

Пространственное моделирование надземной фитомассы лесов Костромской области по спутниковым данным высокого пространственного разрешения

Е. Н. Сочилова, Д. В. Ершов, Е. И. Белова,
Е. А. Гаврилюк, Н. В. Королева, С. В. Князева

*Центр по проблемам экологии и продуктивности лесов им. А. С. Исаева РАН
Москва, 117997, Россия
E-mail: elena@ifl.rssi.ru*

Оценка и мониторинг динамики фитомассы лесов — актуальная задача для изучения их экосистемных функций и услуг на разных пространственных уровнях. В статье представлен метод и результаты пространственного моделирования надземной фитомассы древесной части лесов Костромской области на основе ключевых таксационных характеристик, полученных по результатам тематической обработки разносезонных безоблачных композитных изображений спутников Landsat-8 и -9 (2017–2021). Моделирование выполняется с помощью серии регрессионных моделей расчёта запасов фитомассы древостоя, подроста и подлеска, опубликованных А. З. Швиденко и Д. Г. Щепашенко в период с 2008 по 2023 г. Входные данные в модели — тематические продукты среднего возраста, относительной полноты, бонитета и запаса стволовой древесины преобладающих древесных пород лесов модельного региона, по которым в каждом пикселе с пространственным разрешением 30 м рассчитываются запасы надземной фитомассы. Классификация основных типов растительности наземных экосистем, лесообразующих древесных пород региона, среднего возраста насаждения, бонитетов и относительной полноты выполняется по спутниковым изображениям с помощью алгоритма машинного обучения Random Forest, а запасы стволовой древесины оцениваются методом восстановления нелинейной регрессионной зависимости между спектральной яркостью древостоев на зимних безоблачных композитных изображениях Landsat в красном канале и их таксационными характеристиками по выделам. Обучение классификатора осуществляется с помощью пространственной базы данных лесной таксации, актуальной по состоянию на 2015 г. Оценка точности спутникового продукта фитомассы лесов проводится с помощью независимого набора тестовых выделов, в границах которых оценён запас фитомассы по материалам таксации. В результате сравнения двух наборов данных средняя абсолютная ошибка фитомассы по породам находится в диапазоне 22,63–27,21 т/га. Наибольшая средняя абсолютная процентная ошибка приходится на сосну (31,6 %), наименьшая — на берёзу (20,9 %).

Ключевые слова: региональное картографирование лесов, характеристики лесов по ДЗЗ, запас биомассы в лесах, Random Forest, Костромская область

Одобрена к печати: 27.01.2026

DOI: 10.21046/2070-7401-2026-23-2-216-230

Введение

В Национальной стратегии сохранения биоразнообразия России выделены четыре группы жизнеобеспечивающих функций биологического разнообразия (Кузьмичев и др., 2021), одна из которых относится к продукционным и подразумевает под собой умение оценивать производство биомассы лесов. Надземная биомасса выступает одним из важнейших показателей продуктивности, структуры и состояния лесного покрова (Барталев и др., 2016).

Учитывая актуальность вопроса количественной оценки и мониторинга запасов фитомассы лесов для обширных территорий России, разными учёными проводились исследования как на федеральном уровне (Барталев и др., 2016; Ершов и др., 2023; Замолотчиков и др., 2003, 2005; Щепашенко и др., 2017), так и на региональном (Сочилова и др., 2018) и локальном уровне (Гаврилюк, 2024; Михайлов и др., 2021). Статистические данные учёта лесного фонда выступают в качестве важных составляющих при исследовании продуктивности лесных насаждений. Применительно к данным дистанционного зондирования Земли (ДЗЗ) рас-

чёты ведутся на уровне пикселей или группы пикселей (сегментов), размер которых характеризует пространственное разрешение. Фитомасса может оцениваться либо через модели, определяющие связь её значений непосредственно с дистанционными метриками, либо через модели связи её значений с характеристиками древостоя, извлечёнными из анализа данных ДЗЗ. В *первом подходе* запас фитомассы древесного яруса оценивается по наземным лесотаксационным характеристикам, собранным на пробных площадях, которые затем используются при обучении и пространственном моделировании по ДЗЗ. Наилучший результат при таком подходе достигается за счёт объединения разнотипных данных для оценки биомассы древостоев (например, радарных и оптических) на разных пространственных уровнях (Jos et al., 2021; Tian et al., 2023). В этом случае точность моделирования зависит от точности наземных измерений характеристик лесов и локальных моделей определения запаса фитомассы древостоя, а также спутниковых наборов данных и метрик, извлечённых из них. *Второй подход* предполагает построение (моделирование) серии тематических продуктов с характеристиками лесов (преобладающая порода, средний возраст, относительная полнота, бонитет и другие), которые затем используются в моделях оценки биомассы древостоев, настроенных по данным наземных измерений (Усольцев, 2016; Швиденко и др., 2008). Этот метод зависит от точности моделирования отдельных характеристик лесов, которые могут как накапливать интегральную точность определения запаса фитомассы, так и её взаимно компенсировать. Преимуществом подхода считается возможность использовать спутниковые тематические продукты характеристик лесов не только для оценки фитомассы, но и для изучения биоразнообразия лесов, их экосистемных функций и услуг региона.

В работе А. С. Барталева с соавторами (2016) проведена оценка и сравнение карт запасов древесины в лесах по оптическим спутниковым данным MODIS (*англ.* Moderate Resolution Imaging Spectroradiometer) (пространственное разрешение — 250 м) и Proba-V (115 м). Результат сравнения продемонстрировал занижение спутниковых оценок относительно официальной статистики при высоком значении коэффициента детерминации (R^2). При этом очевидно, что данные о пространственном распределении биомассы и запаса древостоев на территории России по результатам обработки данных ДЗЗ в оптическом диапазоне могут иметь ограничения вследствие наличия облачности. Однако радарному сигналу облачность не мешает, что привело к достаточно широкому использованию данных радарной съёмки при определении объёмных характеристик лесов. Применение алгоритма BIOMASAR к спутниковым данным радара с синтезированной апертурой дало возможность сформировать карту запасов стволовой древесины в лесах северного полушария по состоянию на 2010 г. с пространственным разрешением 1 км, покрывающую в том числе всю территорию России (Santoro et al., 2015), а также получить карту биомассы лесов бореальной зоны (Turner et al., 2014). К недостаткам применения радарной съёмки можно отнести довольно быстрое насыщение сигнала при увеличении количества фитомассы, в таком случае лес со средними запасами фитомассы становится похож на лес с высокими запасами.

С целью оценки фитомассы лесного покрова Сибири И. М. Данилин с соавторами (2005) указывают на совместное использование данных авиационного лазерного и радарного сканирования, а также аэрофотоснимков и космических изображений высокого пространственного разрешения. Рядом исследователей отмечается высокая точность определения биометрических показателей древостоев при воздушном лазерном сканировании (Гаврилюк, 2025; Медведев и др., 2007).

В рамках нашего исследования мы предлагаем использовать моделирование тематических карт с ключевыми характеристиками лесов (второй подход) в качестве входных параметров для пространственной оценки фитомассы древесного полога по спутниковым данным. Детально методика моделирования фитомассы лесов приводится в нашей статье 2023 г. (Ершов и др., 2023). Изложенный в статье метод оценки фитомассы лесов на национальном уровне базируется на применении спутниковых тематических продуктов MODIS (230 м): преобладающая древесная порода, возраст, класс бонитета, относительная полнота и относительный запас стволовой древесины (в $\text{м}^3/\text{га}$). В качестве аналитической формулы для каждой породы используются регрессионные модели (Швиденко и др., 2008; Щепашенко и др., 2013;

Schepaschenko et al., 2018; Shvidenko et al., 2023), с помощью которых рассчитываются запасы фитомассы древостоев. Для регионального уровня применим такой же подход при условии, что мы формируем аналогичные спутниковые тематические продукты высокого пространственного разрешения 10–30 м.

