

<https://doi.org/10.25686/foreco.2024.38.64.010>

УДК 528.88

ОЦЕНКА ДИНАМИКИ НАЗЕМНОЙ ФИТОМАССЫ ЛЕСОВ ПЕНЗЕНСКОЙ ОБЛАСТИ С ИСПОЛЬЗОВАНИЕМ АЛГОРИТМА МАШИННОГО ОБУЧЕНИЯ

Д.М. Дергунов

Поволжский государственный технологический университет

В статье исследована динамика наземной фитомассы лесов Пензенской области за период с 1985 по 2023 год с использованием спутниковых данных Landsat. Основное внимание уделяется разработке и оценке алгоритма Random Forest (RF) на платформе Google Earth Engine (GEE) для создания карт фитомассы. В ходе исследования были проведены полевые измерения, а спутниковые снимки прошли калибровку и спектральное выравнивание. Результаты показали общий рост фитомассы лесов за исследуемый период, особенно заметный в хвойных и лиственных насаждениях. Фитомасса хвойных насаждений увеличилась на 35,1 млн. тонн, а лиственных - на 50,9 млн. тонн. Общая фитомасса лесов Пензенской области увеличилась с 86 млн. тонн в 1985 году до 180 млн. тонн в 2023 году, несмотря на временное снижение в 2010 году из-за лесных пожаров и засухи. Отмечены ограничения, связанные с эффектом насыщения при использовании оптических данных, что снижает точность оценки фитомассы в районах с плотным лесным покровом. Тем не менее, предложенный метод продемонстрировал свою эффективность для мониторинга и оценки фитомассы лесов на больших территориях, предоставляя важные данные для разработки стратегий охраны и восстановления лесных насаждений.

Ключевые слова: наземная фитомасса, спутниковые снимки, дистанционное зондирование, машинное обучение, Random Forest, ГИС, Google Earth Engine, Landsat.

ASSESSMENT OF ABOVE GROUND PHYTOMASS DYNAMICS IN THE FORESTS OF THE PENZA REGION USING MACHINE LEARNING ALGORITHM

D.M. Dergunov

Volga State University of Technology

The article analyzes the dynamics of aboveground forest phytomass in the Penza region from 1985 to 2023 using remote sensing technologies. The study aims to develop and evaluate the effectiveness of the Random Forest (RF) algorithm on the Google Earth Engine (GEE) platform to generate phytomass maps based on Landsat satellite data. Field measurements and satellite images were used to calibrate and validate the model. The results demonstrated an overall increase in forest phytomass over the study period, particularly in coniferous and deciduous stands. For example, the phytomass of coniferous stands increased by 35.1 million tons, and deciduous stands by 50.9 million tons. The total forest phytomass of the Penza region increased from 86 million tons in 1985 to 180 million tons in 2023, despite a temporary decrease in 2010 due to forest fires and drought. However, the study notes limitations related to the saturation effect when using optical data, which reduces the accuracy of phytomass estimates in densely forested areas. Nevertheless, the proposed approach has proven effective for monitoring and assessing forest phytomass over large areas, providing valuable data for developing strategies for forest resources protection and restoration.

Keywords: aboveground phytomass, satellite images, remote sensing, machine learning, Random Forest algorithm, GIS, Google Earth Engine, Landsat.

Введение

Леса играют ключевую роль в поддержании экологического баланса планеты, выполняя функции углеродных депо, регулируя климатические процессы и обеспечивая биоразнообразие. Оценка надземной фитомассы является важным аспектом мониторинга состояния лесных экосистем, поскольку она позволяет оценить запасы древесины, углерода и других важных ресурсов (Курбанов, 2002; Курбанов, 2009; Rockström et al., 2017). Традиционные методы оценки фитомассы, такие как наземные измерения и инвентаризация, являются трудоемкими и дорогостоящими, особенно при работе с большими территориями.

Традиционные методы оценки фитомассы в основном основаны на таксационных данных, таких как диаметр на высоте груди и высота дерева, которые комбинируются с аллометрическими уравнениями для расчета фитомассы различных видов деревьев. Общая фитомасса на региональном уровне определяется путем суммирования фитомассы различных насаждений. Однако такие методы сталкиваются с проблемами, включая трудоемкость и задержки в обновлении данных (Crosby et al., 2017; Усольцев, 2018; Puliti et al., 2021; Румянцев и др., 2024). В то же время развивающиеся технологии дистанционного зондирования (ДЗЗ) предлагают преимущества, такие как длительный период наблюдений, значительный пространственный охват территории и использование различных сенсоров, что делает их важным инструментом для оценки фитомассы леса в сочетании с наземными измерениями. Методы ДЗЗ обеспечивают непрерывный мониторинг лесов с периодическим временным разрешением, что особенно важно для больших и труднодоступных территорий (Lee et al., 2020, Sa et al., 2024). В настоящее время для оценки фитомассы используются данные с оптических и микроволновых радаров, лидаров и аэрофотоснимков, при этом оптические и радарные являются наиболее распространенными.

Оценка фитомассы с использованием ДЗЗ в основном базируется на эмпирических моделях, включая параметрические и непараметрические алгоритмы. Параметрические модели просты в использовании и обеспечивают четкую взаимосвязь, что делает их востребованными в различных экологических приложениях. Однако они основаны на предположении о нормальном распределении и зависят от статистической надежности, что ограничивает их точность при описании сложных взаимосвязей между фитомассой и спутниковыми данными (Ronoud et al., 2019; Mutti et al., 2019). В дополнение к параметрическим методам, таким как линейные и нелинейные модели, непараметрические алгоритмы машинного обучения ML (*англ.* Machine Learning) становятся распространенным решением для преодоления этих ограничений (Akhtar et al., 2020).

