

УДК 621.396.41

А.Ю. Малкин, Н.Г. Марков

## Помехоустойчивость модели полносверточной нейронной сети U-Net при семантической сегментации деревьев пихты на зашумленных снимках с БПЛА

Исследуется помехоустойчивость модифицированной модели полносверточной нейронной сети U-Net с робастной функцией потерь Коши и функцией потерь Focal Loss при решении задачи сегментации (попиксельной классификации) зашумленных снимков деревьев пихты, пораженных вредителями. Показано, что точность классификации таких деревьев падает с ростом площади зашумления и амплитуды импульсных помех на фрагментах обучающей выборки. При этом уровень падения точности зависит от используемой при обучении модифицированной модели U-Net функции потерь. Для модели с робастной функцией потерь Коши прослеживается более медленное снижение помехоустойчивости при увеличении значений параметров зашумления.

**Ключевые слова:** беспилотный летательный аппарат, семантическая сегментация снимков деревьев пихты, помехоустойчивость модифицированной модели полносверточной нейронной сети U-Net.

**DOI:** 10.21293/1818-0442-2024-27-2-64-70

Вспышки массового размножения насекомых-вредителей наносят непоправимый вред лесам во многих странах мира [1]. Увеличивающиеся масштабы последствий проникновения в леса таких вредителей ставят под серьезную угрозу биологическую безопасность ряда регионов мира, в том числе России. Особенно опасны насекомые – вредители для хвойных лесов, где они наносят большой ущерб лесопользованию на значительной площади лесных ресурсов [1, 2]. Так, например, в Сибири в последние годы по наносимому ущербу пихтовым лесам лидирует дальневосточный вредитель – уссурийский полиграф *Polygraphus proximus* [3]. Сегодня он также проявился в пихтовых лесах далеко за пределами Сибири в ряде центральных регионов России и Прибайкалья [4].

В настоящее время для мониторинга лесов все чаще применяются беспилотные летательные аппараты (БПЛА), оснащенные прецизионными фото- или видеокамерами для получения многоспектральных снимков деревьев высокого и сверхвысокого разрешения [5, 6]. Анализ снимков ведут с целью решения той или иной лесоустроительной задачи, включая задачу обнаружения очагов размножения вредителей полуручным способом (эксперт ведет дешифрирование снимков с использованием вспомогательных программ) или автоматически, решая задачу классификации снимков с помощью современных методов и алгоритмов классификации. При выявлении породного состава участка леса и при оценке состояния здоровья пораженных вредителем деревьев, когда на снимках необходимо распознавать несколько классов (состояний) таких деревьев, решается задача мультиклассификации. Например, в случае поражения деревьев пихты уссурийским полиграфом на снимке надо распознать пять классов: четыре состояния деревьев пихты разной степени поражения вредителем и фон [6].

Однако известные методы классификации и традиционные методы машинного обучения при решении различных задач классификации деревьев

на снимках дают невысокую точность их распознавания [5, 6]. Поэтому для решения задач мультиклассификации при оценке степени поражения хвойных деревьев на снимках все чаще начинают применять сверточные нейронные сети (СНС) [6–8]. Результаты исследований, полученные в [9] при применении различных моделей СНС для мультиклассификации снимков лесов, позволяют считать, что наиболее перспективными являются модели полносверточных нейронных сетей класса U-Net [10]. Эти модели с весьма высокой точностью позволяют решать задачи семантической сегментации снимков, когда каждый пиксель получает метку определенного класса, т.е. выполняется попиксельная классификация деревьев. Например, в работе [8] с помощью классической модели U-Net для большинства классов деревьев пихты, поврежденных уссурийским полиграфом, получена высокая точность классификации снимков с БПЛА.

Известно, что снимки лесов, получаемые с БПЛА, по разным причинам могут содержать шумы в виде импульсных помех, часто называемых выбросами. Наличие выбросов, обычно имеющих значительные амплитуды, приводит к искажению результатов мультиклассификации пораженных вредителями деревьев. Это указывает на актуальность исследований, нацеленных на выявление помехоустойчивости используемых для анализа снимков лесов моделей СНС, в первую очередь, полносверточных сетей в виде моделей, подобных U-Net. Для повышения помехоустойчивости моделей класса U-Net при их обучении могут применяться также функции потерь, относящиеся к робастным (устойчивым к шумам) функциям [11].