Цель работы — исследовать возможность автоматизированной обработки спутниковых изображений высокого пространственного разрешения (30 м) методами машинного обучения по материалам таксации лесов для получения серии региональных тематических продуктов ключевых характеристик лесов, на основе которых моделируются в пространстве запасы фитомассы преобладающих древесных пород региона с оценкой точности моделирования фитомассы по независимым наборам характеристик лесов из материалов лесной таксации.

В качестве модельного региона выбрана Костромская область, территория которой по данным Минприроды РФ характеризуется высокой лесистостью — 74,3 % (https://www.mnr.gov.ru/activity/regions/kostromskaya_oblast/?sphrase_id=577864&ysclid=m4b6wcb40x247521121). Общая площадь земель лесного фонда — 4667,2 тыс. га; общий запас древесины на корню — 724,3 млн м³. По возрастным группам преобладают молодняки и средневозрастные насаждения — 59 %, припевающие — 18 %, спелые и перестойные — 23 %.

Методика исследований и исходные данные

Исследования состоят из этапов создания спутниковых тематических продуктов (карт) лесотаксационных характеристик, моделирования в пространстве фитомассы лесов с помощью регрессионных зависимостей и сравнения карты фитомассы с идентичной картой, полученной по материалам лесной таксации на уровне выделов, не участвовавших в обучении и классификации. Оценка фитомассы древостоев, подроста и подлеска выполняется с помощью регрессионных уравнений с учётом древесной породы верхнего яруса, её среднего возраста, объёма стволовой древесины, относительной полноты и класса бонитета (Швиденко и др., 2008; Schepaschenko et al., 2018).

Первый этап — создание серии тематических карт с использованием многоканальных изображений спутников Landsat 8-го и 9-го поколения (30 м), из которых сформированы разносезонные безоблачные композиты (Гаврилюк и др., 2021) на ресурсах облачной платформы GEE (*англ.* Google Earth Engine) (Gorelick et al., 2017). Для оптимизации тематической обработки массивы разносезонных спутниковых композитов нарезаны по квадратам 1×1° по широте и долготе. Для каждого квадрата создаются безоблачные изображения для шести внутригодовых временных интервалов на основе сцен, полученных в период с 2017 по 2021 г., с использованием каналов в видимом, ближнем и коротковолновом инфракрасном SWIR1 (*англ.* short wave infrared) диапазонах. Границы временных интервалов для каждого квадрата определялись следующим образом: 1) на основе семи ключевых фенологических дат (от начала роста до окончания увядания) по данным MODIS Land Cover Dynamics (<https://www.earthdata.nasa.gov/data/catalog/lpcloud-mcd12q2-061>) вычислялись их многолетние медианные значения (номера дня в году); 2) для каждой ключевой даты формировался 41-дневный интервал (± 20 дней от медианной даты), что обеспечивало не менее пяти сцен Landsat за год; 3) интервал для зимнего периода был расширен на 30 дней и составил 71 день, так как количество качественных сцен за зимний период сильно падает. Таким образом у нас формируются шесть внутригодовых интервалов, которые соответствуют следующим сезонам: зима, первая половина весны, вторая половина весны, лето, первая половина осени, вторая половина осени. Для каждого квадрата даты сезонов индивидуальны из-за их физико-географического положения.

Тематические продукты создаются последовательно, начиная с картографирования основных типов наземных экосистем, затем породной и возрастной структуры лесов, запаса стволовой древесины верхнего яруса, относительной полноты и бонитета древостоя. Последние две характеристики моделируются в пространстве не только по спектральным каналам, но дополнительно с использованием спутниковых карт пород, возраста и запаса стволовой древесины.

Картографирование основных типов наземных экосистем

Растровая карта основных типов наземных экосистем создаётся для определения актуальной границы лесов региона. В качестве источника для подготовки эталонов берётся растровая карта растительного покрова ESA (*англ.* European Space Agency) WorldCover 2021 г. с пространственным разрешением 10 м (<https://zenodo.org/records/7254221>). Этот продукт проецируется в систему координат композитных изображений с пространственным разрешением 30 м, фильтруется с помощью серии растровых слоёв участков нарушенных лесов тематических продуктов GFC (*англ.* Global Forest Change) (Hansen et al., 2013) и бинарной маски населённых пунктов WSF (*англ.* World Settlement Footprint) (https://developers.google.com/earthengine/datasets/catalog/DLR_WSF_WSF2015_v1). Дополнительно в каждом классе исключаются участки площадью менее девяти пикселей и пограничные пиксели классов. После всех процедур карта «нарезается» на квадраты $1 \times 1^\circ$ и готовится в виде эталонных масок тематических классов для обучения моделей классификации.

Наилучшую модель классификации позволяет выбрать сравнительный анализ нескольких методов машинного обучения, включая логистическую регрессию (Рашка и др., 2024), линейный дискриминантный анализ, метод ближайших соседей, дерево решений (Breiman et al., 1984), ансамблевый метод Bagging Classifier, адаптивный и градиентный бустинги (Гудфеллоу и др., 2018; Рашка и др., 2024), случайный лес (*англ.* Random Forest) (Breiman, 2001) и ансамблевый метод с использованием стохастического градиентного спуска (Dorogush et al., 2018). Эталоны разделяются на обучающую и тестовую выборку в соотношении 0,75 к 0,25. Для обучающей выборки (0,75) проводится кросс-валидация, в процессе которой данные делятся на три равные части, каждая из которых поочередно используется в качестве обучающей, а оставшиеся две — тестовых. В результате трёх итераций определяются три оценки точности модели на основе отношения правильных предсказаний классов ко всем вариантам предсказаний, из которых рассчитывается среднее значение точности модели. Затем модель снова обучается по выборке и сравнивается с независимыми тестовыми данными (0,25). Дополнительно определяется коэффициент каппа Коэна. Для каждого квадрата формируется окружение спутниковых и эталонных наборов данных из восьми соседних квадратов, которые также классифицируются обученной моделью. Такая избыточность позволяет устранить краевые эффекты на границах квадратов при сборке карты на весь регион исследований. При анализе классов перекрывающихся квадратов используется правило, определяющее выбор класса на основе частоты его встречаемости, т. е. два и более раз.

Картографирование породной структуры лесов

Для формирования сети эталонных участков используются цифровые векторные слои с границами выделов лесоустройства 2015 г., которые нарезаются на квадраты $1 \times 1^\circ$ и фильтруются по нескольким критериям, а именно: покрытые лесом земли с относительной полнотой 0,3 и более; площадь выдела более 2 га; ненарушенные рубками и другими негативными факторами лесные участки по данным тематических продуктов GFC и насаждения с возрастом более 10 лет для лиственных и более 20 лет для хвойных пород.

В каждом прошедшем отбор лесном выделе в квадрате извлекается зональная статистика (медианное значение яркости) по шести спектральным каналам шести разносезонных композитных изображений (36 значений) и проводится аналогичный карте экосистем анализ нескольких методов машинного обучения для выбора наилучшего из них для задачи классификации древесных пород.

Для каждого классифицируемого квадрата формируется окружение спутниковых и эталонных наборов данных из восьми соседних квадратов по периметру. В обучении модели классификации древесных пород кроме целевого квадрата используются эталоны соседних квадратов в отношении 60 % выделов — целевой квадрат и 40 % выделов — соседние квадраты. Отбор выделов выполняется посредством анализа расстояний от центра целевого квадрата.

Перед обучением и классификацией проводится процедура балансировки выборки для классов с недостаточным или избыточным количеством выделов. Результатом классификации каждого квадрата становятся растровая карта преобладающих древесных пород и набор изображений со значениями вероятности распознавания каждой породы. При объединении квадратов в общее покрытие карты пород вероятность породы используется при анализе перекрывающихся пикселей соседних квадратов. Окончательно карта преобладающих древесных пород совмещается с картой растительности наземных экосистем для коррекции границы покрытых лесом территорий региона.

