Семантическая сегментация повреждённых деревьев пихты на снимках с беспилотных летательных аппаратов

И.А. Керчев¹, К.А. Маслов², Н.Г. Марков², О.С. Токарева²

¹ Институт мониторинга климатических и экологических систем СО РАН Томск, 634055, Россия E-mail: ivankerchev@gmail.com ² Национальный исследовательский Томский политехнический университет Томск, 634030, Россия E-mails: kam20@tpu.ru, markovng@tpu.ru, ost@tpu.ru

В последние годы свёрточные нейронные сети нашли применение при анализе космических снимков и изображений земной поверхности, полученных с использованием беспилотных летательных аппаратов (БПЛА). Особенно полезной оказалась их способность к автоматическому извлечению признаков изображения (текстур и форм объектов). В статье описана проблема анализа состояния деревьев пихты по снимкам с БПЛА, дана характеристика объектов исследования и проведён разведочный анализ исходных данных, позволивший осуществить проектирование новой модели свёрточной нейронной сети. Предложена модель свёрточной нейронной сети U-Net. С её помощью решается задача семантической сегментации изображений пихтовых насаждений, повреждённых уссурийским полиграфом, полученных с помощью БПЛА. Приведена архитектура предложенной модели нейронной сети и решены основные задачи, касающиеся процессов её обучения и оценивания качества семантической сегментации, полученной с помощью этой модели. Результаты исследования показали довольно высокую эффективность модели при классификации пикселей классов «фон», «живые», «свежий сухостой» и «старый сухостой».

Ключевые слова: уссурийский полиграф, деревья пихты, беспилотный летательный аппарат, семантическая сегментация изображений, свёрточная нейронная сеть, U-Net

Одобрена к печати: 09.12.2020 DOI: 10.21046/2070-7401-2021-18-1-116-126

Введение

Одним из основных негативных факторов, воздействующих на пихтовые леса ряда регионов Южной Сибири (Кривец и др., 2018), Байкальского региона (Bystrov, Antonov, 2019) и Предуралья (Проведение..., 2020), является инвазивный короед — уссурийский полиграф *Polygraphus proximus* Blandf. При заселении здоровых деревьев вредитель вносит под кору пропагулы фитопатогенных офиостомовых грибов, которые вызывают некрозы луба и более глубоких тканей ствола (Пашенова и др., 2012; Pashenova et al., 2018). В результате нарушения работы ассимиляционно-диссимиляционного аппарата происходит постепенная гибель дерева с характерной дехромацией хвои. Обширные очаги усыхания пихтарников, вызванные чужеродным короедом, влекут за собой значимые экономические и экологические последствия (Кривец и др., 2018). Наличие такого фактора требует проведения непрерывного и оперативного мониторинга пихтовых насаждений с целью оценки их состояния, планирования санитарных и лесозащитных мероприятий.

Данные дистанционного зондирования Земли, полученные с использованием беспилотных летательных аппаратов (БПЛА), сегодня активно применяются при решении задач экологического мониторинга лесных насаждений, обеспечивая при этом высокое пространственное разрешение получаемых снимков и оперативность в принятии решений (Санников и др., 2018; Berie, Burud, 2018; Safonova et al., 2019). Для анализа изображений, полученных в результате съёмки лесных массивов с БПЛА, обычно используют различные традиционные методы классификации (Chenari et al., 2017; Gini et al., 2018; Lee et al., 2019). В работе (Onishi,

Ise, 2018) предлагается классифицировать деревья различных пород с использованием методов глубокого обучения. В исследовании (Safonova et al., 2019) для классификации деревьев пихты применены свёрточные нейронные сети (СНС). Перспективными также могут оказаться СНС, позволяющие решать задачи семантической сегментации изображений.

Данная статья посвящена разработке модели СНС и её исследованию при решении задачи семантической сегментации деревьев пихты, повреждённых уссурийским полиграфом, на снимках с БПЛА. В отличие от других моделей СНС, используемых, например, в работе (Safonova et al., 2019), эта модель позволяет выполнять попиксельную классификацию поражённых деревьев пихты.

