

Научная статья

УДК 51-76

DOI: <https://doi.org/10.18127/j19998554-202506-01>

## Модель оценки поглощения углерода российскими лесами на основе интеграции спутниковых, метеорологических и почвенных данных с использованием машинного обучения

В.С. Чернышенко<sup>1</sup>, К.Д. Белов<sup>2</sup>, Л.Б. Кулыгин<sup>3</sup>, М.А. Четыркина<sup>4</sup>

<sup>1-4</sup> Финансовый университет при Правительстве Российской Федерации (Москва, Россия)

<sup>1</sup> vschernyshenko@fa.ru, <sup>2</sup> constantinbelov5903@gmail.com, <sup>3</sup> Leonid2004.ru@mail.ru, <sup>4</sup> m.chetyrkina24@gmail.com

### Аннотация

**Постановка проблемы.** Нарастающее антропогенное выделение парниковых газов, главным образом CO<sub>2</sub> и метана, подрывает экологическую устойчивость, приводя к изменению климата, экстремальным погодным явлениям и утрате биоразнообразия. А существующие традиционные решения в оценке депонированного, характеризуются ограниченной применимостью к бореальным ландшафтам России вследствие недостаточной репрезентативности обучающих выборок.

**Цель.** Разработать интегрированную многоуровневую модель, позволяющую оценивать поглощение CO<sub>2</sub> лесными экосистемами посредством совмещения спутниковых данных, метеорологических наблюдений и почвенных показателей с алгоритмами машинного обучения.

**Результаты.** Получены данные построения модели, демонстрирующие высокую точность прогнозирования ключевых параметров, отвечающих за депонирование углерода. Установлено, что применение ансамблевых алгоритмов и нейронных сетей позволило достичь высокой точности предсказаний (RMSE 0,25–0,35 т/га; R<sup>2</sup> 0,82–0,88). Приведены значения метрик точности, позволяющие утверждать, что предложенная методика обладает высокой степенью надёжности и применимости к разнообразным лесным массивам, охватывающим значительную часть территории Российской Федерации.

**Практическая значимость.** Полученные результаты демонстрируют практическую применимость искусственного интеллекта для экологического мониторинга и углеродного регулирования, открывая перспективы масштабируемого использования в национальных системах природоохранного планирования.

### Ключевые слова

Машинное обучение, лесные экосистемы, углеродный баланс, спутниковые данные, экологический мониторинг

Статья подготовлена по результатам исследований, выполненных за счет средств Научного фонда Финансового университета при Правительстве РФ.

### Для цитирования

Чернышенко В.С., Белов К.Д., Кулыгин Л.Б., Четыркина М.А. Модель оценки поглощения углерода российскими лесами на основе интеграции спутниковых, метеорологических и почвенных данных с использованием машинного обучения // Нейрокомпьютеры: разработка, применение. 2025. Т. 27. № 6. С. 7–16. DOI: 10.18127/j19998554-202506-01

A brief version in English is given at the end of the article

### Введение

Нарастающее в последнее время антропогенное выделение парниковых газов, главным образом CO<sub>2</sub> и метана, подрывает экологическую устойчивость, приводя к изменению климата, экстремальным погодным явлениям и утрате биоразнообразия [1]. Согласно статистическим отчётам, глобальные выбросы CO<sub>2</sub> в 2022 г. достигли 36,8 Гт, превысив «доковидный» уровень [2]. Основной вклад таких выбросов приходится на быстроразвивающиеся экономики (Китай – ≈ 33% от мировых выбросов, Индия – ≈ 7%), активно использующие уголь и нефть [3]. В ряде развитых стран (ЕС, США) наблюдается снижение темпов выбросов вследствие перехода к возобновляемым источникам энергии [4], однако совокупные эмиссии по-прежнему не укладываются в пределы Парижского соглашения.

В России, несмотря на сокращение выбросов на 2,4% в 2022 г., их абсолютный объём остаётся значительным (1,94 млрд т CO<sub>2</sub> в 2021 г., ≈ 5% мировых выбросов) [6]. Энергетическая и промышленная структура экономики, а также зависимость от экспорта ископаемого топлива затрудняют переход к низкоуглеродной модели развития [7]. Федеральный закон № 296-ФЗ [8] ввёл обязательную отчётность по выбросам и стимулировал климатические проекты лесовосстановления и торговли углеродными единицами. При этом глобальное потепление уже превысило +1,1 °C относительно доиндустриального уровня [9], что усиливает деградацию экосистем и требует инновационных мер по компенсации эмиссий [10].