Пространственное моделирование возрастной структуры лесов

В качестве исходных данных используются нормализованные отношения спектральных каналов (индексов) разносезонных безоблачных композитных изображений и данные о возрасте древостоя из геопространственной базы данных лесной таксации на уровне выделов. Выделы объединяются в страты по диапазонам возраста с шагом в 10 лет (30–40, 40–50 и т. д.), для каждой из которых случайным образом отбираются 10 % выделов, полученные выборки выравниваются.

Анализ регрессионных моделей выполняется с использованием нескольких известных алгоритмов машинного обучения, а именно: ERT (*англ.* Extremely Randomized Trees) — экстремально рандомизированные деревья (Geurts et al., 2006), разновидность градиентного бустинга (Dorogush et al., 2018), метод опорных векторов (Cortes, Vapnik, 1995), RGLM (*англ.* Random Generalized Linear Model) — рандомизированные линейные модели (Song et al., 2013), а также объединение предсказаний всех четырёх названных алгоритмов методом взвешенного осреднения.

Автоматизированная настройка параметров алгоритмов и оценка их эффективности обучения проводится с помощью пространственной кросс-валидации. Для этого выделы обучающей выборки объединялись по принципу пространственной близости в десять групп равного размера, каждая из которой поочередно использовалась в качестве контрольной выборки, а остальные девять — обучающей. Стандартные статистические метрики эффективности регрессионного моделирования — коэффициент детерминации R^2 , средняя абсолютная ошибка MAE (*англ.* Mean Absolute Error), средняя абсолютная процентная ошибка MAPE (*англ.* Mean Absolute Percentage Error) и квадратный корень из средней квадратической ошибки RMSE (*англ.* Root Mean Square Error) — оцениваются для каждой из 10 конфигураций обучающей и контрольной выборки, после чего выбирается лучший алгоритм для моделирования возраста древостоев тестового региона. Показатели неопределённости моделирования — стандартная ошибка и 95%-й доверительный интервал предсказанных значений — оцениваются методами квантильной регрессии для случайных лесов (Meinshausen, 2006).

Пространственное моделирование запасов стволовой древесины

Моделирование запасов стволовой древесины лесов выполняется методом восстановления нелинейной регрессионной зависимости между спектральной яркостью в красном канале зимних безоблачных композитных изображений и таксационными характеристиками эталонных выделов (Сочилова, Ершов, 2012; Сочилова и др., 2018). Из базы данных таксации для каждой породы формируются страты выделов с шагом 5–10 м³/га, чтобы охватить весь диапазон значений. В каждом диапазоне случайным образом выбирается 10 % выделов, для которых определяются средние значения и стандартное отклонение SD (*англ.* Standard Deviation) спектрально-отражательной яркости в красном канале зимнего композитного изображения. Предварительно отобранная выборка выделов проверяется на спектральную однородность методом минимальных расстояний относительно среднего значения яркости в страте. Сформированная выборка выделов для каждой породы по всем диапазонам запаса-

сов объединяется по всем градусным квадратам и используется для построения экспоненциальных регрессионных зависимостей между спектральной яркостью красного канала и данными запасов эталонных участков. Коэффициенты уравнений применяются для пересчёта яркости в красном канале в запас стволовой древесины с генерацией растрового слоя этого показателя.

Картографирование относительной полноты и бонитета древостоев

Картографирование относительной полноты и классов бонитетов древостоев выполняется алгоритмом машинного обучения с использованием эталонной выборки, отобранной на этапе создания карты пород. Кроме спектральных каналов разносезонных безоблачных изображений в качестве независимых переменных используются карты породно-возрастной структуры лесов и запаса стволовой древесины, полученные на предыдущих этапах обработки. Это позволяет лучше настроить модель классификации. В региональных таблицах хода роста древесных пород оценка запаса стволовой древесины выполняется с учётом возраста насаждения, его относительной полноты и бонитета (Швиденко и др., 2008). Мы пытаемся решать обратную задачу пространственной оценки бонитета и полноты древостоя, имея информацию по запасам и породно-возрастной структуре лесов. Этапы обучения и настройки модели классификации выполняются стандартным способом с кросс-валидацией модели и независимой оценкой точности с помощью коэффициента каппа Коэна.

Пространственное моделирование фитомассы лесов

Фитомасса верхнего яруса лесов оценивается с помощью многомерных регионально-адаптированных регрессионных моделей. В качестве аналитической формулы используется регрессионная модель, опубликованная в работе Д. Г. Щепашенко с соавторами (Schepaschenko et al., 2018), по которой для каждой породы рассчитываются конверсионные коэффициенты перехода от запасов стволовой древесины к запасам фитомассы деревьев. Фитомасса нижних ярусов (подрост и подлесок) оценивается по моделям, предложенным А. З. Швиденко с соавторами (Швиденко и др., 2008). На вход моделей подаются характеристики древостоев в виде спутниковых тематических продуктов с пространственным разрешением 30 м (порода, средний возраст, бонитет, относительная полнота, запас) и таблицы породно-региональных коэффициентов уравнений.

Результаты и обсуждение

Тематические продукты с характеристиками лесов и запасов фитомассы древесного полога создаются по разносезонным безоблачным композитным изображениям спутников Landsat-8 и -9 (30 м) за период наблюдения с 2017 по 2021 г.

Подготовка эталонной и тестовых выборок, обучение моделей и *классификация растительности наземных экосистем* Костромской области выполняется по следующим тематическим классам карты WorldCover: 1) древесный покров; 2) кустарниковая растительность; 3) луговая растительность; 4) пахотные земли; 5) урбанизированные территории; 6) внутренние водоёмы и 7) водно-болотные угодья.

По лесотаксационной базе данных была сформирована эталонная и тестовая выборка для древесных пород региона: сосна, ель, дуб, берёза, осина, ольха, липа, ива.

В результате сравнения методов машинного обучения при классификации наземных экосистем и породной структуры было выявлено, что наилучшую результативность по точности и производительности демонстрирует ансамблевый метод Random Forest, который и был выбран (выделен в *табл. 1*).

