

ПОВЫШЕНИЕ ТОЧНОСТИ РАСПОЗНАВАНИЯ ПРОСЕК ДЛЯ ЭФФЕКТИВНОГО СПУТНИКОВОГО МОНИТОРИНГА НЕЗАКОННЫХ ВЫРУБОК ЛЕСА

О.И. Соколков^{1, 2}, sokolkovoi@uriit.ru, <https://orcid.org/0009-0006-5869-1395>

¹ Югорский научно-исследовательский институт информационных технологий,
Ханты-Мансийск, Россия

² Югорский государственный университет, Ханты-Мансийск, Россия

Аннотация. Данная работа посвящена проблеме автоматизированного выявления лесных рубок по данным дистанционного зондирования Земли в контексте проведения своевременных мероприятий по защите лесного законодательства. Поскольку визуальное дешифрирование спутниковых снимков характеризуется низкой производительностью ввиду человеческого фактора (утомляемость и снижение концентрации внимания при длительном выполнении монотонной работы), в условиях стремительного развития технологий искусственного интеллекта широкое распространение приобретают автоматизированные системы мониторинга незаконных лесных рубок, основанные на нейросетевых методах. Такие решения, сочетающие возможности человеческого восприятия и потенциал нейронных сетей, обеспечивают высокую точность и оперативность обработки больших объемов спутниковых данных, повышая результативность мер по охране лесного фонда. Несмотря на успешное применение нейросетевых методов в рассматриваемой предметной области, их использование на практике сталкивается с существенными трудностями, обусловленными недостаточной эффективностью распознавания незаконно вырубленных лесных просек, предназначенных для прокладки дорог, линий электропередачи, трубопроводов. Это приводит к невозможности выявления существенной части нарушений лесного законодательства. **Цель исследования:** повышение точности распознавания лесных просек на спутниковых снимках без снижения качества распознавания рубок других типов. **Материалы и методы.** Предложен метод, основанный на ансамблировании нейронных сетей, предусматривающий обучение моделей с использованием модифицированной функции потерь Tversky Loss и агрегацию выходов посредством побитовых операций. Для подтверждения результативности метода проведена серия экспериментов на наборе данных о лесных рубках, осуществленных на территории Ханты-Мансийского автономного округа – Югры за период 2018–2022 гг. Данные представлены размеченными изображениями со спутника Sentinel-2 и охватывают периоды как «бесснежного» сезона рубок (июнь–сентябрь), так и «снежного» (ноябрь–апрель). **Результаты.** Предложенный метод позволил повысить точность распознавания лесных просек по показателю F1-меры на 5,35 % для «бесснежного» сезона и на 6,8 % – для «снежного» сезона без потерь в качестве распознавания других типов вырубок. **Заключение.** Полученные результаты могут послужить основой для дальнейших аналогичных исследований, ориентированных на другие сложные для распознавания типы рубок, в частности, загражденные плотной облачностью, дымкой, облачными теньями.

Ключевые слова: картографирование лесных рубок, компьютерное зрение, глубокое машинное обучение, ансамблирование, семантическая сегментация изображений, дистанционное зондирование Земли, Sentinel-2

Для цитирования: Соколков О.И. Повышение точности распознавания просек для эффективного спутникового мониторинга незаконных вырубок леса // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». 2026. Т. 26, № 1. С. 21–32. DOI: 10.14529/ctcr260102

IMPROVING THE DETECTION ACCURACY OF LINEAR CLEAR-CUTS FOR EFFECTIVE SATELLITE MONITORING OF ILLEGAL FOREST FELLING

O.I. Sokolkov^{1, 2}, sokolkovoi@uriit.ru, <https://orcid.org/0009-0006-5869-1395>

¹ Ugra Research Institute of Information Technologies, Khanty-Mansiysk, Russia

² Yugra State University, Khanty-Mansiysk, Russia

Abstract. This work is devoted to the problem of automated detection of forest fellings based on Earth remote sensing data in the context of timely measures to protect forest legislation. Manual image analysis is inefficient due to human fatigue caused by prolonged monotonous work, leading to increased interest in neural network-based monitoring systems enabled by recent advances in artificial intelligence technology. Such solutions combining human perception capabilities with the potential of neural networks provide high accuracy and speed in processing large volumes of satellite data, thus improving the effectiveness of measures aimed at protecting forest resources. Although neural network methods have been successfully applied in the considered field, their practical implementation encounters substantial challenges stemming from insufficient performance in detecting illegally cleared areas designated for constructing roads, power lines, and pipelines. This makes it impossible to detect a significant portion of forestry law violations. **Aim of the study.** Improving the accuracy of linear forest clear-cuts recognition in satellite images without reducing the quality of recognition of other types of felling. **Materials and methods.** A method is proposed based on neural network ensemble learning, which incorporates a modified Tversky Loss function for model training and applies bitwise aggregation of outputs. Its efficacy was tested through experiments on a dataset of forest logging activities in Khanty-Mansi Autonomous Okrug – Yugra between 2018 and 2022. This dataset includes labeled Sentinel-2 satellite imagery covering both “snowless” (June–September) and “snowy” (November–April) felling seasons. **Results.** Proposed method improved linear forest clear-cuts detection accuracy by 5.35 % for “snowless” season and by 6.8 % for “snowy” season, with no decrease in recognition quality for other clearing types. **Conclusion.** Obtained results provide a foundation for future research targeting hard-to-detect felling activities, especially those concealed by dense clouds, haze, or cloud shadows.

Keywords: forest felling mapping, computer vision, deep learning, ensembling, semantic image segmentation, Earth remote sensing, Sentinel-2

For citation: Sokolkov O.I. Improving the detection accuracy of linear clear-cuts for effective satellite monitoring of illegal forest felling. *Bulletin of the South Ural State University. Ser. Computer Technologies, Automatic Control, Radio Electronics.* 2026;26(1):21–32. (In Russ.) DOI: 10.14529/ctcr260102

Введение

В субъектах Российской Федерации с большой площадью лесного покрова важнейшими направлениями природоохранной деятельности являются систематический мониторинг состояния лесных экосистем и рациональное использование их ресурсов. Особенно актуально усиление мер по защите лесов в Ханты-Мансийском автономном округе – Югре (Тюменская область), обусловленное масштабным освоением территорий, включая разведку, добычу, транспортировку нефти и газа. Реализация ряда инфраструктурных проектов сопряжена с неизбежностью сокращения площади лесных массивов, вследствие чего приобретают актуальность действенные инструменты защиты лесных ресурсов, направленные на предотвращение незаконных вырубок.

