

**Д.Ю. Капиталинин, П.А. Тищенко, В.М. Сидоренков,
Ю.С. Ачиколова, Д.О. Астапов, О.В. Рябцев, Р.В. Щекалев**

ИСПОЛЬЗОВАНИЕ НЕЙРОСЕТЕЙ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ АВТОМАТИЧЕСКОЙ ВАЛИДАЦИИ МАТЕРИАЛОВ ЛЕСОУСТРОЙСТВА ПО ДАННЫМ СПУТНИКОВОЙ СЪЁМКИ

Введение. Развитие современных технологий в области искусственно-го интеллекта приводит к глобальному изменению систем управления в различных сферах народного хозяйства. Одним из перспективных направлений в области лесной таксации является совершенствование технологий получения информации о лесах с использованием данных спутниковой съемки и наземной таксации. В практическом плане нейросети, обучаясь на большом массиве данных, представляют нестандартный подход в решении сложной задачи классификации природных объектов, в том числе определении их количественных и качественных характеристик. Ранее проведенные исследования показывают, что нейросети способны выявлять сложные зависимости и закономерности в данных, которые могут быть не учтены при применении стандартных статистических методов анализа данных [Сидоренков и др., 2018; Марков, Мачука, 2024; Мельников и др., 2024; Abadi, 2016]. По сути, интеграция нейросетей в алгоритмы лесотаксационного дешифрирования данных спутниковой съемки представляет собой следующий шаг в эволюции лесотаксационных технологий.

В настоящее время эффективные системы на базе нейросетей могут использоваться для автоматизации процессов дешифрирования данных спутниковой съемки по выявлению изменений лесной растительности, вызванных воздействием на леса негативных природных (ветровалы, буреломы, пожары, повреждение вредителями или болезнями леса) или антропогенных (вырубки, застройка территорий, геологическое освоение недр) факторов [Богодухов и др., 2024; Иванов и др., 2024; Марков, Мачука, 2024; Мельников и др., 2024; Marques et al., 2024; Brandt et al., 2025]. Приведенные примеры относятся к области решения задач лесопатологического мониторинга лесов, мониторинга воспроизводства и использования лесов.

Использование технологий искусственного интеллекта в прикладном аспекте для проверки данных лесоустройства является частью процесса, который включает элементы разработки нейросети:

- набор данных полевых исследований и их анализ на предмет ошибок с их исключением;
- подбор материалов оптической спутниковой съемки;
- обучение нейросети на материалах полевых исследований, валидация данных лесоустройства;
- апробация технологии по проверке полученных данных.

Перечисленные этапы технологии являются отдельными элементами, которые также должны быть выполнены с четким соблюдением установленных нормативно-законодательных требований к получению полевых данных о лесах, обработке материалов спутниковой съемки, разработке нейросети, её обучению и проведению валидации. Получение полевых данных таксации осуществляется в соответствии с Лесостроительной инструкцией¹ по методам в зависимости от разряда лесоустройства. Представленные в работе материалы получены по первому разряду таксации с использованием методов инструментальных измерений. Обработка материалов спутниковой съемки осуществлялась по общепринятым методам с проведением геометрической и атмосферной коррекции данных. Геометрическая коррекция данных проводилась по опорным точкам, полученным на местности или с использованием картографического материала.

Методика проведения работ. Основной целью в рамках проведения работы являлось создание технологии валидации данных лесоустройства. Достижение поставленной цели решалось многоступенчатым анализом материалов лесоустройства, которые использовали в работе как основной источник информации. До осуществления проверки исключались насаждения с ветровалами, буреломами и другими негативными процессами природного характера. Их определение проводилось с использованием алгоритмов компьютерного зрения. В дальнейшем эти участки также сравнивались с данными лесоустройства и при несовпадении отмечались как ошибки.

Материалы лесоустройства получены при проведении работ в 2025 г. Для принятия их Департаментом лесного хозяйства по ЦФО были организованы проверочные мероприятия в рамках установленного лесостроительной

¹ Приказ Министерства природных ресурсов и экологии РФ «Об утверждении Лесостроительной инструкции» от 5 августа 2022 г. №510.

инструкцией регламента. Проверка материалов лесоустройства проведена с учетом отсеивания выбросов, которые невозможно было объяснить с использованием математических моделей роста леса, созданных по таблицам хода роста с учетом изменения таксационных показателей при различном возрасте, полноте, бонитете насаждений. В основу математических моделей заложены алгоритмы множественной полиномиальной регрессии. Взаимосвязи получены с использованием программного обеспечения Statistica 13. В работе использованы математические модели с коэффициентом корреляции между прогнозными значениями и показателями из таблиц хода роста, превышающим значение $R = 0,9$, и коэффициентом значимости $p < 0,05$.

Другой механизм проверки данных был построен на моделях множественной полиномиальной регрессии связи таксационных показателей со спектрально-отражательными характеристиками лесных насаждений. В модели введены также показатели бонитета насаждений, как практически не изменяющегося с течением времени фактора. Основной задачей предварительной обработки данных являлось исключение участков с возможными ошибками для очистки данных таксации и проведения последующего обучения нейросети. Этот процесс – часть технологии, позволяющей осуществить обучение нейросети на данных с минимальным содержанием ошибок.

