволяет оперативно информировать всех заинтересованных лиц о произошедших изменениях.

2 Разработанные программные инструменты могут быть легко интегрированы в существующие системы мониторинга нарушений лесного покрова, а созданный картографический веб-сервис – стать основой создания новой системы мониторинга. Использование такого сервиса позволит использовать разработанные алгоритмы для составления оперативных карт нарушений лесного покрова, которые могут быть полезны для текущей оценки ситуации и принятия управленческих решений.

3 Функциональные возможности разработанного прототипа веб-сервиса, главным образом, определяются его проблемной ориентацией и заключаются в следующем:

- возможность оценить результат выполнения алгоритма для каждого выявленного объекта;
- возможность визуализации результатов автоматизированного маскирования облачности и выявления нарушений лесного покрова;
- функции автоматической генерации картографического материала на основе стандартной компоновки, которая может быть использована для формирования приложений к официальным документам отчетности о вырубках.

ЗАКЛЮЧЕНИЕ

Представленная диссертационная работа содержит полученные автором новые результаты в области разработки методов оперативного картографирования нарушений лесного покрова по спутниковым данным с высоким пространственным и временным разрешением.

Основные научные и практические результаты диссертационного исследования заключаются в следующем:

– в результате проведенного анализа литературы установлено, что на сегодняшний день остро стоит вопрос об оперативном предоставлении актуальной и наиболее полной пространственной информации для принятия управленческих решений в лесной отрасли, с учетом появления новых источников данных ДЗЗ, которые обладают высоким пространственным и временным разрешением (PlanetScore, Sentinel-2), становится возможным применять методы оперативного картографирования и в лесной отрасли. В то же время государственные организации РФ, ответственные за проведение мероприятий по охране, защите, контролю пользования лесов, заинтересованы в использовании новых данных ДЗЗ для улучшения качества, оперативности, точности оценки нарушений лесного покрова и снижения затрат. Таким образом, разработка систем оперативного картографирования лесов на основе применения новых методов машинного обучения и новых данных ДЗЗ с использованием web-сервисов имеет большую перспективу;

– на основе проведенных экспериментов по маскированию облачности на разносезонных снимках Sentinel-2 с применением традиционных алгоритмов и метода, основанного на машинном обучении (s2cloudless), доказано, что алгоритм s2cloudless обеспечивает наибольшую точность маскирования (среднее значение *F-меры* 83 %). Более того, использование методов машинного обучения увеличивает точность маскирования облачности по снимкам Sentinel-2 вне зависимости от сезона года и типа облачности на 5–10 %. Применение этого метода для снимков PlanetScore повышает точность маскирования облачности при наличии снежного

покрова. Использование методов машинного обучения при маскировании облачности повышает качество предварительной обработки снимков и в дальнейшем – точность оперативного картографирования нарушений лесного покрова;

– создан новый набор обучающих данных для выявления нарушений лесного покрова с помощью сверточных нейронных сетей, а на его основе проведено более 50 различных экспериментов по распознаванию нарушений лесного покрова с помощью сверточной нейронной сети архитектуры U-net по снимкам Sentinel-2. Установлено, что наиболее информативными признаками для выявления нарушений лесного покрова с помощью сверточных нейронных сетей по одной паре снимков являются спектральные каналы Red, NIR, SWIR и их разности. Это необходимо учитывать при создании моделей распознавания нарушений лесного покрова, а также практических рекомендаций по применению методов машинного обучения в данной области;

– сравнение точности распознавания нарушений лесного покрова на основе сверточной нейронной сети и традиционных методов, основанных на растровой арифметике, показало, что алгоритм на основе сверточных нейронных сетей можно применять при картографировании нарушений лесного покрова, при этом обеспечивается повышение точности распознавания более чем в два раза в сравнении с традиционными методами на контрольном наборе данных. Существенное преимущество сверточных нейронных сетей сохраняется вне зависимости от сезона (для снимков зимнего, летнего и переходных сезонов). Наибольшая точность была достигнута моделью, которая была обучена на снимках летнего периода, наименьшая – на снимках переходного сезона. Преимущества сверточных нейронных сетей наиболее очевидны при детектировании выборочных рубок, которые выделяются как целостные объекты, в то время как с помощью традиционных методов удается выделить лишь отдельные пиксели с наибольшими изменениями в яркости;

– разработанные модели могут быть использованы в системах мониторинга с различным временным разрешением (еженедельный, ежемесячный, ежеквартальный, ежегодный). Точность распознавания нарушений лесного покрова (на основе

показателя *F-меры*) по модели для всех сезонов составила 48 % (с применением традиционных методов 23 %), по модели для летней группы изменений – 45 % (традиционные методы 25 %), по модели для зимней группы изменений – 59 % (традиционные методы 20 %), по модели для переходной группы изменений – 40 % (традиционные методы 21 %). Это позволяет выполнять предварительную обработку снимков для оперативного картографирования нарушений лесного покрова с более высокой точностью в течение всего года;

– разработан прототип картографического веб-сервиса, который может быть легко интегрирован в существующие системы мониторинга, а также стать основой собственной системы. Использование такого сервиса позволит применять разработанные алгоритмы для составления оперативных карт нарушений лесного покрова, которые могут быть полезны в принятии управленческих решений и текущей оценки ситуации.

Полученные результаты диссертационного исследования рекомендуются к использованию в системе поддержки принятия решений в области управления лесным хозяйством, в частности при оценке воздействия негативных явлений на лесной фонд. Помимо этого, результаты могут быть использованы и коммерческими организациями для составления дополнений к различным отчетам и планирования лесозаготовительных мероприятий, полученные алгоритмы могут использоваться в системах автоматического выявления нарушений лесного покрова в таежной лесной зоне.

Перспективы дальнейших исследований в первую очередь связаны с увеличением точности распознавания разных типов нарушений лесного покрова, увеличением точности сегментирования вырубок с неполным изъятием древостоя.

СПИСОК СОКРАЩЕНИЙ И УСЛОВНЫХ ОБОЗНАЧЕНИЙ

СДМ	Система дистанционного мониторинга
WRI	Всемирный институт ресурсов
ИК	Инфракрасный канал
СНС	Сверточная нейронная сеть
МО	Машинное обучение
ДЗЗ	Данные дистанционного зондирования Земли
БПЛА	Беспилотный летательный аппарат
Рослесхоз	Федеральное агентство лесного хозяйства
ГИЛ	Государственная инвентаризация лесов
ИКИ РАН	Институт космических исследований Российской академии наук
GPU	Graphics processing unit – Графическая единица вычислений
Adam	Adaptive moment estimation – Адаптивная оценка момента
HTML	Hypertext Markup Language – Язык разметки гипертекста
RED	Красный спектральный канал
NIR	Ближний инфракрасный канал
SWIR	Средний инфракрасный канал

СПИСОК ЛИТЕРАТУРЫ

1 Андреев, А. И., Шамилова Ю. А., Холодов Е. И. Применение сверточной нейронной сети для детектирования облачности по данным прибора МСУ-МР спутника «Метеор-М» № 2 / А. И. Андреев, Ю. А. Шамилова, Е. И. Холодов. – Текст : непосредственный // Метеорология и гидрология. – 2019. – № 7. – С. 44–53.

2 Берлянт, А. М. Геоинформационные технологии и их использование в эколого-географических исследованиях / А. М. Берлянт, О. Р. Мусин, Ю. В. Свентэк. – Текст : непосредственный // География. – Москва : МГУ, 1993.

3 Берлянт, А. М. Теория геоизображений / А. М. Берлянт. – Москва : ГЕОС, 2006. – Текст : непосредственный.

4 Информационная система комплексного дистанционного мониторинга лесов «Вега-Приморье» / Е. А. Лупян, С. А. Барталев, И. В. Балашов, С. С. Барталев, М. А. Бурцев, В. А. Егоров, В. Ю. Ефремов, В. О. Жарко, А. В. Кашницкий, П. А. Колбудаев, Л. С. Крамарева, А. А. Мазуров, А. Ю. Оксюкевич, Д. Е. Плотников, А. А. Прошин, К. С. Сенько, И. А. Уваров, С. А. Хвостиков, Т. С. Ховратович. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2016. – Т. 13, № 5. – С. 11–28.

5 Информационная система космического мониторинга санитарного состояния лесов ВЕГА-лесопатолог / И. А. Уваров, Д. В. Ершов, А. М. Крылов, С. А. Барталев, Е. А. Лупян. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2012. – Т. 9, № 5. – С. 171–180.

6 Исследование возможностей оценки состояния поврежденных пожарами лесов по данным многоспектральных спутниковых измерений / С. А. Барталев, В. А. Егоров, А. М. Крылов, Ф. В. Стыценко, Т. С. Ховратович. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2010. – Т. 7, № 3. – С. 215–225.

7 Книжников, Ю. Ф. Аэрокосмические методы географических исследований / Ю. Ф. Книжников, О. В. Тутубалина. – Москва : Издательский центр Академия, 2011. – 416 с. – Текст : непосредственный.

8 Королева, Н. В. Оценка погрешности определения площадей ветровалов по космическим изображениям высокого пространственного разрешения LANDSAT-TM / Н. В. Королева, Д. В. Ершов. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2012. – Т. 9, № 1. – С. 80–86.

9 Крылов, А. М. Выявление и оценка площадей катастрофических ветровалов 2009–2010 гг. по данным космической съемки / А. М. Крылов, Е. Г. Малахова, Н. А. Владимирова. – Текст : непосредственный // Известия Санкт-Петербургской лесотехнической академии. – 2012. – № 200. – С. 197–207.