© Чернышенко В.С., Белов К.Д., Кулыгин Л.Б., Четыркина М.А., 2025

Ц е л ь р а б о т ы – разработать интегрированную многоуровневую модель, позволяющую оценивать поглощение CO<sub>2</sub> лесными экосистемами посредством совмещения спутниковых данных, метеорологических наблюдений и почвенных показателей с алгоритмами машинного обучения.

В работе основное внимание уделяется анализу современных методов измерения углеродных выбросов, определению возможностей спутникового мониторинга, изучению роли искусственного интеллекта в автоматизации обработки и интерпретации разнородных данных, а также оценке точности и валидации разработанных методик на примере конкретных лесных территорий.

### **Обзор литературы и существующих решений**

Современные исследования в области экологического мониторинга подчеркивают важность точной оценки углеродных запасов в лесных экосистемах для понимания их роли в глобальном углеродном цикле и смягчении последствий изменения климата. Однако традиционные методы оценки, такие как полевые измерения и эмпирические модели, часто ограничены в масштабируемости и точности, особенно при анализе больших территорий с разнообразными лесными типами. Это стимулировало развитие новых подходов, основанных на машинном обучении, которые предлагают более эффективные и точные методы оценки углеродных запасов в лесах.

Одним из ключевых направлений является интеграция машинного обучения с дистанционным зондированием для оценки наземной биомассы и углеродных запасов. Систематический обзор, проведенный Matiza и соавторами, выявил, что алгоритмы, такие как случайный лес (Random Forest) и градиентный бустинг (XGBoost), демонстрируют высокую точность при прогнозировании углеродных запасов, особенно при использовании данных с мультисенсорных спутников, включая Sentinel-1, Sentinel-2 и LiDAR. Эти методы позволяют учитывать структурные характеристики леса, такие как высота и плотность деревьев, что существенно улучшает точность оценок [11–12].

Кроме того, применение иерархических моделей машинного обучения, объединяющих данные лесных инвентаризаций и дистанционного зондирования, позволяет более точно картировать запасы углерода в лесах. Например, исследование, опубликованное в журнале Scientific Reports [13], показало, что такие подходы значительно улучшают пространственную точность оценки биомассы и углеродных запасов. Это особенно важно для регионов с высокой гетерогенностью лесных экосистем, где традиционные методы могут быть недостаточно точными.

Однако, несмотря на успешное применение этих методов, существуют определенные ограничения. Некоторые исследования указывают на возможность переоценки углеродных запасов при использовании спутниковых данных без должной калибровки и валидации. Например, Reiersen и соавторы отметили [14], что использование спутниковых изображений без учета специфики местных условий может привести к значительным ошибкам в оценке углеродных запасов. Это подчеркивает необходимость комбинирования различных источников данных и методов для повышения точности оценок.

В целом, интеграция методов машинного обучения с данными дистанционного зондирования представляет собой перспективное направление в оценке углеродных запасов лесных экосистем. Однако для достижения высокой точности и надежности результатов необходимо учитывать особенности конкретных регионов, типы лесов и использовать мультисенсорные данные в сочетании с полевыми измерениями. Дальнейшие исследования в этой области помогут разработать более универсальные и точные модели для оценки углеродных запасов, что будет способствовать более эффективному мониторингу и управлению лесными ресурсами в контексте изменения климата.

### **Источники и характеристика данных**

Для осуществления комплексного анализа были привлечены разнородные массивы геопространственных данных, охватывающих рельеф, климат, почвы и характеристики лесных экосистем России. Для оценки влияния топографии на процессы депонирования углерода использовалась цифровая модель рельефа (ЦМР) Shuttle Radar Topography Mission (SRTM) с пространственным разрешением около 30 м. На ее основе рассчитывались ключевые морфометрические параметры: уклон, экспозиция, кривизна, индекс пересечённости местности (TRI), индекс топографического положения (TPI) и др. (рис. 1). Эти по-

казатели позволили детализировать влияние геоморфологических условий на распределение биомассы и продуктивность растительного покрова. Рельеф, будучи определяющим фактором влагонакопления, инсоляции и эрозии, оказывает прямое воздействие на углеродный баланс через модификацию условий роста лесов (рис. 2).