Одним из таких инструментов мониторинга лесных территорий является визуальное дешифрирование спутниковых снимков на предмет выявления вырубок, традиционно выполняемое оператором-человеком. Специалист исследует каждую свободную от облаков зону спутникового снимка с целью обнаружить участки с недавно поврежденным лесным покровом. Повышению точности идентификации способствует сравнительный анализ пары разновременных снимков одной и той же местности, что существенно облегчает выявление искомых участков, особенно в сложных ситуациях. При обнаружении поврежденных участков оператор очерчивает границы этого участка с помощью специализированного программного обеспечения, затем сверяет найденный объект с базой данных санкционированных лесных рубок. В случае подтверждения факта незаконного вмешательства оператор уведомляет органы надзора для проведения последующего полевого обследования.

Стоит отметить ограничения традиционного подхода, основным из которых является влияние на результат психофизиологических особенностей человека. Усталость снижает способность оператора фокусироваться, отвлекающие внешние стимулы нарушают концентрацию внимания, что в итоге приводит к пропуску существенной доли нарушений. Несмотря на удовлетворительную точность ручных процедур, производительности даже десяти операторов недостаточно для систематической, качественной и оперативной обработки спутниковых данных по субъекту с территорией, сопоставимой или превосходящей площадь ХМАО-Югры.

Появляется необходимость минимизировать влияние вышеперечисленных ограничений. Сегодня наблюдается активный рост популярности нейросетевых технологий, включая их применение в обработке изображений. Особое внимание уделяется разработке алгоритмов, предназначенных для обнаружения участков с поврежденным лесным покровом, в частности, незаконно вырубленных территорий. В [1–20] исследуются возможности применения нейронных сетей в данном контексте. В большинстве работ [3, 5, 15, 17, 18] высокую результативность демонстрируют сверхточные нейросетевые архитектуры. В работах [19, 20] показано, что более высокую результативность могут показывать трансформерные нейросетевые архитектуры. Результаты этих исследований указывают на то, что современные нейросетевые методы могут быть применены в контексте спутникового мониторинга лесных территорий.

Тем не менее возлагать всю ответственность за мониторинг незаконных лесных рубок исключительно на нейросетевые системы представляется необоснованным. Несмотря на то, что применение нейронных сетей намного ускоряет выявление лесных нарушений, качество обводки целевых объектов уступает человеческому уровню. Как следствие, пригодным практическим решением является использование автоматизированного подхода, в рамках которого нейронные сети определяют возможные зоны рубок, а операторы проверяют и подтверждают эти данные.

При такой результативной комбинации искусственного интеллекта и человеческого контроля в ряде специфичных случаев остаются проблемы следующего вида: избыточное выделение ложных объектов, недостаточно точное определение границ поврежденных участков, пропуски целевых участков. Эти недостатки оказывают непосредственное влияние на работу оператора. Ложные объекты требуют дополнительного времени на проверку и исключение. Неточно очерченные границы означает дополнительные траты времени на редактирование обводки. Полностью пропущенный нейронной сетью объект игнорируется оператором, поскольку его решение основано исключительно на выводах нейросетевого алгоритма, а не на самостоятельном просмотре всего доступного снимка.

Применение нейросетевых моделей сталкивается с рядом специфических трудностей при обнаружении лесных рубок. Возникают случаи, когда условия съемки затрудняют идентификацию (облачность, тени от облаков, туман), что значительно снижает эффективность поиска. Также существуют ситуации, когда за рубку принимается объект иного происхождения (ветровалы, цветения на болотах, выцветание травы, высыхание берегов рек и озер, участки лесной гари с частично восстановленной растительностью). Третий аспект касается пропуска или неполной обводки точечных и линейных рубок, примером которых являются дорожные сооружения и недавно созданные точечные вырубленные участки, которые еще не успели расшириться. Такие пропуски создают условия для беспрепятственного выполнения нарушителями именно таких видов рубок.

Настоящая работа представляет метод, направленный на улучшение качества распознавания линейных рубок (просек) без снижения эффективности распознавания других разновидностей вырубок. Метод способствует повышению продуктивности автоматизированного спутникового мониторинга. В дальнейшем предполагается проверить его действенность применительно к другим вышеописанным проблемным случаям.

Материалы

Исследование проведено на территории Ханты-Мансийского автономного округа – Югры (ХМАО), находящегося в пределах Тюменской области Российской Федерации. Регион расположен в зоне бореальных лесов, включающих светлохвойные, темнохвойные, мелколиственные и смешанные леса. Округ активно развивает инфраструктуру нефтегазового комплекса и энерго-

системы, что приводит к появлению сложно определяемых нейросетевым методом спутникового мониторинга лесных просек, отмеченных ранее. Местная территория характеризуется резкой сезонностью климата, проявляющейся в наличии двух отчетливых сезонов лесных рубок: «бесснежного» (июнь – сентябрь) и «снежного» (ноябрь – апрель). Это предполагает обязательный учет обоих сезонов при усовершенствовании нейросетевых технологий природоохранного мониторинга.

Рассматриваются спутниковые снимки миссии Sentinel-2 уровня обработки L1C [21], в рамках которой выполняется систематическая мультиспектральная съемка поверхности Земли с полосой захвата 290 км. Спутники-дублиеры Sentinel-2A и Sentinel-2B осуществляют повторную съемку территорий с интервалом 5 дней на экваторе и каждые 2–3 дня в средних широтах. Такие характеристики позволяют обеспечить регулярный мониторинг состояния земной поверхности. Произведенные снимки предоставляются в открытый доступ и представляют собой 13-канальные изображения пространственного разрешения от 10 до 60 метров. Каждый снимок Sentinel-2 охватывает территорию 100 × 100 километров.

Для исследования были отобраны свободные от облачности спутниковые снимки, соответствующие рассматриваемой территории. Путём нарезки и перепроецирования растровых изображений сформированы размеченные пары кадров, каждая из которых охватывает участок площадью 5,12 × 5,12 кв. км. Каждая пара включает в себя три элемента: «текущий» кадр (соответствует текущему моменту времени), «старый» кадр (соответствует предшествующему моменту времени) и подготовленную оператором бинарную маску лесных рубок (рис. 1).

