

<https://doi.org/10.25686/foreco.2024.26.21.008>

УДК 528.88

ПОВЫШЕНИЕ ТОЧНОСТИ КЛАССИФИКАЦИИ ЛЕСОВ ПО СПУТНИКОВЫМ СНИМКАМ С ПОМОЩЬЮ ВСПОМОГАТЕЛЬНЫХ ДАННЫХ

А.К. Попова

Институт динамики систем и теории управления им. В.М. Матросова СО РАН, Иркутск

Своевременные и полные знания о составе лесов важны для задач поддержания биоразнообразия и экологического баланса, а также эффективного управления лесными ресурсами. Получить информацию о распределении и размере площадей деревьев можно с помощью классификации спутниковых снимков. Однако только оптических данных не всегда достаточно для получения результата требуемой точности из-за сходства спектральных характеристик некоторых лесных пород. Одним из подходов к повышению точности классификации леса является использование вспомогательных данных, таких как климатические, почвенные, топографические, а также вегетационные индексы. В статье приведен результат исследования для Слюдянского лесничества Иркутской области. Для проведения исследования был собран набор из 84 переменных, включающий каналы снимка спутника Sentinel-2, а также данные по почвам, климату, высоте полога леса и топографии. Для составления обучающей выборки были определены спектральные характеристики пяти пород деревьев на ключевых участках. Затем на исходном снимке были размечены полигоны, соответствующие этим породам, и общие типы поверхности (земля, трава, вода, облака). Классификация леса проводилась методом машинного обучения Random Forests. В работе приведены результаты классификации трех наборов переменных: только оптические каналы спутникового снимка, все 84 признака, сокращенный набор из 39 признаков. Первый набор переменных показал общую точность 82,77%. Использование всех 84 признаков повысило точность до 99,55%. Однако некоторые признаки показали нулевую важность для классификации. Поэтому был сформирован сокращенный набор из 39 признаков, общая точность расчетов на котором составила 99,42%. Небольшое сокращение точности при значительном уменьшении количества переменных позволило считать сокращенный набор наилучшим для классификации области исследования. Это влияет на скорость расчетов, делая процесс более эффективным без значительной потери точности.

Ключевые слова: классификация пород деревьев, климатические данные, данные о почве, данные ДЗЗ, спутниковые снимки, Sentinel-2, Chelsa, SoilGrids.

IMPROVING THE ACCURACY OF FOREST CLASSIFICATION USING SOIL AND METEOROLOGICAL DATA

A.K. Popova

Matrosov Institute for System Dynamics and Control Theory SB RAS, Irkutsk

Up-to-date and complete knowledge of forest structure is important for maintaining biodiversity and ecological balance, as well as for effective forest management. Information on the distribution and size of tree areas can be obtained by classifying satellite images, but optical data alone are not always sufficient to obtain the required accuracy due to the similarity of spectral characteristics of some forest species. One of the ap-

proaches to improve the accuracy of forest classification is to use such auxiliary data as climatic, soil, topographic, and vegetation indices. The paper presents the results of a study for the Slyudyanka forestry in the Irkutsk region. A set of 84 variables was collected, including both Sentinel-2 satellite image bands and data on soils, climate, forest canopy height, and topography. The spectral characteristics of five tree species in key areas were determined for the training sample, after which polygons corresponding to these species and common surface types (land, grass, water, clouds) were marked on the original image. Forest classification was performed using the Random Forests machine learning algorithm. The paper presents the classification results of three sets of variables: only the optical channels of the satellite image, all 84 features, and a reduced set of 39 features. The first set showed an overall accuracy of 82.77%. Using the whole set of variables increased the accuracy to 99.55%, but some features showed zero importance for classification. Therefore, a reduced set was formed, with a computational accuracy of 99.42%. The small reduction in accuracy with a significant reduction in the number of variables, which affects the speed of calculation, allowed us to consider the reduced set as the best for classifying the study area.