Результаты предварительного анализа данных показали выбросы, которые в большинстве случаев были связаны с ошибками таксации или особенностями не учитываемых при проведении лесоустройства природных процессов, таких как ветровалы, деградация лесов из-за негативных природных процессов. Последующее обучение нейросети осуществлялось на очищенных данных. Матрица таких данных представляет собой набор таксационных показателей верхнего яруса насаждения, совмещенных со спектрально-отражательными характеристиками снимка. Спектрально-отражательные характеристики рассчитывались как средние значения по выделу. При значительном различии спектрально-отражательных характеристик в пределах выдела (более 30%), например, на прогалинах или фрагментах других насаждений, эти данные исключались. Такая ситуация в процессе проведения лесоустройства иногда складывается при таксации больших выделов, которые могут быть неоднородны, и таксатор может не попасть в часть выдела, где возможен ветровал, бурелом, воздействие вредителей и болезней леса.

Реализация задачи по формированию матрицы данных требовала проведения предварительной подготовки материалов спутниковой съемки. Предварительная подготовка материалов съемки, полученной с отечественных аппаратов, осуществлялась на основе алгоритмов DOS (*Dark Object*

Subtraction) атмосферной коррекции – коррекции по темному объекту [Zhang et al., 2010]. Ключевая идея метода заключается в том, что влияние атмосферы можно приблизительно оценить и вычестить из общего сигнала. На любом спутниковом снимке существуют абсолютно черные объекты (*Dark Objects*) – пиксели, которые имеют практически нулевую отражательную способность в определенном диапазоне длин волн (например, глубокая чистая вода в ближнем инфракрасном диапазоне, густая тень, темные крыши). Любой сигнал от таких пикселей считается следствием рассеяния атмосферы (путь аэрозолей) и должен быть вычтен из всего изображения. К положительным аспектам метода можно отнести простоту использования алгоритма, высокую эффективность расчета по времени. К недостаткам метода относится сильное упрощение при расчетах, так как метод предполагает, что атмосферное рассеивание одинаково по всей сцене, что не всегда бывает так, особенно при сложном рельефе. Возникают также сложности точного обнаружения истинно черного объекта в автоматическом режиме: минимальные значения на гистограмме могут быть обусловлены тенью облаков или ошибкой сенсора. Для минимизации отрицательных моментов использовались данные съемки за один проход.

Работа со съёмкой с иностранных аппаратов Sentinel-2 позволила применить атмосферно скорректированные данные на основе сложного алгоритма Sen2Cor [Main-Knorn et al., 2017], разработанного специалистами Европейского космического агентства.

Основная задача алгоритма Sen2Cor [Sen2Cor..., 2025] – выполнение атмосферной коррекции. Он преобразует данные Top-Of-Atmosphere (TOA) (уровень L1C) в данные Bottom-Of-Atmosphere (BOA) поверхностной отражательной способности (уровень L2A). Это означает удаление влияния атмосферы (рассеяние аэрозолей, водяного пара, озона и др.) для получения «чистых» значений от самой поверхности Земли. Помимо основной атмосферной коррекции, он также создает ряд вспомогательных продуктов, которые включены в сцену L2A:

- карта классификации облаков, теней облаков и снега/льда (Scene Classification Map – SCL). Это один из ключевых выходных продуктов, критически важный для последующего анализа;
- индексы AOT (оптическая толщина аэрозолей) и WVP (содержание водяного пара);
- карты географической привязки (GEOM).

Схема работы алгоритма Sen2Cor представлена на рис. 1.



Рис. 1. Схема работы алгоритма Sen2Cor
Fig. 1. Operation scheme of the Sen2Cor algorithm

Sen2Cor является центральным и ключевым звеном полного унифицированного рабочего процесса (pipeline) обработки снимков Sentinel-2 для получения готового к аналитике продукта L2A. Целиком рабочий процесс выглядит так: Level-1C (TOA) → Sen2Cor → Level-2A (BOA + SCL + AOT и др.) → (опционально) дальнейшая обработка (мозаика, обрезка, расчёт индексов и т.д.). Этапы последующей обработки (рис. 2):

1. Передискретизация каналов с 20-метрового пространственного разрешения до 10-метрового (если вы хотите работать с красным, зелёным, синим и ближним инфракрасным диапазонами);
2. Обрезка изображений до области интереса (ROI);
3. Применение карты классификации сцен (SCL) к изображениям с отражательной способностью для маскировки дефектных пикселей.

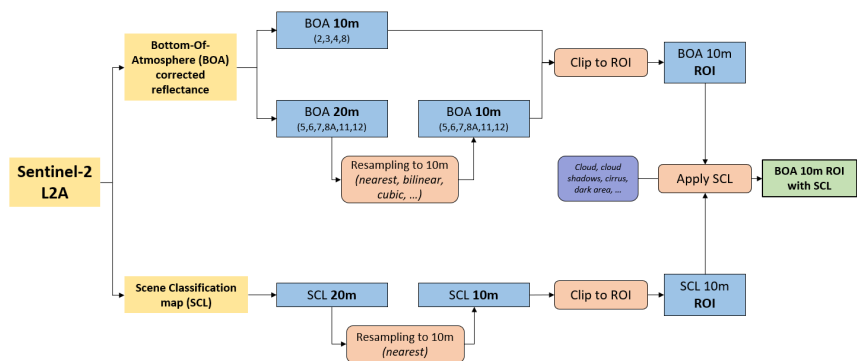


Рис. 2. Схема последующей обработки данных Sentinel-2 уровня L2A
 Fig. 2. Sentinel-2 level L2A data post-processing scheme

Результаты обработки спутниковых данных показали, что атмосферно скорректированные данные спутниковой съемки даже за близкие даты не обеспечивают получение количественных и качественных показателей лесов без ошибок. Несмотря на значительные успехи в области теоретической проработки вопроса атмосферной коррекции, в практическом плане он не доведен до использования с учетом точных методов и технологий анализа на основе спектрально-отражательных характеристик объектов. С учетом вышесказанного дешифрирование данных съемки возможно только при обработке сцен, полученных за одну дату (без переноса модели на другие даты). Данная особенность является сдерживающим фактором для экстраполяции технологии на сходные территории. Анализ территории

возможен при наличии наземных данных и оптической спутниковой съемки [Сидоренков и др., 2018, 2022а, б].

