

Применение гиперспектральных данных дистанционного зондирования и методов геостатистики в задаче управления азотным режимом зерновых культур

В. П. Якушев¹, О. А. Митрофанова¹, В. М. Буре¹, Е. П. Митрофанов¹,
А. А. Смолина¹, Я. Б. Панкратова¹, В. В. Якушев²

¹ Санкт-Петербургский государственный университет
Санкт-Петербург, 199034, Россия
E-mail: o.a.mitrofanova@spbu.ru

² Санкт-Петербургский государственный аграрный университет
Пушкин, Санкт-Петербург, 196601, Россия

Актуальность исследования обусловлена необходимостью оперативного и неразрушающего мониторинга азотного обеспечения зерновых культур для эффективного агроуправления. Современные технологии дистанционного зондирования (гиперспектральная и мультиспектральная съёмка с применением беспилотных летательных средств и спутников) предоставляют обширные данные, однако требуют разработки методов анализа для выделения информативных признаков и обоснования стратегий внесения удобрений. Цель работы заключается в разработке методических подходов к статистическому и вариограммному анализу данных по поиску информативных каналов при мульти- и гиперспектральной съёмке сельскохозяйственных посевов на примере задачи управления азотным режимом зерновых культур. Экспериментальная часть исследования проводилась на полях Ленинградской области (2022–2024). Наиболее информативными для оценки азотного статуса пшеницы оказались вегетационные индексы ChlRI (*англ.* Chlorophyll Reflectance Index), SIPI (*англ.* Structure Insensitive Pigment Index), GNDVI (*англ.* Green Normalized Difference Vegetation Index), NDVI761 (*англ.* Normalized Difference Vegetation Index 761), NDVI850 (*англ.* Normalized Difference Vegetation Index 850) и NDVI780 (*англ.* Normalized Difference Vegetation Index 780), демонстрирующие значимую корреляцию с уровнем азота. При этом подтверждена гипотеза о неэффективности спектральных методов в условиях высокой засорённости полей: корреляции между данными дистанционного зондирования и обеспеченностью азотом оказались статистически незначимыми в опыте с высокой засорённостью. Ключевым инструментом для выбора агро-технологии стал вариограммный анализ, позволяющий оценить долю случайной микрокомпоненты (ξ) в пространственной неоднородности поля. Установлено, что при $\xi > 0,5$ (например, $\xi = 0,64$ в эксперименте 2022 г.) применение дифференцированных технологий нецелесообразно из-за преобладания неуправляемой вариабельности. Для расчёта доз агрохимикатов перспективным направлением признано использование нейросетевых моделей (модификации U-Net), обеспечивающих точность до 99,96 % при комбинировании данных видимого, ближнего инфракрасного диапазонов и вегетационных индексов. Предложенная трёхэтапная методология интегрирует анализ спектральных данных, оценку пространственной неоднородности и принятие технологических решений, повышая эффективность управления азотным питанием посевов.

Ключевые слова: гиперспектральная съёмка, данные дистанционного зондирования, азотный режим, пшеница, вариограммный анализ, точное земледелие, нейросетевые технологии

Одобрена к печати: 21.07.2025

DOI: 10.21046/2070-7401-2025-22-5-129-144

Введение

Мониторинг обеспеченности растений полезными веществами — одна из приоритетных подзадач при принятии эффективных агроуправленческих решений. При этом важными составляющими при обследовании сельскохозяйственного поля выступают не только точность определения необходимых доз агрохимикатов для внесения, но также оперативность и не деструктивный характер анализа.

В последние годы всё чаще для решения подобных задач применяются беспилотные авиационные системы (Митрофанова и др., 2023; Bure et al., 2022; Li et al., 2024; Wang et al., 2024) и спутниковая съёмка (Якушев и др., 2020б; Nino et al., 2024; Segarra et al., 2023), которые позволяют в необходимые сроки получать изображения, в том числе и с высоким пространственным разрешением, и анализировать собранные данные в контексте оценки обеспеченности посевов основными веществами (азотом, магнием, серой, водой и т.д.). При этом следует отметить, что азот считается одним из основных макроэлементов для растений, который необходим для их роста и развития.