Keywords: *tree species classification, climate data, soil data, remote sensing data, satellite images, Sentinel-2, Chelsa, SoilGrids.*

Введение

Информация о распределении пород деревьев на исследуемой территории необходима для задач моделирования динамики леса, оценки пожароопасности, инвентаризации лесов, оценки запасов углерода. При этом актуальные данные достаточной полноты не всегда доступны исследователям и лицам, принимающим решения. Получить необходимые сведения о лесах можно с помощью мультиспектральных данных дистанционного зондирования Земли (ДЗЗ), широко представленных в открытых источниках с регулярным обновлением и различным разрешением. Для исследования лесных ресурсов часто используют изображения с аппаратов Sentinel-2 и Landsat 8 и 9 с разрешением соответственно 10 и 30 м (Nguyen et al., 2020; Talukdar et al., 2020; Bychkov, Popova, 2023).

Разделить разные породы деревьев на снимках помогают методы классификации, использующие в качестве основы обучающую выборку – набор предварительно размеченных на изображении полигонов. Каждому полигону присвоен соответствующий класс типа земной поверхности. Машинное обучение играет важную роль в классификации пород деревьев. Исследования показали (Wang et al., 2022; Wessel et al., 2018; Axelsson et al., 2021; Бычков и др., 2023), что алгоритмы Random Forest (RF), опорных векторов (SVM), k-ближайших соседей (K-NN) и Naïve Bayes (NB) могут эффективно классифицировать породы деревьев на основе спектральных и текстурных характеристик. Кроме того, интеграция данных активного и пассивного дистанционного зондирования, а также добавление вертикальных данных (топография, высота полога леса), еще больше повышает точность классификации древесных пород. Это позволяет различать разные виды деревьев и нелесные районы с высокой общей точностью.

Одних мультиспектральных снимков не всегда достаточно для проведения крупномасштабных экологических исследований. Распознавание пород деревьев может быть сложной задачей из-за сходства коэффициентов отражения и текстуры поверхности разных видов. В таких случаях одним из способов улучшения результатов классификации спутниковых данных является добавление к исходному набору каналов дополнительных данных: вегетационных индексов, топографических характеристик, почвенных и метеорологических карт.

В статье (You et al., 2022) рассмотрены методы повышения точности классификации видов деревьев с использованием изображений Sentinel-2 и вспомогательных данных. Авторы сравнили 16 различных комбинаций признаков для классификации видов лесных деревьев, включая спектральное отражение и индексы, текстуру, фенологическую информацию, топографию, осадки, температуру воздуха, индекс ультрафиолетового аэрозоля и концентрацию NO₂. Наилучшие результаты по классификации показал алгоритм Random Forest (RF) из четырех протестированных (RF, GTB, SVM и CART). Результаты показали повышение общей точности на 18% (до 82,69%) и увеличение коэффициента каппы на 0,21 при использовании вспомогательных данных, таких как температура, осадки и индекс ультрафиолетового аэрозоля, по сравнению с использованием только спектральных характеристик. При этом более важными признаками для классификации стали рельеф местности, индекс ультрафиолетового аэрозоля и фенологическая информация, в то время как часто используемые текстурные характеристики оказали ограниченное влияние на изменение точности.

Работа (Chiang, Valdez, 2019) посвящена методу классификации деревьев в Монголии путем интеграции топографических переменных (высота, уклон, экспозиция и кривизна) с оптической спектральной информацией. Авторы использовали алгоритм максимальной энтропии MaxEnt и получили общую точность 81% и коэффициент Каппа 0,70, по сравнению с 71% общей точностью и коэффициентом каппа 0,52 при использовании только спутниковых данных. При этом топографические переменные для классификации отдельных пород деревьев (береза, кедр, ива) показали более высокую важность, чем мультиспектральные данные. Однако одних топографических данных было недостаточно для точной классификации.

Методы картографирования почвенно-растительного покрова на основе мультиспектральных и стереоданных ZiYuan-3 рассмотрены в исследовании (Xie et al., 2019). Авторы использовали разносезонные спектральные данные и вспомогательные (текстурные, топографические, особенности высоты полога) данные. Использование нескольких источников данных повысило точность классификации почвенно-растительного покрова на 15,5% и классификации лесов на 12,7% по сравнению с использованием только мультиспектральных данных. Добавление данных о высоте полога леса не позволило в целом улучшить классификацию лесного покрова, но повысило точность результатов по конкретным породам деревьев (береза и монгольская сосна обыкновенная).

