# Распознавание нарушений лесного покрова по спутниковым снимкам Sentinel-2 с помощью свёрточных нейронных сетей

## А.В. Тарасов, А.Н. Шихов, Т.В. Шабалина

Пермский государственный национальный исследовательский университет Пермь, 614990, Россия E-mail: andrew.tarasov1993@gmail.com

Мониторинг нарушений лесного покрова — одна из важнейших областей применения спутниковых данных. Перспективный путь повышения точности распознавания таких объектов на снимках заключается в использовании алгоритмов глубокого обучения (свёрточных нейронных сетей). В настоящей работе представлен алгоритм выявления нарушений лесного покрова по снимкам Sentinel-2 на основе свёрточной нейронной сети архитектуры U-Net. Обучение и валидация модели реализованы на примере территории нескольких регионов европейской части России. Всего проведено более 50 экспериментов с базовой архитектурой, в результате которых установлено, что наиболее информативными признаками оказываются спектральные каналы Red, NIR, SWIR1, SWIR2 и их разности. Созданы модели распознавания нарушений лесного покрова для снимков зимнего, летнего и переходного сезонов, а также модель для всех сезонов. Разработанные модели обеспечивают повышение точности распознавания нарушений лесного покрова более чем в два раза в сравнении с традиционными методами, основанными на растровой арифметике. В наибольшей степени их преимущества проявляются при детектировании выборочных рубок, которые выделяются как целостные объекты, в то время как с помощью традиционных методов удаётся выделить лишь отдельные пиксели с наибольшими изменениями в яркости. Также разработанные модели менее чувствительны к теням, что позволяет успешно использовать их для мониторинга вырубок по снимкам осенне-зимнего периода. Основным ограничением метода становятся большие затраты на формирование обучающей выборки, но в то же время увеличение объёма выборки повышает способность модели к обобщению и адаптации к новым данным.

**Ключевые слова:** распознавание нарушений лесного покрова, данные Sentinel-2, свёрточные нейронные сети, глубокое обучение, семантическая сегментация, U-Net

Одобрена к печати: 17.06.2021 DOI: 10.21046/2070-7401-2021-18-3-51-64

#### Введение

Современный этап развития дистанционного зондирования Земли (ДЗЗ) из космоса характеризуется стремительным ростом числа действующих на орбите спутников и одновременным увеличением пространственного и временного разрешения данных, что приводит к взрывному росту их объёма (Лупян и др., 2018). С одной стороны, это позволяет существенно расширить круг задач, решаемых на основе данных ДЗЗ, в частности для мониторинга лесного и сельского хозяйства. С другой стороны, возникает необходимость в разработке новых алгоритмов, обеспечивающих автоматизированное распознавание объектов на спутниковых снимках.

Существующие методы выявления нарушений лесного покрова по спутниковым снимкам основаны на использовании вегетационных индексов и растровой арифметики (Крылов, Владимирова, 2011; Wang, Xu, 2010) или на других преобразованиях спектральных каналов (см., например, работы (Allen, Kupfer, 2001; Nielsen et al., 1998)). По мере повышения пространственного разрешения снимков растёт значимость текстурных и геометрических признаков, которые вообще не учитываются традиционными методами обнаружения изменений. Следовательно, требуется разработка новых алгоритмов, учитывающих эти признаки наряду со спектральными.

Распознавание изменений объектов на космических снимках представляет собой частный случай задачи анализа изображений. В последние годы наиболее эффективными алгоритмами

для решения подобных задач являются свёрточные нейронные сети или алгоритмы глубокого обучения (*англ*. Convolutional Neural Networks — CNN) (Khryashchev et al., 2018). В отличие от традиционных алгоритмов, используемых при автоматизированном дешифрировании снимков, 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).

Алгоритмы глубокого обучения широко применяются для анализа спутниковых снимков (Андреев и др., 2019), в частности для маскирования облачности (Li et al., 2019; Wieland et al., 2019) или классификации типов землепользования (Syrris et al., 2019). Однако количество публикаций по применению CNN для распознавания вырубок и других нарушений лесного покрова пока сравнительно невелико (Isaienkov et al., 2021; Wu et al., 2020). Большинство из них посвящены мониторингу экваториальных лесов в Амазонии (см., например, работы (de Bem et al., 2020; Hethcoat et al., 2019)).

