

## МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ

## MATHEMATICAL MODELING

Научная статья

УДК 004.8

doi: 10.17223/19988605/73/4

**Исследование устойчивости моделей полносверточных нейронных сетей с робастными функциями потерь к импульсным помехам на изображениях****Артем Юрьевич Малкин<sup>1</sup>, Николай Григорьевич Марков<sup>2</sup>**<sup>1, 2</sup> *Национальный исследовательский Томский политехнический университет, Томск, Россия*<sup>1</sup> *malkin@tpu.ru*<sup>2</sup> *markovng@tpu.ru*

**Аннотация.** Исследуется устойчивость моделей полносверточных нейронных сетей mo-u-net, полученных путем использования известных робастных функций потерь (РФП), к импульсным помехам на изображениях деревьев пихты, пораженных уссурийским полиграфом. Для исследования устойчивости применяются метрики точности классификации деревьев IoUc и mIoU. Для исследования моделей создан датасет, фрагменты обучающей выборки которого имеют искусственным образом внесенные импульсные помехи. Анализ результатов исследования каждой из семи моделей показал, что модель с РФП Уэлша является наиболее предпочтительной при работе с зашумленными изображениями.

**Ключевые слова:** семантическая сегментация (попиксельная классификация) изображения; импульсная помеха; робастная функция потерь; помехоустойчивость сверточной нейронной сети.

**Для цитирования:** Малкин А.Ю., Марков Н.Г. Исследование устойчивости моделей полносверточных нейронных сетей с робастными функциями потерь к импульсным помехам на изображениях // Вестник Томского государственного университета. Управление, вычислительная техника и информатика. 2025. № 73. С. 30–40. doi: 10.17223/19988605/73/4

Original article

doi: 10.17223/19988605/73/4

**Research of resistance of fully convolutional neural network models with robust loss functions to impulse noise in images****Artem Yu. Malkin<sup>1</sup>, Nikolai G. Markov<sup>2</sup>**<sup>1, 2</sup> *National Research Tomsk Polytechnic University, Tomsk, Russian Federation*<sup>1</sup> *malkin@tpu.ru*<sup>2</sup> *markovng@tpu.ru*

**Abstract.** The resistance of Mo-U-Net full-field neural network models, obtained by using known robust loss functions (RLFs), to impulse noise on images of fir trees affected by the Ussuri polygraph is investigated using the tree classification accuracy metrics IoUc and mIoU. To investigate the models, a dataset was created with fragments of the training sample having artificially introduced impulse noise. The analysis of the results of each of the seven models showed that the model with Welch's RLF is the most preferable when working with noisy images.

**Keywords:** semantic segmentation (pixel-by-pixel classification) of images; impulse noise; robust loss function; noise immunity of convolutional neural network.

**For citation:** Malkin, A.Yu., Markov, N.G. (2025) Research of resistance of fully convolutional neural network models with robust loss functions to impulse noise in images. *Vestnik Tomskogo gosudarstvennogo universiteta. Upravlenie, vychislitel'naja tehnika i informatika – Tomsk State University Journal of Control and Computer Science*. 73. pp. 30–40. doi: 10.17223/19988605/73/4

## Введение

Управление лесами, концепция которого соотносит экологическую целостность лесов с потребностями человека, во многом зависит от точной и актуальной информации о состоянии лесов, получаемой при их мониторинге [1, 2]. Технологии мониторинга лесов значительно эволюционировали с годами на пути от трудоемких наземных обследований к более сложным методам дистанционного зондирования Земли (ДЗЗ). Это обусловлено необходимостью использования более оперативных и экономически эффективных методов оценки состояния и управления лесными ресурсами, занимающими большие площади. Сегодня все чаще выполняют оперативный мониторинг лесов с помощью современных систем ДЗЗ. При этом используют высокоточную съемку деревьев с помощью фото- и (или) видеокамер, установленных на космических аппаратах, самолетах (вертолетах) или беспилотных летательных аппаратах (БПЛА), а затем проводят дешифрирование полученных изображений [2–5]. Однако специалисты лесной отрасли постоянно сталкиваются с отсутствием современного инструментария – моделей, методов и информационных систем для автоматического дешифрирования таких изображений. Одним из актуальных направлений, позволяющих решать проблему отсутствия такого инструментария, является создание и использование современных моделей сверточных нейронных сетей (СНС) [5, 6]. Эти модели должны оперативно и с приемлемой точностью решать задачи семантической сегментации (попиксельной классификации) изображений, полученных при дистанционном мониторинге лесов.

Особые требования по точности классификации предъявляются к моделям СНС, используемым для дешифрирования изображений, получаемых при оперативном лесопатологическом мониторинге хвойных лесов. В этих случаях на изображениях необходимо оценить степень поражения (состояние здоровья) каждого дерева хвойной породы, заселенного тем или иным насекомым-вредителем. Для этого, учитывая значительное число состояний здоровья пораженных деревьев, необходимы модели СНС, позволяющие решать с высокой точностью задачу мультиклассификации деревьев на таких изображениях [6, 7]. При этом практически важным для сохранения хвойных лесов является обнаружение деревьев, находящихся на ранней стадии поражения вредителями, поскольку для них своевременно могут быть проведены эффективные фитосанитарные мероприятия.