10 Крылов, А. М. Выявление очагов короеда-типографа в Московской области с использованием снимков Landsat / А. М. Крылов, А. А. Соболев, Н. А. Владимирова. – Текст : непосредственный // Лесной вестник. – 2011. – № 4. – С. 54–60.

11 Крылов, А. М. Дистанционный мониторинг состояния лесов по данным космической съемки / А. М. Крылов, Н. А. Владимирова. – Текст : электронный // Геоматика. – 2011. – № 3. – С. 53–58. – URL: <http://geomatika.ru/clauses/282/>.

12 Кузьмичев, Е. П. Объемы незаконных рубок лесных насаждений в Российской Федерации / Е. П. Кузьмичев, И. Г. Трушина, Е. В. Лопатин. – Текст : электронный // Лесхоз. информ.: электрон. сетевой журн. 2018. – № 1. – С. 63–77. – URL: <http://lhi.vniilm.ru>.

13 Лесной кодекс Российской Федерации : федер. закон от 04.12.2006 № 200-ФЗ (ред. от 02.07.2021). – URL: <http://www.consultant.ru>. – Текст : электронный.

14 Лесные пожары на территории России: особенности пожароопасного сезона 2019 г. / Е. А. Лупян, И. В. Балашов, С. А. Барталев, М. А. Бурцев, В. В. Дмитриев, К. С. Сенько, Ю. С. Крашенинникова. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2019. – Т. 16, № 5. – С. 356–363.

15 Новости космической деятельности. – URL: <https://ecoruspace.me/Серия+Sentinel+2.html>. – Текст : электронный.

16 Об утверждении лесоустроительной инструкции : приказ Министерства природных ресурсов и экологии РФ от 29.03.2018 № 122. – URL: <http://www.consultant.ru>. – Текст : электронный.

17 Об утверждении перечня информации, включаемой в отчет об использовании лесов, формы и порядка представления отчета об использовании лесов, а также требований к формату отчета об использовании лесов в электронной форме : приказ Минприроды России от 21.08.2017 № 451 (Зарегистрировано в Минюсте России 22.12.2017 N 49380). – URL: <http://www.consultant.ru>. – Текст : электронный.

18 Об утверждении порядка осуществления государственного лесопатологического мониторинга : приказ Министерства природных ресурсов и экологии РФ от 5.04.2017 № 156. – URL: <http://www.consultant.ru>. – Текст : электронный.

19 Об утверждении порядка проведения лесопатологических обследований и формы акта лесопатологического обследования : приказ Министерства природных ресурсов и экологии РФ от 16.09.2016 № 480. – URL: <http://www.consultant.ru>. – Текст : электронный.

20 Основные возможности и структура информационной системы дистанционного мониторинга лесных пожаров Федерального агентства лесного хозяйства (ИСДМ Рослесхоз) / С. А. Барталев, Д. В. Ершов, Г. Н. Коровин, Р. В. Котельников, Е. А. Лупян, В. Е. Щетинский. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2010. – Т. 7, № 2. – С. 97–10.

21 Пример сверточного слоя. – URL: https://cdn-images-1.medium.com/max/1000/0*dRD6PhKOnnC1hz15.jpg. – Изображение : электронное.

22 Развитие подходов к построению информационных систем дистанционного мониторинга / Е. А. Лупян, М. А. Бурцев, А. А. Прошин, Д. А. Кобец. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из Космоса. – 2018. – Т. 15, № 3. – С. 53–66.

23 Салищев, К. А. Картоведение / К. А. Салищев. – Москва : МГУ, 1990. – Текст : непосредственный.

24 Свидетельство о государственной регистрации программы для ЭВМ № 2017660455 Российская Федерация. Программа ForestCalc / А. В. Тарасов, А. В. Кедров ; правообладатель ООО «Малое инновац. предпр. «Центр косм. техн. и услуг» (RU) ; дата поступления 25.07.2017 ; дата регистрации 21.09.2017. – Текст : непосредственный.

25 Система оперативного обнаружения зимних рубок леса по данным дистанционного зондирования. – URL: <http://nextgis.ru/blog/winter-alarm/>. – Текст : электронный.

26 Совзонд. – URL: <https://sovzond.ru/press-center/news/market/3203/>. – Текст : электронный.

27 Ступин, В. П. Картографо-космический мониторинг природных и антропогенных процессов и явлений Байкальского региона / В. П. Ступин, Б. Н. Олзоев, Л. А. Пластинин. – Текст : непосредственный / Интерэкспо ГЕО-Сибирь. XV Междунар. науч. конгр., 24–26 апреля 2019 г., Новосибирск : сб. материалов в 9 т. Т. 1 : Междунар. науч. конф. «Геодезия, геоинформатика, картография, маркшейдерия». – Новосибирск : СГУГиТ, 2019. № 2. – С. 178–184.

28 Ступин, В. П. Оперативный дистанционный мониторинг Приангарья в интересах обеспечения рационального природопользования и эффективного управления / В. П. Ступин, А. Я. Гиенко, Л. А. Пластинин. – Текст : непосредственный / ГЕО-Сибирь-2010. VI Междунар. науч. конгр. : сб. материалов в 6 т. (Новосибирск, 19–29 апреля 2010 г.). – Новосибирск : СГГА, 2010. – Т. 1, № 3. – С. 138–142.

29 Cycle Gan Datatsets Yosemite. – URL: https://people.eecs.berkeley.edu/~taesung_park/CycleGAN/datasets/summer2winter_yosemite.zip. – Изображение : электронное.

30 Сухих В. И. Аэрокосмические методы в лесном хозяйстве и ландшафтном строительстве / В. И. Сухих. – Йошкар-Ола : МарГТУ, 2005 – 392 с. – Текст : непосредственный.

31 Тарасов, А. В. Классификация лесной растительности методом нейронных сетей / А. В. Тарасов, А. В. Кедров. – Текст : непосредственный // Вестник Пермского национально исследовательского политехнического университета. Электро-

техника, информационные технологии, системы управления. – 2017. – Т. 22, № 3. – С. 44–54.

32 Тарасов, А. В. Опыт применения методов машинного обучения для выявления облачности на примере Пермского края / А. В. Тарасов. – Текст : непосредственный // Материалы всероссийской научно-практической конференции с международ. участием «Цифровая география». – Пермь, 2020. – С. 177–180.

33 Тарасов, А. В. Оценка точности алгоритмов выделения маски облачности по данным Sentinel-2 и PlanetScope / А. В. Тарасов. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2020. – Т. 17, № 7. – С. 26–38. – doi: 10.21046/2070-7401-2020-17-7-26-38.

34 Тарасов, А. В. Оценка точности методов маскирования облачности по снимкам Sentinel-2 и PlanetScope / А. В. Тарасов. – Текст : непосредственный // Материалы VI междунар. научн. конференции «Региональные проблемы дистанционного зондирования Земли». – Красноярск, 2019. – С. 139–143.

35 Тарасов, А. В. Применение оперативного картографирования при ведении лесохозяйственной деятельности / А. В. Тарасов. – Текст : непосредственный // Географический вестник = Geographical bulletin. – 2019. – № 3 (50). – С. 134–145. – doi 10.17072/2079-7877-2019-3-134-145.

36 Тарасов, А. В. Распознавание нарушений лесного покрова по спутниковым снимкам Sentinel-2 с помощью сверточных нейронных сетей / А. В. Тарасов, А. Н. Шихов, Т. В. Шабалина. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2021 – Т. 18, № 3. – С. 51–64. doi: 10.21046/2070-7401-2021-18-3-51-64.

37 Тарасов, А. В. Современные методы оперативного картографирования нарушений лесного покрова / А. В. Тарасов. – Текст : непосредственный // Вестник СГУГиТ. – 2020. – Вып. 3 (25). – С. 201–213. – doi: 10.33764/2411-1759-2020-25-3-201-213.

38 Тарасов, А. В. Современные технологии автоматического картографирования облачности / А. В. Тарасов. – Текст : непосредственный // Интерэкспо ГЕО-Си-

бирь. XVI Междунар. науч. конгр., 18 июня – 8 июля 2020 г., Новосибирск : сб. материалов в 8 т. Т. 1 : Национальная науч. конф. с междунар. участием «Геодезия, геоинформатика, картография, маркшейдерия». – Новосибирск : СГУГиТ, 2020. № 2. – С. 55–61.

39 Управления и подведомственные организации Рослесхоза. – URL: <http://rosleshoz.gov.ru/agency/central>. – Текст : электронный.

40 Чупина, Д. А. Геоинформационное картографирование форм и типов рельефа на основе морфометрического анализа/ Д. А. Чупина, И. Д. Зольников. – Текст : непосредственный // Геодезия и картография. – 2016. – № 6. – С. 35–43.

41 Чупина, Д. А. ГИС-картографирование морфокомплексов Чуйской котловины на основе морфометрических характеристик/ Д. А. Чупина, В. А. Лямина, И. Д. Зольников. – Текст : непосредственный // Геология и минерально-сырьевые ресурсы Сибири. – 2012. – № 2. – С. 96–103.

42 Шихов, А. Н. Анализ случаев возникновения смерчей в лесной зоне Европейской части России по данным дистанционного зондирования Земли / А. Н. Шихов, А. В. Тарасов. – Текст : непосредственный // Материалы III Международной научной конференции «Региональные проблемы дистанционного зондирования Земли». – Красноярск, 2016. – С. 246–249.