Целью работы стала оценка влияния дополнительных данных на точность классификации пород деревьев на примере Слюдянского лесничества Иркутской области, по сравнению с использованием только мультиспектральных спутниковых изображений. Достижение этой цели будет способствовать повышению качества цифровой инвентаризации лесов.

Область исследования

В качестве области исследования было выбрано Слюдянское лесничество Иркутской области (рис. 1). Оно занимает площадь 351 тыс. га, из них земель, покрытых лесной растительностью – 299 тыс. га, что составляет более 85% всей площади лесничества. Согласно Лесному плану Иркутской области (Лесной план..., 2019), в Слюдянском лесничестве сосной занято 13,9 тыс. га, елью – 4,6 тыс. га, пихтой – 22,3 тыс. га, лиственницей – 20,5 тыс. га, кедром –

159,4 тыс. га, березой – 34,1 тыс. га и осиной 3,2 тыс. га. Высокий процент лесистости и большие площади хвойных пород в сочетании с наличием горных труднодоступных лесных участков на территории делают актуальным уточнение классификации лесов области исследования.




Рис. 1. Область исследования на карте

Материалы и методика исследований

В качестве базовых данных для классификации лесного покрова в работе использовались все 13 каналов снимка спутника Sentinel-2. Для покрытия области исследования были поканально объединены 3 исходных снимка, затем они были обрезаны по контуру лесничества. Набор вспомогательных данных был составлен из наиболее распространенных вегетационных индексов (Wang et al., 2024), почвенных, топографических и климатических переменных, высоты полога леса (табл. 1).

Таблица 1. Перечень вспомогательных данных для классификации

Тип	Набор данных	Переменные	Описание
Почва	Soilgrids	bdod	Насыпная плотность, cg/cm ³
		cec	Емкость катионного обмена, mmol(c)/kg
		clay	Доля глинистых частиц (<0,002 мм), g/kg
		nitrogen	Общий азот, cg/kg
		phh2o	рН почвы
		sand	Доля песчаных частиц (> 0,05 мм), g/kg

		silt	Доля частиц ила ($\geq 0,002$ мм и $\leq 0,05$ мм), g/kg
		soc	Содержание органического углерода, dg/kg
Климат	WorldClim	tmax	Средняя максимальная температура за 1970-2000, °C
		tmin	Средняя минимальная температура за 1970-2000, °C
		precipitation	Сумма осадков за 1970-2000, мм
	Chelsa	bio1	Среднегодовая температура воздуха, °C
		bio2	Среднесуточный диапазон температур воздуха, °C
		bio4	Сезонность температуры (стандартное отклонение среднемесячной температуры), °C/100
		bio7	Годовой диапазон температуры воздуха (разница между максимальной температурой самого теплого месяца и минимальной температурой самого холодного месяца), °C
		bio12	Годовое количество осадков, kg/m ²
		bio15	Сезонность осадков, kg/m ²
		fcf	Частота смены заморозков (количество событий, в которых tmin или tmax выше или ниже 0°C)
		fgd	Первый день вегетационного периода
		gs1	Продолжительность вегетационного периода
		gst	Средняя температура вегетационного периода, °C
		lgd	Последний день вегетационного периода
		npp	Чистая первичная продуктивность за год, gC/m ²
		rsds_mean	Средняя солнечная радиация, MJ/m ²
		scd	Количество дней со снежным покровом
		swe	Количество жидкой воды при таянии снега, kg/m ²
Топография	Copernicus Digital Surface Model (DEM)	aspect	Аспект – ориентация уклона в градусах
		slope	Уклон (крутизна)
		hillshade	Затенение рельефа
		elevation	Высота
Высота полога	ETH Global Sentinel-2 10m Canopy Height		Глобальная карта высоты полога
Вегетационные индексы		NDVI	(NIR – Red) / (NIR + Red)
		RVI	Red / NIR
		NDI	(NIR – SWIR) / (NIR + SWIR)
		RI	(Red - Green) / (Red + Green)