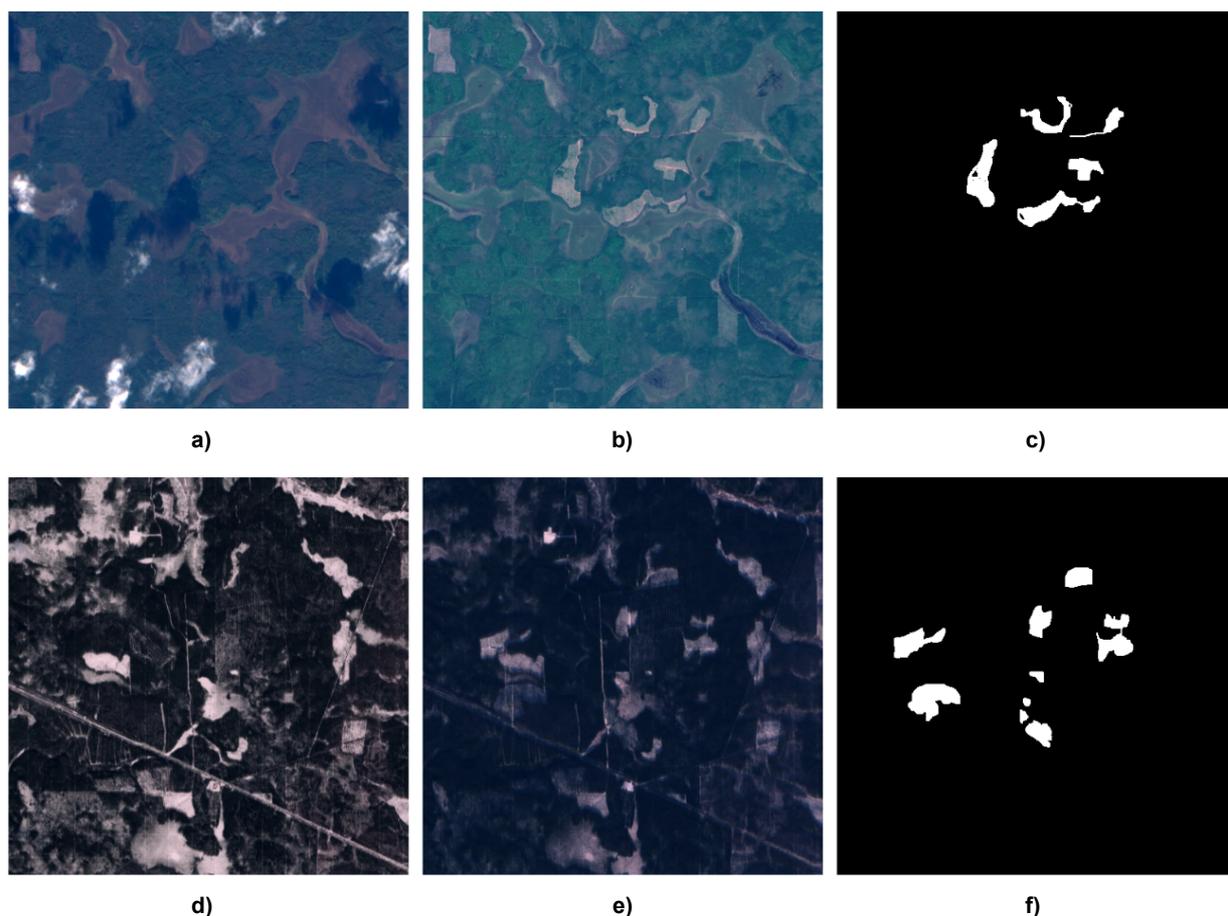


Рис. 1. Визуализация размеченных пар кадров: а, b, с – «старый» кадр, «текущий» кадр, маска рубок «бесснежного» сезона соответственно; d, e, f – «старый» кадр, «текущий» кадр, маска рубок «снежного» сезона соответственно

Fig. 1. Visualization of annotated frame pairs: a, b, c – “old” frame, “current” frame, and felling mask for the “snowless” season respectively; d, e, f – “old” frame, “current” frame, and felling mask for the “snowy” season respectively

Белый пиксель на маске указывает на нарушение лесного покрова вследствие вырубки на соответствующем участке «текущего» кадра по сравнению со «старым» кадром. Черный цвет означает, что на участке «нового» кадра отсутствуют признаки лесной рубки. Следует отметить, что операторы выделяют чёрным цветом также те участки, где выявлено нарушение лесного покрова, имеющее иную природу происхождения, отличную от рубок (ветровалы, пожары и подтопления, отличимые на снимках Sentinel-2 от участков с вырубками).

Пространственное распределение размеченных пар показано на рис. 2. Зелёным цветом отмечены кадры «бесснежного» сезона, синим – «снежного». Набор данных включает в себя 5522 размеченные пары кадров (2691 пара «бесснежного» сезона и 2831 пара «снежного» сезона). Среди размеченных пар имеются как те, которые охватывают как минимум один вырубленный лесной участок, так и те, на которых рубки полностью отсутствуют. Вследствие неравномерного распределения вырубок по рассматриваемой территории наблюдается группирование размеченных пар в виде отдельных кластеров со случаями частичного пространственного пересечения.