Цель данной работы – исследование точности классификации пораженных уссурийским полиграфом деревьев пихты на зашумленных снимках с БПЛА, выполняемой с помощью модифицированной модели СНС U-Net в случаях ее обучения с использованием известной функции потерь Focal Loss, а также с использованием робастной функции потерь Коши.

### Постановка задачи исследования

Пусть необходимо провести исследование помехоустойчивости одной из моделей, подобных классической модели U-Net [10], и используемых для мультиклассификации снимков пораженных деревьев пихты, которые получены с помехами в виде выбросов. В качестве такой модели выберем предложенную нами в [12] модификацию классической модели U-Net. По сравнению с классической моделью в архитектуру этой модифицированной модели U-Net были добавлены следующие изменения:

- входное изображение сети представлено тензором  $256 \times 256 \times 3$ , соответствующим фрагменту RGB-снимка;
- свертки не уменьшают размер карт признаков;
- обрезка карт признаков не используется для соединений пропуска;
- пакетная нормализация BN применяется после каждой нелинейности;
- функция активации ReLU из-за отсутствия корректировки весов нейронов на ее горизонтальной части заменена на хорошо себя зарекомендовавшую нелинейную функцию ELU (от англ. Exponential Linear Unit) [13];
- выходной тензор вычисляется пятью свертками с фильтрами размером  $1 \times 1$ , позволяя классифицировать пиксели сразу пяти классов (четыре класса (состояния здоровья) деревьев пихты и «фон»).

Отметим, что такая модификация модели U-Net позволила при решении задачи мультиклассификации деревьев кедра на снимках с БПЛА получить более высокую точность сегментации пораженных деревьев, находящихся в промежуточных состояниях здоровья (состояния между живыми – нетронутыми вредителями деревьями и старым сухостоем) [12], чем в случае классической модели U-Net.

Первая серия экспериментов должна проводиться с модифицированной моделью U-Net, обученной с использованием функции потерь в виде одной из известных робастных функций. Для этого, основываясь на результатах исследования ряда робастных функций Хьюбера, Эндрюса, Тьюки, Коши, Уэлша, Мешалкина и др., приведенных в работах [11, 14], была выбрана робастная функция Коши. Предполагается, что робастность такой функции потерь должна повысить помехоустойчивость модифицированной модели U-Net при анализе снимков с выбросами. Из [11] следует, что функция Коши описывается выражением

$$\rho(z) = \ln \left( \frac{1}{2} \cdot \left( \frac{z}{\beta} \right)^2 + 1 \right), \quad (1)$$

где  $z$  – величина ошибки предсказания,  $\beta$  – коэффициент при функции потерь. Производная функции Коши представлена формулой

$$\rho'(z) = \frac{z}{\frac{1}{2}z^2 + \beta^2}. \quad (2)$$

Из выражения (2) видим, что описываемая функция является непрерывной на множестве веще-

ственных чисел, что позволяет использовать выражение (1) в качестве функции потерь в алгоритме обратного распространения ошибки при обучении модели СНС.

Во второй серии экспериментов должны быть получены результаты для сравнения с результатами первой серии экспериментов. В этом случае для обучения модифицированной модели U-Net должна использоваться хорошо себя зарекомендовавшая функция потерь Focal Loss, описываемая следующим выражением [15]:

$$\rho(z) = -\alpha \cdot (1-z)^\gamma \cdot \log(z), \quad (3)$$

где  $z$  – величина ошибки предсказания,  $\alpha$  и  $\gamma$  – задаваемые коэффициенты.

Для оценки точности классификации деревьев на снимках с БПЛА с помощью исследуемой на помехоустойчивость модифицированной модели U-Net может использоваться метрика Intersection over Union (IoU). Она считается общепринятой метрикой эффективности при решении задачи семантической сегментации цифровых изображений [16]. Метрика IoU<sub>c</sub> для каждого класса  $c$  деревьев может быть вычислена по формуле

$$\text{IoU}_c = \frac{\text{TP}_c}{\text{TP}_c + \text{FP}_c + \text{FN}_c}, \quad (4)$$

где TP<sub>c</sub>, FP<sub>c</sub> и FN<sub>c</sub> – количество, соответственно, истинно-положительных, ложно-положительных и ложно-отрицательных решений для деревьев класса  $c$ . В наших исследованиях для оценки точности классификации деревьев удобнее использовать интегрированную метрику mean Intersection over Union (mIoU), рассчитываемую как среднее значение IoU<sub>c</sub> по всем  $C$  классам. Будем считать метрику mIoU мерой помехоустойчивости исследуемой модели. Отметим, что значения этих метрик, превышающие 0,5, соответствуют высокой точности классификации деревьев.

