Распознавание вырубок и ветровалов по спутниковым снимкам Sentinel-2 с применением свёрточной нейронной сети U-net и факторы, влияющие на его точность

А. И. Канев¹, А. В. Тарасов², А. Н. Шихов², Н. С. Подопригорова¹, Ф. А. Сафонов¹

¹ Московский государственный технический университет имени Н. Э. Баумана Москва, 105005, Россия

² Пермский государственный национальный исследовательский университет Пермь, 614990, Россия E-mail: shikhovan@gmail.com

Представлены результаты распознавания (сегментации) вырубок и ветровалов по спутниковым снимкам Sentinel-2 с применением свёрточных нейронных сетей архитектуры U-net в разных районах европейской территории России и Урала. Объём обучающей выборки составил свыше 17 тыс. объектов. Как для вырубок, так и для ветровалов получены в целом удовлетворительные оценки точности (среднее значение F-меры свыше 0,5). При этом выявлены существенные различия точности распознавания в зависимости от характеристик нарушений лесного покрова и самих насаждений. Так, максимальная точность достигнута для ветровалов, вызванных смерчами, что обусловлено их геометрическими особенностями. Зависимость точности распознавания ветровалов от породного состава повреждённых лесов неочевидна и требует уточнения, в то же время средняя площадь участка повреждения оказывает на неё существенное влияние. Максимальная точность распознавания вырубок на тестовых парах снимков Sentinel-2 (значение F-меры до 0,80) оказалась значительно выше, чем в ранее опубликованных работах с применением модели U-net. Максимальная точность распознавания характерна для обширных вырубок в смешанных и темнохвойных лесах, а минимальная для выборочных и проходных рубок в лиственных лесах. Точность по зимним и летним парам снимков существенно выше, чем по разносезонным парам. Также точность значимо различается для разных типов вырубок. Минимальное значение точности производителя (англ. producer's accuracy) получено для лесных дорог по летним снимкам, а максимальное — для сплошных рубок по зимним снимкам.

Ключевые слова: вырубки, ветровалы, данные Sentinel-2, свёрточные нейронные сети, U-net, породный состав древостоя

Одобрена к печати: 25.04.2023 DOI: 10.21046/2070-7401-2023-20-3-136-151

Введение

Вырубки и ветровалы — одни из наиболее значимых видов нарушений лесного покрова на европейской территории России (ETP) (Potapov et al., 2015). В последние годы спутниковый мониторинг стал основным источником информации об этих нарушениях в масштабах всей ETP. В настоящее время применяется множество методов идентификации вырубок и ветровалов по спутниковым снимкам, в том числе в оперативном режиме.

Традиционные методы идентификации нарушений лесного покрова основаны на расчёте вегетационных индексов по разновременным снимкам (Барталев и др., 2010; Cocke et al., 2005; Hardisky et al., 1983), преобразованиях Tasseled Cap или Tasseled Cap Wetness (Baumann et al., 2014; Wang, Xu, 2010). К традиционным методам относятся также метод многомерного обнаружения изменений (Nielsen et al., 1998), выборочный анализ главных компонент (Coppin, Bauer, 1994), метод анализа векторов изменений (Allen, Kupfer, 2001). Важной проблемой традиционных методов представляется подбор пороговых критериев, позволяющих разделить здоровые и погибшие насаждения. Значения этих критериев будут различаться для каждой пары снимков в связи с разными условиями съёмки, сезонными факторами, состоянием атмосферы (Крылов, Владимирова, 2011). Для решения этой проблемы применяются различные процедуры оптимизации (см. например, работу (Ховратович и др., 2019)).

Среди современных методов идентификации нарушений лесного покрова можно выделить алгоритмы анализа временных серий изображений, а также методы машинного обучения. К первой группе относятся деревья решений, которые, в частности, были использованы при создании продукта Global Forest Change (Hansen et al., 2013). Из второй группы наиболее широко применяются классификатор случайного леса (*англ.* Random Forest) (Rodriguez-Galiano et al., 2012) и свёрточные нейронные сети (*англ.* Convolutional Neural Networks — CNN), применение которых считается наиболее перспективным подходом к сегментации изображений. В отличие от традиционных алгоритмов, CNN обеспечивают возможность совместного анализа спектральных, геометрических и текстурных свойств объектов на изображениях (Larabi et al., 2016; Mou et al., 2019; Xie et al., 2021). CNN начали применяться для анализа спутниковых снимков с 2018–2019 гг. Результаты сегментации вырубок в лесах умеренного пояса с помощью CNN представлены в работах (Тарасов и др., 2021; Isaienkov et al., 2021). Распознавание ветровалов на основе CNN выполнялось для территорий Центральной Европы по снимкам Sentinel-2 (Scharvogel et al., 2020) и на Сахалине по снимкам сверхвысокого разрешения (Kislov, Korznikov, 2020; Kislov et al., 2021).

В перечисленных работах показаны преимущества методов машинного обучения, в частности высокая эффективность CNN для сегментации выборочных рубок (Тарасов и др., 2021) и при работе со снимками сверхвысокого разрешения (Scharvogel et al., 2020). Однако в этих исследованиях не анализировались факторы, влияющие на качество сегментации, к которым, прежде всего, относятся площадь участков и степень повреждения древостоя, а также его породный состав. В частности, хорошо известно, что по мере снижения площади участка повреждения уменьшается точность его автоматического распознавания с применением любых методов (см. например, работы (Королева, Ершов, 2012; Shikhov et al., 2020)). Породный состав древостоя также может влиять на качество сегментации вырубок и ветровалов, поскольку он оказывает определяющее влияние на спектральные и текстурные характеристики лесного покрова на снимках (Барталев и др., 2016).

Исходя из перечисленных проблем, целью настоящего исследования была поставлена оценка точности распознавания вырубок и ветровалов по разновременным снимкам Sentinel-2 с применением свёрточной нейронной сети U-net и выявление зависимостей точности распознавания от площади участков нарушений и породного состава древостоя.

