

УДК: 631.4:912.4

DOI: 10.35595/2414-9179-2025-2-31-457-472

А. Н. Чашин<sup>1</sup>, Н. М. Мудрых<sup>2</sup>, И. А. Самофалова<sup>3</sup>

## ЦИФРОВОЕ КАРТОГРАФИРОВАНИЕ АГРОХИМИЧЕСКИХ СВОЙСТВ В ДЕТАЛЬНОМ МАСШТАБЕ С ПРИМЕНЕНИЕМ БПЛА

### АННОТАЦИЯ

Проведена оценка эффективности применения данных беспилотной аэрофотосъемки (БПЛА) для повышения точности агрохимического картографирования. Определена практическая значимость интеграции топографических и спектральных предикторов, полученных с БПЛА в моделях цифрового почвенного картографирования. Исследования проведены в Нечерноземной зоне на территории Пермского муниципального округа Пермского края. Объект исследований — участок на учебно-научном опытном поле ФГБОУ ВО Пермский ГАТУ г. Перми. Отбор проб почвы проведен до посева культуры с глубины 0–20 см по фиксированной сетке 100×200 м. Собран набор точечных агрохимических данных (точечные пробы и данные с пахотного слоя в разрезах) по четырем показателям (гумус, минеральный азот, фосфор, калий) и выполнено их пространственное моделирование методом «обычный кригинг». С помощью БПЛА были получены высокодетальные данные, на основе которых рассчитаны топографические и спектральные предикторы. Методом корреляционного анализа (Scatterplot в SAGA GIS) выявлены наиболее информативные предикторы, обладающие статистически значимой связью с агрохимическими свойствами почв. Для картографирования агрохимических показателей в качестве входных переменных в модель машинного обучения (метод Random Forest) использованы выявленные информативные предикторы. Полученные карты свойств сравнивали с результатами исходной интерполяции с использованием RMSE. Дополнительно исследовано, влияет ли улучшенная точность прогнозирования на практическую агрономическую значимость — на примере расчета потребности почв в фосфорных удобрениях. Сравнение результатов машинного обучения и геостатистических методов (кригинг) позволяет сделать вывод о целесообразности использования БПЛА в рамках систем точного земледелия с возможностью оптимизации распределения минеральных удобрений.

**КЛЮЧЕВЫЕ СЛОВА:** агрохимические свойства почв, цифровая почвенная картография, аэрофотосъемка с БПЛА, предикторы, машинное обучение, кригинг

<sup>1</sup> ФГБОУ ВО «Пермский государственный аграрно-технологический университет имени академика Д. Н. Прянишникова», ул. Петропавловская, д. 23, Пермь, Россия, 614990, *e-mail:* [chascshin@mail.ru](mailto:chascshin@mail.ru)

<sup>2</sup> ФГБОУ ВО «Пермский государственный аграрно-технологический университет имени академика Д. Н. Прянишникова», ул. Петропавловская, д. 23, Пермь, Россия, 614990, *e-mail:* [nata020880@hotmail.com](mailto:nata020880@hotmail.com)

<sup>3</sup> ФГБОУ ВО «Пермский государственный аграрно-технологический университет имени академика Д. Н. Прянишникова», ул. Петропавловская, д. 23, Пермь, Россия, 614990, *e-mail:* [samofalovairaida@mail.ru](mailto:samofalovairaida@mail.ru)

Aleksey N. Chashchin<sup>1</sup>, Natalya M. Mudrykh<sup>2</sup>, Iraida A. Samofalova<sup>3</sup>

## DIGITAL MAPPING OF AGROCHEMICAL PROPERTIES ON A DETAILED SCALE USING UAVS

### ABSTRACT

The effectiveness of using aerial photography from an unmanned aerial vehicle (UAV) data to improve the accuracy of agrochemical mapping has been evaluated. The practical significance of integrating topographic and spectral predictors obtained from UAVs in digital soil mapping models has been determined. The research was conducted in the Non-Chernozem zone on the territory of the Perm Municipal District of the Perm Territory. The object of research is a site at the educational and scientific experimental field of the Perm SATU, Perm. Soil sampling was carried out before sowing the crop from a depth of 0–20 cm on a fixed grid of 100×200 m. A set of point agrochemical data (spot samples and data from the arable layer in sections) was collected for four indicators (humus, mineral nitrogen, phosphorus, potassium) and their spatial modeling was performed using the “ordinary kriging” method. Using the UAV, highly detailed data was obtained, on the basis of which topographic and spectral predictors were calculated. The method of correlation analysis (Scatterplot in SAGA GIS) revealed the most informative predictors with a statistically significant relationship with the agrochemical properties of soils. The identified informative predictors were used to map agrochemical indicators as input variables to the machine learning model (Random Forest method). The obtained property maps were compared with the results of the initial interpolation using RMSE. Additionally, it was investigated whether the improved forecasting accuracy affects the practical agronomic significance, using the example of calculating soil demand for phosphorous fertilizers. A comparison of the results of machine learning and geostatistical methods (kriging) allows us to conclude that it is advisable to use UAVs in precision farming systems, with the possibility of optimizing the distribution of mineral fertilizers.

**KEYWORDS:** agrochemical properties of soils, digital soil cartography, aerial photography from UAVs, predictors, machine learning, kriging

### ВВЕДЕНИЕ

Цифровое картографирование континуальных свойств почвенного покрова в детальном масштабе может быть осуществлено в комплексе, сочетающем применение беспилотных летательных аппаратов (БПЛА) [Савин, 2015], лабораторные исследования индивидуальных почвенных проб [Цифровая почвенная картография..., 2017] и методов машинного обучения [Докучаев, 2017]. Такой подход позволяет учитывать как точечные измерения почвенных характеристик, так и пространственные закономерности их распределения, выявляемые с помощью дистанционного зондирования и математико-картографического моделирования.

Цифровые модели рельефа [Гафуров, 2017] позволяют извлекать важную информацию о пространственной вариабельности агрохимических свойств почв. В последние годы использование БПЛА в почвенной картографии получило широкое распространение

---

<sup>1</sup> FSBEI HE “Perm State Agro-Technological University named after academician D. N. Pryanishnikov”, 23, Petropavlovskaya str., Perm, 614990, Russia, e-mail: [chascshin@mail.ru](mailto:chascshin@mail.ru)

<sup>2</sup> FSBEI HE “Perm State Agro-Technological University named after academician D. N. Pryanishnikov”, 23, Petropavlovskaya str., Perm, 614990, Russia, e-mail: [nata020880@hotmail.com](mailto:nata020880@hotmail.com)

<sup>3</sup> FSBEI HE “Perm State Agro-Technological University named after academician D. N. Pryanishnikov”, 23, Petropavlovskaya str., Perm, 614990, Russia, e-mail: [samofalovairaida@mail.ru](mailto:samofalovairaida@mail.ru)

благодаря высокой пространственной разрешающей способности съемки, оперативности получения данных и возможности мультиспектрального анализа [Каиштанов, 2018]. Спектральные индексы [Пивченко, 2019] и цифровые модели рельефа [Гафуров, 2017] на основе данных БПЛА позволяют извлекать важную информацию о пространственной вариабельности агрохимических свойств почв.

Одним из ключевых инструментов для анализа таких данных являются методы машинного обучения. Такие алгоритмы, как множественная логистическая регрессия, метод опорных векторов (SVM) и случайный лес (Random Forest, RF) позволяют строить прогнозные модели, основываясь на многомерных взаимосвязях между агрохимическими свойствами почвы и дистанционными данными [Минаев, 2020]. Применение этих методов позволяет не только уточнять традиционные карты почвенных характеристик, но и выявлять скрытые закономерности, которые трудно обнаружить с помощью классических статистических и геостатистических методов. При этом, несмотря на очевидные преимущества, интеграция данных БПЛА и машинного обучения в цифровое почвенное картографирование требует тщательной калибровки моделей и валидации полученных карт. Для объективной оценки эффективности такого подхода необходимо сравнивать результаты моделирования с традиционными методами пространственной интерполяции и проверять точность прогнозов по независимым контрольным данным [Pouladi, 2019; Мудрых, 2020; Han, Suh, 2024].

