

Сегментация очагов размножения сибирского шелкопряда по спутниковым снимкам

Калинина Анна Сергеевна

студент Сибирского федерального университета, г. Красноярск, Россия, kalininaanna9846@mail.ru

Пятаева Анна Владимировна

к.т.н., доцент, преподаватель Сибирского федерального университета, г. Красноярск, Россия, anna4u@list.ru

АННОТАЦИЯ

Введение: Сибирский шелкопряд является наиболее опасным энтомопатогеном Сибирского региона. Обнаружение областей повреждения этим вредителем является важной практической задачей. **Цель исследования:** Разработка автоматизированного метода обнаружения областей повреждения сибирским шелкопрядом позволит уменьшить экономическое и экологическое воздействие на лесной массив региона. **Результаты:** В качестве основы метода обнаружения областей повреждения использована модифицированная для работы с мультиспектральными снимками архитектура глубокой нейронной сети U-net, выполнен подбор ее гиперпараметров. Программная реализация полученной модели выполнена на языке программирования Python в среде Jupyter Notebook с использованием библиотеки Tensorflow в связке с Keras. Для проведения экспериментальных исследований использованы космоснимки лесного покрова на территории Ирбейского лесничества Красноярского края за период основных вспышек размножения шелкопряда: август и сентябрь 2018 года, июнь и сентябрь 2019 года, август и май 2020 года. Именно на территории этого лесничества преобладают темнохвойные леса, предпочитаемые сибирским шелкопрядом. Самостоятельно построен набор данных из базы спутника Sentinel-2A, содержащий более 40 000 снимков. Максимальная производительность модели по метрике Accuracy 0,98 и потери при обучении ниже 0,002, на валидационном наборе достигнута точность в 87,2%. **Практическая значимость:** Полученные результаты исследований обладают существенной практической значимостью, так как весомо сокращают время работы специалиста, позволяя выполнить обнаружение областей заражения в автоматизированном режиме, кроме того, использование предложенного метода позволяет найти очаги повреждения на раннем этапе, когда эксперт еще не в состоянии отличить пораженных участок от здорового по космоснимку. Использование разработанного метода сегментации областей заражения способствует своевременному назначению мер по защите леса, а значит, имеет немаловажное значение с экономической и экологической точек зрения. **Обсуждение:** Дальнейшим развитием настоящей работы является построение предсказательной модели для прогнозирования возникновения вспышек сибирского шелкопряда, а также учет других возможных вредителей и факторов.

КЛЮЧЕВЫЕ СЛОВА: сегментация; дистанционное зондирование земли; sentinel-2a; сибирский шелкопряд.

Введение

В лесах Урала, Сибири и Дальнего Востока к наиболее вредоносным насекомым-фитофагам относится сибирский шелкопряд [1]. Этот вредитель питается хвойными деревьями, но предпочтение отдает лиственнице, кедру, пихте и ели, реже объедает сосну, а именно хвойные деревья являются преобладающими в лесах Сибири [2]. Деятельность сибирского шелкопряда оказывает существенное влияние на экологическую, экономическую и социальную составляющую жизнедеятельности человека, так как она происходит в зоне арендных участков крупных комбинатов. Особо опасны гусеницы сибирского шелкопряда, так как они дефилируют хвою целиком, а при отсутствии хвои переключаются на кору и даже на шишки. После возникновения вспышки сибирского шелкопряда обычно наблюдается поражение ослабленного участка короедом, что ведет к полному усыханию лесного участка. Это, в свою очередь, увеличивает риск возникновения пожаров, которые наносят непоправимый ущерб лесному хозяйству, экономике и экологии региона.

Миллионы гектар здорового леса ежегодно погибают в Красноярском крае из-за вредоносной деятельности Сибирского шелкопряда. В лесах Ирбейского лесничества вспышки массового размножения вредителя наблюдались в 2018, 2019 и 2020 годах. Увеличению численности вредителя способствовали и благоприятные погодные условия: продолжительный засушливый период, а также благополучная перезимовка большей части гусениц, низкая активность энтомофагов. В результате миграции бабочек в соседние насаждения общая площадь зараженных лесов приняла значительные размеры [3].

Для обнаружения очагов заражения специалисты отдела геоинформационных технологий Центра защиты леса Красноярского края выполняют визуальную оценку спутниковых снимков лесных территорий с использованием облачной платформы ArcGis [4]. При обнаружении подозрительных областей запрашивается ретроспектива космоснимков той же территории для оценки скорости увеличения повреждения. Комплексная оценка скорости изменения размеров повреждения и породного состава насаждений позволяет с высокой долей вероятности правильно определить вид вредителя. Ручное картографирование поврежденных сибирским шелкопрядом лесных массивов на основе спутниковых снимков является очень трудоемким процессом, поэтому автоматическое обнаружение вредителей на основе данных дистанционного зондирования Земли является постоянной темой исследования. Таким образом, обнаружение очагов распространения сибирского шелкопряда по данным спутниковых снимков в автоматизированном режиме является важной практической задачей.

Большинство современных подходов к решению данной проблемы предполагают разработку алгоритмов глубокого обучения, а именно – использование сверточных нейронных сетей [5, 6]. Анализ наиболее значимых работ, посвященных применению глубоких нейронных сетей к задачам лесной отрасли показан в таблице 1.

Кроме глубоких нейронных сетей для решения задач лесного хозяйства, используются и другие методы анализа. Так, при оценке биомассы деревьев по мультиспектральным спутниковым снимкам, применяют классификатор случайный лес [15], для задачи картирования высот лесного покрова по спутниковым данным с высоким пространственным разрешением в работе [16] использованы многолинейная регрессия, случайный лес и метод опорных векторов.