Оценка фитомассы с использованием непараметрических алгоритмов отличается от параметрических тем, что не требует предопределенной структуры модели и не основывается на предположениях о распределении вероятностей и корреляции входных данных (López-Serrano et al., 2020). Благодаря своей гибкости и способности интегрировать множество факторов, непараметрические алгоритмы более эффективны в создании сложных нелинейных моделей биомассы, что приводит к более точным результатам оценки (Han et al., 2021). В современных исследованиях активно применяются различные алгоритмы машинного обучения для оценки фитомассы, включая метод опорных векторов SVM (*англ.* Support Vector Machines) (Souza et al., 2019), случайный лес RF (*англ.* Random Forest) (Bispo et al., 2020; Benmokhtar et al., 2021), стохастический градиентный бустинг SGB (*англ.* Stochastic gradient descent) (Ghosh, Behera, 2018).

Исследования, использующие ДЗЗ для оценки фитомассы, часто сталкиваются с проблемой недооценки высоких значений и переоценки низких (Lu et al., 2016). Прогнозирование характеристик лесного покрова с помощью оптического ДЗЗ осложняется из-за эффекта насыщения сигналов, что снижает точность результатов. Эта проблема особенно выражена на участках с плотным лесным покровом, поскольку оптические сенсоры регистрируют только информацию о верхней части крон деревьев. Для уменьшения данного эффекта рекомендуется использовать индексы растительности, основанные на красном спектре, а также включать спутниковые данные, содержащие информацию о вертикальной структуре леса (Frampton et al., 2013, Yu et al., 2023).

Исследования показывают, что модели RF обладают высокой устойчивостью к выбросам и шуму, а также обеспечивают надежные результаты. Например, в Китае была улучшена оценка лесной фитомассы за счет объединения данных национальной лесной инвентаризации и снимков Landsat 8 с использованием линейной регрессии, RF и XGBoost (Li et al., 2019). Результаты подчеркнули важность выбора переменных и эффективность машинного обучения, особенно модели RF, для точного моделирования фитомассы в зависимости от типа леса. Другие исследователи также подтвердили, что сочетание данных Landsat 8 с моделями RF и оптимизированными переменными позволяет проводить точное картографирование фитомассы в Буркина-Фасо (Karlson et al., 2015). В другом исследовании была достигнута высокая точность оценки лесной фитомассы в различных экосистемах с помощью модели RF, многоспектральных спутниковых данных и современных методов выбора переменных. Эти подходы эффективно характеризуют распределение и сложность структуры лесного покрова (Purohit et al., 2021). Учитывая надежность и точность, модель RF является предпочтительным методом обучения для оценки фитомассы лесных экосистем.

Целью данного исследования было провести мониторинг и оценить фитомассу лесного покрова Пензенской области в период с 1985 по 2023 годы с использованием алгоритма RF в облачном сервисе Google Earth Engine (GEE).

Областью исследования была Пензенская область площадью 43358 км². Лесной покров составляет 1477743 га (34 %), сельскохозяйственные земли занимают 2104601 га (48 %), трава и кустарники – 602944 га (14 %), населенные пункты – 114885 га (2,6 %), а водные объекты – 31018 га (0,7 %).

Материалы и методы

Общий алгоритм работ представлен на рис. 1.




Рис. 1. Алгоритм работ

Данные полевых измерений

Полевые работы проводились с июня по август 2023 года, в ходе которых были собраны данные с 100 пробных площадей. Тестовые участки были выбраны на основе 600 спутниковых снимков высокого разрешения и данных лесоустройства. Эти данные были случайным образом распределены на обучающие и проверочные наборы в пропорции 70/30 %. Каждый участок, размером 30 м × 30 м, соответствовал разрешению снимков Landsat, а местоположение его центральной точки фиксировалось с помощью GPS. Для каждого участка были измерены диаметр (в см) и высота дерева (в м) с использованием мерной вилки и лазерного высотомера. На основе полученных данных была рассчитана фитомасса древостоя на 1 га с применением конверсионных коэффициентов (Курбанов, 2002; Замоладчиков и др., 2003, 2005). В зависимости от возраста и породного состава насаждений полученные значения фитомассы для полевых участков варьировались от 10 до 250 т/га.

Распределение различных типов леса по территории исследования

Для создания карт распределения типов лесов в Пензенской области использовались спутниковые снимки Landsat (5, 7, 8, 9 TM, ETM+ и OLI) Collection 2 Tier 1 Top-Of-Atmosphere (TOA), на которых были удалены облака и созданы медианные композиты. Обработка спутниковых проводилась методом Tasseled Cap («Колпачок с кисточкой»), который разделяет мультиспектральные данные на три составляющие: «яркость», «зелень» и «влажность». Этот метод позволяет выровнять спектральные показатели изображений, полученных в разные фенологические стадии растительности (с мая по август), что обеспечивает лучшую дифференциацию типов земного покрова и облегчает подробный анализ состояния лесов (Курбанов и др., 2015).

Для классификации применялся алгоритм кластеризации «wekaKMeans» в GEE, который представляет собой усовершенствованную версию метода k-средних (англ. K-means) — одного

из самых популярных методов кластеризации. Этот алгоритм извлекает начальные средние значения кластеров из случайных выборок. Изначально классификация проводилась на 25 кластеров. Далее кластеры были перегруппированы методом экспертной оценки с помощью снимков высокого разрешения, данных полевых исследований и данных лесоустройства в 8 классов лесного покрова: хвойные спелые леса, хвойные средневозрастные леса, лиственные спелые леса, лиственные средневозрастные леса, смешанные спелые леса, смешанные средневозрастные леса, молодняки, непокрытые лесом земли. Таким образом созданы тематические карты за период 1985-2023 с шагом в пять лет.

Для оценки точности карт лесного покрова применялись стандартные статистические методы. Рассчитывались следующие оценочные метрики: матрица ошибок, точность производителя (РА), точность пользователя (UA), общая точность классификации (OA), оценка F-меры и коэффициент Каппа (Курбанов и др., 2015). Тестирование проводилось на основе данных, собранных в результате полевых исследований, а также информации, полученной из открытых спутниковых карт и снимков.