В настоящее время востребованной задачей, решаемой при помощи карт агрохимических свойств почв в детальном масштабе, является внедрение элементов системы точного земледелия, что особенно актуально при оптимизации применения минеральных удобрений [Куцаева, 2020; Брыжко, Шабалина, 2021; Беленков, 2025].

Таким образом, исследование возможностей сочетания данных БПЛА и методов машинного обучения для построения высокоточных карт агрохимических свойств почвы является актуальным направлением развития почвенной картографии на сегодняшний день. В связи с вышеизложенным, сформулирована цель исследований — оценить методику цифрового картографирования агрохимических свойств почвы на основе данных БПЛА и машинного обучения.

## МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ

Объектом исследования является почвенный покров ключевого участка на учебно-научном опытном поле ФГБОУ ВО Пермский ГАТУ, г. Пермь. Площадь территории равна 13,4 га (рис. 1). Участок представляет собой склон южной экспозиции. С применением аэрофотосъемки с использованием БПЛА была создана подробная почвенная карта обследуемого участка [Чащин, 2024]. Масштаб цифрового картографирования свойств почвенного покрова равен 1:2 500.

### Методы исследований

Для создания ортофотоплана участка (рис. 2) была проведена БПЛА-съемка. Модель БПЛА — DJI mini 2 (учетный номер РОСАВИАЦИИ 0u66296). Даты съемки — 22.06.2023 и 12.09.2023 г. Высота съемки — 50 м. В связи с существующим законодательством в области мониторинга земель при помощи БПЛА для проведения съемки было получено разрешение Единой системы организации воздушного движения (ЕС ОрВД). Номера режима ВР 8534 и ВР 8744. Запрос временного режима осуществлялся через систему «Небосвод». Создание ортофотоплана и цифровой модели рельефа выполнялось в программе Agisoft Metashape Professional.



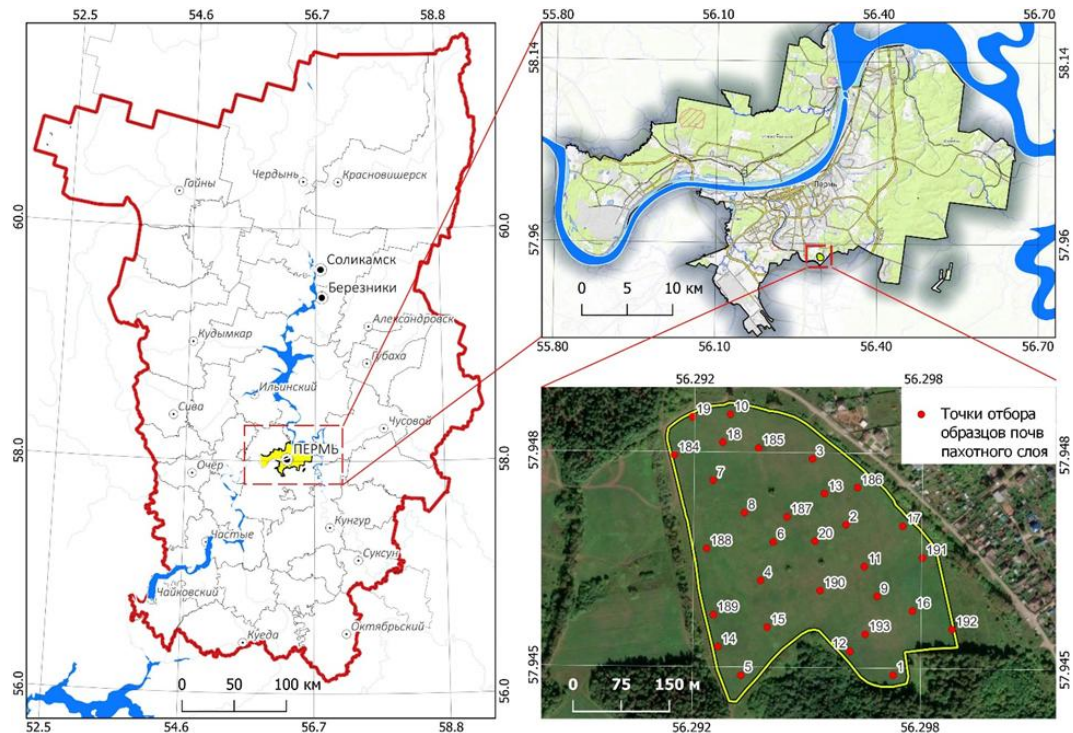


Рис. 1. Местоположение территории исследований  
Fig. 1. Location of the research area



Рис. 2. Цифровой ортофотоплан участка исследований: а — 3D-вид (дата 22.06.2023),  
b — снимок от 12.09.2023 (открытая поверхность почвы),  
c — снимок от 22.06.2023 (период вегетации)  
Fig. 2. Digital orthophotoplane of the research area: a — 3D view (date 06.22.2023),  
b — snapshot from 09.12.2023 (open soil surface),  
c — snapshot from 06.22.2023 (growing season)

Пространственное разрешение созданных ортофотопланов составляет 10 см/пикс, являясь высокодетальным. По полученным материалам аэрофотосъемки сформировано 2 набора предикторов<sup>1</sup> агрохимических свойств почв: топографические и спектральные.

Топографические предикторы созданы в результате цифрового моделирования рельефа методами фотограмметрической обработки аэрофотоснимка открытой поверхности почвы от 12.09.2024. Общее число равно 13, которое включало: цифровая модель рельефа, метры (DEM), расстояние до дренажной сети (Channel Network Distance), индекс сходимости потоков (Convergence Index), индекс длины и крутизны склона (LS-Factor), плановая кривизна (Plan Curvature), Profile Curvature (профильная кривизна), Relative Slope Position (относительное положение на склоне), суммарная водосборная площадь (Total Catchment Area), глубина долины (Valley Depth), экспозиция (Aspect), уклоны, градусы (Slope), индекс топографического положения (TPI), топографический индекс влажности (TWI). Геоизображения некоторых топографических предикторов представлены на рис. 3.