Обучение, валидация и тестирование (исследование) модифицированной модели U-Net проводятся на датасете, созданном сотрудниками Института мониторинга климатических и экологических систем СО РАН и Томского политехнического университета и описанном в [8]. Исходные снимки крон деревьев пихты, пораженных уссурийским полиграфом, получены с помощью БПЛА DJI Phantom 3 Standart с установленной на нем фотокамерой, ведущей съемку в видимом диапазоне электромагнитного спектра (RGB). При дешифрировании этих снимков экспертами выделялись четыре класса жизненного состояния деревьев: «живые», «отмирающие», «свежий сухостой», «старый сухостой», а также пятый класс – «фон» (деревья других пород и иные объекты земной поверхности).

В результате разметки снимков экспертами по классам деревьев и оконтуривания их крон были получены эталонные карты сегментации. Датасет представляет собой совокупность фрагментов исходных снимков размером  $256 \times 256$  пикселей и совокупность соответствующих им фрагментов, полу-

ченных при дешифрировании эталонных карт. Он был поделён на три выборки: обучающая (2004 фрагмента), валидационная (672 фрагмента), тестовая (91 фрагмент). Отметим, что дополнительный анализ фрагментов обучающей выборки показал, что они не содержат выбросов.

### Планирование экспериментов

В каждой серии экспериментов зашумление фрагментов обучающей выборки осуществлялось следующим образом. Пиксели для зашумления каждого фрагмента выбирались случайным образом. Амплитуда яркости каждого зашумляемого пикселя изменялась в каждом из трех экспериментов следующим образом: она увеличивалась относительно исходной амплитуды пикселя в 1,5, 2,0 и 3,0 раза. Число зашумляемых пикселей в каждом фрагменте в этих трех экспериментах не изменялось и было равным 16 384 (занимаемая ими площадь составляет 25% от площади фрагмента). На рис. 1 показаны примеры зашумления фрагмента при разных амплитудах выбросов. Видно, что с увеличением амплитуды выбросов качество фрагментов в обучающей выборке ухудшается.




Рис. 1. Визуализация фрагмента снимка при его зашумлении: *a* – исходный фрагмент; *b* – амплитуда выбросов равна 1,5; *v* – равна 2,0; *z* – равна 3,0

В рамках каждой серии экспериментов необходимо провести еще шесть экспериментов, когда амплитуда выбросов задается равной 1,5, а размер площади зашумления каждого фрагмента изменяется следующим образом: 10% (6 554 зашумленных пикселей), 12,5% (8 192 пикселя), 15% (9 831 пиксель), 30% (19 661 пиксель), 35% (22 937 пикселей), 50% (32 768 пикселей).

Для проведения исследований в соответствии с этим планом на основе исходного датасета был создан еще один датасет с фрагментами обучающей выборки, имеющими выбросы. Особенности зашумления фрагментов нового датасета зависят от сценария проведения каждого конкретного эксперимента, т.е. определяются заданными исследователем значениями амплитуды выбросов и площади зашумления.

### Обучение и валидация модели U-Net

В экспериментах исследуется помехоустойчивость модифицированной модели U-Net со следующими гиперпараметрами и диапазонами их изменения: коэффициенты функций потерь ( $\alpha$  и  $\gamma$  – функции Focal Loss,  $\beta$  функции Коши) – в диапазоне [3; 9] и скорость обучения в диапазоне [ $10^{-4}$ ;  $10^{-2}$ ]. Для поиска квазиоптимальных значений этих гиперпараметров использовался алгоритм байесовской оптимизации. Поиск таких значений гиперпараметров в каждом эксперименте проводился в течение ста

итераций дважды: в случае функции Коши и в случае функции Focal Loss. На рис. 2 в качестве примера представлены результаты вычисления гиперпараметров при обучении и валидации модифицированной модели U-Net на зашумленных фрагментах (площадь зашумления – 25%, амплитуда выбросов – 1,5) в случае функции Коши. Порядковым номерам (номерам итераций) на рис. 2 для этого эксперимента соответствуют полученные по алгоритму байесовской оптимизации наборы гиперпараметров.