Для учета климатических условий использовались современные наборы метеоданных глобального реанализа. В частности, применены данные ERA5 – реанализа пятого поколения Европейского центра среднесрочных прогнозов (ECMWF), доступные через платформу Copernicus. ERA5 предоставляет все-стороннюю климатическую информацию с высокой временной и пространственной детализацией, включая среднемесячную и сезонную температуру воздуха, количество осадков, показатели влажности и радиационный баланс (инсоляцию). Эти параметры характеризуют внешние условия, от которых зависят рост лесной растительности и скорость почвенного дыхания. Дополнительно в работу включены данные глобальных климатических моделей и реанализов от Национального центра атмосферных исследований США (NCAR), например, данные NCEP/NCAR, чтобы обеспечить сопоставимость и проверку климатических переменных. Такой подход гарантирует, что модель получает корректные входные данные по температурному режиму, увлажненности и энергетике экосистем в каждом регионе исследования.




Рис. 1. Примеры визуализации рассчитываемых рельефных признаков

Fig. 1. Examples of visualization of calculated relief features




Рис. 2. Графическое представление значимости рельефных характеристик

Fig. 2. Graphical representation of the significance of relief characteristics

В таблице приведены результаты анализа значимости различных климатических характеристик.


**Таблица. Результаты анализа значимости климатических признаков**

| Переменная               | Коэффициент Пирсона (r) | p-значение |
|--------------------------|-------------------------|------------|
| Средняя температура      | 0,42                    | < 0,01     |
| Минимальная температура  | 0,38                    | < 0,05     |
| Максимальная температура | 0,45                    | < 0,01     |
| Сумма осадков            | 0,62                    | < 0,001    |
| Относительная влажность  | 0,28                    | < 0,05     |
| Солнечная радиация       | –0,22                   | > 0,05     |
| Скорость ветра           | –0,15                   | > 0,05     |

Оценка почвенных характеристик проводилась на основе глобальных баз SoilGrids (ISRIC) и Harmonized World Soil Database (HWSD, FAO/IIASA). Использовались показатели содержания органического углерода (SOC), текстуры (доли песка, ила и глины), pH, плотности и влагоемкости. Почвенные свойства определяют не только запасы органического углерода, но и условия роста растений, влагоудержание и микробиологическую активность, т.е. ключевые процессы формирования углеродных пулов. Полученные данные были приведены к единой геопространственной сетке и дополнены интерполяцией по данным наземных измерений. Результаты статистического анализа показывают, что объемы депонируемого углерода в почвах тесно связаны с рядом почвенных характеристик.


Для характеристики типов растительного покрова использовались спутниковые данные VIIRS (продукты GPP/NPP и классификации покрова), Sentinel-2, а также данные национальных ГИС-ресурсов, в частности, Рослесинфорга. Векторы лесных биоценозов были переклассифицированы по типам: хвойные, смешанные, лиственные, заболоченные леса и т.п. (рис. 3). Эта информация крайне важна, поскольку разные типы лесов характеризуются различной продуктивностью, структурой и скоростью углеродного обмена. Пространственное распределение лесных формаций позволило скорректировать оценки биомассы и выделить наиболее эффективные в углеродном отношении участки.

Для оценки влияния антропогенной нагрузки были рассчитаны евклидовы расстояния от каждой ячейки модели до ближайших дорог, населенных пунктов, сельскохозяйственных угодий и промышленных объектов. Исходные данные брались из открытых пространственных слоев OpenStreetMap и национальных картографических ресурсов. Этот параметр учитывает деградацию экосистем под воздействием человека: близость к техногенным объектам, как правило, сопровождается ухудшением состояния леса, его разрежением и снижением углеродной емкости. Таким образом, расстояние до объектов выступает как прокси-показатель интенсивности воздействия (рис. 4).