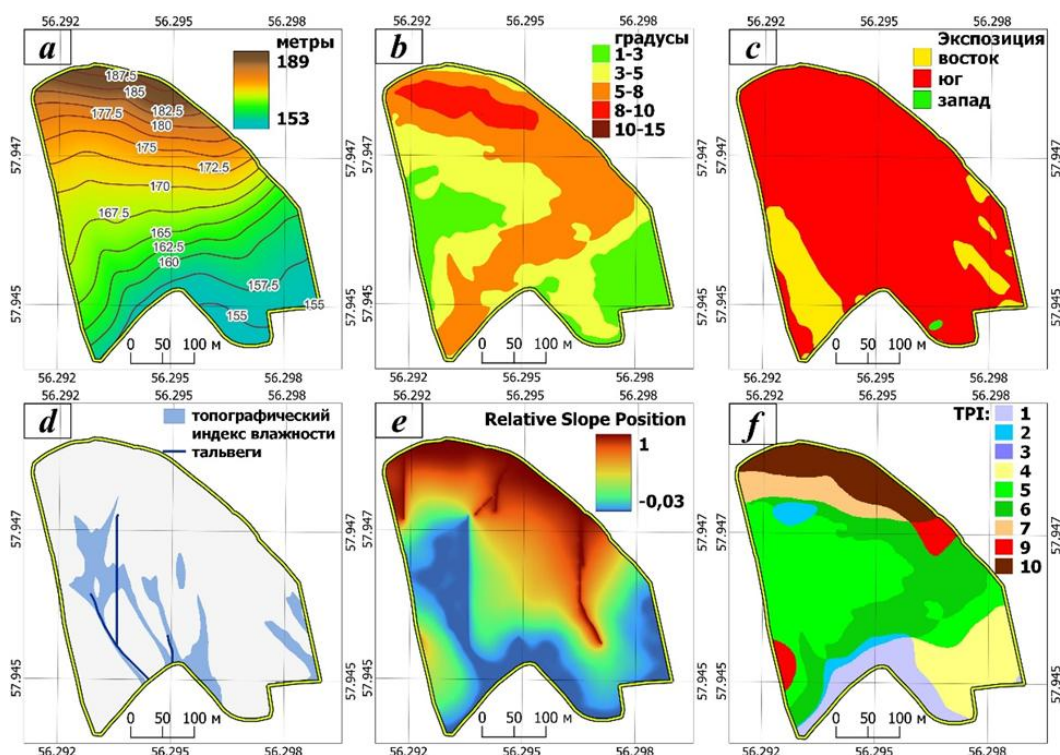


Рис. 3. Геоизображения топографических предикторов: а — цифровая модель рельефа; б — уклоны; с — экспозиция склонов; д — топографический индекс влажности и тальвеги; е — относительное положение на склоне; ф — индекс топографического положения (1 — подножье склона, 2 — понижения, 3 — ровный участок, 4 — прямой склон, 5 — средние части склонов, 6 — верхние части склонов, 7 — перегибы склонов, 9 — гребневидные участки, 10 — водораздельные пространства)

Fig. 3. Geo-images of topographic predictors: a — DEM; b — slopes; c — slope exposure; d — topographic index of humidity and talweg; e — relative position on the slope; f — index of topographic position (1 — foot of the slope, 2 — downgrades, 3 — flat area, 4 — straight slope, 5 — average parts of the slopes, 6 — upper parts of the slopes, 7 — elephant bends, 9 — ridge-like areas, 10 — watershed spaces)

<sup>1</sup> От англ. predictor; to predict — предсказывать, прогнозировать



Спектральные предикторы: отражение в синем, зеленом и красном каналах электромагнитного спектра, а также спектральные индексы: NGRDI [Hunt, 2005], GLI [Hunt, 2013], VARI [Susantoro, 2018] вычисленные для двух дат аэрофотосъемки: вегетационный период (22.06.2023) и состояние открытой поверхности почвы (12.09.2023). Геоизображения спектральных индексов приведены на рис. 4.

Полевые работы, помимо съемки с БПЛА, включали отбор индивидуальных почвенных проб из пахотного слоя почвы 0–20 см. Всего на территории участка было отобрано 30 индивидуальных почвенных образцов. Места отбора образцов почв отмечены на рис. 1.

Лабораторные методы включали определение содержания гумуса (ГОСТ 26213-2021) и элементов питания: аммонийного азота (ГОСТ Р 53219-2008) и нитратного азота (ГОСТ 26951-86), подвижный фосфор ( $P_2O_5$ , мг/кг) и обменный калий ( $K_2O$ ) по методу Кирсанова (ГОСТ Р 54650-2011).

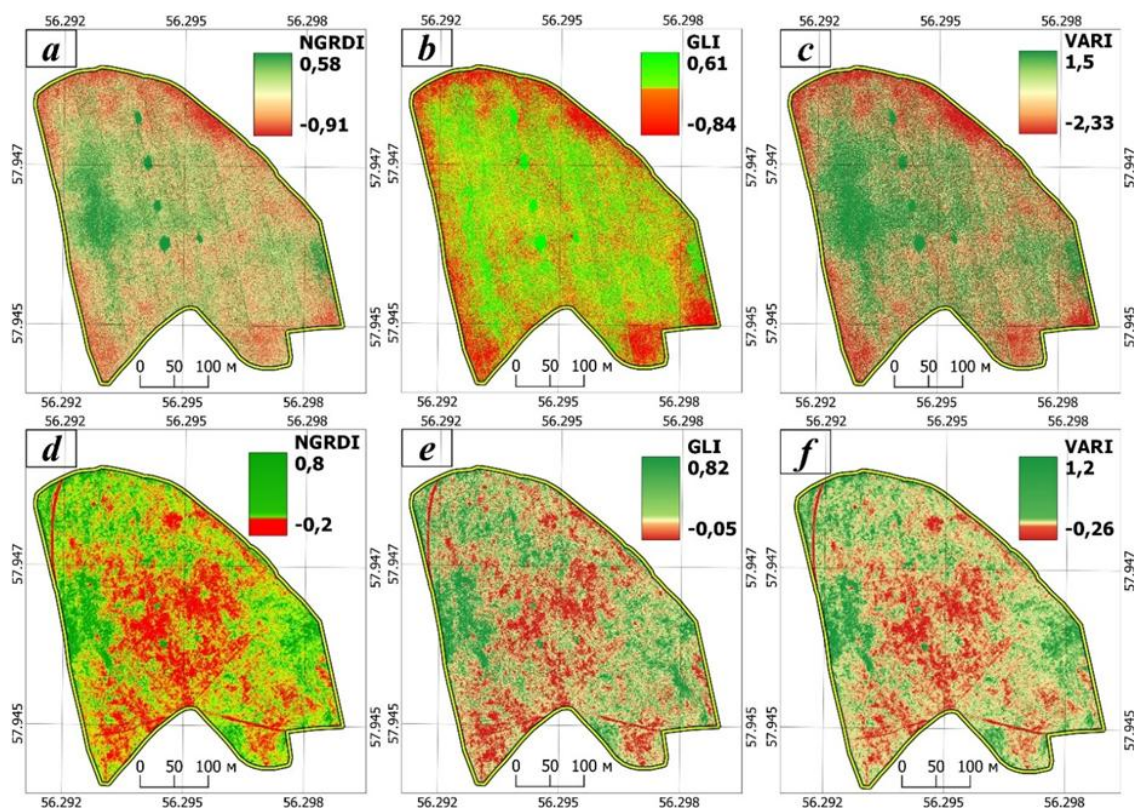


Рис. 4. Геоизображения спектральных предикторов: спектральные индексы открытой поверхности почв: а — NGRDI; б — GLI; в — VARI; спектральные индексы растительного покрова: д — NGRDI; е — GLI; ф — VARI  
 Fig. 4. Geo-images of spectral predictors: spectral indices of the open soil surface: а — NGRDI; б — GLI; в — VARI; spectral indices of vegetation cover: д — NGRDI; е — GLI; ф — VARI

Обработку пространственных данных выполняли в QGIS 3.34 (подготовка картографической основы отбора индивидуальных почвенных проб, визуализация, оформление карт), SAGA GIS 9.2 (цифровое моделирование рельефа, корреляция растровых слоев) и ArcGIS 10.8, модуль Geostatistical Analyst (математико-картографическое моделирование пространственного распределения агрохимических свойств).

Для пространственного моделирования с применением данных БПЛА использовался метод «Случайный лес» (Random Forest), реализованный с помощью библиотеки scikit-learn

в программной среде Python. Случайный лес представляет собой ансамблевый метод машинного обучения, основанный на построении множества решающих деревьев и агрегировании их предсказаний для повышения точности и устойчивости модели [Докучаев, 2017]. В качестве обучающей выборки использовали таблицу, содержащую значения агрохимических показателей в точках отбора образцов и соответствующие значения морфометрических параметров рельефа. Объектом прогноза послужила таблица, включающая пространственную матрицу предикторов, в качестве которых использовали отобранные показатели, продемонстрировавшие наибольшую корреляцию с изучаемыми агрохимическими свойствами.

## РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ И ИХ ОБСУЖДЕНИЕ

В результате лабораторного анализа агрохимических показателей в почвенных образцах, установлено, что содержание гумуса варьирует от очень низкого (1,4 %) до низкого (3,5 %), обеспеченность почв фосфором и калием высокая и очень высокая (табл. 1). Данные по элементам питания ( $P_2O_5$  и  $K_2O$ ) не соответствуют нормальному распределению, поскольку среднее и медиана имеют значительную разность. По этой причине для корректного построения геостатистических поверхностей распределения по этим показателям проведено логарифмирование по методу нормальных меток.