Рис. 2. Пример результатов поиска значений гиперпараметров в случае функции Коши

С целью удобного отображения значений гиперпараметров проведено их линейное преобразование в значения в диапазоне [0; 1]. В этом примере было определено квазиоптимальное нормированное значение коэффициента  $\beta$ , равное 0,0285 (ненормированное равно 3,1708), и квазиоптимальное нормированное значение скорости обучения, равное 0,8585 (ненормированное – 0,0086), при которых модифицированная модель показывает максимальное значение точности классификации по метрике mIoU на валидационной выборке, равное 0,7107. Подобные результаты, но при поиске значений трех гиперпараметров получены при обучении и валидации модели в случае функции потерь Focal Loss. Такая же процедура обучения и валидации модели с целью определения квазиоптимальных значений гиперпараметров проводилась для всех запланированных экспериментов первой и второй серии.

Также осуществлялись обучение и валидация модифицированной модели U-Net с функциями потерь Коши и Focal Loss на соответствующих выборках исходного датасета, т.е. без зашумленных фрагментов. Это позволяет оценить точность классификации деревьев с помощью модели на тестовой выборке исходного датасета и использовать полученные результаты для сравнения с результатами запланированных серий экспериментов с зашумлением фрагментов.

### Результаты исследований и их обсуждение

Далее для каждого эксперимента первой серии исследовалась точность классификации по метрике mIoU деревьев пихты на фрагментах тестовой выборки исходного датасета. При этом в каждом эксперименте использовалась модифицированная мо-

дель U-Net, обученная с применением функции потерь Коши на обучающей выборке с зашумленными фрагментами по соответствующему сценарию. В табл. 1 показаны результаты этих исследований в виде значений метрики mIoU в зависимости от параметров зашумления фрагментов обучающей выборки из нового датасета. В первой строке также приведен результат исследования модели, когда она обучалась и валидировалась на выборках исходного датасета без зашумлений фрагментов (площадь зашумления 0%, амплитуды без выбросов, т.е. равны 1). В табл. 1 также показаны квазиоптимальные значения коэффициента  $\beta$  робастной функции потерь Коши, полученные после обучения и валидации этой модели на зашумленных и незашумленных фрагментах. Можно сделать вывод, что квазиоптимальные значения коэффициента  $\beta$  для робастной функции потерь Коши при обучении модифицированной модели U-Net зависят от площади зашумления обучающих фрагментов при неизменной амплитуде выбросов.

Таблица 1

**Зависимость метрики mIoU от площади зашумления фрагментов при постоянной амплитуде выбросов**

| Параметры зашумления фрагментов |           | Коэф-т $\beta$ функции Коши | mIoU на тестовой выборке |
|---------------------------------|-----------|-----------------------------|--------------------------|
| Площадь, %                      | Амплитуда |                             |                          |
| 0                               | 1         | 6,5205                      | 0,6653                   |
| 10                              | 1,5       | 3,1708                      | 0,6636                   |
| 12,5                            |           | 8,1773                      | 0,6611                   |
| 15                              |           | 8,9910                      | 0,6592                   |
| 20                              |           | 3,0058                      | 0,6594                   |
| 25                              |           | 3,1708                      | 0,6622                   |
| 30                              |           | 4,9932                      | 0,6599                   |
| 35                              |           | 8,9851                      | 0,6597                   |
| 50                              |           | 6,6832                      | 0,6607                   |

В табл. 2 приведены результаты исследования в первой серии экспериментов влияния амплитуды выбросов на точность классификации деревьев на тестовых фрагментах, при этом площадь зашумления в этих экспериментах оставалась неизменной и равной 25%. В табл. 2 также показаны квазиоптимальные значения коэффициента  $\beta$  робастной функции потерь Коши, полученные после обучения и валидации этой модели на зашумленных фрагментах обучающей выборки. Видно, что каждому сценарию зашумления соответствует свое квазиоптимальное значение коэффициента  $\beta$ , которое необходимо искать при обучении и валидации модифицированной модели U-Net.