В последнее время гиперспектральная съёмка находит широкое применение в различных областях, таких как экология, геология и медицина. Она используется для изучения растительности, диагностики заболеваний растений, оценки урожайности и определения количества макроэлементов в почве (Munipalle et al., 2024; Ram et al., 2024). С помощью методов обработки снимков, сделанных в ходе гиперспектральной съёмки, можно получить гиперспектральные данные для обработки, которые представляют собой множество различных спектральных каналов. В отличие от обычных цифровых изображений, где каждый пиксель представляется в трёх каналах, например, в цветовых моделях RGB (красный, зелёный, синий), HSV (цветовой тон, насыщенность, яркость) и Lab (светлота, два цветовых компонента), гиперспектральные данные включают сотни или даже тысячи узких спектральных каналов, покрывающих широкий спектр длин волн.

Для выделения информативных длин волн и вегетационных индексов в сельском хозяйстве используются различные методы. В статье (Jia et al., 2019) было выделено несколько методов для выбора длин волн. Например, множественная линейная регрессия, частичная регрессия, методы опорных векторов, байесовская линейная регрессия и многие другие. Для каждого из методов были выделены свои преимущества и недостатки. Несмотря на перечисленные алгоритмы и достигнутый с их помощью прогресс в области сельского хозяйства, авторы остановились на методе последовательных проекций — SIPLS-SPA (*англ.* synergy interval partial least squares with successive projections algorithm). С помощью этого метода было выделено восемь длин волн для оценки биомассы листьев озимой пшеницы. Группа авторов в статье (Евстифорова, Денисова, 2018) рассматривает зависимость качества регрессионного моделирования урожайности по данным вегетационного индекса NDVI (*англ.* Normalized Difference Vegetation Index) и дополнительных факторов. Основной задачей исследования было выделение дополнительных факторов, которые влияют на плодородие почвы, с помощью регрессионных моделей. В результате использования факторов плодородия точность моделей возросла. Также было отмечено, что регрессионные модели на основе вегетационных индексов остаются наиболее перспективными средствами прогнозирования урожайности.

Помимо определения наиболее информативных спектральных данных для принятия эффективных агроуправленческих решений необходимо выбрать технологию внесения агрохимикатов. Несмотря на то, что многие работы демонстрируют преимущества применения новых дифференцированных подходов (Galioto et al., 2017; Vecchio et al., 2022), вопросы их целесообразности на конкретных сельскохозяйственных полях остаются открытыми (Budzko, Medennikov, 2021; Loures et al., 2020; Mizik, 2023). Результаты предыдущих исследований научной группы показали, что в случае высокой доли влияния на пространственное варьирование рассматриваемого агроэкологического параметра (например, азота) случайной компоненты, технологии точного земледелия не позволят выровнять поле по показателю обеспеченности растений необходимым макроэлементом (Якушев и др., 2020а). Хорошо изученным и перспективным методом решения этой задачи представляется вариограммный анализ (Якушев и др., 2020б).

Цель исследования — разработка методических подходов к статистическому и вариограммному анализу данных по поиску информативных каналов при мульти- и гиперспектральной съёмке сельскохозяйственных посевов на примере задачи управления азотным режимом зерновых культур.

Объекты и методы

Данные дистанционного зондирования

В работе были использованы данные дистанционного зондирования, полученные на опытных сельскохозяйственных полях, расположенных в Ленинградской области, с применением беспилотных авиационных систем, а также двух камер: гиперспектральной (диапазон длин волн от 390,04 до 1031,23 нм) и мультиспектральной (пять каналов — R (англ. Red), G (англ. Green), B (англ. Blue), NIR (англ. Near Infrared), Red Edge).

Съёмка проводилась в 2022 и 2024 гг. на двух различных полях, где были заложены специальные тестовые площадки — небольшие участки поля со сформированным уровнем обеспеченности определённым макроэлементом (азотом, магнием, серой). В рамках рассматриваемой задачи использовались тестовые полосы с известными дозами азота (0, 40, 80, 120, 160 и 200 кг действующего вещества на гектар). В 2022 г. были заложены две полосы, в каждой из которых шесть тестовых площадок. В 2024 г. предусмотрена одна линия из шести площадок. Произрастающая культура на обоих полях — яровая пшеница. При этом в 2024 г. были созданы условия очень высокой засорённости.