Табл. 1. Показатели вариационной статистики агрохимических свойств почв ( $n = 30$ )  
Table 1. Indicators of variation statistics agrochemical properties of soils ( $n = 30$ )

Показатель	Значения показателей				Std. Dev.*
	мин.	макс	среднее	медиана	
Гумус, %	1,4	3,5	2,3	2,1	0,65
Nмин, мг/кг	4,1	45,9	17,9	13,5	13,66
$P_2O_5$ , мг/кг	204	572	345	305	119,62
$K_2O$ , мг/кг	94	850	232	154	225,16

\*Std. Dev. — стандартное отклонение

Результаты анализа пространственного распределения континуальных свойств почвенного покрова отражают графики тренда и вариограмм. Тренд-анализ (рис. 5) выявил выраженные закономерности распределения агрохимических свойств по направлениям восток-запад и север-юг.

Содержание гумуса демонстрирует слабовыраженный тренд на увеличение в центральной части участка по оси X, при этом по направлению север-юг наблюдается незначительное снижение. Минеральный азот характеризуется отчетливым увеличением в южной и восточной частях территории, что указывает на влияние микрорельефа. Концентрация подвижного фосфора имеет максимум в западной части поля с тенденцией к снижению к востоку и к югу. Распределение обменного калия также показывает локальное увеличение в северо-западной части, что может быть связано с его аккумуляцией в понижениях рельефа. В целом, выявленные тренды указывают на пространственную неоднородность свойств почв и подтверждают необходимость проведения детрендинга перед выполнением пространственной интерполяции.

Построенные вариограммы (рис. 6) свидетельствуют о различной степени пространственной автокорреляции для исследованных агрохимических свойств почвенного покрова участка.

Для гумуса наблюдается слабая пространственная зависимость: значения полудисперсии ( $\gamma$ ) растут с расстоянием, однако кривая модели достигает плато достаточно быстро, что указывает на ограниченное влияние пространственного фактора. Минеральный азот

проявляет наиболее выраженную автокорреляцию — с увеличением расстояния полудисперсия ( $\gamma$ ) возрастает значительно, особенно на первых 3–5 интервалах, что свидетельствует о наличии четких пространственных структур в распределении этого элемента. Вариограмма для подвижного фосфора показывает умеренную пространственную зависимость с постепенным ростом значений  $\gamma$ , в то время как для обменного калия ( $K_2O$ ) пространственная структура практически отсутствует — значения полудисперсии колеблются вокруг константы, а кривая модели почти горизонтальна. Таким образом, минеральный азот и подвижный фосфор характеризуются наибольшей степенью пространственной автокорреляции, тогда как гумус и особенно обменный калий имеют случайный характер распределения по участку.

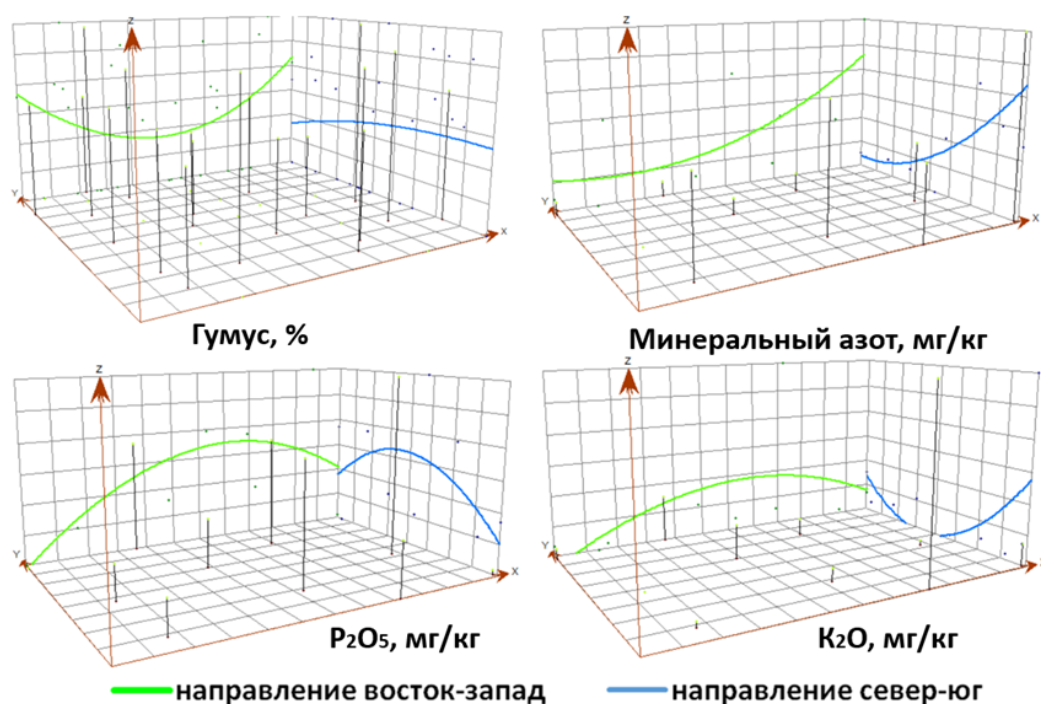


Рис. 5. Графики тренда агрохимических свойств почв: ось  $X$  — направление по долготе; ось  $Y$  — направление по широте; ось  $Z$  — значение агрохимического показателя (гумус, %; минеральный азот, мг/кг;  $P_2O_5$ , мг/кг;  $K_2O$ , мг/кг)

Fig. 5. Trend charts of agrochemical properties of soils:  $X$  — axis is the longitude direction;  $Y$  — axis is the latitude direction;  $Z$  — axis is the value of the agrochemical indicator (humus, %; mineral nitrogen, mg/kg;  $P_2O_5$ , mg/kg;  $K_2O$ , mg/kg)

Подобраны оптимальные параметры создания геостатистических растров агрохимических свойств почвенного покрова. При создании карт средствами модуля geostatistical analyst ArcGIS результаты перекрестной проверки показали наименьшие значения показателя среднеквадратического отклонения (RMSE) у метода «обычный кригинг». В связи с этим данный метод применен для создания агрохимических картограмм. Сформированные геоизображения представлены на рис. 7.

Для карты содержания гумуса использовали градацию из «Национального атласа почв», а для визуализации фосфора применена равноинтервальная классификация диапазона значений.