**Рис. 3.** Разметка региона по типам лесных территорий

**Fig. 3.** Region layout by forest area type



**Рис. 4.** Графическое представление зависимости концентрации углерода в почве от расстояния до объектов  
**Fig. 4.** Graph of the dependence of carbon concentration in soil on the distance to objects

Наиболее информативными показателями состояния растительного покрова стали вегетационные индексы и LAI (индекс листовой поверхности). Они были получены из спутников Sentinel-2 и MODIS, включая продукты MOD13Q1 и LAI MOD15A2H. NDVI использовался для количественной оценки плотности и активности фотосинтетической поверхности, а LAI – для определения суммарной площади листьев на единицу площади земли. К числу ключевых вегетационных индексов относились NDVI (количественная оценка фотосинтетически активной биомассы), GNDVI (более высокая чувствительность к концентрации хлорофилла), OSAVI (учёт влияния почвенного фона при низкой плотности растительного покрова), ExG (выделение «зелёных» пикселей), ExR (акцент на «красном» спектре, позволяющий выявлять повреждённые или горелые территории) и NDI (обобщение разностных индексов для отслеживания изменений в спектральных характеристиках поверхности). Совокупный анализ этих индексов давал возможность прогнозировать не только текущее состояние растительности, но и оценивать её динамику, связанную с климатическими или антропогенными воздействиями, что непосредственно влияет на потенциал поглощения углерода. Эти индексы обладают высокой чувствительностью к изменению продуктивности и биомассы леса, что делает их критически важными для расчета валового первичного производства (GPP) и чистого обмена углерода (NEE).

Благодаря такой комплексной методике сбора и валидации обучающей выборки модель получает более точное представление об особенностях каждого типа леса, влиянии климатических факторов и роли почвенных характеристик в депонировании углерода. Именно синергия локальных полевых измерений и мультитемпоральных спутниковых данных, подготовленных по стандартам передовых исследований [15], обеспечивает высокую прогностическую точность и масштабируемость при оценке потенциального поглощения углерода в лесных экосистемах.

### Методология построения модели

Предложенная методика основана на многоуровневом подходе к интеграции данных, включающем в себя последовательную обработку мультиспектральной спутниковой информации, вегетационных индексов, метеорологических показателей, почвенных факторов и рельефа. На начальном этапе формируются специализированные модули, каждый из которых предназначен для извлечения ключевых признаков из соответствующего набора данных. Так, модуль обработки спутниковых мультиспектров реализован в виде свёрточной нейронной сети (CNN), обеспечивающей выделение пространственных и спектральных паттернов из тайлов спутниковых снимков. Отдельный блок вегетационных индексов (NDVI, GNDVI, OSAVI и др.) извлекает количественные показатели состояния растительности, отражающие её способность к фотосинтезу и, следовательно, к поглощению углерода.

Метеорологические показатели (температура, осадки, влажность, солнечная радиация и другие переменные) также обрабатываются индивидуальным модулем, который, в зависимости от структуры данных, может представлять собой либо набор Dense-слоёв, либо рекуррентную архитектуру (RNN) для учёта временной изменчивости. Блок рельефа анализирует цифровые модели высот и производные характеристики (уклон, аспект, грубость поверхности), а почвенный блок использует отдельный Dense-слой для учёта pH, содержания органического вещества и гранулометрических свойств. Слияние признаков (Fusion Layer) в виде нескольких полносвязных слоёв консолидирует результаты всех перечисленных модулей. Конечный регрессионный выход, представленный одним нейроном с линейной активацией, даёт оценку поглощения CO<sub>2</sub> исследуемым участком лесных экосистем.

При реализации подобного подхода использовались как глубокие (свёрточные нейронные сети), так и классические методы машинного обучения (случайный лес, градиентный бустинг). В ряде случаев применялись гибридные ансамблевые модели, объединяющие преимущества разных алгоритмов (рис. 5). Оценка точности осуществлялась с помощью метрик RMSE, MAE и коэффициента детерминации ( $R^2$ ). Для валидации модели была выбрана схема k-fold кросс-валидации, а также отдельные тестовые полигоны, охватывающие различные типы лесов и широтные зоны. С учётом существенных различий между таёжными массивами, лиственными лесами и смешанными насаждениями, проводилась дополнительная калибровка (fine-tuning) сети, позволяющая учесть региональную специфику формируемых моделей.




