

<https://doi.org/10.25686/foreco.2025.99.31.002>

УДК 004.8

СЕМАНТИЧЕСКАЯ СЕГМЕНТАЦИЯ ПОЛУЧЕННЫХ С БПЛА ИЗОБРАЖЕНИЙ ДЕРЕВЬЕВ ПИХТЫ В УСЛОВИЯХ ИМПУЛЬСНЫХ ПОМЕХ

А.Ю. Малкин, Н.Г. Марков

Национальный исследовательский Томский политехнический университет

*В статье представлены результаты исследования устойчивости модели сверточной нейронной сети Mo-U-Net с робастной функцией потерь (РФП) Рамсея к импульсным помехам на изображениях деревьев пихты *Abies Sibirica*, полученных с беспилотного летательного аппарата. В качестве меры устойчивости такой модели к помехам используются метрики точности классификации деревьев IoUc и mIoU. Для обучения, валидации и проведения исследования модели создан набор данных, фрагменты обучающей выборки которого имеют искусственным образом внесенные импульсные помехи. Исследовано влияние амплитуды импульсных помех на устойчивость этой модели при постоянной доле площади зашумления фрагментов, равной 0,25. Выявлено снижение устойчивости модели по метрике mIoU на 3% – 6% с ростом амплитуды помех от 1,5 до 3,0. При исследовании влияния доли площади зашумления импульсными помехами фрагментов обучающей выборки на устойчивость модели при постоянной амплитуде помех $A=1,5$ показано, что по метрике mIoU модель демонстрирует плавное снижение устойчивости на 0% – 9% к помехам с ростом доли площади зашумления от 0,10 до 0,50. Анализ полученных значений метрики IoUc на тестовой выборке для деревьев классов «Живое», «Свежий сухостой» и «Старый сухостой», а также для класса «Фон» показал, что наблюдается плавное снижение устойчивости модели при увеличении доли площади зашумления фрагментов или амплитуды помех, но все значения этой метрики превышают пороговое значение 0,5 и поэтому для этих классов модель может быть рекомендована для практического применения. Для деревьев класса «Отмирающее» значения метрики IoUc на тестовой выборке для всех вариантов задания в экспериментах значений амплитуд помех и долей зашумления фрагментов значительно меньше порога 0,5, что говорит о низкой устойчивости модели к помехам и, соответственно, не позволяет использовать ее на практике в случае классификации деревьев этого класса.*

Ключевые слова: полносверточная нейронная сеть Mo-U-Net, семантическая сегментация (попиксельная классификация) изображения, импульсные помехи, робастная функция потерь Рамсея.

SEMANTIC SEGMENTATION OF IMAGES OF FIR TREES OBTAINED FROM UAVS UNDER IMPULSE NOISE CONDITIONS

A.Yu. Malkin, N.G. Markov

National Research Tomsk Polytechnic University

*The article presents the results of a study of the robustness of the Mo-U-Net convolutional neural network model with Ramsey's robust loss function (RLF) to impulse noise in images of fir trees *Abies Sibirica* obtained from an unmanned aerial vehicle. The IoUc and mIoU tree classification accuracy metrics are used as a measure of the robustness of such a model to noise. For training, validation, and research of the model, a dataset was created, fragments of the training sample of which have artificially introduced impulse noise. The influence of the amplitude of impulse noise on the robustness of this model was investigated at a constant noise area fraction of 0.25. A decrease in its robustness was found to be 3% – 6%, depending on the increase in noise amplitude from 1.5 to 3.0. The study examined the effect of the area of impulse noise in the training sample fragments on the stability of the model at a constant noise amplitude of $A = 1.5$. It was found that, according to the mIoU metric on the test sample, the model demonstrates a smooth decrease in stability to interference with an increase in the proportion of noise area from 0.10 to 0.50, respectively, from 0% to 9%.*

Analysis of the obtained IoUc metric values on the test sample for trees of the classes 'Alive', 'Fresh deadwood' and 'Old deadwood' classes, as well as for the 'Background' class, showed that there is a gradual decrease in the model's stability with an increase in the proportion of noise area of fragments or the amplitude of interference, but all values of this metric exceed the threshold value of 0.5 and therefore the model can be recommended for practical application for these classes. For trees in the 'Dying' class, the IoUc metric values in the test sample for all variants of the task in the experiments of interference amplitude values and fragment noise proportions are significantly less than the threshold of 0.5, which indicates the low stability of the model to interference and, accordingly, does not allow it to be used in practice in the case of classifying trees of this class.

Keywords: Mo-U-Net fully-convolutional neural network, semantic segmentation (pixel-by-pixel classification) of an image, impulse noise, robust Ramsey loss function.

Введение

Массовое размножение насекомых-вредителей представляют собой одну из наиболее значимых угроз для лесных экосистем в различных регионах мира (van Lierop et al., 2015). Наибольшую опасность такие вредители представляют для хвойных насаждений, причем они способны вызвать как существенные экологические последствия в регионе, так и экономические потери вследствие снижения качества и объёмов заготавливаемой древесины (Chang et al., 2012; van Lierop et al., 2015; Dedyukhin et al., 2021; Kerchev et al., 2022). Примером подобного стволового вредителя является уссурийский полиграф (*Polygraphus proximus* Blandford), который стал доминирующим вредителем пихтовых лесов России (Кривец и др., 2018). Так, с 2007 года зафиксированы многочисленные очаги его массового размножения в Сибири и в ряде центральных регионов страны, включая Московскую область, а сравнительно недавно – в Удмуртии и Прибайкалье (Bystrov, Antonov, 2019; Dedyukhin, Titova, 2021). Аналогичная картина имеет место при распространении очагов размножения другого агрессивного стволового вредителя – союзного короеда (*Ips amitinus* Eichhoff) в кедровниках Сибири (Kerchev et al., 2022). В этих условиях ключевым решением проблемы гибели деревьев от таких насекомых-вредителей является проведение оперативного лесопатологического мониторинга хвойных лесов с целью своевременного выявления очагов вредителей и организации соответствующих фитосанитарных мероприятий.