По значениям метрики mIoU на тестовой выборке в табл. 1 и 2 можно сделать вывод, что амплитуда выбросов оказывает существенное влияние на точность классификации тестовых фрагментов и, соответственно, на помехоустойчивость модели, а размер площади зашумления меньше влияет на точность классификации.

Затем была проведена вторая серия экспериментов, при этом получены результаты исследования по точности классификации модифицированной

модели U-Net, обученной и валидированной с применением функции потерь Focal Loss. Результаты представлены в табл. 3 и 4.

Таблица 2

**Зависимость метрики mIoU от амплитуды выбросов при постоянной площади зашумления фрагментов**

| Параметры зашумления фрагментов |           | Коэф-т $\beta$ функции Коши | mIoU на тестовой выборке |
|---------------------------------|-----------|-----------------------------|--------------------------|
| Площадь                         | Амплитуда |                             |                          |
| 25%                             | 1,5       | 3,1708                      | 0,6533                   |
|                                 | 2,0       | 6,0652                      | 0,6254                   |
|                                 | 3,0       | 6,7963                      | 0,5885                   |

В таблицах также приведены квазиоптимальные значения коэффициентов  $\alpha$  и  $\gamma$  функции потерь Focal Loss, полученные при обучении и валидации этой модели. Из табл. 3 и 4 видно, что каждому сценарию зашумления соответствуют свои квазиоптимальные значения коэффициентов  $\alpha$  и  $\gamma$ , которые необходимо искать при обучении и валидации модифицированной модели U-Net с функцией потерь Focal Loss.

Таблица 3

**Зависимость метрики mIoU от площади зашумления фрагментов при постоянной амплитуде выбросов**

| Параметры зашумления фрагментов |           | Коэф-т функции Focal Loss |          | mIoU на тестовой выборке |
|---------------------------------|-----------|---------------------------|----------|--------------------------|
| Площадь, %                      | Амплитуда | $\alpha$                  | $\gamma$ |                          |
| 0                               | 1         | 4,4331                    | 3,1041   | 0,6701                   |
| 10                              | 1,5       | 3,1987                    | 6,7168   | 0,6792                   |
| 12,5                            |           | 6,7553                    | 3,1520   | 0,6751                   |
| 15                              |           | 6,2227                    | 5,5577   | 0,6652                   |
| 20                              |           | 7,7003                    | 7,1951   | 0,6706                   |
| 25                              |           | 6,1240                    | 4,9331   | 0,6659                   |
| 30                              |           | 3,2237                    | 5,6579   | 0,6703                   |
| 35                              |           | 5,5296                    | 6,4003   | 0,6559                   |
| 50                              |           | 5,0804                    | 3,6445   | 0,6493                   |

Таблица 4

**Точность классификации деревьев по метрике mIoU в зависимости от параметров зашумления**

| Параметры зашумления фрагментов |           | Коэф-т Focal Loss |          | mIoU на тестовой выборке |
|---------------------------------|-----------|-------------------|----------|--------------------------|
| Площадь                         | Амплитуда | $\alpha$          | $\gamma$ |                          |
| 25%                             | 1,5       | 6,1240            | 4,9331   | 0,6659                   |
|                                 | 2,0       | 4,0445            | 3,0102   | 0,6447                   |
|                                 | 3,0       | 5,8859            | 7,3226   | 0,5705                   |

Из табл. 3 и 4 следует, что влияние амплитуды выбросов на точность классификации деревьев на тестовых фрагментах более существенное, чем влияние размера площади зашумления фрагмента. Этот вывод аналогичен выводу, сделанному по результатам первой серии экспериментов при исследовании помехоустойчивости модифицированной модели U-Net в случае робастной функции потерь Коши.