Рис. 5. Схема архитектуры модели


Fig. 5. Model architecture diagram

### Результаты построения модели и оценка качества прогнозов


Апробация разработанного подхода (рис. 6) показала, что среднеквадратичная ошибка (RMSE) при прогнозировании поглощения CO<sub>2</sub> варьировалась в диапазоне 0,25–0,35 т/га, а коэффициент детерминации  $R^2$  достигал 0,82–0,88 в зависимости от типа лесных насаждений. Значения MAE при этом сохранялись на уровне 0,15–0,20 т/га, что свидетельствует о высоком соответствии модели реальным данным. Для наглядной визуализации результатов были сформированы карты-модели (рис. 7 и 8), демонстрирующие расчётные величины поглощения углерода по регионам Российской Федерации. Наиболее высокие показатели отмечались в зонах с высокой плотностью древостоя и благоприятными климатическими условиями (достаточная влажность и положительный тепловой баланс).

Анализ факторов, оказывающих наибольшее влияние на интенсивность поглощения, выявил доминирующую роль структуры растительного покрова (включая высоту и густоту древостоя), почвен-


ных характеристик (содержание органики и pH), а также суммарной радиации. Тем не менее дальнейшее повышение точности прогнозов возможно за счёт улучшения качества входных данных, более детальной геопривязки и учёта локальных климатических аномалий. Дополнительными ограничениями выступают возможные пропуски в исходных массивах (облака, шум от аппаратуры спутника), требующие корректной интерполяции или иного способа заполнения. Несмотря на эти сложности, многоуровневый характер модели, сочетающий разные источники информации и различные алгоритмы, обеспечивает комплексный охват факторов, определяющих формирование углеродного баланса лесных экосистем.



**Рис. 6.** Сравнение точности моделей прогноза поглощения CO<sub>2</sub> для различных типов лесных насаждений  
**Fig. 6.** Comparison of the accuracy of CO<sub>2</sub> absorption prediction models for different types of forest plantations



**Рис. 7.** Предсказание объёмов депонированного углерода  
**Fig. 7.** Prediction of carbon dioxide deposition



**Рис. 8.** Предсказание объёмов депонированного углерода на юго-западе Калужской области  
**Fig. 8.** Prediction of carbon deposition volumes in the south-west of the Kaluga Region

### Заключение

Комплексный характер проведенного исследования, объединяющего геопространственные данные (мультиспектральные и многотемпоральные снимки Landsat, Sentinel, VIIRS), метеорологические ряды (температура, осадки, солнечная радиация) и почвенные показатели (pH, содержание органического вещества и гранулометрический состав), обеспечивает исключительную полноту учёта факторов, влияющих на динамику углеродного цикла. На практике это даёт возможность оперативно оценивать текущее состояние лесных экосистем и прогнозировать их развитие в условиях меняющегося климата. Такой подход создаёт предпосылки для регулярной актуализации данных по накоплению углерода на национальном уровне, способствуя выработке рациональных природоохранных мер и повышая эффективность управления лесными ресурсами.

Помимо этого, стоит отметить, что участие в глобальном «углеродном рынке» также может открыть дополнительные возможности для привлечения инвестиций и создания новых бизнес-моделей, таких как углеродные фермы или проекты по лесовосстановлению. Применение модели может позволить в России генерировать углеродные кредиты для международного рынка, потенциально обеспечивая доходы в размере 50–70 млрд рублей ежегодно к 2035 г. при цене \$25/т CO<sub>2</sub>-эквивалента. Это укрепит экономическую устойчивость страны и привлечёт инвестиции в зелёные технологии.

### Список источников

1. Intergovernmental Panel on Climate Change. (2022). Sixth Assessment Report. [Электронный ресурс]. URL: <https://www.ipcc.ch> (дата обращения: 07.04.2025).
2. International Energy Agency. (2023). Global Energy and CO<sub>2</sub> Status Report. [Электронный ресурс]. URL: <https://www.iea.org/> (дата обращения: 07.04.2025).
3. British Petroleum. (2022). BP Statistical Review of World Energy 2022. [Электронный ресурс]. URL: <https://www.bp.com/> (дата обращения: 07.04.2025).
4. European Commission, Eurostat. (2022). Greenhouse gas emission statistics. [Электронный ресурс]. URL: <https://ec.europa.eu/eurostat> (дата обращения: 08.04.2025).



