

# Использование свёрточных нейронных сетей для геопространственного моделирования породной структуры и таксационных характеристик лесов (на примере ХМАО — Югры)

М. Д. Московченко

Тюменский государственный университет, Тюмень, 625003, Россия  
E-mail: moskovchenkomd@yandex.ru

До недавнего времени единственно надёжным источником данных о характеристиках лесной растительности были данные лесоустройства. В настоящее время появляется возможность корректировать материалы лесоустройства, в том числе на локальном повыведельном уровне, с использованием данных дистанционного зондирования Земли (ДЗЗ) и методов геопространственного моделирования. В статье на примере территории Ханты-Мансийского округа — Югры (ХМАО — Югры) исследована возможность применения свёрточных нейронных сетей для геопространственного моделирования породной структуры и лесотаксационных характеристик насаждений. При моделировании в качестве обучающих данных были использованы материалы лесоустройства ХМАО — Югры, а в качестве предикторов — данные ДЗЗ (космоснимки Sentinel-2), цифровая модель местности ASTER GDEM, данные о ландшафтном покрове ESA WorldCover и данные об изменении лесного покрова Global Forest Change. Применение модели, основанной на архитектуре DeepLab, позволило определить все три лесотаксационные характеристики: преобладающую породу, напочвенный покров и бонитет леса — с точностью 88 % как на тренировочном, так и на валидационном и тестовом наборах данных, а также создать актуальные цифровые карты этих характеристик с разрешением 10 м. Оценка результатов моделирования при применении полученных моделей на территориях сопредельных регионов — Ямало-Ненецкого автономного округа (точность моделирования составила 85 %) и Красноярского края (от 62 до 67 %) — показала, что они могут использоваться на смежных территориях других регионов Западной Сибири, но неприменимы при моделировании лесотипологических показателей в Восточной Сибири.

**Ключевые слова:** нейросети, моделирование, U-Net, DEEPLAB, лесоустройство, картографирование лесов, Западная Сибирь

Одобрена к печати: 30.03.2023  
DOI: 10.21046/2070-7401-2023-20-2-75-93

## Введение

Растительность — один из наиболее динамичных и уязвимых компонентов ландшафта. Необходимость в получении данных о состоянии растительного покрова особенно актуальна для севера Западной Сибири, где природная среда подвержена воздействию нефте- и газодобывающей отрасли (Корниенко, 2022), что приводит к снижению количества фотосинтетически активной биомассы в темнохвойных лесах (Miles, Esau, 2016), а современные климатические изменения проявляются интенсивнее по сравнению с другими регионами (Kirpotin et al., 2021), приводя к увеличению значений вегетационного индекса NDVI (*англ.* Normalized Difference Vegetation Index — нормализованный разностный вегетационный индекс) (Зуев и др., 2019).

До недавнего времени основным источником данных о растительном покрове таёжной зоны были данные лесоустройства. Однако их обновление происходит медленно, из-за чего они частично теряют достоверность. Давность материалов лесоустройства для 58 % площади лесов страны превышает 20 лет (Филипчук и др., 2020). Общедоступные карты лесоустройства Ханты-Мансийского округа — Югры (ХМАО — Югры) (Особо..., 2006) не учитывают последствия лесных пожаров, площадь которых в Уральском федеральном округе в летний период 2010–2019 гг. выросла в 1,5 раза по сравнению с предыдущим десятилетием (Бондур и др., 2020). Разработка мер по снижению ущерба от воздействий техногенных и природных

факторов на лесной комплекс округа требует использования карт породного состава лесов (Хамедов и др., 2009).

Возросшая доступность баз пространственных данных, в первую очередь данных дистанционного зондирования Земли (ДЗЗ), а также развитие аппарата математических методов обусловили возможность развития геопространственного моделирования (Савельев, 2004). Эффективность применения ДЗЗ для моделирования типологических, биометрических, структурных и функциональных характеристик лесных сообществ была неоднократно доказана в работах российских и зарубежных исследователей. Данные ДЗЗ были использованы для выделения породной структуры насаждений и типов леса (Гаврилюк и др., 2018; Ершов и др., 2020; Cheng, Wang, 2019; Cheng et al., 2021), запасов фитомассы (Сочилова и др., 2018a; Das, Singh, 2016), таксационных и структурных параметров древостоев (Гаврилюк и др., 2021; Сочилова и др., 2018б).

В последнее пятилетие широкое распространение в различных видах человеческой деятельности получает использование нейросетей, которые стали применяться и для геопространственного моделирования различных характеристик растительного покрова. Обзор приводимых в литературных источниках данных показывает, что применение нейронных сетей позволяет добиться точности моделирования на уровне 80–90 % и более. Так, свёрточная нейронная сеть показала лучший результат, превзойдя методы «опорных векторов» и «случайного леса» при моделировании видового состава лесной растительности в северо-восточном Китае (точность 84 % против 72 и 79 %) (Xi et al., 2021) и видового состава посевов сельскохозяйственных культур в Китае (82 % против 74 и 73 %) (Wei et al., 2019). Применение свёрточной нейронной сети U-Net для моделирования распространения древесной растительности в Австралии позволило достичь точности 90 % (Flood et al., 2019). Моделирование ландшафтного покрова в Финляндии с применением наиболее часто используемых свёрточных нейронных сетей позволило установить, что они достигают точности моделирования от 87 до 92 % (Scepanovic et al., 2021).

Однако нельзя говорить о безусловном превосходстве данного подхода над традиционными методами геопространственного моделирования, такими как метод опорных векторов, алгоритмы случайного леса (*англ.* Random Forest) и максимального правдоподобия (*англ.* Maximum likelihood) (Барталев и др., 2011). Неопределённость в отношении качества результатов обработки данных ДЗЗ нейронными сетями часто делает сложным внедрение этого метода (Lenczner et al., 2022). Например, сравнение метода опорных векторов и полносвязной нейронной сети при моделировании охраняемых видов деревьев в Южной Африке показало преимущество первого (точность 77 % против 75 %) (Omer et al., 2015). Поэтому применение нейронных сетей для задач геопространственного моделирования требует дальнейшей апробации и совершенствования.

В настоящей статье приведены результаты применения свёрточной нейронной сети для геопространственного моделирования некоторых лесотаксационных параметров — преобладающей породы, бонитета и типа леса — для территории ХМАО — Югры. Цель представленной работы заключается в разработке модели, основанной на свёрточной нейросети, для картографирования и мониторинга таксационных характеристик лесных сообществ севера Западной Сибири. Для достижения цели было проведено обучение модели свёрточной нейронной сети на данных лесоустройства и ДЗЗ, а также картографирование лесов с выделением трёх лесотипологических показателей: преобладающей породы, типа леса и бонитета. На заключительном этапе была проведена оценка точности разработанной нейросетевой модели и определена возможность её переноса на сопредельные регионы.

## Материалы и методы

### *Лесотипологические признаки исследуемой территории*

Площадь территории ХМАО — Югры составляет примерно 534,8 тыс. км<sup>2</sup>, около 55,2 % которой покрыто северо- и среднетаёжными лесами с преобладанием светлохвойных (сосна,

очень редко лиственница), реже темнохвойных (кедр, ель) пород. Часто встречаются участки мелколиственных древостоев. Последнее обновление лесоустройства, охватывающее всю территорию округа, проводилось в период с 1995 по 2001 г., с тех пор выполняются регулярные работы по обновлению данных на отдельных участках (Платонов, 2011). Согласно данным лесоустройства, на территории ХМАО — Югры можно выделить 12 формаций по типам преобладающих пород. Из них девять лесных формаций: пять хвойных (сосновые, кедровые, еловые, пихтовые, лиственничные) и четыре лиственных (березняки, осинники, леса из тополя, ивы), а также три кустарниковых формации: ивняки, ольшаники, ерники. На территории ХМАО — Югры выделено 54 типа леса, относящиеся к девяти группам в зависимости от режима увлажнения, почв и приуроченности к крупным элементам рельефа (Луганский и др., 2010). Используемая классификация была разработана для Урала, однако она применима и для Западной Сибири, где выделяются те же типы леса. Нами в классификацию была добавлена ещё одна группа — кустарниковая, включающая в себя ерниковые и ольшаниковые леса. Таким образом, классификация включает 10 групп типов леса: нагорную, брусничную, ягодниково-зеленомошную, травяно-зеленомошную, разнотравную, липняковую, крупнотравно-приручевую, долгомошно-хвощевую, торфяно-болотно-сфагновую и кустарниковую. Также данные лесоустройства ХМАО — Югры содержат информацию о бонитете лесов. Выделяются пять классов бонитета, а V класс включает в себя подклассы Va и Vб — наименее продуктивные леса.

Для определения возможности применения модели в других регионах были получены наборы данных, соответствующие по набору предикторов и пространственному разрешению тем данным, на которых проводилось обучение модели. Были использованы материалы лесоустройства и данные ДЗЗ для территорий Ноябрьского лесничества в южной части Ямало-Ненецкого автономного округа (ЯНАО), расположенного в непосредственной близости от территории, на которой модель обучалась, и трёх лесничеств Красноярского края: Ирбейского, Курагинского и Сухобузимского, удалённых от ХМАО — Югры на 800–1000 км (рис. 1).