В последние годы лесопатологический мониторинг лесов ведется с использованием самых разных методов ДЗЗ, но предпочтение чаще всего отдается фотосъемке с использованием БПЛА самолетного или вертолетного типа. При проведении такой съемки в результате сбоя аппаратуры получаемые изображения крон деревьев могут иметь помехи в виде случайных аддитивных шумов и (или) импульсных помех. Более того, если используется передача изображений по радиоканалу с БПЛА в наземный пункт сбора данных, то на изображениях могут появиться дополнительные помехи. В любом случае возникает задача оценки влияния таких помех на точность мультиклассификации пораженных деревьев на изображениях. Иными словами, необходимо выявить устойчивость используемых для мультиклассификации моделей СНС к тем или иным помехам на изображениях.

Анализ результатов ряда исследований [8, 9] показал, что для повышения устойчивости моделей СНС при работе с зашумленными изображениями применяется два основных подхода. В рамках первого из них на основе известных моделей СНС создаются модели со специальными архитектурами, устойчивыми к различным помехам. Так, в работе [8] в архитектуры базовых моделей ResNet-50 и ImageNet встраивается модуль релевантной фокусировки признаков (Relevant Feature Focusing; ReFF), который генерирует аннотации релевантных признаков. Это позволяет новым моделям СНС повысить устойчивость к изменению распределения объектов на изображениях, вызванному помехами. В результате исследований авторами установлено, что включение модуля ReFF в изучаемые модели СНС дает положительный результат даже при наличии существенного объема нерелевантных данных и малом

количестве аннотаций для классов объектов: прирост точности классификации по метрике Accuracy в условиях помех составляет до 15% относительно случаев, когда модуль ReFF не включается в модели. К сожалению, авторы не дают конкретных рекомендаций по проектированию модулей, подобных модулю ReFF, для случаев современных моделей СНС с более сложными архитектурами.

Другим основным подходом к повышению устойчивости моделей СНС к помехам на входных изображениях является применение робастных (устойчивых к шумам) функций потерь при обучении этих моделей. Использование робастных функций потерь (РФП) дает возможность при правильно подобранном коэффициенте потерь этих функций уменьшить значение ошибки в методе ее обратного распространения и, соответственно, повысить точность классификации объектов, в том числе в условиях помех. Автор [9] использовал довольно широкий набор РФП при решении задачи классификации ирисов Фишера на изображениях с помощью нейронных сетей прямого распространения: функции потерь Хьюбера, Тьюки, Рамсея, Коши и др. При этом проводился поиск интервалов значений коэффициента потерь  $\beta$  исследуемых РФП, которые затем можно было рекомендовать для обучения нейронных сетей при решении задачи классификации ирисов Фишера. Отметим, что некоторые РФП помимо обучения нейронных сетей прямого распространения применялись также для обучения рекуррентных сетей [10] и СНС [11–13] при решении задач семантической сегментации и классификации объектов на изображениях. Результаты исследований моделей нейронных сетей с различными РФП, изложенные в работах [9–13], указывают на перспективность робастного подхода к повышению устойчивости моделей глубокого обучения в условиях помех. На него и будем опираться в наших исследованиях.

Цель данной работы – проведение исследований устойчивости моделей полносверточных нейронных сетей класса U-Net [14] с различными РФП при решении задач мультиклассификации в условиях импульсных помех на изображениях. В качестве примера таких изображений используются реальные снимки высокого разрешения с фотокамеры на БПЛА деревьев пихты сибирской *Abies sibirica* (далее – *A. sibirica*), пораженных стволовым вредителем – уссурийским полиграфом *Polygraphus proximus* (далее – *P. Proximus*). Перед обучением указанных моделей СНС в эти изображения искусственным образом вводятся импульсные помехи. Исследования устойчивости обученных моделей выполняются при различных амплитудах импульсных помех и площади зашумления изображений.

### 1. Задача исследования устойчивости моделей полносверточных нейронных сетей

В работе [5] показано, что среди моделей СНС для решения задач мультиклассификации пораженных хвойных деревьев на изображениях по критериям ‘точность классификации – скорость выполнения модели’ предпочтение следует отдать полносверточным нейронным сетям. В последние годы все чаще применяют классическую модель полносверточной нейронной сети U-Net [14] и модели на ее основе, позволяющие решать задачи попиксельной классификации изображений. Так, в [5, 7, 15] приведены обнадеживающие результаты мультиклассификации изображений пораженных уссурийским полиграфом *P. proximus* деревьев пихты *A. sibirica* (пять классов) и пораженных союзным короедом *Ips amitinus* деревьев кедра *Pinus sibirica* (шесть классов), полученные с помощью моделей на основе классической модели U-Net. Однако в случае использования классической модели U-Net наблюдается низкая точность классификации одного (случай деревьев *A. sibirica*) или двух (случай деревьев *Pinus sibirica*) промежуточных классов (состояний здоровья) деревьев [7, 15], что не устраивает специалистов лесной отрасли. Распознавание деревьев в промежуточных состояниях (состояния между здоровым деревом и старым сухостоем) имеет большое практическое значение для их сохранения, поскольку выявленные деревья могут быть своевременно подвергнуты эффективным санитарно-оздоровительным мероприятиям. Поэтому в данной работе предлагается исследовать на устойчивость к импульсным помехам модель Mo-U-Net, детально описанную в [5]. Она является модификацией модели U-Net и показывает, как это следует из [5, 16], практически приемлемую точность классификации хвойных деревьев, находящихся в промежуточных состояниях здоровья. В качестве функции потерь в ней использовалась функция Focal Loss [5].