Особенность развития популяций насекомых-вредителей заключается в резких флуктуациях численности: после латентного периода акклиматизации возможны стремительные всплески и такие же быстрые спады (Кривец и др., 2018; Dedyukhin, Titova, 2021; Kerchev et al., 2022). Это определяет необходимость решения двух первоочередных задач лесопатологического мониторинга: задачи раннего обнаружения очагов размножения стволовых вредителей и задачи систематического контроля жизненного состояния поражённых ими хвойных деревьев в таких очагах. Практическое значение также имеет решение третьей задачи – выявление сухостоя, формирующегося как вследствие заболеваний деревьев, так и из-за климатических изменений. Учет объемов сухостоя позволяет более точно оценивать запасы такой древесной фитомассы, объемы углеродных выбросов и их вклад в региональный углеродный баланс. Таким образом, многообразие хвойных пород деревьев и их лесопатологических состояний, а также огромные площади, занимаемые хвойными лесами в России, указывают на необходимость разработки современных методологических подходов и инструментов для оперативного лесопатологического мониторинга лесных экосистем с целью решения трех основных указанных выше лесопатологических задач.

Кратко остановимся на тех шагах, которые сделаны в направлении развития современной методологии и инструментов для реализации лесопатологического мониторинга хвойных

лесов. С начала XXI века в практике лесного хозяйства все чаще применяются технологии дистанционного зондирования Земли (ДЗЗ). Исследования показывают, что результаты высокоточной (разрешение 0,1 – 1,0 м/пиксель) аэро- и космической съемки, а тем более результаты сверхвысокоточной (разрешение 0,02 – 0,1 м /пиксель) съемки с помощью БПЛА с современными цифровыми фото – или видеокамерами позволяют выявлять даже локальные повреждения крон хвойных деревьев (van Lierop et al., 2015; Musolin et al., 2022; Кривец и др., 2018; Kerchev et al., 2022; Safonova et al., 2019; Керчев и др., 2021; Zhou et al., 2022; Chenari et al., 2017). Сравнительный анализ носителей такой аппаратуры для съемки указывает на экономическую эффективность съемки с использованием БПЛА по сравнению с применением самолетов и вертолетов, а также на меньшую зависимость съемки от атмосферных условий в случае применения БПЛА. Важным преимуществом современных технологий дистанционного зондирования является возможность выделения как спектральных, так и пространственных признаков повреждений крон деревьев (текстура и геометрия крон), что существенно повышает точность диагностики здоровья деревьев. Методологическая основа оперативного лесопатологического мониторинга предполагает применение космических аппаратов и БПЛА различных классов, оснащённых аппаратурой для RGB- и многоспектральной съемки высокого и сверхвысокого разрешения.

Сегодня анализ (интерпретация) полученных при лесопатологическом мониторинге изображений проводится с целью решения каждой из трех описанных выше задач полуавтоматизированным способом (эксперт ведет дешифрирование изображений с использованием вспомогательных программ) или автоматически с помощью специальных программно- или аппаратно-реализованных методов и алгоритмов классификации. Отметим, что при более перспективной автоматической классификации изображений решается задача мультиклассификации, когда по ряду признаков на изображении крон деревьев каждое дерево надо отнести к одному из нескольких классов. Именно такую задачу необходимо решать при оценке жизненного состояния пораженных вредителем деревьев в очаге его размножения (вторая основная задача лесопатологического мониторинга), когда на изображениях необходимо распознавать несколько классов (жизненных состояний) таких деревьев. Так, в случае поражения деревьев пихты *Abies Sibirica* (далее *A.Sibirica*) уссурийским полиграфом на изображениях надо распознать пять классов объектов: четыре класса жизненного состояния деревьев пихты *A.Sibirica* (разной степени поражения вредителем) и фон (деревья других пород и иные объекты земной поверхности). Можно видеть, что при решении двух других основных задач, возникающих при лесопатологическом мониторинге хвойных лесов, также используются результаты мультиклассификации изображений деревьев. Как показано в ряде исследований при мультиклассификации изображений хвойных деревьев традиционные модели и методы классификации дают ограниченную точность классификации деревьев отдельных классов (Денисов и др., 2016; Safonova et al., 2019). В связи с этим в последние годы наблюдается активное использование моделей и методов глубокого обучения, в частности сверточных нейронных сетей (СНС), продемонстрировавших довольно высокую эффективность при решении задач мультиклассификации на изображениях, пораженных вредителями хвойных деревьев (Xie et al., 2024; Керчев и др., 2021). Результаты исследований, изложенные в (Safonova et al., 2019; Kocon et al., 2022), свидетельствуют о том, что наибольший потенциал при решении задач мультиклассификации таких изображений имеют модели полносверточных сетей класса U-Net и их модификации.

В работе (Малкин, Марков, 2024) показано, что точность мультиклассификации деревьев на изображениях во многом зависит от качества исходных изображений. На практике при съемке на таких изображениях могут появляться случайные аддитивные и (или) импульсные помехи различной физической природы, что снижает точность мультиклассификации деревьев. Например, наличие импульсных помех с большой амплитудой на изображениях хвойных деревьев способно существенно исказить результаты их мультиклассификации и, в итоге, снизить достоверность оценки жизненного состояния древостоев. В этой связи актуальным направлением становится разработка и исследование моделей СНС, устойчивых к различного рода помехам на анализируемых изображениях хвойных деревьев. Особенно важно исследовать устойчивость перспективного класса полносверточных сетей U-Net.