Данные дистанционного зондирования

Для анализа динамики фитомассы в разные периоды времени использовались данные спутниковых датчиков Landsat Level 2, Collection 2, Tier 1 Surface Reflectance (SR), доступные в облаке GEE за период с 1985 по 2023 год для Пензенской области. В частности, были использованы коллекции изображений: LANDSAT/LT05/C02/T1_L2, LANDSAT/LE07/C02/T1_L2, LANDSAT/LC08/C02/T1_L2 и LANDSAT/LC09/C02/T1_L2 за 1985–2023 гг. Все изображения Landsat SR прошли атмосферную коррекцию в GEE. Каждое изображение содержит шесть спектральных каналов с разрешением 15 метров для панхроматического диапазона и 30 метров для остальных каналов. Для повышения качества изображений Landsat применялась функция filterMetadata для выбора изображений с облачностью менее 20%. В результате, с 1985 по 2023 год было отобрано 405 изображений Landsat (с облачностью менее 20%) с интервалом в 5 лет (табл. 1).

Таблица 1. Спутниковые изображения, используемые в исследовании

Спутники	Год	Количество снимков
Landsat 5 ID=LANDSAT/LT05/C02/T1_L2	1985	33
	1990	18
	1995	38
	2000	5
	2005	18
	2010	51
Landsat 7 ID=LANDSAT/LE07/C02/T1_L2	2000	28
	2005	34
	2010	37
Landsat 8 ID= LANDSAT/LC08/C02/T1_L2	2015	49
	2020	35
	2023	22
Landsat 9 ID=LANDSAT/LC09/C02/T1_L2	2023	37

После выбора спутниковых данных за необходимый период в GEE были выполнены операции по удалению теней и маскировки облаков с использованием функции «cloudMask». Сначала из изображений Landsat извлекались данные слоя «QA_PIXEL», после чего выполнялись побитовые и логические операции для выявления пикселей, соответствующих облакам и теням. Полученные маски применялись к изображениям, заменяя или удаляя области с облачностью и теневыми эффектами, что позволило получить четкие изображения без артефактов.

Затем изображения за выбранный период были объединены с помощью медианной фильтрации, при которой каждому пикселю присваивалось медианное значение из всего набора данных. Этот метод эффективно устраняет артефакты, вызванные облаками и их тенями, а также сглаживает переходы между разными сценами Landsat, что значительно улучшает качество итогового композитного изображения. В результате все снимки Landsat за вегетационный период с мая по сентябрь текущего года были объединены в одно композитное изображение, которое отражает состояние лесного покрова Пензенской области за этот период (рис. 2).




Рис. 2. Медианный безоблачный композит в естественных цветах снимков Landsat 8 и 9, полученный в GEE для Пензенской области за 2023 год

Для оценки фитомассы леса были использованы спектральные каналы и вегетационные индексы, полученные из изображений Landsat. Данные включали шесть спектральных диапазонов: синий (0,45–0,51 мкм), зеленый (0,53–0,59 мкм), красный (0,63–0,69 мкм), NIR (0,85–0,89 мкм), SWIR1 (1,55–1,65 мкм) и SWIR2 (2,1–2,3 мкм). Также были рассчитаны вегетационные индексы, такие как нормализованный разностный индекс вегетации (NDVI), улучшенный индекс вегетации (EVI), нормализованный коэффициент гари (NBR) и нормализованный разностный индекс влажности (NDMI). В модель RF также были включены классы лесного покрова, извлеченные из тематических карт (см. табл. 2).

Таблица 2. Показатели, используемые в модели RF

Переменные	Описание	Формула
Классы лесного покрова	Хвойные спелые и средневозрастные, Лиственные спелые и средневозрастные, Смешанные спелые и средневозрастные, Молодняки, Непокрытые лесом земли	
Спектральные каналы Landsat	Blue, Green, Red, Near-Infrared, Shortwave Infrared 1, Shortwave Infrared 2	
NDVI	Нормализованный разностный вегетационный индекс (англ. – Normalized Differenced Vegetation Index)	$\frac{Band5 - Band4}{Band5 + Band4}$
EVI	Расширенный вегетационный индекс (англ. – Enhanced Vegetation Index)	$2,5 \times \frac{Band5 - Band4}{Band5 + 6 \times Band4 - 7,5 \times Band2}$
NBR	Нормализованный индекс гари (англ. – Normalized Burn Ratio)	$\frac{Band5 - Band7}{Band5 + Band7}$
NDMI	Нормализованный разностный индекс влажности (англ. – Normalized Difference Moisture Index)	$\frac{Band5 - Band6}{Band5 + Band6}$

Алгоритм машинного обучения Random Forest. В работе был использован алгоритм машинного обучения RF, который представляет собой последовательность действий по ансамблевому обучению на основе прогноза нескольких модельных «деревьев решений» (Breiman, 2001). Он формирует несколько групп данных через случайную выборку и строит «деревья решений» для каждой из них, увеличивая разнообразие моделей за счет случайного выбора признаков.

На этапе прогнозирования RF усредняет результаты всех деревьев решений для получения окончательных прогнозов. Классификатор RF в GEE использует шесть входных параметров: (1) количество «деревьев» классификации, (2) количество переменных в каждом «дереве», (3) минимальная популяция «листьев», (4) доля входных переменных в каждом «дереве», (5) режим «вне мешка» и (6) случайная начальная переменная для построения «деревя». Для достижения высокой точности моделирования и предотвращения переобучения необходимо оптимизировать параметры алгоритма RF. Для этого алгоритм запускался в GEE с различными комбинациями параметров:

- количество создаваемых «деревьев решений» от 100 до 1000 с шагом 100;
- количество переменных для разделения от 1 до 12 с шагом 1 (по умолчанию квадратный корень от количества переменных);
- минимальное количество «листьев» от 1 до 10 с шагом 1 (по умолчанию 1);
- доля входных признаков в «мешке» от 0,1 до 1 с шагом 0,1 (по умолчанию 0,5);
- максимальное количество узлов в «дереве» от 10 до 100 с шагом 10 (по умолчанию неограниченно) (Рис. 3).