Для автоматизации процесса валидации лесотаксационных данных сотрудниками НЦ ОМЗ, ФБУ ВНИИЛМ и ФГБУ «Рослесинфорг» разработано специализированное программное обеспечение, которое в тестовом варианте названо «Геотрон.Лес-валидация». Оно интегрировано с геоинформационной платформой (ГИП) «Геотрон» (разработка АО «Российские космические системы»). Программное обеспечение представляет собой геоинформационный web-сервис с возможностью загрузки данных лесоустройства и материалов спутниковой съёмки через сеть Интернет и их последующей автоматической обработки.

Сервис состоит из модулей, показанных на рис. 3.

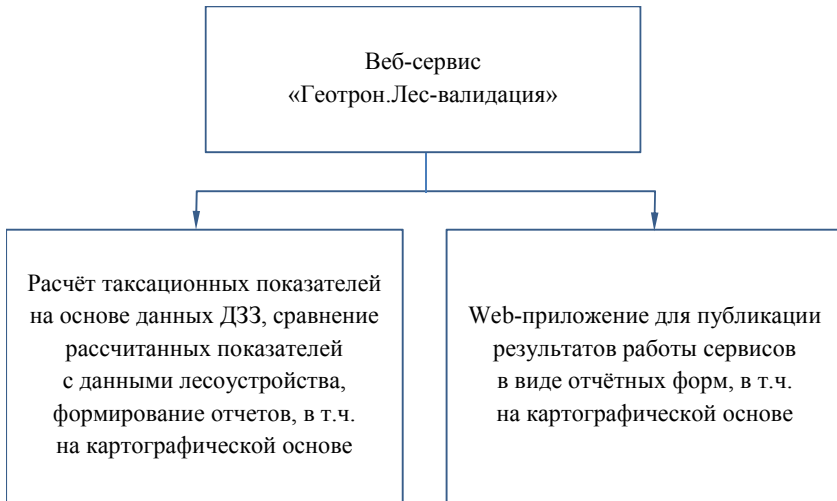


Рис. 3. Схема основных модулей сервиса «Геотрон.Лес-валидация»
Fig. 3. Diagram of the “Geotron.Forest validation” service main modules

При валидации данных лесоустройства рассматриваются следующие параметры насаждения: относительная полнота, запас, возраст, преобладающая порода.

Исходными данными для работы сервиса являются материалы лесоустройства в формате Esri shapefile, содержащие полигоны-границы выделов с привязанной атрибутивной информацией. Атрибуты должны содержать следующие поля:

- KV (номер квартала);

- SKNR (номер выдела);
- VMR (преобладающая порода);
- BON (бонитет);
- AMZ1 (возраст);
- SKAL1 (относительная полнота);
- TUR1H1 (запас яруса на 1 га).

В программное обеспечение можно загрузить данные космической съемки на обследуемую территорию с аппаратов «Канопус-В» с уровнем обработки 2В (мультиспектральные данные), Sentinel-2 с уровнем обработки L2A. Сервис использует для работы 4 канала: R, G, B (видимый диапазон) и NIR (ближний инфракрасный). В случае Sentinel-2 используются каналы видимого спектра и инфракрасный канал с разрешением съемки 10 м.

Интеграция исходных данных в программный комплекс осуществляется с использованием специально разработанного сервиса, в котором происходит проверка данных на корректность ввода и содержания необходимой атрибутивной информации (рис. 4).

Валидация результатов лесоустройства

[полнота, запас, возраст, преобл. порода]

Выберите изображение:

1

Drag and drop file here
Limit 450MB per file • TIF, TIFF

Browse files

mosaic_images.tif 8.8MB

Uploaded image file name: mosaic_images.tif

Выберите zip-архив с набором shp-файлов (данные лесоустройства):

2

Drag and drop file here
Limit 450MB per file • ZIP

Browse files

vydela_newproj.zip 0.8MB

Uploaded zip-shpfile name: vydela_newproj.zip

Выберите модель:

Архангельск

You selected: 1

Начать расчёт...

Рис. 4. Форма для внесения исходных данных
Fig. 4. Form for entering initial data

Внесение данных предполагает указание пути к расположению файла или файлов спутниковой съемки на территорию исследований (1), а также расположение архива с данными лесоустройства в формате Esri shapefile (2) и выбор заранее обученной модели при ее наличии (3).

Обучающая выборка состоит из средних значений спектральной яркости в диапазонах видимого и инфракрасного спектра пикселей в границах каждого выдела для каждого канала (т.е. включает четыре значения), а также входных данных – таксационных показателей (бонитет, относительная полнота, запас, возраст насаждений, преобладающая порода). Результат создания обучающей выборки формируется в текстовый файл (рис. 5).

При работе программы в случае отсутствия обученной модели происходит ее генерация. Обучение модели производится на основе созданной матрицы данных, в дальнейшем модель используется в определении основных таксационных показателей. В разработанном программном обеспечении есть возможность автоматической генерации модели, а также подбора параметров экспертом.