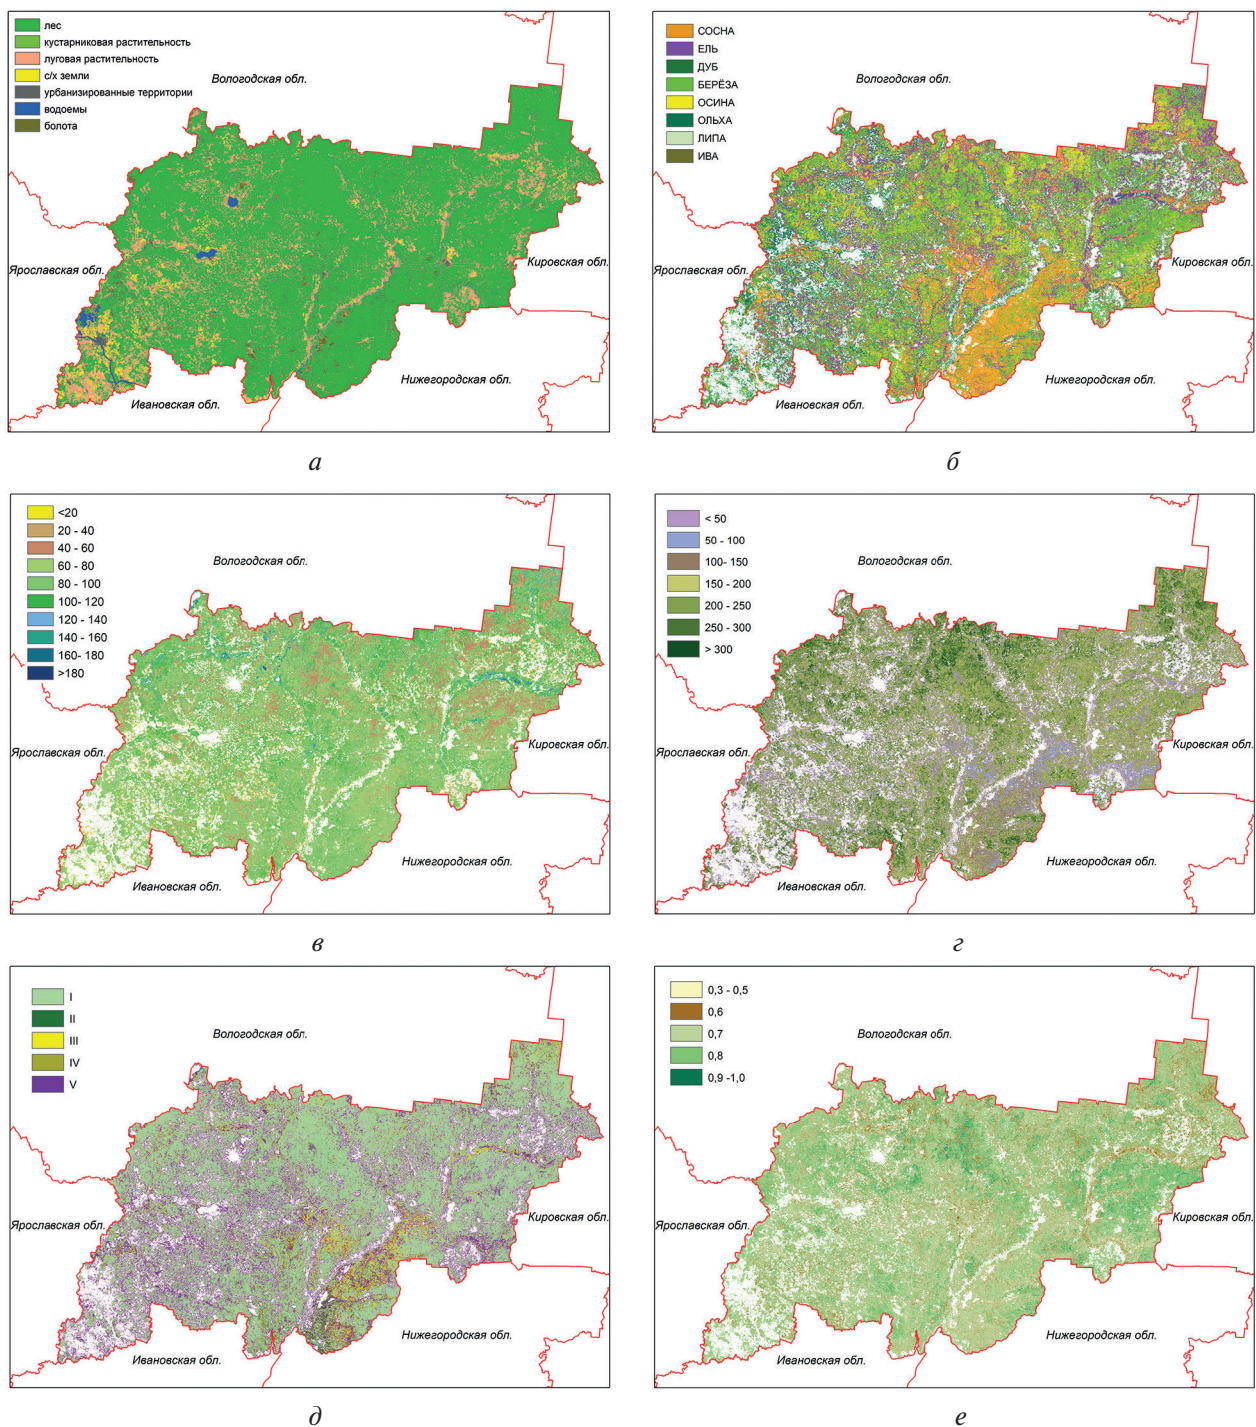


Рис. 1. Спутниковые тематические продукты характеристик лесов Костромской области по состоянию на 2021 г.: а — наземные экосистемы; б — древесные породы; в — средний возраст лесов; г — объём стволовой древесины (в м³/га); д — классы бонитета; е — относительная полнота древостоя

По результатам классификации наземных экосистем (рис. 1а) площадь лесов субъекта составляет 81,9 %, луговой растительности — 11,8 %, пахотных земель — 2,9 %, урбанизированных территорий — 1,9 %, водоёмов — 0,8 % и водно-болотных угодий — 0,7 %. Общая точность (англ. ассигасу) классификации всех классов наземных экосистем или доля всех правильных предсказаний классов от общего числа предсказаний равна 0,88. Доля правильно классифицированных классов среди всех классов, которые модель отнесла к конкретному классу (англ. precision), составляет 0,89. Доля правильно классифицированных классов среди всех реально существующих классов в контрольной выборке (англ. recall) равна 0,87.

Таблица 1. Результаты сравнения моделей классификации наземных экосистем и породной структуры лесов

Метод	Кросс-валидация		Точность на тестовых данных		Каппа Коэна на тестовых данных		Время обработки тестовых данных, мин	
	1	2	1	2	1	2	1	2
Логистическая регрессия	0,93	0,64	0,94	0,65	0,91	0,58	0,5	0,3
Линейный дискриминантный анализ	0,94	0,70	0,94	0,71	0,92	0,65	0,1	0,1
Метод ближайших соседей	0,96	0,66	0,98	0,77	0,97	0,72	2,8	1,7
Дерево решений	0,93	0,65	1,00	1,00	1,00	1,00	0,4	0,4
Bagging Classifier	0,96	0,74	0,87	1,00	0,84	1,00	26,3	22,7
Random Forest	0,96	0,74	1,00	1,00	1,00	1,00	2,8	2,4
Ada Boost	0,89	0,60	0,89	0,61	0,88	0,53	3,1	2,2
Gradient Boosting	0,95	0,72	0,96	0,76	0,96	0,71	45,0	35,3
Cat Boost	0,96	0,72	0,98	0,80	0,97	0,76	0,7	0,8

Примечание: 1 — карта наземных экосистем; 2 — карта породного состава; Bagging Classifier — ансамбль деревьев решений с использованием бэггинга; Random Forest — случайный лес; Ada Boost — адаптивный бустинг; Gradient Boosting — градиентный бустинг; Cat Boost — разновидность градиентного бустинга.

По результатам моделирования породной структуры лесов (см. рис. 1б) получено, что сосна занимает 18,6 % от лесного покрытия, ель — 17,7 %, берёза — 31,2 %, осина — 16,3 %, ольха — 15,7 %, дуб — 0,4 %, прочие породы — 0,1 %. Общая точность классификации всех классов карты древесных пород составляет 0,72. Доля правильно классифицированных классов среди всех классов равна 0,76, и доля правильно классифицированных классов среди всех реально существующих классов древесных пород — 0,66.

Для картографирования возрастной структуры лесов использовались отношения спектральных каналов или индексы разносезонных безоблачных композитных изображений. На этапе оценки информативности методом регрессионного анализа из 48 комбинаций отношений каналов было отобрано 20 индексов, которые использовались для проверки эффективности методов машинного обучения (табл. 2).