На рис. 3 для визуальной оценки результатов по точности классификации деревьев пихты на зашумленных снимках приведены результаты сегментации тестового снимка с помощью модифицированной модели U-Net, обученной при использовании ро-

бастной функции потерь Коши и при использовании функции потерь Focal Loss. Квазиоптимальные значения коэффициентов этих функций потерь взяты из результатов экспериментов для следующих значений параметров зашумления: доля зашумленной площади фрагментов 25% и амплитуда выбросов 1,5. Считаем данный сценарий зашумления наиболее вероятным при реальной фотосъемке пихтовых лесов с помощью БПЛА. Из сравнения на рис. 3 изображений *в* с *б* и *г* с *б* следует, что при визуальной оценке результатов применения модифицированной модели U-Net в случае робастной функции потерь Коши наблюдается более точная классификация большинства состояний пораженных деревьев пихты, чем в случае функции потерь Focal Loss. Однако по причине малочисленности деревьев пихты на тестовом снимке, принадлежащих классу «Отмирающие», точность классификации деревьев этого класса невысока в обоих случаях.




Рис. 3. Сегментация тестового снимка: *а* – исходный снимок; *б* – эталонная карта; результаты сегментации с помощью модели U-Net, обученной с применением: *в* – робастной функции потерь Коши; *г* – функции потерь Focal Loss

Сравнивая результаты из табл. 1 с результатами из табл. 3, а также результаты из табл. 2 с результатами из табл. 4, можно сделать два вывода. Во-первых, модифицированная модель, обученная с применением функции потерь Focal Loss, показывает относительно модели, обученной с применением робастной функции потерь Коши, более высокую точность классификации тестовых фрагментов в случаях, когда модель обучается на фрагментах с площадью зашумления не более 30% при амплитуде выбросов 1,5. То есть для этих сценариев зашумления фрагментов модель с функцией потерь Focal Loss более помехоустойчива. При большей степени зашумления предпочтение следует отдать модифицированной модели U-Net с робастной функцией

потерь Коши. Во-вторых, для модели с функцией потерь Коши прослеживается относительно модели с функцией потерь Focal Loss более медленное падение значений метрики mIoU (медленное снижение помехоустойчивости модели) при увеличении параметров зашумления обучающих фрагментов.

### Заключение

Для исследования точности классификации пораженных вредителями деревьев пихты на зашумленных снимках с БПЛА с помощью модифицированной модели U-Net проведены две серии экспериментов. В первой серии при обучении этой модели использовалась робастная функция потерь Коши, а во второй – известная функция потерь Focal Loss.

По результатам этих исследований можно сделать следующие выводы. Модель, обученная с применением функции потерь Focal Loss, показывает относительно модели, обученной с применением робастной функции потерь Коши, более высокую точность классификации тестовых фрагментов размером 256×256 пикселей в случаях, когда модель обучается на фрагментах с площадью зашумления не более 30% при амплитуде выбросов 1,5. То есть для этих сценариев зашумления фрагментов модель с функцией потерь Focal Loss более помехоустойчива.

При большей степени зашумления предпочтение следует отдать модифицированной модели U-Net с робастной функцией потерь Коши. Более того, для модели с функцией потерь Коши прослеживается относительно модели с функцией потерь Focal Loss более медленное падение значений метрики mIoU (медленное снижение помехоустойчивости модели) при увеличении параметров зашумления обучающих фрагментов.

Эти результаты также позволяют сформулировать рекомендации по практическому применению модифицированной модели U-Net в условиях появления выбросов на исходных снимках. Так, в случаях слабого зашумления снимка (доля зашумленных пикселей не превышает 30% площади его обучающих фрагментов или при амплитуде выбросов менее 3,0) рекомендуется применять модель с функцией потерь Focal Loss. В других случаях, а также при невозможности заранее выявить уровень зашумления снимков, следует использовать эту модель с робастной функцией потерь Коши.

### Литература

1. 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.
2. Invasive pests of forests and urban trees in Russia: origin pathways, damage, and management / D. Musolin, N. Kirichenko, N. Karpun, M. Mandelshtam, A. Selikhovkin, E. Zhuravleva, E. Aksenenko, V. Golub, I. Kerchev, R. Vasaitis, M. Volkovitch, E. Zhuravleva // *Forests*. – 2022. – Vol. 13. – P. 521.
3. Технология мониторинга пихтовых лесов в зоне инвазии уссурийского полиграфа в Сибири: метод. пособие / С.А. Кривец, Э.М. Бисирова, Е.С. Волкова, Н.М. Деб-

ков, И.А. Керчев, М.А. Мельник, А.Н. Никифоров, Н.А. Чернова. – Томск: УМИУМ, 2018. – 74 с.