43 Шихов, А. Н. Идентификация случаев возникновения смерчей в лесной зоне по многолетним рядам данных дистанционного зондирования Земли / А. Н. Шихов, А. В. Тарасов. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2016. – Т. 13, № 8 – С. 84–94. – doi: 10.21046/2070-7401-2016-13-3-84-94.

44 A machine learning approach to map tropical selective logging / M. G. Hethcoat, D. P. Edwards, J. M. B. Carreiras, R. G. Bryant, F. M. França, S. Quegan. – Текст : непосредственный // Remote Sensing of Environment. – 2019. – Vol. 221. – P. 569–582.

45 A survey on deep transfer learning. In International conference on artificial neural networks / C. Tan, F. Sun, T. Kong, W. Zhang, C. Yang, C. Liu. – Текст : непосредственный. – Springer, Cham. – 2018 Oct 4. – P. 270–279.

46 Agarap, A. F. Deep learning using rectified linear units (relu). arXiv preprint arXiv:1803.08375 / A. F. Agarap. – 2008. – Текст : непосредственный.

47 Airborne laser scanning based forest inventory: Comparison of experimental results for the Perm region, Russia and prior results from Finland / Т. Kauranne, S. Pyankov, V. Junntila, A. Tarasov [and others]. – Текст : непосредственный // Forests. – 2017. – Vol. 8, № 3. – P. 1–20. – doi: 10.3390/f8030072.

48 Allen, T. R. Spectral response and spatial pattern of Fraser fir mortality and regeneration, Great Smoky Mountains, USA / Т. R. Allen, J. A. Kupfer. – Текст : непосредственный // Plant Ecology. – 2001. – Vol. 156. – P. 59–74.

49 Aurelien, Geron. Прикладное машинное обучение с помощью scikit-learn и tensorflow / Geron Aurelien. – Диалектика, 2018. – Текст : непосредственный.

50 Baetens, L. Validation of Copernicus Sentinel-2 Cloud Masks Obtained from MAJA, Sen2Cor, and FMask Processors Using Reference Cloud Masks Generated with a Supervised Active Learning Procedure. Remote Sens / L. Baetens C. Desjardins, O. Hagolle. – Текст : непосредственный. – 2019. – 11. – 433.

51 Banko, M. Scaling to Very Very Large Corpora for Natural Language Disambiguation / M. Banko, E. Brill. – Текст : непосредственный // Proceedings of the 39th Annual Meeting of the Association for Computational Linguistics. – Toulouse, France. 2001. – P. 26–33.

52 Breiman, L. Random forests. Machine learning. / L. Breiman. – 2001. – Oct;45(1):5–32. – Текст : непосредственный.

53 Brief: Binary robust independent elementary features / M. Calonder, V. Lepetit, C. Strecha, P. Fua. – Текст : непосредственный. – Proc. ECCV. – 2010. – P. 778–792.

54 Change detection of deforestation in the brazilian amazon using landsat data and convolutional neural networks / P. P. Bem de, O. A. de Carvalho Jr., R. F. Guimarães, R. A. T. Gomes. – Текст : непосредственный // Remote Sensing. – 2020. – V. 12(6). – Art. No. 901. – doi: 10.3390/rs12060901.

55 Clouds Classification from Sentinel-2 Imagery with Deep Residual Learning and Semantic Image Segmentation / C. C. Liu, Y. C. Zhang, P. Y. Chen, C. C. Lai,

Y. H. Chen, J. H. Cheng, M. H. Ko. – Текст : непосредственный // Remote Sens. – 2019. – 11. – 119.

56 Cocke, A. E. Comparison of burn severity assessments using Differenced Normalized Burn Ratio and ground data / A. E. Cocke, P. Z. Fulé, J. E. Crouse. – Текст : непосредственный // International Journal of Wildland Fire. – 2005. – Vol. 14(2). – P. 189–198.

57 COCO and Pascal VOC data format for Object. – URL: <https://towardsdatascience.com/coco-data-format-for-object-detection-a4c5eaf518c5>. – Текст : электронный.

58 Comparison of different convolutional neural network architectures for satellite image segmentation / V. Khryashchev, L. Ivanovisky, V. Pavlov, A. Rubtsov, A. Ostrovskaya. – Текст : непосредственный // Proceeding of the 23rd conference of fruct association. – Jyväskylä, Finland, 2018. – P. 172–180.

59 Computer analysis of multitemporal Landsat data for mapping of land use, forest clearcuts and mires - methodological studies / L. Wastenson, W. Arnberg, L. Boresjo, M. Ihse. – Текст : непосредственный // Geographiska Annaler, Series A. – 1981. – Vol. 63 (3-4). – P. 325–337.

60 Congedo, L. Semi-automatic classification plugin for QGIS / L. Congedo – Sapienza Univ, 2013. – P. 1–25. – Текст : непосредственный.

61 Copernicus Open Access Hub. – URL: <https://scihub.copernicus.eu/dhus/#/home>. – Текст : электронный.

62 Coppin, P. R. Processing of multi-temporal Landsat TM imagery to optimize extraction of forest cover change features / P. R. Coppin, M. E. Bauer. – Текст : электронный // IEEE Transactions on Geoscience and Remote Sensing. – 1994. – Vol. 32. – P. 918–927.

63 Crist, E. P. Vegetation and soils information contained in transformed Thematic Mapper data / E. P. Crist, R. Laurin, R. C. Cicone. – Текст : непосредственный // Proceedings of International Geosciences and Remote Sensing Symposium (IGARSS) – Paris, France. 1986. – P. 1465–1470.

64 Dagobert, T. M. Visibility Detection in Time Series of Planetscope Images / T. M. Dagobert, J. Morel, C. D. Franchis, R. G. Von Gioi. – Текст : непосредственный // International Geoscience and Remote Sensing Symposium (IGARSS). – Yokohama, 2019. – P. 1673–1676.

65 Deep learning based cloud detection for medium and high resolution remote sensing images of different sensors / Z. Li, H. Shen, Q. Cheng, Y. Liu, S. You, Z. He. – Текст : непосредственный // ISPRS Journal of Photogrammetry and Remote Sensing. – 2019. – V. 150. – P. 197–212. – doi: 10.1016/j.isprsjprs.2019.02.017.

66 Deep learning for multi-modal classification of cloud, shadow and land cover scenes in PlanetScope and Sentinel-2 imagery / Y. Shendryk, Y. Rist, C. Ticehurst, P. Thorburn. – Текст : непосредственный // ISPRS Journal of Photogrammetry and Remote Sensing. – 2019. – Vol. 157. – P. 124–136.

67 Deep Learning for Regular Change Detection in Ukrainian Forest Ecosystem with Sentinel-2 / K. Isaienkov, M. Yushchuk, V. Khramtsov, O. Seliverstov. – Текст : непосредственный // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. – 2021. – V. 14. – P. 364–376.

68 Deep residual learning for image recognition / K. He, X. Zhang, S. Ren, J. Sun. – Текст : непосредственный. – In Proceedings of the IEEE conference on computer vision and pattern recognition. – 2016. – P. 770–778.

69 Deep residual learning for image recognition Paper Presented / K. He, X. Zhang, S. Ren, J. Sun. – Текст : непосредственный // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. – 2016.

70 Denison, D. G. A bayesian cart algorithm / D. G. Denison, B. K. Mallick, A. F. Smith. – Текст : непосредственный // Biometrika. – 1998. – 85(2). – P. 363–377.

71 Densely connected convolutional networks Paper Presented at the CVPR / G. Huang, Z. Liu, L. Van Der Maaten, K. Q. Weinberger. – 2017. – Текст : непосредственный.

72 Dice, L. R. Measures of the amount of ecologic association between species / L. R. Dice. – Текст : непосредственный // Ecology. – 1945. – V. 26. – P. 297–302.

- 73 Docker. – URL: <https://www.docker.com/>. – Текст : электронный.
- 74 Dorfman, R. 1979. A formula for the Gini coefficient / R. Dorfman. – Текст : непосредственный // The review of economics and statistics. – 1979. – P. 146–149.
- 75 Dropout: A Simple Way to Prevent Neural Networks from Overfitting / N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, R. Salakhutdinov. – Текст : непосредственный // Journal of Machine Learning Research. – 2014. – V. 15. – Art. No. 56. – P. 1929–1958.
- 76 EarthExplorer. – URL: <https://earthexplorer.usgs.gov/>. – Текст : электронный.
- 77 Eastern Europe's forest cover dynamics from 1985 to 2012 quantified from the full Landsat archive / P. V. Potapov, S. A. Turubanova, A. Tyukavina, A. M. Krylov, J. L. McCarty, V. C. Radeloff, M. C. Hansen. – Текст : непосредственный // Remote Sensing of Environment. – 2015. – Vol. 159. – P. 28–43.
- 78 Evaluation of the potential of convolutional neural networks and random forests for multi-class segmentation of Sentinel-2 imagery / V. Syrris, P. Hasenohr, B. Delipetrev, A. Kotsev, P. Kempeneers, P. Soille. – Текст : непосредственный // Remote Sensing. – 2019. – Vol. 11(8). – Art. No. 907.
- 79 Fast Cloud Segmentation Using Convolutional Neural Networks / J. Dröner, N. Korfhage, S. Egli, M. Mühlhling, B. Thies, J. Bendix, B. Freisleben, B. Seeger. – Текст : непосредственный // Remote Sens. – 2018. – 10. – 1782.
- 80 Feng, Z. Patch-based fully convolutional neural network with skip connections for retinal blood vessel segmentation / Z. Feng, J. Yang, L. Yao. – Текст : непосредственный // IEEE International Conference on Image Processing (ICIP). – 2017.
- 81 Flask library. – URL: <https://flask.palletsprojects.com/en/1.1.x/>. – Текст : электронный.
- 82 Freund, Y. A decision-theoretic generalization of on-line learning and an application to boosting / Y. Freund, R. E. Schapire. – Текст : непосредственный // Journal of computer and system sciences. – 1997. – Aug 1. – 55(1):119–39.
- 83 GDAL Library. – URL: <https://gdal.org/>. – Текст : электронный.