Среди различных архитектур свёрточных нейронных сетей, разработанных в последние годы, одна из наиболее перспективных для анализа изображений, в том числе космических снимков, — архитектура U-Net (Ronneberger et al., 2015). Данная архитектура успешно применялась, в частности, для идентификации ветровалов (Scharvogel et al., 2020) и мониторинга нарушений лесного покрова на территории Украины (Isaienkov et al., 2021) по снимкам Sentinel-2. При этом точность распознавания для вырубок оказалась существенно выше, чем для ветровалов.

В настоящей статье представлены результаты экспериментов по распознаванию нарушений лесного покрова по разновременным спутниковым снимкам Sentinel-2 с применением свёрточных нейронных сетей архитектуры U-Net на примере ряда регионов европейской части России. Оценивается влияние сезонного фактора на точность распознавания.

#### Материалы и методы

## Создание обучающей выборки

Для эффективного построения моделей машинного обучения требуется соответствующий набор обучающих данных. Такие модели относятся к группе алгоритмов с учителем (*англ.* supervised learning), поэтому для них нужна обучающая выборка с размеченными контурами интересующих объектов и соответствующий этой маске набор признаков. Так как модель строится для проведения ежемесячного мониторинга, необходимо было получить данные об изменениях лесного покрова по паре снимков с разницей не более чем несколько месяцев. С другой стороны, мониторинг будет проводиться в течение всего года, поэтому требуется выявлять изменения в разные сезоны. Подходящие обучающие наборы в открытом доступе отсутствуют, в связи с этим был создан собственный обучающий набор данных. Для создания выборки использовались снимки со спутника Sentinel-2, которые предоставляются в формате тайлов размером ~100×100 км. На *рис. 1* (см. с. 53) представлено их пространственное распределение.

Для этих участков загружались несколько пар малооблачных (облачность не более 20 %) снимков в течение всего года с разницей в один месяц. По каждой паре снимков были векторизованы все нарушения лесного покрова, которые классифицированы на пять типов: сплошная рубка, проходная рубка, лесная дорога, ветровал, гарь. Для каждого объекта в выборке сохранялись идентификаторы двух снимков: до произошедшего изменения и после него, в формате Vendor Product ID.

Если на вырубке оставались отдельные деревья или участки лесной растительности, они не исключались из объекта. Также сохранялись тени от деревьев на границе объекта. При отсутствии безоблачных изображений допускалось увеличение временного интервала между снимками в паре, но он не должен был превышать 6 мес. Полученные таким образом слои для каждой пары снимков объединялись в один векторный слой. При этом проводилась проверка однотипности названий классов, корректность идентификаторов снимков и т.д. После этого были загружены все снимки, которые были задействованы при выявлении изменений (98 снимков Sentinel-2 уровня обработки L1C).



Рис. 1. Область для формирования обучающей выборки нарушений лесного покрова

Таким образом, итоговая обучающая выборка представляет собой векторный слой с нарушениями лесного покрова (3612 объектов), включая 2600 сплошных вырубок, 702 выборочные вырубки, 290 участков лесных дорог, 20 ветровалов. Для формирования выборки использовано 98 снимков Sentinel-2. Примеры разных типов объектов в выборке представлены на *рис. 2* (см. с. 54).

## Предварительная обработка изображений

На первом этапе данные обучающей выборки необходимо было представить в виде тайлов — небольших растровых изображений (чаще всего размером 256×256 или 512×512 пикселей), где содержится целевая маска и набор входных признаков. Чтобы иметь возможность при обучении моделей рассчитывать различные производные признаки (например, вегетационные индексы), в тайлах были сохранены исходные значения яркости всех каналов обоих снимков. Для каждой пары снимков в обучающем наборе каналы первого и второго изображений приводились к пространственному разрешению 10 м и объединялись в один 26-канальный растр. Далее соответствующий этой паре слой нарушений конвертировался в растровый формат и добавлялся в качестве дополнительного канала к созданному растру. Таким образом, для каждой пары снимков был получен 27-канальный растр, который содержит маску нарушений и значения яркости в 13 каналах снимков, полученных до и после появления нарушения (*рис. 3*, см. с. 55).