Известно, что одним из подходов к повышению помехоустойчивости моделей СНС является использование робастных функций потерь (РФП), минимизирующих влияние помех на анализируемых изображениях при обучении таких моделей (Сивак, 2022). Цель данной работы заключается в исследовании устойчивости перспективной полносверточной модели СНС с РФП Рамсея при решении задачи мультиклассификации пораженных уссурийским полиграфом деревьев пихты на зашумленных импульсными помехами изображениях, полученных с БПЛА.

Объект и методика исследований

Объект исследований

В данной работе ставится и решается задача исследования устойчивости одной из перспективных моделей СНС к импульсным помехам на изображениях деревьев пихты *A. Sibirica*. В качестве объекта исследования используется модель полносверточной нейронной сети Mo-U-Net, которая хорошо себя зарекомендовала при решении задачи семантической сегментации (попиксельной классификации) изображений деревьев пихты, поражённых уссурийским полиграфом (Марков, Мачука, 2024). Отметим, что модель Mo-U-Net является модификацией известной классической модели полносверточной сети U-Net (Ronneberger et al., 2015). При модификации модели U-Net изменен размер входных и выходных карт признаков в соответствии с размерами имеющихся фрагментов изображений деревьев пихты *A. Sibirica*, при этом операции свертки не уменьшают размер карт признаков. Кроме того, вместо функции активации ReLU выбрана функция ELU. На рисунке 1 представлена архитектура модели СНС Mo-U-Net.




Рис. 1. Архитектура модели Mo-U-Net

Для оценки качества семантической сегментации (точности попиксельной классификации) каждого класса c деревьев применяется метрика IoU_c:

$$\text{IoU}_c = \frac{\text{TP}_c}{\text{TP}_c + \text{FP}_c + \text{FN}_c},$$

где TP_c – это истинно-положительные предсказания, FP_c – ложно-положительные предсказания, FN_c – ложно-отрицательные предсказания. Для оценки качества сегментации (точности классификации) деревьев также используется интегрированная метрика mean Intersection over Union (mIoU), рассчитываемая как среднее значение IoU_c по всем N классам деревьев:

$$\text{mIoU} = \frac{1}{N} \sum_{c=1}^N \text{IoU}_c.$$

Будем считать метрики IoU_c и mIoU мерами устойчивости к помехам исследуемой модели СНС. Значения IoU_c и mIoU больше 0,5 говорят о высоком качестве сегментации и, соответственно, о высокой устойчивости модели СНС к помехам.

В поставленной задаче исследований для обучения модели Mo-U-Net вместо функции потерь Focal Loss (Марков, Мачука, 2024) будем применять известную РФП Рамсея, которая представлена следующим выражением (Сивак, 2022):

$$\rho(z) = \frac{1 - (1 + \beta|z|)\exp(-\beta|z|)}{\beta^2},$$

где $z \in [0, 1]$ – величина ошибки предсказания, β – коэффициент функции потерь. Предполагается, что эта РФП позволит хотя бы частично уменьшить влияние импульсных помех при классификации изображений. Такая гипотеза основывается на результатах из работы (Малкин, Марков, 2024), показывающих, что использование РФП при задании квази-оптимального значения коэффициента β позволяет при обучении модели СНС сделать ее более устойчивой к импульсным помехам на изображениях. Производная функции потерь Рамсея представлена следующим выражением:

$$\rho'(z) = z \exp(-\beta|z|).$$

Данное выражение является непрерывным во всем множестве действительных чисел $\mathbb{R}$, что позволяет использовать РФП Рамсея для обучения модели Mo-U-Net по алгоритму обратного распространения ошибки.

Все изложенное позволило в итоге сформулировать задачу исследования устойчивости модели полносверточной сети Mo-U-Net с РФП Рамсея в случае импульсных помех на изображениях пораженных уссурийским полиграфом деревьев пихты *A. Sibirica*. При этом исследования должны проводиться при изменяющихся значениях как амплитуды импульсных помех, так и площади, занимаемой такими помехами на изображениях.

Для проведения исследований на языке программирования Python 3 с применением фреймворка PyTorch программно реализованы модель СНС Mo-U-Net и РФП Рамсея.

Наборы данных для проведения исследований

Для проведения исследований устойчивости модели Mo-U-Net использовались изображения с БПЛА участка деревьев пихты, пораженных уссурийским полиграфом. Этот участок расположен в Бакcharском лесничестве (Парбигское участковое лесничество, окрестности поселка Парбиг) Бакcharского района Томской области. Его координаты: 57°16'35,2" С 81°30'18,7"В. На рисунке 2 участок показан точкой А, справа на рисунке приведен фрагмент изображения этого участка.




Рис. 2. Местоположение изучаемого участка А деревьев пихты *A. Sibirica* в Томской области

Как следует из (Кривец и др., 2018; Musolin et al., 2022; Керчев и др., 2021), в 2016-2017 гг. Бакcharский район Томской области можно было охарактеризовать как действующий фронт инвазии уссурийского полиграфа, то есть на выбранном участке древостоя наблюдалась активная стадия освоения насаждений пихты этим вредителем. В августе 2017г. группой специалистов-лесопатологов Института мониторинга климатических и экологических систем СО РАН (ИМКЭС СО РАН) проводились наземные обследования и съемка участка с помощью фотокамеры, установленной на БПЛА DJI Phantom 3 Standart. Съемка производилась в видимом диапазоне электромагнитного спектра (RGB) с высоты 365 и 388 м в период с 7 по 28 августа 2017 г. Для этого участка получен ряд RGB-изображений высокого разрешения (0,1 м/пиксель).