В задаче RF классификации используется метод голосования большинства, при котором класс (показатель) с наибольшим количеством положительных голосов среди всех «деревьев» определяет итоговый результат. В случае регрессии окончательное значение вычисляется как среднее предсказанных значений от каждого «деревя» (рис. 3).




Рис. 3. Фрагмент одного из «деревьев решений» алгоритма RF: RSS – сумма квадратов ошибок прогнозов, n – количество наблюдений, $\bar{x}$ – среднее значение фитомассы

Используя данные полученные с тестовых участков и $\bar{x}$ спутниковых снимков была получена модель, которая использовалась для создания карт наземной фитомассы леса за период с 1985 по 2023 с интервалом в 5 лет.

Результаты и обсуждение

На основе кластеризации с использованием метода «wekaKMeans» в GEE были созданы тематические карты лесного покрова Пензенской области за период с 1985 по 2023 год с интервалом в 5 лет. Каждая карта состоит из 7 основных классов лесного покрова, которые были в дальнейшем использованы в модели RF (рис. 4).

Общая точность карт варьирует от 78% до 86%, а коэффициент Каппа составляет от 0,73 до 0,81. Точность карт постепенно возрастает с каждым годом, достигая максимального значения в 2023 году. Это можно объяснить улучшением качества спутниковых изображений Landsat и увеличением числа достоверных тестовых участков, используемых для моделирования и оценки на исследуемой территории. В результате тестирования различных параметров модели RF в GEE наилучшие показатели точности были получены при использовании 300 «деревьев решений», 12 переменных для разделения, минимальном количестве «листьев» равном 2, доле входных признаков в «мешке» 0,9 и неограниченном максимальном количестве «узлов в дереве» (рис. 5)




Рис. 4. Тематическая карта пространственного распределения классов лесного покрова Пензенской области за 2023 год.




Рис. 5. Графики распределения среднеквадратической ошибки при различных параметрах модели RF

Оценка значимости переменных в алгоритме RF является важным этапом анализа данных, позволяющим выявлять факторы, оказывающие наибольшее влияние на исследуемый показатель. При моделировании наземной фитомассы лесов с использованием спутниковых снимков Landsat такая оценка помогает определить наиболее информативные спектральные каналы, вегетационные индексы и другие показатели (рис. 6). Анализ распределения значимости переменных показывает, что наибольшее влияние на определение фитомассы оказывают спектральные показатели каналов B4 (красный), B5 (ближний инфракрасный, NIR), B5 (ближний инфракрасный, NIR) и B6 (коротковолновый инфракрасный, SWIR-1). Вслед за ними следуют вегетационные индексы EVI, NDVI и NDBaI, что указывает на их сильную связь с оценкой фитомассы леса. Классы лесного покрова для оценки фитомассы имеют относительную значимость 8.5 %.




Рис. 6. Относительная значимость параметров модели RF для оценки фитомассы лесного покрова

Модель случайного леса (RF) для оценки наземной фитомассы лесного покрова Пензенской области была сопоставлена с эмпирическими данными, полученными на тестовых участках. Анализ показал, что линейная модель RF лучше всего отражает общую структуру данных (рис. 7). В то же время, результаты модели RF демонстрируют завышенные значения фитомассы в диапазоне от 0 до 150 т/га и заниженные — в диапазоне от 180 до 250 т/га по сравнению с данными тестовых участков. Статистические показатели точности полученной модели демонстрируют приемлемые значения: $R^2 = 0,82$ и $\sigma = 7,6$ т/га.




Рис. 7. Соотношение между данными наземной фитомассы тестовых участков и модели RF

Карта распределения наземной фитомассы лесного покрова Пензенской области за 2023 год показывает ярко выраженную неравномерность (рис. 8). Высокая плотность фитомассы отмечается в лесных массивах востока области, а также на северо-востоке и севере Пензенской области. В центральных и южных районах региона фитомасса представлена фрагментированными (точечными) участками леса.




Рис. 8. Карта распределения наземной фитомассы лесов Пензенской области за 2023 год, полученная с использованием алгоритма RF по данным Landsat

На следующих этапах работы с моделью были созданы карты пространственного распределения (30 м) наземной фитомассы лесов Пензенской области за период с 1985 по 2023 годы с интервалом в пять лет. Результаты анализа показывают, что за исследуемый период площадь лесного покрова и соответствующая ей наземная фитомасса в Пензенской области постепенно увеличивались (рис. 9). Площадь лесов выросла с 927 тысяч га до почти 1,5 млн. га, в основном за счет зарастания бывших сельскохозяйственных земель лесными насаждениями. Общая наземная фитомасса лесного покрова увеличилась более чем вдвое — с 86 млн. т до 180 млн т. Однако в 2010 году было зафиксировано снижение общей фитомассы в следствие лесных пожаров и засухи в летний период.




Рис. 9. Динамика площади и наземной фитомассы лесного покрова Пензенской области за период с 1985 по 2023 год

Для определения и оценки наземной фитомассы каждого тематического класса также применялся модуль зональной статистики в программном комплексе NextGIS QGIS. Для этого использовались ранее созданные маски лесного покрова Пензенской области для каждого тематического класса за исследуемые годы.

На протяжении всего исследуемого периода хвойные спелые и средневозрастные насаждения демонстрировали устойчивый прирост наземной фитомассы. В целом, фитомасса хвойных насаждений увеличилась на 35,1 млн. т, что привело к росту их доли в общей наземной фитомассе лесного покрова на 12,5 % (рис. 10).



Рис. 10. Динамика наземной фитомассы хвойных насаждений за период с 1985 по 2023 годы

Фитомасса лиственных насаждения Пензенской области увеличилась за исследуемый период на 50,9 млн. т, однако их доля в общей наземной фитомассе снизилась на 3,6 %. Основной прирост обеспечили спелые насаждения, в то время наземная фитомасса средневозрастных оставалась на стабильном уровне (рис. 11).