Задача анализа состояния деревьев пихты по снимкам с БПЛА

Для оперативного мониторинга повреждённых уссурийским полиграфом деревьев пихты Институтом мониторинга климатических и экологических систем (ИМКЭС) СО РАН разработана оценочная шкала их жизненного состояния (Кривец и др., 2018). На *рис. 1* приведены шесть категорий состояния деревьев пихты сибирской (*Abies sibirica*) в очагах массового размножения уссурийского полиграфа в соответствии с этой шкалой. Первая из них — здоровое дерево, хвоя зелёная; вторая категория — дерево атаковано полиграфом, но не заселено, крона его как у здорового дерева или изреженная, несколько ветвей имеют на концах хвою ярко-рыжего цвета. К третьей категории относятся атакованные полиграфом, но незаселённые, сильно ослабленные деревья. Их кроны могут быть как у здоровых деревьев, но более половины ветвей несут усыхающую хвою. Четвёртая категория — заселённые полиграфом усыхающие деревья, хвоя которых в верхней части кроны ещё зелёная, но ниже на ветках — яркорыжего цвета. Пятая категория — свежий сухостой, хвоя кроны мёртвая, красная. Наконец, шестая категория — старый сухостой, крона мёртвая, серая, хвоя полностью осыпалась.



Рис. 1. Деревья пихты на различных стадиях повреждения полиграфом. Римскими цифрами обозначены категории деревьев (Кривец и др., 2018)

Осуществление лесопатологических обследований дистанционным методом с использованием космических аппаратов и БПЛА с соответствующей съёмочной аппаратурой значительно расширяет возможности мониторинга пихтовых лесов. Важно как можно раньше выявить наличие деревьев пихты второй и третьей категории, чтобы спланировать и провести фитосанитарные мероприятия.

В наших исследованиях в качестве исходных данных для анализа состояния деревьев пихты использованы два снимка участков пихтового леса в Томской обл., заселённых уссурийским полиграфом, с пространственным разрешением около 0,1 м. Снимки получены с помощью БПЛА (квадрокоптер DJI Phantom 3 Standart) с установленной на нём фотокамерой, ведущей съёмку в видимом диапазоне электромагнитного спектра (цветовая модель RGB) с высоты 365 и 388 м в период с 7 по 28 августа 2017 г. Для анализа этих снимков предлагается разработать, обучить и использовать модель СНС, позволяющую решать задачу семантической сегментации изображений.

Кроны деревьев на снимках были размечены экспертом с учётом категории деревьев. В силу того, что при разметке снимков визуально эксперту не удавалось отделить некоторые категории деревьев друг от друга, было решено объединить близкие категории в один класс. При этом в первый класс попали деревья первой и второй категорий, во второй класс — третьей и четвёртой. В результате выделены следующие четыре класса деревьев: 1 — «живые», 2 — «отмирающие» (сильно ослабленные, усыхающие), 3 — «свежий сухостой» и 4 — «старый сухостой» (сухостой прошлых лет). Пример такой разметки на трёх фрагментах снимков приведён на *рис. 2a*. Далее в соответствии с первичной точечной разметкой эксперта на снимках были выделены эталонные сегменты (полигоны), представляющие кроны деревьев пихты разных классов и фон. Примеры эталонных карт сегментации приведены на *рис. 26*.



Puc. 2. Фрагменты исходных снимков с разметкой по классам (*a*) и соответствующих им эталонных карт сегментации (*б*)

На одном из снимков был выбран тестовый участок. Он не участвовал в дальнейшем обучении СНС, а использовался исключительно для оценки эффективности предлагаемой модели. В итоге были сформированы обучающая и тестовая выборки — изображения и соответствующие им эталонные карты сегментации для разрабатываемой модели СНС.

Разведочный анализ данных

Для разработки модели СНС необходимо провести разведочный анализ полученных эталонных карт сегментации. На *рис. 3* представлены гистограммы, показывающие соотношения объектов различных классов в обучающей выборке. Видно, что наблюдается значительная несбалансированность классов: преобладают пиксели класса «фон», среди деревьев наименее представленными оказались деревья классов «отмирающие» и «свежий сухостой». Данный факт учитывался при обучении модели СНС.



Рис. 3. Количество пикселей (a) и деревьев (δ) по классам в обучающей выборке

Для оценки разделимости классов был проведён анализ UMAP-вложений (*анел*. Uniform Manifold Approximation and Projection) и коэффициентов силуэта (*анел*. silhouette coefficients), изображения которых приведены на *рис.* 4. Поскольку стоит задача разделения крон деревьев пихты по классам, были рассмотрены спектральные характеристики сегментов, ограничивающих кроны. В качестве признаков сегментов использовались гистограммы яркости в RGB-каналах снимка: для каждого из трёх каналов была построена гистограмма яркости с 15 интервалами разбиения; таким образом, вектор признаков для каждого сегмента представлял собой упорядоченный набор из 45 чисел.