При наземном обследовании этого участка леса специалистами - лесопатологами ИМКЭС СО РАН было установлено, что встречаемость дальневосточного короеда на деревьях пихты довольно высока и составила 87,4%, в том числе 43,2% деревьев отработано уссурийским

полиграфом единолично, еще 29,5% совместно с черным пихтовым усачом, а остальные 14,7 % – в комплексе с разными видами усачей и рогохвостами. Еще 10,5 % пихт отработаны без участия уссурийского полиграфа, преимущественно черным пихтовым усачом, а на 2,1% не было обнаружено признаков деятельности стволовых насекомых. Все это позволило специалистам охарактеризовать данный участок как очаг именно уссурийского полиграфа. Более того, визуально на полученных ими изображениях данный участок пихтового древостоя можно считать очагом стволового вредителя – уссурийского полиграфа, так как в отличие от очага филофага на этих изображениях видны красные кроны (признак сохранения хвои после гибели дерева пихты) (Керчев и др., 2021). С другой стороны, участки гибели пихтарников и кедрачей в год объедания сибирским шелкопрядом, приводящим к гибели насаждений, на изображениях выглядят серыми из-за голых стволов и ветвей в результате полной дефолиации. Эти результаты дистанционного обследования позволяют наряду с результатами наземного обследования характеризовать данный участок как очаг размножения именно уссурийского полиграфа.

Полученные в результате обследования участка леса сведения о поражении деревьев пихты применялись экспертами из ИМКЭС СО РАН при дешифрировании изображений с БПЛА. В процессе дешифрирования изображений эксперты выделили пять классов: четыре класса, отражающие жизненное состояние (степень поражения уссурийским полиграфом) пихтовых деревьев («Живое», «Отмирающее», «Свежий сухостой», «Старый сухостой»), и дополнительный класс «Фон», включающий деревья других пород, а также иные объекты земной поверхности. В итоге экспертами были сформированы эталонные карты сегментации, на которых кроны деревьев пихты оконтурены и цветом указана принадлежность каждого дерева к одному из четырех классов жизненного состояния деревьев. На рисунке 3 в качестве примера представлены результаты сегментации экспертами одного из изображений деревьев пихты *A. Sibirica*, покрывающего часть обследованного участка и названного тестовым, поскольку он использовался для создания тестовой выборки.




Рис. 3. Разметка изображения экспертом: а) тестовое изображение, полученное с БПЛА; б) сегментация тестового изображения экспертом

По исходным изображениям и полученным для них экспертами ИМКЭС СО РАН эталонными картами сегментации в Томском политехническом университете был создан набор данных. При его формировании каждое изображение и соответствующая ему карта

сегментации были разрезаны на фрагменты размером $256 \times 256 \times 3$ пикселей. В итоге созданный набор данных – это совокупность парных фрагментов размером $256 \times 256 \times 3$ пикселей. Далее набор данных был разделен на три выборки: обучающую (2004 фрагмента), валидационную (672 фрагмента) и тестовую (91 фрагмент). При анализе фрагментов этого набора данных было установлено, что они не содержат импульсных помех, что позволило использовать их при формировании нового набора данных, содержащего импульсные помехи на фрагментах обучающей выборки.

В итоге для решения задачи исследования устойчивости модели Mo-U-Net на основе описанного набора данных был создан новый набор данных с динамически настраиваемыми параметрами зашумления фрагментов импульсными помехами. Для этого на языке Python были разработаны соответствующие программные средства. Кратко рассмотрим, как с помощью этих средств динамически настраиваются параметры зашумления каждого фрагмента исходного набора данных. Первым из таких настраиваемых параметров является амплитуда A импульсных помех, значение которой показывает, во сколько раз увеличена амплитуда яркости исходного подлежащего зашумлению RGB-пикселя фрагмента. На рисунке 4 показаны визуальные результаты зашумления фрагмента импульсными помехами при постоянной площади зашумления, равной 25% площади фрагмента, и с различными величинами амплитуды A помех: 1,5, 2,0, 3,0. Из рисунка 4 следует ухудшение качества фрагмента изображения по мере роста амплитуды импульсных помех.





Рис. 4. Зашумление фрагмента изображения в наборе данных: а – исходный фрагмент без зашумления; зашумление 25% площади фрагмента при изменяющейся амплитуде A импульсных помех, равной: б – 1,5; в – 2,0; г – 3,0

Вторым параметром, динамически настраиваемым при задании импульсных помех при формировании нового набора данных, является площадь S зашумления помехами каждого фрагмента. Она задается в процентах (в долях) от общей площади фрагмента, равной $256 \times 256 \times 3$ пикселей. После задания в программе значения данного параметра для каждого фрагмента по равномерному закону распределения происходит случайный выбор пикселей, амплитуда яркости которых задается программно в соответствии принятой в эксперименте амплитудой A импульсных помех. Площадь числа пикселей, подлежащих зашумлению, не должна превышать заданную площадь S зашумления помехами фрагмента (долю зашумленных пикселей от общего числа пикселей фрагмента). На рисунке 5 приведена визуальная демонстрация влияния импульсных помех на фрагменте изображения на его качества при различных значениях площади S зашумления фрагмента помехами: 25%, 30%, 50%, при этом амплитуда A импульсных помех постоянна и составляет 1,5 от амплитуды

яркости исходных пикселей фрагмента. Из рисунка 5 видно ухудшение качества фрагмента изображения по мере увеличения площади S , занимаемой импульсными помехами.



а) б) в) г)
Рисунок 5 – Зашумление фрагмента изображения в наборе данных при различных значениях площади S зашумления: а – исходный фрагмент без зашумления; зашумление при амплитуде A помех, равной 1,5: б – 25% площади фрагмента; в – 35% площади фрагмента; г – 50% площади фрагмента

Планирование экспериментов

Рассмотрим этапы подготовки и проведения экспериментов, направленных на исследование устойчивости модели Mo-U-Net, обучаемой с использованием РФП Рамсея, к воздействию импульсных помех на фрагментах изображений деревьев пихты. Подготовительный этап включает формирование нового набора данных на основе исходного набора данных: во все фрагменты обучающей выборки искусственно добавляются импульсные помехи, тогда как фрагменты валидационной и тестовой выборок остаются без искажений помехами. Это позволяет изучать поведение модели в условиях импульсных помех на фрагментах изображений, при этом сохраняя возможность объективной оценки качества сегментации фрагментов с помощью модели по «чистым» фрагментам валидационной и тестовой выборок.