Таблица 1

Анализ работ в лесной отрасли

| Название статьи | Используемые признаки и методы | | | | | | | | | |
|--|--------------------------------------|--------------------------|---------------------|----------------------------|-----------------------|--------------------|--------------------------|--------------------------|-------------|--------------|
| | Задача | Спутник | Разрешение, пиксели | Модель | Алгоритмы оптимизации | Количество классов | Размер обучающей выборки | Количество эпох обучения | Точность, % | Преобработка |
| Deep Learning for Regular Change Detection in Ukrainian Forest Ecosystem with Sentinel-2 [7] | Детектирование рубок | Sentinel-2 | 224×224 | U-net | Adam, SGD | 2 | 12700 | 100 | 55 | + |
| Deep Learning Approach for Calamity Assessment Using Sentinel-2 Data [8] | Распознавание ветровалов | Sentinel-2 | 32×32 | U-net | Adam | 2 | 11310 | 30 | 92 | - |
| Change detection of deforestation in the brazilian amazon using Landsat data and convolutional neural networks [9] | Обнаружение обезлесения | Landsat-8 | 200×200 | ResUnet, Sharp Mask, U-Net | Adam, Nadam | 2 | 3376 | 250 | 94 | - |
| Forest Damage Assessment Using Deep Learning on High Resolution Remote Sensing Data [10] | Обнаружение ветровых борозд | Sentinel-2 | 256×256 | U-net | Adam | 2 | 1525 | 90 | 92 | + |
| Extending deep learning approaches for forest disturbance segmentation on very high resolution satellite images [11] | Распознавание лесных нарушений | WorldView-3 | 256×256 | U-net | Adam | 15 | 30000 | 1500 | 97 | - |
| Deep-learning Versus OBIA for Scattered Shrub Detection with Google Earth Imagery: Ziziphus lotus as Case Study [12] | Распознавание лиственных кустарников | Worldview-2, Pleiades-1A | 224×224 | ResNet | SGD | 2 | 200 | 110 | 97 | + |

| | | | | | | | | | | |
|--|--|-----------------------------|---------------------|-------|-----|---|------|-----|------|---|
| Regional mapping and spatial distribution analysis of canopy palms in an amazon forest using deep learning and VHR images [13] | Распознавание пальм | JE RS-1, Landsat-8, CBERS-4 | 128×128 | U-net | SGD | 2 | 4826 | 300 | 95,5 | + |
| Convolutional Neural Network Approach for Mapping Arctic Vegetation using Multi-Sensor Remote Sensing Fusion [14] | Построение семантически сегментированных карт арктической растительности | SPOT-5, PALSA, AR и IfS AR | 9×9, 36×36, 144×144 | U-net | SGD | 6 | 1200 | 100 | 96 | - |

Алгоритм сегментации областей заражения сибирским шелкопрядом

Для сегментации областей заражения сибирским шелкопрядом использовались спутниковые снимки, полученные по данным Sentinel-2A [17]. На рисунке 1 показан пример размеченного изображения с выделенными областями повреждения сибирским шелкопрядом различного размера: от очень маленьких участков площадью 0,3 га до обширных поврежденных участков площадью 34,6 га.

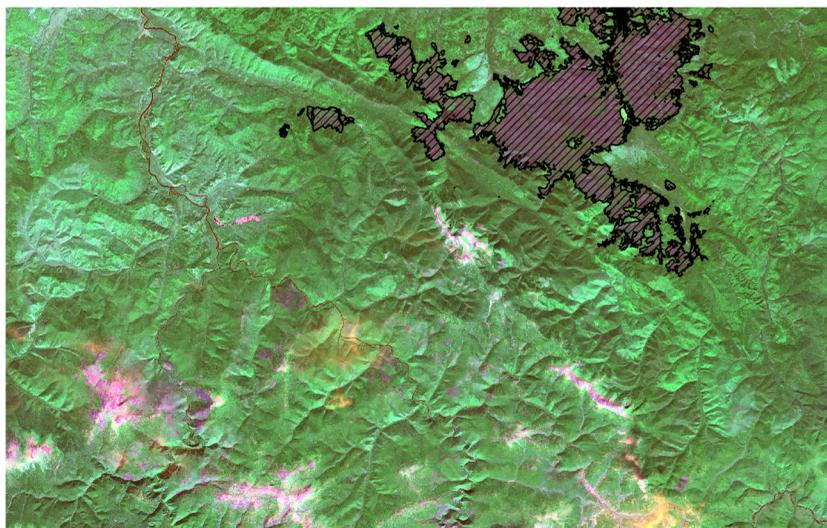


Рис.1. Изображение с меткой поврежденного шелкопрядом участка леса

Для автоматизации процесса обнаружения очагов повреждения лесных территорий сибирским шелкопрядом использована модифицированная архитектура нейронной сети U-net [18]. В ее сверточной части кодирования создается большое количество карт объектов с уменьшенной размерностью, в то время как разверточная часть декодирования используется

для создания карт сегментации (того же размера, что и входные данные) с помощью восходящих сверток. Нейронная сеть U-net модифицирована для работы с мультиканальными спутниковыми снимками (рис. 2) [5].

В модифицированной модели U-net (рис. 2) экспериментальным путем выполнен подбор гиперпараметров, таких как размер батч-пакета, количество эпох, функция потерь, функция активации, размер входного изображения и скорость обучения. При этом настройка осуществлялась с помощью метрики *IoU* [19], а также времени вычисления (эпоха/сек). Метрика *IoU* - intersection over union, показывает, сколько пикселей правильно выделено по сравнению правильно обнаруженных, ложноположительных и ложноотрицательных пикселей. Метрика *IoU* может быть задана выражением (1).

$$IoU = \frac{TP}{TP + FP + FN}, \quad (1)$$

где *TP* - количество истинно-положительных пикселей;

FP – ложноположительных пикселей;

FN - ложноотрицательных пикселей.