Снимок до нарушения



Снимок до нарушения



Снимок до нарушения



Снимок после нарушения





Изменение



a Снимок после нарушения





Изменение



Снимок после нарушения



Граница выделенного объекта в выборке

Рис. 2. Объекты из обучающей выборки на снимках Sentinel-2, полученных до и после изменения: а сплошная рубка; б — выборочная рубка; в — лесная дорога. Первая, вторая колонки — фрагменты снимков в синтезе «естественные цвета». Третья колонка — «мультивременной» синтез RGB, где R красный канал фрагмента нового снимка; G — красный канал фрагмента старого снимка; B — зелёный канал фрагмента нового снимка

в



Рис. 3. Общая схема процесса предварительной обработки снимков

Такой растр послужил основой для непосредственного формирования тайлов для обучения. Для этого был разработан авторский алгоритм, который формирует их с учётом максимизации площади целевой маски на одном тайле, а также исключает возможные перекрытия между тайлами. После формирования тайлов с маской изменений генерировались фрагменты без целевой маски методом случайной выборки, при этом пересечение с уже созданными тайлами не допускалось.

С учётом того, что яркости пикселей могут значительно отличаться в течение года, полученные тайлы были сгруппированы по сезонам (летние, зимние и переходного периода). К летней группе были отнесены изменения, произошедшие в бесснежный период (т.е. когда снежный покров отсутствует на обоих снимках), к зимней — при наличии снежного покрова на обоих снимках. К группе переходных изменений относились все объекты, где на одном из снимков в паре был снежный покров (т.е. изменения за период март – июнь и сентябрь – декабрь были отнесены к одной группе).

#### Характеристика моделей машинного обучения

В настоящей работе для выявления нарушений лесного покрова использовались алгоритмы, которые не учитывают временной аспект, а анализируют только пару снимков. В качестве основного алгоритма была выбрана архитектура U-Net, которая относится к группе автоэнкодеров. Такая группа сетей позволяет сначала разбить всё изображение на базовые признаки, на основе которых выделяются более высокоуровневые признаки. Более того, подобная архитектура позволяет на выходе сохранить размер входного сегментируемого изображения без дополнительных преобразований. Поэтому результаты сегментации легко совмещать с начальными данными. Прямая связь, которая существует между конечными и начальными слоями, обеспечивает лучшее распространение градиента по всей сети, что, по сути, позволяет проводить более быстрое обучение, а также комбинировать как низкоуровневые, так и высо-коуровневые признаки (Larabi et al., 2016) (*puc. 4*, см. с. 57).

В виде дополнения на первом этапе архитектура U-Net была использована совместно с предобработчиком (*англ*. backbone) vgg16. Однако после первых экспериментов было установлено, что такой подход приводит к сильному переобучению модели (потере способности к обобщению) уже на первых итерациях обучения, поэтому в дальнейших экспериментах использовалась только архитектура U-Net.

Для предотвращения переобучения использовалась аугментация изображений, а именно геометрические преобразования (поворот, зеркальное отображение и др.). С этой же целью были добавлены слои дропаута (*англ*. dropout) (Srivastava et al., 2014). Несколько сцен из каждой группы изменений были исключены из обучения для использования в качестве контрольных данных (тестовые данные). Оставшаяся часть использовалась при обучении, при этом для обучения и валидации она была разделена в пропорции 75 и 25 % соответственно.

На вход модели подаётся фрагмент двух последовательных изображений и их разница. Для обучения использовался оптимизатор Adam с функцией потерь «бинарная кроссэнтропия» (*анел*. Binary Cross Entropy). Также после каждого свёрточного слоя использовался слой Batch Normalization. В качестве метрики оценки качества использовался коэффициент Дайса (Dice, 1945). При обучении каждые 20 эпох шаг обучения снижался в 10 раз.