Каждый год съёмка проводилась четыре раза за вегетационный период. Предварительная обработка мультиспектральных изображений выполнялась с использованием программы Agisoft Metashape (выравнивание, геопривязка, построение ортофотопланов), а гиперспектральных — с помощью Spectronon (коррекция, привязка, извлечение спектральных данных).

Вегетационные индексы

Вегетационные индексы представляют собой показатели, которые рассчитываются в результате операций с различными спектральными диапазонами. Они отражают общее состояние растительности и используются для решения различных задач в сельском хозяйстве. Существует множество вегетационных индексов, но в настоящей работе рассматриваются 12 индексов из предыдущих исследований научной группы (Якушев и др., 2019). В табл. 1 представлены формулы используемых вегетационных индексов, а также ссылки на источники.

Таблица 1. Вегетационные индексы

Спектральные индексы	Формула	Ссылка на источник
Индекс отражения хлорофилла ChlRI (англ. Chlorophyll Reflectance Index)	$\frac{R750 - R705}{R750 + R705 - 2R445}$	(Sims, Gamon, 2002)
Структурно-интенсивный пигментный индекс SIPI (англ. Structure Insensitive Pigment Index)	$\frac{R800 - R445}{R800 - R680}$	(Penuelas et al., 1995)
Рассеивание света листом R800 (англ. Reflectance 800)	R800	(Sims, Gamon, 2002)
Модифицированный фотохимический индекс отражения PRI (англ. Photochemical Reflectance Index)	$0,7 - \frac{R570 - R531}{R570 + R531}$	(Peñuelas et al., 2013)
Модифицированный индекс отражения антоцианов ARI (англ. Anthocyanin Reflectance Index)	$0,7 - R750 \left(\frac{1}{R550} - \frac{1}{R700} \right)$	(Якушев и др., 2019)
Модифицированный индекс отражения флавоноидов FRI (англ. Flavonoid Reflectance Index)	$0,7 - R800 \left(\frac{1}{R410} - \frac{1}{R450} \right)$	(Merzlyak et al., 2005)
Нормализованный водный индекс WRI (англ. Water Ratio Index)	$\frac{R920 - R970}{R920 + R970}$	(Prasad et al., 2007)

Окончание табл. 1

Спектральные индексы	Формула	Ссылка на источник
Зелёный нормализованный разностный вегетационный индекс (<i>англ.</i> Green Normalized Difference Vegetation Index — GNDVI)	$\frac{R_{850} - R_{580}}{R_{850} + R_{580}}$	(Gitelson et al., 1996)
Нормализованный разностный вегетационный индекс 780 (<i>англ.</i> Normalized Difference Vegetation Index 780 — NDVI 780)	$\frac{R_{780} - R_{670}}{R_{780} + R_{670}}$	(Deepak et al., 2020)
Нормализованный разностный вегетационный индекс 850 (<i>англ.</i> Normalized Difference Vegetation Index 850 — NDVI 850)	$\frac{R_{850} - R_{651}}{R_{850} + R_{651}}$	(Richardson et al., 2002)
Нормализованный разностный вегетационный индекс 761 (<i>англ.</i> Normalized Difference Vegetation Index 761 — NDVI 761)	$\frac{R_{761} - R_{651}}{R_{761} + R_{651}}$	(Richardson et al., 2002)
Индекс отражения азота NRI (<i>англ.</i> Nitrogen Reflectance Index)	$\frac{R_{570} - R_{670}}{R_{570} + R_{670}}$	(Bausch et al., 1996)

Методы

Для определения информативных спектральных данных используются традиционные методы математической статистики — корреляционный и регрессионный анализ:

- Для анализа наличия связи между спектральными данными и уровнем обеспеченности растений азотом (N) рассчитываются коэффициенты корреляции Пирсона, для проверки значимости полученных оценок используется критерий Стьюдента.
- Для исследования степени связи между спектральными данными и уровнем обеспеченности растений азотом строится множественная регрессия с учётом мультиколлинеарности, а также парные регрессии с помощью метода наименьших квадратов. Для проверки значимости полученных оценок коэффициентов уравнений используется критерий Стьюдента, для проверки значимости уравнений в целом — критерий Фишера, а также рассчитывается коэффициент детерминации.