При обучении модели Mo-U-Net на зашумленных импульсными помехами изображениях будут использоваться следующие семь РФП [9]: Коши, Рамсея, Хьюбера, Эндрюса, Geman-McCluer, Уэлша и

Мешалкина (табл. 1). Из работы [9] следует, что производные от этих робастных функций являются непрерывными на множестве вещественных чисел, и это позволяет использовать такие функции в качестве функций потерь в алгоритме обратного распространения ошибки при обучении модели Mo-U-Net. Заметим, по сути, обучению и исследованию подлежит семь полносверточных моделей нейронных сетей, полученных путем замены у модели Mo-U-Net функции потерь Focal Loss на ту или иную РФП из указанных в табл. 1. Для этого разрабатывается и программно реализуется модификация алгоритма обратного распространения ошибки, учитывающая особенности используемых РФП.

Таблица 1

Робастные функции потерь и их производные

| Функция потерь $\rho(z)$   | Производная функции потерь $\rho'(z)$  |
|--|--|
| Коши   |  |
| $\ln\left(\frac{1}{2}\left(\frac{z}{\beta}\right)^2 + 1\right)$  | $\frac{z}{\frac{1}{2}z^2 + \beta^2}$   |
| Рамсея   |  |
| $\frac{1 - (1 + \beta z )\exp(-\beta z )}{\beta^2}$  | $z \exp\{-\beta z \}$  |
| Хьюбера  |  |
| $\begin{cases} \frac{z^2}{2}, &  z  \leq \beta, \\ \beta z  - \frac{\beta^2}{2}, &  z  > \beta \end{cases}$          | $\begin{cases} z, &  z  \leq \beta, \\ -\beta, & z < \beta, \\ \beta, & z < \beta \end{cases}$ |
| Эндрюса  |  |
| $\begin{cases} \beta\left(1 - \cos\frac{z}{\beta}\right), &  z  < \pi\beta, \\ 2\beta, &  z  \geq \beta \end{cases}$ | $\begin{cases} \sin\frac{z}{\beta}, &  z  < \pi\beta, \\ 0, &  z  \geq \beta \end{cases}$      |
| Geman-McCluer  |  |
| $\frac{z^2/\beta}{1 + z^2/\beta}$  | $\frac{2z}{\beta(1 + z^2/\beta)^2}$  |
| Уэлша  |  |
| $1 - \exp\left(-\frac{1}{2}\left(\frac{z}{\beta}\right)^2\right)$  | $\frac{1}{\beta^2} z \exp\left(-\frac{1}{2}\left(\frac{z}{\beta}\right)^2\right)$              |
| Мешалкина  |  |
| $\beta^{-1}\left(1 - \exp\left(\frac{-\beta z^2}{2}\right)\right)$   | $\exp\left(\frac{-\beta z^2}{2}\right)z$   |

Для обучения, валидации и исследования устойчивости каждой из семи полносверточных моделей будет использоваться датасет, созданный сотрудниками Института мониторинга климатических и экологических систем СО РАН и Томского политехнического университета [7]. При его формировании использовались RGB-изображения пораженных деревьев *A. sibirica* высокого разрешения (0,1 м), полученные летом 2017 г. в Томской области с использованием фотокамеры, установленной на БПЛА DJI Phantom 3 Standart. При дешифрировании этих изображений экспертами выделялось четыре класса состояния здоровья деревьев: «Живое», «Отмирающее», «Свежий сухостой» и «Старый сухостой», а также пятый класс – «Фон» (деревья других пород и иные объекты земной поверхности), что позволило получить эталонные карты сегментации. Датасет представляет собой совокупность фрагментов исходных изображений размером  $256 \times 256 \times 3$  пикселей и соответствующих им фрагментов эталонных карт. Он поделен на три выборки: обучающая – 2 004 фрагмента, валидационная – 672 фраг-

мента, и тестовая – 91 фрагмент. На основе этого датасета должен создаваться новый датасет, фрагменты которого имеют импульсные помехи, вносимые по описанной ниже методике.

Для оценки точности классификации деревьев пихты *A. sibirica* на изображениях с помощью исследуемых моделей Mo-U-Net будет использоваться метрика Intersection over Union (IoU) [14]. Для каждого класса  $c$  деревьев она может быть вычислена по формуле:

$$IoU_c = \frac{TP_c}{TP_c + FP_c + FN_c}, \quad (1)$$

где  $TP_c$ ,  $FP_c$  и  $FN_c$  – количество, соответственно, истинно положительных, ложно положительных и ложно отрицательных решений для деревьев класса  $c$ . В наших исследованиях наряду с выражением (1) удобно использовать интегрированную метрику mean Intersection over Union (mIoU), рассчитываемую как среднее значение  $IoU_c$  по всем  $C$  классам. Отметим, что значения этих метрик, превышающие 0,5, соответствуют высокой точности классификации деревьев. Будем считать метрики  $IoU_c$  и mIoU мерой устойчивости каждой исследуемой модели к импульсным помехам: чем больше значения этих метрик, тем выше устойчивость модели.