Рис. 11. Динамика наземной фитомассы лиственных насаждений за период с 1985 по 2023 годы

Фитомасса смешанных лесных насаждений практически не изменилась, увеличившись всего на 1,5 млн. т, однако их доля в общей наземной фитомассе лесного покрова значительно сократилась с 20,2% до 10,5%. Смешанные средневозрастные насаждения демонстрируют стабильный рост, за исключением 1995 и 2010 годов. Смешанные спелые насаждения теряли фитомассу с 1985 по 1995 год, затем наблюдался небольшой рост до 2005 года, после чего последовало очередное снижение в 2010, а затем снова накопление до 2023 года (рис. 12).




Рис. 12. Динамика фитомассы смешанных насаждений за период с 1985 по 2023 годы

Наземная фитомасса молодняков в исследуемом регионе возросла на 6,3 млн. т, однако их доля в общей наземной фитомассе лесного покрова оставалась стабильной на уровне 5% на протяжении всего изучаемого периода. Только в 1995 и 2005 годах фиксировались кратковременные повышения до 8 %. С 1985 по 2005 годы наблюдался общий рост фитомассы молодняков, однако в 2000 и 2010 годах произошли резкие снижения из-за лесных пожаров. С 2011 года отмечается устойчивый рост фитомассы молодняков в Пензенской области (рис. 13).




Рис. 13. Динамика фитомассы молодняков Пензенской области за период с 1985 по 2023 годы

Выводы

Алгоритм RF показал высокую точность ($R^2=0,8$) при использовании спектральных каналов и вегетационных индексов в качестве переменных. Анализ относительной важности переменных в модели RF подчеркивает сложность оценки фитомассы лесов. Модель учитывает как физические свойства растительности (спектральные показатели каналов B4, B5 и B6), так и вегетационные индексы (NDVI и EVI), отражающие состояние растительности. Оценка общей наземной фитомассы лесов Пензенской области за период с 1985 по 2023 год показала устойчивый рост 86 млн тонн до 180 млн. т.

Анализ по породному и возрастному составу показал, что лиственные насаждения имеют наибольшую фитомассу – 104 млн. т, увеличившись на 50,9 млн. т за рассматриваемый период. Хвойные насаждения занимают второе место с фитомассой 46 млн. т, которая выросла за 40 лет на 35 млн. т. Фитомасса смешанных насаждений составила 19 млн. т, увеличившись на 1,5 млн. т. Молодняки в 2023 году достигли фитомассы 11 млн. т, прибавив 6 млн. т за исследуемый период.

При этом доля фитомассы лиственных пород в процентном соотношении снижается, а доля хвойных увеличивается.

Использование спутниковых данных играет ключевую роль не для мониторинга пространственно-временных изменений фитомассы лесов, но и для глубокого понимания влияния породной и возрастной структуры древостоя на эти изменения. Эти данные также имеют критическое значение для разработки эффективных стратегий охраны и восстановления лесов.

Библиографический список

1. Замолодчиков Д. Г., Уткин А. И., Честных О. В. Коэффициенты конверсии запасов насаждений в фитомассу основных лесообразующих пород России // Лесная таксация и лесоустройство. 2003. Вып. 1(32). С. 119-127.
2. Замолодчиков Д. Г., Уткин А. И., Коровин Г. Н. Конверсионные коэффициенты фитомассы/запас в связи с дендрометрическими показателями и составом древостоев // Лесоведение. 2005. № 6. С. 73–81.
3. Курбанов Э. А. Бюджет углерода сосновых экосистем Волго-Вятского района: монография. Йошкар-Ола: Изд-во Марийского государственного технического университета, 2002. 300 с. ISBN 5-8158-0184-4.
4. Курбанов Э. А. Углерододепонирующие насаждения Киотского протокола: монография 2-е изд. Йошкар-Ола: Изд-во Марийского государственного технического университета, 2009. 184 с. ISBN 978-5-8158-0689-4.
5. Курбанов Э. А., Воробьев О. Н., Лежнин С. А., Губаев А. В. Полевщикова Ю. А. Тематическое картирование растительного покрова по спутниковым снимкам: валидация и оценка точности: монография. Йошкар-Ола: ПГТУ, 2015. 131 с. ISBN 978-5-8158-1596-4.
6. Румянцев Д. Е. Чумаченко С. И., Липаткин В. А., Киселева В. В., Шипинская У. С., Лежнев Д. В., Парфенова А. Е. Оценка влияния климатического режима на относительную интенсивность депонирования углерода в древостоях сосны обыкновенной в условиях карбонового полигона Фряновского лесничества (Московская область) // Лесной вестник. 2024. Т. 28, № 4. С. 43–52. DOI: 10.18698/2542-1468-2024-4-43-52
7. Усольцев В. А. Депонирование углерода лесами уральского региона России (по состоянию Государственного учета лесного фонда на 2007 год): монография. Екатеринбург: Изд-во Уральский государственный лесотехнический университет, РАН, УрО, Ботан. сад, 2018. 265 с.
8. Akhtar A.M., Qazi W.A., Ahmad S.R. Gilani H., Mahmood S.A., Rasool A. Integration of high-resolution optical and SAR satellite remote sensing datasets for aboveground biomass estimation in subtropical pine forest, Pakistan // Environ Monit Assess. 2020. Vol. 192. p. 584. <https://doi.org/10.1007/s10661-020-08546-1>.
9. Benmokhtar S., Robin M., Maanan M., Bazairi H. Mapping and Quantification of the Dwarf Eelgrass *Zostera noltei* Using a Random Forest Algorithm on a SPOT 7 Satellite Image // ISPRS International Journal of Geo-Information. 2021. Vol. 10. № 5. p. 313. <https://doi.org/10.3390/ijgi10050313>.
10. Bispo P. C., Rodríguez-Veiga P., Zimbres B., do Couto de Miranda S., Henrique Giusti Cezare C., Fleming S., Baldacchino F., Louis V., Rains D., Garcia M., et al. Woody Aboveground Biomass Mapping of the Brazilian Savanna with a Multi-Sensor and Machine Learning Approach // Remote Sensing. 2020. Vol. 12, № 17. p. 2685. <https://doi.org/10.3390/rs12172685>.
11. Crosby M. K., Matney T. G., Schultz E. B., Evans D. L., Grebner D. L., Londo H. A., Rodgers J. C., Collins C.A. Consequences of Landsat Image Strata Classification Errors on Bias and Variance of Inventory Estimates: A Forest Inventory Case Study // IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens. 2017. Vol. 10. pp. 243–251. <https://doi.org/10.1109/JSTARS.2016.2597762>.
12. Frampton W.J., Dash, J., Watmough G., Milton, E.J. Evaluating the Capabilities of Sentinel-2 for Quantitative Estimation of Biophysical Variables in Vegetation // ISPRS J. Photogramm. Remote Sensing. 2013. Vol. 82. pp. 83–92. <https://doi.org/10.1016/j.isprsjprs.2013.04.007>.
13. Ghosh S.M., Behera, M.D. Aboveground biomass estimation using multi-sensor data synergy and machine learning algorithms in a dense tropical forest // Applied Geography. 2018. Vol. 96. pp. 29–40. <https://doi.org/10.1016/j.apgeog.2018.05.011>.
14. Han H., Wan R., Li B. Estimating Forest Aboveground Biomass Using Gaofen-1 Images, Sentinel-1 Images, and Machine Learning Algorithms: A Case Study of the Dabie Mountain Region, China // Remote Sensing. 2022. Vol. 14, № 1. p. 176. <https://doi.org/10.3390/rs14010176>.