Таблица 2. Показатели эффективности различных методов машинного обучения при регрессионном моделировании возраста древостоев

Метод	R^2		MAE, лет		MAPE, %		RMSE, лет	
	RND	SYS	RND	SYS	RND	SYS	RND	SYS
Base	-0,055	-0,056	26,92	25,99	36,10	34,59	36,04	35,18
RGLM	0,116	0,077	23,26	23,42	29,97	30,21	32,23	32,44
ERT	0,429	0,367	18,58	19,04	23,14	23,66	26,07	26,90
CB	0,427	0,360	18,58	19,17	22,69	23,45	26,10	27,06
SVM	0,242	0,179	22,12	22,14	27,97	27,90	30,15	30,68
Avg	0,380	0,314	19,69	20,10	24,79	25,30	27,23	28,06

Примечание: RND — обучение по случайной выборке, SYS — обучение по систематической выборке, Base — базовая статистическая модель (всегда предсказывает среднее по выборке), RGLM — рандомизированные линейные модели, ERT — экстремально рандомизированные деревья, CB (англ. Catboost) — градиентный бустинг, SVM — метод опорных векторов, Avg — взвешенное осреднение предсказаний всех методов.

Окончательный выбор был сделан в пользу метода ERT из-за формально более высоких показателей R^2 и RMSE и относительно простого функционала.

В результате применения модели средний возраст древостоев (см. *рис. 1в*) региона составил 77 лет при стандартном отклонении 27 лет. Более 50 % площади всех лесов находятся в диапазоне от 60 до 95 лет, леса моложе 30 лет занимают немного более 10 % площади, а старше 100 лет — около 16 %. Средняя величина стандартной ошибки моделирования составила 27 лет (33 % от предсказанного значения), а средняя ширина 95%-го доверительного интервала — 106,5 лет (129 %).

Пространственное моделирование запаса стволовой древесины проводится с помощью коэффициентов экспоненциальной регрессии четырёх основных лесообразующих пород тестового региона: сосна, ель, берёза и осина. Для остальных пород не удалось сформировать достаточно устойчивую выборку, поэтому для прочих мягколиственных пород использовались модели осины. Для дуба моделирование запасов древесины не проводилось в силу малой распространённости этой породы (0,4 % территории лесного покрова). Коэффициент детерминации R^2 экспоненциальной связи спектральной яркости в красном канале с запасами для эталонных участков для берёзы равен 0,91, для осины и прочих мягколиственных пород — 0,85, для сосны — 0,78 и для ели — 0,82.

В результате моделирования средний запас древостоев региона составляет 180,8 м³/га при стандартном отклонении 94,5 м³/га, определены площади лесов региона со следующими диапазонами относительных объёмов стволовой древесины: менее 50 м³/га — 12,0 % площади лесов региона, 50–100 м³/га — 11,6 %, 100–150 м³/га — 16,7 %, 150–200 м³/га — 17,6 %, 200–250 м³/га — 15,1 %, 250–300 м³/га — 14,9 %, более 300 м³/га — 12,1 % (см. *рис. 1г*).

С помощью контрольных данных таксации проведена оценка точности результатов пространственного моделирования запаса стволовой древесины по красному зимнему каналу. Среднеквадратическая ошибка определения объёма стволовой древесины сосны составляет 45,6 м³/га, ели — 57,3 м³/га, 23,0 м³/га для берёзы и 53,6 м³/га для осины и прочих мягколиственных пород.

Классификации бонитетов (I–V) и относительной полноты древостоев (0,3–1,0) выполняются методом Random Forest по спектральным каналам и картам породно-возрастной структуры и запаса стволовой древесины лесов. Оценка точности моделирования бонитетов на тестовых данных показала, что доля правильных ответов — 0,681. Возрастная структура имеет наибольшее влияние на результат классификации бонитетов. По результатам моделирования получена карта бонитетов со следующим распределением по занимаемой площади лесов региона: I — 68,7 %; II — 2,7 %; III — 4,3 %; IV — 5,7 %; V — 19,2 % (см. *рис. 1д*). Оценка важности признаков классификации относительной полноты показала, что наибольший вклад в результат вносит коротковолновый канал SWIR1 для сезона «ранняя весна», доля правильных ответов — 0,457. По результатам моделирования создана карта относительной полноты древостоя с распределением по занимаемой площади: 0,3–0,4 — 1,4 %; 0,5 — 0,9 %; 0,6 — 11,6 %; 0,7 — 55,7 %; 0,8 — 27,3 %, 0,9–1 — 3,2 % (см. *рис. 1е*).

Полученные тематические карты характеристик лесов подаются на вход модели расчёта запасов фитомассы верхнего полога и подрост/подлеска (*рис. 2*, см. с. 225). Среднее значение наземной фитомассы древесного полога составляет 77,5 т/га при стандартном отклонении 61,7 т/га, подрост и подлеска — 2,9 т/га при стандартном отклонении 1,3 т/га. Для оценки точности результатов моделирования выполнены расчёты фитомассы для контрольных выделов по данным лесной таксации модельного региона.

Оценка точности спутникового продукта фитомассы лесов проводится с помощью независимого набора тестовых выделов, в границах которых определён запас фитомассы по тем же формулам, что использовались для спутниковых продуктов, но только на основе материалов лесной таксации. Тестовые выделы выбирались таким образом, чтобы выполнялись следующие условия: одна порода преобладает в выделе; порода в выделе совпадает по результатам классификации и по данным таксации; выдел не использовался в обучающих выборках; площадь выдела более 1 га и в выделе все пиксели принадлежат лесу.

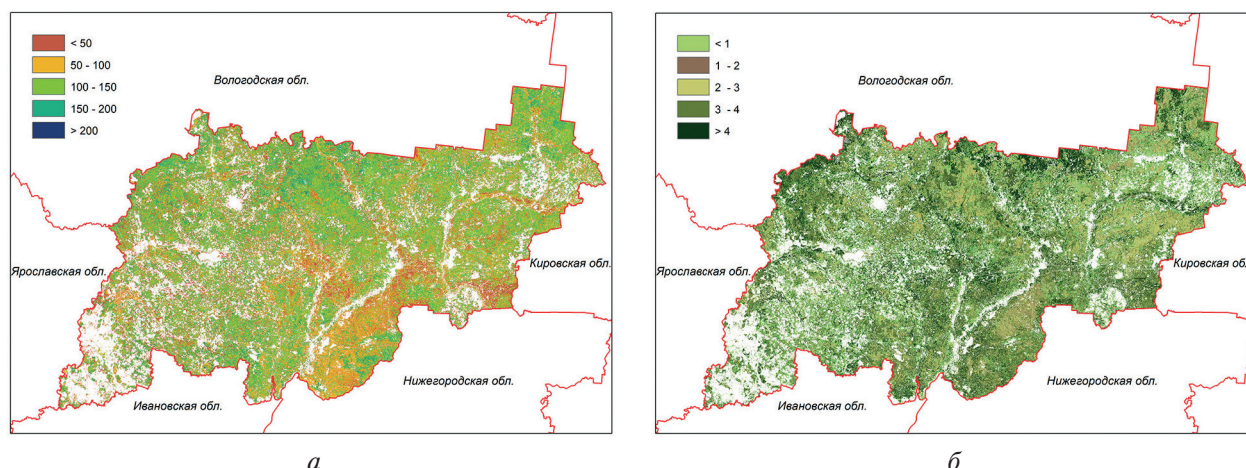


Рис. 2. Запасы фитомассы (в т/га) древостоя (а), подроста и подлеска (б) в лесах Костромской области по состоянию на 2021 г.

В результате сравнения двух наборов данных получены следующие оценки точности определения запасов фитомассы для основных преобладающих пород (табл. 3). Средняя абсолютная ошибка фитомассы по породам находится в диапазоне 22,63–27,21 т/га, для подроста и подлеска — 0,76 т/га. Наибольшая средняя абсолютная процентная ошибка приходится на сосну (31,6 %), наименьшая — на берёзу (20,9 %).