Название	Формула						
Исходные значения яркости пикселей							
Яркость в канале Red (красный) снимка до изменения	B4 <sub>OLD</sub>						
Яркость в канале NIR ( <i>англ</i> . near infrared, ближний ин- фракрасный (ИК)) снимка до изменения	B8 <sub>OLD</sub>						
Яркость в канале SWIR1 ( <i>англ</i> . short wave infrared, средний инфракрасный) снимка до изменения	B11 <sub>OLD</sub>						
Яркость в канале SWIR2 снимка до изменения	B12 <sub>OLD</sub>						
Яркость в канале Red снимка после изменения	$B4_{NEW}$						
Яркость в канале NIR снимка после изменения	$B8_{NEW}$						
Яркость в канале SWIR1 снимка после изменения	<b>B</b> 11 <sub>NEW</sub>						
Яркость в канале SWIR2 снимка после изменения	B12 <sub>NEW</sub>						
Расчётные значения							
Разность в канале Red	$B4_{OLD} - B4_{NEW}$						
	$B4_{NEW} - B4_{OLD}$						
Разность в канале NIR	$B8_{OLD} - B8_{NEW}$						
	$B8_{NEW} - B8_{OLD}$						
Разность в канале SWIR1	$B11_{OLD} - B11_{NEW}$						
	$B11_{NEW} - B11_{OLD}$						
Разность в канале SWIR2	$B12_{OLD} - B12_{NEW}$						
	$B12_{NEW} - B12_{OLD}$						
Разность NDVI (Normalized Difference Vegetation Index — нормализован- ный разностный вегетационный индекс)	$\frac{B8_{NEW} - B4_{NEW}}{B8_{NEW} + B4_{NEW}} - \frac{B8_{OLD} - B4_{OLD}}{B8_{OLD} + B4_{OLD}}$						
	$\frac{B8_{OLD} - B4_{OLD}}{B8_{OLD} + B4_{OLD}} - \frac{B8_{NEW} - B4_{NEW}}{B8_{NEW} + B4_{NEW}}$						
Разность SWVI (Short Wave Vegetation Index — коротковолновый вегета- ционный индекс)	$\frac{B8_{NEW} - B12_{NEW}}{B8_{NEW} + B12_{NEW}} - \frac{B8_{OLD} - B12_{OLD}}{B8_{OLD} + B12_{OLD}}$						
	$\frac{B8_{NEW} - B13_{NEW}}{B8_{NEW} + B13_{NEW}} - \frac{B8_{OLD} - B13_{OLD}}{B8_{OLD} + B13_{OLD}}$						
	$\frac{B8_{OLD} - B12_{OLD}}{B8_{OLD} + B12_{OLD}} - \frac{B8_{NEW} - B12_{NEW}}{B8_{NEW} + B12_{NEW}}$						
	$\frac{B8_{OLD} - B13_{OLD}}{B8_{OLD} + B13_{OLD}} - \frac{B8_{NEW} - B13_{NEW}}{B8_{NEW} + B13_{NEW}}$						

Таблица 1. Признаки, использованные при обучении нейронной сети



Рис. 4. Схематичное представление модели U-Net

Вышеописанная структура и настройки использовались при обучении всех моделей. В процессе исследования менялась в первую очередь комбинация входных признаков. Для обучения алгоритма использовались наиболее информативные каналы для оценки состояния лесной растительности. Список всех использованных признаков представлен в *табл.* 1. Обучение проводилось как на отдельных группах изменений (летние, зимние, переходного периода), так и на всех изменениях в течение года.

Вторая группа параметров, которая изменялась в процессе экспериментов, относилась к так называемым гиперпараметрам. Изменялось значение начального шага обучения (*англ*. learning rate) и размер подвыборки (*англ*. batch size) для обучения.

Алгоритм был реализован с помощью библиотеки TensorFlow 2.0 (https://www.tensorflow. org/), которая написана на языке программирования Python. Она содержит базовые конструкции для построения нейронных сетей, различные функции активации, разные виды слоёв нейронной сети, что позволяет создавать сложные модели машинного обучения. Также эта библиотека позволяет проводить вычисления на графических процессорах, что существенно снижает время на расчёт. Для обучения использовалась видеокарта Nvidia Tesla K20 в составе вычислительного комплекса ПГНИУ-Кеплер.

#### Результаты

Всего проведено порядка 50 различных экспериментов с базовой архитектурой. Наилучшую точность показали модели, в которых при обучении использовались спектральные каналы Red, NIR, SWIR1, SWIR2 и их разности. Графики обучения моделей (зависимости функции потерь и точности от эпохи обучения), которые достигли наибольшей точности, представлены на *рис. 5* (см. с. 58).

Наибольшая точность распознавания нарушений лесного покрова получена по модели, обученной по данным только за бесснежный период (см. *рис. 26*). В свою очередь, наименьшая точность получена по модели, обученной на данных переходного периода (см. *рис. 2г*). Как и ожидалось, нарушения лесного покрова, произошедшие в переходные сезоны, наиболее сложные для распознавания. Стоит отметить, что модель, обученная на изменениях всех сезонов, также показала высокую точность (свыше 60 %). Такая модель наиболее удобна для применения в системах мониторинга. Возможно использование и отдельных моделей, но в этом случае необходимо разработать инструмент автоматического определения сезона или выбирать нужную модель экспертно.