## 2. Методика подготовки и проведения экспериментов

Рассмотрим методику подготовки и проведения экспериментов по исследованию устойчивости полносверточных моделей с различными РФП к импульсным помехам на изображениях. На этапе подготовки к тому или иному запланированному эксперименту на основе описанного выше датасета создается новый датасет. Все фрагменты его обучающей выборки будут иметь искусственным образом внесенные импульсные помехи, фрагменты валидационной и тестовой выборок не зашумляются. При зашумлении фрагментов этой выборки учитывается, какой эксперимент с моделями СНС запланирован, и в зависимости от этого задаются значения параметров зашумления каждого из фрагментов. Первым таким параметром является доля площади зашумления: отношение количества пикселей, значения которых будут изменены помехами, к общему количеству пикселей фрагмента изображения. Вторым задаваемым параметром служит амплитуда  $A$  помехи – число, указывающее, во сколько раз будет увеличено значение яркости зашумляемого пикселя для каждого из трех каналов RGB. Выбор координаты очередного пикселя фрагмента для зашумления производится по равномерному случайному закону распределения. Все сказанное позволяет считать, что новый датасет будет включать динамически формируемую в зависимости от предстоящего эксперимента обучающую выборку. При подготовке к экспериментам один параметр фиксируется, а второй изменяется в заданных пределах. Так будет сформировано четыре варианта нового датасета для проведения первой серии экспериментов, когда при фиксированной амплитуде  $A = 1,5$  изменяется доля площади зашумления каждого фрагмента выборки: 0,15; 0,25; 0,35; 0,50. Для сравнения результатов по точности классификации деревьев с помощью моделей в условиях импульсных помех с результатами классификации изображений без таких помех должны быть проведены обучение, валидация и исследования моделей в случае фрагментов без помех, т.е. с использованием исходного датасета. Для второй серии экспериментов создается три варианта нового датасета, когда при постоянной доле площади зашумления фрагментов, равной 0,25, изменяется амплитуда помех: 1,5; 2,0; 3,0.

После этапа подготовки варианта нового датасета проводится собственно эксперимент. Он выполняется в два этапа. На первом происходят обучение и валидация модели с выбранной РФП, а на втором этапе – собственно исследование устойчивости обученной модели с использованием тестовой выборки датасета.

При обучении и валидации модели с заданной РФП изменяемым является гиперпараметр – коэффициент  $\beta$  для этой функции потерь, принимающий значения в диапазоне [0,001; 9,000]. Поиск квазиоптимального значения данного гиперпараметра осуществляется при обучении и валидации модели с помощью байесовского алгоритма оптимизации [16], при этом число используемых наборов гиперпараметров равно 100. В соответствии с процедурой из [13] квазиоптимальными являются те значения гиперпараметров, при которых модель показывает максимальное значение точности классификации

по метрике mIoU на валидационной выборке. Полученное таким образом квазиоптимальное значение коэффициента  $\beta$  затем используется в заданной РФП при проведении второго этапа эксперимента по исследованию устойчивости модели. Отметим, что такая процедура определения квазиоптимального значения коэффициента  $\beta$  должна проводиться для каждой РФП и в каждом из запланированных экспериментов.

### 3. Результаты исследований и их обсуждение

Нетрудно видеть, что проведение всех вышеперечисленных экспериментов с каждой из семи моделей СНС потребует значительных вычислительных ресурсов. Поэтому предлагается сначала провести эксперимент со всеми моделями с использованием нового датасета с наиболее часто встречающимися параметрами зашумления. Полученные результаты исследований на тестовой выборке позволят выбрать модель, наиболее устойчивую к импульсным помехам. Затем с этой моделью проводить все эксперименты при описанных выше в методике вариантах изменения параметров зашумления. Проведенный нами анализ имеющихся изображений хвойных лесов, полученных с помощью фотокамеры, установленной на БПЛА, показал, что весьма вероятным сценарием зашумления изображений при съемке является следующий: площадь каждого фрагмента обучающей выборки зашумлена на 25% (доля импульсных помех от общего числа пикселей фрагмента равна 0,25), а амплитуда  $A$  импульсных помех имеет значение 1,5.

Именно с этими значениями параметров были зашумлены фрагменты обучающей выборки нового датасета и были обучены и валидированы все семь моделей СНС. Затем для каждой из РФП путем выявления максимального значения метрики mIoU на валидационной выборке получено квазиоптимальное значение коэффициента  $\beta$ . Полученные значения коэффициента  $\beta$  для всех функций потерь приведены в табл. 2. Здесь же представлены результаты эксперимента в виде значений метрики mIoU на валидационной и тестовой выборках.

Таблица 2

Результаты валидации и тестирования моделей СНС с различными РФП, обученных на фрагментах с долей площади зашумления 0,25 и  $A = 1,5$

| Функция потерь | Коэффициент $\beta$ | Выборка       | mIoU   |
|----------------|---------------------|---------------|--------|
| Коши           | 5,6900              | Валидационная | 0,6705 |
|                |                     | Тестовая      | 0,5651 |
| Рамсея         | 0,0010              | Валидационная | 0,7212 |
|                |                     | Тестовая      | 0,6089 |
| Хьюбера        | 1,7109              | Валидационная | 0,6980 |
|                |                     | Тестовая      | 0,6023 |
| Эндрюса        | 3,5703              | Валидационная | 0,6737 |
|                |                     | Тестовая      | 0,5768 |
| Geman-McCluer  | 3,9004              | Валидационная | 0,6938 |
|                |                     | Тестовая      | 0,6149 |
| Уэлша          | 4,2786              | Валидационная | 0,7011 |
|                |                     | Тестовая      | 0,6194 |
| Мешалкина      | 6,6236              | Валидационная | 0,6869 |
|                |                     | Тестовая      | 0,5884 |