Для определения оптимальной стратегии агротехнологии используется геостатистическая модель неоднородности сельскохозяйственного поля (Якушев и др., 2010):

$$z(\mathbf{r}) = m(\mathbf{r}) + s(\mathbf{r}) + \varepsilon(\mathbf{r}),$$

где $z(\mathbf{r})$ — поле точечных значений параметра Z радиус-вектора $\mathbf{r}$. Первая составляющая $m = m(\mathbf{r})$ называется макрокомпонентой, отражающей низкочастотные пространственные изменения параметра, связанные, как правило, с особенностями ландшафта. Вторая составляющая $s = s(\mathbf{r})$ называется мезокомпонентой, описывающей изменчивость параметра в пределах масштаба сельскохозяйственного поля. Третья компонента $\varepsilon = \varepsilon(\mathbf{r})$ называется микрокомпонентой, характеризующей случайную микромасштабную вариабельность параметра. Задача заключается в оценке случайной микрокомпоненты: чем выше доля её влияния в модели неоднородности, тем менее эффективным будет применение дифференцированных технологий внесения агрохимикатов в связи с тем, что пространственно некоррелированные случайные изменения параметра не поддаются управлению.

Для оценки случайной микрокомпоненты используется вариограммный анализ. На первом этапе строится экспериментальная вариограмма по следующей формуле:

$$\hat{\gamma}(\mathbf{h}) = \frac{1}{2N(\mathbf{h})} \sum_{i=1}^{N(\mathbf{h})} [Z(x_i) - Z(x_i + \mathbf{h})]^2,$$

где $N(\mathbf{h})$ — число пар экспериментальных точек, разделённых вектором $\mathbf{h}$. Для простоты в дальнейшем будем предполагать отсутствие анизотропии (анализ проводится без учёта

направления), соответственно, векторная величина $\mathbf{h}$ заменяется на её абсолютное значение $h = |\mathbf{h}|$.

В качестве основных компонент вариограммы выделяются: самородок c_0 — величина вариограммы при $h = 0$, порог $c = c_1 + c_0$ — предельное значение вариограммы (если оно достигается) и ранг a — расстояние, на котором оно достигается.

Построенная экспериментальная вариограмма аппроксимируется теоретической моделью. В качестве примера будем рассматривать часто встречающуюся в подобных задачах сферическую модель:

$$\gamma(h) = \begin{cases} c_0 + c \left[\frac{3h}{2a} - \frac{1}{2} \left(\frac{h}{a} \right)^3 \right], & 0 \leq h \leq a, \\ c_0 + c, & h > a. \end{cases}$$

На следующем шаге полученная теоретическая модель нормируется посредством разделения обеих частей равенства на c :

$$v(\mu) = \begin{cases} \xi + (1 - \xi)T(\mu), & 0 \leq \mu \leq 1, \\ 1, & \mu > 1, \end{cases}$$

где $\xi = c_0/c$ — относительная нагет-дисперсия; $\mu = h_{\max}/a$ — расстояние, выраженное в единицах ранга a ; $T(\mu)$ — полином, определяемый равенством

$$T(\mu) = \frac{3}{2}\mu - \frac{1}{2}\mu^3.$$

При этом после нормализации долю случайной микрокомпоненты будет характеризовать величина

$$\theta = \frac{c_0}{\gamma}(h) = \frac{\xi}{v}(\mu).$$

В случае, когда параметр μ оказывается больше 1, а, соответственно, нормированная вариограмма $v = 1$, оценивается величина нагет-дисперсии ξ , а в ином случае параметра θ .

Результаты и их обсуждение

На *рис. 1* (см. с. 134) представлена общая схема предлагаемых подходов к интеллектуальному управлению азотным режимом питания растений на основе статистического и вариограммного анализа данных дистанционного зондирования. Концепция состоит из трёх основных блоков. На первом этапе проводится статистический анализ: вычисление коэффициентов корреляции, проверка их значимости, построение множественных и парных регрессий. На основе проведённых вычислений первого блока выделяются наиболее информативные спектральные данные. Далее выделенные характеристики передаются в следующий блок вариограммного анализа, на основе которого оценивается доля микрокомпоненты в модели неоднородности сельскохозяйственного поля по исследуемому управляющему фактору (например, обеспеченности азотом). На основе этих результатов определяется оптимальная стратегия агротехнологии. На последнем этапе рассчитываются оптимальные дозы агрохимикатов для внесения. Для решения последней подзадачи могут использоваться как традиционные методы машинного обучения (Mitrofanova et al., 2022), так и более сложные методы глубокого обучения (Blekanov et al., 2023).