84 Generative adversarial nets. *Advances in neural information processing systems* / I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, Y. Bengio. – 2014. – 27. – Текст : непосредственный.

85 Goodfellow, I. *Deep learning* / I. Goodfellow, Y. Bengio, A. Courville. – MIT Press, 2016. – Текст : непосредственный.

86 Google's Neural Machine Translation System: Bridging the Gap between Human and Machine Translation / Yonghui Wu and Mike Schuster and Zhifeng Chen and Quoc V. Le and Mohammad Norouzi and Wolfgang Macherey and Maxim Krikun and Yuan Cao and Qin Gao and Klaus Macherey and Jeff Klingner and Apurva Shah and Melvin Johnson and Xiaobing Liu and Łukasz Kaiser and Stephan Gouws and Yoshikiyo Kato and Taku Kudo and Hideto Kazawa and Keith Stevens and George Kurian and Nishant Patil and Wei Wang and Cliff Young and Jason Smith and Jason Riesa and Alex Rudnick and Oriol Vinyals and Greg Corrado and Macduff Hughes and Jeffrey Dean. – Текст : электронный. – 2016. – URL: <http://arxiv.org/abs/1609.08144>.

87 Gursky, J. Boosting Showdown: Scikit-Learn vs XGBoost vs LightGBM vs CatBoost in Sentiment Classification / J. Gursky. – URL: <https://towardsdatascience.com/boosting-showdown-scikit-learn-vs-xgboost-vs-lightgbm-vs-catboost-in-sentiment-classification-f7c7f46fd956> (дата обращения 20.07.2020). – Текст : электронный.

88 Hardisky, M. A. The influence of soil salinity, growth form and leaf moisture on the spectral radiance of *Spartina alterniflora* canopies / M. A. Hardisky, V. Klemas, R. M. Smart. – Текст : непосредственный // *Photogrammetric engineering and remote sensing*. – 1983. – Vol. 49, № 1. – P. 77–83.

89 High-Resolution Global Maps of 21st-Century Forest Cover Change / M. C. Hansen, P. V. Potapov, R. Moore, M. Hancher, S. A. Turubanova, A. Tyukavina, D. Thau, S. V. Stehman, S. J. Goetz, T. R. Loveland, A. Kommareddy, A. Egorov, L. Chini, C. O. Justice, J. R. G. Townshend. – Текст : непосредственный // *Science*. – 2013. – Vol. 342. – P. 850–853.

90 Hoerl, E. Ridge Regression: Biased Estimation for Nonorthogonal Problems / E. Hoerl, W. R. Kennard. – Текст : непосредственный // *Technometrics*. – 1970. – V. 12. – P. 55–67.

91 Huo, L.-Z. Object-based classification of forest disturbance types in the conterminous United States / L.-Z. Huo, L. Boschetti, A. M. Sparks. – Текст : непосредственный // *Remote Sensing*. – 2019. – Vol. 11(5). – Art. No. 477.

92 Hyperspectral image classification based on superpixel pooling convolutional neural network with transfer learning / Xie F., Gao Q., Jin C., Zhao F. – Текст : непосредственный // *Remote Sensing*. – 2021. – V. 13 (5). – P. 1–17.

93 Image fusion-based land cover change detection using multi-temporal high-resolution satellite images / B. Wang, Choi, S. Choi, S. Lee, P. Wu, Y. Gao. – Текст : непосредственный // *MDPI*, 2017.

94 ImageNet Dataset. – URL: <https://www.image-net.org>. – Текст : электронный.

95 Integrating GIS and remotely sensed data for mapping forest disturbance and change / J. Rogan, J. Miller, M. A. Wulder, S. E. Franklin. – Текст : непосредственный // *Understanding forest disturbance and spatial pattern: Remote sensing and GIS approaches*. – 2006 – Jul 27:133–72.

96 Krizhevsky, A. ImageNet Classification with Deep Convolutional Neural Networks / A. Krizhevsky, I. Sutskever, E. G. Hinton. – Текст : непосредственный // *Proceedings of the 25th International Conference on Neural Information Processing Systems (issue 25)*. – New York, United States. – 2012. – P. 1097–1105.

97 Landsat remote sensing of forest windfall disturbance / M. Baumann, M. Ozdogan, P. T. Wolter, A. M. Krylov, N. A. Vladimirova, V. C. Radeloff. – Текст : непосредственный // *Remote Sensing of Environment*. – 2014. – Vol. 143. – P. 171–179.

98 Larabi, M. Convolutional neural network features based change detection in satellite images / M. Larabi, Q. Liu, Y. Wang. – Текст : непосредственный // *Proceedings of the 1st International Workshop Pattern Recognition*. – 2016. – Art. no. 100110W.

99 Leaflet is an open-source JavaScript library for mobile-friendly interactive maps. – URL: <https://leafletjs.com/>. – Текст : электронный.

100 LightGBM: A Highly Efficient Gradient Boosting Decision Tree / K. Guolin, M. Qi, T. Finley, T. Wang, W. Chen, M. Weidong, Y. Qiwei, L. Tie-Yan. – Текст : непосредственный // *Proceeding of 31st Annual Conference on Neural Information Processing Systems (NIPS 2017)*. – California, United States. – 2017. – P. 3149–3157.

101 MACCS-ATCOR joint algorithm (MAJA). 1000107. 10.1117/12.2240935 / Lonjou Vincent Desjardins, Camille Hagolle, Olivier Petrucci, Beatrice Tremas, Thierry Dejus, Michel Makarau, Aliaksei Auer, Stefan. – 2016. – Текст : непосредственный.

102 Maximizing forest value through using Sentinel-2 in combination with hyperspectral UAVs / C. Aas, A. Jochemsen, V. Mantas, N. Lewyckyj, M. Jozefiak, M. Buchhorn. – Текст : непосредственный // *Proceedings of the 69th International Astronautical Congress*. – Bremen, Germany, 2018. – P. 4492–4498.

103 Mayer, B. Technical note: The libRadtran software package for radiative transfer calculations description and examples of use / B. Mayer, A. Kylling. – Текст : непосредственный // *Atmos. Chem. Phys.* – 2005. – 5(7). – 1855–1877.

104 Methods for Mapping Forest Disturbance and Degradation from Optical Earth Observation Data: a Review / M. Hirschmugl, H. Gallaun, M. Dees, P. Datta, J. Deutscher, N. Koutsias, M. Schardt. – Текст : непосредственный // *Current Forestry Reports*. – 2017. – Vol. 3(1). – P. 32–45.

105 Middleton, S. E. Real-time crisis mapping of natural disasters using social media / S. E. Middleton, L. Middleton, S. Modafferi. – Текст : непосредственный // *IEEE Intelligent Systems*. – 2013. – Dec 23;29(2):9–17.

106 Mitchell, T. M. Machine learning / T. M. Mitchell. – 1997. – New York: McGraw–Hill. – Текст : непосредственный.

107 Modelling natural disturbances in forest ecosystems: A review / R. Seidl, P. M. Fernandes, T. F. Fonseca, F. Gillet, A. M. Jönsson, K. Merganičová, S. Netherer, A. Arpacı, J.-D. Bontemps, H. Bugmann, JR. González-Olabarria, P. Lasch, C. Meredieu, F. Moreira, M.-J. Schelhaas, F. Mohren. – Текст : непосредственный // *Ecological Modelling*. – 2011. – Vol. 222 (4). – P. 903–924.

108 Mou, L. Learning spectral-temporal features via a recurrent convolutional neural network for change detection in multispectral imagery / L. Mou, L. Bruzzone, X. X. Zhu. – Текст : непосредственный // IEEE Transactions on Geoscience and Remote Sensing. – 2019. – V. 57(2). – P. 924–935.

109 Multimodal Ground-Based Cloud Classification Using Joint Fusion Convolutional Neural Network / S. Liu, M. Li, Z. Zhang, B. Xiao, X. Cao. – Текст : непосредственный // Remote Sens. – 2018. – 10. – 822.

110 Multimodal Unsupervised Image-to-Image Translation / Huang Xun, Ming-Yu Liu, Serge Belongie, Jan Kautz. – Текст : непосредственный // ECCV, 2018.

111 Multi-type forest change detection using bfast and monthly Landsat time series for monitoring spatiotemporal dynamics of forests in subtropical wetland / Wu L, Li Z, Liu X, Zhu L, Tang Y, Zhang B, Xu B, Liu M, Meng Y, Liu B. – Текст : непосредственный // Remote Sensing. – 2020. – Vol. 12 (2). – Art. no. 341. – doi: 10.3390/rs12020341.

112 Nielsen, A. A. Multivariate alteration detection (MAD) and MAF postprocessing in multispectral, bitemporal image data: New approaches to change detection studies / A. A. Nielsen, K. Conradsen, J. J. Simpson. – Текст : непосредственный // Remote Sensing of Environment. – 1998. – Vol. 64 (1). – P. 1–9.