Материалы и методы

Создание обучающих и проверочных наборов данных

Обучающий набор данных создан на основе разновременных и разносезонных спутниковых снимков Sentinel-2 с пространственным разрешением 10 м. Разметка выполнена ручной векторизацией контуров вырубок и ветровалов на парных снимках, которые относятся к 57 тайлам в глобальной системе разграфки, принятой для данных Sentinel-2. Обучающие данные собраны по различным регионам европейской территории России и Урала (*puc. 1*, см. с. 138). Информация для формирования выборки ветровалов была получена из баз данных (Шихов и др., 2022; Shikhov et al., 2020). Для формирования выборки антропогенных нарушений (рубок) частично использовались данные, собранные в рамках исследования (Тарасов и др., 2021). Для каждого объекта в выборке сохранялись идентификаторы двух снимков: до изменения и после него — в формате Product ID. По аналогии с работой (Тарасов и др., 2021), если на вырубке оставались отдельные деревья или участки лесной растительности, они не исключались из объекта (это может иметь критическое значение для успешного распознавания выборочных и проходных рубок). Также сохранялись тени от деревьев на границе объекта.



Рис. 1. Пространственное расположение объектов из обучающей выборки

Обучающая выборка включает пары снимков разных сезонов: два бесснежных снимка (*англ*. summer), два снимка со снежным покровом (*англ*. winter) и пары, в которых снежный покров имеется на одном снимке (*англ*. transition). Наибольшее число нарушений лесного покрова выделено по снимкам за июль, а наименьшее — за октябрь. Распределение снимков в выборке соответствует известной закономерности, что наиболее информативными для выявления вырубок и ветровалов становятся снимки за летний сезон и за вторую половину зимы (Крылов, Владимирова, 2011; Тарасов, 2021).

Для оценки точности распознавания нарушений лесного покрова были созданы три *проверочных набора данных*, содержащих векторные контуры вырубок и ветровалов (*табл. 1*). Проверочные данные были созданы заново, а не выбраны из обучающего набора, поскольку в дальнейшем они использовались для оценки влияния площади участков нарушений и породного состава древостоя на точность распознавания. Для решения первой задачи был необходим проверочный набор, созданный по снимкам сверхвысокого пространственного разрешения (тогда как обучающая выборка была создана по снимкам Sentinel-2). Для решения второй задачи проверочные данные должны быть представлены для лесов разного породного состава, а в обучающей выборке это условие соблюдалось не в полной мере, особенно применительно к ветровалам.

Проверочные данные для лесов разного породного состава получены для трёх участков (тестовых сцен) на территории Пермского края и Республики Коми, существенно различающихся по преобладающим породам в древостое и характеру лесопользования (см. *рис.* 1,

табл. 2). На двух из трёх участков помимо вырубок были обнаружены ветровалы, которые также были оцифрованы, и точность их распознавания оценивалась вместе с вырубками, которые стали преобладающим видом нарушений на всех трёх участках. На основе созданных проверочных данных (см. *табл. 1*) оценивалась точность распознавания нарушений лесного покрова по парным снимкам одного сезона (с интервалом около года), а также по разносезонным изображениям с минимальной облачностью (не более 5 % от площади сцены). При оценке точности для исключения ошибок, связанных с нелесопокрытыми территориями, использовалась маска леса, созданная на основе данных проекта Global Forest Canopy Height 2020 г. (Potapov et al., 2021).

Тип выборки	Общее количество объ- ектов в выборке/сум- марная площадь, га	Типы объектов в выборке (их количество по типам)	Исходные сним- ки для создания выборки	Пространственное распределение объектов
Обучающая	17 745/124 209	Сплошные рубки (2523), выборочные рубки (544), проходные рубки (2981), лесные дороги (721), ветровалы (10 976)	Sentinel-2, 2017— 2022 гг. (10 м)	Лесная зона ЕТР и Урала
Проверочная для ветровалов	3746/6315	Ветровалы (3746)	Sentinel-2, 2017– 2021 гг. (10 м)	Лесная зона ЕТР и Урала
Проверочная для ветрова- лов с высоким разрешением	1175/740	Ветровалы (1175)	Снимки с сер- висов Google (0,6 м) после 2018 г.	Тверская обл. и Удмуртия
Проверочная для лесов раз- ного породного состава	2575/16 018	Рубки (1796), ветровалы (779)	Sentinel-2, 2021— 2022 гг. (10 м)	Пермский край, Республика Коми

Таблица	1	Общая ха	рактеристик	а обу	лающих и	прове	почных	наборов	ланных
ruonnyu	1.	ООщил ли	ιρακτορποτηκ	u 00 j	пающил и	inpode	po mbix	maoopon	данныл

Таблица 2. Характеристика участков (сцен Sentinel-2), на которых выполнена оценка точности распознавания

Зона	Даты снимков	Характеристики	лесов по (Барталев и др., 2016)	Количество объектов/	
разграфки Sentinel-2		Доля лесопокрытой площади, %	Преобладающие типы леса (доля от общей площади, %)	суммарная/средняя площадь вырубок и ветровалов в проверочном наборе, га	
T39VWH	28.02.2021, 13.07.2021, 10.03.2021, 13.06.2021	93,8	Светлохвойные леса (37,7); темнохвойные леса (18,4)	Вырубки: 689/6857/9,9; ветровалы: 691/1114/1,6	
T40VEM	26.03.2021, 04.06.2021, 19.03.2022, 18.08.2022	92,1	Лиственные леса (34,7); темнохвойные леса (32,3)	Вырубки: 557/5410/9,7; ветровалы: 88/209/2,4	
T40VDJ	26.03.2021, 29.06.2021, 09.02.2021, 16.08.2021	60,9	Лиственные леса (60,3); смешанные леса с преобла- данием лиственных (22,3)	Вырубки: 550/2428/4,4; ветровалы: 0/0/—	

Предварительная обработка изображений выполнена на основе ранее разработанных инструментов (Тарасов и др., 2021). Она включала формирование обучающих тайлов (образцов) — небольших растровых изображений размером 256×256 пикселей, в каждом из которых содержится целевая маска и набор входных признаков. Каждый из них содержит обучающую маску нарушений и значения яркости в 13 каналах снимков, полученных до и после появления нарушения. Также сформированы обучающие образцы без целевой маски, при этом пересечение с ранее созданными образцами не допускалось.