5. United Nations. (2015). Paris Agreement. [Электронный ресурс]. URL: <https://unfccc.int/process-and-meetings/the-paris-agreement> (дата обращения: 08.04.2025).
6. Федеральная служба государственной статистики (Росстат). (2023). Статистический сборник «Охрана окружающей среды». [Электронный ресурс]. URL: <https://rosstat.gov.ru/> (дата обращения: 08.04.2025).
7. Минприроды РФ. (2022). Доклады о состоянии и об охране окружающей среды Российской Федерации. [Электронный ресурс]. URL: <https://www.mnr.gov.ru/> (дата обращения: 08.04.2025).
8. Государственная Дума РФ. (2021). Федеральный закон №296-ФЗ. [Электронный ресурс]. URL: <http://publication.pravo.gov.ru/> (дата обращения: 08.04.2025).
9. World Meteorological Organization. (2022). WMO Statement on the State of the Global Climate. [Электронный ресурс]. URL: <https://public.wmo.int/> (дата обращения: 09.04.2025).
10. Food and Agriculture Organization of the United Nations. (2021). State of the World's Forests. [Электронный ресурс]. URL: <https://www.fao.org/publications> (дата обращения: 09.04.2025).
11. Matiza C., Mutanga O., Peerbhay K., Odindi J., & Lottering R. A systematic review of remote sensing and machine learning approaches for accurate carbon storage estimation in natural forests. *Southern Forests: a Journal of Forest Science*. 2023. 85(3-4) (дата обращения: 07.04.2025).
12. Autumn Nguyen, Sulagna Saha, Machine Learning and Multi-source Remote Sensing in Forest Carbon Stock Estimation: A Review. [Электронный ресурс]. URL: <https://arxiv.org/abs/2411.17624> (дата обращения: 07.04.2025).
13. Advancing forest carbon stocks' mapping using a hierarchical approach. (2024). *Scientific Reports*. [Электронный ресурс]. URL: <https://www.nature.com/articles/s41598-024-71133-8> (дата обращения: 07.04.2025).
14. Reiersen G., Dao D., Lütjens B., Klemmer K., Zhu X., & Zhang C. (2021). Tackling the Overestimation of Forest Carbon with Deep Learning and Aerial Imagery. [Электронный ресурс]. URL: <https://arxiv.org/abs/2107.11320> (дата обращения: 07.04.2025).
15. Remote Sensing, MDPI, 16[18], 3394. (2023). Comprehensive Multi-Temporal Satellite Data for Boreal Forest Carbon Sequestration Analysis. [Электронный ресурс]. URL: <https://www.mdpi.com/2072-4292/16/18/3394> (дата обращения: 09.04.2025).

#### **Информация об авторах**

**Всеволод Сергеевич Чернышенко** – к.ф.-м.н., доцент

SPIN-код: 7749-1822

**Константин Дмитриевич. Белов** – бакалавр

SPIN-код: не представлен

**Леонид Борисович Кулыгин** – бакалавр

SPIN-код: не представлен

**Мария Артемовна Четыркина** – бакалавр

SPIN-код: не представлен

Статья поступила в редакцию 13.10.2025

Одобрена после рецензирования 21.10.2025

Принята к публикации 30.10.2025

Original article

# **A machine learning-based model for assessing carbon sequestration in russian forests using integrated satellite, meteorological, and soil data**

**V.S. Chernyshenko<sup>1</sup>, C.D. Belov<sup>2</sup>, L.B. Kulygin<sup>3</sup>, M.A. Chetyrkina<sup>4</sup>**

<sup>1-4</sup> Financial University under the Government of the Russian Federation (Moscow, Russia)

<sup>1</sup> vschernyshenko@fa.ru, <sup>2</sup> constantinbelov5903@gmail.com, <sup>3</sup> Leonid2004.ru@mail.ru, <sup>4</sup> m.chetyrkina24@gmail.com

## **Abstract**

The escalating anthropogenic emissions of greenhouse gases, predominantly CO<sub>2</sub> and methane, are compromising ecological stability, driving climate change, increasing the frequency of extreme weather events, and accelerating biodiversity loss. Conventional carbon sequestration assessment methods face limitations when applied to Russia's boreal landscapes due to inadequate representativeness in training datasets.