Рис. 4. UMAP-вложения для гистограмм сегментов (*a*, *б*); диаграмма силуэтов для гистограмм сегментов (*в*). Пунктирной линией показано среднее значение коэффициента силуэта

UMAP — метод снижения размерности пространства признаков, позволяющий анализировать характер распределения многомерных данных. Идея метода заключается в поиске такого представления данных в пространстве меньшей размерности, чтобы топологическая структура искомого представления была схожа с исходной (McInnes et al., 2018). При построении UMAP-вложений гистограмм сегментов (см. *рис. 4a* и б) варьировались два параметра алгоритма: количество ближайших соседей в топологической структуре исходных данных (n_n) и минимальное расстояние между точками в результирующем представлении меньшей размерности (min_dist).

Коэффициенты силуэта позволяют оценивать разделимость классов, основываясь на вычислении относительных расстояний между векторами признаков. Коэффициент силуэта для конкретного экземпляра (в нашем случае сегмента, представляющего крону дерева) рассчитывается как разность среднего расстояния от этого экземпляра в пространстве признаков до всех экземпляров ближайшего соседнего класса и среднего расстояния от этого экземпляра до всех остальных экземпляров внутри своего класса, делёная на максимальное из этих расстояний. Близкие к единице значения коэффициента указывают на хорошо отделимые от ближайшего соседнего класса экземпляры, отрицательные — на наиболее вероятно относящиеся к ближайшему соседнему классу, близкие к нулю — на близость экземпляра к границе принятия решения (Rousseeuw, 1987). Внутри каждого класса экземпляры сортируются по значению коэффициента силуэта и наносятся на диаграмму силуэтов, где вдоль вертикальной оси отображаются классы, а вдоль горизонтальной — значения коэффициентов силуэта для сегментов.

Анализируя локальные особенности распределения данных (см. *рис. 4a*), можно сказать о наличии двух крупных кластеров, один из которых состоит преимущественно из точек,

относящихся к классам «живые» и «отмирающие», а другой — из точек классов «свежий сухостой» и «старый сухостой», при этом сложно построить границы решений для разделения классов уже внутри этих кластеров. На *рис. 46*, показывающем глобальные особенности распределения, наблюдается переход между классами в порядке ухудшения состояния деревьев пихты. Анализ диаграммы силуэтов (см. *рис. 46*) позволяет сделать вывод о низкой разделимости классов в обучающей выборке в общем, так как среднее значение коэффициента силуэта составило 0,083. Значительной доле сегментов классов «отмирающие», «свежий сухостой» и «старый сухостой» соответствуют отрицательные значения коэффициентов силуэта.

Таким образом, разведочный анализ исходных данных показал, что поставленная задача сегментации не является тривиальной, поскольку учёт только цветовых характеристик пикселей, составляющих сегменты, не позволяет достичь высокой разделимости классов. В связи с этим необходимо использовать достаточно сложные модели, способные учитывать текстуру объектов и их форму, например модели СНС, позволяющие решать задачи попиксельной классификации.

Предлагаемая модель СНС

В качестве базовой была выбрана архитектура CHC U-Net, относящаяся к классу полносвёрточных сетей (*англ.* fully convolutional network). Первоначально она была разработана для решения задачи сегментации биомедицинских изображений, где показана её очень высокая эффективность (Ronneberger et al., 2015). Эта модель имеет две составляющие: энкодер и декодер. Энкодер, используя последовательность свёрточных слоёв (*англ.* convolutional) и слоёв подвыборки (*англ.* pooling), преобразует исходное изображение в представление скрытого пространства. Декодер преобразует представление скрытого пространства в итоговую карту классификации с помощью слоёв масштабирования и свёрточных слоёв. На последнем слое к картам признаков применяется свёртка 1×1 с необходимым для конкретной задачи количеством фильтров. Также характерная особенность архитектуры сетей подкласса U-Net заключается в наличии операций конкатенации, соединяющих карты признаков из энкодера с картами признаков в декодере с целью повышения детальности результирующих карт классификации (Ronneberger et al., 2015).