Химические и механические параметры почвы напрямую связаны с тем, какие породы деревьев будут произрастать в данной местности. Данные по почве были получены с сайта проекта ISRIC World Soil Information (<https://www.isric.org/>). Там представлены глобальные наборы данных SoilGrids в виде карт в формате tif с разрешением 250 м, которые включают

сведения о химических и физических свойствах почвы. Значения каждого параметра приведены для 6 интервалов глубины почвы от 0 до 200 см. В качестве механических параметров для исследования были выбраны показатели плотности и состава почвы, химических – содержание азота и органического углерода, уровень pH. Для каждого параметра были загружены карты на все 6 интервалов глубины.

Климат оказывает сильное влияние на характер лесной растительности. В качестве климатических параметров были выбраны основные – минимальная и максимальная температура, количество осадков. Их значения были получены из наборов WorldClim, которые представляют собой усредненные значения за период 1970-2000 гг. с пространственным разрешением 30 секунд. Дополнительно были загружены биоклиматические наборы Chelsa. Они являются производными от основных климатических переменных и предназначены для моделирования распределения видов, так как отражают годовые тенденции (например, среднегодовую температуру), сезонность (годовой диапазон температуры и осадков), параметры вегетационного периода и экстремальные или ограничивающие экологические факторы. Значения биоклиматических переменных Chelsa являются средними за период 1981-2010 гг.

Высота дерева зависит от его породы. На территории области исследования произрастают как лиственные, так и хвойные деревья разных пород, поэтому было исследовано влияние данных о высоте полога на точность классификации. Глобальная карта высоты полога леса с разрешением 10 м загружена в виде набора ETH Global Sentinel-2 10m Canopy Height. Она содержит параметры высоты деревьев, полученные с помощью методов глубокого обучения на основе лидарных данных GEDI и оптических снимков Sentinel-2 (Lang et al., 2023).

Топография влияет на распределение лесных видов в горных экосистемах, поэтому топографические показатели используют для уточнения классификации пород деревьев (Liu et al., 2021). В работе параметры высоты, склонов и затенения были рассчитаны на основе цифровой модели рельефа Copernicus DEM, созданной в 2011-2015 гг.

При составлении обучающей выборки основой для составления обучающей выборки служила карта лесов России за 2009 г. с разрешением 150 м (Schepaschenko et al., 2018). На основе визуального сравнения этой карты со спутниковыми снимками высокого разрешения для каждой из семи пород деревьев было выбрано по несколько ключевых участков. Для каждого участка в QGIS с помощью плагина Semi-automatic classification plugin были вычислены спектральные характеристики по каналам снимка Sentinel-2, использованного в дальнейшем для классификации. После анализа полученных значений было решено проводить дальнейшую разметку выборки и классификацию по пяти породам – сосна, кедр, лиственница, пихта и береза. Спектральные характеристики осины и ели оказались слишком близкими к значениям для березы и пихты соответственно, а площади этих пород на территории лесничества значительно меньше. Поэтому в будущем для разметки участков, занятых этими осиной и елью, потребуется дополнительная информация.

На рис. 2 приведен график изменения значений отражения участков разных пород по каналам Sentinel-2. Полученные значения использовались для разметки полигонов, занятых выделенными породами. Дополнительно были размечены общие классы поверхности – вода, открытая земля, облака.




Рис. 2. График спектральных характеристик пород по каналам

Все спектральные и вспомогательные данные были приведены к одному разрешению, растры выровнены и обрезаны по контуру лесничества. Классификация проводилась методом машинного обучения Random Forests с помощью библиотеки Python scikit-learn.

Результаты

Сначала были классифицированы только каналы снимка Sentinel-2. При этом значение общей точности составило ОАА=82,77%, precision=0,87, полнота recall=0,76. После добавления всех вспомогательных данных полный набор составил 84 переменные. Результаты классификации показали общую точность ОАА=99,55%, precision=0,99, полноту recall=1,00. Для всех переменных была определена их важность (рис.3) для идентификации классов земной поверхности. Чем выше на рисунке значение количественной оценки признака, тем он оказался более важным для принятия решения методом Random forests. Каналы снимка Sentinel-2 в списке обозначены комбинацией литеры «В» с цифрами, где цифры – номер канала. Почвенные переменные были взяты для разной глубины, цифры в их названии обозначают среднее значение для этого интервала в см. Например, phh2o_15-30_mean – это среднее значение pH почвы на глубине от 15 до 30 см.