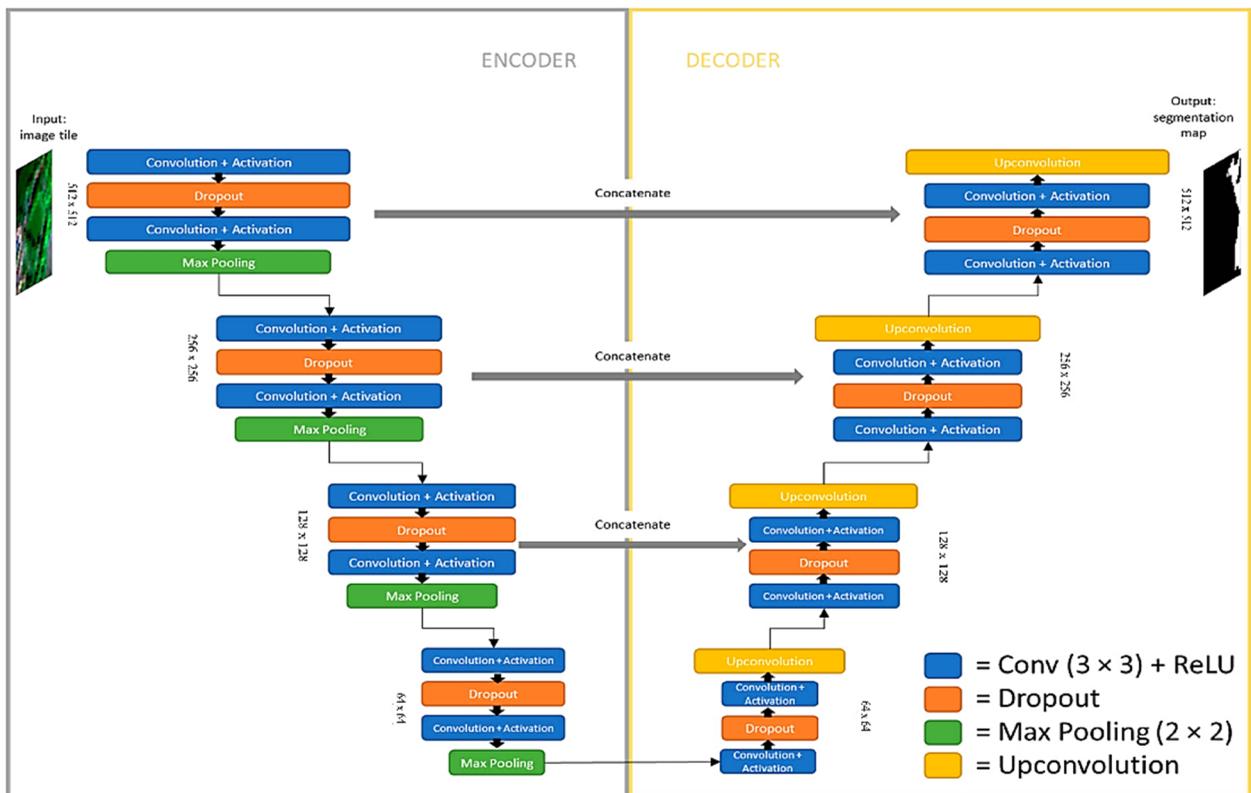


Рис. 2. Модифицированная модель U-Net

В таблице 2 показаны рассчитанные значения для метрики *IoU* и среднего времени вычисления одной эпохи нейронной сети в зависимости от разрешения входного изображения и скорости обучения.

Таблица 2

Определение размера входного изображения и скорости обучения нейронной сети

| Параметр | <i>IoU</i> | Время вычисления (сек/эпоха) |
|--------------------------------------|------------|------------------------------|
| Размер входного изображения, пиксели | | |
| 128×128 | 0,338 | 424 |
| 256×256 | 0,383 | 407 |
| 512×512 | 0,396 | 559 |
| Скорость обучения | | |
| 0,01 | 0,107 | 567 |
| 0,001 | 0,401 | 550 |
| 0,0001 | 0,351 | 555 |
| 0,00001 | 0,317 | 590 |

Как видно из результатов тестирования лучшее качество работы по метрике *IoU* нейронная сеть *U-net* демонстрирует при размере входного изображения в 512 x 512 пикселей и скорости обучения 0,01. Это показывает, что для сегментации алгоритму требуется больше шагов для верного нахождения областей, зараженных сибирским шелкопрядом, что потенциально уменьшает ошибку обучения. Большой размер входного изображения позволяет учесть большее количество значимых признаков. Остальные параметры модели подобраны аналогичным способом итоговая конфигурация сети U-Net состоит в следующем: повторное применение двух сверточных слоев с фильтрами 3×3 во время сжатия с функцией активации ReLU и batch normalization, применяемой к каждому из них, а также операции нелинейного преобразования (слой pooling) 2×2 с шагом 2 для понижающей дискретизации. На каждом шаге понижающей дискретизации удваивается количество функциональных каналов. Расширение заключается в повышающей дискретизации карты объектов, за которой следует свертка 2×2 («свертка вверх»), которая вдвое сокращает число каналов объектов, два сверточных слоя с фильтрами 3×3, за которыми следует функция активации ReLU. Целью данного расширения является точная локализация в сочетании с контекстной информацией из сжимающего пути [20].

Программная реализация полученной модели выполнена на языке программирования Python [21] в среде Jupyter Notebook [22] с использованием библиотеки Tensorflow [23] в связке с Keras [24]. Безусловным достоинством этой библиотеки является возможность производить параллельные вычисления на GPU, что существенно ускоряет процесс обучения и тестирования модели.