Из табл. 2 следует, что модель СНС с функцией Уэлша демонстрирует лучшее значение метрики mIoU на тестовой выборке относительно результатов для исследуемых моделей с другими функциями потерь. Поэтому далее эксперименты проводились в соответствии с изложенной методикой только с этой моделью. Для пояснения, как происходит поиск квазиоптимального значения коэффициента  $\beta$ , на рис. 1 показаны результаты поиска такого значения коэффициента  $\beta$ , при котором модель СНС с РФП Уэлша демонстрирует максимальное значение метрики mIoU на валидационной выборке. Для удобства представления и анализа этих кривых значения коэффициента  $\beta$  были нормализованы. Видим, что квазиоптимальное значение коэффициента  $\beta$ , равное 4,2786, было получено на 83-м наборе

гиперпараметров из 100 используемых наборов, когда метрика mIoU на валидационной выборке приняла максимальное значение, равное 0,7011.



Рис. 1. Результаты поиска значений коэффициента  $\beta$  в случае функции Уэлша

Для исследования влияния площади зашумления импульсными помехами фрагментов обучающей выборки на точность классификации деревьев пихты с помощью модели с РФП Уэлша при постоянной амплитуде помех  $A = 1,5$  была проведена первая серия экспериментов. В табл. 3 представлены результаты таких экспериментов. В ней показаны полученные квазиоптимальные значения коэффициента  $\beta$  функции Уэлша и значения метрики IoUc для каждого класса деревьев и метрики mIoU на валидационной и тестовой выборках.

Таблица 3

**Точность классификации деревьев по метрикам IoUc и mIoU с помощью модели Mo-U-Net с РФП Уэлша в зависимости от площади зашумления обучающих фрагментов при постоянной амплитуде помех  $A = 1,5$**

| Доля площади зашумления обучающих фрагментов | Коэффициент $\beta$ | Выборка   | IoUc   |            |               |               |        | mIoU   |
|--|---------------------|-----------|--------|------------|---------------|---------------|--------|--------|
|  |                     |           | Живое  | Отмирающее | Свеж. сухост. | Стар. сухост. | Фон    |        |
| 0<br>(нет помех)                             | 5,4457              | Валидация | 0,7651 | 0,6677     | 0,7914        | 0,7277        | 0,9113 | 0,7726 |
|  |                     | Тестовая  | 0,6538 | 0,3267     | 0,7423        | 0,6202        | 0,8211 | 0,6328 |
| 0,15   | 7,9897              | Валидация | 0,7903 | 0,6698     | 0,7669        | 0,6974        | 0,9134 | 0,7676 |
|  |                     | Тестовая  | 0,7023 | 0,2585     | 0,7244        | 0,5882        | 0,8272 | 0,6201 |
| 0,25   | 4,2786              | Валидация | 0,7283 | 0,5803     | 0,7031        | 0,6037        | 0,8903 | 0,7011 |
|  |                     | Тестовая  | 0,6723 | 0,2980     | 0,7425        | 0,5694        | 0,8146 | 0,6194 |
| 0,35   | 8,2191              | Валидация | 0,5982 | 0,2978     | 0,6593        | 0,5942        | 0,8474 | 0,5994 |
|  |                     | Тестовая  | 0,6183 | 0,2768     | 0,6469        | 0,5369        | 0,7939 | 0,5746 |
| 0,50   | 7,3545              | Валидация | 0,5132 | 0,2445     | 0,5978        | 0,5279        | 0,8036 | 0,5374 |
|  |                     | Тестовая  | 0,5425 | 0,2827     | 0,7056        | 0,5235        | 0,7381 | 0,5585 |

Из полученных результатов следует вывод о том, что исследуемая модель по метрике mIoU на тестовой выборке демонстрирует плавное снижение устойчивости к импульсным помехам с ростом доли площади зашумления фрагментов обучающей выборки: устойчивость понижается на 2,0% при доле площади зашумления 0,15 и на 11,7% при максимальной доле площади зашумления, равной 0,50. При этом значение метрики mIoU равно 0,5585 даже при наличии помех на половине площади каждого фрагмента, что превышает порог 0,5 и указывает на довольно высокую точность классификации деревьев пихты. Отсюда следует вывод о возможности практического применения модели в лесной отрасли даже при наличии импульсных помех на половине площади анализируемого изображения. Аналогичные выводы можно сделать из анализа значений метрики IoUc на тестовой выборке для классов деревьев «Живое», «Свежий сухостой» и «Старый сухостой», а также для класса «Фон». Однако для промежуточного класса деревьев «Отмирающее» значения метрики IoUc на тестовой выборке значительно меньше порога 0,5 даже для фрагментов без помех и уменьшаются с ростом доли площади зашумления фрагментов. Такие результаты объясняются малым числом деревьев пихты на изображениях, исполь-

зуемых при формировании обучающей выборки (дисбаланс классов), а функция потерь Уэлша в отличие от известной двухпараметрической функции потерь Focal Loss, используемой при решении подобной задачи в [5], когда значение метрики IoUc в случае деревьев этого класса превышает порог 0,5, не позволяет снизить влияние такого дисбаланса. Это указывает на невозможность практического использования исследуемой модели в случае классификации деревьев данного класса.