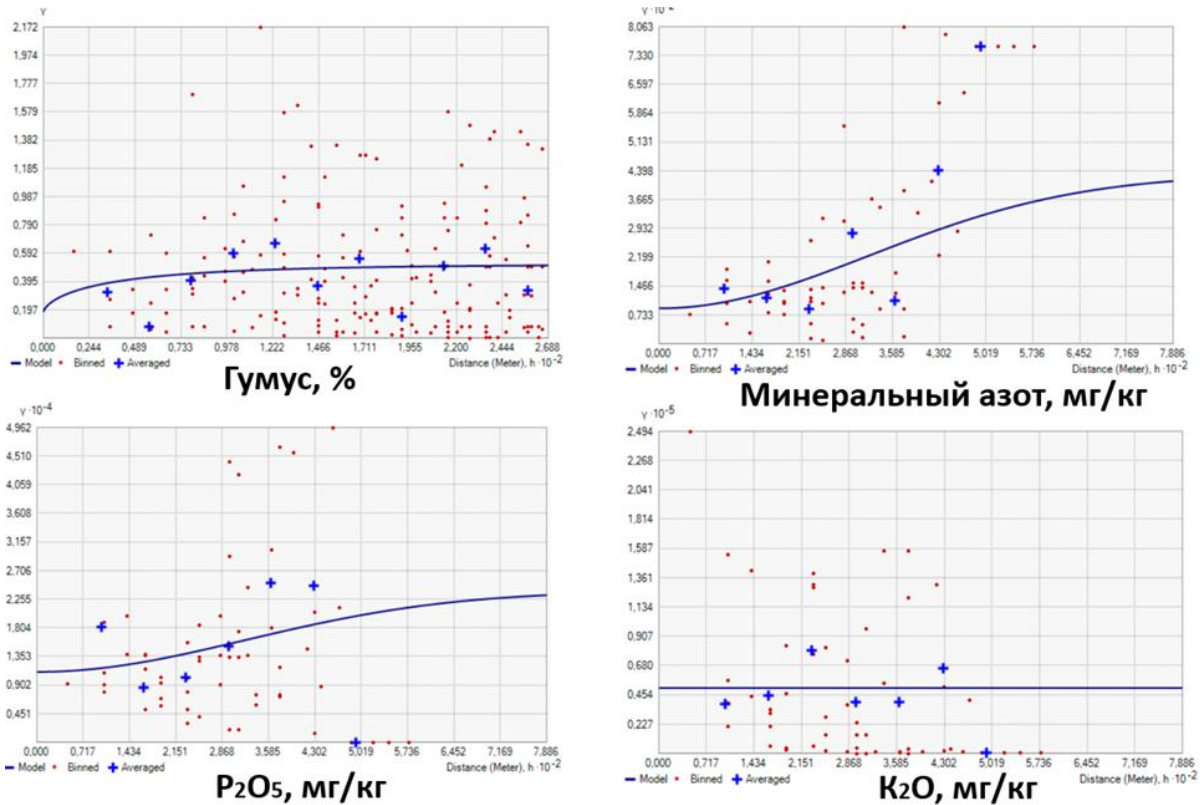


Рис. 6. Вариограммы агрохимических свойств почв  
Fig. 6. Variograms of agrochemical properties of soils

С целью отбора наиболее информативных предикторов для последующего машинного обучения был проведен корреляционный анализ между агрохимическими показателями и параметрами рельефа. Расчет коэффициентов корреляции выполнялся в SAGA GIS с использованием инструмента «Scatterplot» (график рассеяния). Этот инструмент позволяет получить коэффициент детерминации для парных растровых слоев. Такой подход оказался информативным, поскольку позволяет предварительно выявить параметры, наиболее тесно связанные с агрохимическими свойствами почвы, тем самым сузив набор входных переменных для построения прогностических моделей. Коэффициенты корреляции агрохимических свойств с топографическими параметрами приведены в табл. 2. Установлено, что наиболее сильная отрицательная корреляция наблюдается между содержанием минерального азота и абсолютной высотой (DEM) ( $r = -0,87$ ), а также с относительным положением склона (Relative Slope Position) ( $r = -0,55$ ), что указывает на накопление азота в нижних частях склона. Гумус положительно коррелирует с глубиной долины (Valley Depth) ( $r = 0,50$ ) и имеет обратную корреляцию с положением на склоне ( $r = -0,42$ ), что также подтверждает закономерности аккумуляции органического вещества. Для  $P_2O_5$  и  $K_2O$  определены средние коэффициенты корреляции с крутизной (Slope), расстоянием до дренажной сети (Channel Network Distance) и глубиной долины. Расчет корреляции растров дал возможность обоснованно выбрать набор предикторов, отражающих пространственную неоднородность факторов рельефа и оказывающих влияние на распределение почвенных свойств.

Коэффициенты корреляции спектральных параметров со свойствами почвы значительно менее информативны по сравнению с топографическими. Однако следует отметить, что в вегетационный период по азоту и содержанию гумуса растры спектральных индексов имеют более тесную связь (особенно связь индекса VARI, которая стала выше в 33 p.), чем

открытая поверхность почвы, что указывает на важность растительного покрова как индикатора плодородия почв (табл. 3).

Таким образом, в результате анализа, основанного на получении коэффициентов корреляции растровых карт определены следующие предикторы:

- гумус: Relative Slope, Valley Depth;
- минеральный азот: DEM, Channel Network Distance, Relative Slope Position, Valley Depth;
- фосфор: Slope, Relative Slope Position;
- калий: DEM, TPI.