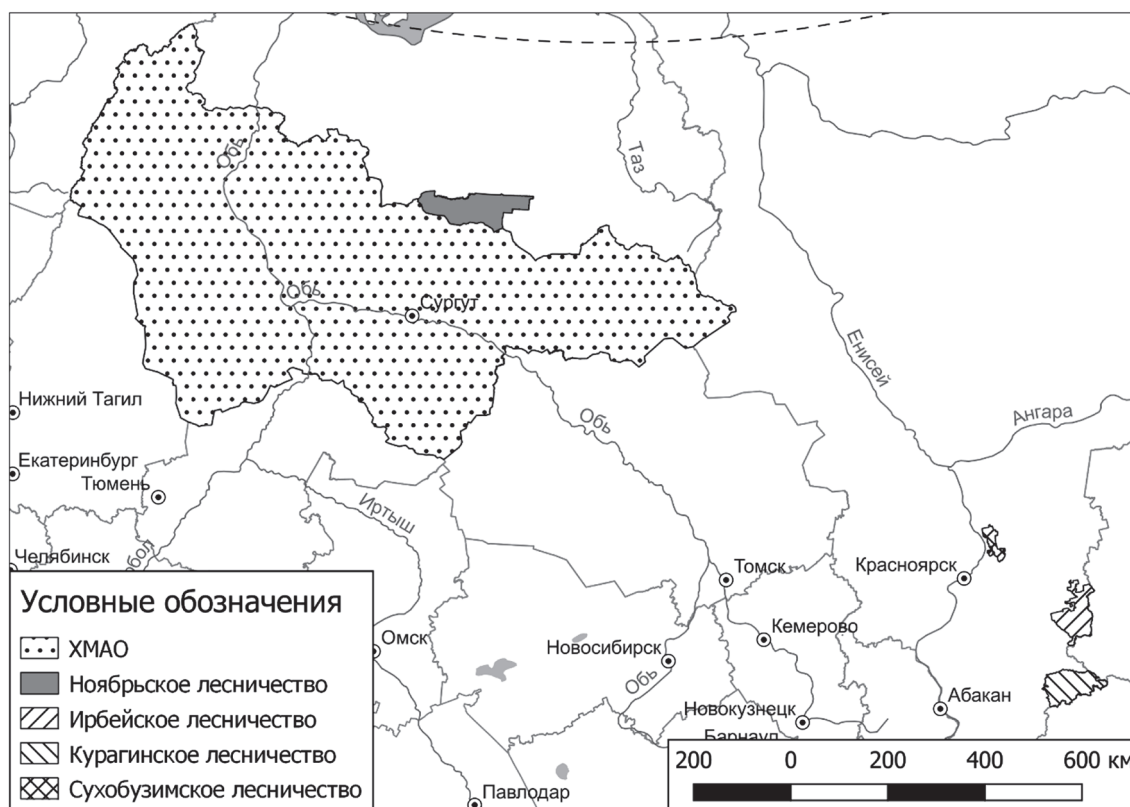


Рис. 1. Географическое положение исследуемых территорий




Рис. 2. Преобладающие древесные породы ХМАО — Югры, ЯНАО, Красноярского края

В южной части ЯНАО ландшафты и частота встречаемости разных преобладающих пород мало отличаются от ХМАО — Югры — также около 30 % территории занимают леса с доминирующей сосной, а около 10 % занимают кедровники (рис. 2). Растительность Красноярского края значительно отличается от растительности ХМАО — Югры как по преобладающим древесным породам, так и по факторам среды, влияющим на их распространение. Так, в Красноярском крае больше доля лесопокрываемых площадей, значительно выше доля березняков, еловых и пихтовых лесов, но практически отсутствуют сосновые леса (см. рис. 2). Отличаются и природные условия — гораздо ниже заболоченность и заозёрность, большую роль в формировании биоты играет рельеф.

### Данные и их предобработка

Для построения классификатора характеристик древостоя в качестве предикторов были использованы следующие источники: космоснимки Sentinel-2 (Drusch et al., 2012), цифровая модель местности (ЦММ) ASTER Global Digital Elevation Model (ASTER GDEM) (ASTER..., 2018), данные о ландшафтном покрове ESA (англ. European Space Agency — Европейское космическое агентство) WorldCover (<https://zenodo.org/record/5571936#.ZDcY0R5BxWI>) и данные об изменении лесного покрова Global Forest Change (Hansen et al., 2013).

Основным источником пространственной информации были мультиспектральные снимки Sentinel-2. В работе использованы 12 из 13 каналов: видимого, ближнего инфракрасного и коротковолнового инфракрасного диапазонов. В процессе предобработки был исключён 10-й канал из коротковолнового инфракрасного диапазона. Использовались снимки, сделанные в период вегетации (с июня по сентябрь) в 2017–2021 гг. Исходные снимки были предобработаны при помощи алгоритма коррекции, минимизирующего влияние атмосферных аэрозолей (Louis et al., 2016). Затем для приведения всех каналов снимка к единому разрешению 10 м был применён алгоритм суперразрешения, основанный на свёрточной нейронной сети и позволяющий увеличить пространственное разрешение, используя данные каналов того же снимка, имеющих более высокое разрешение (Lanaras et al., 2018). Далее на каждый снимок была наложена маска, скрывающая облака и области с техническими помехами. После наложения масок снимки объединялись в единые растровые слои, охватывающие всю исследуемую территорию, по одному файлу на каждый канал снимка, накладываясь друг на друга в порядке убывания степени покрытия облаками.

Поскольку структура растительного покрова в значительной степени зависит от рельефа, в модели были учтены данные ЦММ ASTER GDEM версии 3 (ASTER..., 2018). Пространственное разрешение данной модели — 30 м. Помимо данных ДЗЗ и ЦММ использовались данные о ландшафтном покрове ESA WorldCover (<https://zenodo.org/record/5571936#.ZDcY0R5BxWI>). Этот набор данных, составленный на основе данных Sentinel-2, имеет разрешение 10 м и охватывает весь мир, выделяя 10 классов ландшафтного покрова. Так как используемые в качестве обучающих данные лесоустройства для большинства участков были

получены более 20 лет назад, для учёта изменений использовались данные Global Forest Change Forest Loss Year (Hansen et al., 2013), отражающие территории, на которых зафиксированы потери лесного покрова с указанием года потери, и имеющие разрешение 30 м.

Обучение нейросети проведено по данным лесоустройства Ханты-Мансийского автономного округа — Югры, представленных в форме векторных слоёв, в процессе предобработки преобразованных в растровые слои с разрешением 10 м. Наборы описываемых характеристик древостоя значительно различались в зависимости от лесничества, однако данные всех лесничеств содержали информацию о преобладающей породе, бонитете и типе леса. Эти параметры позволяют в общих чертах описать лесные сообщества, поэтому они и использовались при моделировании. Моделирование каждого параметра выполнялось по отдельности, для каждого параметра была создана собственная модель.

Все категориальные данные (данные о ландшафтном покрове ESA WorldCover и данные лесоустройства) были путём унитарного кодирования (*англ.* one-hot encoding) преобразованы в наборы бинарных переменных, где каждая переменная соответствует одному классу. Все данные — как предикторы, так и обучающие данные — были переведены в одну систему координат WGS 84/UTM zone 42N (*англ.* Universal Transverse Mercator — UTM, проекция Меркатора) и приведены к единому разрешению 10 м. Итоговый размер каждого растра составил 139 330×80 807 пикселей. Так как большой размер растра затрудняет одновременное использование всех данных, растры были разбиты на квадраты — «тайлы» размером 128×128 пикселей (1,28×1,28 км), что является распространённой практикой при обработке больших объёмов данных с применением методов машинного обучения (Шолле, 2018).

Для обработки данных использовался язык программирования Python (van Rossum, 1995) и библиотеки GDAL (<https://github.com/OSGeo/gdal>), RasterIO (<https://github.com/rasterio/rasterio>), EarthPy (Wasser et al., 2019), Fiona (<https://github.com/Toblerity/Fiona>), GeoPandas (<https://zenodo.org/record/3946761#.ZDW6mh5BxWI>). Для отрисовки изображений использовалась библиотека Matplotlib (Hunter, 2007).

### Описание используемых методов моделирования

Искусственная нейронная сеть представляет собой упрощённую модель нейронной сети мозга, состоящую из простых процессоров — искусственных нейронов, объединённых в слои, которые могут быть соединены между собой в разных последовательностях и могут выполнять с данными различные операции, поэтому можно собирать нейронные сети разных конфигураций и различной глубины.

Свёрточные нейронные сети (*англ.* convolutional neural networks) (LeCun et al., 1989) отличаются возможностью их применения не только для задач классификации, но и для задач сегментации, т.е. разделения изображения на несколько сегментов, в том числе при анализе географических данных (Sundelius, 2017). Полносвязная нейронная сеть оценивает каждый пиксель вне зависимости от соседних пикселей, т.е. не учитывает пространственную структуру данных. Свёрточная нейронная сеть способна обнаруживать одинаковые паттерны в данных вне зависимости от того, в какой части растрового изображения они находятся. Данные в свёрточной нейронной сети последовательно проходят через несколько слоёв свёртки (conv2d) и слоёв пулинга (*англ.* maxpooling), что позволяет получить из исходных данных абстрактные карты признаков.

Важным этапом в процессе обучения нейросети выступает выбор оптимальной архитектуры. При построении свёрточной нейронной сети использовались две вариации архитектуры U-Net (Ronneberger et al., 2015): без пакетной нормализации (*англ.* batch normalization) (Huang et al., 2020) и с ней. Помимо сети с архитектурой U-Net, была обучена нейронная сеть с архитектурой DeepLab v3. Её основное отличие — использование вместо стандартного алгоритма свёртки усовершенствованного алгоритма расширенной свёртки (*англ.* atrous или dilated convolution) (Chen et al., 2017). Сеть с такой архитектурой уже применялась для моделирования ландшафтного покрова (Liu et al., 2021). Нейронные сети этих двух архитектур

состоят из двух частей: кодировщика и декодировщика. Кодировщик представляет собой простую свёрточную нейронную сеть, выделяющую из данных высокоуровневые признаки. Декодировщик же возвращает полученные высокоуровневые признаки к разрешению исходного изображения.