Рис. 5. Обучающая выборка, каждая строка соответствует одному выделу
 Fig. 5. Training sample, each line corresponds to one map unit

В качестве основной библиотеки для работы и обучения нейросетевых моделей был использован open-source фреймворк TensorFlow для машинного обучения, разработанный международной корпорацией Google [Abadi, 2016]. Он предоставляет гибкие инструменты для создания, обучения и развёртывания нейронных сетей и других моделей машинного обучения. Также использовался Keras – высокоуровневый API (*Application Programming Interface*, программный интерфейс приложений) для нейронных сетей, изначально разработанный как отдельная библиотека, но со временем интегрированный в TensorFlow. Преимуществом библиотеки Keras является интуитивно понятный и простой API, что позволяет быстро создавать и тестировать различные модели.

После проведения обучения нейросети она используется для определения таксационных показателей, на заключительном этапе рассчитывается «delta» – разница между данными из лесоустроительной документации и данными, рассчитанными с помощью нейросети. Количественная величина различия фактического показателя и показателя, определённого нейросетью, заносится в атрибуты каждого выдела. Таким образом, появляется возможность отобрать данные с отклонениями по запасу, полноте, возрасту насаждений, превышающие определённый порог от средней величины по выделу. При выполнении работ отклонение от средних таксационных показателей по запасу насаждений составило 30%, по относительной полноте насаждения – 0,2 единицы. По преобладающей породе отклонением считалось различие между породой насаждения, прогнозируемой моделью, и установленной при проведении таксации.

Реализация вычислений в геоинформационной системе дает возможность быстрого отображения границ выделов с критическими отклонениями по запасу, относительной полноте, возрасту и породе насаждения (рис. 6). Существует также возможность скачать результат на накопитель данных для дальнейшей верификации при проверке лесоустройства в районе выполнения работ.

Валидация данных лесоустройства выполнена для территории Меленковского участкового лесничества (Владимирская область). Результаты работы программы автоматически выводятся в виде картографического материала, на котором зеленым цветом выделены расчетные значения по модели и желтым – данные лесоустройства (рис. 7–10). Картографический вывод материала дает возможность сразу провести оценку результатов, особенно на территориях с ошибками по полноте (рис. 6) и запасу (рис. 8) насаждений. Значительные отклонения по этим показателям характерны для редиин, прогалин, участков, пройденных различными видами выборочных рубок, ветровалов и буреломов.

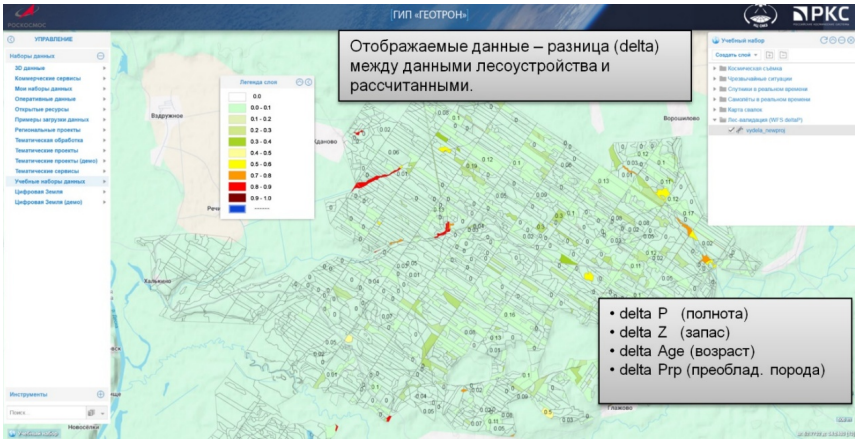


Рис. 6. Отображение результатов в Геоинтеграционной платформе «Геотрон»
Fig. 6. Display of results in the Geotron software




Рис. 7. Пример результатов работы сервиса (Меленковское уч. лесничество).
Жёлтым цветом показаны исходные данные лесоустройства (поле «Skal1»),
зелёным – рассчитанные с помощью нейросети значения полноты
Fig. 7. Example of the software output (Melenkovskoye forestry district).
The initial forest management data (field «Skal1») are shown in yellow,
and the forest density values calculated using the neural network are shown in green

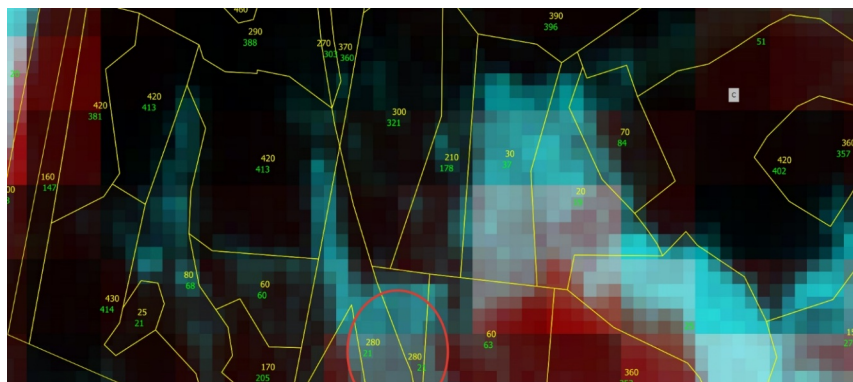


Рис. 10. Пример выявления несоответствий по запасу (Меленковское уч. лесничество), выделено красным

Fig. 10. Example of identifying discrepancies in stock volume (Melenkovskoye forestry district), marked in red

Практическая апробация модели на территории Меленковского лесничества показала, что значительная часть расхождения между материалами лесоустройства и реальной ситуацией в лесу характерна для сложных насаждений, где в составе участвует несколько пород. Большая часть исследуемых участков, где наблюдалось расхождение с материалами лесоустройства, относится к молоднякам и средневозрастным насаждениям, сформированным на местах бывших вырубок, где частично были созданы культуры, а на оставшейся территории в результате естественных процессов возобновились мелколиственные породы. Часто при таксации такие участки из-за разного состава насаждений ошибочно относились или к хвойному, или к лиственному хозяйству. К другому классу объектов, на которых при проведении лесоустройства часто наблюдались ошибки по запасу и полноте, можно отнести редкостойные (с относительной полнотой от 0,3 до 0,5) приспевающие и спелые древостои с различным породным составом первого яруса.