113 PEPS – Operating platform Sentinel products (CNES). – URL: <https://peps.cnes.fr/rocket/#/home>. – Текст : электронный.

114 Planet Explorer. – URL: <https://www.planet.com/explorer>. – Текст : электронный.

115 Planet products Specification. – URL: https://assets.planet.com/docs/Planet_Combined_Imagery_Product_Specs_letter_screen.pdf. – Текст : электронный.

116 Planet: Understanding the Amazon from Space. – 2017. – URL: <https://www.kaggle.com/c/planet-understanding-the-amazon-from-space>. – Текст : электронный.

117 Post-hurricane forest damage assessment using satellite remote sensing / W. Wang, J. J. Qu, X. Hao, Y. Liu, J. A. Stanturf. – Текст : непосредственный // Agricultural and Forest Meteorology. – 2010. – Vol. 150. – P. 122–132.

118 Qiu, S. Fmask 4.0: Improved cloud and cloud shadow detection in Landsats 4-8 and Sentinel-2 imagery / S. Qiu, Z. Zhu, H. Binbin. – Текст : электронный // Remote Sensing of Environment. – 2019. – Vol (231).

119 Ready-to-Use Methods for the Detection of Clouds, Cirrus, Snow, Shadow, Water and Clear Sky Pixels in Sentinel-2 MSI Images / A. Hollstein, K. Segl, L. Guanter, M. Brell, M. Enesco. – Текст : непосредственный // Remote Sens. – 2016. – 8. – 666.

120 Redmon, J. YOLO9000: better, faster, stronger. / J. Redmon, A. Farhadi. – Текст : непосредственный // Proceedings of the IEEE conference on computer vision and pattern recognition. – 2017. – P. 7263–7271.

121 Remote sensing estimates of stand-replacement fires in Russia 2002–2011 / A. Krylov, J. L. McCarty, P. Potapov, T. Loboda, A. Tyukavina, S. Turubanova, M. C. Hansen. – Текст : непосредственный // Environmental Research Letters. – 2014. – Vol. 9 (10). – Art. No. 105007.

122 Rest API Tutorial. – URL: <https://restfulapi.net/>. – Текст : электронный.

123 Retrieving real-time co-seismic displacements using GPS/GLONASS: a preliminary report from the September 2015 M w 8.3 Illapel earthquake in Chile / K. Chen, M. Ge, A. Babeyko, X. Li, F. Diao, R. Tu. – Текст : непосредственный. – Geophysical Journal International. – 2016. – Aug 1 ; 206(2):941-53.

124 Richter, R. An automatic atmospheric correction algorithm for visible/NIR imagery / R. Richter, D. Schlapfer, A. Muller. – Текст : непосредственный // International Journal of Remote Sensing. – 2006. – 27(9–10), 2077–2085.

125 Ronneberger, O. U-Net: Convolutional networks for biomedical image segmentation. / O. Ronneberger, P. Fischer, T. Brox. – Текст : непосредственный. – 2015. – arXiv:1505.04597.

126 Rosenblatt, F. The perceptron: A probabilistic model for information storage and organization in the brain / F. Rosenblatt. – Текст : непосредственный // Psychol. Rev. – 1958. – Vol. 65. – P. 386–408.

127 Russakovsky, O. ImageNet large-scale visual recognition challenge / O. Russakovsky, J. Deng, H. Su. – 2010–2015. – Текст : непосредственный.

128 Samuel, A. L. Some Studies in Machine Learning Using the Game of Checkers / A. L. Samuel. – Текст : непосредственный // IBM JOURNAL. – 1959. – Vol. 3, Issue 3. – P. 210–229.

129 Sayn-Wittgenstein, L. Landsat application in Canadian forestry / Sayn- L. Wittgenstein, J. M. Wightman. – Текст : непосредственный // Proceeding of the 10th International Symposium on Remote Sensing of Environment. – Michigan, United States, 1975. – Vol. 2. – P. 1209–1218.

130 Scanex Image Processor v.5.1. Программа обработки данных дистанционного зондирования Земли. Руководство пользователя. – Москва, 2018. – 379 с. – Текст : непосредственный.

131 Scharvogel, D. Deep Learning Approach for Calamity Assessment Using Sentinel-2 Data / D. Scharvogel, M. Brandmeier, M. A. Weis. – Текст : непосредственный // Forests. – 2020. – V. 11. – DOI:10.3390/f11121239.

132 Schwertz, E. Near real-time mapping of the 1975 mississippi river flood in louisiana using landsat imagery1 / E. Schwertz, B. Spicer, H. Svehlak. – Текст : непосредственный // JAWRA Journal of the American Water Resources Association. – Vol. 13. – P. 107–115. – doi:10.1111/j.1752-1688.1977.tb01994.x.

133 Semi-Automatic Classification Plugin for QGIS. – URL: <http://www.planning4adaptation.eu>. – Текст : электронный.

134 Sen2Cor for Sentinel-2, Proc. SPIE 10427 / M. Main-Knorn, B. Pflug, J. Louis, V. Debaecker, U. Müller-Wilm, F. Gascon. – Текст : непосредственный // Image and Signal Processing for Remote Sensing XXIII, 1042704, 2017.

135 Sentinel – 2 product specification. <https://sentinel.esa.int/documents/247904/685211/Sentinel-2-Products-Specification-Document>. – Текст : электронный.

136 Sentinel-2 classification app. – URL: <https://apps.sentinel-hub.com/classificationApp-trial>. – Текст : электронный.

137 Sentinel-2 processing-levels. – URL: <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/processing-levels>. – Текст : электронный.

138 Silvisense. – URL: <https://silvisense.com/>. – Текст : электронный.

139 Simonyan, K. Very deep convolutional networks for large-scale image recognition / K. Simonyan, A. Zissermanar. – Текст : непосредственный. –Xiv preprint arXiv:1409.1556. – 2014.

140 Sub-weekly detection of deforestation with planet data. – URL: <https://medium.com/planet-stories/sub-weekly-detection-of-deforestation-with-planet-data-7699553b3926>. – Текст : электронный.

141 TensorFlow. – URL: <https://www.tensorflow.org/>. – Текст : электронный.

142 Towards real-time building damage mapping with low-cost UAV solutions / F. Nex, D. Duarte, A. Steenbeek, N. Kerle. – Текст : непосредственный // Remote sensing. – 2019. – Jan. – 11(3):287.

143 Understanding batch normalization. arXiv preprint arXiv:1806.02375 / J. Bjorck, C. Gomes, B. Selman, K. Q. Weinberger. – 2018. – Текст : непосредственный.

144 VUE js. – URL: <https://vuejs.org>. – Текст : электронный.

145 Wang, F. Comparison of remote sensing change detection techniques for assessing hurricane damage to forests / F. Wang, Y. J. Xu. – Текст : непосредственный // Environmental Monitoring and Assessment. – 2010. – Vol. 162. – P. 311–326.

146 Wieland, M. Multi-sensor cloud and cloud shadow segmentation with a convolutional neural network / M. Wieland, Y. Li, S. Martinis. – Текст : непосредственный // Remote Sensing. – 2019. – Vol. 230. – Art. No. 111203.

147 Williams, D. L. Monitoring gypsy moth defoliation by applying change detection techniques to Landsat imagery / D. L. Williams, M. L. Stauffer. – Текст : непосредственный // Proceedings of symposium on Remote Sensing for Vegetation Damage Assessment. – Seattle, United States. – 1978. – P. 221–229.

148 YOLO: Real-Time object detection. –URL: <https://pjreddie.com/darknet/yolo/>. – Текст : электронный.

149 Zhe, Z. Object-based cloud and cloud shadow detection in Landsat imagery / Z. Zhe, E. W. Curtis. – Текст : непосредственный // Remote Sensing of Environment. – 2012. – Vol (118). – P. 83–94.

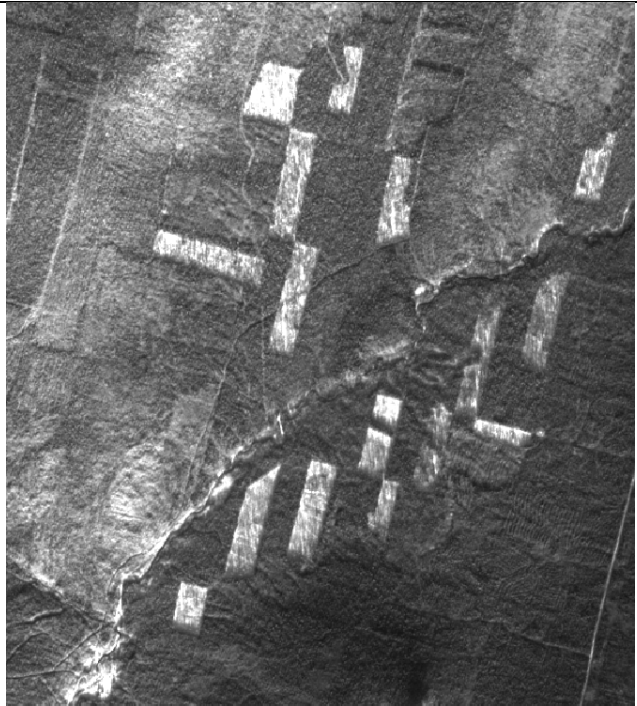
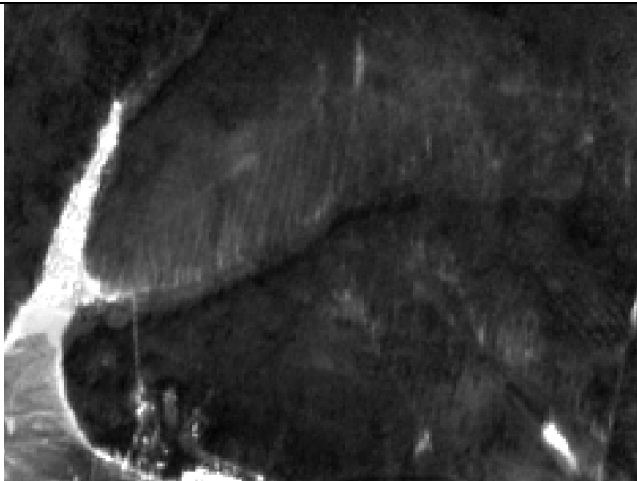
150 Zupanc, A. Improving Cloud Detection with Machine Learning / A. Zupanc. – 2019. – URL: <https://medium.com/sentinel-hub/improving-cloud-detection-with-machine-learning-c09dc5d7cf13>. – Текст : электронный.