Обучение модели на основе нейронной сети выполнялось с использованием языка программирования Python (van Rossum, 1995) и библиотек TensorFlow (Abadi et al., 2016) и Keras (<https://github.com/fchollet/keras>), для обработки данных использовалась библиотека NumPy (Harris et al., 2020), для картографирования — библиотека Rasterio (<https://github.com/rasterio/rasterio>).

Метрики классификационной способности моделей рассчитывались на основе матрицы ошибок. Для оценки моделей для каждого пикселя рассчитывались следующие метрики: categorical accuracy (точность), precision (точность), recall (отклик) и Receiver Operator Characteristic Area Under Curve (ROC AUC, кривая ошибок). В качестве функции потерь (англ. loss) при обучении использовалась функция категориальной перекрёстной энтропии. Исходный набор данных из 688 248 тайлов был случайным образом разделён на тренировочный (400 000 тайлов), валидационный (100 000 тайлов) и тестовый (188 248 тайлов) наборы. Разделение данных на тренировочную, валидационную и тестовую выборки представляется распространённой практикой в машинном обучении (Шолле, 2018) и используется для предотвращения переобучения.

## Результаты и обсуждение

### Нейросетевое моделирование лесотипологических показателей

Первым этапом в процессе нейросетевого моделирования выступает подбор оптимальных гиперпараметров — определение оптимального набора слоёв, функции потерь, оптимизатора. Вначале использовалась простая версия сети U-Net без пакетной нормализации. После двух эпох (эпоха — один цикл обучения на тренировочных данных) модель достигла точности 74,9 % на тренировочных и 75,1 % на валидационных данных, но далее её точность только уменьшалась. Добавление пакетной нормализации позволило добиться точности 88,2 % на тренировочных и 88,4 % на валидационных данных (табл. 1). Модель обучалась в течение 20 эпох. Проверка модели на тестовых данных позволила убедиться, что модель способна работать в том числе и с ранее неизвестными ей данными — её точность на тестовых данных составила 88,2 %. Таким образом, эта модель уже может быть применена на практике, а использовавшийся при её обучении алгоритм и архитектура модели могут применяться для создания моделей в других регионах.

Таблица 1. Сравнение результатов обучения нейронных сетей U-Net и DeePLab для моделирования преобладающей породы

Данные	Модель	Loss	Accuracy, %	Precision	Recall	ROC AUC
Тренировочные	U-Net	0,3164	88,2	0,9331	0,8434	0,9955
	DEEPLAB	0,2995	88,7	0,9324	0,8531	0,9960
Валидационные	U-Net	0,3124	88,4	0,9395	0,8389	0,9957
	DEEPLAB	0,3074	88,5	0,9315	0,8504	0,9957
Тестовые	U-Net	0,3158	88,2	0,9393	0,8372	0,9957
	DEEPLAB	0,3108	88,4	0,9309	0,8489	0,9956

Применение архитектуры DeePLab v3 позволило немного улучшить результаты: точность достигла 88,7 % на тренировочных и 88,5 % на валидационных данных (см. табл. 1). На тестовых данных модель также показала хорошую точность — 88,4 %. Всего модель обучалась в течение 25 эпох, дальше улучшались только результаты на обучающих, но не на валидаци-

онных данных, т.е. началось переобучение. Однако основным преимуществом данной архитектуры становится не бóльшая точность, которая по сравнению с архитектурой U-Net увеличивается ненамного, а бóльшая скорость обучения. Как видно из рис. 3, модель DeepLab уже к 10-й эпохе минимизирует функцию потерь до такого уровня, которого модель U-Net достигает лишь к 15-й эпохе. В пространственном моделировании, как правило, используются большие объёмы данных, и их обработка требует значительных вычислительных ресурсов, вычисления могут занимать большие временные промежутки, поэтому оптимизация вычислений становится необходимой.




Рис. 3. Сравнение изменения функции потерь в процессе обучения сетей U-Net и DeepLab: 1 — U-Net, тренировочные данные; 2 — U-Net, валидационные данные; 3 — DeepLab, тренировочные данные; 4 — DeepLab, валидационные данные




Рис. 4. Изменение точности (ассурагу) в процессе обучения: 1 — тренировочные данные; 2 — валидационные данные

Таблица 2. Матрица ошибок моделирования преобладающей породы (млн пикселей)

		Данные лесостроительства													Всего	Precision	
		1	2	3	4	5	6	7	8	9	10	11	12	13			
Результат классификации	Безлесные территории	1	422	3	0,2	1	0,1	0,03	1	0,4	0,01	1	0,02	35	0,01	463	91
	Берёза	2	7	116	0,1	2	0,1	0,04	2	0,4	0	3	0,1	8	0	138	84
	Берёза карликовая	3	0,1	0,05	2	0,02	0	0	0,02	0,01	0	0	0,02	0	3	93	
	Ель	4	3	2	0,1	69	0,02	0,01	1	1	0	1	0,2	3	0	79	87
	Ива	5	0,02	0,02	0	0,02	1	0	0	0	0	0	0,01	0	1	95	
	Ива кустарниковая	6	0,01	0,01	0	0	0	0,3	0	0	0	0	0,01	0	0,4	92	
	Сосна кедровая	7	3	2	0,1	1	0,02	0,01	152	1	0	0,4	0,1	4	0	164	93
	Лиственница	8	0,1	0,2	0,1	0,3	0	0,01	0,2	25	0	0,02	0	1	0	27	93
	Ольха	9	0	0	0	0	0	0	0	0	0,05	0	0	0	0	0,05	95
	Осина	10	0,02	0,5	0	0,1	0	0	0,2	0	0	18	0,01	0,3	0	19	94
	Пихта	11	0,02	0,03	0	0,1	0	0	0,1	0	0	0	3	0	0	3	93
	Сосна	12	27	12	0,1	2	0,02	0,02	7	1	0	1	0,1	302	0	353	85
	Тополь	13	0	0	0	0	0	0	0	0	0	0	0	0,05	0,05	95	
	Всего		463	136	3	76	2	0,4	164	29	0,07	22	3	353	0,06	1251	93
Recall		91	85	78	91	83	76	93	88	74	79	87	86	81	85	88	

В целом улучшение большинства метрик модели происходило одинаковым образом. Например, точность значительно росла с 1-й по 5-ю эпоху, затем рост замедлялся и к 20–25-й эпохе рост точности на валидационных данных прекращался, дальше начинало происходить переобучение (рис. 4, см. с. 81).

При анализе матрицы ошибок можно увидеть, что модель качественно определяет наиболее часто встречающиеся породы: сосну, берёзу и сосну кедровую, а также безлесные территории (табл. 2). При этом наиболее частыми ошибками при классификации оказывается отнесение осины к классу берёзы и наоборот, отнесение сосны кедровой к классу сосны и наоборот, а также ошибки в определении двух основных пород — сосны и берёзы. Наихудшие результаты модель показывает при определении наиболее редко встречающихся пород — тополя, ольхи, ивы.

Далее на основе той же архитектуры DeepLab была обучена модель типов леса. Модель обучалась в течение 10 эпох и достигла точности 87,4 % на тренировочных данных и 87,7 % на валидационных. Проверка на тестовых данных показала, что модель можно применять и к ранее неизвестным ей данным — точность составила 87,5 % (табл. 3).

При моделировании типов леса модель допускает больше ошибок, чем при определении преобладающих пород, в частности модель плохо отличает брусничную группу от ягодниково-зеленомошной (табл. 4).

Таблица 3. Результаты обучения нейросети DeepLab для определения типов леса

Данные	Loss	Accuracy, %	Precision	Recall	ROC AUC
Тренировочные	0,327	87,4	0,944	0,818	0,9935
Валидационные	0,323	87,7	0,946	0,819	0,9937
Тестовые	0,326	87,5	0,945	0,818	0,9936

Таблица 4. Матрица ошибок моделирования типов леса (млн пикселей)

		Данные лесостроительства												Precision
		1	2	3	4	5	6	7	8	9	10	Всего		
Результат классификации	Безлесные территории	1	425	3	13	6	1	0,02	0,2	1	6	17	472	90
	Нагорные	2	0,3	34	0,3	0,1	0,05	0	0	0,02	0,1	0,2	35	97
	Брусничные	3	17	2	187	2	1	0,1	0,1	0,1	2	3	215	87
	Ягодниково-зеленомошные	4	1	0,4	0,3	114	0,7	0,1	0,03	0,3	1	2	120	95
	Травяно-зеленомошные	5	0,02	0	0,03	0,1	13	0,01	0	0,05	0,03	0,02	13	98
	Разнотравные	6	0	0	0	0	0	1	0	0	0	0	1	100
	Ерниковые	7	0	0	0	0	0	0	1	0	0	0	1	99
	Крупнотравно-приручьевые	8	0,4	0,1	0,2	0,2	0,2	0	0	28	1	0,2	30	93
	Долгомошно-хвощевые	9	0,1	2	0,2	1	1	0,1	0,1	2	93	5	105	88
	Торфяно-болотно-сфагновые	10	19	2	6	3	0,1	0,1	0	2	2	224	259	87
	Всего		463	44	207	127	17	1	2	34	105	251	1252	94
	Recall		92	78	90	90	74	75	75	82	88	89	82	88

Наконец, на основе архитектуры DeepLab была обучена модель, определяющая бонитет леса. Модель обучалась в течение 10 эпох и достигла точности 88,6 % как на тренировочных, так и на валидационных данных. Проверка на тестовых данных показала, что модель можно применять и к ранее неизвестным ей данным — точность составила 88,5 % (табл. 5).