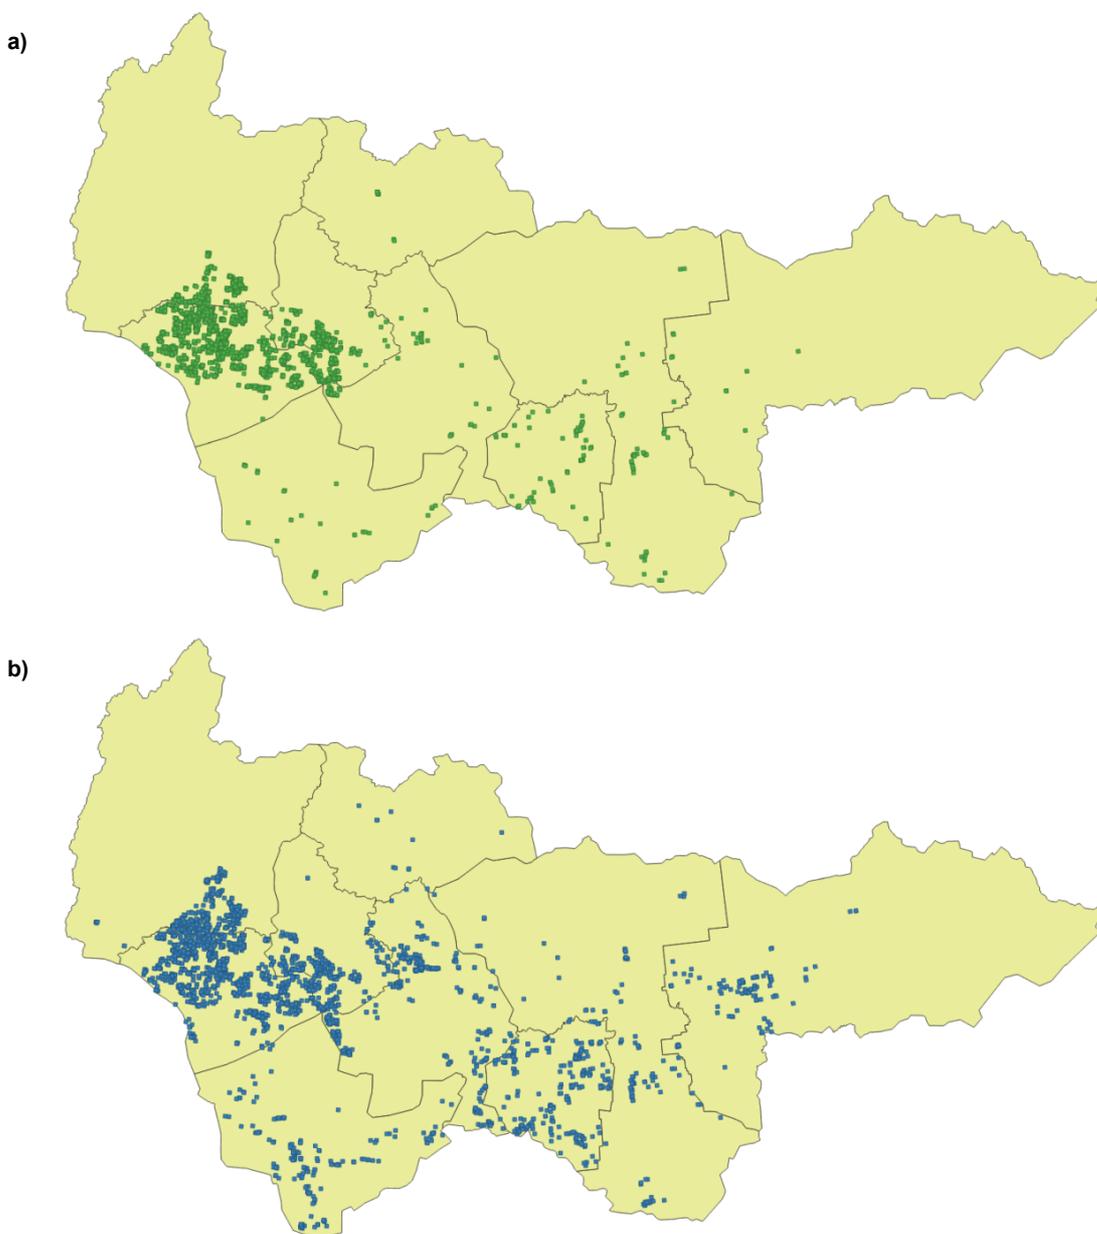


Рис. 2. Распределение размеченных пар кадров по территории ХМАО-Югры: а – пары «бесснежного» сезона; б – пары «снежного» сезона

Fig. 2. Distribution of annotated frame pairs across the territory of Khanty-Mansi Autonomous Okrug – Yugra: a – “snowless” season pairs; b – “snowy” season pairs

Методы

Рассматривается задача бинарной семантической сегментации разновременной пары пространственно согласованных спутниковых изображений. Требуется сформировать маску рубок на основе «текущего» и «старого» кадров, что на практике означает имитацию поведения человека-оператора. Предполагается реализация нейросетевого моделирования, подразумевающая в данном контексте обучение нейронных сетей на тренировочной выборке размеченных пар кадров, систематический мониторинг обучаемых моделей на предмет переобучения путём апробации на валидационной выборке, итоговую оценку качества модели на независимой тестовой выборке.

Предлагаемое в рамках настоящей работы решение основывается на построении ансамбля независимых нейросетевых моделей, каждая из которых формирует собственную маску лесных рубок – и впоследствии их прогнозы отображаются в единый результирующий прогноз от всего ансамбля. Каждая отдельно взятая модель обучается по принципу «мягкой» специализации с «осторожным» выходом за ее пределы. Под «мягкостью» специализации подразумевается наличие у каждой модели ансамбля собственного профиля (ряд заранее известных ситуаций, при возникновении которых от модели ожидается наибольшая результативность), но при этом они также обучаются справляться задачами вне своей специфики, пусть и с меньшей эффективностью. Термином «осторожность» обозначено желаемое поведение модели в процессе вывода решений: если случившаяся ситуация выходит за рамки профиля модели – она должна быть склонной к ложноотрицательным ошибкам (пропускать объекты), а не ложноположительным. Окончательный прогноз получается путем объединения бинарных масок, сформированных отдельными моделями, посредством логического оператора «ИЛИ». Его применение в сочетании с ранее представленным принципом «осторожности» позволяет смягчить проблему накопления ложноположительных ошибок при получении агрегированного вывода.

Для задачи выявления лесных рубок предлагается использовать ансамбль из следующих двух моделей. Первая модель настраивается таким образом, чтобы она была специализированной именно на выявлении «тонких» видов рубок (точечных и линейных), при этом имела тенденцию совершать ложноотрицательные ошибки по всем остальным рубкам (далее именуются «широкими»). Вторая модель настраивается прямо противоположным образом.

Чтобы зафиксировать модель таким образом, чтобы она выделяла исключительно тонкие вырубки, необходимо предварительно определить понятие «тонких» вырубков путем разработки специального алгоритма. Такой алгоритм, основываясь на исходной бинарной маске всех вырубков, позволит формировать новую бинарную маску, содержащую лишь тонкие вырубки и исключая остальные типы.

Предлагается алгоритм выделения тонких объектов на маске рубок. Его суть состоит в повторяющихся операциях последовательного удаления граничных пикселей каждого объекта с последующим равнозначным числом восстановительных шагов. В ходе каждой итерации восстановления утраченные пиксели возвращаются только из числа ближайших соседей. Подобный метод обеспечивает полное удаление тонких фрагментов после завершения цикла указанных процедур. Чем большее количество итераций эрозии-восстановления выполнить, тем более широкие фрагменты будут оставлены на маске.

Иллюстрация описываемых процедур представлена на рис. 3. После выполнения итераций эрозии $i_{\text{ер}} = 1, \dots, N$ производится аналогичное количество итераций восстановления $i_{\text{вос}} = 1, \dots, N$. Итоговая маска представляет собой маску тонких рубок. Зелеными стрелками отражается: при $i_{\text{вос}} = x, x \in 1, \dots, N$, используется информация о сохранившихся пикселях, зафиксированная при $i_{\text{ер}} = N - x + 1$. По завершении процесса восстановления выполняется логическое исключение («исключающее ИЛИ») между полученной выходной и первоначальной масками. Это формирует предварительную маску тонких вырубков, содержащую незначительные шумы, которые необходимо устранить. Для этого применяется этап фильтрации мелких объектов («Фильтр малых объектов»). Алгоритм эрозии, выполняемый над бинарными масками, представлен в [22].