Степень зашумления фрагментов обучающей выборки нового набора данных регулируется динамически, как это показано выше, путем задания значений двух ключевых параметров A и S . Серии экспериментов организуются по схеме, когда значение одного из этих параметров фиксируется, а значения другого параметра варьируются в заданных пределах. В первой серии доля площади S зашумления фрагментов обучающей выборки фиксируется и равна 0,25, а амплитуда A помех варьируется: $A = 1,5; 2,0; 2,5; 3,0$. Это позволяет проследить зависимость точности классификации по метрикам IoUc и mIoU пораженных деревьев пихты моделью Mo-U-Net от амплитуды импульсных помех на фрагментах обучающей выборки и, в итоге, выявить устойчивость исследуемой модели к таким помехам. Для корректного сопоставления полученных результатов дополнительно проводится обучение и тестирование этой же модели на исходном наборе данных, то есть без внесённых во фрагменты импульсных помех. Во второй серии экспериментов амплитуда фиксирована на уровне $A = 1,5$, при этом доля S зашумления помехами площади фрагмента изменяется и принимает значения 0,10; 0,20; 0,25; 0,30; 0,40; 0,50.

Каждый эксперимент реализуется с использованием нового набора данных в два этапа. На первом этапе осуществляется обучение и валидация модели Mo-U-Net с РФП Рамсея. В процессе обучения модели Mo-U-Net изменяемым параметром выступает коэффициент β функции потерь Рамсея, значения которого выбираются из диапазона $[0,001; 9,000]$. Подбор квази-оптимального значения этого коэффициента выполняется с помощью алгоритма

байесовской оптимизации в течение 100 итераций. В соответствии с методикой (Малкин, Марков, 2024), квази-оптимальными считаются такие значения коэффициента β , при которых достигается максимальное значение метрики mIoU на валидационной выборке.

На втором этапе эксперимента исследуется устойчивость модели, обученной с найденным квази-оптимальным значением β , на тестовой выборке. По итогам анализа полученных результатов будут определяться рекомендации по применению модели Mo-U-Net с РФП Рамсея в случае импульсных помех на фрагментах изображений пораженных деревьев пихты.

Результаты исследований и их обсуждение

На рисунке 6 в качестве примера представлены результаты вычисления коэффициента β при обучении и валидации модели Mo-U-Net с РФП Рамсея на зашумлённых фрагментах со следующими заданными значениями параметров помех: доля площади зашумления $S = 0,25$, амплитуда A помех – 1,5. Порядковым номерам (номерам итераций) на рисунке 5 для этого эксперимента соответствуют полученные по алгоритму байесовской оптимизации наборы гиперпараметров, включая коэффициент β . В этом примере на 81-ой итерации было определено квази-оптимальное значение коэффициента β , равное 0,3233, при котором модель Mo-U-Net показывает максимальное значение точности классификации по метрике mIoU на валидационной выборке, равное 0,61. Такая же процедура обучения и валидации модели с целью определения квази-оптимальных значений гиперпараметров проводилась для всех запланированных экспериментов первой и второй серии.




Рис. 6. Обучение и валидация модели при доле зашумления 0,25 площади фрагментов обучающей выборки и при амплитуде импульсных помех 1,5

В рамках проводимых экспериментов первой серии исследовалась точность классификации деревьев пихты моделью Mo-U-Net с РФП Рамсея по метрикам IoUc и mIoU на фрагментах тестовой выборки в зависимости от амплитуды импульсных помех. При этом фиксируется доля площади зашумления, равная 0,25, фрагментов обучающей выборки. В таблице 1 представлены результаты этих исследований в виде значений метрик IoUc и mIoU на тестовой выборке. Для сравнения в таблице 1 приведен результат исследования модели Mo-U-Net, когда она обучалась и валидировалась на выборках исходного набора данных без зашумления фрагментов (площадь зашумления фрагментов помехами 0%, амплитуды пикселей не

меняются, т.е. равны 1). В таблице 1 также показаны квази-оптимальные значения коэффициента β РФП Рамсея, полученные после обучения и валидации этой модели для случаев незашумленных и зашумленных фрагментов обучающих выборок. Можно сделать вывод, что эти квазиоптимальные значения коэффициента β зависят от амплитуды импульсных помех на фрагментах обучающей выборки.

Таблица 1

Значения метрик IoUc и mIoU на тестовой выборке в зависимости от амплитуды А импульсных помех при постоянной доле площади зашумления фрагментов, равной 0,25

Амплитуда А импульсных помех	Квази-оптимальное значение коэф-та β	IoUc					mIoU
		Живое	Отмирающее	Свежий сухостой	Старый сухостой	Фон	
1,0 (нет помех)	1,3357	0,70	0,27	0,74	0,64	0,85	0,64
1,5	0,3233	0,58	0,26	0,66	0,60	0,90	0,60
2,0	1,4744	0,66	0,33	0,72	0,59	0,82	0,62
2,5	1,3047	0,69	0,27	0,64	0,53	0,86	0,60
3,0	1,0952	0,61	0,39	0,73	0,57	0,81	0,62

Из таблицы 1 также следует, что модель Mo-U-Net с РФП Рамсея демонстрирует незначительное снижение устойчивости к импульсным помехам по метрике mIoU на 3% – 6% с ростом амплитуды помех А от 1,5 до 3,0. Однако значения этой метрики превышают 0,5, что говорит об удовлетворительном качестве работы модели в условиях таких помех. Результаты по точности классификации по метрике IoUc деревьев классов «Живое», «Свежий сухостой» и «Старый сухостой», а также для класса «Фон» превышают пороговое значение 0,5, что говорит об устойчивости модели к импульсным помехам применительно к этим классам. Однако для деревьев класса «Отмирающее» значения метрики IoUc на тестовой выборке для всех вариантов задания в экспериментах значений амплитуд помех значительно меньше порога 0,5, что говорит о низкой устойчивости модели к помехам в этом случае.