Таблица 3. Оценка точности определения запасов фитомассы древостоя

Преобладающая порода	Количество выделов	Средняя абсолютная ошибка MAE, т/га	Стандартное отклонение MAE (SD)	Средняя абсолютная процентная ошибка MAPE, %	Стандартное отклонение MAPE (SD)
Сосна	9155	27,21	23,69	31,6	20,7
Ель	2606	24,70	16,86	21,3	16,8
Берёза	1022	22,63	20,43	20,9	20,1
Осина	4648	22,90	16,14	21,4	16,9
Подрост, подлесок	11585	0,76	0,53	36,1	27,3




Рис. 3. Средняя абсолютная ошибка (в %) MAPE оценки фитомассы древостоя

Анализ результатов моделирования запасов фитомассы по породам показывает, что наибольшие ошибки MAPE сосредоточены в диапазоне до 50 т/га (рис. 3). Ошибки снижаются для средних и высоких диапазонов (50–100, 100–150 и выше 150 т/га), за исключением со-

сны обыкновенной. Ошибки пространственного моделирования запаса связаны в основном с особенностями формирования безоблачных композитов Landsat за период в несколько лет, во время которого существует вероятность негативных изменений растительного покрова (вырубки, пожары, ветровалы и т. п.). Другая возможная причина, как уже отмечалось ранее, это накопление ошибок моделирования по каждому производному спутниковому тематическому продукту характеристик лесов, использующихся при моделировании запаса фитомассы лесов. Величина эффекта накопления ошибок может быть оценена только при сравнении двух методов моделирования запасов с независимыми наземными наборами данных характеристик лесов, указанных в обзорной части статьи. Но это тема отдельного эксперимента, который планируется в дальнейшем авторами статьи на одном из модельных лесных участков Костромской области, где собран детальный наземный материал о характеристиках лесов на 30 пробных площадях, а также выполнена аэрофотосъёмка и воздушное лазерное сканирование древостоя в разной стадии сукцессий на тестовом полигоне площадью 4 км².

Заключение

В статье представлены результаты исследования возможностей применения разновременных безоблачных композитных спутниковых изображений высокого пространственного разрешения (30 м) для регионального картографирования запасов фитомассы древостоя, подроста и подлеска на примере Костромской области. Пространственная оценка проводится с использованием подхода, направленного на создание серии тематических продуктов с характеристиками лесов, которые затем применяются в расчётах фитомассы древостоев, подроста и подлеска модельного региона с пространственным разрешением 30 м.

Тематический продукт запасов фитомассы древостоя сравнивается с наборами данных фитомассы лесов, рассчитанных по независимым от классификации материалам лесной таксации контрольных выделов, отобранных случайным образом на территории лесного фонда Костромской области. В результате сравнения запас фитомассы древесного полога по спутниковым данным определяется со средней абсолютной ошибкой для основных лесообразующих пород (сосна, ель, берёза и осина) в диапазоне от 22,6 до 27,2 т/га на уровне таксационных выделов.

Таким образом, можно сделать вывод, что предложенный подход к оценке запасов фитомассы лесов с применением спутниковых данных высокого пространственного разрешения может использоваться на региональном уровне. Особое внимание необходимо уделять совершенствованию методов подготовки безоблачных композитных изображений, чтобы снизить степень неопределённости, связанной с изменениями в лесах в течение нескольких лет.

Отдельной задачей следует считать сравнение двух методов оценки запасов фитомассы с независимыми наборами наземных измерений характеристик лесов и данных беспилотной аэрофотосъёмки с целью определения величины эффекта накопления ошибок, вызванных использованием производных тематических продуктов с характеристиками лесов по спутниковым данным высокого пространственного разрешения.

Работа выполнена за счёт средств государственного задания по теме «Биоразнообразие и экосистемные функции лесов» (Регистрационный номер НИОКТР 124013000750-1).

Литература

1. *Барталев С. А., Егоров В. А., Жарко В. О., Лупян Е. А., Плотников Д. Е., Хвостиков С. А., Шабанов Н. В.* Спутниковое картографирование растительного покрова России. М.: ИКИ РАН, 2016. 208 с.
2. *Данилин И. М., Медведев Е. М., Абэ Н. И., Худак А. Т., Санкт-Онге Б.* Высокие технологии XXI века для аэрокосмического мониторинга и таксации лесов: Задачи исследований и перспективы использования// Лесная таксация и лесоустройство. 2005. Вып. 1(34). С. 28–38.
3. *Гаврилюк Е. А.* Геопространственное моделирование запасов углерода в древесном пуле на основе данных ДЗЗ при использовании обучающих выборок наземных измерений с пробных площадей

- разного типа // Материалы 22-й Международ. конф. «Современные проблемы дистанционного зондирования Земли из космоса». М.: ИКИ РАН, 2024. С. 170. DOI: 10.21046/22DZZconf-2024a.
4. *Гаврилюк Е. А.* Сравнительный анализ эффективности геопространственного моделирования запасов стволовой древесины и углерода древостоев на основе спутниковых данных и результатов воздушного лазерного сканирования // Материалы 9-й Всероссийской науч. конф. с международ. участием «Аэрокосмич. методы и геоинформац. технологии в лесоведении, лесном хозяйстве и экологии». М.: ЦЭПЛ РАН, 2025. С. 23–25.
 5. *Гаврилюк Е. А., Королева Н. В., Карпущина Д. А. и др.* 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.
 6. *Гудфеллоу Я., Бенджио И., Курвилль А.* Глубокое обучение: пер. с англ.; 2-е изд. М.: ДМК Пресс. 2018. 652 с.
 7. *Ершов Д. В., Сочилова Е. Н., Королева Н. В.* Методические подходы к картографированию лесных горючих материалов // Вопросы лесной науки. 2023. Т. 6. № 2. 128 с. DOI: 10.31509/2658-607x-202362-128.
 8. *Замолодчиков Д. Г., Уткин А. И., Честных О. В.* Коэффициенты конверсии запасов насаждений в фитомассу для основных лесобразующих пород России // Лесная таксация и лесоустройство. 2003. Вып. 1(32). С. 119–127.
 9. *Замолодчиков Д. Г., Уткин А. И., Коровин Г. Н.* Конверсионные коэффициенты фитомасса/запас в связи с дендрометрическими показателями и составом древостоев // Лесоведение. 2005. № 6. С. 73–81.
 10. *Кузьмичев Е. П., Трушина И. Г., Трушина Н. И.* Основные методические подходы к оценке экосистемных услуг в зарубежных странах: обзор проблемы // Лесохозяйственная информация. 2021. № 1. С. 144–164. DOI: 10.24419/LHI.2304-3083.2021.1.10.
 11. *Медведев Е. М., Данилин И. М., Мельников С. Р.* Лазерная локация земли и леса: учеб. пособие; 2-е изд., перераб. и доп. М.: Геолитар, Геокосмос; Красноярск: Институт леса им. В. Н. Сукачева СО РАН, 2007. 230 с.
 12. *Михайлов В. В., Спесивцев А. В., Соболевский В. А. и др.* Многомодельное оценивание динамики фитомассы растительных сообществ тундры на основе спутниковых снимков // Исслед. Земли из космоса. 2021. № 2. С. 15–30. DOI: 10.31857/S0205961421020056.
 13. *Рашка С., Лю Ю., Мирджалили В.* Машинное обучение с PyTorch и Scikit-Learn; пер. с англ. Астана: Фолиант, 2024. 688 с.
 14. *Сочилова Е. Н., Ершов Д. В.* Анализ возможности определения запасов древесных пород по спутниковым данным Landsat ETM // Современные проблемы дистанционного зондирования Земли из космоса. 2012. Т. 9. № 3. С. 277–282.
 15. *Сочилова Е. Н., Сурков Н. В., Ершов Д. В., Хамедов В. А.* Оценка запасов фитомассы лесных пород по спутниковым изображениям высокого пространственного разрешения (на примере лесов Ханты-Мансийского АО) // Вопросы лесной науки. 2018. Т. 1. № 1. 22 с. DOI: 10.31509/2658-607X-2018-1-1-1-23.
 16. *Усольцев В. А.* Фитомасса модельных деревьев лесобразующих пород Евразии: база данных, климатически обусловленная география, таксационные нормативы. Екатеринбург: Уральский гос. лесотехн. ун-т, 2016. 338 с.
 17. *Швиденко А. З., Шепашенко Д. Г., Нильссон С., Булуй Ю. И.* Таблицы и модели хода роста и продуктивности насаждений основных лесобразующих пород Северной Евразии (нормативно-справочные материалы); 2-е изд., доп. М.: Федер. агентство лесного хоз-ва, 2008. 886 с.
 18. *Шепашенко Д. Г., Мухортова Л. В., Швиденко А. З., Ведрова Э. Ф.* Запасы органического углерода в почвах России // Почвоведение. 2013. № 2. С. 123–132. DOI: 10.7868/S0032180X13020123.
 19. *Шепашенко Д. Г., Швиденко А. З., Пергер К. и др.* Изучение фитомассы лесов: текущее состояние и перспективы // Сибирский лесной журн. 2017. № 4. С. 3–11. DOI: 10.15372/SJFS20170401.
 20. *Breiman L.* Random Forests // Machine Learning. 2001. V. 45. No. 1. P. 5–32. DOI: 10.1023/A:1010933404324.
 21. *Breiman L., Friedman J., Olshen R. A., Stone C. J.* Classification and regression trees. N.Y.: Chapman and Hall/CRC, 1984. 368 p. DOI: 10.1201/9781315139470.
 22. *Cortes C., Vapnik V.* Support-vector networks // Machine Learning. 1995. V. 20. No. 3. P. 273–297. DOI: 10.1023/A:1022627411411.
 23. *Dorogush A. V., Ershov V., Gulin A.* CatBoost: gradient boosting with categorical features support // <https://arxiv.org/>. arXiv:1810.11363. 2018. 7 p. DOI: 10.48550/arXiv.1810.11363.
 24. *Geurts P., Ernst D., Wehenkel L.* Extremely randomized trees // Machine Learning. 2006. V. 63. No. 1. P. 3–42. DOI: 10.1007/s10994-006-6226-1.
 25. *Gorelick N., Hancher M., Dixon M. et al.* Google Earth Engine: Planetary-scale geospatial analysis for everyone // Remote Sensing of Environment. 2017. V. 202. P. 18–27. DOI: 10.1016/j.rse.2017.06.031.