This study aims to develop an integrated multilevel model for quantifying CO<sub>2</sub> absorption by forest ecosystems through the synergistic integration of satellite remote sensing data, meteorological observations, and soil parameters using machine learning techniques.

The developed model exhibits superior predictive accuracy for key carbon sequestration parameters. Implementation of ensemble algorithms and neural networks yielded highly precise estimations (RMSE 0.25–0.35 t/ha; R<sup>2</sup> 0.82–0.88). These performance metrics confirm the model's robustness and applicability across diverse forest biomes spanning extensive regions of the Russian Federation.

The findings demonstrate the operational viability of artificial intelligence for large-scale environmental monitoring and carbon management, offering substantial potential for integration into national frameworks for ecological conservation planning.

## **Keywords**

*Machine learning, forest ecosystems, carbon balance, remote sensing, environmental monitoring, carbon sequestration, boreal forests*

## **For citation**

*Chernyshenko V.S., Belov C.D., Kulygin L.B., Chetyrkina M.A.* A machine learning-based model for assessing carbon sequestration in russian forests using integrated satellite, meteorological, and soil data. *Neurocomputers*. 2025. V. 27. № 6. P. 7–16. DOI: 10.18127/j19997493-202506-01 (in Russian).

## **References**

1. Intergovernmental Panel on Climate Change. (2022). Sixth Assessment Report. URL: <https://www.ipcc.ch>
2. International Energy Agency. (2023). Global Energy and CO<sub>2</sub> Status Report. URL: <https://www.iea.org/>
3. British Petroleum. (2022). BP Statistical Review of World Energy 2022. URL: <https://www.bp.com/>
4. European Commission, Eurostat. (2022). Greenhouse gas emission statistics. URL: <https://ec.europa.eu/eurostat>
5. United Nations. (2015). Paris Agreement. URL: <https://unfccc.int/process-and-meetings/the-paris-agreement>
6. Federal State Statistics Service. (2023). Statistical Compendium «Environmental Protection». URL: <https://rosstat.gov.ru/>
7. Ministry of Natural Resources and Ecology of Russia. (2022). State of the Environment and Environmental Protection Reports of the Russian Federation. URL: <https://www.mnr.gov.ru/>
8. State Duma of the Russian Federation. (2021). Federal Law No. 296-FZ. URL: <http://publication.pravo.gov.ru/>
9. World Meteorological Organization. (2022). WMO Statement on the State of the Global Climate. URL: <https://public.wmo.int/>
10. Food and Agriculture Organization of the United Nations. (2021). State of the World's Forests. URL: <https://www.fao.org/publications>
11. Matiza C., Mutanga O., Peerbhay K., Odindi J., & Lottering R. (2023). A systematic review of remote sensing and machine learning approaches for accurate carbon storage estimation in natural forests / Southern Forests: a Journal of Forest Science, 85(3-4)
12. Autumn Nguyen, Sulagna Saha, Machine Learning and Multi-source Remote Sensing in Forest Carbon Stock Estimation: A Review. URL: <https://arxiv.org/abs/2411.17624>
13. Advancing forest carbon stocks' mapping using a hierarchical approach. (2024). Scientific Reports. URL: <https://www.nature.com/articles/s41598-024-71133-8>
14. Reiersen G., Dao D., Lütjens B., Klemmer K., Zhu X., & Zhang C. (2021). Tackling the Overestimation of Forest Carbon with Deep Learning and Aerial Imagery. URL: <https://arxiv.org/abs/2107.11320>
15. Remote Sensing, MDPI, 16[18], 3394. (2023). Comprehensive Multi-Temporal Satellite Data for Boreal Forest Carbon Sequestration Analysis. URL: <https://www.mdpi.com/2072-4292/16/18/3394>

## **Information about the authors**

**Vsevolod S. Chernyshenko** – Dr. Sc. (Phys.-Math.), Associate Professor

**Constantin D. Belov** – Bachelor

**Leonid B. Kulygin** – Bachelor

**Maria A. Chetyrkina** – Bachelor

The article was submitted 13.10.2025

Approved after reviewing 21.10.2025

Accepted for publication 30.10.2025