ПРИЛОЖЕНИЕ А

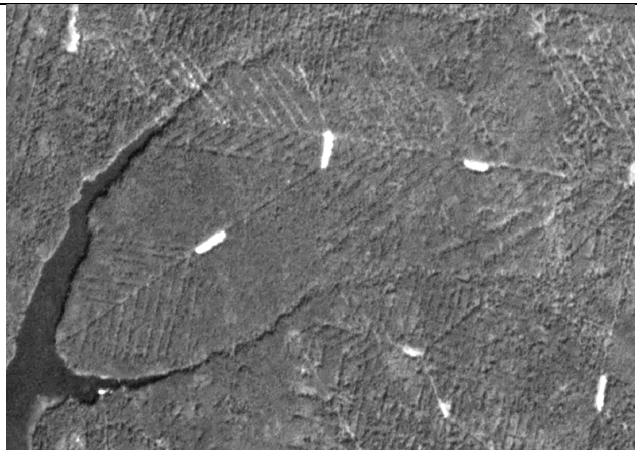
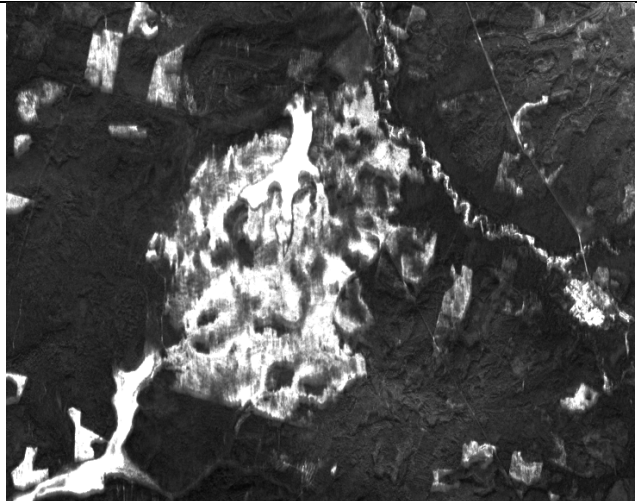
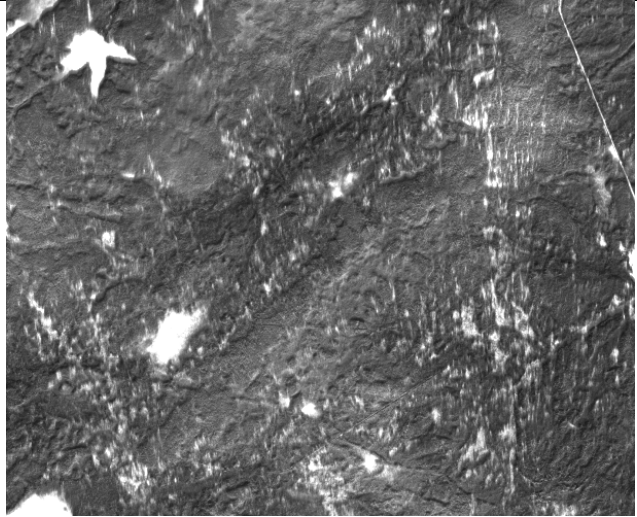
(обязательное)

ДЕШИФРОВОЧНЫЕ ПРИЗНАКИ НАРУШЕНИЙ ЛЕСНОГО ПОКРОВА

Таблица А.1

Вид нарушения	Характеристика снимка	Изображение на снимке
1	2	3
Сплошная рубка	Снимок Sentinel-2 20 ноября 2019 г., канал В4, разрешение 10 м/пиксель, масштаб, 1 : 40 000	
Выборочная рубка	Снимок Sentinel-2 20 ноября 2019 г., канал В4, разрешение 10 м/пиксель, масштаб 1 : 15 000	

Окончание таблицы А.1

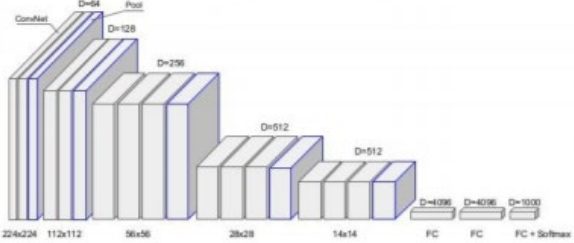
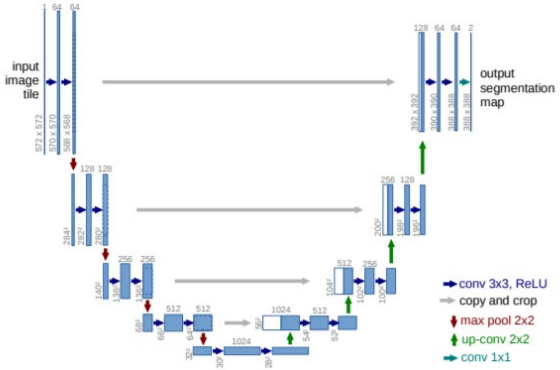
1	2	3
	Снимок PlanetScore-2 29 июня 2018 г., канал Red, разрешение 3 м/пиксель, масштаб 1 : 15 000	
Гарь	Снимок Sentinel-2 20 ноября 2019 г., канал В4, разрешение 10 м/пиксель, масштаб 1 : 60 000	
Ветровал	Снимок Sentinel-2 20 ноября 2019 г., канал В4, разрешение 10 м/пиксель, масштаб 1 : 80 000	

ПРИЛОЖЕНИЕ Б

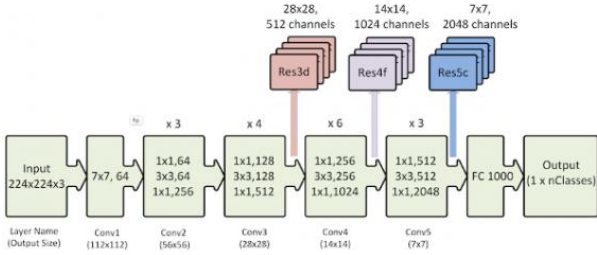
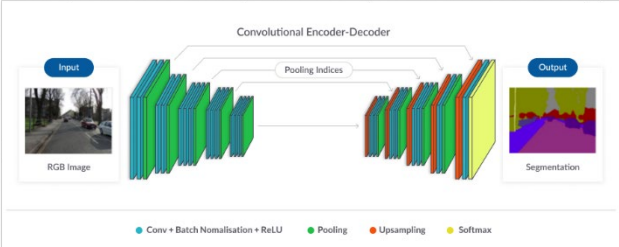
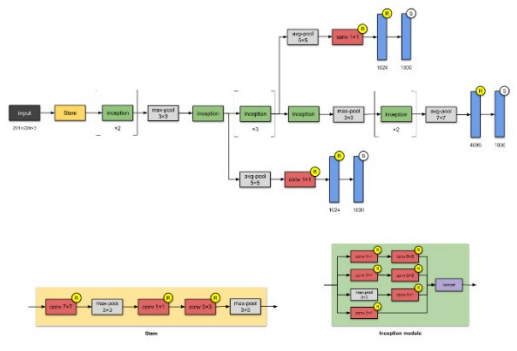
(обязательное)

СРАВНЕНИЕ ОСНОВНЫХ АРХИТЕКТУР СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

Таблица Б.1

Название архитектуры	Схема архитектуры	Автор/создатель, год создания	Количество параметров для обучения
1	2	3	4
VGGNet		Visual Geometry Group (2014)	≈138 млн
U-net		Olaf Ronneberger, Philipp Fischer, Thomas Brox (2015)	≈ 0,5 млн