Как видно из рисунка 3, большинство оптических каналов спутникового снимка слабо влияли на результат классификации. Самый большой вклад в распознавание внес канал 10, предназначенный для выделения облаков. Исходный снимок был малооблачным, но легкие облака на нем есть. Низкая важность оптических каналов и большинства вегетационных индексов связана с тем, что при формировании части вспомогательных данных (климатические Chelsa и высота полога леса) использовали машинное обучение, в том числе на основе снимков Sentinel-2. Поэтому алгоритм Random forests при обучении выбирал наиболее информативные непересекающиеся признаки.

Из всех использованных переменных лучший результат показали: gst – средняя температура вегетационного периода; bio1 – среднегодовая температура воздуха; CanopyHeight – высота полога леса. Места с 5 по 10 в рейтинге важности также занимают климатические переменные, содержащие сведения о средней минимальной и максимальной температуре, количестве осадков, продолжительности вегетационного периода.

Из всех параметров почвы наиболее важными для классификации оказались: содержание азота в интервале 0-5 см; доля частиц ила на глубинах 0-5, 5-15 и 15-30 см; доля глинистых частиц на глубинах 15-30 и 30-60 см.




Рис. 3. Важность по всем переменным

Чтобы уменьшить время вычислений, было решено отбросить признаки с низкой важностью. После ряда экспериментов был выбран набор из 39 переменных, который обеспечил общую точность 99,42%. При этом значения важности признаков на уменьшенном наборе отличаются (рис. 4). Первые строчки также заняты климатическими параметрами – длительность вегетационного периода, сезонность осадков, диапазон температуры воздуха. Следом на четвертом месте идет ориентация склонов, которая в полном наборе находилась только в середине списка. Из почвенных переменных самыми важными остались количество частиц ила, к ним добавились рН почвы на глубине 60-100 см и насыпная плотность 15-30 см. При этом концентрация азота, которая в полном наборе имела наибольшее значение важности из почвенных переменных, в этом наборе показала самое низкое значение из всех признаков.




Рис. 4. Важность по сокращенному набору переменных

Полученный результат показывает большое влияние вспомогательных данных на результат классификации пород деревьев. На территории исследования это позволило повысить общую точность с 82,77% до 99,42%. При этом спектральные каналы спутникового снимка Sentinel-2 оказали наименьший вклад в процесс классификации, а наибольшее значение для результата

имели климатические переменные и высота полога леса. Значения важностей почвенных переменных – средние, причем в разных комбинациях переменных они могут сильно отличаться. Например, концентрация азота на глубине 0-5 см была самой важной из параметров почвы в наборе из 84 переменных, а среди 39 признаков она стала наименее важной.




Рис. 5. Результат классификации

Выводы

Проведенная оценка использования дополнительных данных при классификации пород деревьев показала их большое влияние – нам удалось повысить общую точность классификации по спутниковым снимкам на 16,65% до 99,42%. Впервые собранный набор из климатических, почвенных и топографических данных, а также высота полога леса, вместе использовались для классификации территории Слюдянского лесничества. Все вспомогательные данные получены из открытых источников и являются глобальными, поэтому могут использоваться для других территорий. Полученная классификация позволяет оценить размеры площадей деревьев разных пород, что важно для эффективного управления, планирования и моделирования лесных ресурсов.

Работа поддержана в рамках госзадания Минобрнауки России по проекту "Методы и технологии облачной сервис-ориентированной цифровой платформы сбора, хранения и обработки больших объёмов разноформатных междисциплинарных данных и знаний, основанные на применении искусственного интеллекта, модельно-управляемого подхода и машинного обучения" (номер гос. регистрации 121030500071-2).