Экспериментальные исследования

Для проведения экспериментальных исследований использованы космоснимки лесного покрова, покрывающие территорию Ирбейского лесничества Красноярского края. На территории этого лесничества преобладают темнохвойные леса, именно такие виды деревьев предпочитает сибирский шелкопряд. В качестве рассматриваемых периодов были выбраны: август и сентябрь 2018 года, июнь и сентябрь 2019 года, август и май 2020 года, так как

именно в эти даты наблюдались засушливые периоды, способствующие активному размножению сибирского шелкопряда.

Для обучения нейронной сети вручную сформирован и размечен набор данных, содержащий 180 снимков дистанционного зондирования Земли с разрешением 10980×10980 пикселей. Набор изображений был отобран из базы данных спутника Sentinel-2A. Растровые изображения с географической привязкой были подготовлены в формате GeoTiff. Среди всех снимков за указанный период были выбраны снимки, не содержащие или имеющие незначительную облачность. Каждый снимок разделен на фрагменты размером 512×512 пикселей, так как при таком размере изображений нейронная сеть показала максимальную точность. Далее для фрагментов изображений выполнена аугментация, которая заключалась в повороте изображений (на случайное значение угла до 90°) и случайных мультипликативных изменениях яркости пикселей (до 30 %). Аугментация позволяет существенно увеличить обучающую выборку, что не дает модели переобучаться. Пример полученных изображений представлен на рисунке 4. Подготовленный таким образом набор данных содержал более 40000 снимков. Весь набор данных разделен на три части: обучающая, тестовая и валидационная, в соотношении 63%, 20% и 17% соответственно. Примеры изображений из полученного набора данных приведены на рисунке 3 (а)-(в).

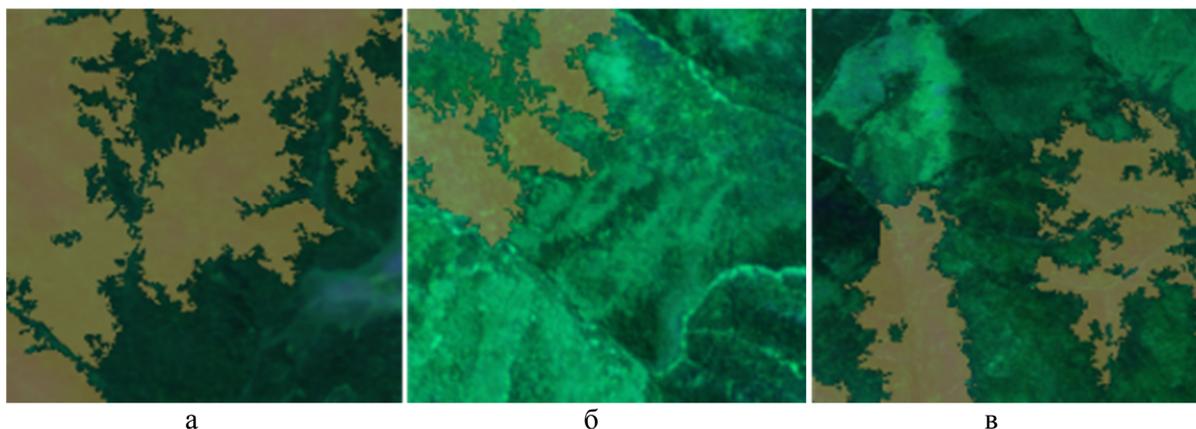


Рис. 3. Примеры изображений из набора данных

Для оценки качества работы модели использованы классические метрики: доля правильных ответов – *Accuracy*; точность – *Precision*; полнота – *Recall* и *F*-мера (*F_score*). Метрики могут быть описаны формулами (2) - (5) соответственно:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}, \quad (2)$$

$$Precision = \frac{TP}{TP + FP}, \quad (3)$$

$$Recall = \frac{TP}{TP + FN}, \quad (4)$$

$$F_score = 2 \times \frac{Precision \times Recall}{Precision + Recall}, \quad (5)$$

где *TN* - количество истинно-отрицательных пикселей. Значения показателей *TP*, *FP* и *FN* вычисляются аналогично выражению (1).

Лучшее значение метрик *Accuracy*, *Precision*, *Recall* и *F*-меры составляет 1,0, а худшее – 0,0.

Таблица 3

Показатели производительности модели

| Метрика | Сибирский шелкопряд | Отсутствие заражения |
|------------------|---------------------|----------------------|
| <i>Precision</i> | 0,943 | 0,985 |
| <i>Recall</i> | 0,932 | 0,999 |
| <i>F_score</i> | 0,937 | 0,992 |
| <i>Accuracy</i> | 0,987 | 0,987 |

Максимальная производительность модели была достигнута на 135 эпохе, обеспечивая точность по метрике *Accuracy* 0,98 и потери при обучении ниже 0,002. На рисунке 4 изображены графики функции ошибки 4-(а) и точности 4-(б) на обучающей и валидационной выборках. Максимальная достигнутая точность на валидационном наборе составила 87,2%.

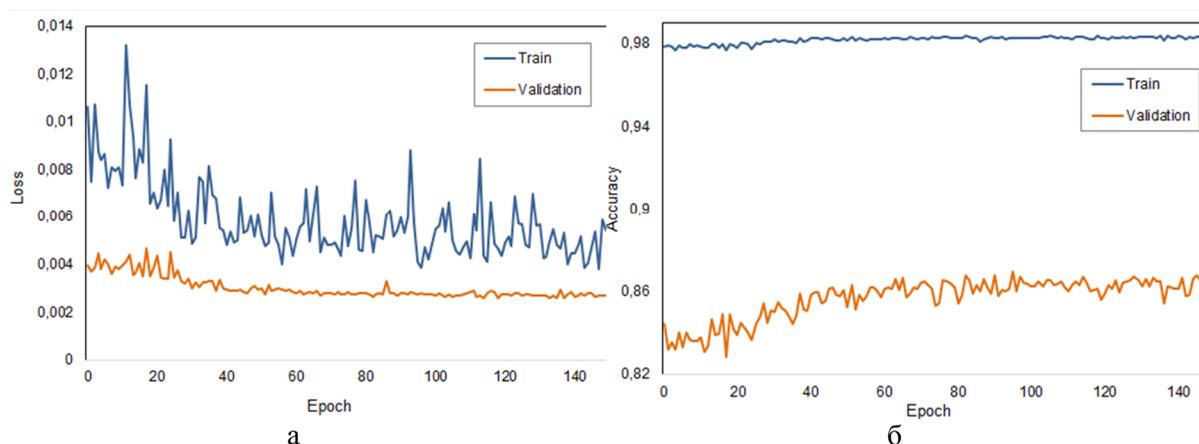


Рис. 4. Результаты сегментации: (а) - функция потерь; (б) – точность по метрике *Accuracy*