Окончание таблицы Б.1

1	2	3	4
ResNet	 <p>The diagram illustrates the ResNet architecture. It starts with an input of size 224x224x3. The layers are: Conv1 (7x7, 64), Conv2 (3x3, 64), Conv3 (3x3, 128), Conv4 (3x3, 256), and Conv5 (3x3, 512). There are three residual blocks of type 'x3', four of type 'x4', six of type 'x6', and three of type 'x3'. The residual blocks are Res3d (28x28, 512 channels), Res4f (14x14, 1024 channels), and Res5c (7x7, 2048 channels). The final layer is FC 1000, leading to an output of 1 x nClasses.</p>	Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun (2015)	≈ 40 млн
SegNet	 <p>The diagram shows the SegNet architecture, a Convolutional Encoder-Decoder. It takes an RGB image as input and produces a segmentation map as output. The encoder consists of convolutional layers (blue and green) and pooling layers (green). The decoder consists of upsampling layers (orange) and convolutional layers (blue and green). The final output is a segmentation map. A legend indicates: Conv + Batch Normalisation + ReLU (blue), Pooling (green), Upsampling (orange), and Softmax (yellow).</p>	Alex Kendall, Vijay Badrinarayanan, Roberto Cipolla, University of Cambridge (2015)	≈ 14,7 млн
Inception-v1	 <p>The diagram illustrates the Inception-v1 architecture. It shows a complex network of convolutional and pooling layers. The input is processed through several stages, including convolutional layers (blue and green) and pooling layers (green). The final output is a segmentation map. A legend indicates: Conv + Batch Normalisation + ReLU (blue), Pooling (green), Upsampling (orange), and Softmax (yellow).</p>	Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, Andrew Rabinovich. Google, University of Michigan, University of North Carolina (2015)	≈ 5 млн

ПРИЛОЖЕНИЕ Г

(обязательное)

РАСПРЕДЕЛЕНИЕ ВЫБОРКИ ПО ГРУППАМ ИЗМЕНЕНИЙ

Таблица Г.1

ID пары снимков	Номер тайла	Дата первого снимка	Дата второго снимка	Количество тайлов, созданных из пары снимков	Разница, дней	Группа изменений
1	2	3	4	5	6	7
0	T39VVJ	27.02.2017	18.05.2017	35	80	переходный
1	T39VVJ	18.05.2017	17.07.2017	11	60	лето
2	T39VVJ	17.07.2017	16.08.2017	7	30	лето
3	T39VVJ	16.08.2017	05.09.2017	11	20	лето
4	T39VVJ	05.09.2017	22.02.2018	126	170	переходный
5	T39VWH	24.02.2018	11.03.2018	16	15	зима
6	T39VWH	11.03.2018	30.04.2018	30	50	зима
7	T39VWH	05.05.2018	29.06.2018	16	55	переходный
8	T39VWH	24.07.2018	31.08.2018	20	38	лето
9	T39VWH	02.09.2018	09.11.2018	42	68	переходный
10	T39VWH	20.01.2019	04.02.2019	7	15	зима
11	T39VWH	29.06.2018	24.07.2018	17	25	лето
12	T39VWH	31.08.2018	02.09.2018	7	2	лето
13	T39VWH	09.11.2018	20.01.2019	55	72	переходный
14	T39VWJ	05.09.2017	12.10.2017	1	37	лето
15	T39VWJ	27.02.2018	31.03.2018	7	32	зима
16	T39VWJ	31.03.2018	30.04.2018	19	30	зима
17	T39VWJ	30.04.2018	29.06.2018	8	60	переходный

Продолжение таблицы Г.1

1	2	3	4	5	6	7
18	T39VWJ	24.07.2018	31.08.2018	5	38	лето
19	T39VWJ	12.10.2017	25.01.2018	17	105	переходный
20	T39VWJ	25.01.2018	27.02.2018	16	33	зима
21	T39VWJ	29.06.2018	24.07.2018	28	25	лето
22	T39VWJ	31.08.2018	22.09.2018	17	22	лето
23	T39VXH	02.09.2017	12.10.2017	8	40	лето
24	T39VXH	01.02.2018	26.02.2018	1	25	зима
25	T39VXH	26.02.2018	07.04.2018	1	40	зима
26	T39VXH	02.05.2018	29.06.2018	32	58	переходный
27	T39VXH	30.08.2018	24.09.2018	19	25	лето
28	T39VXH	12.10.2017	01.02.2018	34	112	переходный
29	T39VXH	29.06.2018	24.07.2018	12	25	лето
30	T39VXH	24.07.2018	30.08.2018	12	37	лето
31	T39VXJ	25.01.2018	26.02.2018	33	32	зима
32	T39VXJ	26.02.2018	28.03.2018	42	30	зима
33	T39VXJ	12.05.2018	29.06.2018	2	48	переходный
34	T39VXJ	12.10.2017	25.01.2018	66	105	переходный
35	T39VXJ	28.03.2018	25.04.2018	17	28	зима
36	T39VXJ	25.04.2018	12.05.2018	1	17	переходный
37	T39VXJ	29.06.2018	31.07.2018	13	32	лето
38	T40VDJ	06.01.2018	12.03.2018	19	65	зима
39	T40VDJ	12.03.2018	11.05.2018	8	60	переходный
40	T40VDJ	11.05.2018	23.07.2018	10	73	лето
41	T40VDJ	23.07.2018	01.09.2018	10	40	лето
42	T40VEM	30.07.2018	01.09.2018	13	33	лето
43	T40VDJ	01.09.2018	29.01.2019	80	150	переходный
44	T40VEK	26.01.2017	17.03.2017	20	50	зима

Окончание таблицы Г.1

1	2	3	4	5	6	7
46	T40VEK	19.04.2017	22.11.2017	40	217	зима
47	T40VEK	06.01.2018	10.02.2018	24	35	зима
48	T40VEK	22.11.2017	06.01.2018	31	45	зима
49	T40VEL	16.05.2018	01.09.2018	128	108	лето
50	T40VEL	01.09.2018	10.11.2018	17	70	переходный
51	T40VEL	28.02.2018	10.03.2018	8	10	зима
52	T40VEL	10.03.2018	26.04.2018	14	47	зима
53	T40VEL	26.04.2018	16.05.2018	12	20	переходный
54	T40VEL	10.11.2018	24.01.2019	14	75	зима
55	T40VEL	24.01.2019	20.02.2019	7	27	зима
56	T40VEM	06.09.2017	25.11.2017	15	80	переходный
57	T40VEM	25.11.2017	13.02.2018	32	80	зима
58	T40VEM	06.04.2018	03.07.2018	9	88	переходный
59	T40VEM	03.07.2018	30.07.2018	7	27	лето
60	T40VEM	13.02.2018	10.03.2018	9	25	зима
61	T40VEM	10.03.2018	06.04.2018	5	27	зима
62	T40VFK	02.02.2018	29.03.2018	36	55	зима
63	T40VFK	23.05.2018	27.06.2018	6	35	лето
64	T40VFK	04.08.2018	05.09.2018	1	32	лето
65	T40VFK	09.11.2018	14.12.2018	13	35	переходный
66	T40VFK	11.01.2018	02.02.2018	10	22	зима
67	T40VFK	06.04.2018	23.05.2018	13	47	переходный
68	T40VFK	27.06.2018	22.07.2018	14	25	лето
69	T40VFK	22.07.2018	04.08.2018	14	13	лето
70	T40VFK	05.09.2018	09.11.2018	39	65	переходный
71	T41VLE	23.05.2018	17.07.2018	8	55	лето
72	T41VLE	04.03.2018	23.05.2018	12	80	переходный
73	T41VLE	17.07.2018	09.11.2018	28	115	переходный

ПРИЛОЖЕНИЕ Д

(обязательное)

КОЛИЧЕСТВО ВЫДЕЛЕННЫХ АЛГОРИТМАМИ ОБЪЕКТОВ ДЛЯ ОДНОГО КОНТРОЛЬНОГО

Таблица Д.1

ID тайла	Диапазон изменений	Группа изменений	Традиционные методы	Алгоритмы машинного обучения с самой высокой точностью			
				Все сезоны	Зимний сезон	Переходный сезон	Летний сезон
1	2	3	4	5	6	7	8
При учете всех объектов, которые пересекаются с контрольным							
T40VEM	2019 – 2020	зима	1,56	1,42	1,15	-	-
T40VEM	2017 – 2018	зима	-	-	-	-	-
T37VFJ	2017 – 2018	переходная	2,72	2,00	-	1,25	-
T38VMP	2017 – 2018	переходная	3,33	1,33	-	1,66	-
T39VWF	2017 – 2018	лето	2,37	1,50	-	-	1,00
T39VXH	2017 – 2018	лето	-	-	-	-	-
T37WFM	2017 – 2018	лето	-	-	-	-	-
T38VPL	2017 – 2018	лето	2,25	1,16	-	-	1,50
При учете всех объектов, центроид которых попадает в контрольный							
T40VEM	2019 – 2020	зима	1,60	1,50	1,15	-	-
T40VEM	2017 – 2018	зима	-	-	-	-	-
T37VFJ	2017 – 2018	переходная	2,46	2,23	-	1,30	-
T38VMP	2017 – 2018	переходная	5,50	1,60	-	2,00	-
T39VWF	2017 – 2018	лето	2,37	1,60	-	-	1,00
T39VXH	2017 – 2018	лето	-	-	-	-	-
T37WFM	2017 – 2018	лето	-	-	-	-	-
T38VPL	2017 – 2018	лето	2,25	1,00	-	-	1,50

Окончание таблицы Д.1



1	2	3	4	5	6	7	8
При учете всех объектов, которые полностью находятся внутри контрольного							
T40VEM	2019 – 2020	зима	1,14	2,00	1,00	-	-
T40VEM	2017 – 2018	зима	-	-	-	-	-
T37VFJ	2017 – 2018	переходная	2,31	2,66	-	1,50	-
T38VMP	2017 – 2018	переходная	9,00	1,66	-	1,50	-
T39VWF	2017 – 2018	лето	2,00	1,50	-	-	-
T39VXH	2017 – 2018	лето	-	-	-	-	-
T37WFM	2017 – 2018	лето	-	-	-	-	-
T38VPL	2017 – 2018	лето	5,00	-	-	-	-