4. Bystrov S.O. First record of the four-eyed fir bark beetle *Polygraphus proximus* Blandford, 1894 (Coleoptera, Curculionidae: Scolytinae) from Irkutsk province Russia / S.O. Bystrov, I.A. Antonov // *Entomological Review*. – 2019. – Vol. 99. – P. 54–55.

5. Денисов С.А. Опыт применения квадрокоптера для мониторинга возобновления леса / С.А. Денисов, А.А. Домрачев, А.С. Елсуков // *Вестник Поволжского гос. технологического ун-та. Сер.: Лес. Экология. Природопользование*. – 2016. – № 4 (32). – С. 34–46.

6. 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. Maglinets, F. Herrera // *Remote Sensing*. – 2019. – Vol. 11. – P. 643–662.

7. 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.

8. 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.

9. 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.

10. 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. – P. 234–241.

11. 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.

12. Модели U-Net для семантической сегментации поврежденных 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.

13. Clevert D.A. Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs) / D.A. Clevert, T. Unterthiner, S. Hochreiter // *arXiv*. – 2015 [Электронный ресурс]. – Режим доступа: <https://arxiv.org/abs/1511.07289>, свободный (дата обращения: 04.07.2024).

14. Mlotshwa T. Cauchy Loss Function: Robustness Under Gaussian and Cauchy Noise / T. Mlotshwa, H. van Deventer, A.S. Bosman // *arXiv*. – 2023 [Электронный ресурс]. – Режим доступа: <https://arxiv.org/abs/2302.07238>, свободный (дата обращения: 04.07.2024).

15. Focal Loss for Dense Object Detection / T. Lin, P. Goyal, R. Girshick, K. He, P. Dollár // *arXiv*. – 2017 [Электронный ресурс]. – Режим доступа: <https://arxiv.org/abs/1708.02002>, свободный (дата обращения: 04.07.2024).

16. Optimizing the Dice Score and Jaccard Index for Medical Image Segmentation: Theory & Practice / J. Bertels, T. Eelbode, M. Berman, D. Vandermeulen, F. Maes, R. Bisschops, M. Blaschko // *arXiv*. – 2019 [Электронный ресурс]. – Режим доступа: <https://arxiv.org/abs/1911.01685>, свободный (дата обращения: 04.07.2024).

#### Малкин Артем Юрьевич

Ассистент отделения информационных технологий Инженерной школы информационных технологий и робототехники (ИШИТР) Национального исследовательского Томского политехнического университета (НИ ТПУ) Ленина пр-т, 30, г. Томск, Россия, 634050  
Тел.: +7-923-421-14-79  
Эл. почта: [aum27@tpu.ru](mailto:aum27@tpu.ru)

#### Марков Николай Григорьевич

Д-р техн. наук, профессор отделения информационных технологий ИШИТР НИ ТПУ Ленина пр-т, 30, г. Томск, Россия, 634050  
ORCID: 0000-0002-4586-2662  
Тел.: +7 (382-2) 70-17-77 (вн.т. 22-22)  
Эл. почта: [markovng@tpu.ru](mailto:markovng@tpu.ru)

Malkin A.Y., Markov N.G.

#### Noise immunity of the U-Net fully convolutional neural network model for semantic segmentation of fir trees on UAV images

The paper studies the noise immunity of a modified model of a fully convolutional neural network U-Net with robust Cauchy loss function and Focal Loss function when solving the problem of segmentation (pixel classification) of noisy images of fir trees infected by pests. It is shown that the accuracy of multiclassification of such trees decreases with the increase of area noise and the amplitude of impulse noise on the fragments of the training sample. At the same time, the level of accuracy degradation depends on the modified U-Net loss function used for training. For the model with robust Cauchy loss function, there is a slower decrease in noise immunity with increasing values of noise parameters.

**Keywords:** unmanned aerial vehicle, semantic segmentation of fir tree images, Noise immunity of a modified U-Net fully convolutional neural network model.

**DOI:** 10.21293/1818-0442-2024-27-2-64-70

#### References

1. 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.