*Рис. 5.* Основные показатели обучения лучших моделей: *a* — при обучении на всех группах изменений; *б* — при обучении на летней группе изменений; *в* — при обучении на зимней группе изменений; *г* — при обучении на переходной группе изменений

Выявленные контуры нарушений лесного покрова сравнивались с аналогичными, но полученными с использованием традиционных пороговых методов обнаружения изменений. Из всего многообразия традиционных методов были выбраны метод одноканального обнаружения изменений по красному каналу — для зимней группы изменений и разность индекса NBR (Normalized Burn Ratio — нормализованный индекс гарей) (Cocke et al., 2005) — для летнего и переходного периодов. Пороговые значения устанавливались экспертно. После выделения изменений слой конвертировался в векторный формат.

В качестве контрольных данных был выбран поднабор из исходной выборки, который не участвовал в обучении. Для летнего сезона были взяты четыре сцены, для зимнего и переходного периода — по две сцены. В качестве меры оценки точности использовался показатель *f*-меры:

$$Fmeasure = \frac{2 \times precision \times recall}{precision + recall};$$

$$precision = \frac{TP}{TP + FP};$$
$$recall = \frac{TP}{TP + FN};$$

TP — нарушения лесного покрова, верно отнесённые к нужному классу; FP — ошибочно отнесённые к нужному классу (ошибка I рода); FN — не отнесённые к нужному классу (ошибка II рода).

Результат работы модели представляет собой растр, значения в пикселях которого показывают вероятность произошедшего изменения (от 0 до 1). Порог вероятности для преобразования выявленных изменений в векторный формат был принят равным 0,1 на основе анализа соотношения пропусков объектов и ложных срабатываний.

При оценке точности использовался векторный слой с предварительной фильтрацией по площади (площадь объекта >0,1 га). Никакие другие фильтры не применялись. Точность распознавания нарушений лесного покрова, полученная с помощью разработанной модели и традиционных методов, сравнивалась с контрольными данными с помощью показателя *f*-меры (*табл. 2*).

Тайл Sentinel-2	Дата перво- го снимка	Дата второ- го снимка	Период изменений	Точность традицион-	Алгоритм машинного обучения с самой высокой точностью, обученный на сезонах			с самой сезонах:
				ных методов	всех	зимнем	переходном	летнем
T40VEM	20.11.2019	24.03.2020	Зимний	0,06	0,51	0,56	_	_
T40VEM	25.11.2017	13.02.2018		0,33	0,67	0,65	_	_
T37VFJ	08.03.2018	31.07.2018	Переходный	0,09	0,41	_	0,41	_
T38VMP	22.03.2020	22.06.2020		0,43	0,39	_	0,42	_
T39VWF	25.05.2017	23.08.2017	Летний	0,16	0,38	_	_	0,49
T39VXH	29.06.2018	04.09.2018		0,62	0,60	_	_	0,59
T37WFM	18.07.2020	04.10.2020		0,13	0,56	_		0,36
T38VPL	17.06.2018	01.08.2018		0,05	0,27	_	_	0,61

Таблица 2. Значения F1-score для контрольных данных

В среднем по восьми проанализированным сценам точность распознавания нарушений лесного покрова по разработанной модели составила 0,48, а традиционными методами — 0,23. В зимний период повышение точности распознавания по разработанной модели достигается за счёт устойчивости к наличию теней.



*Рис. б.* Примеры выделения выборочных рубок по снимкам разных периодов: *a* — переходный; *б* — летний; *в* — зимний; *е*, *д* — летний период с разницей дат съёмки в 1 год. Все фрагменты снимков представлены в синтезе «естественные цвета»

Наименьшая точность наблюдается в переходный период, что объясняется сильным изменением яркости между изображениями (при наличии снежного покрова на одном из двух снимков).

Принципиальное отличие в результатах состоит в том, что разработанные модели выделяют нарушения лесного покрова как целостный объект, что хорошо проявляется при детектировании выборочных рубок. Поэтому для всех выборочных рубок из контрольного набора было рассчитано количество объектов, которые пересекаются с ними в слоях, полученных с помощью разработанных моделей и традиционных методов (*табл. 3*).