На рисунке 5 представлены результаты сегментации поврежденных шелкопрядом лесных участков. Изображения получены на основе комбинации спектральных характеристик каналов Red (664.5 nm), NIR (835.1 nm) и SWIR (2202.4 nm). Преобладающие на рисунках насыщенные оттенки зеленого являются индикаторами здоровой и (или) широколиственной растительности, в то время как более светлые оттенки зеленого цвета характеризуют травянистую или редколесья и кустарниковую растительность. Области, отмеченные на рисунке цветами, отличными от оттенков зеленого, являются регионами, подверженными воздействию сибирского шелкопряда.

Заключение

Обнаружение очагов распространения сибирского шелкопряда по данным спутниковых снимков в автоматизированном режиме является важной практической задачей, имеющей существенное значение для экономики и экологии региона. Разработка автоматизированного способа обнаружения областей, поврежденных сибирским шелкопрядом позволит существенно упростить процесс разметки карт для картографов, сократить время на обработку данных, существенно уменьшить физический объем данных. Кроме того, обнаружение по-

врежденных областей в автоматизированном режиме позволит найти очаги повреждения на раннем этапе, когда эксперт еще не в состоянии визуально отличить на космоснимке пораженный участок от здорового.

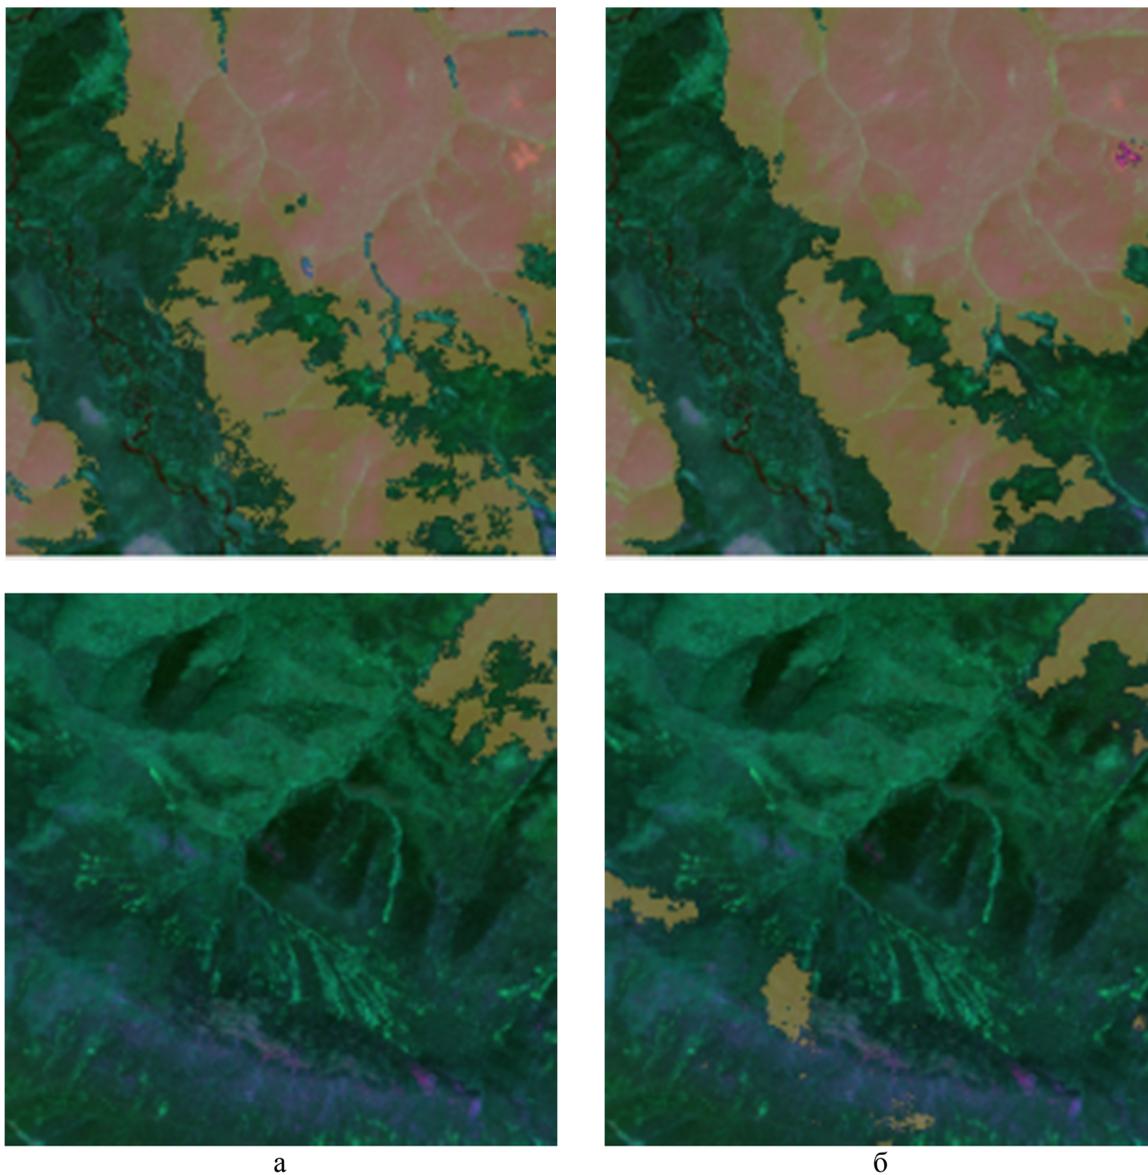


Рис. 5. Результаты работы алгоритма сегментации (а) – снимок, размеченный экспертом вручную; (б) – нейронная сеть