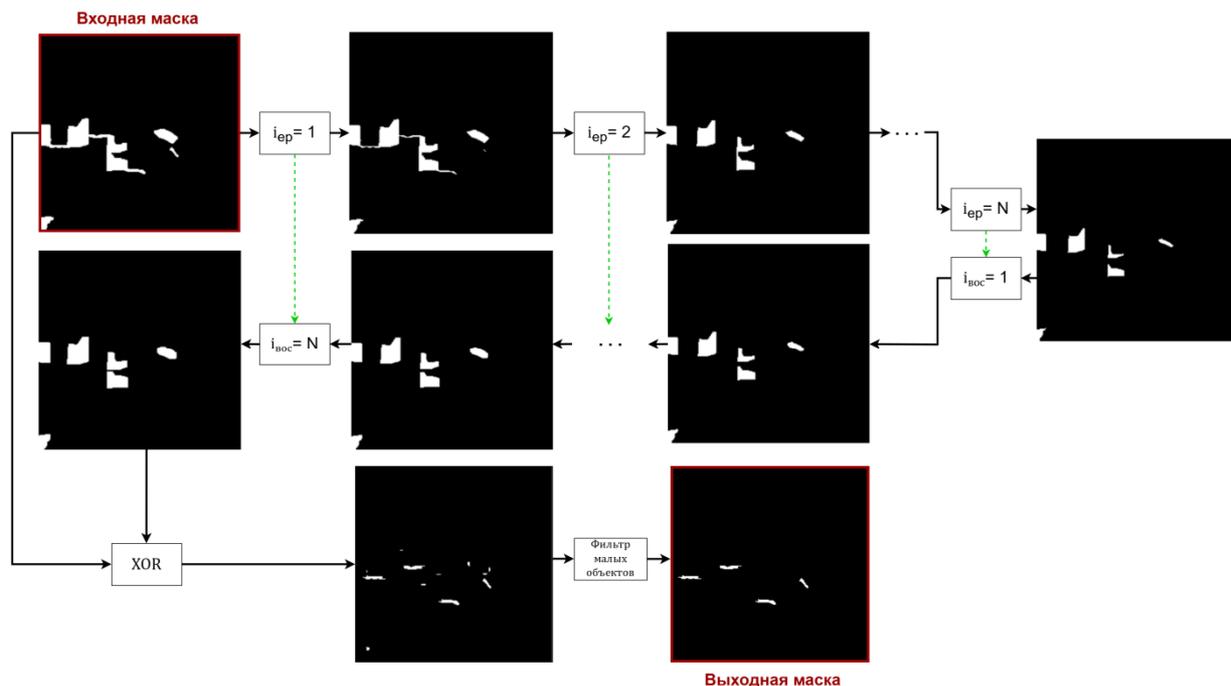


Рис. 3. Иллюстрация работы фильтра тонких фрагментов
 Fig. 3. Illustration of thin fragment filter operation

Для реализации вышеописанных «мягких» «аккуратных» прогнозов предлагается следующий метод. Чтобы изменить характер ошибок прогнозирования в сторону ложноположительных ошибок, рассматривается функция потерь Tversky Loss [23]. Одна из отличительных ее особенностей – возможность повышать параметр α при понижении параметра β , за счет чего есть возможность достичь эффекта «осторожной» модели при обучении. Эффект фокусировки достигается модификацией схемы вычислений подсчета TP , FP и FN . Вводится маска приоритетов наряду с маской истинных предсказаний. Так, за более приоритетные участки модель будет больше штрафовать за ошибку и более вознаграждаться за правильный ответ.

Положим, ширина, высота выходной и ожидаемой маски W и H соответственно. В процессе обучения подаем на вход нейросети очередное изображение из тренировочной выборки и получаем еще не бинаризованную карту прогнозов $\tilde{Y}_{двухмерн} \in [0,1]^{H \times W}$. Ожидаем от модели истинную бинарную маску $Y_{двухмерн} \in \{0,1\}^{H \times W}$. Имеем маску приоритетов $S_{двухмерн} \in R$. Далее для упрощения представления далее преобразуем $Y_{двухмерн}$, $\tilde{Y}_{двухмерн}$, $S_{двухмерн}$ в одномерный вид Y, \tilde{Y}, S так, что: $Y \in \{0,1\}^M, \tilde{Y} \in [0,1]^M, M = H \cdot W$. Применяем функцию потерь в виде

$$L_{\alpha,\beta}(Y, \tilde{Y}) = 1 - \frac{((Y\tilde{Y})S)}{\gamma\tilde{Y} + \alpha((1-Y)\tilde{Y})S + \beta(Y(1-\tilde{Y})S)}. \tag{1}$$

Что касается метрик оценивания, используются как стандартные, так и специализированные метрики, позволяющие оценить эффективность решения конкретно в аспекте точности распознавания лесных рубок. Представляем перечень применяемых базовых метрик:

$$Precision(Y, \tilde{Y}) = \frac{TP}{TP+FP}, Recall(Y, \tilde{Y}) = \frac{TP}{TP+FN}, \tag{2}$$

$$F_1(Y, \tilde{Y}) = \frac{2 \cdot Precision(Y, \tilde{Y}) \cdot Recall(Y, \tilde{Y})}{Precision(Y, \tilde{Y}) + Recall(Y, \tilde{Y})},$$

где TP – количество пикселей, которые были правильно отнесены к рубкам. FN – количество пикселей, в которых рубка была пропущена. FP – количество пикселей, которые были неправильно отнесены к рубкам.

Необходима оценка качества распознавания лесных просек («тонких» объектов в целом). Для этого в расчет $TP_{тонк}$, $FP_{тонк}$, $FN_{тонк}$ берутся лишь те пиксели масок, что входят в окрестности и пределы маски тонких рубок. Визуализация таких окрестностей представлена на рис. 4. Говорим о $F_{1 тонк}$ и $F_{1 проч}$ (остальная область – синяя маска), что вычисляется по аналогии $TP_{проч}$, $FP_{проч}$, $FN_{проч}$.

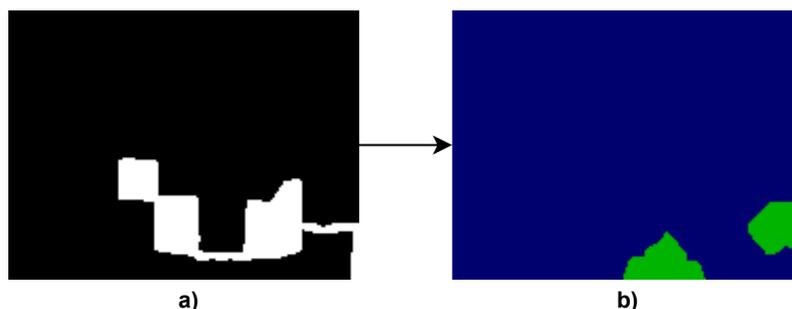


Рис. 4. Иллюстрация выделения областей для подсчета $F_{1\text{ тонк}}$ (зеленый цвет) и $F_{1\text{ проч}}$ (синий цвет):
а – исходная маска; б – соответствующие выделенные области маски

Fig. 4. Illustration of region extraction for calculating $F_{1\text{ тонк}}$ (green color) and $F_{1\text{ проч}}$ (blue color):
а – original mask; б – corresponding extracted regions

Результаты и обсуждение

Задачи сегментации снимков для «снежного» и «бесснежного» сезонов решались отдельно, используя отдельные модели (ансамбли моделей). Процесс обучения включал фиксированное количество эпох, на каждой из которых сохраняются контрольные точки (чекпоинты). После завершения обучения среди всех сохранённых чекпоинтов выбирается та версия модели, которая демонстрирует лучшие результаты на валидационном датасете. Эта выбранная модель считается обученной и далее проверяется на тестовых данных согласно ранее описанным критериям.