Тайл	Даты первого и второго снимков изменений	Период изменений	Традицион- ные методы	Алгоритм машинного обучения с самой высокой точностью, обученный на сезонах:				
				всех	зимнем	переходном	летнем	
T40VEM	20.11.2019-24.03.2020	Зимний	1,60	1,42	1,15	-	—	
T37VFJ	08.03.2018-31.07.2018	Переходный	2,31	2,66	—	1,50	—	
T38VMP	22.03.2020-22.06.2020		9,00	1,66	_	1,50	_	
T39VWF	25.05.2017-23.08.2017	Летний	2,00	1,50	_	_	1,00	
T38VPL	17.06.2018-01.08.2018		5,00	1,00	_	_	1,50	

*Таблица 3*. Количество выделенных объектов для одного контрольного объекта с типом «выборочная рубка»

Во всех случаях разработанные модели выявляют меньше объектов для одного контрольного объекта, чем традиционные методы, причём наибольшее различие наблюдается в переходные сезоны. На *рис. 6* (см. с. 60) представлены примеры выделения выборочных рубок моделью, обученной на всех группах изменений. Отметим, что на приведённом рисунке (см. *рис. 66*) объект вообще не был выделен традиционными методами.

## Ограничения модели

В целом пропуски и ложные срабатывания моделей часто происходят на тех же объектах, что и при использовании традиционных методов обнаружения изменений. По результатам проведённых экспериментов выявлены следующие ограничения использованных моделей.

Большинство ложных срабатываний происходит на нелесопокрытых территориях при резком изменении яркости объектов, например при появлении или разрушении ледового покрова на реках либо при распашке полей. Такие ложные срабатывания более характерны для переходных периодов (весна – лето, осень – зима). Таким образом, при условии предварительного маскирования воды и нелесопокрытых территорий можно существенно увеличить точность предсказания за счёт фильтрации ложных срабатываний.

На точность распознавания негативно влияет также наличие теней от облаков, рельефа и т.д., особенно в зимние периоды, когда их длина увеличивается из-за низкого угла освещения солнцем. Успешное распознавание выборочных рубок возможно только при изъятии более 20–30 % древостоя. Эта проблема может быть решена, если использовать для распознавания снимки более высокого пространственного разрешения и адаптировать модель под них.

## Заключение

Основной результат проведённого исследования заключается в оценке применимости свёрточных нейронных сетей архитектуры U-Net для выявления нарушений лесного покрова по снимкам Sentinel-2 и сравнение эффективности CNN и традиционных методов, основанных на растровой арифметике. Такое исследование, возможно, стало первым для территории России. Разработанные модели в целом обеспечивают значительное (более чем в два раза) повышение точности распознавания нарушений лесного покрова в сравнении с традиционными методами. В наибольшей степени их преимущества проявляются при детектировании выборочных рубок, которые выделяются как целостные объекты, в то время как с помощью традиционных методов удаётся выделить лишь отдельные пиксели с наибольшими изменениями в яркости. Также модели машинного обучения менее чувствительны к теням, что позволяет успешно использовать их для мониторинга вырубок по снимкам осенне-зимнего периода.

Впервые получены оценки точности распознавания в зависимости от сезона (для снимков зимнего, летнего и переходных сезонов). Для этого были обучены модели распознавания для отдельных сезонов года, а также одна общая модель для всех сезонов. Характеристики точности по этим моделям оказались сопоставимы между собой. Наибольшая точность достигнута моделью, которая была обучена на снимках летнего периода, наименьшая — на снимках переходных сезонов.

Разработанные модели могут быть использованы в системах мониторинга с различным временным разрешением (еженедельным, ежемесячным, ежеквартальным, ежегодным). Дальнейшее развитие исследования будет посвящено повышению точности моделей, а также выделению разных типов нарушений.

Исследование выполнено при поддержке Российского фонда фундаментальных исследований (проект № 19-35-90005).