Рис. 5. Архитектура предлагаемой модели СНС

Исходная СНС U-Net была модифицирована нами для классификации пикселей, соответствующих четырём классам деревьев пихты и фону. На *рис. 5* представлена архитектура предлагаемой модели СНС, где каждому прямоугольнику соответствует тензор — многомерный массив, представляющий собой набор карт признаков, числами обозначено количество компонентов тензоров. Стрелками показаны соответствующие операции: свёртка (Conv3×3, Conv1×1), вычисление функции активации ReLU, пакетная нормализация (BN) (Ioffe, Szegedy, 2015), уменьшение масштаба карт признаков путём выбора максимального значения из соседних в картах признаков (MaxPooling), увеличение масштаба карт признаков (UpSampling), копирование тензора и его конкатенация с другим (Copying+Concatenation). Категориальное распределение на выходе декодера моделируется для каждого пикселя путём применения многомерной логистической функции Softmax.

В отличие от базовой CHC U-Net предлагаемая модель обладает следующими особенностями: входное изображение сети представлено тензором с числом компонентов $256 \times 256 \times 3$, что соответствует фрагменту трёхканального RGB-снимка; операции свёрток не уменьшают размер выходных карт признаков; после каждого вычисления ReLU следует операция пакетной нормализации; выходной тензор формируется с помощью пяти свёрток с ядрами размером 1×1 , позволяя тем самым сразу классифицировать пиксели пяти классов.

Для программной реализации модели CHC и процедуры обучения был использован язык программирования Python и библиотека Keras.

Метрики качества классификации. Для оценки эффективности модели СНС были использованы метрики *Precision*, *Recall* и *F*1-мера, которые определяются для каждого класса следующим образом (Hossin, Sulaiman, 2015): *Precision*_c = $TP_c/(TP_c + FP_c)$, *Recall*_c = $TP_c/(TP_c + FN_c)$, $F1_c = 2Precision_c \times Recall_c/(Precision_c + Recall_c)$, где TP_c , FP_c , FN_c обозначают соответственно количество истинно-положительных, ложно-положительных и ложно-отрицательных решений для класса *c*.

Кроме того, была использована метрика intersection over union (*IoU*), считающаяся общепринятой метрикой эффективности при решении задачи семантической сегментации цифровых изображений, которая вычисляется по формуле (Rahman, Wang, 2016): $IoU_c = TP_c/(TP_c + FP_c + FN_c)$. Известно, что значения *IoU*, превышающие 0,5, соответствуют приемлемому качеству сегментации. В качестве совокупного показателя качества модели была использована метрика mean intersection over union (*mIoU*), рассчитываемая как среднее значение *IoU* по всем классам.

Процесс обучения модели. Для минимизации разницы в условиях освещённости различных сцен исходной выборки была проведена процедура совмещения гистограмм, при этом в качестве опорного изображения был выбран один снимок из обучающей выборки. Для формирования обучающих и валидационных примеров для СНС снимки из обучающей выборки были нарезаны на фрагменты 256×256 пикселей со сдвигом 128 пикселей. Также осуществлялась аугментация данных путём поворота исходных снимков. Утечка данных из валидационной выборки устранялась наложением масок на исходные снимки. Таким образом, гарантировалось, что признаки валидационных примеров не будут повторяться среди обучающих примеров. Всего было получено 2469 обучающих и 360 валидационных примеров.

С целью улучшения обобщающей способности модели СНС была использована техника аугментации «на лету» (*англ.* online augmentation), позволяющая расширить обучающую выборку путём случайных преобразований данных: увеличение масштаба, затемнение и осветление снимков, а также отражение фрагментов снимка относительно вертикальной оси.

В качестве критерия для определения оптимальных весовых коэффициентов СНС была использована максимизация метрики *mIoU*, а также алгоритм оптимизации Adam, основанный на вычислении градиента целевой функции (Kingma, Ba, 2014). Оптимизация *mIoU* позволяет частично решить выявленную проблему несбалансированности выборки по классам. Чтобы свести задачу максимизации к задаче минимизации, целевая функция была определена как: $L = (1 - mIoU) \rightarrow min$.

Для определения оптимальных гиперпараметров предлагаемой СНС и алгоритма её обучения использовался известный метод сеточного поиска (*англ.* grid search). Для итоговой модели СНС были определены такие значения параметров, при которых целевая функция показала наименьшее значение, рассчитанное по валидационной выборке.