Обсуждение. Результаты анализа проведенного эксперимента по валидации данных лесоустройства на территории Меленковского участкового лесничества Владимирской области показали, что точность обучения и работы нейросети возрастает при использовании данных большого количества выделов. Количество выделов менее одной тысячи штук может при-

водить к некорректному результату. Приемлемые результаты получаются при количестве выделов, превышающем пять тысяч штук. Исходя из числа выделов, разработанная технология позволяет получить хорошие результаты по валидации на территории, превышающей площадь более десяти тысяч гектаров, что сравнимо с площадью одного участкового лесничества в центральной части России.

Исследование технологий на базе систем искусственного интеллекта и эксперименты по их внедрению в практику лесоустройства продемонстрировали сложный путь от разработки алгоритма нейросети, выявления специфики подготовки полевых и спутниковых данных к обучению нейросети и созданию производственной технологии на базе программного обеспечения. Интеграция технологии в практику лесного хозяйства – это сложный процесс, который требует проверки полученных результатов в полевых условиях. Тем не менее технологии искусственного интеллекта становятся неотъемлемой частью системы проведения лесоустроительных работ не только в части проверки данных, но и в части таксации, принятия решений по назначению лесохозяйственных мероприятий. Применение нейросетей в области лесоустройства открывает новые горизонты по развитию направления лесоустройства с использованием данных спутниковой съемки в части автоматизации процессов получения таксационных показателей лесов, выделения территорий, подверженных различным видам повреждений леса из-за воздействия природных и антропогенных факторов. На современном этапе для обучения нейросетей пока еще требуются наземные данные, но с увеличением объема информации, в том числе расширения базы данных материалов лесоустройства, появится возможность использовать обученные нейросети для дешифрирования различных типов лесов. Другим важным направлением, которое требует исследований, является необходимость совершенствования технологии атмосферной коррекции данных спутниковой съемки с целью формирования единой основы массива данных для обучения нейросетей.

В части совершенствования технологии валидации данных лесоустройства с использованием нейросетей планируется доработка программного обеспечения в следующих направлениях:

- объединение разрозненных данных (полевые таксационные описания, аэрофотоснимки, LiDAR, мультиспектральная съёмка, исторические данные, картографические материалы) в единую платформу с чёткой структурой метаданных;

- анализ исторических данных с пометкой ошибок;
- выявление несоответствий границ выделов ситуации, представленной на космическом снимке, и проведение соответствующей коррекции;
- анализ топологии выделов, проверка геометрии (разрывы, самопересечения, наложения, некорректные соседства типов леса и т.д.), устранение ошибок;
- выявление незамеченных гарей, ветровалов, рубок;
- применение методов повышения резкости изображений;
- дополнение обучающей выборки данными по рельефу (уклон, экспозиция, почвенные данные, климатические индексы и т.д.);
- внедрение интерактивных систем обратной связи, позволяющих пользователям оперативно сообщать о возможных ошибках и недостатках автоматически обработанных данных.

Реализация перечисленных рекомендаций позволит значительно повысить качество и надёжность процессов технологии валидации данных лесоустройства, сократить временные затраты на проверку и обработку материалов, а также минимизировать риски возникновения ошибок при принятии управленческих решений в сфере охраны и рационального использования лесных ресурсов.

Заключение. С каждым годом технологии по использованию нейросетей становятся более совершенными, а возможности их применения в решении сложных задач расширяются. Не вызывает сомнений, что уже в ближайшем будущем мы увидим новые алгоритмы, способные решать задачи не только таксации лесных экосистем, но и моделирования их роста в зависимости от разных факторов.

Вклад авторов. Капиталинин Д.Ю. – руководство проведением экспериментальных работ, текст статьи; Тищенко П.А. – разработка ПО автоматизации алгоритмов лесотаксационного дешифрирования и валидации данных лесоустройства; Сидоренков В.М. – разработка методики и алгоритмов лесотаксационного дешифрирования и валидации материалов лесоустройства, текст статьи; Ачилова Ю.С. и Щекалев Р.В. – научно-методическое сопровождение эксперимента, текст статьи; Астапов Д.О. – обработка данных лесоустройства и материалов лесотаксационного дешифрирования, подготовка данных спутниковой съемки к анализу; Рябцев О.В. – апробация материалов эксперимента, закладка пробных площадей в точках с критическим отклонением расчетных данных по модели с материалами лесоустройства.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Библиографический список

Богодухов М.А., Барталев С.А., Жарко В.О. Исследование возможностей распознавания преобладающих пород леса с использованием регрессионной оценки долевого участия пород по запасу на основе данных Sentinel-2 и материалов пробных площадей // Современные проблемы дистанционного зондирования Земли из космоса: мат. 22-й Межд. конф. М., 2024. С. 159.