Обучение свёрточной нейронной сети U-net

Выбор архитектуры U-net (Ronneberger et al., 2015) был обусловлен её ранее доказанной способностью сегментировать выборочные и проходные рубки как целостные объекты, а также успешным опытом применения для распознавания нарушений лесного покрова (Тарасов, 2021; Тарасов и др., 2021; Isaienkov et al., 2021). Обучение модели для распознавания вырубок выполнено на основе всей исходной выборки (показанной на *рис. 1*), из которой были исключены ветровалы, и ещё 15 % вырубок, которые были выделены для валидации. На основе ранее полученных оценок информативности различных спектральных каналов и индексов (Тарасов и др., 2021) на вход модели подавались 16 каналов и их разностей (old и new — каналы снимков, полученных до и после изменения соответственно):

- Исходные спектральные каналы с пространственным разрешением 10 и 20 м: B4_{old}, B8_{old},
- $\begin{array}{c} B4_{new}, B8_{new}, B11_{old}, B11_{new}, B12_{old}, B12_{new}.\\ \bullet \ Pashocmu, \ вычисленные \ no \ pashoвременным \ chumkam: B4_{old} B4_{new}, B4_{new} B4_{old}, B8_{old} B8_{new}, B8_{new} B8_{old}, B12_{old} B12_{new}, B12_{new} B12_{old}, B11_{old} B11_{new}, B11_{new} B11_{old}.\\ \end{array}$

В экспериментах использовались следующие гиперпараметры: количество эпох в обучении — 230, коэффициент обучения Lr (определяющий, с какой скоростью будет изменяться функция потерь) — $1e^{-3}$, размер подвыборки для обучения (*англ*. batch size) — 8.

Изначально был выполнен эксперимент по сравнению различных функций потерь. Оценивались модели с пятью различными функциями потерь:

1. Бинарная кросс-энтропия (БКЭ, англ. binary cross entropy).

- 2. Индекс Дайса (англ. Dice loss).
- 3. Модификация Dice loss в виде функции потерь:

$$DL(p,p) = 1 - \frac{2 \sum p_{h,w} \hat{p}_{h,w}}{\sum p_{h,w} + \sum \hat{p}_{h,w}},$$

где $p_{h,w}$ — бинарная целевая маска, $p_{h,w} \subset \{0,1\}$; \hat{p} — маска прогноза, $0 \le \hat{p} \le 1$. 4. Индекс Тверского (*англ*. Tversky loss):

$$TI(p, \hat{p}) = 1 - \frac{p\hat{p}}{p\hat{p} + \beta(1-p)\hat{p} + (1-\beta)p(1-\hat{p})},$$

где \hat{p} — маска прогноза; β — коэффициент, определяющий величину штрафа для ложноотрицательных результатов.

Индекс добавляет вес к ложным срабатываниям FP (англ. false positive) и пропускам объектов FN (анел. false negative) и был разработан для оптимизации сегментации несбалансированных наборов данных за счёт использования констант, которые могут регулировать степень штрафа за различные типы ошибок в функции потерь. В частности, β-константа применяется в ситуациях, когда модели дают обманчиво положительные результаты с помощью очень консервативного прогноза. Чем выше значение β , тем больше вес метрики recall (полнота), чем precision (точность). В данном эксперименте использовалось значение $\beta = 0.7$.

5. Сумма коэффициента Дайса (*англ*. Dice coefficient) и бинарной кросс-энтропии.

Эта функция потерь сочетает в себе Dice loss со стандартной БКЭ, которая обычно используется по умолчанию для моделей сегментации. Комбинация двух методов допускает некоторое разнообразие потерь, при этом выигрывая от стабильности БКЭ.

Для оценки результата использовались следующие метрики:

1. Dice coefficient:

$$DC = \frac{2TP}{2TP + FP + FN},$$

где ТР (англ. true positive) — истинные положительные результаты; FP — ложные положительные результаты; FN — ложные отрицательные результаты.

2. Индекс Жаккара, или Intersection over Union (IoU):

$$IoU = \frac{TP}{TP + FP + FN}.$$

Также использованы метрики sensitivity (чувствительность), specificity (специфичность) и F-мера. Самые высокие значения коэффициента Дайса, IoU и F-меры получены при использовании индекса Дайса в качестве функции потерь, а самые низкие — при использовании БКЭ (*табл. 3*).

Функция потерь	Коэффициент Дайса	IoU	Sensitivity	Specificity	F -мера
БКЭ	0,73	0,78	0,89	0,99	0,73
Коэффициент Дайса	0,79	0,82	0,79	1,00	0,79
Индекс Тверского	0,78	0,81	0,81		0,78
Коэффициент Дайса + БКЭ			0,79		

Таблица 3. Сравнение моделей U-net при разных функциях потерь

Также было проведено обучение модели на парных снимках разных сезонов и сопоставление её с моделью, обученной на снимках всех сезонов года. В качестве функции потерь была задана БКЭ, количество эпох в обучении — 260. Наибольшая точность получена по модели, обученной на всех сезонах (среднее значение Dice Loss около 0,65), для остальных моделей точность оказалась значительно ниже.

Для распознавания ветровалов была обучена отдельная модель. Объём данных для тестирования составил 370 образцов. Обучение выполнялось на тех же 16 признаках, что и для вырубок. В качестве функции потерь был принят коэффициент Дайса, количество эпох в обучении — 230; остальные гиперпараметры модели были те же, что и для вырубок. Далее ветровалы были выделены по разному пороговому значению вероятности и рассчитаны метрики точности для каждого порога. Оптимальное значение порога по показателю F-меры — 0,3 или 0,4 (при меньших площадях растёт доля FP).

Оценка влияния внешних факторов на сегментацию вырубок и ветровалов

На основе вышеописанных моделей проведены эксперименты по сегментации вырубок и ветровалов с оценкой точности по проверочным наборам данных и рассмотрено влияние площади участков повреждения и преобладающих лесообразующих пород на точность распознавания. Точность оценивалась по матрице ошибок, на основе которой рассчитаны метрики precision, recall, коэффициенты Дайса и Жаккара. Для оценки влияния площади вырубок и ветровалов на точность распознавания они были разбиты по градациям площади. Для ветровалов оценка по градациям площади выполнена на основе проверочного набора, оцифрованного по снимкам сверхвысокого разрешения, для вырубок использовался проверочный набор, полученный по данным Sentinel-2 (характеристики этих наборов приведены в *табл. 1*).

Для оценки влияния породного состава были сопоставлены значения коэффициентов Дайса и Жаккара для вырубок и ветровалов, выделенных в разных типах леса (темнохвойных, светлохвойных, лиственных и смешанных). Данные о преобладающих породах были получены на основе Карты растительности России (Барталев и др., 2016). Полученная оценка имеет ориентировочный характер из-за низкого пространственного разрешения данных (230 м), но может дать общее представление о влиянии породного состава древостоев на качество сегментации вырубок и ветровалов. Для ветровалов расчёт выполнялся в пределах минимального выпуклого полигона, построенного вокруг территории, подвергшейся воздействию ветровала (*рис. 2*, см. с. 142).