Таблица 5. Результаты обучения нейросети DeepLab для определения бонитета

Данные	Loss	Accuracy, %	Precision	Recall	ROC AUC
Тренировочные	0,2648	88,6	0,9364	0,8411	0,9945
Валидационные	0,2640	88,6	0,9351	0,8436	0,9945
Тестовые	0,2658	88,5	0,9349	0,8421	0,9944

Анализ матрицы ошибок моделирования бонитета показывает, что модель достаточно точно определяет классы бонитета, в особенности наиболее распространённый V класс (табл. 6). Для некоторых классов (IV, Va, Vб) модель демонстрирует не такую высокую точность, часто относя леса этих бонитетов к смежным более высоким или низким классам бонитета.

Таблица 6. Матрица ошибок моделирования бонитета (млн пикселей)

		Данные лесоустройства										
		1	2	3	4	5	6	7	8	Всего	Precision	
Результат классификации	Безлесные территории	1	451	0	0,1	2	7	15	11	21	507	89
	I	2	0	0,1	0	0	0	0	0	0	0,1	98
	II	3	0	0	4	0,1	0,04	0,02	0	0	5	95
	III	4	0,1	0	0,2	53	2	0,2	0,2	0,03	55	96
	IV	5	1	0,01	1	3	105	6	1	0,2	115	91
	V	6	5	0	0,1	5	25	357	14	2	408	88
	Va	7	3	0	0,02	0,1	0,3	3	103	2	111	92
	Vб	8	3	0	0,1	0,1	0,4	1	1	63	69	92
	Всего		463	0,1	5	63	139	382	129	89	1270	93
	Recall		97	91	82	84	75	93	80	71	84	89

В результате применения полученной модели ко всем данным — тренировочным, валидационным и тестовым — были составлены карты преобладающих древесных пород, типов леса и бонитетов леса. Примеры полученных результатов, показанные на рис. 5–7 (см. с. 84–86), демонстрируют, что модель хорошо отделяет леса от безлесных территорий (в данном случае — болот). Модель заполнила пропуски на карте, где лесопокрываемые площади не были охвачены таксацией (на территории заповедников «Юганский» и «Малая Сосьва»). Относительно худшие результаты модель показала в горах Северного Урала, где она значительно упрощает пространственную структуру биогеоценозов, отражает её более однородной, чем она есть на самом деле, не выделяя отдельные урочища, отличающиеся по преобладающей породе, типу леса и бонитету от окружающих.

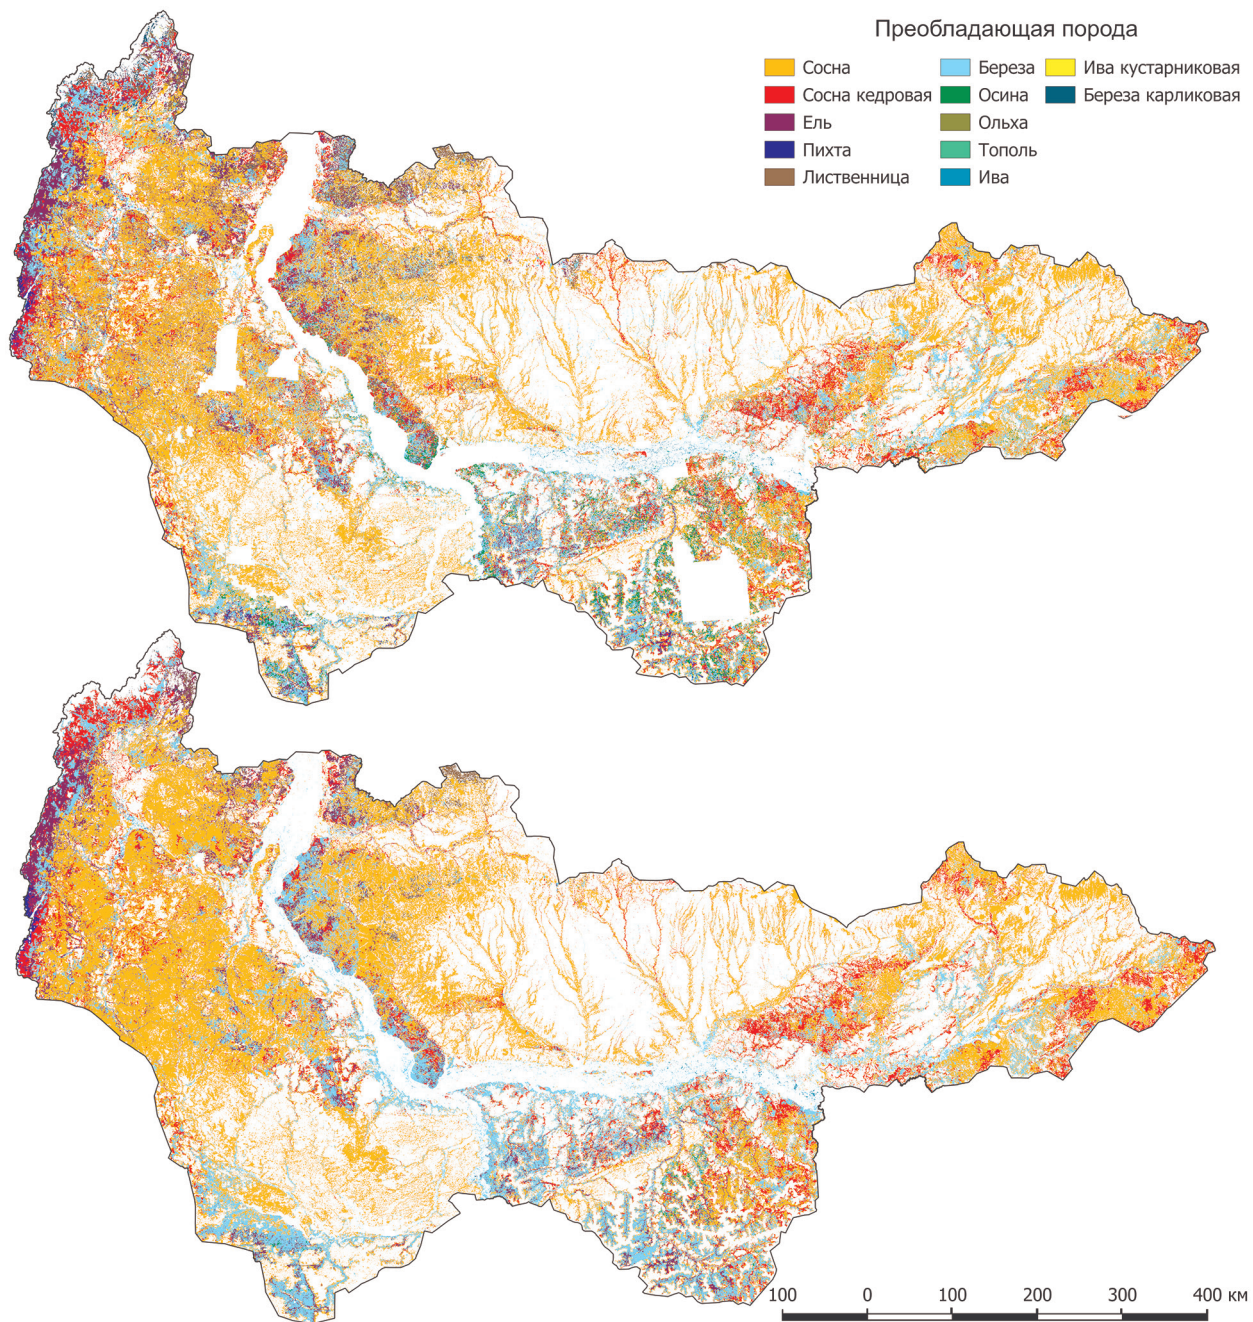


Рис. 5. Преобладающие древесные породы ХМАО — Югры по данным лесоустройства (вверху) и по результатам моделирования (внизу)