Результаты исследования предлагаемой модели СНС

Обученная модель СНС была применена для семантической сегментации изображения тестового участка (*puc. 6*). Совместный визуальный анализ изображения тестового участка (см. *puc. 6a*), эталонной карты сегментации (см. *puc. 6б*) и результирующей выходной карты сегментации (см. *puc. 6в*) показал, что модель СНС способна воспроизводить границы между деревьями и успешно классифицировать значительную часть крон деревьев пихты. Большая часть неправильно классифицированных пикселей из классов «живые» и «старый сухостой» была отнесена к классу «фон», класса «отмирающие» — примерно в равной доле к классам «фон» и «живые», класса «свежий сухостой» — к классу «старый сухостой», как это видно из нормализованной матрицы ошибок классификации (*puc. 7*).



а б в Рис. 6. Результаты сегментации изображения тестового участка: *а* — тестовый участок;

Рис. 6. Результаты сегментации изоб	бражения тестового участка: <i>а</i> — тестовый участ	ΟK
δ — эталонная карта сегме	ентации; в — выходная карта сегментации	

1	Фон	0,91	0,056	0,0082	0,0075	0,017
лассь	Живые	0,14	0,86	0,0025	0,00044	0,00032
ные к	Отмирающие	0,25	0,27	0,48	0	0
еалы	Свежий сухостой	0,09	4,7e-05	0,018	0,78	0,11
	Старый сухостой	0,16	0,0011	0,0004	0,022	0,81
		Фон	Живые	Отмирающие	Свежий сухостой	Старый сухостой

Расчётные классы

Puc. 7. Нормализованная матрица ошибок классификации

В табл. 1 приведены значения метрик качества сегментации изображения тестового участка. Из неё следует, что минимальную эффективность по всем приведённым метрикам модель СНС показала при классификации пикселей класса «отмирающие». Невысокие результаты для этого класса объясняются малым количеством деревьев данного класса в обучающей выборке. Значения метрики IoU_c для классов «фон», «живые», «свежий сухостой» и «старый сухостой» превышают 0,5, что говорит о достаточно высоком качестве сегментации снимков деревьев пихты этих классов и фона. Значение mIoU было рассчитано по значениям IoU_c для каждого класса *c* и составило 0,66.

Класс	Precision _c	<i>Recall</i> _c	F1 _c	IoU _c
Фон	0,91	0,91	0,91	0,84
Живые	0,81	0,86	0,84	0,72
Отмирающие	0,65	0,48	0,55	0,38
Свежий сухостой	0,91	0,78	0,84	0,72
Старый сухостой	0,76	0,81	0,79	0,65

Таблица 1. Результаты оценки качества сегментации изображения тестового участка

Также рассчитывались значения ошибок для каждого класса *c* по следующим формулам: для ошибок первого рода $FPR_c = FP_c/(FP_c + TN_c)$, второго рода (ошибок пропуска) $FNR_c = FN_c/(FN_c + TP_c)$ и для ошибок добавления $FDR_c = FP_c/(FP_c + TP_c)$. Здесь использованы те же обозначения, что и в формулах для метрик, приведённых выше, а TN_c — количество истинно-отрицательных решений. Результаты расчёта этих ошибок, выраженные в процентах, приведены в *табл. 2*.

Класс	FPR _c , %	FNR _c , %	FDR _c , %
Фон	14,11	8,86	9,05
Живые	5,24	14,19	18,62
Отмирающие	0,71	52,01	34,71
Свежий сухостой	0,69	21,94	9,50
Старый сухостой	2,07	18,52	23,61

Таблица 2. Значения ошибок первого и второго рода и ошибок добавления для каждого класса

Из *табл. 2* видно, что значения ошибок первого рода не являются показательными из-за несбалансированности классов в тестовой выборке. Для ошибок второго рода FNR_c и ошибок добавления FDR_c для всех классов прослеживается отрицательная корреляция со значениями метрик *Recall* и *Precision* (см. *табл. 1*). С учётом ошибок округления это соответствует функциональным зависимостям: $FNR_c = (1 - Recall_c) \times 100 \%$, $FDR_c = (1 - Precision_c) \times 100 \%$.