Рис. 2. Выделение контуров ветровала различными методами (*a*); породный состав лесов в пределах области, подвергшейся воздействию ветровала, на основе карты растительности России (Барталев и др., 2016) (*б*)

Результаты

Оценка точности сегментации ветровалов и влияющих на неё факторов

Оценка выполнена для шести случаев ветровалов, наблюдавшихся в разных частях лесной зоны ЕТР и Урала. Характеристики точности, полученные для ветровалов в целом, приведены в *табл. 4.* Порог вероятности для бинарной классификации для выходных данных принят равным 0,2. В целом точность распознавания ветровалов оказалась удовлетворительной (F-мера $\geq 0,5$, за исключением случая 16.07.2020 в Удмуртии). При этом выявлены существенные различия по точности распознавания в зависимости от характеристик как самого ветровала, так и повреждённого лесного массива (*табл. 5*). Так, наиболее высокая точность отмечена для ветровалов, вызванных смерчами. Это обусловлено их геометрическими особенностями, а именно чёткими границами и резким преобладанием сплошного характера повреждения древостоя (Shikhov et al., 2020).

Дата	Субъект РФ	Площадь, га		Precision	Recall	F- мера	IoU
		фактическая U-net					
13.09.2018	Пермский край	138	216	0,54	0,85	0,66	0,49
16.07.2020	Республика Удмуртия	421	52	0,90	0,11	0,20	0,11
08.07.2020	Архангельская обл.	3654	4074	0,65	0,72	0,68	0,52
24.06.2018	Тверская обл.	766	675	0,77	0,68	0,72	0,57
27.06.2020	Кировская обл.	987	883	0,53	0,47	0,50	0,33
09.11.2018	Свердловская обл.	348	616	0,52	0,92	0,67	0,50

Таблица 4. Общая оценка точности распознавания ветровалов

Дата	Тип	Количество	Медианная/	Преобладающий тип леса (доля от общей площади, %)			
	явления	участков ветровала	средняя площадь участка, га	на участке в целом	на повреждённой ветром площади		
13.09.2018	Смерчи	79	0,68/1,75	Смешанные леса с преобладанием хвойных (33,8)	Смешанные леса с преоблада- нием хвойных (36,0)		
16.07.2020	Шквал	493	0,51/0,85	Лиственные леса (46,3)	Смешанные леса (41,8)		
08.07.2020	Шквал	1715	0,64/2,13	Темнохвойные леса (31,2)	Светлохвойные леса (49,0)		
24.06.2018	Шквал	766	0,40/1,13	Лиственные леса (75,8)	Лиственные леса (64,3)		
27.06.2020	Шквал	664	0,51/1,48	Лиственные леса (35,7)	Лиственные леса (41,3)		
09.11.2018	Сильный ветер	122	0,37/2,84	Лиственные леса (27,8)	Темнохвойные леса (43,8)		

Таблица 5. Характеристики участков ветровалов и преобладающих древесных пород

Породный состав древостоя оценивался как в пределах минимального ограничивающего полигона вокруг ветровала (см. *рис. 2*), так и непосредственно для ячеек, пересекающихся с участками ветровала. Зависимость точности распознавания от породного состава повреждённых древостоев неочевидна и требует уточнения на основе данных о породном составе лесов с более высоким пространственным разрешением. Так, ветровалы, для которых получена высокая точность распознавания, наблюдались как в темнохвойных, так и в смешанных и лиственных лесах (см. *табл. 5*). Для наиболее крупного из рассматриваемых ветровалов, наблюдавшегося 08.07.2020 в Пинежском р-не Архангельской обл., точность распознавания на участках в сосновых лесах оказалась несколько ниже, чем в темнохвойных лесах. Однако это различие могло быть обусловлено и другими факторами, в частности размером повреждённых участков и степенью повреждения древостоя на них.

Средняя площадь участка повреждения оказывает более существенное влияние. Ветровал, для которого точность распознавания минимальна, характеризуется самым малым значением этого показателя (0,85 га). Наибольшая средняя площадь участка характерна для ветровала 09.11.2018, точность его сегментации достаточно высокая (F-мера = 0,67). Наряду со средней площадью участков существенное влияние на качество распознавания может оказывать степень повреждения древостоя (чем больше доля сплошного повреждения, тем выше точность распознавания).

Более точные данные о площади участков ветровалов получены по снимкам сверхвысокого пространственного разрешения (*табл. 6*). Средняя площадь участков для рассматриваемых ветровалов различается всего в 1,5 раза, а значение F-меры — более чем в 2 раза. Точность распознавания повреждённых участков возрастает по мере увеличения их площади. Отношение TP к истинной площади (т. е. доля корректно распознанной площади повреждений) изменяется от 18 % для наиболее локальных повреждений (менее 0,1 га) до 88 % для участков площадью свыше 5 га (*рис. 3a*, см. с. 144). Зависимость этого показателя от фактической площади — линейная с $R^2 = 0.96$ (*рис. 36*).

Дата	Количество участков ветровала	Медианная/средняя площадь участка, га	Площадь, га (фактическая/U-net)	Precision	Recall	F-мера	IoU
24.06.2018	497	0,14/0,59	295/347	0,65	0,76	0,70	0,54
16.07.2020	678	0,11/0,36	246/55	0,69	0,15	0,25	0,14

Таблица 6. Оценка точности распознавания ветровалов по снимкам сверхвысокого пространственного разрешения



Рис. 3. Зависимость доли корректно распознанных участков ветровала от их площади (*a*) и отношение фактической и расчётной площади участка (*б*) по снимкам Sentinel-2

Оценка точности распознавания нарушений лесного покрова на тестовых сценах Sentinel-2

Точность распознавания вырубок и ветровалов с применением модели U-net оказалась в основном удовлетворительной (F-мера $\ge 0,5$) по зимним и летним парам снимков и неудовлетворительной — по парам, в которых снежный покров присутствует на одном из двух изображений (*табл. 7, рис. 4,* см. с. 145). При этом направление сезонного перехода (зима – лето или лето – зима) не оказывает заметного влияния на точность распознавания. Максимальные значения F-меры и IoU по зимним и летним парам снимков существенно выше, чем ранее опубликованные в работах (Тарасов и др., 2021; Isaienkov et al., 2021), что показывает практическую значимость полученных результатов.