15. Karlson M., Ostwald M., Reese H., Sanou J., Tankoano B., Mattsson E. Mapping Tree Canopy Cover and Aboveground Biomass in Sudano-Sahelian Woodlands Using Landsat 8 and Random Forest. // *Remote Sensing*. 2015. Vol. 7, № 8. p. 10017-10041. <https://doi.org/10.3390/rs70810017>.
16. Lee Y. S., Lee S., Baek W. K., Jung H. S., Park S. H., Lee M.J. Mapping Forest Vertical Structure in Jeju Island from Optical and Radar Satellite Images Using Artificial Neural Network // *Remote Sensing*. 2020. Vol. 12, № 5. p. 797. <https://doi.org/10.3390/rs12050797>.
17. Li Y., Li C., Li M., Liu Z. Influence of Variable Selection and Forest Type on Forest Aboveground Biomass Estimation Using Machine Learning Algorithms // *Forests*. 2019. Vol. 10, № 12. p. 1073. <https://doi.org/10.3390/f10121073>.
18. Li X., Long J., Zhang M., Liu Z., Lin H. Coniferous Plantations Growing Stock Volume Estimation Using Advanced Remote Sensing Algorithms and Various Fused Data // *Remote Sensing*. 2021. Vol. 13, № 17. p. 3468. <https://doi.org/10.3390/rs13173468>.
19. López-Serrano P. M., Cárdenas Domínguez J. L., Corral-Rivas J. J., Jiménez E., López-Sánchez C. A., Vega-Nieva D. J. Modeling of Aboveground Biomass with Landsat 8 OLI and Machine Learning in Temperate Forests // *Forests*. 2020. Vol. 11, № 1. p. 11. <https://doi.org/10.3390/f11010011>.
20. Lu D., Chen Q., Wang G., Liu L., Li G., Moran E. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems // *International Journal of Digital Earth*. 2016. Vol. 9, № 1. p. 63–105. <https://doi.org/10.1080/17538947.2014.990526>.
21. Mutti P.R., da Silva L.L., Medeiros S.D.S., Dubreuil V., Mendes K.R., Marques T.V., Lucio P.S., Santos e Silva C.M., Bezerra B.G. Basin scale rainfall-evapotranspiration dynamics in a tropical semiarid environment during dry and wet years // *Int. J. Appl. Earth Obs. Geoinf.* 2019. Vol. 75. pp. 29–43. <https://doi.org/10.1016/j.jag.2018.10.007>.
22. Puliti S., Breidenbach J., Schumacher J., Hauglin M., Klingenberg T.F., Astrup R. Above-ground biomass change estimation using national forest inventory data with Sentinel-2 and Landsat // *Remote Sensing of Environment*. 2021. Vol. 265. <https://doi.org/10.1016/j.rse.2021.112644>.
23. Purohit S., Aggarwal S.P., Patel N.R. Estimation of forest aboveground biomass using combination of Landsat 8 and Sentinel-1A data with random forest regression algorithm in Himalayan Foothills // *Tropical Ecology*. 2021. Vol. 62. pp. 288–300. <https://doi.org/10.1007/s42965-021-00140-x>.
24. Rockström J., Gaffney O., Rogelj J., Meinshausen M., Nakicenovic N., Schellnhuber H. J. A roadmap for rapid decarbonization // *Science*. 2017. Vol. 355, № 6331. pp. 1269-1271. <https://doi.org/10.1126/science.aah3443>.
25. Ronoud G., Darvish Sefat A. A., Fatehi P. Beech tree density estimation using Sentinel-2 data (case study: Khyroud forest) // *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.* 2019. Vol. 42. pp. 891–895. <https://doi.org/10.5194/isprs-archives-XLII-4-W18-891-2019>.
26. Sa R., Nie Y., Chumachenko S., Fan W. Biomass Estimation and Saturation Value Determination Based on Multi-Source Remote Sensing Data // *Remote Sensing*. 2024. Vol. 16, № 12. p. 2250. <https://doi.org/10.3390/rs16122250>.
27. Singh C., Karan S.K., Sardar P., Samadder S.R. Remote sensing-based biomass estimation of dry deciduous tropical forest using machine learning and ensemble analysis // *J. Environ. Manag.* 2022. Vol. 308. <https://doi.org/10.1016/j.jenvman.2022.114639>.
28. Souza G.S.A.d., Soares V.P., Leite H.G., Gleriani J.M., do Amaral C.H., Ferraz A.S., Silveira M.V.d.F., Santos J.F.C.d., Velloso S.G.S., Domingues G.F. Multi-sensor prediction of Eucalyptus stand volume: A support vector approach // *ISPRS J. Photogramm. Remote Sensing*. 2019. Vol. 156. pp. 135–146. <https://doi.org/10.1016/j.isprsjprs.2019.08.002>.
29. Yu T., Pang Y., Liang X., Jia W., Bai Y., Fan Y., Wang X. China's larch stock volume estimation using Sentinel-2 and LiDAR data // *Geo-Spatial Information Science*. 2023. Vol. 26. № 3. pp. 392–405. <https://doi.org/10.1080/10095020.2022.2105754>.