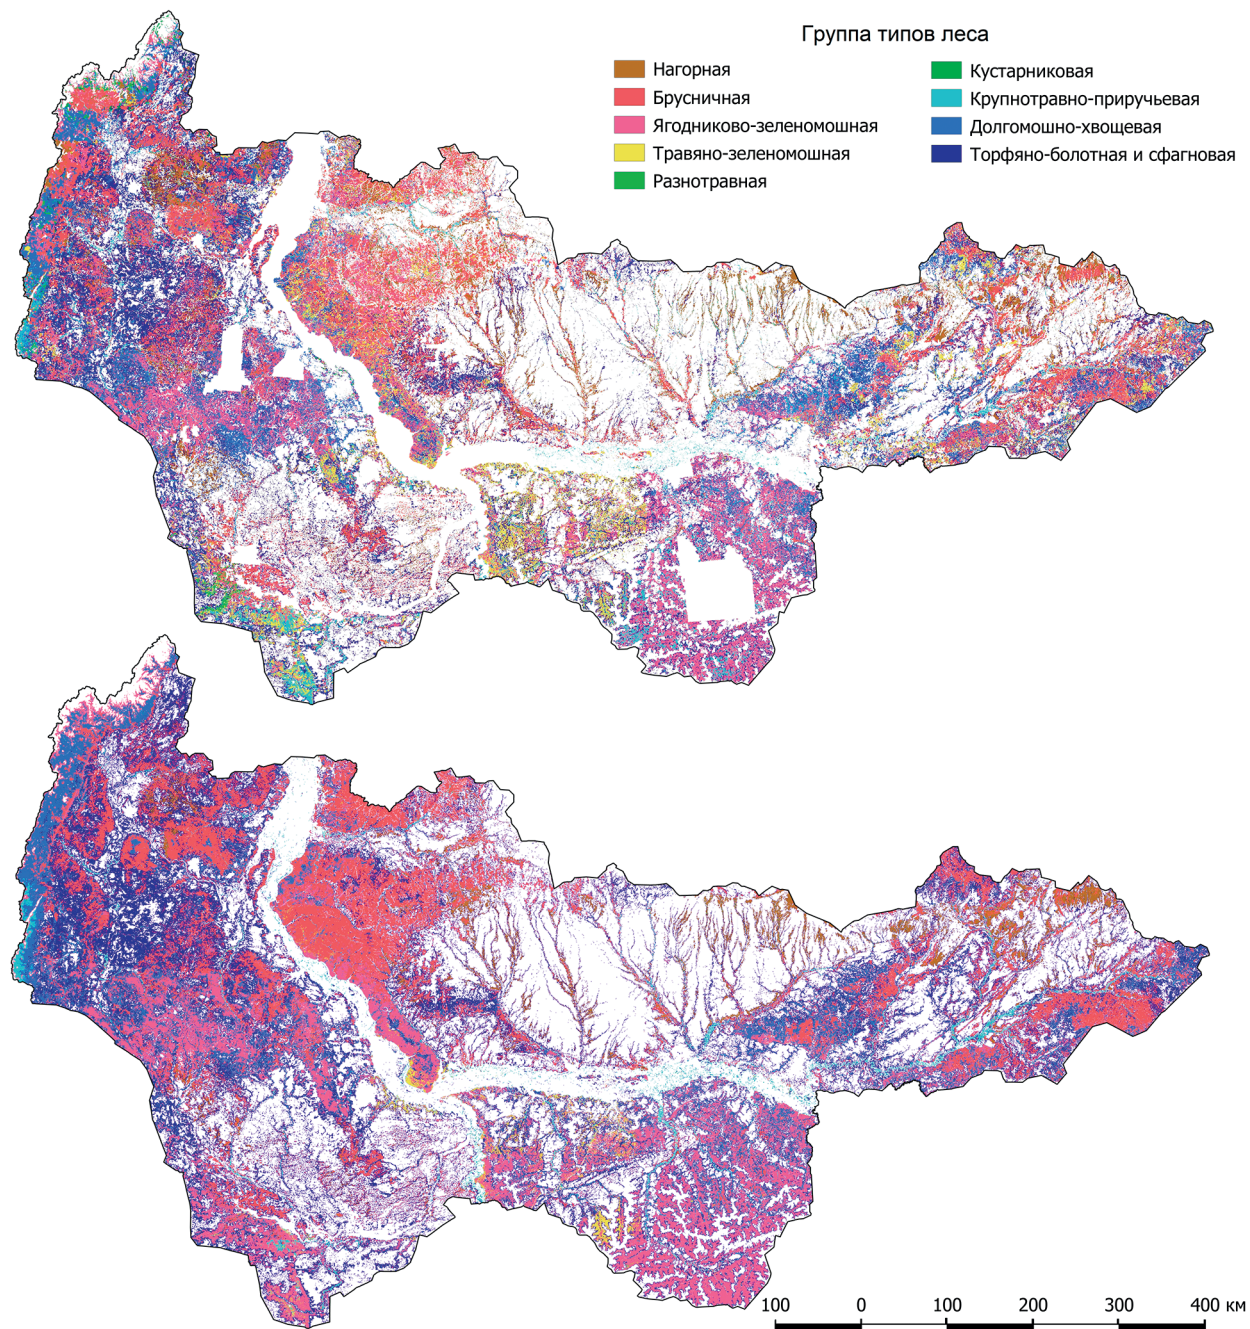


Рис. 6. Типы леса ХМАО — Югры по данным лесоустройства (вверху) и по результатам моделирования (внизу)




Рис. 7. Бонитет леса ХМАО — Югры по данным лесоустройства (вверху) и по результатам моделирования (внизу)

### **Оценка применимости моделей растительности на территориях вне исследуемого региона**

При моделировании лесотипологических показателей на основе тестовых данных все нейросетевые модели показали точность, сравнимую с точностью, достигнутой при моделировании на тренировочных данных. Это означает, что модели могут быть применены как минимум на территории всего Ханты-Мансийского автономного округа — Югры.

При пространственном моделировании преобладающих пород ЯНАО модель показала точность 85 % — лишь немного ниже, чем на территории, где модель была обучена. В Красноярском крае модель достигла меньшей точности: в разных лесничествах от 62 до 67 % (табл. 7). Вероятно, причиной становятся как существенные различия породного со-

става древостоев (см *рис. 2*), так и различия факторов среды, влияющих на морфологические особенности деревьев.

Таблица 7. Тест модели, определяющей преобладающую породу, в разных регионах

Данные	Loss	Accuracy, %	Precision	Recall	ROC AUC
ХМАО — Югра	0,3108	88,35	0,9309	0,8489	0,9956
ЯНАО, Ноябрьское лесничество	0,4931	85,57	0,8964	0,8344	0,9835
Красноярский край:					
• Ирбейское лесничество	1,2071	67,12	0,8147	0,6356	0,9528
• Курагинское лесничество	0,9501	64,15	0,9185	0,5554	0,9626
• Сухобузимское лесничество	1,7470	62,12	0,7522	0,5696	0,9155

Таким образом, применение полученной модели возможно не только на территории ХМАО — Югры, но и во всей зоне тайги Западной Сибири, однако в других регионах, к примеру в Восточной Сибири или европейской части России, её применение нецелесообразно вследствие низкой точности.

## Заключение

Моделирование таксационных характеристик лесного покрова как биотического компонента ландшафта может быть осуществлено на основе данных лесоустройства как обучающих данных, а также на основе данных ДЗЗ с высоким пространственным разрешением. Данные ДЗЗ, получаемые со спутников с мультиспектральными сенсорами, позволяют моделировать спектр характеристик, отражаемых в таблицах лесостроительных материалов: доминирующую породу, бонитет леса и тип леса по напочвенному покрову.

Применение модели, основанной на архитектуре DeepLab, позволило смоделировать характеристики древостоя на территории ХМАО — Югры (а именно определить преобладающую породу, напочвенный покров и бонитет леса) с точностью 88 % и создать актуальную цифровую карту типов леса в регионе с разрешением 10 м. Проведённые исследования показали, что свёрточные нейронные сети с кодировщиком и декодировщиком (например, U-Net и DeepLab) позволяют достигнуть точности, сопоставимой с точностью традиционно применяющихся моделей, таких как метод опорных векторов или «случайный лес», моделировать породную структуру и таксационные характеристики лесов. Они позволяют провести сегментацию изображения на классы с учётом фактора соседства, общей пространственной структуры и взаимного расположения ареалов разных классов.

Перспективы оптимизации моделирования связаны с привлечением дополнительных факторов как на входе модели (например, данных по разным сезонам года), так и в процессе обучения (моделирование большего спектра таксационных характеристик леса), что позволило бы добавить в модель дополнительные показатели и расширить возможность её применения и на соседние регионы.

## Литература

1. Барталев С. А., Егоров В. А., Ершов Д. В., Исаев А. С., Лупян Е. А., Плотников Д. Е., Уваров И. А. Спутниковое картографирование растительного покрова России по данным спектрорадиометра MODIS // Современные проблемы дистанционного зондирования Земли из космоса. 2011. Т. 8. № 4. С. 285–302.
2. Бондур В. Г., Воронова О. С., Черепанова Е. В., Цидилина М. Н., Зима А. Л. Пространственно-временной анализ многолетних природных пожаров и эмиссий вредных газов и аэрозолей в России по космическим данным // Исслед. Земли из космоса. 2020. № 4. С. 3–17. DOI: 10.31857/s0205961420040028.