Выбранные тестовые сцены значимо различаются по доле лесопокрытой площади, преобладающим лесообразующим породам, характеру лесопользования и средней площади вырубок (см. *рис. 1, табл. 2*). На юге Пермского края (сцена T40VDJ) преобладают выборочные и проходные рубки (их доля достигает 51 % от общей площади) при средней площади вырубки 4,4 га. На северо-западе края и в прилегающих районах Республики Коми (сцена T39VWH) доля сплошных рубок достигает 66 %, а средняя площадь вырубки — 9,9 га; на северо-востоке (сцена T40VEM) средняя площадь рубки аналогична (9,7 га), но доля сплошных рубок ниже (37%). Северо-западный участок отличается доминированием сосновых и темнохвойных насаждений, тогда как на северо-востоке доля темнохвойных и лиственных лесов сопоставима, а на юге лиственные леса преобладают (см. табл. 2). Это объясняет существенные различия в точности распознавания вырубок: максимальная точность характерна для обширных вырубок в смешанных и темнохвойных лесах, которых больше всего на северо-западном участке, а минимальная — для выборочных и проходных рубок в лиственных лесах (они преобладают на юге). Для участка с преобладанием крупных сплошных вырубок (T39VWH) точность распознавания выше не только по зимним и летним парам снимков, но и по снимкам переходного сезона.

Для участка T39VWH по зимней и летней паре снимков, по которым была получена максимальная точность распознавания (см. *табл.* 7), была оценена также точность для разных типов нарушений лесного покрова: сплошных рубок, выборочных и проходных рубок, лесных дорог и ветровалов. Выявлены существенные различия по точности распознавания между разными типами: как и ожидалось, максимальное значение точности производителя (*англ.* producer's accuracy) получено для лесных дорог в летнее время, а минимальное — для сплошных рубок в зимнее время (*табл. 8*).



Рис. 4. Примеры результатов распознавания вырубок и ветровалов: *a* — сцена T40VDJ, пара снимков 29.06.2021–16.08.2022; *б* — сцена T39VWH, пара снимков 13.07.2021–13.06.2022; *в* — сцена T40VEM, пара снимков 04.06.2021–18.08.2022; *г* — сцена 39VWH, пара снимков 28.02.2021–10.03.2022

ID сцены	Даты снимков	Сезон	Фактическое число / площадь объектов, га	Precision	Recall	F-мера	IoU
T40VDJ	26.03.2021- 29.06.2021	Переходный зима-лето	124/466	0,65	0,43	0,51	0,35
	26.03.2021- 09.02.2022	Зима	385/1638	0,81	0,56	0,66	0,49
	29.06.2021– 16.08.2022	Лето	426/1960	0,85	0,21	0,33	0,20
	09.02.2022– 16.08.2022	Переходный лето – зима	165/788	1,00	0,00	0,01	0,00
	29.06.2021- 09.02.2022	Переходный зима – лето	261/1172	0,55	0,36	0,43	0,28
T39VWH	28.02.2021– 13.07.2021	Переходный зима – лето	849/2670	0,56	0,75	0,64	0,47
	28.02.2021- 10.03.2022	Зима	1304/7164	0,73	0,83	0,78	0,64
	13.07.2021– 13.06.2022	Лето	531/5310	0,90	0,70	0,79	0,65
	10.03.2022– 13.06.2022	Переходный зима-лето	76/816	0,83	0,02	0,03	0,02
	13.07.2021– 10.03.2022	Переходный лето—зима	455/4494	0,73	0,80	0,77	0,62
T40VEM	26.03.2021- 04.06.2021	Переходный зима – лето	54/483	0,63	0,78	0,70	0,54
	26.03.2021– 19.03.2022	Зима	556/4625	0,37	0,79	0,51	0,34
	04.06.2021– 18.08.2022	Лето	583/5116	0,80	0,66	0,73	0,57
	04.06.2021– 19.03.2022	Переходный лето-зима	494/4132	0,39	0,57	0,47	0,30
	19.03.2022– 18.08.2022	Переходный зима-лето	82/918	0,60	0,15	0,24	0,13

Таблица 7. Результаты распознавания нарушений лесного покрова на тестовых сценах. Выделены результаты со значением F-меры > 0,6

Таблица 8. Оценка точности распознавания для разных типов нарушений лесного покрова

ID сцены	Даты снимков	Тип нарушения	Число объектов	Площадь, га	ТР, га	Точность производителя
T39VWH	13.07.2021-	Сплошная рубка	283	3527,2	2636,0	0,75
13.06.2022	13.06.2022	Выборочная/проходная рубка	159	1484,0	938,1	0,63
		Лесная дорога	65	266,9	126,0	0,47
T39VWH T39VWH T39VWH T39VWH	28.02.2021- 10.03.2022	Сплошная рубка	350	4060,7	3600,8	0,89
		Выборочная/проходная рубка	177	1615,9	1268,9	0,79
		Лесная дорога	88	373,6	237,5	0,64
		Ветровал	689	1114,1	821,4	0,74

Заключение

Применение моделей машинного обучения, в частности свёрточных нейронных сетей, представляется наиболее перспективным направлением в области распознавания нарушений лесного покрова по спутниковым снимкам. В рамках проведённого исследования была оценена точность выявления вырубок и ветровалов с применением свёрточной нейронной сети архитектуры U-net. Как для вырубок, так и для ветровалов выявлены существенные различия по точности в зависимости от характеристик нарушений лесного покрова и самих лесов.

При распознавании ветровалов значение F-меры превышает 0,5 (за исключением одного случая). Максимальная точность распознавания достигнута для ветровалов, вызванных смерчами, что обусловлено их геометрическими особенностями. Зависимость точности от породного состава лесов неочевидна и требует уточнения на основе данных о породном составе с высоким пространственным разрешением. Средняя площадь участка повреждения оказывает более существенное влияние, что продемонстрировано на основе проверочных данных, полученных по снимкам сверхвысокого разрешения. Для трёх ветровалов из шести точность распознавания оказалась выше, чем в аналогичной работе (Scharvogel et al., 2020), что показывает соответствие результатов мировому уровню.