Заключение

Рассмотрена задача анализа полученных с БПЛА снимков пихтовых насаждений, повреждённых уссурийским полиграфом. Для решения этой задачи предложена модель СНС, основанная на базовой модели СНС подкласса U-Net. Разработанная модель СНС позволяет осуществлять попиксельную классификацию поражённых деревьев пихты в зависимости от степени их повреждения уссурийским полиграфом. Модель СНС показала достаточно высокую эффективность при классификации пикселей классов «фон», «живые», «свежий сухостой», «старый сухостой» и низкую — для класса «отмирающие». Отметим, что полученная модель СНС может применяться только для сегментации деревьев пихты на снимках с БПЛА, полученных в летний период года.

Эффективность предложенной модели СНС может быть улучшена путём её обучения на большем количестве снимков разных участков пихтовых лесов. Также она может быть повышена при использовании дополнительных данных, например снимков в ближнем инфракрасном диапазоне спектра, карт глубины и т.п.

Исследование выполнено при финансовой поддержке Российского фонда фундаментальных исследований (проект № 18-47-700010 р а).

Наземные мониторинговые наблюдения и съёмка с БПЛА темнохвойных насаждений проводились в рамках выполнения базового проекта ИМКЭС СО РАН (проект № VI.52.2.6).

Литература

- 1. 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: метод. пособие. Томск: УМИУМ, 2018. 74 с.
- 2. Пашенова Н. В., Петько В. М., Керчев И. А., Бабичев Н. С. Перенос офиостомовых грибов уссурийским полиграфом Polygraphus proximus Blandford (Coleoptera, Scolytidae) в Сибири // Изв. Санкт-Петербургской лесотехнич. акад. 2012. № 200. С. 114–120.
- Проведение санитарно-оздоровительных мероприятий в лесных насаждениях, повреждённых Уссурийским полиграфом, на территории Удмуртской Республики // ФБУ «Рослесозащита». 22.04.2020. URL: http://perm.rcfh.ru/news/22860.html.
- 4. *Санников П. Ю., Андреев Д. Н., Бузмаков С. А.* Выявление и анализ сухостоя при помощи беспилотного летательного аппарата // Современные проблемы дистанционного зондирования Земли из космоса. 2018. Т. 15. № 3. С. 103–113. DOI: 10.21046/2070-7401-2018-15-3-103-113.
- Berie H. T., Burud I. Application of unmanned aerial vehicles in earth resources monitoring: focus on evaluating potentials for forest monitoring in Ethiopia // European J. Remote Sensing. 2018. V. 51. Iss. 1. P. 326–335. DOI: 10.1080/22797254.2018.1432993.
- 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. V. 99. No. 1. P. 54–55. DOI: 10.1134/S001387381901007X.
- Chenari A., Erfanifard Y., Dehghani M., Pourghasemi H. R. Woodland Mapping at Single-Tree Levels Using Object-Oriented Classification of UAV Images // Intern. Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. 2017. V. XLII-4/W4. P. 43–49. DOI: 10.5194/ isprs-archives-XLII-4-W4-43-2017.
- Gini R., Sona G., Ronchetti G., Passoni D., Pinto L. Improving Tree Species Classification Using UAS Multispectral Images and Texture Measures // Intern. J. Geo-Informatics. 2018. V. 7. Iss. 8. P. 315. DOI: 10.3390/ijgi7080315.
- Hossin M., Sulaiman M. N. A Review on Evaluation Metrics for Data Classification Evaluations // Intern. J. Data Mining and Knowledge Management Process. 2015. V. 5. No. 2. P. 1–11. DOI: 10.5121/ ijdkp.2015.5201.
- 10. *Ioffe S.*, *Szegedy C.* Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift // arXiv preprint. arXiv:1502.03167. 2015. 11 p. URL: https://arxiv.org/abs/1502.03167.
- 11. *Kingma D. P., Ba J.* Adam: A Method for Stochastic Optimization // arXiv preprint. arXiv:1412.6980. 2014. 15 p. URL: https://arxiv.org/abs/1412.6980.
- 12. *Lee S.*, *Park S.*, *Baek G.*, *Kim H.*, *Lee C.* Detection of Damaged Pine Tree by the Pine Wilt Disease Using UAV Image // Korean J. Remote Sensing. 2019. V. 35. No. 3. P. 359–373. DOI: 10.7780/kjrs.2019.35.3.2.
- 13. *McInnes L., Healy J., Melville J.* UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction // arXiv preprint. arXiv:1802.03426. 2018. 51 p. URL: https://arxiv.org/abs/1802.03426.
- 14. *Onishi M.*, *Ise T.* Automatic Classification of Trees Using a UAV Onboard Camera and Deep Learning // arXiv preprint. arXiv:1804.10390. 2018. 9 p. URL: https://arxiv.org/abs/1804.10390.
- Pashenova N. V., Kononov A. V., Ustyantsev K. V., Blinov A. G., Pertsovaya A. A., Baranchikov Yu. N. Ophiostomatoid fungi associated with the four-eyed fir bark beetle on the territory of Russia // Russian J. Biological Invasions. 2018. V. 9. No. 1. P. 63–74. DOI: 10.1134/S2075111718010137.
- Rahman M.A., Wang Y. Optimizing Intersection-Over-Union in Deep Neural Networks for Image Segmentation // Advances in Visual Computing: Intern. Symp. Visual Computing. Lecture Notes in Computer Science. Springer, 2016. V. 10072. P. 234–244. DOI: 10.1007/978-3-319-50835-1_22.