Иванов С.В., Сидоренков В.М., Ачиколова Ю.С., Астапов Д.О., Тищенко П.А., Буряк Л.В., Рыбкин А.С. Возможности использования данных группировки спутников ДЗЗ стран БРИКС для решения тематических задач получения информации о лесных экосистемах // Лесохозяйственная информация. 2024. № 4. С. 42-55.

Марков Н.Г., Мачука К.Р. Модели и методы глубокого обучения для решения задач дистанционного мониторинга лесных ресурсов // Известия Томского политехнического университета. Инжиниринг георесурсов. 2024. Т. 335, № 6. С. 55-74.

Мельников А.В., Полищук Ю.М., Русанов М.А., Аббазов В.Р., Кочергин Г.А., Куприянов М.А., Байсаямова О.А., Соколов О.И. Сравнительный анализ нейросетевых моделей для картографирования лесных рубок по летним космическим снимкам // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 806-814.

Сидоренков В.М., Мартынюк А.А., Сережкин А.В. Использование данных спутниковой съемки Sentinel 2 для оценки характеристик лесной растительности таежных лесов // Экологические и биологические основы повышения продуктивности и устойчивости природных и искусственно возобновленных экосистем: мат. межд. науч. конф. Воронеж, 2018. С. 103-115.

Сидоренков В.М., Астапов Д.О., Перфильева О.В., Рябцев О.В., Рыбкин А.С. Определение таксационных показателей чистых насаждений сосны по данным спутника «Канопус-В» // Ракетно-космическое приборостроение и информационные системы. 2022а. Т. 9, № 2. С. 36-43.

Сидоренков В.М., Астапов Д.О., Рыбкин Е.С., Ачиколова Ю.С., Рябцев О.В. Возможности использования спутниковой съемки с космического аппарата Метеор-М для определения количественных и качественных характеристик лесов // Лесохозяйственная информация. 2022b. № 2. С. 5-12.

Abadi M. TensorFlow: learning functions at scale // Proceedings of the 21st ACM SIGPLAN International Conference on Functional Programming: ICFP 2016. N.-Y., 2016. P. 1.

Brandt M., Chave J., Li S., Fensholt R., Ciais P., Wigneron J.-P., Gieseke F., Saatchi S., Tucker C.J., Igel C. High-resolution sensors and deep learning models for tree resource monitoring // Nature Reviews Electrical Engineering. 2025. Vol. 2, no. 1. P. 13-26.

Main-Knorn M., Pflug B., Louis J., Debaecker V., Müller-Wilm U., Gascon F. Sen2Cor for Sentinel-2 // Proceedings of SPIE. 2017. Vol. 10427. P. 37-48.

Marques T., Carreira S., Miragaia R., Ramos J., Pereira A. Applying deep learning to real-time UAV-based forest monitoring: Leveraging multi-sensor imagery for improved results // *Expert Systems with Applications*. 2024. Vol. 245: Applying deep learning to real-time UAV-based forest monitoring. P. 107-123.

Sen2Cor. Science Toolbox Exploitation Platform // European Space Agency. URL: <https://step.esa.int/main/snap-supported-plugins/sen2cor/> (дата обращения: 10.06.2025).

Zhang Z., He G., Wang X. A practical DOS model-based atmospheric correction algorithm // *International Journal of Remote Sensing*. 2010. Vol. 31. P. 2837-2852.

References

Abadi M. TensorFlow: learning functions at scale. *Proceedings of the 21st ACM SIGPLAN International Conference on Functional Programming: ICFP 2016*. New York, 2016, p. 1.

Bogodukhov M.A., Bartalev S.A., Zharko V.O. Study of the possibilities of recognizing predominant forest species using regression assessment of the share of species by stock based on Sentinel-2 data and materials from sample plots. Current problems in remote sensing of the Earth from space: mat. of 22nd int. conf. Moscow, 2024, p. 159. (In Russ.)

Brandt M., Chave J., Li S., Fensholt R., Ciais P., Wigneron J.-P., Gieseke F., Saatchi S., Tucker C.J., Igel C. High-resolution sensors and deep learning models for tree resource monitoring. *Nature Reviews Electrical Engineering*, 2025, vol. 2, no. 1, pp. 13-26.

Ivanov S.V., Sidorenkov V.M., Achikolova Yu.S., Astapov D.O., Tishchenko P.A., Buryak L.V., Rybkin A.S. Possibilities of using data from the BRICS remote sensing satellite constellation to solve thematic issues of obtaining information on forest ecosystems. *Forestry information*, 2024, no. 4, pp. 42-55. (In Russ.)

Main-Knorn M., Pflug B., Louis J., Debaecker V., Müller-Wilm U., Gascon F. Sen2Cor for Sentinel-2. *Proceedings of SPIE*, 2017, vol. 10427, pp. 37-48.

Markov N.G., Machuka K.R. Deep learning models and methods for solving problems of forest resources remote monitoring. *Bulletin of Tomsk Polytechnic University. Georesources engineering*, 2024, vol. 335, no. 6, pp. 55-74. (In Russ.)

Marques T., Carreira S., Miragaia R., Ramos J., Pereira A. Applying deep learning to real-time UAV-based forest monitoring: Leveraging multi-sensor imagery for improved results. *Expert Systems with Applications*, 2024, vol. 245: Applying deep learning to real-time UAV-based forest monitoring, pp. 107-123.