Вторая серия экспериментов проводилась для исследования влияния амплитуды импульсных помех на точность классификации деревьев пихты с помощью модели с РФП Уэлша. При этом доля площади зашумления фрагментов не изменялась и была равна 0,25. Полученные результаты валидации и тестирования обученной модели по метрикам IoUc и mIoU представлены в табл. 4. Во втором столбце показаны также вычисленные и используемые в экспериментах квазиоптимальные значения коэффициента  $\beta$ .

Таблица 4

**Значения метрик IoUc и mIoU в случаях разных амплитуд импульсных помех при постоянной доле площади зашумления фрагментов, равной 0,25**

| Амплитуда помех на обучающих фрагментах | Коэффициент $\beta$ | Выборка       | IoUc   |            |               |               |        | mIoU   |
|---|---------------------|---------------|--------|------------|---------------|---------------|--------|--------|
|   |                     |               | Живое  | Отмирающее | Свеж. сухост. | Стар. сухост. | Фон    |        |
| Без помех                               | 5,4457              | Валидационная | 0,7651 | 0,6677     | 0,7914        | 0,7277        | 0,9113 | 0,7726 |
|   |                     | Тестовая      | 0,6538 | 0,3267     | 0,7423        | 0,6202        | 0,8211 | 0,6328 |
| 1,5                                     | 4,2786              | Валидационная | 0,7283 | 0,5803     | 0,7031        | 0,6037        | 0,8903 | 0,7011 |
|   |                     | Тестовая      | 0,6723 | 0,2980     | 0,7425        | 0,5694        | 0,8146 | 0,6194 |
| 2,0                                     | 2,2407              | Валидационная | 0,6635 | 0,4245     | 0,6698        | 0,5771        | 0,8683 | 0,6406 |
|   |                     | Тестовая      | 0,6347 | 0,2758     | 0,7036        | 0,5129        | 0,7890 | 0,5832 |
| 3,0                                     | 4,0045              | Валидационная | 0,6574 | 0,4167     | 0,6690        | 0,6089        | 0,8686 | 0,6441 |
|   |                     | Тестовая      | 0,6162 | 0,3744     | 0,7439        | 0,5874        | 0,7990 | 0,6242 |

Видим, что при наличии помех имеют место уменьшение значений метрик IoUc и mIoU и, соответственно, снижение устойчивости модели. Например, по метрике mIoU на тестовой выборке снижение на 2,1% для случая  $A = 1,5$ , на 7,8% для  $A = 2,0$  и на 1,4% для  $A = 3$ . Незначительное снижение устойчивости модели в случае  $A = 3$  по сравнению со случаями помех с амплитудами  $A = 1,5$  и  $A = 2,0$  происходит из-за того, что такой значительный рост яркости зашумленных пикселей позволяет модели лучше выделить детали крон деревьев пихты. По значениям метрики IoUc, превышающим порог 0,5, можно сделать вывод о ее довольно высокой устойчивости и практической применимости в условиях помех со значительными амплитудами в случае деревьев классов «Живое», «Свежий сухостой» и «Старый сухостой» и класса «Фон». К сожалению, для деревьев класса «Отмирающее» значения метрики IoUc на тестовой выборке для всех вариантов задания значений амплитуд помех значительно меньше порога 0,5, что указывает на низкую устойчивость модели к помехам и поэтому не позволит использовать ее на практике в случае классификации деревьев данного класса.

### Заключение

Проведены исследования устойчивости семи полносверточных моделей, полученных на основе модели Mo-U-Net с использованием ряда известных РФП, при решении задачи классификации зашумленных импульсными помехами изображений деревьев пихты. Для этого создан датасет, фрагменты обучающей выборки которого имеют искусственным образом внесенные импульсные помехи. В соответствии с разработанной методикой подготовки и проведения исследований при зашумлении фрагментов учитывается, какой эксперимент с моделями запланирован, и в зависимости от этого задаются значения параметров импульсных помех. При обучении и валидации каждой из моделей при различных значениях амплитуды помех и доли площади зашумления фрагментов обучающей выборки осуществлен поиск квазиоптимальных значений коэффициентов  $\beta$  каждой функции потерь. Полученные квазиоптимальные значения коэффициентов  $\beta$  далее использованы при проведении исследований устойчивости моделей.

В результате исследований показано, что модель с функцией Уэлша демонстрирует лучшее значение метрики mIoU на тестовой выборке среди результатов для моделей с другими функциями потерь. Это позволило провести дальнейшие эксперименты в соответствии с предложенной методикой только с этой моделью. В первую очередь было исследовано влияние площади зашумления импульсными помехами фрагментов обучающей выборки на устойчивость модели с функцией Уэлша при постоянной амплитуде помех  $A = 1,5$ . При этом выявлено, что по метрике mIoU на тестовой выборке модель демонстрирует плавное снижение устойчивости к помехам с ростом доли площади зашумления фрагментов от 0,15 до 0,5 соответственно на 2,0–11,7%. Значение метрики mIoU равно 0,5585 даже при наличии помех на половине площади каждого фрагмента, что превышает порог 0,5 и указывает на высокую точность классификации деревьев пихты. Для исследования влияния амплитуды импульсных помех на устойчивость модели с функцией Уэлша проведена вторая серия экспериментов при постоянной доле площади зашумления фрагментов, равной 0,25. Из анализа значений метрики mIoU на тестовой выборке следует, что устойчивость модели снижается на 1,4–7,8% в зависимости от амплитуды помех, однако все значения метрики mIoU превышают порог 0,5.