Обнаружение поврежденных областей выполнено на основе модифицированной нейронной сети U-Net, адаптированной для работы с мультисканальными спутниковыми изображениями. В работе экспериментальным путем подобраны гиперпараметры модифицированной нейронной сети. Экспериментальные исследования проведены на самостоятельно построенном наборе данных, полученном из каналов Red, NIR и SWIR спутника Sentinel-2A. Комбинация этих каналов используется специалистами центра защиты леса Красноярского края для визуального поиска повреждений лесных территорий. Из всего массива данных отобраны снимки Ирбейского лесничества, так как на территории этого лесничества нахо-

дятся предпочитаемые сибирским шелкопрядом хвойные породы деревьев. Экспериментальные исследования подтверждают эффективность сегментации областей повреждения сибирским шелкопрядом на основе технологий глубокого обучения, а именно с применением модифицированной нейронной сети U-Net.

Таким образом, полученные в работе результаты подчеркивают возможность обнаружения поврежденных шелкопрядом лесных участков с использованием данных Sentinel-2A в автоматическом режиме. Теоретическая и практическая значимость исследования состоит в развитии подходов в применении методов глубокого обучения совместно с данными дистанционного зондирования Земли для обследования лесов и обнаружения их повреждений.

Дальнейшее развитие этой работы может позволить своевременно получать данные о возникновении заражения вредителями лесных насаждений на ранних этапах, когда визуальных признаков ещё не появилось. Раннее обнаружение зараженных участков позволит своевременно отреагировать на ситуацию, значительно сократить затраты на предотвращение распространения вредителей и снизить материальный и экологический потенциальный ущерб.

Литература

1. *Тарасова О. В., Волков В. Е.* Влияние погодных условий на развитие вспышек массового размножения сибирского шелкопряда в средней Сибири // Сибирский лесной журнал. 2021. №5. С. 49-59, doi: 10.15372/SJFS20210506.
2. *Кузьмин С.Р., Кузьмина Н.А.* Лесосеменные районы сосны обыкновенной на основе оценки роста географических культур в Сибири // Сибирский лесной журнал. 2020. №6. С. 3-15, doi: 10.15372/SJFS20200601.
3. *Иванова Ю.Д., Ковалев А.В.* Размещение особей сибирского шелкопряда в границах очагов вспышки массового размножения // Сибирский лесной журнал. 2021. № 5. С. 37-48, doi: 10.15372/SJFS20210505.
4. *Облачная платформа ArcGis.* URL: <https://www.arcgis.com/index.html> (дата обращения 05.07.2022).
5. *Хрящев В.В., Приоров А.Л., Павлов В.А., Ларионов Р.В.* Модификация архитектуры сверточной нейронной сети U-net в задаче сегментации мультисканальных спутниковых изображений // Цифровая обработка сигналов. 2019. №3. С. 39-45.
6. *Керчев И.А., Маслов К.А., Марков Н.Г, Токарева О.С.* Семантическая сегментация повреждённых 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.
7. *Isaienkov K.* Deep Learning for Regular Change Detection in Ukrainian Forest Ecosystem with Sentinel-2 // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2021. V. 14. Pp. 364–376, doi: 10.1109/JSTARS.2020.3034186.
8. *Scharvogel D., Brandmeier M., Weis M.* Deep Learning Approach for Calamity Assessment Using Sentinel-2 Data // Forests. 2020. V. 11. Pp. 1239, doi: 10.3390/f11121239.
9. *Bem de P. P., De Carvalho O. A., Guimarães R. F., Gomes R. A. T.* Change detection of deforestation in the brazilian amazon using landsat data and convolutional neural networks // Remote Sensing. 2020. V. 12(6). Pp. 901, doi:10.3390/rs11171976.
10. *Hamdi Z.M., Brandmeier M., Straub Ch.* Forest Damage Assessment Using Deep Learning on High Resolution Remote Sensing Data // Remote Sensing. 2019. Vol. 11(17). Pp. 1976, doi: 10.3390/rs11171976.
11. *Kislov D. E., Korznikov K.A., Altman J., Vozmishcheva A.S., Krestov P.V.* Extending deep learning approaches for forest disturbance segmentation on very high resolution satellite images //

Remote Sensing in Ecology and Conservation. 2021. Vol. 7. №. 3. Pp. 355-368, doi: 10.1002/rse2.194.

12. *Guirado E, Tabik S., Alcaraz Segura D., Cabello J., Herrera F.* Deep-learning Versus OBIA for Scattered Shrub Detection with Google Earth Imagery: *Ziziphus lotus* as Case Study // Remote Sensing. 2017. No. 9. Pp. 1220, doi: 10.3390/rs9121220.

13. *Wagner F. H., Da Silva R.D., Nagle X., Streher A.S., Phillips O.L., Gloor M., Aragao L.E.O.C.* Regional mapping and spatial distribution analysis of canopy palms in an amazon forest using deep learning and VHR images // Remote Sensing. 2020. T. 12. №. 14. Pp. 2225, doi: 10.3390/rs12142225.

14. *Langford Z. L., Kumar J., Hoffman F.M.* Convolutional Neural Network Approach for Mapping Arctic Vegetation using Multi-Sensor Remote Sensing Fusion // IEEE International Conference on Data Mining Workshops (New Orleans, LA, USA, 18-21 November 2017), 2017. Pp. 322-331, doi: 10.1109/ICDMW.2017.48.