Блок 1. Выделение наиболее информативных спектральных данных. В качестве экспериментального примера был проведён статистический анализ опытной полевой информации. Гиперспектральные данные рассматривались отдельно по годам, за 2022 и 2024, в связи с тем, что в 2024 г. были созданы условия для очень высокой засорённости на сельскохозяйственном поле. Вычислительные эксперименты проводились с использованием языка программирования R. Для упрощения расчётов спектры были разбиты на диапазоны (*табл. 2*) в соответствии с общепринятыми подходами.

Для набора данных за 2022 г. была построена корреляционная матрица для средних спектральных значений из выбранных диапазонов (рис. 2, см. с. 135).




Рис. 1. Общая схема предлагаемого подхода

Таблица 2. Разбиение на диапазоны длин волн

Длины волн, нм	Цвет	Диапазон
380–440	Фиолетовый	Видимый свет
440–485	Синий	
485–500	Голубой	
500–565	Зелёный	
565–590	Жёлтый	
590–625	Оранжевый	
625–740	Красный	
740–1400		Ближнее инфракрасное излучение

Также была построена множественная регрессия для первого набора данных:

$$N = 29433X_1 - 21448X_2 - 2196X_3 - 2366X_4 - 4900X_5 + 6374X_6 - 2149X_7 + 753X_8 + 275,$$

где N — уровень обеспеченности растений азотом; X_1 — средние спектральные значения из диапазона 390–450 нм; X_2 — из диапазона 450–485 нм; X_3 — из диапазона 485–500 нм; X_4 —

из диапазона 500–565 нм; X_5 — из диапазона 565–590 нм; X_6 — из диапазона 590–625 нм; X_7 — из диапазона 625–750 нм; X_8 — из диапазона 750–1050 нм. Несмотря на то, что уравнение в целом статистически значимо ($p\text{-value} = 0,00007$; $R^2 = 0,54$), многие его коэффициенты по критерию Стьюдента оказались незначимыми. После поочерёдного удаления из уравнения незначимых коэффициентов получили следующее выражение:

$$N = 8732X_1 - 5004X_2 + 285X_3 + 131,$$

где X_1 — средние спектральные значения из диапазона 390–450 нм; X_2 — средние спектральные значения из диапазона 565–590 нм; X_3 — средние спектральные значения из диапазона 750–1050 нм. При этом исходя из корреляционной матрицы (см. далее *рис. 2*) между этими переменными коэффициенты корреляции менее 0,7, соответственно, мультиколлинеарность отсутствует. Все коэффициенты уравнения статистически значимы на уровне значимости 0,001, уравнение в целом также статистически значимо ($p\text{-value} = 0,00002$; $R^2 = 0,43$).




Рис. 2. Корреляционная матрица для средних спектральных значений из выделенных диапазонов (2022)

Дополнительно также были построены парные регрессии между средними спектральными значениями из выделенных диапазонов и переменной N . Результаты вычислений представлены в *табл. 3*. Из таблицы видно, что статистически значимыми оказались парные регрессии с диапазонами 500–565, 565–590 и 590–625 нм.

На следующем этапе была рассчитана корреляционная матрица для вегетационных индексов на основе набора данных за 2022 г. (*рис. 3*, см. с. 136).

При этом не все коэффициенты корреляции с переменной N оказались статистически значимы. С учётом этого следует выделить следующие вегетационные индексы:

- ChIRI (0,54)
- SIPI (0,51)
- GNDVI (0,48)
- NDVI761 (0,44), NDVI850 (0,44)
- NDVI780 (0,43)

Таблица 3. Результаты построения парных регрессий для средних спектральных значений из выделенных диапазонов и переменной N (2022)