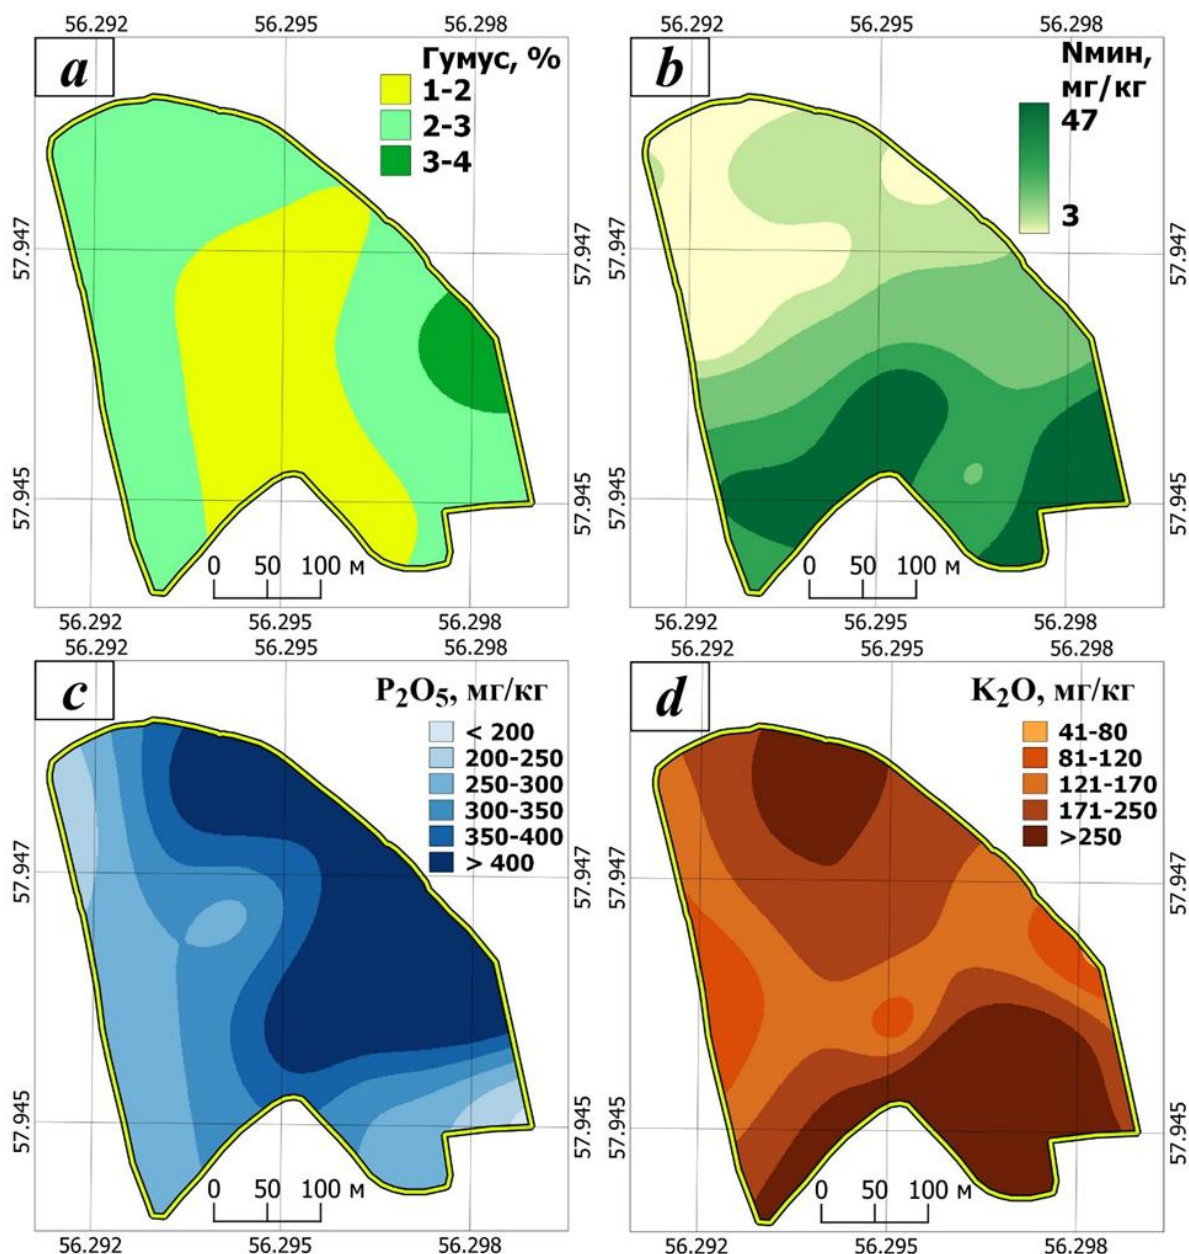


Рис. 7. Геоизображения агрохимических свойств, полученные методом «обычный кригинг»: а — гумус; б —  $N_{мин}$ ; в —  $P_2O_5$ ; д —  $K_2O$   
 Fig. 7. Geo-images of agrochemical properties obtained by the “ordinary kriging” method: a — humus; b —  $N_{min}$ ; c —  $P_2O_5$ ; d —  $K_2O$

Табл. 2. Коэффициенты корреляции Пирсона некоторых топографических предикторов с агрохимическими свойствами почвы

Table 2. Pearson correlation coefficients of some topographic predictors with agrochemical properties of the soil

Свойства почв	Channel Network Distance	LS-Factor	Relative Slope Position	Valley Depth	DEM	Aspect	Slope	TPI	TWI
Гумус	0,27	0,14	−0,42	0,50	0,17	−0,20	−0,17	−0,32	0,12
N <sub>мин</sub>	−0,57	0,10	−0,55	0,60	−0,87	−0,42	−0,35	−0,53	−0,24
P <sub>2</sub> O <sub>5</sub>	0,37	0,39	0,45	−0,32	0,10	0,05	0,47	0,28	0,15
K <sub>2</sub> O	0,19	0,20	0,24	0,32	−0,50	0,37	0,24	−0,41	0,07

Обозначения:

Channel Network Distance — расстояние до дренажной сети

LS-Factor — индекс длины и крутизны склона

Relative Slope Position — относительное положение на склоне

Valley Depth — глубина долины

DEM — абсолютная высота

Aspect — экспозиция

Slope — уклоны

TPI — индекс топографического положения

TWI — топографический индекс влажности

Табл. 3. Коэффициенты корреляции Пирсона спектральных предикторов с агрохимическими свойствами почвы

Table 3. Pearson correlation coefficients of spectral predictors with agrochemical properties of soil

Свойства почв	RED	GREEN	BLUE	NGRDI	GLI	VARI
Гумус	−0,16/−0,04	−0,13/0,17	−0,09/−0,06	0,02/0,28	0,02/0,24	0,01/0,33
N <sub>мин</sub>	0,05/0,24	0,06/0,22	0,13/0,20	0,05/0,23	0,04/0,22	0,06/0,20
P <sub>2</sub> O <sub>5</sub>	0,08/0,03	0,06/0,05	−0,02/−0,02	0,05/−0,04	0,05/0,00	−0,04/−0,03
K <sub>2</sub> O	0,03/0,17	0,00/0,20	0,06/0,10	−0,09/−0,08	−0,05/−0,07	−0,10/−0,05

Примечание. В числителе — открытая поверхность почвы по снимку от 12.09, в знаменателе — растительный покров по снимку от 22.06

Спектральные переменные в связи со слабой корреляцией использованы не были.

В рамках моделирования с использованием алгоритма «Random Forest» в качестве входных предикторов, помимо данных о рельефе, дополнительно были использованы пространственно-интерполированные растры свойств почвы, полученные методом обычного кригинга. Такой подход основан на концепции spatial stacking [Sekulić, 2020], предполагающей включение в модель предсказанных пространственных поверхностей как дополнительных признаков. Это позволяет учесть пространственную автокорреляцию и пространственные закономерности распределения агрохимических свойств, тем самым повышая точность и устойчивость модели. Использование геостатистических растров, полученных методом «обычный кригинг», как вспомогательных переменных способствует более полному описанию сложных взаимосвязей между факторами среды и почвенными параметрами, что особенно актуально в условиях неоднородных агроландшафтов.

В результате пространственного моделирования на основе предикторов были сформированы карты агрохимических свойств почв в детальном м-бе 1:2 500 (рис. 8).

Для сравнения с результатами геостатистического моделирования было проведено вычисление значений RMSE, получаемых в результате кросс-валидации (табл. 4).