В таблице 2 приведены результаты второй серии экспериментов, в ходе которой исследуется устойчивость модели в случае различной площади S зашумления фрагментов обучающей выборки при постоянной амплитуде зашумления, равной 1,5. Для проведения сравнительного анализа с этими результатами в первой строке таблицы приведены результаты для случая обучения модели на фрагментах без помех.

Таблица 2

Значения метрик IoUc и mIoU на тестовой выборке в зависимости от площади S зашумления фрагмента при постоянной амплитуде импульсных помех, равной 1,5

Площадь S зашумления фрагмента, в долях	Квази-оптимальное значение коэф-та β	IoUc					mIoU
		Живое	Отмирающее	Свежий сухостой	Старый сухостой	Фон	
0,00 (нет помех)	1,3357	0,70	0,27	0,74	0,64	0,85	0,64
0,10	0,9672	0,67	0,32	0,74	0,62	0,85	0,64
0,20	1,0581	0,69	0,30	0,68	0,62	0,87	0,63
0,25	0,3233	0,58	0,26	0,66	0,60	0,90	0,60
0,30	1,3519	0,61	0,26	0,71	0,59	0,83	0,60
0,40	0,8745	0,57	0,27	0,69	0,51	0,81	0,57
0,50	0,9934	0,60	0,30	0,70	0,51	0,79	0,58

Из результатов, представленных в таблице 2, следует, что квазиоптимальные значения коэффициента β для РФП Рамсея также зависят от такого параметра как площадь зашумления фрагмента. Видим, что по метрике mIoU модель демонстрирует плавное снижение устойчивости на 0% – 9% к помехам с ростом доли площади зашумления от 0,10 до 0,50. Отметим, что в случае зашумления 10% площади фрагментов обучающей выборки значение метрики mIoU на тестовой выборке совпадает с таковым значением в случае обучения модели на фрагментах без импульсных помех. Это можно интерпретировать как применение техники аугментации данных при обучении моделей, когда незначительная доля помех на фрагменте не оказывает негативного влияния на точность классификации, а позволяет получить новый фрагмент для обучения модели. Для деревьев класса «Отмирающее» значения метрики IoUc на тестовой выборке для всех вариантов задания в экспериментах доли площади зашумления значительно меньше порога 0,5.

Из полученных результатов исследований, представленных в таблицах 1 и 2, следует, что модель Mo-U-Net с РФП Рамсея для четырех классов из пяти является устойчивой при решении задачи мультиклассификации пораженных деревьев пихты *A. Sibirica* на зашумленных импульсными помехами изображениях. Однако, для деревьев пихты *A. Sibirica* класса «Отмирающее» значения метрики IoUc не превышают 0,5, что говорит о неустойчивости модели к помехам в случае деревьев данного класса жизненного состояния. Возможная причина такого результата - дисбаланс классов, то есть малое число деревьев класса «Отмирающее» относительно числа деревьев других классов в обучающей выборке исходного набора данных.

Заключение

Программно-реализована модель полносверточной нейронной сети Mo-U-Net с РФП Рамсея. Это позволило провести исследование ее устойчивости к импульсным помехам на изображениях пораженных уссурийским полиграфом деревьев пихты *A. Sibirica* с использованием разработанного набора данных с зашумленными импульсными помехами фрагментами обучающей выборки. Исследования показали, что по метрике mIoU модель демонстрирует плавное снижение устойчивости к помехам с ростом доли площади зашумления фрагментов, в то время как увеличение амплитуды импульсных помех при доле площади зашумления S , равной 0,25, оказывает слабое влияние на снижение ее устойчивости.

Показано, что результаты исследований модели Mo-U-Net с РФП Рамсея по точности классификации по метрике IoU выше порогового значения 0,5 для деревьев пихты *A. Sibirica* классов «Живое», «Свежий сухостой» и «Старый сухостой», а также для класса «Фон». Это позволяет считать такую модель устойчивой к импульсным помехам на изображениях и рекомендовать ее к практическому применению для классификации деревьев таких классов на изображениях в условиях импульсных помех. Однако при классификации на изображениях с импульсными помехами с помощью этой модели деревьев пихты *A. Sibirica* класса «Отмирающее» значения метрики IoUc не превышают 0,5, что говорит о неустойчивости модели к таким помехам и не позволяет рекомендовать ее для классификации деревьев пихты *A. Sibirica* данного класса.

Библиографический список

1. Денисов С.А. Опыт применения квадрокоптера для мониторинга возобновления леса / С.А. Денисов, А.А. Домрачев, А.С. Елсуков // Вестник Поволжского государственного технологического университета. Сер.: Лес. Экология. Природопользование. – 2016. – № 4 (32). – С. 34–46.