Предварительная обработка данных проводилась одинаково для всех моделей и включала этапы нормализации и нарезки изображений. Исходные данные были нормализованы методом Z-нормализации, устраняющим влияние исходного масштаба на результаты моделирования. Затем изображения разрезались на отдельные кадры и балансировались. Для «бесснежного» периода обучающая выборка содержала 40 052 пары изображений, валидационная – 12 500 пар, тестовая – 5 625 пар. В случае «снежного» периода объемы составляли соответственно 49 563, 14 017 и 7 220 пар изображений. Для решения задачи «бесснежного» сезона мы используем лишь следующие каналы: B2 (голубой), B3 (зеленый), B4 (красный), B5 (VNIR), B11 и B12 (SWIR). Изображения каналов с разрешением 20 и 60 м с помощью процедуры увеличения пространственного разрешения с использованием глубокой нейронной сети DeepSentinel-2 [24] приводились к разрешению 10 м. Используем пакетный градиентный спуск с размером пакета (batch size), равным 32.

На основании предварительных экспериментов с перебором гиперпараметров для всех последующих экспериментов была выбрана архитектура Mobilenetv2-Unet++ [25] с числом параметров 6.8 М. Благодаря достаточно небольшому размеру модели и возможности параллельной обработки такие модели могут эффективно использоваться в контексте нейросетевого ансамблирования.

Результаты экспериментов по обоим сезонам приведены в таблице. Обозначения в таблице означают следующее:

- Baseline: модель архитектуры MobileNetV2_U-Net++, обученная на оригинальном наборе данных;
- Augmentation: такой же эксперимент, как Baseline, но с добавлением равного количества (50 %) искаженных кадров (смещение, поворот, отзеркаливание, вращение): половина кадра с участками лесных просек, половина – кадры без рубок (для восстановления баланса);
- Thin Thick Ensemble: предлагаемый подход, реализованный в ансамбле двух моделей MobileNetV2_U-Net++, обученных на оригинальном наборе данных;
- Thin Thick Ensemble & Augmentation: обучение вышеописанного ансамбля на аугментированном наборе данных.

Показано, что схема Thin Thick Ensemble & Augmentation дала результативность на 5,35 % больше по сравнению с Baseline по метрике $F_{1\text{ тонк}}$. При этом не потеряли показатель $F_{1\text{ проч}}$, что означает сохранение качества обнаруживать другие виды лесных вырубок, кроме лесных просек. Показано также, что схема Thin Thick Ensemble & Augmentation дала результативность на +6,8 % больше по сравнению с Baseline по «снежному сезону». При этом также не потеряли показатель

$F_{1 \text{ проч}}$. В обоих случаях наблюдается эффект: комбинация подхода аугментации изображения и предложенной схемы «мягкого осторожного» ансамбля дает результативность больше, чем применение этих подходов по отдельности.

Результаты экспериментов по двум сезонам
Experimental results for two seasons

| Эксперимент | Сезон | | | |
|------------------------------------|----------------------|----------------------|----------------------|----------------------|
| | Бесснежный | | Снежный | |
| | $F_{1 \text{ тонк}}$ | $F_{1 \text{ проч}}$ | $F_{1 \text{ тонк}}$ | $F_{1 \text{ проч}}$ |
| Baseline | 0,7971 | 0,9260 | 0,7640 | 0,8969 |
| Augmentation | 0,8362 | 0,9276 | 0,7803 | 0,9015 |
| Thin Thick Ensemble | 0,8384 | 0,9292 | 0,8225 | 0,8986 |
| Thin Thick Ensemble & Augmentation | 0,8506 | 0,9296 | 0,8320 | 0,9011 |

Приведенные выше результаты показывают, что предложенный метод позволяет значительно повысить точность распознавания лесных рубок в условиях наличия значительной доли их в виде лесных просек по сравнению с традиционными подходами.

Стоит учесть, что рассматриваемые модели не принимают во внимание лесные участки с иными характерными признаками, затрудняющими автоматическое распознавание. Облачный покров представляет собой серьезную проблему при анализе космических снимков [20], поскольку облака и их тени способны полностью или частично скрывать участки земной поверхности, препятствуя достоверному выявлению лесных рубок. Поэтому вопросы учета влияния облачности на эффективность распознавания лесных рубок на спутниковых изображениях требуют дальнейшей научной проработки.

Заключение

Предложен метод повышения эффективности распознавания лесных просек, основанный на модифицированной функции потерь TverskyLoss с использованием нейросетевого ансамблирования. Эффективность метода подтверждена экспериментально на двух наборах данных, соответствующих «снежному» и «бесснежному» сезонам. Благодаря предложенному методу удалось повысить качество распознавания лесных просек по показателю $F_{1 \text{ тонк}}$ на 5,35 % для «бесснежного сезона» и 6,8 % для «снежного сезона» без потерь в качестве распознавания рубок других категорий. Для дальнейшего повышения точности нейросетевой модели необходимы дополнительные исследования, направленные на расширение и повышение качества тренировочного набора данных посредством включения большего разнообразия примеров лесных вырубок. Представляют научный и прикладной интерес вопросы распознавания рубок на спутниковых снимках в условиях наличия отвлекающих помех, таких как лесные гари и ветровалы. Важным направлением дальнейших исследований является повышение точности обнаружения лесных рубок при влиянии неблагоприятных атмосферных условий, таких как плотная облачность (включая затененность облаками) и туманность.

Список литературы

1. Deep Learning-Driven Multi-Temporal Detection: Leveraging DeeplabV3+/ Efficientnet-B08 Semantic Segmentation for Deforestation and Forest Fire Detection / J. Soundararajan, A. Kalukin, J. Malof, D. Xu // Remote Sensing. 2025. Vol. 17, no. 14. P. 2333. DOI: 10.3390/rs17142333
2. Deforestation detection with fully convolutional networks in the Amazon Forest from Landsat-8 and Sentinel-2 images / D.L. Torres, J.N. Turnes, P.J. Soto Vega et al. // Remote Sensing. 2021. Vol. 13, no. 24. P. 5084. DOI: 10.3390/rs13245084
3. John D., Zhang C. An attention-based U-Net for detecting deforestation within satellite sensor imagery // International Journal of Applied Earth Observation and Geoinformation. 2022. Vol. 107. P. 102685. DOI: 10.1016/j.jag.2022.102685
4. Classification of landscape affected by deforestation using high-resolution remote sensing data and deep-learning techniques / S.-H. Lee, K.-J. Han, K. Lee et al. // Remote Sensing, 2020. Vol. 12, no. 20. P. 3372. DOI: 10.3390/rs12203372