3. *Гаврилюк Е. А., Горнов А. В., Ершов Д. В.* Оценка пространственного распределения видов деревьев заповедника «Брянский лес» и его охранной зоны на основе разносезонных спутниковых данных Landsat // Бюл. Брянского отделения Русского ботан. об-ва. 2018. № 3(15). С. 13–23. DOI: 10.22281/2307-4353-2018-3-13-23.
4. *Гаврилюк Е. А., Королева Н. В., Карпухина Д. А., Соколова Е. Н., Ершов Д. В.* Геопространственное моделирование биометрических и структурных характеристик лесов Брянской области на основе спутниковых и выборочных лесотаксационных данных // Лесоведение. 2021. № 6. С. 609–626. DOI: 10.31857/S002411482106005X.
5. *Ершов Д. В., Гаврилюк Е. А., Белова Е. И., Никитина А. Д.* Определение породной структуры лесного участка по ортофотопланам беспилотной аэрофотосъёмки // Актуальные проблемы современно-лесоводства: Вторые международ. чтения памяти Г. Ф. Морозова. К столетию памяти классика русского лесоводства (1920–2020 гг.). Симферополь, 2020. С. 141–152.
6. *Зуев В. В., Короткова Е. М., Павлинский А. В.* Климатически обусловленные изменения растительного покрова тайги и тундры Западной Сибири в 1982–2015 гг. по данным спутниковых наблюдений // Исслед. Земли из космоса. 2019. № 6. С. 66–76. DOI: 10.31857/S0205-96142019666-76.
7. *Корниенко С. Г.* Характеристика антропогенных трансформаций ландшафтов в районе Бованенковского месторождения по данным спутников Landsat // Современные проблемы дистанционного зондирования Земли из космоса. 2022. Т. 19. № 2. С. 106–129. DOI: 10.21046/2070-7401-2022-19-2-106-129.
8. *Луганский Н. А., Залесов С. В., Луганский В. Н.* Лесоведение: учеб. пособие. Екатеринбург: Уральский гос. лесотехн. ун-т, 2010. 432 с.
9. Особо охраняемые природные территории и леса Ханты-Мансийского автономного округа: атлас / ред. С. А. Алешин, Э. А. Ахпателов, В. А. Волков. Ханты-Мансийск; Екатеринбург: ИздатНаукаСервис, 2006. 120 с.
10. *Платонов Е. П.* Практика использования земель лесного фонда для недропользования в Ханты-Мансийском автономном округе — Югре // Недропользование XXI век. 2011. № 2. С. 60–63.
11. *Савельев А. А.* Биохорологическое разнообразие и моделирование пространственной структуры растительного покрова: Геоинформационный подход: автореф. дис. ... д-ра биол. наук. Казань, 2004. 24 с.
12. *Соколова Е. Н., Сурков Н. В., Ершов Д. В., Хамедов В. А.* (2018а) Оценка запасов фитомассы лесных пород по спутниковым изображениям высокого пространственного разрешения (на примере лесов Ханты-Мансийского АО) // Вопросы лесной науки. 2018. Т. 1. № 1. С. 1–23. DOI: 10.31509/2658-607X-2018-1-1-1-23.
13. *Соколова Е. Н., Сурков Н. В., Ершов Д. В., Егоров В. А., Барталев С. С., Барталев С. А.* (2018б) Картографирование классов бонитета лесов Приморского края на основе спутниковых изображений и данных о характеристиках рельефа // Современные проблемы дистанционного зондирования Земли из космоса. 2018. Т. 15. № 5. С. 96–109. DOI: 10.21046/2070-7401-2018-15-5-96-109.
14. *Филипчук А. Н., Малышева Н. В., Золина Т. А., Югов А. Н.* Бореальные леса России: возможности для смягчения изменения климата // Лесохозяйственная информация. 2020. № 1. С. 92–114. DOI: 10.24419/LNI.2304-3083.2020.1.10.
15. *Хамедов В. А., Копылов В. Н., Полищук Ю. М., Сугаипова А. Н., Шимов С. В.* Создание карты лесов Ханты-Мансийского округа на основе космических снимков среднего разрешения // Современные проблемы дистанционного зондирования Земли из космоса. 2009. Т. 6. № 2. С. 474–478.
16. *Шолле Ф.* Глубокое обучение на Python: пер. с англ. СПб.: Питер, 2018. 400 с.
17. *Abadi M., Agarwal A., Barham P., Brevdo E., Chen Z., Citro C., Corrado G. S., Davis A., Dean J., Devin M., Ghemawat S., Goodfellow I., Harp A., Irving G., Isard M., Jia Y., Jozefowicz R., Kaiser L., Kudlur M., Levenberg J., Mane D., Monga R., Moore S., Murray D., Olah C., Schuster M., Shlens J., Steiner D., Sutskever I., Talwar K., Tucker P., Vanhoucke V., Vasudevan V., Viegas F., Vinyals O., Warden P., Wattenberg M., Wicke M., Yu Y., Zheng X.* Tensorflow: Large-scale machine learning on heterogeneous distributed systems // arXiv preprint. arXiv:1603.04467. 2016. DOI: 10.48550/arXiv.1603.04467.
18. ASTER Global Digital Elevation Model V003 / NASA EOSDIS Land Processes DAAC. NASA/METI/AIST/Japan Spacesystems. U.S./Japan ASTER Science Team. 2018. <https://doi.org/10.5067/ASTER/ASTGTM.003>.
19. *Chen L. C., Papandreou G., Schroff F., Adam H.* Rethinking Atrous Convolution for Semantic Image Segmentation // arXiv preprint. arXiv:1706.05587. 2017. DOI: 10.48550/arXiv.1706.05587.
20. *Cheng K., Wang J.* Forest Type Classification Based on Integrated Spectral-Spatial-Temporal Features and Random Forest Algorithm — A Case Study in the Qinling Mountains // Forests. 2019. V. 10. No. 7. Art. No. 559. DOI: 10.3390/f10070559.
21. *Cheng K., Wang J., Yan X.* Mapping Forest Types in China with 10 m Resolution Based on Spectral – Spatial – Temporal Features // Remote Sensing. 2021. V. 13. No. 5. Art. No. 973. DOI: 10.3390/rs13050973.

22. *Das S., Singh T.P.* Forest Type, Diversity and Biomass Estimation in Tropical Forests of Western Ghat of Maharashtra Using Geospatial Techniques // *Small-scale Forestry*. 2016. No. 15. P. 517–532. DOI: 10.1007/s11842-016-9337-y.
23. *Drusch M., Del Bello U., Carlier S., Colin O., Fernandez V., Gascon F., Hoersch B., Isola C., Laberinti P., Martimort P., Meygret A., Spoto F., Sy O., Marchese F., Bargellini P.* Sentinel-2: ESA's optical high-resolution mission for GMES operational services // *Remote Sensing of Environment*. 2012. V. 120. P. 25–36. DOI: 10.1016/j.rse.2011.11.026.
24. *Flood N., Watson F., Collett L.* Using a U-net convolutional neural network to map woody vegetation extent from high resolution satellite imagery across Queensland, Australia // *Intern. J. Applied Earth Observation and Geoinformation*. 2019. V. 82. Art. No. 101897. DOI: 10.1016/j.jag.2019.101897.
25. *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. Iss. 6160. P. 850–853. DOI: 10.1126/science.12446.
26. *Harris C. R., Millman K. J., van der Walt S. J., Gommers R., Virtanen P., Cournapeau D., Wieser E., Taylor J., Berg S., Smith N. J., Kern R., Picus M., Hoyer S., van Kerkwijk M. H., Brett M., Haldane A., del Rio J. F., Wiebe M., Peterson P., Gerard-Marchant P., Sheppard K., Reddy T., Weckesser W., Abbasi H., Gohlke C., Oliphant T. E.* Array programming with NumPy // *Nature*. 2020. V. 585. No. 7825. P. 357–362. DOI: 10.1038/s41586-020-2649-2.
27. *Huang H., Lin L., Tong R., Hu H., Zhang Q., Iwamoto Y., Han X., Chen Y., Wu J.* UNet 3+: A Full-Scale Connected UNet for Medical Image Segmentation // *IEEE Intern. Conf. Acoustics, Speech and Signal Processing (ICASSP)*. 2020. P. 1055–1059. DOI: 10.1109/icassp40776.2020.9053405.
28. *Hunter J. D.* Matplotlib: A 2D graphics environment // *Computing in Science and Engineering*. 2007. V. 9. No. 3. P. 90–95. DOI: 10.1109/MCSE.2007.55.
29. *Kirpotin S. N., Callaghan T. V., Peregon A. M., Babenko A. S., Berman D. I., Bulakhova N. A., Byzaakay A. A., Chernykh T. M., Chursin V., Interesova E. A., Gureev S. P., Kerchev I. A., Kharuk V. I., Khovalyg A. O., Kolpashchikov L. A., Krivets S. A., Kvasnikova Z. N., Kuzhevskaya I. V., Merzlyakov O. E., Nekhoroshev O. G., Popkov V. K., Pyak A. I., Valevich T. O., Volkov I. V., Volkova I. I.* Impacts of environmental change on biodiversity and vegetation dynamics in Siberia // *Ambio*. 2021. V. 50. P. 1926–1952. DOI: 10.1007/s13280-021-01570-6.
30. *Lanaras C., Bioucas-Dias J., Galliani S., Baltsavias E., Schindler K.* Super-resolution of Sentinel-2 images: Learning a globally applicable deep neural network // *ISPRS J. Photogrammetry and Remote Sensing*. 2018. V. 146. P. 305–319. DOI: 10.1016/j.isprsjprs.2018.09.018.
31. *LeCun Y., Bose B., Denker J. S., Henderson D., Howard R. E., Hubbard W., Jackel L. D.* Backpropagation Applied to Handwritten Zip Code Recognition // *Neural Computation*. 1989. No. 1. P. 541–551. DOI: 10.1162/neco.1989.1.4.541.
32. *Lenczner G., Chan-Hon-Tong A., Le Saux B., Luminari N., Le Besnerais G.* DIAL: Deep Interactive and Active Learning for Semantic Segmentation in Remote Sensing // *IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing*. 2022. No. 15. P. 3376–3389. DOI: 10.1109/jstars.2022.3166551.
33. *Liu M., Fu B., Xie S., He H., Lan F., Li Y., Lou P., Fan D.* Comparison of multi-source satellite images for classifying marsh vegetation using DeepLabV3 Plus deep learning algorithm // *Ecological Indicators*. 2021. V. 125. Art. No. 107562. DOI: 10.1016/j.ecolind.2021.107562.
34. *Louis J., Debaecker V., Pflug B., Main-Khorm M., Bieniarz J., Mueller-Wilm U., Cadau E., Gascon F.* Sentinel-2 Sen2Cor: L2A processor for users // *Proc. Living Planet Symp*. 2016. V. SP-740. P. 1–8.
35. *Miles V. V., Esau I.* Spatial heterogeneity of greening and browning between and within bioclimatic zones in northern West Siberia // *Environmental Research Letters*. 2016. No. 11. Art. No. 115002. DOI: 10.1088/1748-9326/11/11/115002.
36. *Omer G., Mutanga O., Abdel-Rahman E. M., Adam E.* Performance of support vector machines and artificial neural network for mapping endangered tree species using WorldView-2 data in Dukuduku forest, South Africa // *IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing*. 2015. V. 8. No. 10. P. 4825–4840. DOI: 10.1109/JSTARS.2015.2461136.
37. *Ronneberger O., Fischer P., Brox T.* U-net: Convolutional networks for biomedical image segmentation // *Intern. Conf. Medical image computing and computer-assisted intervention*. 2015. P. 234–241. DOI: 10.1007/978-3-319-24574-4\_28.
38. *Scepanovic S., Antropov O., Laurila P., Rauste Y., Ignatenko V., Praks J.* Wide-area land cover mapping with Sentinel-1 imagery using deep learning semantic segmentation models // *IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing*. 2021. V. 14. P. 10357–10374. DOI: 10.1109/JSTARS.2021.3116094.
39. *Sundelius C.* Deep Fusion of Imaging Modalities for Semantic Segmentation of Satellite Imagery: Master Thesis in Electrical Engineering. Linköping, 2017. 88 p.
40. *van Rossum G.* Python reference manual. Amsterdam, Netherlands: Centre for Mathematics and Computer Science, 1995. No. R 9525.