- 17. *Ronneberger O., Fischer P., Brox T.* U-Net: Convolutional Networks for Biomedical Image Segmentation // arXiv preprint. arXiv:1505.04597. 2015. 8 p. URL: https://arxiv.org/abs/1505.04597.
- 18. *Rousseeuw P.J.* Silhouettes: A graphical aid to the interpretation and validation of cluster analysis // J. Computational and Applied Mathematics. 1987. V. 30. P. 33–65. DOI: 10.1016/0377-0427(87)90125-7.
- 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. No. 6. Art. No. 643. 19 p. DOI: 10.3390/rs11060643.

Semantic segmentation of damaged fir trees in unmanned aerial vehicle images

I.A. Kerchev¹, K.A. Maslov², N.G. Markov², O.S. Tokareva²

 ¹ Institute of Monitoring of Climatic and Ecological Systems SB RAS Tomsk 634055, Russia E-mail: ivankerchev@gmail.com
² National Research Tomsk Polytechnic University, Tomsk 634030, Russia E-mails: kam20@tpu.ru, markovng@tpu.ru, ost@tpu.ru

A number of recent studies have shown that convolutional neural networks have found their application in the analysis of satellite images and images of the Earth surface, acquired with the use of unmanned aerial vehicles. Especially useful is their capability to automatically extract image features, such as textures and shapes of objects. This paper addresses the problem of the analysis of the state of fir trees in unmanned aerial vehicle images, provides the description of the research objects and conducts an exploratory analysis of the source data that allowed to build a new model of a convolutional neural network. A new convolutional neural network model, which is based on fully convolutional network U-Net architecture, is proposed. This model is used to do semantic segmentation of unmanned aerial vehicle images of fir forests damaged by Polygraphus proximus. In the paper, the architecture of the proposed neural network model is presented, and the main problems are solved regarding the processes of its training and assessment of the quality of semantic segmentation results obtained using the model. The results have shown a relatively high performance of the model while classifying pixels of the classes Background, Living trees, Recently dead trees and Long dead trees. At the end, several ways are proposed to increase the performance of the developed model.

Keywords: Polygraphus proximus, fir trees, unmanned aerial vehicle, semantic image segmentation, convolutional neural network, U-Net

Accepted: 09.12.2020 DOI: 10.21046/2070-7401-2021-18-1-116-126

References

- 1. 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 pikhtovykh lesov v zone invazii ussuriiskogo poligrafa v Sibiri* (Fir forest monitoring technology in the invasion zone of the Ussuri polygraph in Siberia), Tomsk: UMIUM, 2018, 74 p.
- Pashenova N. V., Petko V. M., Kerchev I. A., Babichev N. S., Perenos ofiostomovykh gribov ussuriiskim poligrafom Polygraphus proximus Blandford (Coleoptera, Scolytidae) v Sibiri (Transfer of ophiostomatoid fungi by Polygraphus proximus Blandford (Coleoptera, Scolytidae) in Siberia), *Izvestiya Sankt-Peterburgskoi lesotekhnicheskoi akademii*, 2012, No. 200, pp. 114–120.
- 3. http://perm.rcfh.ru/news/22860.html.
- 4. Sannikov P. Yu., Andreev D. N., Buzmakov S. A., Vyyavlenie i analiz sukhostoya pri pomoshchi bespilotnogo letatel'nogo apparata (Identification and analysis of deadwood using an unmanned aerial vehicle),

Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa, 2018, Vol. 15, No. 3, pp. 103–113, DOI: 10.21046/2070-7401-2018-15-3-103-113.