Melnikov A.V., Polischuk Yu.M., Rusanov M.A., Abbazov V.R., Kochergin G.A., Kupriyanov M.A., Baysalyamova O.A., Sokolov O.I. Comparative analysis of neural network models for mapping forest cuttings based on summer space images. *Scientific and Technical Bulletin of Information Technologies, Mechanics and Optics*, 2024, vol.24, no. 5, pp. 806-814.

Sen2Cor. Science Toolbox Exploitation Platform // European Space Agency. URL: <https://step.esa.int/main/snap-supported-plugins/sen2cor/> (accessed June 10, 2025)

Sidorenkov V.M., Martynyuk A.A., Serezhkin A.V. Using Sentinel-2 satellite imagery data to assess the characteristics of forest vegetation in taiga forests. *Ecological and biological foundations for increasing the productivity and sustainability of natural and artificially restored ecosystems: proceedings of the int. sci. conf. Voronezh, 2018*, pp. 103-115. (In Russ.)

Sidorenkov V.M., Astapov D.O., Perfilyeva O.V., Ryabtsev O.V., Rybkin A.S. Determination of forest characteristics of pure pine stands based on Kanopus-V imagery data. *Rocket and Space Instrumentation and Information Systems, 2022a*, vol. 9, no. 2, pp. 36-43. (In Russ.)

Sidorenkov V.M., Astapov D.O., Rybkin E.S., Achikolova I.S., Ryabtsev O.V. Possibilities of using satellite imagery from the Meteor-M spacecraft to determine the quantitative and qualitative forests characteristics. *Forestry information, 2022b*, no. 2, pp. 5-12.

Zhang Z., He G., Wang X. A practical DOS model-based atmospheric correction algorithm. *International Journal of Remote Sensing, 2010*, vol. 31, pp. 2837-2852.

Материал поступил в редакцию 16.09.2025

Капиталинин Д.Ю., Тищенко П.А., Сидоренков В.М., Ачиколова Ю.С., Астапов Д.О., Рябцев О.В. Щекалев Р.В. Использование нейросетей глубокого обучения для автоматической валидации материалов лесоустройства по данным спутниковой съёмки // *Известия Санкт-Петербургской лесотехнической академии. 2025. Вып. 256. С. 213–233. DOI: 10.21266/2079-4304.2025.256.213-233*

В статье рассматривается применение нейросетей глубокого обучения для проверки таксационных показателей лесов, полученных при проведении лесоустройства. Авторами разработана технология верификации данных лесоустройства, основанная на использовании оптических спутниковых снимков высокого разрешения, обработка которых происходит посредством нейросетей. В качестве исходных данных взяты снимки территории Меленковского участкового лесничества Владимирской области с аппаратов Sentinel-2, проведена атмосферная коррекция с помощью алгоритма Sen2Cor. Автоматизация процесса лесотаксационного дешифрирования снимков выполнена в программном обеспечении «Геотрон. Лес-валидация» – специализированном геоинформационном ресурсе, разработанном сотрудниками НЦ ОМЗ, ФБУ ВНИИЛМ и ФГБУ «Рослесинфорг». Для обучения нейросетевых моделей использовались библиотеки TensorFlow и Keras, обучающая выборка основана на средних значениях пикселей в границах каждого выдела для каждого канала. После обучения нейросеть определяет таксационные показатели для каждого выдела, а также выдает разницу между данными из лесоустроительной документации и рассчитанными с помощью

нейросети, что позволяет выявить отклонения по запасу, полноте, возрасту насаждений. Работа модели продемонстрировала, что значительная часть неточных данных по лесоустройству характерна для сложных насаждений с несколькими породами в составе, а также для редкостойных приспевающих и спелых древостоев с различным породным составом первого яруса. Результат проведенного эксперимента показал, что точность обучения и работы нейросети напрямую зависит от объема данных, в частности, количества выделов, по которым происходит обучение. Приемлемые результаты получаются при количестве выделов, превышающем 5000 штук. Исходя из этого, разработанная технология позволяет получить хорошие результаты по валидации результатов лесоустройства на территории, превышающей площадь 10 тысяч гектаров, что сравнимо со средней площадью одного участкового лесничества в центральной части России.

Ключевые слова: лесоустройство, таксационные показатели, глубокое обучение, нейросеть, спутниковая съемка, TensorFlow, Keras.

Капиталинин Д.Ю., Тищенко П.А., Сидоренков В.М., Ачиколова И.С., Астапов Д.О., Рыabtsev O.V. Shchekalev R.V. Applying deep learning neural networks for automatic validation of forest management materials based on satellite imagery. *Izvestia Sankt-Peterburgskoj Lesotehnicheskoj Akademii*, 2025, iss. 256, pp. 213–233 (in Russian with English summary). DOI: 10.21266/2079-4304.2025.256.213-233

The article discusses the use of deep learning neural networks to verify forest taxation indicators obtained during forest management. The authors have designed a technology for verifying forest management data based on the high-resolution optical satellite images processed applying neural networks. The initial data were images of the Melenkovskoye forestry district in the Vladimir region taken from Sentinel-2 satellites; atmospheric correction was performed with the Sen2Cor algorithm. The process of forest taxation interpretation of images was automated with the «Geotron. Forest Validation» software, a specialized geoinformation resource developed by the NC OMZ, FBU VNIILM and FGBU “Roslesinforg”. The TensorFlow and Keras libraries were used to train the neural network models; the training sample was based on the average pixel values within the boundaries of each plot for every channel. After training, the neural network determined forest characteristics for each section, and also gave the difference between the forest management documentation data and those calculated by the neural network; this allowed identifying deviations in the stock volume, forest density, and stands age. The model's operation demonstrated that a significant portion of inaccurate forest management data is typical for complex stands with several species in the composition, as well as for sparse maturing and mature stands with different species composition of the first tier. The study result showed that the accuracy of neural network training and operating directly depends on the of data amount, in particular, the number of sections for which training occurs. Acceptable results are obtained with a sections number exceeding 5,000 pieces. Considering this, the developed technology allows obtaining good results in validating

forest management data on an area exceeding 10 thousand hectares, which is comparable to the average area of one forestry district in the central part of Russia.