References

1. Zamolodchikov D. G., Utkin A. I., Chestnykh O. V. Koeffitsienty konversii zapasov nasazhdenii v fitomassu osnovnykh lesoobrazuyushchikh porod Rossii (Conversion coefficients of stands' reserves into phytomass of the main forest-forming species of Russia). *Lesnaya taksatsiya i lesoustroistvo*. 2003. Vol. 1(32). pp. 119-127.
2. Zamolodchikov D. G., Utkin A. I., Korovin G. N. Konversionnye koeffitsienty fitomassy/zapas v svyazi s dendrometricheskimi pokazatelyami i sostavom drevostoev (Conversion coefficients of phytomass/reserve in connection with dendrometric indicators and composition of tree stands). *Lesovedenie*, 2005. No. 6. pp. 73–81.

3. Kurbanov E. A. Byudzhety ugleroda sosnovykh ekosistem Volgo-Vyatskogo raiona: monografiya (Carbon budget of pine ecosystems of the Volga-Vyatka region: monograph). Ioshkar-Ola: Izd-vo Mariiskogo gosudarstvennogo tekhnicheskogo universiteta, 2002. 300 p. ISBN 5-8158-0184-4.
4. Kurbanov E. A. Uglerododeponiruyushchie nasazhdeniya Kiotskogo protokola: monografiya 2-e izd (Carbon sequestering plantings of the Kyoto Protocol: monograph 2nd ed.). Ioshkar-Ola: Izd-vo Mariiskogo gosudarstvennogo tekhnicheskogo universiteta, 2009. 184 p. ISBN 978-5-8158-0689-4.
5. Kurbanov E. A., Vorob'ev O. N., Lezhnin S. A., Gubaev A. V., Polevshchikova Yu. A. Tematicheskoe kartirovanie rastitel'nogo pokrova po sputnikovym snimkam: validatsiya i otsenka tochnosti: monografiya (Thematic mapping of vegetation cover from satellite images: validation and accuracy assessment: monograph). Ioshkar-Ola: PGU, 2015. 131 p. ISBN 978-5-8158-1596-4.
6. Rumyantsev D. E., Chumachenko S. I., Lipatkin V. A., Kiseleva V. V., Shipinskaya U. S., Lezhnev D. V., Parfenova A. E. Otsenka vliyaniya klimaticheskogo rezhima na otnositel'nyuyu intensivnost' deponirovaniya ugleroda v drevostoyakh sosny obyknovennoi v usloviyakh karbonovogo poligona Fryanovskogo lesnichestva (Moskovskaya oblast') (Assessment of the influence of the climatic regime on the relative intensity of carbon sequestration in Scots pine stands under the conditions of the carbon polygon of the Fryanovsk forestry (Moscow region)). *Lesnoi vestnik*, 2024. Vol. 28. No. 4. pp. 43–52. DOI: 10.18698/2542-1468-2024-4-43-52
7. Usoltsev V. A. Deponirovanie ugleroda lesami ural'skogo regiona Rossii (po sostoyaniyu Gosudarstvennogo ucheta lesnogo fonda na 2007 god): monografiya (Carbon sequestration by forests of the Ural region of Russia (according to the State Forest Fund Accounting for 2007): monograph). Ekaterinburg: Izd-vo Ural'skii gosudarstvennyi lesotekhnicheskii universitet, RAN, UrO, Botan. sad, 2018. 265 p.
8. Akhtar A.M., Qazi W.A., Ahmad S.R., Gilani H., Mahmood S.A., Rasool A. Integration of high-resolution optical and SAR satellite remote sensing datasets for aboveground biomass estimation in subtropical pine forest, Pakistan. *Environ Monit Assess*, 2020. Vol. 192. p. 584. <https://doi.org/10.1007/s10661-020-08546-1>.
9. Benmokhtar S., Robin M., Maanan M., Bazairi H. Mapping and Quantification of the Dwarf Eelgrass *Zostera noltei* Using a Random Forest Algorithm on a SPOT 7 Satellite Image. *ISPRS International Journal of Geo-Information*, 2021. Vol. 10, No. 5. p. 313. <https://doi.org/10.3390/ijgi10050313>.
10. Bispo P. C., Rodríguez-Veiga P., Zimbres B., do Couto de Miranda S., Henrique Giusti Cezare C., Fleming S., Baldacchino F., Louis V., Rains D., Garcia M., et al. Woody Aboveground Biomass Mapping of the Brazilian Savanna with a Multi-Sensor and Machine Learning Approach. *Remote Sensing*, 2020. Vol. 12, No. 17. p. 2685. <https://doi.org/10.3390/rs12172685>.
11. Crosby M. K., Matney T. G., Schultz E. B., Evans D. L., Grebner D. L., Londo H. A., Rodgers J. C., Collins C.A. Consequences of Landsat Image Strata Classification Errors on Bias and Variance of Inventory Estimates: A Forest Inventory Case Study. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 2017. Vol. 10. pp. 243–251. <https://doi.org/10.1109/JSTARS.2016.2597762>.
12. Frampton W.J., Dash, J., Watmough G., Milton, E.J. Evaluating the Capabilities of Sentinel-2 for Quantitative Estimation of Biophysical Variables in Vegetation. *ISPRS J. Photogramm. Remote Sensing*, 2013. Vol. 82. pp. 83–92. <https://doi.org/10.1016/j.isprsjprs.2013.04.007>.
13. Ghosh S.M., Behera, M.D. Aboveground biomass estimation using multi-sensor data synergy and machine learning algorithms in a dense tropical forest. *Applied Geography*, 2018. Vol. 96. pp. 29–40. <https://doi.org/10.1016/j.apgeog.2018.05.011>.
14. Han H., Wan R., Li B. Estimating Forest Aboveground Biomass Using Gaofen-1 Images, Sentinel-1 Images, and Machine Learning Algorithms: A Case Study of the Dabie Mountain Region, China. *Remote Sensing*, 2022. Vol. 14, No. 1. p. 176. <https://doi.org/10.3390/rs14010176>.
15. Karlson M., Ostwald M., Reese H., Sanou J., Tankoano B., Mattsson E. Mapping Tree Canopy Cover and Aboveground Biomass in Sudano-Sahelian Woodlands Using Landsat 8 and Random Forest. *Remote Sensing*, 2015. Vol. 7, No. 8. pp. 10017–10041. <https://doi.org/10.3390/rs70810017>.
16. Lee Y. S., Lee S., Baek W. K., Jung H. S., Park S. H., Lee M.J. Mapping Forest Vertical Structure in Jeju Island from Optical and Radar Satellite Images Using Artificial Neural Network. *Remote Sensing*, 2020. Vol. 12, No. 5. p. 797. <https://doi.org/10.3390/rs12050797>.
17. Li Y., Li C., Li M., Liu Z. Influence of Variable Selection and Forest Type on Forest Aboveground Biomass Estimation Using Machine Learning Algorithms. *Forests*, 2019. Vol. 10, No. 12. p. 1073. <https://doi.org/10.3390/f10121073>.