15. *Lourevco P., Godinho S., Sousa A., Goncalves A.C.* Estimating tree aboveground biomass using multispectral satellite-based data in Mediterranean agroforestry system using random forest algorithm // Remote Sensing Applications: Society and Environment, 2021, doi :10.1016/J.RSASE.2021.100560.

16. *Huang W., Min W., Ding J., Liu Y., Hu Y., Ni W., Shen H.* Forest height mapping using inventory and multi-source satellite data over Hunan Province in southern China // Forest Ecosystems, V. 9, 2022, doi: 10.1016/j.fecs.2022.100006.

17. The European Space Agency. Sentinel Online. URL: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2> (дата обращения 05.07.2022).

18. *Ronneberger O., Fischer P., Brox T.* U-Net: Convolutional Networks for Biomedical Image Segmentation. Medical Image Computing and Computer-Assisted Intervention (MICCAI), Springer, LNCS, V. 9351, 2015. Pp. 234-241.

19. *Rahman M. A., Wang Y.* Optimizing Intersection-Over-Union in Deep Neural Networks for Image Segmentation. Advances in Visual Computing. ISVC 2016. Lecture Notes in Computer Science, V. 10072, 2016, Springer, Cham, doi: 10.1007/978-3-319-50835-1_22.

20. *Калинина А.С.* Распознавание очагов массового размножения стволовых вредителей на спутниковых снимках с помощью нейронной сети // Материалы II Международной научно-практической конференции «Студенческий научный форум 2021» (Пенза, 23 декабря 2021 г.). Пенза, 2021. С. 63-66.

21. Python. URL: <https://www.python.org/> (дата обращения 05.07.2022).

22. Jupyter Notebook: The Classic Notebook Interface. URL: <https://jupyter.org/> (дата обращения 05.07.2022).

23. Сквозная платформа с открытым исходным кодом для машинного обучения TensorFlow. URL: <https://www.tensorflow.org/> (дата обращения 05.07.2022).

24. Deep learning framework Keras. URL: <https://keras.io/> (дата обращения 05.07.2022).

BREEDING HOUSES OF THE SIBERIAN SILKWORM SEGMENTATION BY SATELLITE DATA

ANNA S. KALININA,

Student, Siberian Federal University, Russia,
Krasnoyarsk, kalininaanna9846@mail.ru

ANNA V. PYATAEVA,

PhD, Docent, Lecturer of the Siberian Federal
University, Russia, Krasnoyarsk, anna4u@list.ru

ABSTRACT

Introduction: The Siberian silkworm is the most dangerous insect pest in the Siberian region. The detection of damage areas by this pest is an important practical task. **Purpose:** The development of an automated method for detecting areas of damage by the Siberian silkworm will reduce the economic and environmental impact on the forest area of the region. **Results:** As the basis of the method for detecting areas of damage, the architecture of the U-net deep neural network modified for working with multispectral images was used, and its hyperparameters were selected. The software implementation of the resulting model was made in the Python programming language in the Jupyter Notebook environment using the Tensorflow library in conjunction with Keras. For experimental studies, satellite images of the forest cover on the territory of the Irbey forestry of the Krasnoyarsk Territory were used during the period of the main outbreaks of silkworm reproduction: August and September 2018, June and September 2019, August and May 2020. It is on the territory of this forest area that dark coniferous forests, preferred by the Siberian silkworm, prevail. Self-built data set from the Sentinel-2A satellite database containing more than 40,000 images. The maximum performance of the model according to the Accuracy metric is 0.98 and the training loss is below 0.002, an accuracy of 87.2% is achieved on the validation set. **Practical relevance:** The obtained results of the research have significant practical significance, as they significantly reduce the time of the specialist's work, allowing the detection of areas of infection in an automated mode, in addition, the use of the proposed method allows you to find lesions at an early stage, when the expert is not yet able to distinguish the affected area from the healthy one by satellite image. The use of the developed method of segmentation of areas of infection contributes to the timely appointment of measures to protect the forest, which means that it is of no small importance from an economic and environmental point of view. **Discussion:** The further development of this work is the construction of a predictive model for predicting the occurrence of outbreaks of the Siberian silkworm, as well as taking into account other possible pests and factors.

Keywords: segmentation; Earth remote sensing; Sentinel-2A; siberian silkworm.