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 этой метрики 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 данного класса.

Полученные результаты исследования устойчивости семи полносверточных моделей позволили сформировать практически важные рекомендации специалистам лесной отрасли при нейросетевом анализе изображений, полученных при мониторинге хвойных лесов с помощью БПЛА.

#### Список источников

1. 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. V. 42. P. 490–505. doi: 10.1139/x11-190
2. 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. V. 352. P. 78–88. doi: 10.1016/j.foreco.2015.06.010
3. Musolin D., Kirichenko N., Karpun N., Mandelshtam M., Selikhovkin A., Zhuravleva E., Aksenenko E., Golub V., Kerchev I., Vasaitis R., Volkovitch M., Zhuravleva E., Selikhovkin A. Invasive pests of forests and urban trees in Russia: origin pathways, damage, and management // *Forests*. 2022. V. 13. Art. 521. doi: 10.3390/f13040521
4. Кривец С.А., Бисирова Э.М., Волкова Е.С., Дебков Н.М., Керчев И.А., Мельник М.А., Никифоров А.Н., Чернова Н.А. Технология мониторинга пихтовых лесов в зоне инвазии уссурийского полиграфа в Сибири. Томск : УМИУМ, 2018. 74 с.
5. Марков Н.Г., Мачука К. Модели и методы глубокого обучения для решения задач дистанционного мониторинга лесных ресурсов // *Известия Томского политехнического университета. Инжиниринг георесурсов*. 2024. Т. 335, № 6. С. 55–74. doi: 10.18799/24131830/2024/6/4600
6. 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. V. 11. P. 643–662. doi: 10.3390/rs11060643
7. Керчев И.А., Маслов К.А., Марков Н.Г., Токарева О.С. Семантическая сегментация поврежденных деревьев пихты на снимках с беспилотных летательных аппаратов // *Современные проблемы дистанционного зондирования Земли из космоса*. 2021. Т. 18, № 1. С. 116–126. doi: 10.21046/2070-7401-2021-18-1-116-126
8. Adachi K., Yamaguchi S. Learning Robust Convolutional Neural Networks with Relevant Feature Focusing Via Explanations // *2022 IEEE International Conference on Multimedia and Expo (ICME)*. IEEE, 2022. P. 1–6.
9. Сивак М.А. Робастное обучение нейронных сетей с простой архитектурой для решения задач классификации : дис. ... канд. техн. наук : 05.13.17. Новосибирск, 2022. 117 с.
10. Fanjun L., Ying L. Robust echo state network with Cauchy loss function and hybrid regularization for noisy time series prediction // *Applied Soft Computing*. 2023. V. 146. Art. 110640.
11. Li X., Lu Q., Dong Y., Tao D. Robust subspace clustering by cauchy loss function // *IEEE Transactions on Neural Networks and Learning Systems*. 2018. V. 30 (7). P. 2067–2078.

12. Li X., Xia Z., Zhang H. Cauchy activation function and XNet // arXiv preprint arXiv: 2409.19221. 2024. URL: <https://arxiv.org/abs/2409.19221>
13. Малкин А.Ю., Марков Н.Г. Помехоустойчивость модели полносверточной нейронной сети U-Net при семантической сегментации деревьев пихты на зашумленных снимках с БПЛА // Доклады ТУСУР. 2024. Т. 27, № 2. С. 64–70. doi: 10.21293/1818-0442-2024-27-2-64-70
14. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // Medical Image Computing and Computer-Assisted Intervention. 2015. V. 9351. P. 234–241. doi: 10.1007/978-3-319-24574-4\_28
15. Марков Н.Г., Маслов К.А., Керчев И.А., Токарева О.С. Модели U-Net для семантической сегментации поврежденных деревьев сосны сибирской кедровой на снимках с БПЛА // Современные проблемы дистанционного зондирования Земли из космоса. 2022. Т. 19, № 1. С. 65–77. doi: 10.21046/2070-7401-2022-19-1-65-77
16. Wu J., Chen X.Y., Zhang H., Xiong L.D., Lei H., Deng S.H. Hyperparameter optimization for machine learning models based on Bayesian optimization // Journal of Electronic Science and Technology. 2019. Vol. 17 (1). P. 26–40.