Точность распознавания вырубок в целом оказалась выше, чем для ветровалов (F-мера в ряде случаев превышает 0,7), и выше, чем в ранее опубликованных работах для вырубок (Тарасов и др., 2021; Isaienkov et al., 2021). Наиболее успешно детектируются обширные сплошные рубки в смешанных и темнохвойных лесах, а минимальная точность характерна для выборочных и проходных рубок в лиственных лесах. Обучение отдельной модели для проходных и выборочных рубок потенциально может повысить точность распознавания таких объектов, по которым результаты пока неудовлетворительные.

Сезон съёмки существенно влияет на точность распознавания вырубок и ветровалов. Для зимних (со снежным покровом) и летних (без снежного покрова) пар снимков точность значительно выше, чем для разносезонных. Направление перехода (зима – лето или лето – зима) не оказывает заметного влияния на точность. Также точность существенно различается для разных типов вырубок. Как и ожидалось, минимальное значение точности производителя получено для лесных дорог по летним снимкам, а максимальное — для сплошных рубок по зимним снимкам.

Перспективы дальнейшего повышения точности распознавания вырубок и ветровалов по снимкам Sentinel-2 связаны как с применением новых архитектур свёрточных нейронных сетей, так и с использованием методов ансамблирования.

Исследование выполнено при поддержке Российского научного фонда и Пермского края (проект № 22-27-20018).

Литература

- 1. Барталев С.А., Егоров В.А., Крылов А.М., Стыценко Ф.В., Ховратович Т.С. Исследование возможностей оценки состояния поврежденных пожарами лесов по данным многоспектральных спутниковых измерений // Современные проблемы дистанционного зондирования Земли из космоса. 2010. Т. 7. № 3. С. 215–225.
- 2. Барталев С. А. Егоров В. А., Жарко В. О., Лупян Е. А., Плотников Д. Е., Хвостиков С. А., Шабанов Н. В. Спутниковое картографирование растительного покрова России. М.: ИКИ РАН, 2016. 208 с.
- 3. *Королева Н. В., Ершов Д. В.* Оценка погрешности определения площадей ветровалов по космическим изображениям высокого пространственного разрешения Landsat-TM // Современные проблемы дистанционного зондирования Земли из космоса. 2012. Т. 9. № 1. С. 80–86.
- 4. *Крылов А. М., Владимирова Н.А.* Дистанционный мониторинг состояния лесов по данным космической съемки // Геоматика. 2011. № 3. С. 53–58.
- 5. *Тарасов А. В.* Оперативное картографирование нарушений лесного покрова на основе спутниковых данных с высоким пространственно-временным разрешением: дис. ... канд. техн. наук. Пермь, 2021. 135 с.

- 6. *Тарасов А. В., Шихов А. Н., Шабалина Т. В.* Распознавание нарушений лесного покрова по спутниковым снимкам Sentinel-2 с помощью свёрточных нейронных сетей // Современные проблемы дистанционного зондирования Земли из космоса. 2021. Т. 18. № 3. С. 51–64. DOI: 10.21046/2070-7401-2021-18-3-51-64.
- 7. *Ховратович Т. С., Барталев С. А., Кашницкий А. В.* Метод детектирования изменений лесов на основе подпиксельной оценки проективного покрытия древесного полога по разновременным спутниковым изображениям // Современные проблемы дистанционного зондирования Земли из космоса. 2019. Т. 16. № 4. С. 102–110. DOI: 10.21046/2070-7401-2019-16-4-102-110.
- 8. Шихов А. Н., Чернокульский А. В., Ажигов И. О. Пространственно-временное распределение ветровалов в лесной зоне Западной Сибири в 2001–2020 гг. // Современные проблемы дистанционного зондирования Земли из космоса. 2022. Т. 19. № 3. С. 186–202. DOI: 10.21046/2070-7401-2022-19-3-186-202.
- 9. *Allen T. R., Kupfer J. A.* Spectral response and spatial pattern of Fraser fir mortality and regeneration, Great Smoky Mountains, USA // Plant Ecology. 2001. V. 156. Iss. 1. P. 59–74. DOI: 10.1023/A:1011948906647.
- Baumann M., Ozdogan M., Wolter P. T., Krylov A., Vladimirova N., Radeloff V. C. Landsat remote sensing of forest windfall disturbance // Remote Sensing of Environment. 2014. V. 143. P. 171–179. DOI: 10.1016/j. rse.2013.12.020.
- Cocke A. E., Fulé P.Z., Crouse J. E. Comparison of burn severity assessments using Differenced Normalized Burn Ratio and ground data // Intern. J. Wildland Fire. 2005. V. 14(2). P. 189–198. DOI: 10.1071/ WF04010.
- 12. *Coppin P. R., Bauer M. E.* Processing of multi-temporal Landsat TM imagery to optimize extraction of forest cover change features // IEEE Trans. Geoscience and Remote Sensing. 1994. V. 32. P. 918–927.
- Hansen M. C., Potapov P. V., Moore R., Hancher M., Turubanova S. A., Tyukavina A., Thau D., Stehman S. V., Goetz S. J., Loveland T. R., Kommareddy A., Egorov A., Chini L., Justice C. O., Townshend J. R. G. High-Resolution Global Maps of 21st-Century Forest Cover Change // Science. 2013. V. 342(6160). P. 850–853. DOI: 10.1126/science.1244693.
- Hardisky M.A., Klemas V., Smart R. M. The influence of soil salinity, growth form, leaf moisture on the spectral radiance of Spartina alterniflora canopies // Photogrammetric Engineering and Remote Sensing. 1983. V. 49. P. 77–83.
- Isaienkov K., Yushchuk M., Khramtsov V., Seliverstov O. Deep Learning for Regular Change Detection in Ukrainian Forest Ecosystem with Sentinel-2 // IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing. 2021. V. 14. P. 364–376. DOI: 10.1109/JSTARS.2020.3034186.
- 16. *Kislov D. E., Korznikov K. A.* Automatic windthrow detection using very-high-resolution satellite imagery and deep learning // Remote Sensing. 2020. V. 12(7). Art. No. 1145. DOI: 10.3390/rs12071145.
- 17. *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). P. 355–368. DOI: 10.1002/rse2.194.
- Larabi M., Liu Q., Wang Y. Convolutional neural network features based change detection in satellite images // Proc. 1st Intern. Workshop Pattern Recognition, RRPR 2016. Dec. 4, 2016, Cancún, Mexico. 2016. Art. No. 100110W.
- Mou L., Bruzzone L., Zhu X.X. Learning spectral-spatialoral features via a recurrent convolutional neural network for change detection in multispectral imagery // IEEE Trans. Geoscience and Remote Sensing. 2019. V. 57(2). P. 924–935. DOI: 10.1109/TGRS.2018.2863224.
- Nielsen A.A., Conradsen K., Simpson J.J. Multivariate alteration detection (MAD) and MAF postprocessing in multispectral, bitemporal image data: New approaches to change detection studies // Remote Sensing of Environment. 1998. V. 64(1). P. 1–19.
- 21. Potapov P. V., Turubanova S. A., Tyukavina A., Krylov A. M., McCarty J. L., Radeloff V. C., Hansen M. C. Eastern Europe's forest cover dynamics from 1985 to 2012 quantified from the full Landsat archive // Remote Sensing of Environment. 2015. V. 159. P. 28–43. https://doi.org/10.1016/j.rse.2014.11.027.
- 22. Potapov P., Li X., Hernandez-Serna A., Tyukavina A., Hansen M. C., Kommareddy A., Pickens A., Turubanova S., Tang H., Silva C. E., Armston J., Dubayah R., Blair J. B., Hofton M. Mapping global forest canopy height through integration of GEDI and Landsat data // Remote Sensing of Environment. 2021. V. 253. Art. No. 112165. DOI: 10.1016/j.rse.2020.112165.
- 23. *Rodriguez-Galiano V. F., Ghimire B., Rogan J., Chica-Olmo M., Rigol-Sanchez J. P.* An assessment of the effectiveness of a random forest classifier for land-cover classification // ISPRS J. Photogrammetry and Remote Sensing. 2012. V. 67(1). P. 93–104. DOI: 10.1016/j.isprsjprs.2011.11.002.
- 24. *Ronneberger O., Fischer P., Brox T.* U-Net: Convolutional networks for biomedical image segmentation // arXiv: e-print service. arXiv:1505.04597. 2015. 8 p. https://arxiv.org/pdf/1505.04597.pdf.
- 25. Scharvogel D., Brandmeier M., Weis M. A Deep Learning Approach for Calamity Assessment Using Sentinel-2 Data // Forests. 2020. V. 11(2). Art. No. 1239. 21 p. DOI: 10.3390/f11121239.