REFERENCES

1. Tarasova O. V., Volkov V. E. Vliyanie pogodnyh usloviy na razvitie vspyshek massovogo razmnozhenija sibirskogo shelkopryada v srednej Sibiri [Influence of weather conditions on the development of Siberian silk moth outbreaks in Central Siberia]. *Sibirskij lesnoj zhurnal* [Siberian forest journal]. 2021. №5. Pp. 49-59, doi: 10.15372/SJFS20210506. (In Rus)
2. Kuzmin S.R., Kuzmina N.A. Lesosemennye rajony sosny obyknovnoj na osnove ocenki rosta geograficheskikh kul'tur v Sibiri [Forest seed regions of scots pine based on growth assessment in the provenance trial in Siberia]. *Sibirskij lesnoj zhurnal* [Siberian forest journal]. 2020. №6. Pp. 3-15, doi: 10.15372/SJFS20200601. (In Rus)
3. Ivanova Yu.D., Kovalev A.V. Razmeshhenie osobej sibirskogo shelkopryada v granicah ochagov vspyshki massovogo razmnozhenija [Placement of Siberian silkworm individuals within the outbreak of mass reproduction]. *Sibirskij lesnoj zhurnal* [Siberian forest journal]. 2021. № 5. Pp. 37-48, doi: 10.15372/SJFS20210505. (In Rus)
4. Oblachnaja platforma ArcGis [Cloud platform ArcGis]. URL: <https://www.arcgis.com/index.html> (date of access 05.07.2022). (In Rus)
5. Khryashchev V.V., Priorov A.L., Pavlov V.A., Larionov R.V. Modifikacija arhitektury svertochnoj nejronnoj seti U-net v zadache segmentacii mul'tikanal'nyh sputnikovyh izobrazhenij [Modification of the U-net convolutional neural architecture in the multi-channel satellite images segmentation problem]. *Cifrovaja obrabotka signalov* [Sinhala digital processing]. 2019. №3. Pp. 39-45. (In Rus)
6. Kerchev I.A., Maslov K.A., Markov N.G., Tokareva O.S. Semanticheskaja segmentacija povrezhdjonnyh derev'ev pihty na snimkah s bespilotnyh letatel'nyh apparatov [Semantic segmentation of damaged fir trees in unmanned aerial vehicle images]. *Sovremennye problemy distancionnogo zondirovanija Zemli iz kosmosa* [Modern problems of remote sensing of the Earth from space]. 2021. T. 18. №1. Pp. 116–126, doi: 10.21046/2070-7401-2021-18-1-116-126. (In Rus)
7. Isaienkov K. Deep Learning for Regular Change Detection in Ukrainian Forest Ecosystem with Sentinel-2 // *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2021. V. 14. Pp. 364–376, doi: 10.1109/JSTARS.2020.3034186.
8. Scharvogel D. Brandmeier M., Weis M. Deep Learning Approach for Calamity Assessment Using Sentinel-2 Data // *Forests*. 2020. V. 11. Pp. 1239, doi: 10.3390/f11121239.
9. Bem de P. P., De Carvalho O. A., Guimarães R. F., Gomes R. A. T. Change detection of deforestation in the brazilian amazon using landsat data and convolutional neural networks // *Remote Sensing*. 2020. V. 12(6). Pp. 901, doi:10.3390/rs11171976.
10. Hamdi Z.M., Brandmeier M., Straub Ch. Forest Damage Assessment Using Deep Learning on High Resolution Remote Sensing Data // *Remote Sensing*. 2019. Vol. 11(17). Pp. 1976, doi: 10.3390/rs11171976.
11. Kislov D. E., Korznikov K.A., Altman J., Vozmishcheva A.S., Krestov P.V. Extending deep learning approaches for forest disturbance segmentation on very high-resolution satellite images // *Remote Sensing in Ecology and Conservation*. 2021. V. 7. №. 3. Pp. 355-368, doi: 10.1002/rse2.194.
12. Guirado E, Tabik S., Alcaraz Segura D., Cabello J., Herrera F. Deep-learning Versus OBIA for Scattered Shrub Detection with Google Earth Imagery: *Ziziphus lotus* as Case Study // *Remote Sensing*. 2017. No. 9. Pp. 1220, doi: 10.3390/rs9121220.
13. Wagner F. H., Da Silva R.D., Nagle X., Streher A.S., Phillips O.L., Gloor M., Aragao L.E.O.C. Regional mapping and spatial distribution analysis of canopy palms in an amazon forest using deep learning and VHR images // *Remote Sensing*. 2020. T. 12. №. 14. Pp. 2225, doi: 10.3390/rs12142225.
14. Langford Z. L., Kumar J., Hoffman F.M. Convolutional Neural Network Approach for Mapping Arctic Vegetation using Multi-Sensor Remote Sensing Fusion // *IEEE International Conference on Data Mining Workshops (New Orleans, LA, USA, 18-21 November 2017)*, 2017. Pp. 322-331, doi: 10.1109/ICDMW.2017.48.
15. Loureco P., Godinho S., Sousa A., Goncalves A.C. Estimating tree aboveground biomass using multispectral satellite-based data in Mediterranean agroforestry system using random forest algorithm // *Remote Sensing Applications: Society and Environment*, 2021, doi :10.1016/J.RSASE.2021.100560.

16. Huang W., Min W., Ding J., Liu Y., Hu Y., Ni W., Shen H. Forest height mapping using inventory and multi-source satellite data over Hunan Province in southern China // *Forest Ecosystems*, V. 9, 2022, doi: 10.1016/j.fecs.2022.100006.
17. The European Space Agency. Sentinel Online. URL: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2> (date of access 05.07.2022).
18. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, Springer, LNCS, V. 9351, 2015. Pp. 234-241.
19. Rahman M. A., Wang Y. Optimizing Intersection-Over-Union in Deep Neural Networks for Image Segmentation. *Advances in Visual Computing. ISVC 2016. Lecture Notes in Computer Science*, V. 10072, 2016, Springer, Cham, doi: 10.1007/978-3-319-50835-1_22.
20. Kalinina A.S. Raspoznavanie ochagov massovogo razmnozhenija stvolovyh vreditelej na sputnikovyh snimkah s pomoshh'ju nejronnoj seti [Recognition of foci of mass reproduction of stem pests in satellite images using a neural network]. *Materialy II Mezhdunarodnoj nauchno-prakticheskoj konferencii "Studentcheskij nauchnyj forum 2021"* [Proceedings of the II International Scientific and Practical Conference "Student Scientific Forum 2021", Penza, on December 23, 2021]. Penza, 2021. Pp. 63-66. (In Rus)
21. Python. URL: <https://www.python.org/> (date of access 05.07.2022).
22. Jupyter Notebook: The Classic Notebook Interface. URL: <https://jupyter.org/> (date of access 05.07.2022).
23. Ckvoznaja platforma s otkrytym ishodnym kodom dlja mashinnogo obuchenija TensorFlow [End-to-End Open Source Machine Learning Platform TensorFlow]. URL: <https://www.tensorflow.org/> (date of access 05.07.2022). (In Rus)
24. Deep learning framework Keras. URL: <https://keras.io/> (date of access 05.07.2022).