26. Hansen M. C., Potapov P. V., Moore R. et al. High-resolution global maps of 21st-century forest cover change // *Science*. 2013. V. 342. P. 850–853. DOI: 10.1126/science.1244693.
27. Jos G., Mansor S., Matthew N. K. A review: Forest Aboveground Biomass (AGB) estimation using satellite remote sensing // *J. Remote Sensing and GIS*. 2021. V. 10. Iss. 8. Article 1000P241.
28. Meinshausen N. Quantile Regression Forests // *J. Machine Learning Research*. 2006. No. 7. P. 983–999.
29. Santoro M., Beaudoin A., Beer C. et al. Forest growing stock volume of the northern hemisphere: Spatially explicit estimates for 2010 derived from Envisat ASAR // *Remote Sensing of Environment*. 2015. V. 168. P. 316–334. <https://doi.org/10.1016/j.rse.2015.07.005>.
30. Schepaschenko D., Moltchanova E., Shvidenko A. et al. Improved estimates of biomass expansion factors for Russian forests // *Forests*. 2018. V. 9. No. 6. Article 312. DOI: 10.3390/f9060312.
31. Shvidenko A., Mukhortova L., Kapitsa E. et al. A modelling system for dead wood assessment in the forests of Northern Eurasia // *Forests*. 2023. V. 14. No. 1. Article 45. DOI: 10.3390/f14010045.
32. Song L., Langfelder P., Horvath S. Random generalized linear model: a highly accurate and interpretable ensemble predictor // *BMC Bioinformatics*. 2013. V. 14. Article 5. DOI: 10.1186/1471-2105-14-5.
33. Thurner M., Beer C., Santoro M. et al. Carbon stock and density of northern boreal and temperate forests // *Global Ecology and Biogeography*. 2014. V. 23. Iss. 3. P. 297–310. DOI: 10.1111/geb.12125.
34. Tian L., Wu X., Tao Y. et al. Review of remote sensing-based methods for forest aboveground biomass estimation: Progress, challenges, and prospects // *Forests*. 2023. V. 14. No. 6. Article 1086. DOI: 10.3390/f14061086.

Spatial modeling of aboveground forest biomass from high-resolution satellite data (Kostroma Region case study)

E. N. Sochilova, D. V. Ershov, E. I. Belova,
E. A. Gavriluk, N. V. Koroleva, S. V. Knyazeva

Isaev Centre for Forest Ecology and Productivity RAS, Moscow 117997, Russia
E-mail: elena@ifj.rssi.ru

Assessment and monitoring of forest biomass dynamics is an urgent task for studying forest ecosystem functions and services at different spatial levels. We present our method and results of spatial modeling of aboveground biomass based on key taxation forest characteristics for Kostroma Region. For taxation data mapping, Landsat-8 and -9 multi-season cloudless composite images of 2017–2021 are used. A. Shvidenko's and D. Schepaschenko's regression models (published between 2008 and 2023) for calculating the aboveground biomass of stand, undergrowth, and shrubs are applied. Model input data are thematic products of the average stand age, relative stand index, forest site index, and stem wood volume of the dominated tree species of the test region, for which aboveground biomass is calculated in each pixel with a spatial resolution of 30 m. The Random Forest machine-learning algorithm using satellite images performs classification of land cover, dominated tree species, average stand age, relative stand index and forest site index of the region. The volume of stem wood is estimated using the method of nonlinear regression relationships between the spectral reflectance of forest stands in winter cloudless composite Landsat images in the red channel and their taxation characteristics. The classifier is trained using a spatial forest inventory database current as of 2015. The accuracy of the satellite-based forest biomass product is evaluated using an independent set of taxation data plots with known aboveground forest biomass. As a result of comparing two data sets, the mean absolute error (MAE) of biomass by species is in the range of 22.63–27.21 t/ha. The highest mean absolute percentage error (MAPE) is for pine (31.6 %), the lowest is for birch (20.9 %).

Keywords: regional forest mapping, forest characteristics based on remote sensing data, forest biomass reserves, Random Forest, Kostroma Region