## Литература

- 1. *Андреев А. И., Шамилова Ю.А., Холодов Е. И.* Применение сверточной нейронной сети для детектирования облачности по данным прибора МСУ-МР спутника «Метеор-М» № 2 // Метеорология и гидрология. 2019. № 7. С. 44–53.
- 2. *Крылов А. М., Владимирова Н.А.* Дистанционный мониторинг состояния лесов по данным космической съемки // Геоматика. 2011. № 3. С. 53–58.
- 3. Лупян Е.А., Бурцев М.А., Прошин А.А., Кобец Д.А. Развитие подходов к построению информационных систем дистанционного мониторинга // Современные проблемы дистанционного зондирования Земли из космоса. 2018. Т. 15. № 3. С. 53–66. DOI: 10.21046/2070-7401-2018-15-3-53-66.
- 4. *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. P. 59–74.
- 5. *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.
- 6. *de Bem P. P., de Carvalho O. A. Jr., 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). Art. No. 901. DOI: 10.3390/rs12060901.
- 7. *Dice L. R.* Measures of the amount of ecologic association between species // Ecology. 1945. V. 26. P. 297–302.
- 8. *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.
- 9. *Hethcoat M. G., Edwards D. P., Carreiras J. M. B., Bryant R. G., França F. M., Quegan S.* A machine learning approach to map tropical selective logging // Remote Sensing of Environment. 2019. V. 221. P. 569–582. DOI: 10.1016/j.rse.2018.11.044.
- Khryashchev V., Ivanovisky L., Pavlov V., Rubtsov A., Ostrovskay A. Comparison of different convolutional neural network architectures for satellite image segmentation // Proc. 23<sup>rd</sup> Conf. Fruct Association. Jyvaskyla, Finland. 2018. P. 172–180.
- 11. *Larabi M., Liu Q., Wang Y.* Convolutional neural network features based change detection in satellite images // Proc. 1<sup>st</sup> Intern. Workshop Pattern Recognition. 2016. Art. No. 100110W.
- Li Z., Shen H., Cheng Q., Liu Y., You S., He Z. Deep learning based cloud detection for medium and high resolution remote sensing images of different sensors // ISPRS J. Photogrammetry and Remote Sensing. 2019. V. 150. P. 197–212. DOI: 10.1016/j.isprsjprs.2019.02.017.
- 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.

- 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.
- 15. *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/1505.04597v1.
- 16. Scharvogel D., Brandmeier M., Weis M. A Deep Learning Approach for Calamity Assessment Using Sentinel-2 Data // Forests. 2020. V. 11. DOI: 10.3390/f11121239.
- 17. Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R. Dropout: A Simple Way to Prevent Neural Networks from Overfitting // J. Machine Learning Research. 2014. V. 15. Art. No. 56. P. 1929–1958.
- Syrris V., Hasenohr P., Delipetrev B., Kotsev A., Kempeneers P., Soille P. Evaluation of the potential of convolutional neural networks and random forests for multi-class segmentation of Sentinel-2 imagery // Remote Sensing. 2019. V. 11(8). Art. No. 907. DOI: 10.3390/rs11080976.
- 19. 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.
- 20. *Wieland M., Li Y., Martinis S.* Multi-sensor cloud and cloud shadow segmentation with a convolutional neural network // Remote Sensing. 2019. V. 230. Art. No. 111203.
- 21. *Wu L., Li Z., Liu X., Zhu L., Tang Y., Zhang B., Xu B., Liu M., Meng Y., Liu B.* Multi-type forest change detection using BFAST and monthly Landsat time series for monitoring spatiotemporal dynamics of forests in subtropical wetland // Remote Sensing. 2020. V. 12(2). Art. No. 341. DOI: 10.3390/rs12020341.
- 22. 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.

# Detection of forest disturbances in Sentinel-2 images with convolutional neural networks

## A. V. Tarasov, A. N. Shikhov, T. V. Shabalina

Perm State University, Perm 614990, Russia E-mail: andrew.tarasov1993@gmail.com

Monitoring of forest disturbances is an important application field in forest management. Deep learning (convolutional neural network, CNN) is state-of-the-art approach to improve accuracy of forest changes detection. In this study, the algorithm for forest losses detection with Sentinel-2 images based on U-Net architecture was proposed. Training and evaluation were conducted on our own dataset compiled on Sentinel-2 images for several regions of the European Russia. More than 50 experiments with base U-Net architecture to find the best model were performed. It was found that Red, NIR, SWIR1, SWIR2 bands of Sentinel-2 images and their differences were the most important features for forest change detection. General model for all season and separate models for summer, winter and transitional season were developed. Against traditional methods based on map algebra substantial improvement (more than two times) of the accuracy of forest disturbances detection was achieved by the developed models. The developed CNN-based models identified selective loggings as single (unified) forest loss areas as opposed to traditional methods that detect only pixels with strong difference of spectral reflectance. The developed models can be applied in forest change detection in autumn-winter season due to lower shadow sensitivity. Main limitation of the models is time-consuming compilation of training dataset. However, training dataset size increase facilitates adaptation of the algorithm to new data.