Библиографический список

1. Бычков И.В., Ружников Г.М., Федоров Р.К., Попова А.К., Авраменко Ю.В. О классификации космических снимков Sentinel-2 нейронной сетью ResNet-50 // Компьютерная оптика. 2023. Т. 47, № 3. С. 474-481. DOI: 10.18287/2412-6179-CO-1216.
2. Лесной план Иркутской области 2019-2028. Приложение к Указу губернатора Иркутской области от 29.05.2019 №. 112-уг: Иркутск, 2019; 217 с.
3. Axelsson A. et al. Tree species classification using Sentinel-2 imagery and Bayesian inference // Int. J. Appl. Earth Obs. 2021. Vol. 100, P. 102318. DOI: 10.1016/j.jag.2021.102318.
4. Bychkov I., Popova A. Forest Landscape Model Initialization with Remotely Sensed-Based Open-Source Databases in the Absence of Inventory Data // Forests. 2023. Vol. 14(10). P. 1995. DOI: 10.3390/f14101995.
5. Chiang S., Valdez M. Tree Species Classification by Integrating Satellite Imagery and Topographic Variables Using Maximum Entropy Method in a Mongolian Forest // Forests. 2019. Vol. 10. P. 961. DOI: 10.3390/F10110961.
6. Lang N., Jetz W., Schindler K. et al. A high-resolution canopy height model of the Earth // Nat Ecol Evol. 2023. Vol. 7, P. 1778–1789. DOI: 10.1038/s41559-023-02206-6.
7. Liu M., Liu J., Atzberger C., Jiang Y., Ma M., Wang X. Zanthoxylum Bungeanum Maxim Mapping 633 with Multi-Temporal Sentinel-2 Images: The Importance of Different Features and Consistency of Results // ISPRS Journal of Photogrammetry and Remote Sensing. 2021. Vol. 174. P. 68–86. DOI:10.1016/j.isprsjprs.2021.02.003.
8. Nguyen T. et al. Landsat time-series for estimating forest aboveground biomass and its dynamics across space and time: A review // Remote Sens. 2020. Vol. 12. P. 98. DOI:10.3390/rs12010098.
9. Schepaschenko D, Moltchanova E, Shvidenko A, Blyshchyk V, Dmitriev E, Martynenko O, See L, Kraxner F. Improved Estimates of Biomass Expansion Factors for Russian Forests // Forests. 2018. №9(6). P. 312. <https://doi.org/10.3390/f9060312>.
10. Talukdar S. et al. Land-use land-cover classification by machine learning classifiers for satellite observations-A review // Remote Sens. 2020. Vol. 12, № 7. P. 1135. DOI: 10.3390/rs12071135.
11. Wang J. et al. Machine learning in modelling land-use and land cover-change (LULCC): Current status, challenges and prospects // Science of the Total Environment. 2022. Vol. 822. P. 153559. DOI: 10.1016/j.scitotenv.2022.153559.
12. Wessel M., Brandmeier M., Tiede D. Evaluation of different machine learning algorithms for scalable classification of tree types and tree species based on Sentinel-2 data // Remote Sens. 2018. Vol. 10. P. 1419. DOI: 10.3390/rs10091419.
13. Xie Z., Chen Y., Lu D., Li G., Chen E. Classification of Land Cover, Forest, and Tree Species Classes with ZiYuan-3 Multispectral and Stereo Data // Remote Sensing. 2019. Vol. 11, №. 2: 164. DOI: 10.3390/rs11020164.
14. You H, Huang Y, Qin Z, Chen J, Liu Y. Forest Tree Species Classification Based on Sentinel-2 Images and Auxiliary Data // Forests. 2022. Vol. 13(9). P. 1416. DOI: 10.3390/f13091416.
15. Wang X., Zhang C., Qiang Z., Xu W., Fan J. A New Forest Growing Stock Volume Estimation Model Based on AdaBoost and Random Forest Model // Forests. 2024. Vol. 15 (2). P. 260.