## References

1. Chang, W.Y., Lantz, V.A., Hennigar, C.R. & MacLean, D.A. (2012) Economic impacts of forest pests: a case study of spruce budworm outbreaks and control in New Brunswick, Canada. *Canadian Journal of Forest Research*. 42. pp. 490–505. doi: 10.1139/x11-190
2. Van Lierop, P., Lindquist, E., Sathyapala, S. & Franceschini, G. (2015) Global forest area disturbance from fire, insect pests, diseases and severe weather events. *Forest Ecology and Management*. 352. pp. 78–88. doi: 10.1016/j.foreco.2015.06.010
3. Musolin, D., Kirichenko, N., Karpun, N., Mandelshtam, M., Selikhovkin, A., Zhuravleva, E. Aksenenko, E., Golub, V., Kerchev, I., Vasaitis, R., Volkovitsh, M., Zhuravleva, E. & Selikhovkin, A. (2022) Invasive pests of forests and urban trees in Russia: origin pathways, damage, and management. *Forests*. 13. p. 521. doi: 10.3390/f13040521
4. Krivets, S.A., Bisirova, E.M., Volkova, E.S., Debkov, N.M., Kerchev, I.A., Melnik, M.A. Nikiforov, A.N. & Chernova, N.A. (2018) *Tekhnologiya monitoringa pikhtovykh lesov v zone invazii ussuriyskogo poligrafa v Sibiri* [Monitoring technology of fir forests in the zone of Ussurian polygraph invasion in Siberia]. Tomsk: UMIUM.
5. Markov, N.G. & Machuka, K. (2024) Models and methods of deep learning for remote monitoring of forest resources. *Izvestiya TPU. Inzhiniring georesurov*. 335(6). pp. 55–74. doi: 10.18799/24131830/2024/6/4600
6. Safonova, A., Tabik, S., Alcaraz-Segura, D., Rubtsov, A., Maglinets, Y. & Herrera, F. (2019) Detection of fir trees (*Abies sibirica*) damaged by the bark beetle in UAV images with deep learning. *Remote Sensing*. 11. p. 643. doi: 10.3390/rs11060643
7. Kerchev, I.A., Maslov, K.A., Markov, N.G. & Tokareva, O.S. (2021) Semantic segmentation of damaged fir trees in UAV imagery. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*. 18(1). pp. 116–126. doi: 10.21046/2070-7401-2021-18-1-116-126
8. Adachi, K. & Yamaguchi, S. (2022) Learning robust convolutional neural networks with relevant feature focusing via explanations. *Proc. IEEE Int. Conf. on Multimedia and Expo (ICME)*. IEEE. pp. 1–6.
9. Sivak, M.A. (2022) *Robustnoe obuchenie neyronnykh setey s prostoy arkhitekturoy dlya resheniya zadach klassifikatsii* [Robust Training of Neural Networks with Simple Architecture for Solving Classification Problems]. Engineering Cand. Diss. Novosibirsk: NSTU.
10. Li, F. & Li, Y. (2023) Robust echo state network with Cauchy loss function and hybrid regularization for noisy time series prediction. *Applied Soft Computing*. 146. Art. 110640.
11. Li, X., Xia, Z. & Zhang, H.C. (2018) Robust subspace clustering by Cauchy loss function. *IEEE Transactions on Neural Networks and Learning Systems*. 30(7). pp. 2067–2078.
12. Li, X., Xia, Z. & Zhang, H.C. (2024) Cauchy activation function and XNet. *arXiv preprint, arXiv:2409.19221*.
13. Malkin, A.Yu. & Markov, N.G. (2024) Pomexoustoychivost' modeli polnosvertochnoy neyronnoy seti U-Net pri semanticheskoy segmentatsii derev'ev pikhty na zashumlennykh snimkakh s BPLA [Noise Immunity of the U-Net Fully Convolutional Neural Network Model in Semantic Segmentation of Fir Trees on Noisy UAV Images]. *Doklady TUSUR*. 27(2). pp. 64–70. doi: 10.21293/1818-0442-2024-27-2-64-70
14. Ronneberger, O., Fischer, P. & Brox, T. (2015) U-Net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention*. Art. 9351. doi: 10.1007/978-3-319-24574-4\_28
15. Markov, N.G., Maslov, K.A., Kerchev, I.A. & Tokareva, O.S. (2022) Modeli U-Net dlya semanticheskoy segmentatsii povrezhdennykh derev'ev sosny sibirskoy kedrovoy na snimkakh s BPLA [U-Net Models for Semantic Segmentation of Damaged Siberian Pine Trees on UAV Images]. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*. 19(1). pp. 65–77. doi: 10.21046/2070-7401-2022-19-1-65-77
16. Wu, J. et al. (2019) Hyperparameter optimization for machine learning models based on Bayesian optimization. *Journal of Electronic Science and Technology*. 17(1). pp. 26–40.

## Информация об авторах:

Малкин Артем Юрьевич – аспирант Отделения информационных технологий инженерной школы информационных технологий и робототехники Национального исследовательского Томского политехнического университета (Томск, Россия). E-mail: [malkin@tpu.ru](mailto:malkin@tpu.ru)

**Марков Николай Григорьевич** – профессор, доктор технических наук, профессор Отделения информационных технологий инженерной школы информационных технологий и робототехники Национального исследовательского Томского политехнического университета (Томск, Россия). E-mail: markovng@tpu.ru

*Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.*

**Information about the authors:**

**Malkin Artem Yu.** (Post-Graduate Student, National Research Tomsk Polytechnic University, Tomsk, Russian Federation). E-mail: malkin@tpu.ru

**Markov Nikolai G.** (Professor, Doctor of Technical Sciences, National Research Tomsk Polytechnic University, Tomsk, Russian Federation). E-mail: markovng@tpu.ru

*Contribution of the authors: the authors contributed equally to this article. The authors declare no conflicts of interests.*

*Поступила в редакцию 02.06.2025; принята к публикации 02.12.2025*

*Received 02.06.2025; accepted for publication 02.12.2025*