5. Deep Learning for Regular Change Detection in Ukrainian Forest Ecosystem With Sentinel-2 / K. Isaienkov, M. Yushchuk, V. Khramtsov, O. Seliverstov // *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2021. Vol. 14. P. 364–376. DOI: 10.1109/JSTARS.2020.3034186
6. Forest change detection in incomplete satellite images with deep neural networks / S.H. Khan, X. He, F. Porikli, M. Bennamoun // *IEEE Transactions on Geoscience and Remote Sensing*. 2017. Vol. 55, no. 9. P. 5407–5423. DOI: 10.1109/TGRS.2017.2707528
7. de Andrade R.B., Mota G.L.A., da Costa G.A.O.P. Deforestation Detection in the Amazon Using DeepLabv3+ Semantic Segmentation Model Variants // *Remote Sensing*. 2022. Vol. 14, no. 19. P. 4694. DOI: 10.3390/rs14194694
8. RepDDNet: a fast and accurate deforestation detection model with high-resolution remote sensing image / Z. Wang, Z. Wang, D. Yan et al. // *International Journal of Digital Earth*. 2023. Vol. 16, no. 1. P. 2013–2033. DOI: 10.1080/17538947.2023.2220619
9. Fodor G., Conde M.V. Rapid Deforestation and Burned Area Detection using Deep Multimodal Learning on Satellite Imagery // *arXiv:2307.04916*. 2023. DOI: 10.48550/arXiv.2307.04916
10. Модели U-Net для семантической сегментации повреждённых деревьев сосны сибирской кедровой на снимках с БПЛА / Н.Г. Марков, К.А. Маслов, И.А. Керчев, О.С. Токарева // *Современные проблемы дистанционного зондирования Земли из космоса*. 2022. Т. 19, № 1. С. 65–77. DOI: 10.21046/2070-7401-2022-19-1-65-77
11. A Combined Deep Learning and Prior Knowledge Constraint Approach for Large-Scale Forest Disturbance Detection Using Time Series Remote Sensing Data / B. Du, Z. Yuan, Y. Bo, Y. Zhang // *Remote Sensing*. 2023. Vol. 15, no. 12. P. 2963. DOI: 10.3390/rs15122963
12. Comparing Sentinel-2 MSI and Landsat 8 OLI Imagery for Monitoring Selective Logging in the Brazilian Amazon / T. Almeida Lima et al. // *Remote Sensing*. 2019. Vol. 11, no. 8. P. 961. DOI: 10.3390/rs11080961
13. Pałaś K.W., Zawadzki J. Sentinel-2 Imagery Processing for Tree Logging Observations on the Białowieża Forest World Heritage Site // *Forests*. 2020. Vol. 11, no. 8. P. 857. DOI: 10.3390/f11080857
14. Near Real-Time Change Detection System Using Sentinel-2 and Machine Learning: A Test for Mexican and Colombian Forests / A.M. Pacheco-Pascagaza et al. // *Remote Sensing*. 2022. Vol. 14, no. 3. P. 707. DOI: 10.3390/rs14030707
15. Распознавание вырубок и ветровалов по спутниковым снимкам Sentinel-2 с применением сверточной нейронной сети U-net и факторы, влияющие на его точность / А.И. Канев, А.В. Тарасов, А.Н. Шихов и др. // *Современные проблемы дистанционного зондирования Земли из космоса*. 2023. Т. 20, № 3. С. 136–151. DOI: 10.21046/2070-7401-2023-20-3-136-151
16. Сравнительная оценка различных архитектур сверточных нейронных сетей для семантической сегментации нарушений лесного покрова по разновременным спутниковым снимкам / Н.С. Подопригорова, А.В. Тарасов, А.Н. Шихов, А.И. Канев // *Исследование Земли из космоса*. 2024. № 3. P. 3–15. DOI: 10.31857/S0205961424030013
17. Monitoring direct drivers of small-scale tropical forest disturbance in near real-time with Sentinel-1 and -2 data / B. Slagter, J. Reiche, D. Marcos et al. // *Remote Sensing of Environment*. 2023. Vol. 295. P. 113655. DOI: 10.1016/j.rse.2023.113655
18. О классификации космических снимков Sentinel-2 нейронной сетью ResNet-50 / И.В. Бычков, Г.М. Ружников, Р.К. Федоров и др. // *Компьютерная оптика*. 2023. Т. 47, № 3. С. 474–481. DOI: 10.18287/2412-6179-CO-1216
19. Каюмов О.О., Пятаева А.В. Сегментация лесных рубок по данным спутниковых снимков на базе модели MaskFormer // *Международный научно-исследовательский журнал*. 2023. № 10 (136). С. 1–8. DOI: 10.23670/IRJ.2023.136.16
20. Сравнительный анализ нейросетевых моделей для картографирования лесных рубок по летним космическим снимкам / А.В. Мельников, Ю.М. Полищук, М.А. Русанов и др. // *Научно-технический вестник информационных технологий, механики и оптики*. 2024. Т. 24, № 5. С. 806–814. DOI: 10.17586/2226-1494-2024-24-5-806-814
21. Sentinel Hub. Sentinel-2 L1C. URL: <https://docs.sentinel-hub.com/api/latest/data/sentinel-2-l1c/> (дата обращения: 27.05.2025).
22. Bradski G., Kaehler A. *Learning OpenCV*. Sebastopol (CA): O'Reilly, 2008.

23. Gábor H. The Tversky loss function and its modifications for medical image segmentation. URL: https://math-projects.elte.hu/media/works/187/report/tversky_loss_and_variants.pdf (дата обращения 20.12.2025).

24. Super-resolution of Sentinel-2 images: Learning a globally applicable deep neural network / C. Lanarasa, J. Bioucas-Dias, S. Galliana et al. // ISPRS Journal of Photogrammetry and Remote Sensing. 2018. Vol. 146. P. 305–319. DOI: 10.1016/j.isprsjprs.2018.09.018

25. Python library with Neural Networks for Image Semantic Segmentation based on PyTorch. URL: https://github.com/qubvel-org/segmentation_models_pytorch?tab=readme-ov-file (дата обращения: 27.05.2025).