Key words: forest management, forest characteristics, deep learning, neural network, satellite imagery, TensorFlow, Keras.

КАПИТАЛИНИН Дмитрий Юрьевич – и.о. директора ФГБУ «Рослесинфорг». ORCID: 0009-0001-5489-9192.

109316, Волгоградский пр., д. 45, стр. 1, г. Москва, Россия. E-mail: kapitalinin.d@yandex.ru

KAPITALININ Dmitry Yu. – Acting Director of the Federal State Budgetary Institution «Roslesinform». ORCID: 0009-0001-5489-9192.

109316, Volgogradsky av. 45, build. 1. E-mail: kapitalinin.d@yandex.ru

ТИЩЕНКО Павел Александрович – начальник сектора НЦ ОМЗ АО «Российские космические системы»

27490, ул. Декабристов, вл. 51, стр. 25, г. Москва, Россия. E-mail: tishenko_pa@ntsomz.ru

TISHCHENKO Pavel A. – Head of department, NC OMZ, JSC Russian Space Systems.

27490, Dekabristov str. 51, build. 25. Moscow. Russia. E-mail: tishenko_pa@ntsomz.ru

СИДОРЕНКОВ Виктор Михайлович – и. о. директора Всероссийского научно-исследовательского института лесоводства и механизации лесного хозяйства, кандидат сельскохозяйственных наук. ORCID: 0000-0003-4189-1906. SPIN-код: 6071-2570.

141202, Институтская ул., д. 15, г. Пушкино, Московская обл., Россия. E-mail: lesvn@yandex.ru

SIDORENKOV Viktor M. – PhD (Agriculture), Acting Director of the All-Russian Scientific Research Institute of Forestry and Forestry Mechanization. ORCID: 0000-0003-4189-1906. SPIN-code: 6071-2570.

141202, Institutskaya str. 15. Pushkino. Moscow region. Russia. E-mail: lesvn@yandex.ru

АЧИКОЛОВА Юлия Сергеевна – заведующая лабораторией динамики леса Всероссийского научно-исследовательского института лесоводства и механизации лесного хозяйства, кандидат сельскохозяйственных наук. ORCID: 0000-0002-7937-5061. SPIN-код: 2270-4644.

141202, Институтская ул., д. 15, г. Пушкино, Московская обл., Россия. E-mail: pipintook@yandex.ru

ACHIKOLOVA Iuliia S. – Head of Forest Dynamics Laboratory of the All-Russian Scientific Research Institute of Forestry and Forestry Mechanization. ORCID: 0000-0002-7937-5061. SPIN-code: 2270-4644.

141202, Institutskaya str. 15. Pushkino. Moscow region. Russia. E-mail: pipintook@yandex.ru

АСТАПОВ Даниил Олегович – заведующий лабораторией лесоустройства и лесной таксации Всероссийского научно-исследовательского института лесоводства и механизации лесного хозяйства. ORCID: 0000-0003-4189-1906. SPIN-код: 6489-9193.

141202, Институтская ул., д. 15, г. Пушкино, Московская обл., Россия. E-mail: astdann09@yandex.ru

АСТАПОВ Daniil O. – Head of the Laboratory of forest management and forest taxation of the All-Russian Scientific Research Institute of Forestry and Forestry Mechanization. ORCID: 0000-0003-4189-1906. SPIN-code: 6489-9193.

141202, Institutskaya str. 15. Pushkino. Moscow region. Russia. E-mail: astdann09@yandex.ru

РЯБЦЕВ Олег Викторович – заведующий отделом инновационных технологий, внедрения и лесного проектирования Всероссийского научно-исследовательского института лесоводства и механизации лесного хозяйства, кандидат сельскохозяйственных наук. ORCID: 0000-0003-4189-1906. SPIN-код: 6803-9857.

141202, Институтская ул., д. 15, г. Пушкино, Московская обл., Россия. E-mail: sektorles@yandex.ru

RYABTSEV Oleg V. – PhD (Agriculture), Head of Department of innovative technologies, implementation and forest design of the All-Russian Scientific Research Institute of Forestry and Forestry Mechanization. ORCID: 0000-0003-4189-1906. SPIN-code: 6803-9857.

141202, Institutskaya str. 15. Pushkino. Moscow region. Russia. E-mail: sektorles@yandex.ru

ЩЕКАЛЕВ Роман Викторович – профессор кафедры почвоведения Санкт-Петербургского государственного лесотехнического университета им. С.М. Кирова, доктор сельскохозяйственных наук. ORCID: 0000-0001-7657-1705. SPIN-код: 5826-3852.

194021, Институтский пер., д. 5, Санкт-Петербург, Россия. E-mail: schekalevrv@yandex.ru

SHCHEKALEV Roman V. – DSc (Agriculture), Professor of Soil Science Department, St. Petersburg State Forest Technical University. ORCID: 0000-0001-7657-1705. SPIN-code: 5826-3852.

194021, Institute per. 5. St. Petersburg. Russia. E-mail: schekalevrv@yandex.ru