18. Li X., Long J., Zhang M., Liu Z., Lin H. Coniferous Plantations Growing Stock Volume Estimation Using Advanced Remote Sensing Algorithms and Various Fused Data. *Remote Sensing*, 2021. Vol. 13, No. 17. p. 3468. <https://doi.org/10.3390/rs13173468>.
19. López-Serrano P. M., Cárdenas Domínguez J. L., Corral-Rivas J. J., Jiménez E., López-Sánchez C. A., Vega-Nieva D. J. Modeling of Aboveground Biomass with Landsat 8 OLI and Machine Learning in Temperate Forests. *Forests*, 2020. Vol. 11, No. 1. p. 11. <https://doi.org/10.3390/f11010011>.
20. Lu D., Chen Q., Wang G., Liu L., Li G., Moran E. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. *International Journal of Digital Earth*, 2016. Vol. 9, No. 1. p. 63-105. <https://doi.org/10.1080/17538947.2014.990526>.
21. Mutti P.R., da Silva L.L., Medeiros S.D.S., Dubreuil V., Mendes K.R., Marques T.V., Lucio P.S., Santos e Silva C.M., Bezerra B.G. Basin scale rainfall-evapotranspiration dynamics in a tropical semiarid environment during dry and wet years. *Int. J. Appl. Earth Obs. Geoinf.*, 2019. Vol. 75. pp. 29–43. <https://doi.org/10.1016/j.jag.2018.10.007>.
22. Puliti S., Breidenbach J., Schumacher J., Hauglin M., Klingenberg T.F., Astrup R. Above-ground biomass change estimation using national forest inventory data with Sentinel-2 and Landsat. *Remote Sensing of Environment*, 2021. Vol. 265. <https://doi.org/10.1016/j.rse.2021.112644>.
23. Purohit S., Aggarwal S.P., Patel N.R. Estimation of forest aboveground biomass using combination of Landsat 8 and Sentinel-1A data with random forest regression algorithm in Himalayan Foothills. *Tropical Ecology*, 2021. Vol. 62. pp. 288–300. <https://doi.org/10.1007/s42965-021-00140-x>.
24. Rockström J., Gaffney O., Rogelj J., Meinshausen M., Nakicenovic N., Schellnhuber H. J. A roadmap for rapid decarbonization. *Science*. 2017. Vol. 355, No. 6331. pp. 1269-1271. <https://doi.org/10.1126/science.aah3443>.
25. Ronoud G., Darvish Sefat A. A., Fatehi P. Beech tree density estimation using Sentinel-2 data (case study: Khyroud forest). *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, 2019. Vol. 42. pp. 891–895. <https://doi.org/10.5194/isprs-archives-XLII-4-W18-891-2019>.
26. Sa R., Nie Y., Chumachenko S., Fan W. Biomass Estimation and Saturation Value Determination Based on Multi-Source Remote Sensing Data. *Remote Sensing*, 2024. Vol. 16, No. 12. p. 2250. <https://doi.org/10.3390/rs16122250>.
27. Singh C., Karan S.K., Sardar P., Samadder S.R. Remote sensing-based biomass estimation of dry deciduous tropical forest using machine learning and ensemble analysis. *J. Environ. Manag.*, 2022. Vol. 308. <https://doi.org/10.1016/j.jenvman.2022.114639>.
28. Souza G.S.A.d, Soares V.P., Leite H.G., Gleriani J.M., do Amaral C.H., Ferraz A.S., Silveira M.V.d.F., Santos J.F.C.d., Velloso S.G.S., Domingues G.F. Multi-sensor prediction of Eucalyptus stand volume: A support vector approach. *ISPRS J. Photogramm. Remote Sensing*, 2019. Vol. 156. pp. 135–146. <https://doi.org/10.1016/j.isprsjprs.2019.08.002>.
29. Yu T., Pang Y., Liang X., Jia W., Bai Y., Fan Y., Wang X. China's larch stock volume estimation using Sentinel-2 and LiDAR data. *Geo-Spatial Information Science*, 2023. Vol. 26, No. 3. pp. 392–405. <https://doi.org/10.1080/10095020.2022.2105754>.