2. Керчев И.А. Семантическая сегментация поврежденных деревьев пихты на снимках с беспилотных летательных аппаратов / И.А. Керчев, К.А. Маслов, Н.Г. Марков, О.С. Токарева // Современные проблемы дистанционного зондирования Земли из космоса. – 2021. – Т. 18, № 1. – С. 116–126. DOI: 10.21046/2070-7401-2021-18-1-116-126.
3. Кривец С.А. Технология мониторинга пихтовых лесов в зоне инвазии уссурийского полиграфа в Сибири. / С.А. Кривец, Э.М. Бисирова, Е.С. Волкова, Н.М. Дебков, И.А. Керчев, М.А. Мельник, А.Н. Никифоров, Н.А. Чернова // Томск: УМИИУМ, 2018. – 74 с.
4. Малкин А.Ю. Помехоустойчивость модели полносверточной нейронной сети U-Net при семантической сегментации деревьев пихты на зашумленных снимках с БПЛА / А.Ю. Малкин, Н.Г. Марков // Доклады ТУСУР. – 2024. – Т. 27, № 2. – С. 64–70. DOI: 10.21293/1818-0442-2024-27-2-64-70.
5. Марков Н.Г. Модели и методы глубокого обучения для решения задач дистанционного мониторинга лесных ресурсов / Н.Г. Марков, К. Мачука // Известия Томского политехнического университета. Инжиниринг георесурсов. – 2024. – Т. 335, № 6. – С. 55–74. DOI: 10.18799/24131830/2024/6/4600.
6. Сивак М.А. Робастное обучение нейронных сетей с простой архитектурой для решения задач классификации: дис... канд. техн. наук: 05.13.17. Новосибирск: НГТУ, 2022. – 111 с.
7. Bystrov S.O. First record of the four-eyed fir bark beetle *Polygraphus proximus* Blandford, 1894 (Coleoptera, Curculionidae: Scolytinae) from Irkutsk province Russia / S.O. Bystrov, I.A. Antonov // Entomological review. – 2019. – V. 99. – P. 54–55. DOI: 10.1134/S001387381901007X.
8. Chang W.Y. Economic impacts of forest pests: a case study of spruce budworm outbreaks and control in New Brunswick, Canada / W.Y. Chang, V.A. Lantz, C.R. Hennigar, D.A. MacLean // Canadian journal of forest research. – 2012. – V. 42. – P. 490–505. DOI: 10.1139/x11-190.
9. Chenari A. Woodland mapping at single-tree levels using object-oriented classification of UAV images / A. Chenari, Y. Erfanifard, M. Dehghani, H.R. Pourghasemi // The international archives of the photogrammetry, remote sensing and spatial information sciences. – 2017. – Vol. XLII-4/W4. – P. 43–49. DOI: 10.5194/isprs-archives-XLII-4-W4-43-2017.
10. Dedyukhin S.V. Finding of the bark beetle *Polygraphus proximus* Blandford, 1894 (Coleoptera, Curculionidae: Scolytinae) in Udmurtia / S.V. Dedyukhin, V.V. Titova // Russian journal of biological invasions. – 2021. – Vol. 12. – P. 258–263. DOI: 10.1134/S2075111721030048.
11. Kerchev I.A. Distribution of the small spruce bark beetle *Ips amitinus*(Eichhoff, 1872) in Western Siberia / I.A. Kerchev, S.A. Krivets, E.M. Bisirova, N.A. Smirnov // Russian journal of biological invasions. – 2022. – Vol. 13. – P. 58–63. DOI: 10.1134/S2075111722010076.
12. Kocon K. Comparison of CNN-based segmentation models for forest type classification / K. Kocon, M. Krämer, H.M. Würz // AGILE: GIScience Series. – 2022. – Vol. 3. – P. 42.
13. Lee S. Detection of damaged pine tree by the pine wilt disease using UAV image / S. Lee, S. Park, G. Baek, H. Kim, C. Lee // Korean journal of remote sensing. – 2019. – Vol. 35. – P. 359–737. DOI: 10.7780/kjrs.2019.35.3.2.
14. Musolin D.L. Invasive pests of forests and urban trees in Russia: origin pathways, damage, and management / D.L. Musolin, N.I. Kirichenko, N.N. Karpun, M.Y. Mandelshtam, A.V. Selikhovkin, E.N. Zhuravleva, E.V. Aksenenko, V.B. Golub, I.A. Kerchev, R. Vasaitis, M.G. Volkovitch // Forests. – 2022. – Vol. 13. – P. 521. DOI: 10.3390/f13040521.
15. Onishi M. Automatic classification of trees using a UAV onboard camera and deep learning / M. Onishi, T. Ise // arXiv preprint arXiv:1804.10390. – 2018.
16. Ronneberger O. U-Net: Convolutional networks for biomedical image segmentation / O. Ronneberger, P. Fischer, T. Brox // Medical image computing and computer-assisted intervention. – 2015. – Vol. 9351.
17. Safonova A. Detection of fir trees (*Abies sibirica*) damaged by the bark beetle in unmanned aerial vehicle images with deep learning / A. Safonova, S. Tabik, D. Alcaraz-Segura, A. Rubtsov, Y. Maglins, F. Herrera // Remote sensing. – 2019. – Vol. 11. – P. 643–662. DOI: 10.3390/rs11060643.
18. van Lierop P. Global forest area disturbance from fire, insect pests, diseases and severe weather events / P. van Lierop, E. Lindquist, S. Sathyapala, G. Franceschini // Forest ecology and management. – 2015. – Vol. 352. – P. 78–88. DOI: 10.1016/j.foreco.2015.06.010.
19. Xie W. Early-stage pine wilt disease detection via multi-feature fusion in UAV imagery / W. Xie, H. Wang, W. Liu, H. Zang // Forests. – 2024. Vol. 15. – P. 171.
20. Zhou H. Surveillance of pine wilt disease by high resolution satellite / H. Zhou, X. Yuan, H. Zhou, H. Shen, L. Ma, L. Sun // Journal of forestry research. – 2022. – Vol. 33. – P. 1401–1408. DOI: 10.1007/s11676-021-01423-8.