41. Wasser L., Joseph M. B., McGlinchy J., Palomino J., Korinek N., Holdgraf C., Head T. EarthPy: A Python package that makes it easier to explore and plot raster and vector data using open source Python tools // J. Open Source Software. 2019. V. 4. No. 43. Art. No. 1886. DOI: 10.21105/joss.01886.
42. Wei S., Zhang H., Wang C., Wang Y., Xu L. Multi-temporal SAR data large-scale crop mapping based on U-Net model // Remote Sensing. 2019. V. 11. No. 1. Art. No. 68. DOI: 10.3390/rs11010068.
43. Xi Y., Ren C., Tian Q., Ren Y., Dong X., Zhang Z. Exploitation of Time Series Sentinel-2 Data and Different Machine Learning Algorithms for Detailed Tree Species Classification // IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing. 2021. V. 14. P. 7589–7603. DOI: 10.1109/JSTARS.2021.3098817.

## Use of convolutional neural networks for geospatial modelling of species structure and taxation characteristics of forests (case study of Khanty-Mansi Autonomous Okrug – Yugra)

M. D. Moskovchenko

Tyumen State University, Tyumen 625003, Russia  
E-mail: moskovchenkomd@yandex.ru

Until recently, forest inventory data was the only reliable data source in forestry. Nowadays, correction of forest inventory data became possible, including correction at the local per-community level, using remote sensing data and geospatial modeling methods. This study assessed the possibility of using convolutional neural networks for geospatial modelling of the species structure and taxation characteristics of forests on the example of the territory of Khanty-Mansi Autonomous Okrug – Yugra. Forest inventory data of the Khanty-Mansi Autonomous Okrug – Yugra was used as a target variable, remote sensing data (Sentinel-2 satellite imagery), digital elevation model ASTER GDEM, ESA WorldCover landcover data and Global Forest Change dataset were used as independent variables. The model of the vegetation of the Khanty-Mansi Autonomous Okrug (of its dominant species, ground cover and forest site index classes) based on DeepLab architecture achieved an accuracy of 88 % on both train, validation and test datasets and made it possible to create an up-to-date digital map of vegetation in the region with a resolution of 10 m. Using the pre-trained models for modelling forest characteristics in the territories of adjacent regions — Yamalo-Nenets Autonomous Okrug (modeling accuracy was 85 %) and the Krasnoyarsk Krai (modeling accuracy was from 62 to 67 %) — showed that they can be used in adjacent territories of the other regions of Western Siberia but are not applicable for modeling forest characteristics in Eastern Siberia.

**Keywords:** neural networks, modelling, U-Net, DEEPLAB, forest management, forest mapping, Western Siberia

Accepted: 30.03.2023

DOI: 10.21046/2070-7401-2023-20-2-75-93

### References

1. Bartalev S.A., Egorov V.A., Ershov D.V., Isaev A.S., Loupian E.A., Plotnikov D.E., Uvarov I.A., Mapping of Russia's vegetation cover using MODIS satellite spectroradiometer data, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2011, Vol. 8, No. 4, pp. 285–302 (in Russian).
2. Bondur V.G., Voronova O.S., Cherepanova E.V., Tsidilina M.N., Zima A.L., The spatiotemporal analysis of multiannual wildfires and trace gas and aerosol emissions in Russia based of satellite data, *Issledovanie Zemli iz kosmosa*, 2020, No. 4, pp. 3–17 (in Russian), DOI: 10.31857/s0205961420040028.
3. Gavriluyuk E.A., Gornov A.V., Ershov D.V., Estimation of spatial trees species distribution in Bryansk Forest Nature Reserve based on multitemporal Landsat data, *Bull. Bryansk dpt. of RBS*, 2018, No. 3(15), pp. 13–23 (in Russian), DOI: 10.22281/2307-4353-2018-3-13-23.



4. Gavrilyuk E. A., Koroleva N. V., Karpukhina D. A., Sochilova E. N., Ershov D. V., Geospatial modeling of biometric and structural forest attributes in the Bryansk oblast based on satellite imagery and selective inventory data, *Lesovedenie*, 2021, No. 6, pp. 609–626 (in Russian), DOI: 10.31857/S002411482106005X.
5. Ershov D. V., Gavrilyuk E. A., Belova E. I., Nikitina A. D., Determination of the species structure of a forest area using orthophotoimages from unmanned aerial vehicles, *Aktual'nye problemy sovremennogo lesovodstva: Vtorye mezhdunarodnye chteniya pamyati G. F. Morozova. K stoletiyu pamyati klassika russkogo lesovodstva (1920–2020 gg.)* (Actual problems of modern forestry: Second international readings in memory of G. F. Morozov. On the centenary of the memory of the classic of Russian forestry (1920–2020)), Simferopol, 2020, pp. 141–152 (in Russian).
6. Zuev V. V., Korotkova E. M., Pavlinsky A. V., Climate-related changes in the vegetation cover of the taiga and tundra of Western Siberia in 1982–2015 according to satellite observations, *Issledovanie Zemli iz kosmosa*, 2019, No. 6, pp. 66–76 (in Russian), DOI: 10.31857/S0205-96142019666-76.
7. Kornienko S. G., Characteristics of anthropogenic transformations of landscapes in the area of Bovanenkovo gas field based on Landsat satellite data, *Sovremennyye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2022, Vol. 19, No. 2, pp. 106–129 (in Russian), DOI: 10.21046/2070-7401-2022-19-2-106-129.
8. Luganskii N. A., Zalesov S. V., Luganskii V. N., *Lesovedenie* (Forest science), Ekaterinburg: Uralskii gosudarstvennyi lesotekhnicheskii universitet, 2010, 432 p. (in Russian).
9. *Osobo okhranyaemye prirodnye territorii i lesa Khanty-Mansiiskogo avtonomnogo okruga: atlas* (Protected areas and forests of Khanty-Mansi Autonomous Okrug, Atlas), Khanty-Mansiisk; Ekaterinburg: IzdatNaukaServis, 2006, 120 p. (in Russian).
10. Platonov E. P., Practice of use of the earths of wood fund for the subsoil industry in the Khanty-Mansiysk autonomous okrug — Yugra, *Nedropol'zovanie XXI vek*, 2011, No. 2, pp. 60–63 (in Russian).
11. Savel'ev A. A., *Biokhologicheskoe raznoobrazie i modelirovanie prostranstvennoi struktury rastitel'nogo pokrova: Geoinformatsionnyi podkhod: Avtoref. diss. dokt. biol. nauk* (Biochorological diversity and modeling of the spatial structure of vegetation cover: Geoinformatic approach, Ext. abstract Dr. biol. sci. thesis), Kazan, 2004, 24 p. (in Russian).
12. Sochilova E. N., Surkov N. V., Ershov D. V., Khamedov V. A. (2018a), Assessment of biomass of forest species using satellite images of high spatial resolution (on the example of the forest of Khanty-Mansi autonomous okrug), *Forest science issues*, 2018, Vol. 2, No. 52, pp. 1–19, DOI: 10.31509/2658-607x-2019-2-2-1-20.
13. Sochilova E. N., Surkov N. V., Ershov D. V., Egorov V. A., Bartalev S. S., Bartalev S. A. (2018b), Mapping of forest site index classes in Primorskiy Krai based on satellite images and terrain characteristics, *Sovremennyye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2018, Vol. 15, No. 5, pp. 96–109 (in Russian), DOI: 10.21046/2070-7401-2018-15-5-96-109.
14. Filipchuk A. N., Malysheva N. V., Zolina T. A., Yugov A. N., The boreal forest of Russia: Opportunities for the effects of climate change mitigation, *Lesokhozyaistvennaya informatsiya*, 2020, No. 1, pp. 92–114 (in Russian), DOI 10.24419/LHI.2304-3083.2020.1.10.
15. Khamedov V. A., Kopylov V. N., Polishchuk Yu. M., Sugaipova A. N., Shimov S. V., Forestry mapping of Khanty-Mansi autonomous okrug on base of middle resolution space images, *Sovremennyye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2009, Vol. 6, No. 2, pp. 474–478 (in Russian).
16. Chollet F., *Deep learning with Python*, Shelter Island, New York: Manning, 2018, 386 p.
17. Abadi M., Agarwal A., Barham P., Brevdo E., Chen Z., Citro C., Corrado G. S., Davis A., Dean J., Devin M., Ghemawat S., Goodfellow I., Harp A., Irving G., Isard M., Jia Y., Jozefowicz R., Kaiser L., Kudlur M., Levenberg J., Mane D., Monga R., Moore S., Murray D., Olah C., Schuster M., Shlens J., Steiner D., Sutskever I., Talwar K., Tucker P., Vanhoucke V., Vasudevan V., Viegas F., Vinyals O., Warden P., Wattenberg M., Wicke M., Yu Y., Zheng X., Tensorflow: Large-scale machine learning on heterogeneous distributed systems, *arXiv preprint, arXiv:1603.04467*, 2016, DOI: 10.48550/arXiv.1603.04467.
18. *ASTER Global Digital Elevation Model V003*, NASA EOSDIS Land Processes DAAC, NASA/METI/AIST/Japan Spacesystems, U.S./Japan ASTER Science Team, 2018, <https://doi.org/10.5067/ASTER/ASTGTM.003>.
19. Chen L. C., Papandreou G., Schroff F., Adam H., Rethinking Atrous Convolution for Semantic Image Segmentation, *arXiv preprint, arXiv:1706.05587*, 2017, DOI: 10.48550/arXiv.1706.05587.
20. Cheng K., Wang J., Forest Type Classification Based on Integrated Spectral-Spatial-Temporal Features and Random Forest Algorithm — A Case Study in the Qinling Mountains, *Forests*, 2019, Vol. 10, No. 7, Art. No. 559, DOI: 10.3390/f10070559.
21. Cheng K., Wang J., Yan X., Mapping Forest Types in China with 10 m Resolution Based on Spectral–Spatial–Temporal Features, *Remote Sensing*, 2021, Vol. 13, No 5, Art. No. 973, DOI: 10.3390/rs13050973.
22. Das S., Singh T. P., Forest Type, Diversity and Biomass Estimation in Tropical Forests of Western Ghat of Maharashtra Using Geospatial Techniques, *Small-scale Forestry*, 2016, Vol. 15, pp. 517–532, DOI: 10.1007/s11842-016-9337-y.