Accepted: 27.01.2026

DOI: 10.21046/2070-7401-2026-23-2-216-230

References

1. Bartalev S. A., Egorov V. A., Zharko V. O., Loupian E. A., Plotnikov D. E., Khvostikov S. A., Shabanov N. V., *Sputnikovoe kartografirovaniye rastitel'nogo pokrova Rossii* (Land cover mapping over Russia using Earth observation data), Moscow: IKI RAN, 2016, 208 p. (in Russian).
2. Danilin I. M., Medvedev E. M., Abe N. I., Khudak A. T., Sankt-Onge B., High technologies of the 21st century for aerospace monitoring and forest taxation: Research objectives and use prospects, *Lesnaya taksatsiya i lesoustroistvo*, 2005, Iss. 1(34), pp. 28–38 (in Russian).
3. Gavrilyuk E. A., Geospatial modeling of woody pool carbon stocks using remote sensing data and training samples from different types of ground-based sample plots, *Materialy 22-i Mezhdunarodnoi konferentsii "Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa"* (Proc. 22nd Intern. Conf. "Current Problems in Remote Sensing of the Earth from Space"), Moscow: IKI RAN, 2024, p. 170 (in Russian), DOI: 10.21046/22DZZconf-2024a.
4. Gavrilyuk E. A., Comparative analysis of the effectiveness of geospatial modeling for stem wood volume and stand carbon stock using satellite data and airborne laser scanning results, *Materialy 9-i Vserossiiskoi nauchnoi konferentsii s mezhdunarodnym uchastiem "Aehrokosmicheskie metody i geoinformatsionnye tekhnologii v lesovedenii, lesnom khozyaistve i ehkologii"* (Proc. 9th All-Russia Scientific Conf. with Intern. Participation "Aerospace Methods and Geoinformation Technologies in Forestry, Forestry Management, and Ecology"), Moscow: TsEhPL RAN, 2025, pp. 23–25 (in Russian).
5. Gavrilyuk E. A., Koroleva N. V., Karpukhina D. A. et al., 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.
6. Goodfellow I., Bengio Y., Courville A., *Deep Learning*, MIT Press, 2016, 802 p.
7. Ershov D. V., Sochilova E. N., Koroleva N. V., Methodological approaches to mapping forest fuels, *Voprosy lesnoi nauki*, 2023, V. 6, No. 2, 128 p. (in Russian), DOI: 10.31509/2658-607x-202362-128.
8. Zamolodchikov D. G., Utkin A. I., Chestnyh O. V., Conversion factors of forest stocks volumes in biomass for the main dominated forest species of Russia, *Lesnaya taksatsiya i lesoustroistvo*, 2003, Iss. 1(32), pp. 119–127 (in Russian).
9. Zamolodchikov D. G., Utkin A. I., Korovin G. N., Conversion coefficients phytomass/reserves related to dendrometric parameters and stand composition, *Lesovedenie*, 2005, No. 6, pp. 73–81 (in Russian).
10. Kuzmichev E. P., Trushina I. G., Trushina N. I., Key methodological approaches to assess ecosystem services in foreign states: Overview of the problem, *Forestry information*, 2021, No. 1, pp. 144–164 (in Russian), DOI: 10.24419/LHI.2304-3083.2021.1.10.
11. Medvedev E. M., Danilin I. M., Melnikov S. R., *Lazernaya lokatsiya zemli i lesa: uchebnoe posobie* (Laser location of land and forest: Training manual), 2nd ed., Moscow: Geolidar, Geocosmos; Krasnoyarsk: V. N. Sukachev Institute of Forest SB RAS, 2007, 230 p. (in Russian).
12. Mikhailov V. V., Spesivtsev A. V., Sobolevsky V. A. et al., Multi-model evaluation of phytomass dynamics of tundra plant communities based on satellite images, *Issledovaniya Zemli iz kosmosa*, 2021, No. 2, pp. 15–30 (in Russian), DOI: 10.31857/S0205961421020056.
13. Raschka S., Liu Y. (H.), Mirjalili V., *Machine Learning with PyTorch and Scikit-Learn*, Birmingham: Packt, 2022, 741 p.
14. Sochilova E. N., Ershov D. V., Possibility analysis of stem volume of forests assessment using Landsat ETM data, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2012, V. 9, No. 3, pp. 277–282 (in Russian).
15. Sochilova E. N., Surkov N. V., Ershov D. V., Khamedov V. A., 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*, 2019, V. 2, No. 2, 19 p., DOI: 10.31509/2658-607X-2019-2-2-1-20.
16. Usoltsev V. A., *Fitomassa model'nykh derev'ev lesoobrazuyushchikh porod Evrazii: baza dannykh, klimaticheski obuslovlennaya geografiya, taksatsionnye normativy* (Single-tree biomass of forest-forming species in Eurasia: database, climate-related geography, mensuration standards), Ekaterinburg: Ural State Forest Engineering University, 2016, 338 p. (in Russian)
17. Shvidenko A. Z., Schepaschenko D. G., Nil'sson S., Buluj Yu. I., *Tablitsy i modeli khoda rosta i produktivnosti nasazhdenii osnovnykh lesoobrazuyushchikh porod Severnoi Evrazii (normativno-spravochnye materialy)* (Tables and models of growth and productivity of forests of major forest forming species of Northern Eurasia (standard and reference materials)), Moscow: Federal'noe agentstvo lesnogo khozyaistva, 2008, 886 p. (in Russian).
18. Schepaschenko D. G., Mukhortova L. V., Shvidenko A. Z., Vedrova E. F., The pool of organic carbon in the soils of Russia, *Eurasian Soil Science*, 2013, V. 46, No. 2, pp. 107–116, DOI: 10.1134/S1064229313020129.
19. Schepaschenko D. G., Shvidenko A. Z., Perger C. et al., Forest biomass observation: Current state and perspective, *Sibirskii lesnoi zhurnal*, 2017, No. 4, pp. 3–11 (in Russian), DOI: 10.15372/SJFS20170401.

20. Breiman L., Random forests, *Machine Learning*, 2001, V. 45, No. 1, pp. 5–32, DOI: 10.1023/A:1010933404324.
21. Breiman L., Friedman J., Olshen R. A., Stone C. J., *Classification and regression trees*, New York: Chapman and Hall/CRC, 1984, 368 p., DOI: 10.1201/9781315139470.
22. Cortes C., Vapnik V., Support-vector networks, *Machine Learning*, 1995, V. 20, No. 3, pp. 273–297, DOI: 10.1023/A:1022627411411.
23. Dorogush A. V., Ershov V., Gulin A., CatBoost: gradient boosting with categorical features support, <https://arxiv.org/>, arXiv:1810.11363, 2018, 7 p., DOI: 10.48550/arXiv.1810.11363.
24. Geurts P., Ernst D., Wehenkel L., Extremely randomized trees, *Machine Learning*, 2006, V. 63, No. 1, pp. 3–42, DOI: 10.1007/s10994-006-6226-1.
25. Gorelick N., Hancher M., Dixon M. et al., Google Earth Engine: Planetary-scale geospatial analysis for everyone, *Remote Sensing of Environment*, 2017, V. 202, pp. 18–27, DOI: 10.1016/j.rse.2017.06.031.
26. Hansen M. C., Potapov P. V., Moore R. et al., High-resolution global maps of 21st-century forest cover change, *Science*, 2013, V. 342, pp. 850–853, DOI: 10.1126/science.1244693.
27. Jos G., Mansor S., Matthew N. K., A review: Forest Aboveground Biomass (AGB) estimation using satellite remote sensing, *J. Remote Sensing and GIS*, 2021, V. 10, Iss. 8, Article 1000P241.
28. Meinshausen N., Quantile Regression Forests, *J. Machine Learning Research*, 2006, No. 7, pp. 983–999.
29. Santoro M., Beaudoin A., Beer C. et al., Forest growing stock volume of the northern hemisphere: Spatially explicit estimates for 2010 derived from Envisat ASAR, *Remote Sensing of Environment*, 2015, V. 168, pp. 316–334, <https://doi.org/10.1016/j.rse.2015.07.005>.
30. Schepaschenko D., Moltchanova E., Shvidenko A. et al., Improved estimates of biomass expansion factors for Russian forests, *Forests*, 2018, V. 9, No. 6, Article 312, DOI: 10.3390/f9060312.
31. Shvidenko A., Mukhortova L., Kapitsa E. et al., A modelling system for dead wood assessment in the forests of Northern Eurasia, *Forests*, 2023, V. 14, No. 1, Article 45, DOI: 10.3390/f14010045.
32. Song L., Langfelder P., Horvath S., Random generalized linear model: a highly accurate and interpretable ensemble predictor, *BMC Bioinformatics*, 2013, V. 14, Article 5, DOI: 10.1186/1471-2105-14-5.
33. Thurner M., Beer C., Santoro M. et al., Carbon stock and density of northern boreal and temperate forests, *Global Ecology and Biogeography*, 2014, V. 23, Iss. 3, pp. 297–310, DOI: 10.1111/geb.12125.
34. Tian L., Wu X., Tao Y. et al., Review of remote sensing-based methods for forest aboveground biomass estimation: Progress, challenges, and prospects, *Forests*, 2023, V. 14, No. 6, Article 1086, DOI: 10.3390/f14061086.