References

1. Soundararajan J., Kalukin A., Malof J., Xu D. Deep Learning-Driven Multi-Temporal Detection: Leveraging DeeplabV3+/ Efficientnet-B08 Semantic Segmentation for Deforestation and Forest Fire Detection. *Remote Sensing*. 2025;17(14):2333. DOI: 10.3390/rs17142333

2. Torres D.L., Turnes J.N., Soto Vega P.J., Feitosa R.Q., Silva D.E., Marcato Junior J., Almeida C. Deforestation detection with fully convolutional networks in the Amazon Forest from Landsat-8 and Sentinel-2 images. *Remote Sensing*. 2021;13(24):5084. DOI: 10.3390/rs13245084

3. John D., Zhang C. An attention-based U-Net for detecting deforestation within satellite sensor imagery. *International Journal of Applied Earth Observation and Geoinformation*. 2022;107:102685. DOI: 10.1016/j.jag.2022.102685

4. Lee S.-H., Han K.-J., Lee K., Lee K.-J., Oh K.-Y., Lee M.-J. Classification of landscape affected by deforestation using high-resolution remote sensing data and deep-learning techniques. *Remote Sensing*. 2020;12(20):3372. DOI: 10.3390/rs12203372

5. Isaienkov K., Yushchuk M., Khrantsov V., Seliverstov O. Deep Learning for Regular Change Detection in Ukrainian Forest Ecosystem With Sentinel-2. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2021;14:364–376. DOI: 10.1109/JSTARS.2020.3034186

6. Khan S.H., He X., Porikli F., Bennamoun M. Forest change detection in incomplete satellite images with deep neural networks. *IEEE Transactions on Geoscience and Remote Sensing*. 2017;55(9):5407–5423. DOI: 10.1109/TGRS.2017.2707528

7. de Andrade R.B., Mota G.L.A., da Costa G.A.O.P. Deforestation Detection in the Amazon Using DeepLabv3+ Semantic Segmentation Model Variants. *Remote Sensing*. 2022;14(19):4694. DOI: 10.3390/rs14194694

8. Wang Z., Wang Z., Yan D., Mo Z., Zhang H., Zhang Q. RepDDNet: a fast and accurate deforestation detection model with high-resolution remote sensing image. *International Journal of Digital Earth*. 2023;16(1):2013–2033. DOI: 10.1080/17538947.2023.2220619

9. Fodor G., Conde M.V. Rapid Deforestation and Burned Area Detection using Deep Multimodal Learning on Satellite Imagery. *arXiv:2307.04916*. 2023. DOI: 10.48550/arXiv.2307.04916

10. Markov N.G., Maslov K.A., Kerchev I.A., Tokareva O.S. U-Net models for semantic segmentation of damaged *Pinus sibirica* trees in UAV imagery. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*. 2022;19(1):65–77. (In Russ.) DOI: 10.21046/2070-7401-2022-19-1-65-77

11. Du B., Yuan Z., Bo Y., Zhang Y. A Combined Deep Learning and Prior Knowledge Constraint Approach for Large-Scale Forest Disturbance Detection Using Time Series Remote Sensing Data. *Remote Sensing*. 2023;15(12):2963. DOI: 10.3390/rs15122963

12. Almeida Lima T. et al. Comparing Sentinel-2 MSI and Landsat 8 OLI Imagery for Monitoring Selective Logging in the Brazilian Amazon. *Remote Sensing*. 2019;11(8):961. DOI: 10.3390/rs11080961

13. Pałasz K.W., Zawadzki J. Sentinel-2 Imagery Processing for Tree Logging Observations on the Białowieża Forest World Heritage Site. *Forests*. 2020;11(8):857. DOI: 10.3390/f11080857

14. Pacheco-Pascagaza A.M. et al. Near Real-Time Change Detection System Using Sentinel-2 and Machine Learning: A Test for Mexican and Colombian Forests. *Remote Sensing*. 2022;14(3):707. DOI: 10.3390/rs14030707

15. Kanev A.I., Tarasov A.V., Shikhov A.N., Podoprigrorova N.S., Safonov F.A. Identification of logged and windthrow areas from Sentinel-2 satellite images using the U-net convolutional neural network and factors affecting its accuracy. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*. 2023;20(3):136–151. (In Russ.) DOI: 10.21046/2070-7401-2023-20-3-136-151

16. Podoprigorova N.S., Tarasov A.V., Shikhov A.N., Kanev A.I. Comparative Assessment of Different Architectures of Convolutional Neural Network for Semantic Segmentation of Forest Disturbances from Multi-Temporal Satellite Images. *Earth Research from Space*. 2024;(3):3–15. (In Russ.) DOI: 10.31857/S0205961424030013
17. Slagter B., Reiche J., Marcos D., Mullissa A., Lossou E., Pena-Claros M., Herold M. Monitoring direct drivers of small-scale tropical forest disturbance in near real-time with Sentinel-1 and -2 data. *Remote Sensing of Environment*. 2023;295:113655. DOI: 10.1016/j.rse.2023.113655
18. Bychkov I.V., Ruzhnikov G.M., Fedorov R.K., Popova A.K., Avramenko Y.V. On classification of Sentinel-2 satellite images by a neural network ResNet-50. *Computer Optics*. 2023;47(3):474–481. (In Russ.)
19. Qayumov O.O., Pyataeva A.V. Forest cutting segmentation from satellite image data based on MaskFormer model. *International Research Journal*. 2023;10(136):1–8. (In Russ.) DOI: 10.23670/IRJ.2023.136.16
20. Melnikov A.V., Polishchuk Yu.M., Rusanov M.A., Abbazov V.R., Kochergin G.A., Kupriyanov M.A., Baisalyamova O.A., Sokolov O.I. Comparative analysis of neural network models for felling mapping in summer satellite imagery. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*. 2024;24(5):806–814. (In Russ.) DOI: 10.17586/2226-1494-2024-24-5-806-814
21. Sentinel Hub. Sentinel-2 L1C. Available at: <https://docs.sentinel-hub.com/api/latest/data/sentinel-2-l1c/> (accessed 27.05.2025)
22. Bradski G., Kaehler A. *Learning OpenCV*. Sebastopol (CA): O'Reilly, 2008.
23. Gábor H. The Tversky loss function and its modifications for medical image segmentation. Available at: https://math-projects.elte.hu/media/works/187/report/tversky_loss_and_variants.pdf (accessed 20.12.2025)
24. Lanarasa C., Bioucas-Dias J., Galliana S., Baltasviase E., Schindlera K. Super-resolution of Sentinel-2 images: Learning a globally applicable deep neural network. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2018;146:305–319. DOI: 10.1016/j.isprsjprs.2018.09.018
25. Python library with Neural Networks for Image Semantic Segmentation based on PyTorch. Available at: https://github.com/qubvel-org/segmentation_models.pytorch?tab=readme-ov-file (accessed 27.05.2025).

Информация об авторе

Соколов Олег Игоревич, ведущий программист Центра развития искусственного интеллекта, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, Россия; аспирант Инженерной школы цифровых технологий, Югорский государственный университет, Ханты-Мансийск, Россия; sokolkovoi@uriit.ru.

Information about the author

Oleg I. Sokolov, Lead Programmer of the Center of AI Development, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, Russia; Postgraduate Student of the Engineering School of Digital Technologies, Yugra State University, Khanty-Mansiysk, Russia; sokolkovoi@uriit.ru.

Автор заявляет об отсутствии конфликта интересов.

The author declares no conflict of interests.

Статья поступила в редакцию 21.12.2025

The article was submitted 21.12.2025