ПРИЛОЖЕНИЕ Е

(обязательное)

БАЗОВАЯ ФОРМА ДЛЯ ФОРМИРОВАНИЯ КАРТЫ С НАРУШЕНИЕМ ЛЕСНОГО ПОКРОВА

Карточка дешифрирования № - 1
Дата дешифрирования 26.04.2021

193	Лесничество -
	Участковое лесничество -
	Урочище/совхоз -
	Квартал № -
	Целевое назначение -
	Кат. защитности Эксплуатационные леса
	Вырубленная площадь 0.0 га
	Тип объекта -
	Примечание -
	Условные обозначения
	 - Квартальная сеть
	 - Граница выявленного объекта

Дата съемки 17-07-2019
Разрешение 10 м/пикс

Масштаб 10 000

Рисунок Е.1 – Пример формы для формирования карты с нарушением лесного покрова

ПРИЛОЖЕНИЕ Ж

(обязательное)

КОЛИЧЕСТВО ВЫЯВЛЕННЫХ И ПРОПУЩЕННЫХ ОБЪЕКТОВ В РАЗРЕЗЕ ЗОН ПРОВЕРКИ

Таблица Ж.1

Дата первого снимка	Дата второго снимка	Зона	Сезон	Количество контрольных объектов	Количество правильно выделенных объектов	Количество пропусков	Количество ложных объектов	Площадь всех контрольных объектов (га)	Площадь правильно выделенных объектов (га)	Площадь пропусков (га)	Площадь ложных объектов (га)	По количеству			По площади			Средняя площадь ложно выделенного объекта (га)	Средняя площадь невыделенного объекта (га)
												Процент правильно выделенных рубок	Процент невыделенных рубок	Процент ложных вырубков	Процент правильно выделенных рубок	Процент невыделенных рубок	Процент ложных вырубков		
2018.01.06	2018.03.12	Кунгур (зона 1)	Зимний	19	16	3	29	162,3	145,5	16,7	7,8	84,2	15,8	152,6	89,7	10,3	4,8	0,3	5,6
2018.03.12	2018.04.06	Кунгур (зона 1)	Переходный	8	6	2	9	27,8	26,1	1,8	0,5	75,0	25,0	112,5	93,6	6,4	1,7	0,1	1,8
2018.05.14	2018.07.23	Кунгур (зона 1)	Летний	17	16	1	9	70,7	67,2	3,5	3,8	94,1	5,9	52,9	95,0	5,0	5,4	0,4	3,5
2018.09.03	2018.12.30	Кунгур (зона 1)	Переходный	39	34	5	53	220,0	191,7	28,3	30,5	87,2	12,8	135,9	87,1	12,9	13,9	1,1	5,7
2018.01.06	2018.03.12	Чусовой (зона 2)	Зимний	28	28	0	41	333,6	333,6	0,0	23,9	100,0	0,0	146,4	100,0	0,0	7,2	0,6	0,0
2018.03.12	2018.05.14	Чусовой (зона 2)	Переходный	31	30	1	25	272,9	261,0	11,8	17,4	96,8	3,2	80,6	95,7	4,3	6,4	0,7	11,8
2018.05.14	2018.09.01	Чусовой (зона 2)	Летний	26	25	1	19	382,7	378,1	4,6	10,6	96,2	3,8	73,1	98,8	1,2	2,8	0,6	4,6
2018.09.01	2019.01.29	Чусовой (зона 2)	Зимний	35	32	3	41	370,6	319,4	51,3	62,5	91,4	8,6	117,1	86,2	13,8	16,9	1,5	17,1
2018.02.21	2018.03.28	Гайны (зона 3)	Зимний	32	30	2	5	283,2	282,4	0,8	2,3	93,8	6,3	15,6	99,7	0,3	0,8	0,5	0,4
2018.03.28	2018.05.02	Гайны (зона 3)	Переходный	25	21	4	19	293,3	258,1	35,2	9,9	84,0	16,0	76,0	88,0	12,0	3,4	0,5	8,8
2018.05.02	2018.08.30	Гайны (зона 3)	Переходный	89	87	2	96	1144,8	1143,8	1,0	115,8	97,8	2,2	107,9	99,9	0,1	10,1	1,2	0,5
2018.08.30	2019.01.20	Гайны (зона 3)	Переходный	54	50	4	111	939,2	867,8	71,4	132,6	92,6	7,4	205,6	92,4	7,6	14,1	1,2	13,4
2018.08.30	2019.02.04	Гайны (зона 3)	Переходный	82	78	4	202	1680,5	1640,6	39,9	222,7	95,1	4,9	246,3	97,6	2,4	13,3	1,1	10,0

ПРИЛОЖЕНИЕ И

(обязательное)

РАЗМЕЩЕНИЕ ТЕРРИТОРИИ ПРОВЕРОЧНЫХ ЗОН




Рисунок И.1 – Границы проверочных зон на территории Пермского края

ПРИЛОЖЕНИЕ К

(обязательное)

СПИСОК ИСПОЛЬЗОВАННЫХ ПРИЗНАКОВ ПРИ ОБУЧЕНИИ МОДЕЛИ

Таблица К.1

Название	Формула
Исходные значения пикселей	
Значение красного канала снимка до изменения	$B4_{OLD}$
Значение красного инфракрасного канала снимка до изменения	$B8_{OLD}$
Значение среднего инфракрасного канала снимка до изменения	$B11_{OLD}$
Значение среднего инфракрасного канала снимка до изменения	$B12_{OLD}$
Значение красного канала снимка после изменения	$B4_{NEW}$
Значение красного инфракрасного канала снимка после изменения	$B8_{NEW}$
Значение среднего инфракрасного канала снимка после изменения	$B11_{NEW}$
Значение среднего инфракрасного канала снимка после изменения	$B12_{NEW}$
Расчетные значения	
Разница красных каналов (1)	$B4_{OLD} - B4_{NEW}$
Разница красных каналов (2)	$B4_{NEW} - B4_{OLD}$
Разница инфракрасных каналов (1)	$B8_{OLD} - B8_{NEW}$
Разница инфракрасных каналов (2)	$B8_{NEW} - B8_{OLD}$
Разница в среднем инфракрасном канале (1)	$B11_{OLD} - B11_{NEW}$
Разница в среднем инфракрасном канале (2)	$B11_{NEW} - B11_{OLD}$
Разница в среднем инфракрасном канале (3)	$B12_{OLD} - B12_{NEW}$
Разница в среднем инфракрасном канале (4)	$B12_{NEW} - B12_{OLD}$
Разница NDVI (1)	$\frac{(B8_{NEW} - B4_{NEW})}{(B8_{NEW} + B4_{NEW})} - \frac{(B8_{OLD} - B4_{OLD})}{(B8_{OLD} + B4_{OLD})}$
Разница NDVI (2)	$\frac{(B8_{OLD} - B4_{OLD})}{(B8_{OLD} + B4_{OLD})} - \frac{(B8_{NEW} - B4_{NEW})}{(B8_{NEW} + B4_{NEW})}$
Разница SWVI (1)	$\frac{(B8_{NEW} - B12_{NEW})}{(B8_{NEW} + B12_{NEW})} - \frac{(B8_{OLD} - B12_{OLD})}{(B8_{OLD} + B12_{OLD})}$
Разница SWVI (2)	$\frac{(B8_{NEW} - B13_{NEW})}{(B8_{NEW} + B13_{NEW})} - \frac{(B8_{OLD} - B13_{OLD})}{(B8_{OLD} + B13_{OLD})}$
Разница SWVI (1)	$\frac{(B8_{OLD} - B12_{OLD})}{(B8_{OLD} + B12_{OLD})} - \frac{(B8_{NEW} - B12_{NEW})}{(B8_{NEW} + B12_{NEW})}$
Разница SWVI (2)	$\frac{(B8_{OLD} - B13_{OLD})}{(B8_{OLD} + B13_{OLD})} + \frac{(B8_{NEW} - B13_{NEW})}{(B8_{NEW} + B13_{NEW})}$

ПРИЛОЖЕНИЕ Л

(обязательное)

СПРАВКА О ВНЕДРЕНИИ В ПРОИЗВОДСТВЕННУЮ ДЕЯТЕЛЬНОСТЬ
РЕЗУЛЬТАТОВ ДИССЕРТАЦИОННОГО ИССЛЕДОВАНИЯГРУППА
ПРЕДПРИЯТИЙ
ПЦБКОбщество с ограниченной ответственностью
«Уралбумага»Бродовский тракт, д. 11, Пермь, 614089
ИНН/КПП 7405005401/590401001
ОГРН 102590051853310.08.2021 № 341
На № _____ от _____Диссертационный совет
Д 212.251.04 СГУГиТг. Новосибирск,
ул. Плеханова, 10

Акт внедрения результатов диссертационной работы.

Результаты диссертационной работы Тарасова Андрея Владимировича, представленной на соискание ученой степени кандидата технических наук по направлению 25.00.33 на тему «Оперативное картографирование нарушений лесного покрова на основе спутниковых данных с высоким пространственно-временным разрешением», используются в работе ООО «Уралбумага» при выполнении оперативного мониторинга ГКУ «Добрянское лесничество» на территории Пермского края в рамках проекта «Умный лес» с целью выявления контуров произошедших изменений.

Заместитель генерального директора



С.П. Смирнова

Исп. Леонтьев А.В.
тел. 89824701888