**Keywords:** forest change detection, Sentinel-2 data, convolutional neural networks, deep learning, semantic segmentation, U-Net

Accepted: 17.06.2021 DOI: 10.21046/2070-7401-2021-18-3-51-64

## References

- 1. Andreev A. I., Shamilova Yu. A., Kholodov E. I., Using Convolutional Neural Networks for Cloud Detection from Meteor-M No. 2 MSU-MR Data, *Russian Meteorology and Hydrology*, 2019, Vol. 44(7), pp. 459–466.
- 2. Krylov A. M., Vladimirova N. A., Remote sensing data for forest monitoring, *Geomatica*, 2011, No. 3, pp. 53–58 (in Russian).
- 3. Loupian E.A., Burtsev M.A., Proshin A.A., Kobets D.A., Evolution of remote monitoring information systems development concepts, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2018, Vol. 15, No. 3, pp. 53–66 (in Russian), DOI: 10.21046/2070-7401-2018-15-3-53-66.
- 4. 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, pp. 59–74.
- 5. 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.
- 6. de Bem P. P., de Carvalho O. A. Jr., 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, Vol. 12, DOI: 10.3390/rs12060901.
- 7. Dice L. R., Measures of the amount of ecologic association between species, *Ecology*, 1945, Vol. 26, pp. 297–302.
- 8. 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.
- 9. Hethcoat M.G., Edwards D.P., Carreiras J.M.B., Bryant R.G., França F.M., Quegan S., A machine learning approach to map tropical selective logging, *Remote Sensing of Environment*, 2019. Vol. 221, pp. 569–582, DOI: 10.1016/j.rse.2018.11.044.
- Khryashchev V., Ivanovisky L., Pavlov V., Rubtsov A., Ostrovskay A., Comparison of different convolutional neural network architectures for satellite image segmentation, *Proc. 23<sup>rd</sup> Conf. Fruct Association*, Jyvaskyla, Finland, 2018, pp. 172–180.
- 11. Larabi M., Liu Q., Wang Y., Convolutional neural network features based change detection in satellite images, *Proc.* 1<sup>st</sup> Intern. Workshop Pattern Recognition, 2016, Art. No. 100110W.
- Li Z., Shen H., Cheng Q., Liu Y., You S., He Z., Deep learning based cloud detection for medium and high resolution remote sensing images of different sensors, *ISPRS J. Photogrammetry and Remote Sensing*, 2019, Vol. 150, pp. 197–212, DOI: 10.1016/j.isprsjprs.2019.02.017.
- 13. 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.
- 14. 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.
- 15. 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/1505.04597v12015, arXiv: 1505.04597.
- 16. Scharvogel D., Brandmeier M., Weis M., A Deep Learning Approach for Calamity Assessment Using Sentinel-2 Data, *Forests*, 2020, Vol. 11, DOI: 10.3390/f11121239.
- 17. Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R., Dropout: A Simple Way to Prevent Neural Networks from Overfitting, *J. Machine Learning Research*, 2014, Vol. 15, Art. No. 56, pp. 1929–1958.
- 18. Syrris V., Hasenohr P., Delipetrev B., Kotsev A., Kempeneers P., Soille P., Evaluation of the potential of convolutional neural networks and random forests for multi-class segmentation of Sentinel-2 imagery, *Remote Sensing*, 2019, Vol. 11(8), Art. No. 907, DOI: 10.3390/rs11080976.
- 19. 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.
- 20. Wieland M., Li Y., Martinis S., Multi-sensor cloud and cloud shadow segmentation with a convolutional neural network, *Remote Sensing*, 2019, Vol. 230, Art. No. 111203.
- 21. Wu L., Li Z., Liu X., Zhu L., Tang Y., Zhang B., Xu B, Liu M., Meng Y., Liu B., Multi-type forest change detection using BFAST and monthly Landsat time series for monitoring spatiotemporal dynamics of forests in subtropical wetland, *Remote Sensing*, 2020, Vol. 12(2), Art. No. 341, DOI: 10.3390/rs12020341.
- 22. 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.