References

1. Bychkov I.V., Ruzhnikov G.M., Fedorov R.K., Popova A.K., Avramenko Yu.V. O klassifikatsii kosmicheskikh snimkov Sentinel-2 neironnoi set'yu ResNet-50 (On the classification of Sentinel-2 space images by the ResNet-50 neural network). *Komp'yuternaya optika*, 2023. Vol. 47, No. 3. pp. 474-481. DOI: 10.18287/2412-6179-CO-1216.
2. Lesnoi plan Irkutskoi oblasti 2019-2028. Prilozhenie k Ukazu gubernatora Irkutskoi oblasti ot 29.05.2019 №. 112-ug (Forest plan of the Irkutsk region 2019-2028. Appendix to the Decree of the Governor of the Irkutsk region dated 05/29/2019 No. 112-ug). Irkutsk, 2019; 217 p.
3. Axelsson A. et al. Tree species classification using Sentinel-2 imagery and Bayesian inference. *Int. J. Appl. Earth Obs*, 2021. Vol. 100, P. 102318. DOI: 10.1016/j.jag.2021.102318.
4. Bychkov I., Popova A. Forest Landscape Model Initialization with Remotely Sensed-Based Open-Source Databases in the Absence of Inventory Data. *Forests*, 2023. Vol. 14(10). P. 1995. DOI: 10.3390/f14101995.
5. Chiang S., Valdez M. Tree Species Classification by Integrating Satellite Imagery and Topographic Variables Using Maximum Entropy Method in a Mongolian Forest. *Forests*, 2019. Vol. 10. P. 961. DOI: 10.3390/F10110961.
6. Lang N., Jetz W., Schindler K. et al. A high-resolution canopy height model of the Earth. *Nat Ecol Evol*, 2023. Vol. 7. pp. 1778–1789. DOI: 10.1038/s41559-023-02206-6.

7. Liu M., Liu J., Atzberger C., Jiang Y., Ma M., Wang X. Zanthoxylum Bungeanum Maxim Mapping 633 with Multi-Temporal Sentinel-2 Images: The Importance of Different Features and Consistency of Results. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021. Vol. 174. pp. 68–86. DOI:10.1016/j.isprsjprs.2021.02.003.
8. Nguyen T. et al. Landsat time-series for estimating forest aboveground biomass and its dynamics across space and time: A review. *Remote Sens*, 2020. Vol. 12. P. 98. DOI:10.3390/rs12010098.
9. Schepaschenko D, Moltchanova E, Shvidenko A, Blyshchyk V, Dmitriev E, Martynenko O, See L, Kraxner F. Improved Estimates of Biomass Expansion Factors for Russian Forests. *Forests*, 2018. No. 9(6). P. 312. <https://doi.org/10.3390/f9060312>.
10. Talukdar S. et al. Land-use land-cover classification by machine learning classifiers for satellite observations-A review. *Remote Sens*, 2020. Vol. 12, No. 7. pp. 1135. DOI: 10.3390/rs12071135.
11. Wang J. et al. Machine learning in modelling land-use and land cover-change (LULCC): Current status, challenges and prospects. *Science of the Total Environment*, 2022. Vol. 822. P. 153559. DOI: 10.1016/j.scitotenv.2022.153559.
12. Wessel M., Brandmeier M., Tiede D. Evaluation of different machine learning algorithms for scalable classification of tree types and tree species based on Sentinel-2 data. *Remote Sens*, 2018. Vol. 10. P. 1419. DOI: 10.3390/rs10091419.
13. Xie Z., Chen Y., Lu D., Li G., Chen E. Classification of Land Cover, Forest, and Tree Species Classes with ZiYuan-3 Multispectral and Stereo Data. *Remote Sensing*, 2019. Vol. 11, No. 2. P. 164. DOI: 10.3390/rs11020164.
14. You H, Huang Y, Qin Z, Chen J, Liu Y. Forest Tree Species Classification Based on Sentinel-2 Images and Auxiliary Data. *Forests*, 2022. Vol. 13(9). P. 1416. DOI: 10.3390/f13091416.
15. Wang X., Zhang C., Qiang Z., Xu W., Fan J. A New Forest Growing Stock Volume Estimation Model Based on AdaBoost and Random Forest Model. *Forests*, 2024. Vol. 15 (2). P. 260.