- Shikhov A. N., Chernokulsky A. V., Azhigov I. O., Semakina A. V. A satellite-derived database for stand-replacing windthrow events in boreal forests of European Russia in 1986–2017 // Earth System Science Data. 2020. V. 12. P. 3489–3513. DOI: 10.5194/essd-12-3489-2020.
- Xie F., Gao Q., Jin C., Zhao F. Hyperspectral image classification based on superpixel pooling convolutional neural network with transfer learning // Remote Sensing. 2021. V. 13(5). P. 1–17. DOI: 10.3390/rs13050930.
- 28. *Wang F., Xu Y.J.* Comparison of remote sensing change detection techniques for assessing hurricane damage to forests // Environmental Monitoring and Assessment. 2010. V. 162. P. 311–326. DOI: 10.1007/s10661-009-0798-8.

Identification of logged and windthrow areas from Sentinel-2 satellite images using the U-net convolutional neural network and factors affecting its accuracy

A. I. Kanev¹, A. V. Tarasov², A. N. Shikhov², N. S. Podoprigorova¹, F.A. Safonov¹

¹ Bauman Moscow State Technological University, Moscow 105005, Russia ² Perm State University, Perm 614990, Russia E-mail: shikhovan@gmail.com

The results of detection (segmentation) of forest disturbances (logged and windthrow areas) based on Sentinel-2 satellite images with convolutional neural networks of U-net architecture in different regions of the European territory of Russia and the Urals are presented. The volume of the training sample was over 17 thousand objects. Overall, both logged and windthrow areas are detected with satisfactory accuracy (the average F-measure is over 0.5). At the same time, substantial differences in detection accuracy were found depending on the characteristics of both disturbances themselves and the affected forest cover. Thus, the maximum accuracy was achieved for tornado-induced windthrow areas, due to their geometric features. The dependence of windthrow detection accuracy on the species composition of damaged forests is not obvious and requires clarification; at the same time, the average area of damaged forest sites has a substantial effect on it. The maximum F-measure calculated for logged areas detected on test pairs of Sentinel-2 images reaches 0.80, which is substantially higher than in previously published studies with the U-net model. The maximum accuracy is typical for large clear-cuts in mixed and dark coniferous forests, while selective logged areas in deciduous forests are characterized by lowest one. The accuracy for wintertime and summertime pairs of images is substantially higher than for multi-seasonal pairs. Also, the accuracy strongly varies for different types of logged areas. Thus, forest roads on summertime images are detected with lowest producer's accuracy, while logged areas on wintertime images are detected with highest one.

Keywords: logged areas, windthrow areas, Sentinel-2 data, convolutional neural networks, U-net, forest species composition

Accepted: 25.04.2023 DOI: 10.21046/2070-7401-2023-20-3-136-151

References

- 1. Bartalev S.A., Egorov V.A., Krylov A.M., Stytsenko F.V., Khovratovich T.S., The evaluation of possibilities to assess forest burnt severity using multi-spectral satellite data, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2010, Vol. 7, No. 3, pp. 215–225. (in Russian).
- 2. Bartalev S.A. Egorov V.A., Zharko V.O., Loupian E.A., Plotnikov D.E., Khvostikov S.A., Shabanov N.V., *Sputnikovoe kartografirovanie rastitel'nogo pokrova Rossii* (Land cover mapping over Russia using Earth observation data, Moscow: IKI RAS, 2016, 208 p. (in Russian).
- 3. Koroleva N.V., Ershov D.V., Assessment of an error of determination of areas of windfalls using space images of high spatial resolution of Landsat-TM, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2012, Vol. 9. No. 1, pp. 80–86 (in Russian).