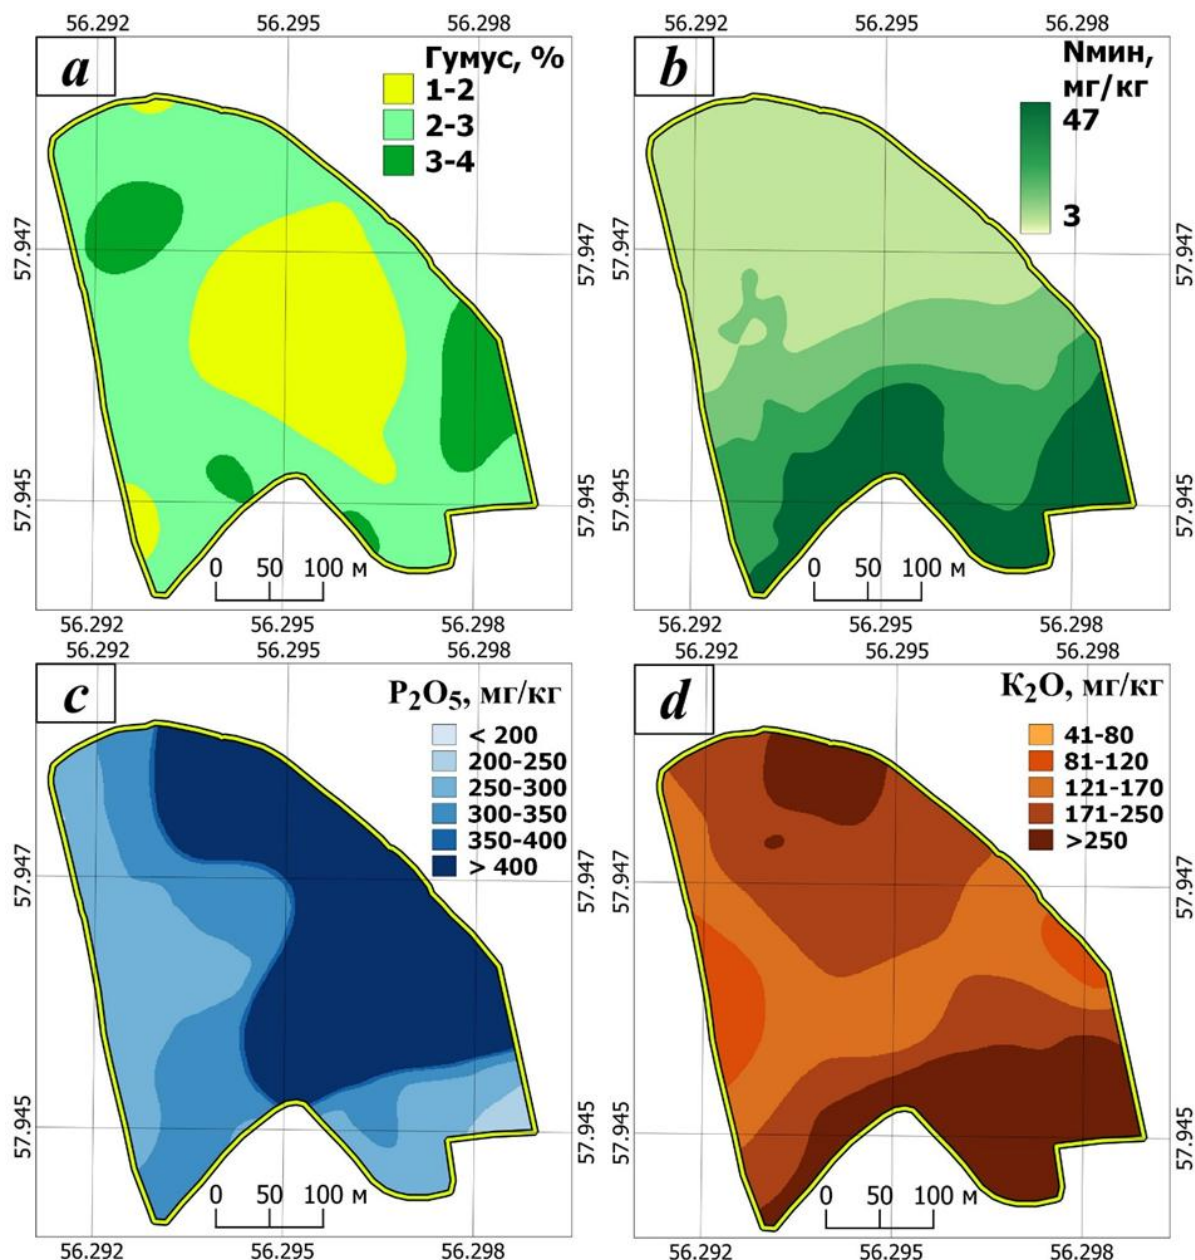


Рис. 8. Пространственные модели агрохимических свойств почв, созданные методом Random Forest: а — гумус; б —  $N_{min}$ ; в —  $P_2O_5$ ; д —  $K_2O$

Fig. 8. Spatial models of agrochemical properties of soils created by the Random Forest method: а — humus; б —  $N_{min}$ ; в —  $P_2O_5$ ; д —  $K_2O$

Табл. 4. Значение RMSE по результатам кросс-валидации

Table 4. RMSE value based on cross-validation results

Метод	Гумус, %	$N_{min}$ , мг/кг	$P_2O_5$ , мг/кг	$K_2O$ , мг/кг
Random Forest	0,14	8,3	28,1	61,9
Ordinary Kriging	0,71	12,5	63,5	120,1

Результаты анализа свидетельствуют о том, что точность прогнозного картографирования с использованием машинного обучения и данных БПЛА выше геостатистических поверхностей от 20 % (гумус) до 52 % (фосфор). В контексте практического применения, на примере данных по фосфору: площади почв, имеющие обеспеченность менее 200 мг/кг составляют 0,8 га, а на основе БПЛА-данных, обработанных методом машинного обучения, площадь равна 0,2 га. В данном примере полученные результаты позволяют сократить объемы фосфорных удобрений.

## ВЫВОДЫ

Современные условия информационных технологий позволяют использовать в методике цифрового картографирования агрохимических свойств почвы данные БПЛА и машинное обучение (Random Forest). Установлено, что метод машинного обучения, на примере алгоритма Random Forest и с включением геостатистических переменных (растров топографических индексов и ЦМР, а также карт, полученных методом кригинга) позволяет достоверно повысить точность пространственного моделирования агрохимических показателей почвы по сравнению с традиционными методами интерполяции. Полученные значения RMSE при перекрестной валидации подтверждают эффективность такого подхода: улучшение прогноза составило от 20 % (для содержания гумуса) до 52 % (для содержания фосфора), что указывает на значимый вклад пространственных зависимостей и спектральной информации в точность предсказаний. С практической точки зрения полученные результаты демонстрируют потенциал применения БПЛА и алгоритмов машинного обучения в задачах агрохимического картографирования и оптимизации внесения удобрений, что было продемонстрировано на примере картографирования подвижного фосфора.

## БЛАГОДАРНОСТИ

Работа выполнена при финансовой поддержке Министерства науки и высшего образования РФ (проект № 1023051000003-9-4.1.1).

## ACKNOWLEDGEMENTS

The study was financially supported by the Ministry of Science and Higher Education of the Russian Federation (project No. 1023051000003-9-4.1.1).

## СПИСОК ЛИТЕРАТУРЫ

- Беленков А. И., Мазиров М. А., Воронов М. А. Результаты научного и практического освоения точного земледелия в полевом опыте. Плодородие, 2025. № 1(142). С. 31–41. DOI: 10.25680/S19948603.2025.142.08.
- Брыжко И. В., Шабалина Т. В. Геоинформационное обеспечение точного земледелия на примере Тюменской области. ИнтерКарто. ИнтерГИС. Материалы Международной конференции, 2021. Т. 27. Ч. 4. С. 66–81. DOI: 10.35595/2414-9179-2021-4-27-66-81.
- Гафуров А. М. Возможности использования беспилотного летательного аппарата для оценки почвенной и овражной эрозии. Ученые записки Казанского университета. Серия: Естественные науки, 2017. Т. 159. № 4. С. 654–667.
- Докучаев П. М. Построение цифровой почвенной карты и картограммы углерода с использованием методов цифрового почвенного картографирования (на примере Вятско-Камской провинции дерново-подзолистых почв южной тайги): Диссертация на соискание ученой степени кандидата биологических наук. М., 2017. 206 с.

*Капитанов А. Н., Вернюк Ю. И., Савин И. Ю., Щепотьев В. В., Докукин П. А., Шарычев Д. В., Ли К. А.* Картографирование ручейковой эрозии пахотных почв по данным с беспилотных летательных аппаратов. Почвоведение, 2018. № 4. С. 506–512. DOI: 10.7868/S0032180X18040111.

*Куцаева О. А.* Создание менеджмент-зон для дифференцированного внесения минеральных удобрений с использованием инструментов геостатистики. Вестник Белорусской государственной сельскохозяйственной академии, 2020. № 2. С. 176–181.

*Минаев Н. В.* Цифровая модель почвенно-ландшафтных связей Владимирского Ополя. Диссертация на соискание ученой степени кандидата биологических наук. М., 2020. 149 с.

*Мудрых Н. М., Самофалова И. А., Чащин А. Н.* Прогнозирование эрозионных потерь почвы с использованием модели RUSLE. АгроЭкоИнфо, 2020. № 4. Электронный ресурс: [http://agroecoinfo.narod.ru/journal/STATYI/2020/4/st\\_430.pdf](http://agroecoinfo.narod.ru/journal/STATYI/2020/4/st_430.pdf) (дата обращения 10.04.2025).

*Пивченко Д. В., Мешалкина Ю. Л., Ярославцев А. М., Тихонова М. В., Визирская М. М., Васенев И. И.* Сравнительный анализ вегетационных индексов для агроэкологического мониторинга озимой пшеницы в условиях Московской области. АгроЭкоИнфо, 2019. № 3. Электронный ресурс: [http://agroecoinfo.narod.ru/journal/STATYI/2019/3/st\\_324.doc](http://agroecoinfo.narod.ru/journal/STATYI/2019/3/st_324.doc) (дата обращения 10.04.2025).

*Савин И. Ю., Вернюк Ю. И., Фараслис И.* Возможности использования беспилотных летательных аппаратов для оперативного мониторинга продуктивности почв. Бюллетень почвенного института имени В. В. Докучаева, 2015. № 80. С. 95–105. DOI: 10.19047/0136-1694-2015-80-95-105.

Цифровая почвенная картография. М.: РУДН, 2017. 156 с.

*Чащин А. Н., Гилёв В. Ю.* Картографирование почв на основе аэрофотосъемки с БПЛА. АгроЭкоИнфо, 2024. № 5. DOI: 10.51419/202145502. Электронный ресурс: [http://agroecoinfo.ru/STATYI/2024/5/st\\_502.pdf](http://agroecoinfo.ru/STATYI/2024/5/st_502.pdf). (дата обращения 10.04.2025).