23. Drusch M., Del Bello U., Carlier S., Colin O., Fernandez V., Gascon F., Hoersch B., Isola C., Laberinti P., Martimort P., Meygret A., Spoto F., Sy O., Marchese F., Bargellini P., Sentinel-2: ESA's optical high-resolution mission for GMES operational services, *Remote Sensing of Environment*, 2012, Vol. 120, pp. 25–36, DOI: 10.1016/j.rse.2011.11.026.
24. Flood N., Watson F., Collett L., Using a U-net convolutional neural network to map woody vegetation extent from high resolution satellite imagery across Queensland, Australia, *Intern. J. Applied Earth Observation and Geoinformation*, 2019, Vol. 82, Art. No. 101897, DOI: 10.1016/j.jag.2019.101897.
25. 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, Issue 6160, pp. 850–853, DOI: 10.1126/science.12446.
26. Harris C. R., Millman K. J., van der Walt S. J., Gommers R., Virtanen P., Cournapeau D., Wieser E., Taylor J., Berg S., Smith N. J., Kern R., Picus M., Hoyer S., van Kerkwijk M. H., Brett M., Haldane A., del Rio J. F., Wiebe M., Peterson P., Gerard-Marchant P., Sheppard K., Reddy T., Weckesser W., Abbasi H., Gohlke C., Oliphant T. E., Array programming with NumPy, *Nature*, 2020, Vol. 585, No. 7825, pp. 357–362, DOI: 10.1038/s41586-020-2649-2.
27. Huang H., Lin L., Tong R., Hu H., Zhang Q., Iwamoto Y., Han X., Chen Y., Wu J., UNet 3+: A Full-Scale Connected UNet for Medical Image Segmentation, *IEEE Intern. Conf. Acoustics, Speech and Signal Processing (ICASSP)*, 2020, pp. 1055–1059, DOI: 10.1109/icassp40776.2020.9053405.
28. Hunter J. D., Matplotlib: A 2D graphics environment, *Computing in Science and Engineering*, 2007, Vol. 9, No. 3, pp. 90–95, DOI: 10.1109/MCSE.2007.55.
29. Kirpotin S. N., Callaghan T. V., Peregon A. M., Babenko A. S., Berman D. I., Bulakhova N. A., Byzaakay A. A., Chernykh T. M., Chursin V., Interesova E. A., Gureev S. P., Kerchev I. A., Kharuk V. I., Khovalyg A. O., Kolpashchikov L. A., Krivets S. A., Kvasnikova Z. N., Kuzhevskaja I. V., Merzlyakov O. E., Nekhoroshev O. G., Popkov V. K., Pyak A. I., Valevich T. O., Volkov I. V., Volkova I. I., Impacts of environmental change on biodiversity and vegetation dynamics in Siberia, *Ambio*, 2021, Vol. 50, pp. 1926–1952, DOI: 10.1007/s13280-021-01570-6.
30. Lanaras C., Bioucas-Dias J., Galliani S., Baltasvias E., Schindler K., Super-resolution of Sentinel-2 images: Learning a globally applicable deep neural network, *ISPRS J. Photogrammetry and Remote Sensing*, 2018, Vol. 146, pp. 305–319, DOI: 10.1016/j.isprsjprs.2018.09.018.
31. LeCun Y., Bose B., Denker J. S., Henderson D., Howard R. E., Hubbard W., Jackel L. D., Backpropagation Applied to Handwritten Zip Code Recognition, *Neural Computation*, 1989, No. 1, pp. 541–551, DOI: 10.1162/neco.1989.1.4.541.
32. Lenczner G., Chan-Hon-Tong A., Le Saux B., Luminari N., Le Besnerais G., DIAL: Deep Interactive and Active Learning for Semantic Segmentation in Remote Sensing, *IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, No. 15, pp. 3376–3389, DOI: 10.1109/jstars.2022.3166551.
33. Liu M., Fu B., Xie S., He H., Lan F., Li Y., Lou P., Fan D., Comparison of multi-source satellite images for classifying marsh vegetation using DeepLabV3 Plus deep learning algorithm, *Ecological Indicators*, 2021, Vol. 125, Art. No. 107562, DOI: 10.1016/j.ecolind.2021.107562.
34. Louis J., Debaecker V., Pflug B., Main-Khorn M., Bieniarz J., Mueller-Wilm U., Cadau E., Gascon F., Sentinel-2 Sen2Cor: L2A processor for users, *Proc. Living Planet Symp.*, 2016, Vol. SP-740, pp. 1–8.
35. Miles V. V., Esau I., Spatial heterogeneity of greening and browning between and within bioclimatic zones in northern West Siberia, *Environmental Research Letters*, 2016, Vol. 11, No. 11, Art. No. 115002, DOI: 10.1088/1748-9326/11/11/115002.
36. Omer G., Mutanga O., Abdel-Rahman E. M., Adam E., Performance of support vector machines and artificial neural network for mapping endangered tree species using WorldView-2 data in Dukuduku forest, South Africa, *IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, Vol. 8, No. 10, pp. 4825–4840, DOI: 10.1109/JSTARS.2015.2461136.
37. Ronneberger O., Fischer P., Brox T., U-net: Convolutional networks for biomedical image segmentation, *Intern. Conf. Medical Image Computing and Computer-Assisted Intervention*, Cham: Springer, 2015, pp. 234–241, DOI: 10.1007/978-3-319-24574-4\_28.
38. Scepanovic S., Antropov O., Laurila P., Rauste Y., Ignatenko V., Praks J., Wide-area land cover mapping with Sentinel-1 imagery using deep learning semantic segmentation models, *IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, Vol. 14, pp. 10357–10374, DOI: 10.1109/JSTARS.2021.3116094.
39. Sundelius C., *Deep Fusion of Imaging Modalities for Semantic Segmentation of Satellite Imagery: Master of Science Thesis in Electrical Engineering*, Linköping, 2017, 88 p.
40. van Rossum G., *Python reference manual*, Amsterdam, Netherlands: Centre for Mathematics and Computer Science, 1995, No. R 9525.
41. Wasser L., Joseph M. B., McGlinchy J., Palomino J., Korinek N., Holdgraf C., Head T., EarthPy: A Python package that makes it easier to explore and plot raster and vector data using open source Python tools, *J. Open Source Software*, 2019, Vol. 4, No. 43, Art. No. 1886, DOI: 10.21105/joss.01886.

42. Wei S., Zhang H., Wang C., Wang Y., Xu L., Multi-temporal SAR data large-scale crop mapping based on U-Net model, *Remote Sensing*, 2019, Vol. 11, No. 1, Art. No. 68, DOI: 10.3390/rs11010068.
43. Xi Y., Ren C., Tian Q., Ren Y., Dong X., Zhang Z., Exploitation of Time Series Sentinel-2 Data and Different Machine Learning Algorithms for Detailed Tree Species Classification, *IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, Vol. 14, pp. 7589–7603, DOI: 10.1109/JSTARS.2021.3098817.