References

1. Denisov S.A., Domrachev A.A., Elsukov A.S. Opyt primeneniya kvadrokoptera dlya monitoringa vozobnovleniya lesa (Experience of using a quadcopter for forest regeneration monitoring), *Vestnik Povolzhskogo gosudarstvennogo tekhnologicheskogo universiteta. Seriya: Les. Ekologiya. Prirodopol'zovanie*, 2016, No. 4 (32), pp. 34–46.
2. Kerchev I.A., Maslov K.A., Markov N.G., Tokareva O.S. Semanticheskaya segmentatsiya povrezhdennykh derev'ev pikhty na snimkakh s bespilotnykh letatel'nykh apparatov (Semantic segmentation of damaged fir trees on UAV

- images), *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2021, Vol. 18, No. 1, pp. 116–126. DOI: 10.21046/2070-7401-2021-18-1-116-126.
3. Krivets S.A., Bisirova E.M., Volkova E.S., Debkov N.M., Kerchev I.A., Mel'nik M.A., Nikiforov A.N., Chernova N.A. Tekhnologiya monitoringa pikhtovykh lesov v zone invazii ussuriyskogo poligrafa v Sibiri (Technology for monitoring fir forests in the area of invasion of the Ussuri polygraph in Siberia), Tomsk, UMIUM, 2018, 74 p.
 4. Malkin A.Yu., Markov N.G. Pomekhoustoychivost' modeli polnosvertochnoy neyronnoy seti U-Net pri semanticheskoy segmentatsii derev'ev pikhty na zashumlennykh snimkakh s BPLA (Noise immunity of the U-Net model in semantic segmentation of fir trees on noisy UAV images), *Doklady TUSUR*, 2024, Vol. 27, No. 2, pp. 64–70. DOI: 10.21293/1818-0442-2024-27-2-64-70.
 5. Markov N.G., Machuka K. Modeli i metody glubokogo obucheniya dlya resheniya zadach distantsionnogo monitoringa lesnykh resursov (Models and methods of deep learning for solving problems of remote monitoring of forest resources), *Izvestiya Tomskogo politekhnicheskogo universiteta. Inzhiniring georesursov*, 2024, Vol. 335, No. 6, pp. 55–74. DOI: 10.18799/24131830/2024/6/4600.
 6. Sivak M.A. Robastnoe obuchenie neyronnykh setey s prostoy arkhitekturoy dlya resheniya zadach klassifikatsii (Robust training of neural networks with simple architecture for solving classification tasks), PhD Thesis, Novosibirsk, NSTU, 2022, 111 p.
 7. Bystrov S.O., Antonov I.A. First record of the four-eyed fir bark beetle *Polygraphus proximus* Blandford, 1894 (Coleoptera, Curculionidae: Scolytinae) from Irkutsk province Russia, *Entomological Review*, 2019, Vol. 99, pp. 54–55. DOI: 10.1134/S001387381901007X.
 8. Chang W.Y., Lantz V.A., Hennigar C.R., MacLean D.A. Economic impacts of forest pests: a case study of spruce budworm outbreaks and control in New Brunswick, Canada, *Canadian Journal of Forest Research*, 2012, Vol. 42, pp. 490–505. DOI: 10.1139/x11-190.
 9. Chenari A., Erfanifard Y., Dehghani M., Pourghasemi H.R. Woodland mapping at single-tree levels using object-oriented classification of UAV images, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2017, vol. XLII-4/W4, pp. 43–49. DOI: 10.5194/isprs-archives-XLII-4-W4-43-2017.
 10. Dedyukhin S.V., Titova V.V. Finding of the bark beetle *Polygraphus proximus* Blandford, 1894 (Coleoptera, Curculionidae: Scolytinae) in Udmurtia, *Russian Journal of Biological Invasions*, 2021, Vol. 12, pp. 258–263. DOI: 10.1134/S2075111721030048.
 11. Kerchev I.A., Krivets S.A., Bisirova E.M., Smirnov N.A. Distribution of the small spruce bark beetle *Ips amitinus* (Eichhoff, 1872) in Western Siberia, *Russian Journal of Biological Invasions*, 2022, Vol. 13, pp. 58–63. DOI: 10.1134/S2075111722010076.
 12. Kocon K., Krämer M., Würz H.M. Comparison of CNN-based segmentation models for forest type classification, *AGILE: GIScience Series*, 2022, Vol. 3, p. 42.
 13. Lee S., Park S., Baek G., Kim H., Lee C. Detection of damaged pine tree by the pine wilt disease using UAV image, *Korean Journal of Remote Sensing*, 2019, vol. 35, pp. 359–373. DOI: 10.7780/kjrs.2019.35.3.2.
 14. Musolin D.L., Kirichenko N.I., Karpun N.N., Mandelshtam M.Y., Selikhovkin A.V., Zhuravleva E.N., Aksenenko E.V., Golub V.B., Kerchev I.A., Vasaitis R., Volkovitch M.G. Invasive pests of forests and urban trees in Russia: origin pathways, damage, and management, *Forests*, 2022, Vol. 13, p. 521. DOI: 10.3390/f13040521.
 15. Onishi M., Ise T. Automatic classification of trees using a UAV onboard camera and deep learning, *arXiv preprint arXiv:1804.10390*, 2018.
 16. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for biomedical image segmentation, *Medical Image Computing and Computer-Assisted Intervention*, 2015, Vol. 9351.
 17. Safonova A., Tabik S., Alcaraz-Segura D., Rubtsov A., Maglinets Y., Herrera F. Detection of fir trees (*Abies sibirica*) damaged by the bark beetle in unmanned aerial vehicle images with deep learning, *Remote Sensing*, 2019, Vol. 11, pp. 643–662. DOI: 10.3390/rs11060643.
 18. van Lierop P., Lindquist E., Sathyapala S., Franceschini G. Global forest area disturbance from fire, insect pests, diseases and severe weather events, *Forest Ecology and Management*, 2015, Vol. 352, pp. 78–88. DOI: 10.1016/j.foreco.2015.06.010.
 19. Xie W., Wang H., Liu W., Zang H. Early-stage pine wilt disease detection via multi-feature fusion in UAV imagery, *Forests*, 2024, Vol. 15, p. 171.
 20. Zhou H., Yuan X., Zhou H., Shen H., Ma L., Sun L. Surveillance of pine wilt disease by high resolution satellite, *Journal of Forestry Research*, 2022, Vol. 33, pp. 1401–1408. DOI: 10.1007/s11676-021-01423-8.