2. Musolin D., Kirichenko N., Karpun N., Mandelstam M., Selikhovkin A., Zhuravleva E., Aksenenko E., Golub V., Kerchev I., Vasaitis R., Volkovitsh M., Zhuravleva E. Invasive pests of forests and urban trees in Russia: origin pathways, damage, and management. *Forests*, 2022, vol. 13, p. 521.

3. Krivets S.A., Bisirova E.M., Volkova E.S., Debkov N.M., Kerchev I.A., Melnik M.A., Nikiforov A.N., Chernova N.A. *Tekhnologiya monitoringa pihovykh lesov v zone invazii ussurijskogo poligrafa v Sibiri* [Stratigraphy and paleogeography of BerriAsian-Lower Aptian deposits of Western Siberia in connection with the wedge-like structure of crosssection]. Tomsk, UMIUM Publ., 2018. 74 p. (in Russ.).

4. 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.

5. Denisov S.A., Domrachev A.A., Elsuikov A.S. *Opyt primeneniya kvadrokoptera dlya monitoringa vozobnovleniya*

lesa [Experience of using quadcopter for monitoring forest regeneration]. *Vestnik of Volga State University of Technology. Series «Forest. Ecology. Nature Management»*, 2016, no. 1 (32), pp. 34–46 (in Russ.).

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, vol. 11, pp. 643–662.

7. 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.

8. Kerchev I.A., Maslov K.A., Markov N.G., Tokareva O.S. *Semanticheskaya segmentaciya povrezhdennyh derev'ev pihty na snimkah s bespilotnyh letatel'nyh apparatov* [Semantic segmentation of damaged fir trees in unmanned aerial vehicle imagery]. *Current problems in remote sensing of the Earth from Space*, 2021, vol. 18, no. 1, pp. 116–126 (in Russ.).

9. 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.

10. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention*, 2015, vol. 9351, pp. 234–241.

11. Sivak M.A. *Robustnoe obuchenie neyronnyh setej s prostoj arhitekturoj dlya resheniya zadach klassifikacii*. Dissertation for Candidate of Sciences degree. Novosibirsk, 2022, 111 p. (in Russ.).

12. Markov N.G., Maslov K.A., Kerchev I.A., Tokareva O.S. *Modeli U-Net dlya semanticheskoy segmentacii povrezhdennyh derev'ev sosny sibirskoj kedrovoj na snimkah s BPLA* [U-Net models for semantic segmentation of damaged Siberian pine cedar trees in UAV imagery]. *Current problems in remote sensing of the Earth from Space*, 2022, vol. 19, no. 1, pp. 65–77 (in Russ.).

13. Clevert D.A., Unterthiner T., Hochreiter S. Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs). Available at: <https://arxiv.org/abs/1511.07289>, free (Accessed: July 04, 2024).

14. Mlotshwa T., van Deventer H., Bosman A.S. Cauchy Loss Function: Robustness Under Gaussian and Cauchy Noise. Available at: <https://arxiv.org/abs/2302.07238>, free (Accessed: July 04, 2024).

15. Lin T., Goyal P., Girshick R., He K., Dollár P. Focal Loss for Dense Object Detection. Available at: <https://arxiv.org/abs/1708.02002>, free (Accessed: July 04, 2024).

16. Bertels J., Eelbode T., Berman M., Vandermeulen D., Maes F., Bisschops R., Blaschko M. Optimizing the Dice Score and Jaccard Index for Medical Image Segmentation: Theory & Practice. Available at: <https://arxiv.org/abs/1911.01685>, free (Accessed: July 04, 2024).

---

#### Artem Y. Malkin

Teaching Assistant, Division for Information Technology  
School of Computers Science & Robotics  
National Research Tomsk Polytechnic University  
30, Lenin pr., Tomsk, Russia, 634050  
Phone: +7-923-421-14-79  
Email: aym27@tpu.ru

#### Nikolai G. Markov

Doctor of Science in Engineering, Professor, Division for Information Technology,  
School of Computers Science & Robotics  
National Research Tomsk Polytechnic University  
30, Lenin pr., Tomsk, Russia, 634050  
ORCID: 0000-0002-4586-2662  
Phone: +7 (382-2) 70-17-77 (ext. 22-22)  
Email: markovng@tpu.ru