*Han H., Suh J.* Spatial Prediction of Soil Contaminants Using a Hybrid Random Forest — Ordinary Kriging Model. Applied Sciences, 2024. V. 14. No. 4. P. 1666. DOI: 10.3390/app14041666.

*Hunt E. R., Cavigelli M., Daughtry C. S. T., McMurtrey J. E., Walthall C. L.* Evaluation of Digital Photography from Model Aircraft for Remote Sensing of Crop Biomass and Nitrogen Status. Precision Agriculture, 2005. V. 6. P. 359–378. DOI: 10.1007/s11119-005-2324-5.

*Hunt E. R., Doraiswamy P. C., McMurtrey J. E., Daughtry C. S. T., Perry E. M., Akhmedov B.* A Visible Band Index for Remote Sensing Leaf Chlorophyll Content at the Canopy Scale. International Journal of Applied Earth Observation and Geoinformation, 2013. V. 21. P. 103–112. DOI: 10.1016/j.jag.2012.07.020.

*Pouladi N., Møller A. B., Tabatabai S., Greve M. H.* Mapping Soil Organic Matter Contents at Field Level with Cubist, Random Forest and Kriging. Geoderma, 2019. V. 342. P. 85–92. DOI: 10.1016/j.geoderma.2019.02.019.

*Sekulić A., Kilibarda M., Heuvelink G. B. M., Nikolić M., Bajat B.* Random Forest Spatial Interpolation. Remote Sensing, 2020. V. 12. No. 10. P. 1687. DOI: 10.3390/rs12101687.

*Susantoro T. M., Wikantika K., Saepuloh A., Harsolumakso A. H.* Selection of Vegetation Indices for Mapping the Sugarcane Condition Around the Oil and Gas Field of North West Java Basin, Indonesia. IOP Conference Series: Earth and Environmental Science, 2018. No. 149. P. 012001. DOI: 10.1088/1755-1315/149/1/012001.



## REFERENCES

- Belenkov A. I., Mazirov M. A., Voronov M. A.* Results of Scientific and Practical Development of Precision Farming in Field Experiment. *Plodorodie (Fertility)*, 2025. No. 1(142). P. 31–41 (in Russian). DOI: 10.25680/S19948603.2025.142.08.
- Bryzhko I. V., Shabalina T. V.* GIS-Based Support for Precision Farming on the Example of the Tyumen Region. *InterCarto. InterGIS. Proceedings of International Conference*, 2021. V. 27. Part 4. P. 66–81 (in Russian). DOI: 10.35595/2414-9179-2021-4-27-66-81.
- Chashchin A. N., Gilyov V. Yu.* Soil Mapping Based on UAV Aerial Photography. *AgroEcoInfo*, 2024. No. 5. DOI: 10.51419/202145502. Web resource: [http://agroecoinfo.ru/STATYI/2024/5/st\\_502.pdf](http://agroecoinfo.ru/STATYI/2024/5/st_502.pdf) (accessed 10.04.2025) (in Russian).
- Digital soil cartography. Moscow: RUDN University, 2017. 156 p. (in Russian).
- Dokuchaev P. M.* Construction of a Digital Soil Map and Carbon Cartogram Using Digital Soil Mapping Methods (On the Example of the Vyatka-Kamskaya Province of Sod-Podzolic Soils of the Southern Taiga). The dissertation for the PhD in biological sciences. Moscow, 2017. 206 p. (in Russian).
- Gafurov A. M.* Possible Use of Unmanned Aerial Vehicle for Soil Erosion Assessment. *Uchenye Zapiski Kazanskogo Universiteta. Seriya: Estestvennye Nauki (Proceedings of Kazan University. Series: Natural Sciences)*, 2017. V. 159. No. 4. P. 654–667 (in Russian).
- Han H., Suh J.* Spatial Prediction of Soil Contaminants Using a Hybrid Random Forest — Ordinary Kriging Model. *Applied Sciences*, 2024. V. 14. No. 4. P. 1666. DOI: 10.3390/app14041666.
- Hunt E. R., Cavigelli M., Daughtry C. S. T., McMurtrey J. E., Walthall C. L.* Evaluation of Digital Photography from Model Aircraft for Remote Sensing of Crop Biomass and Nitrogen Status. *Precision Agriculture*, 2005. V. 6. P. 359–378. DOI: 10.1007/s11119-005-2324-5.
- Hunt E. R., Doraiswamy P. C., McMurtrey J. E., Daughtry C. S. T., Perry E. M., Akhmedov B.* A Visible Band Index for Remote Sensing Leaf Chlorophyll Content at the Canopy Scale. *International Journal of Applied Earth Observation and Geoinformation*, 2013. V. 21. P. 103–112. DOI: 10.1016/j.jag.2012.07.020.
- Kashtanov A. N., Vernyuk Yu. I., Savin I. Yu., ShchepotyeV V. V., Dokukin P. A., Sharychev D. V., Li K. A.* Mapping of Rill Erosion of Arable Soils Based on Unmanned Aerial Vehicles Survey. *Eurasian Soil Science*, 2018. V. 51. No. 4. P. 479–484. DOI: 10.7868/S0032180X18040111.
- Kutsaeva O. A.* Creation of Management Zones for Differentiated Application of Mineral Fertilizers with the Use of Geostatistics Tools. *Bulletin of the Belarussian State Agricultural Academy*, 2020. No. 2. P. 176–181.
- Minaev N. V.* Digital Model of Soil-Landscape Connections of the Vladimirske Opolye. The dissertation for the PhD in biological sciences. Moscow, 2020. 149 p. (in Russian).
- Mudrykh N. M., Samofalova I. A., Chashchin A. N.* Forecasting Soil Erosional Losses Using the RUSLE Model. *AgroEcoInfo*, 2020. No. 4. Web resource: [http://agroecoinfo.narod.ru/journal/STATYI/2020/4/st\\_430.pdf](http://agroecoinfo.narod.ru/journal/STATYI/2020/4/st_430.pdf) (accessed 10.04.2025) (in Russian).
- Pivchenko D. V., Meshalkina Yu. L., Yaroslavtsev A. M., Tikhonova M. V., Vizirskaya M. M., Vasenev I. I.* Comparative Analysis of Vegetation Indices for Agroecological Monitoring of Winter Wheat in the Moscow Region. *AgroEcoInfo*, 2019. No. 3. Web resource: [http://agroecoinfo.narod.ru/journal/STATYI/2019/3/st\\_324.doc](http://agroecoinfo.narod.ru/journal/STATYI/2019/3/st_324.doc) (accessed 10.04.2025) (in Russian).

*Pouladi N., Møller A. B., Tabatabai S., Greve M. H.* Mapping Soil Organic Matter Contents at Field Level with Cubist, Random Forest and Kriging. *Geoderma*, 2019. V. 342. P. 85–92. DOI: 10.1016/j.geoderma.2019.02.019.

*Savin I. Yu., Vernyuk Yu. I., Faraslis I.* The Possible Use of Pilotless Aircrafts for Operative Monitoring of Soil Productivity. *Dokuchaev Soil Bulletin*, 2015. V. 80. P. 95–105 (in Russian). DOI: 10.19047/0136-1694-2015-80-95-105.

*Sekulić A., Kilibarda M., Heuvelink G. B. M., Nikolić M., Bajat B.* Random Forest Spatial Interpolation. *Remote Sensing*, 2020. V. 12. No. 10. P. 1687. DOI: 10.3390/rs12101687.

*Susantoro T. M., Wikantika K., Saepuloh A., Harsolumakso A. H.* Selection of Vegetation Indices for Mapping the Sugarcane Condition Around the Oil and Gas Field of North West Java Basin, Indonesia. *IOP Conference Series: Earth and Environmental Science*, 2018. No. 149. P. 012001. DOI: 10.1088/1755-1315/149/1/012001.

---