- 4. Krylov A. M., Vladimirova N.A., Remote monitoring of forest based on satellite imagery data, *Geomatika*, 2011, No. 3, pp. 53–58 (in Russian).
- 5. Tarasov A.V., *Operativnoe kartografirovanie narushenii lesnogo pokrova na osnove sputnikovykh dannykh s vysokim prostranstvenno-vremennym razresheniem: Diss. kand. tekhn. nauk* (Operational mapping of forest cover disturbances based on satellite images with high spatial and temporal resolution, Cand. techn. sci. thesis), Perm, 2021, 135 p. (in Russian).
- 6. Tarasov A. V., Shikhov A. N., Shabalina T. V., Detection of forest disturbances in Sentinel-2 images with convolutional neural networks, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2021, Vol. 18, No. 3, pp. 51–64 (in Russian), DOI: 10.21046/2070-7401-2021-18-3-51-64.
- Khovratovich T. S., Bartalev S. A., Kashnitskii A. V., Forest change detection based on sub-pixel estimation of crown cover density using bitemporal satellite data, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2019, Vol. 16, No. 4, pp. 102–110 (in Russian), DOI: 10.21046/2070-7401-2019-16-4-102-110.
- Shikhov A. N., Chernokulskii A. V., Azhigov I. O., Spatio-temporal distribution and origins of windthrow events in the forest zone of Western Siberia in 2001–2020, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2022, Vol. 19, No. 3, pp. 186–202 (in Russian), DOI: 10.21046/2070-7401-2022-19-3-186-202.
- 9. Allen T. R., Kupfer J. A., Spectral response and spatial pattern of Fraser fir mortality and regeneration, Great Smoky Mountains, USA, *Plant Ecology*, 2001, Vol. 156, Issue 1, pp. 59–74, DOI: 10.1023/A:1011948906647.
- Baumann M., Ozdogan M., Wolter P.T., Krylov A., Vladimirova N., Radeloff V.C., Landsat remote sensing of forest windfall disturbance, *Remote Sensing of Environment*, 2014, Vol. 143, pp. 171–179, DOI: 10.1016/j.rse.2013.12.020.
- 11. Cocke A.E., Fulé P.Z., Crouse J.E., Comparison of burn severity assessments using Differenced Normalized Burn Ratio and ground data, *Intern. J. Wildland Fire*, 2005, Vol. 14(2), pp. 189–198.
- 12. Coppin P. R., Bauer M. E., Processing of multi-temporal Landsat TM imagery to optimize extraction of forest cover change features, *IEEE Trans. Geoscience and Remote Sensing*, 1994, Vol. 32, pp. 918–927.
- Hansen M. C., Potapov P. V., Moore R., Hancher M., Turubanova S. A., Tyukavina A., Thau D., Stehman S. V., Goetz S. J., Loveland T. R., Kommareddy A., Egorov A., Chini L., Justice C. O., Townshend J. R. G., High-Resolution Global Maps of 21st-Century Forest Cover Change, *Science*, 2013, Vol. 342(6160), pp. 850–853, DOI: 10.1126/science.1244693.
- 14. Hardisky M.A., Klemas V., Smart R.M., The influence of soil salinity, growth form, leaf moisture on the spectral radiance of Spartina alterniflora canopies, *Photogrammetric Engineering and Remote Sensing*, 1983, Vol. 49, pp. 77–83.
- 15. Isaienkov K., Yushchuk M., Khramtsov V., Seliverstov O., Deep Learning for Regular Change Detection in Ukrainian Forest Ecosystem with Sentinel-2, *IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, Vol. 14, pp. 364–376.
- 16. Kislov D. E., Korznikov K. A., Automatic windthrow detection using very-high-resolution satellite imagery and deep learning, *Remote Sensing*, 2020, Vol. 12(7), Art. No. 1145, DOI: 10.3390/rs12071145.
- 17. 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.
- Larabi M., Liu Q., Wang Y., Convolutional neural network features based change detection in satellite images, *Proc. 1st Intern. Workshop Pattern Recognition*, *RRPR 2016*, Dec. 4, 2016, Cancún, Mexico, 2016, Art. No. 100110W.
- 19. Mou L., Bruzzone L., Zhu X.X., Learning spectral-spatial features via a recurrent convolutional neural network for change detection in multispectral imagery, *IEEE Trans. Geoscience and Remote Sensing*, 2019, Vol. 57(2), pp. 924–935.
- 20. Nielsen A.A., Conradsen K., Simpson J.J., Multivariate alteration detection (MAD) and MAF postprocessing in multispectral, bitemporal image data: New approaches to change detection studies, *Remote Sensing of Environment*, 1998, Vol. 64(1), pp. 1–19.
- Potapov P.V., Turubanova S.A., Tyukavina A., Krylov A. M., McCarty J. L., Radeloff V.C., Hansen M. C., Eastern Europe's forest cover dynamics from 1985 to 2012 quantified from the full Landsat archive, *Remote Sensing of Environment*, 2015, Vol. 159, pp. 28–43, https://doi.org/10.1016/j.rse.2014.11.027.
- 22. Potapov P., Li X., Hernandez-Serna A., Tyukavina A., Hansen M. C., Kommareddy A., Pickens A., Turubanova S., Tang H., Silva C. E., Armston J., Dubayah R., Blair J. B., Hofton M., Mapping global forest canopy height through integration of GEDI and Landsat data, *Remote Sensing of Environment*, 2021, Vol. 253, Art. No. 112165, DOI: 10.1016/j.rse.2020.112165.
- 23. Rodriguez-Galiano V. F., Ghimire B., Rogan J., Chica-Olmo M., Rigol-Sanchez J. P., An assessment of the effectiveness of a random forest classifier for land-cover classification, *ISPRS J. Photogrammetry and Remote Sensing*, 2012, Vol. 67(1), pp. 93–104, DOI: 10.1016/j.isprsjprs.2011.11.002.

- 24. Ronneberger O., Fischer P., Brox T., U-Net: Convolutional networks for biomedical image segmentation, *arXiv: e-print service, arXiv:1505.04597*, 2015, 8 p., https://arxiv.org/pdf/1505.04597.pdf.
- 25. Scharvogel D., Brandmeier M., Weis M., A Deep Learning Approach for Calamity Assessment Using Sentinel-2 Data, *Forests*, 2020, Vol. 11(2), Art. No. 1239, 21 p., DOI: 10.3390/f11121239.
- Shikhov A. N., Chernokulsky A. V., Azhigov I. O., Semakina A. V., A satellite-derived database for standreplacing windthrow events in boreal forests of European Russia in 1986–2017, *Earth System Science Data*, 2020, Vol. 12, pp. 3489–3513, DOI: 10.5194/essd-12-3489-2020.
- 27. Xie F., Gao Q., Jin C., Zhao F., Hyperspectral image classification based on superpixel pooling convolutional neural network with transfer learning, *Remote Sensing*, 2021, Vol. 13(5), pp. 1–17.
- 28. Wang F., Xu Y.J., Comparison of remote sensing change detection techniques for assessing hurricane damage to forests, *Environmental Monitoring and Assessment*, 2010, Vol. 162, pp. 311–326.