- 5. Berie H. T., Burud I., Application of unmanned aerial vehicles in earth resources monitoring: focus on evaluating potentials for forest monitoring in Ethiopia, *European J. Remote Sensing*, 2018, Vol. 51, Issue 1, pp. 326–335, DOI: 10.1080/22797254.2018.1432993.
- 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, No. 1, pp. 54–55, DOI: 10.1134/S001387381901007X.
- Chenari A., Erfanifard Y., Dehghani M., Pourghasemi H. R., Woodland Mapping at Single-Tree Levels Using Object-Oriented Classification of UAV Images, *Intern. Archives of the Photogrammetry*, *Remote Sensing and Spatial Information Sciences*, 2017, Vol. XLII-4/W4, pp. 43–49, DOI: 10.5194/ isprs-archives-XLII-4-W4-43-2017.
- 8. Gini R., Sona G., Ronchetti G., Passoni D., Pinto L., Improving Tree Species Classification Using UAS Multispectral Images and Texture Measures, *Intern. J. Geo-Informatics*, 2018, Vol. 7, Issue 8, p. 315, DOI: 10.3390/ijgi7080315.
- Hossin M., Sulaiman M. N., A Review on Evaluation Metrics for Data Classification Evaluations, Intern. J. Data Mining and Knowledge Management Process, 2015, Vol. 5, No. 2, pp. 1–11, DOI: 10.5121/ ijdkp.2015.5201.
- 10. Ioffe S., Szegedy C., Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, *arXiv preprint*, *arXiv:1502.03167*, 2015, 11 p., available at: https://arxiv.org/abs/1502.03167.
- 11. Kingma D. P., Ba J., Adam: A Method for Stochastic Optimization, *arXiv preprint*, *arXiv:1412.6980*, 2015, 15 p., available at: https://arxiv.org/abs/1412.6980.
- 12. Lee S., Park S., Baek G., Kim H., Lee C., Detection of Damaged Pine Tree by the Pine Wilt Disease Using UAV Image, *Korean J. Remote Sensing*, 2019, Vol. 35, No. 3, pp. 359–373, DOI: 10.7780/kjrs.2019.35.3.2.
- McInnes L., Healy J., Melville J., UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction, arXiv preprint, arXiv:802.03426, 2018, 51 p., available at: https://arxiv.org/ abs/1802.03426.
- 14. Onishi M., Ise T., Automatic Classification of Trees Using a UAV Onboard Camera and Deep Learning, *arXiv preprint, arXiv:1804.10390*, 2018, 9 p., available at: https://arxiv.org/abs/1804.10390.
- 15. Pashenova N. V., Kononov A. V., Ustyantsev K. V., Blinov A. G., Pertsovaya A. A., Baranchikov Yu. N., Ophiostomatoid fungi associated with the four-eyed fir bark beetle on the territory of Russia, *Russian J. Biological Invasions*, 2018, Vol. 9, No. 1, pp. 63–74, DOI: 10.1134/S2075111718010137.
- Rahman M.A., Wang Y., Optimizing Intersection-Over-Union in Deep Neural Networks for Image Segmentation, In: *Advances in Visual Computing: Intern. Symp. Visual Computing, Lecture Notes in Computer Science*, Springer, 2016, Vol. 10072, pp. 234–244, DOI: 10.1007/978-3-319-50835-1_22.
- 17. Ronneberger O., Fischer P., Brox T., U-Net: Convolutional Networks for Biomedical Image Segmentation, *arXiv preprint, arXiv:1505.04597*, 2015, 8 p., available at: https://arxiv.org/abs/1505.04597.
- 18. Rousseeuw P.J., Silhouettes: A graphical aid to the interpretation and validation of cluster analysis, *J. Computational and Applied Mathematics*, 1987, Vol. 30, pp. 33–65, DOI: 10.1016/0377-0427(87)90125-7.
- 19. 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, No. 6, Art. No. 643, 19 p., DOI: 10.3390/rs11060643.