Уравнение	Уровень значимости		p -value	Коэффициент детерминации R^2
	коэффициента 1	коэффициента 2		
$N = -1116X_1 + 143$	0,5133	0,03450	0,5133	0,009
$N = -1724X_2 + 184$	0,2025	0,00740	0,2025	0,035
$N = -1670X_3 + 187$	0,1933	0,00750	0,1933	0,037
$N = -2324X_4 + 335$	0,0090	0,00040	0,0090	0,140
$N = -1767X_5 + 288$	0,0060	0,00006	0,0060	0,160
$N = -1532X_6 + 241$	0,0080	0,00002	0,0080	0,150
$N = -496X_7 + 194$	0,1699	0,00700	0,1699	0,040
$N = 106X_8 + 38$	0,3050	0,53200	0,3050	0,023




Рис. 3. Корреляционная матрица для вегетационных индексов (2022)

Для вегетационных индексов по данным за 2022 г. также была построена множественная регрессия:

$$N = 1608\text{ChlRI} + 1419\text{SIPI} + 133\text{R800} + 56\text{PRI} - 157\text{ARI} + 52\text{FRI} + 162\text{WRI} - 4098\text{GNDVI} - 311\text{NDVI780} + 11054\text{NDVI850} - 6178\text{NDVI761} - 178\text{NRI} - 2938.$$

Несмотря на то, что уравнение в целом оказалось статистически значимым ($p\text{-value} = 0,0003$; $R^2 = 0,60$), многие коэффициенты статистически незначимы. После поочерёдного удаления незначимых коэффициентов получили следующее выражение:

$$N = 588\text{ChlRI} - 91\text{ARI} + 45\text{FRI} + 733\text{NDVI850} - 655.$$

При этом если учесть мультиколлиниарность (см. *рис. 3*), то получаем две модели по трём переменным:

1. $N = 1033\text{ChlRI} - 88\text{ARI} + 32\text{FRI} - 372$ ($p\text{-value} = 0,000001$; $R^2 = 0,50$, коэффициенты значимы на уровне значимости 0,001);
2. $N = -73\text{ARI} + 49\text{FRI} + 1365\text{NDVI850} - 806$ ($p\text{-value} = 0,000001$; $R^2 = 0,49$, коэффициенты значимы на уровне значимости 0,001).

Также были построены парные регрессии (*табл. 4*). Как видно из таблицы, наилучшим образом объясняют уровень обеспеченности растений азотом индексы ChlRI, SIPI, GNDVI, NDVI780, NDVI850, NDVI761.

Таблица 4. Результаты построения парных регрессий для вегетационных индексов и переменной N (2022)

Уравнение	Уровень значимости		$p\text{-value}$	Коэффициент детерминации R^2
	коэффициента 1	коэффициента 2		
$N = 573\text{ChlRI} - 217$	0,00008	0,00500	0,00008	0,290
$N = -1203\text{SIPI} + 1359$	0,00030	0,00009	0,00030	0,260
$N = 107\text{R800} + 37$	0,27700	0,53700	0,27700	0,026
$N = 436\text{PRI} - 198$	0,17600	0,36600	0,17600	0,040
$N = 18\text{ARI} + 100$	0,49300	0	0,49400	0,010
$N = 2\text{FRI} + 107$	0,78400	0,00030	0,78400	0,002
$N = 289\text{WRI} + 85$	0,55700	0,00400	0,55700	0,008
$N = 676\text{GNDVI} - 379$	0,00060	0,00500	0,00060	0,230
$N = 498\text{NDVI780} - 294$	0,00300	0,02000	0,00300	0,180
$N = 546\text{NDVI850} - 325$	0,00200	0,01000	0,00200	0,200
$N = 493\text{NDVI761} - 276$	0,00200	0,02000	0,00200	0,190
$N = 192\text{NRI} + 47$	0,13600	0,19500	0,13600	0,050

Затем тот же анализ проведён для набора данных за 2024 г. с очень высоким уровнем засорённости сельскохозяйственного поля. На первом шаге была построена корреляционная матрица для тех же диапазонов длин волн. При этом все коэффициенты корреляции спектральных характеристик с переменной N оказались статистически незначимы, в связи с чем невозможно выделить наиболее информативные на основе матрицы. Регрессионный анализ также не дал результатов.

Далее был проанализирован набор вегетационных индексов за 2024 г. Однако и коэффициенты корреляции, и коэффициенты построенных регрессий оказались статистически незначимыми. Таким образом, подтверждается гипотеза о том, что при высоком уровне засорённости спектральные характеристики неэффективны в задаче мониторинга обеспеченности растений полезными веществами.

Блок 2. Определение эффективной стратегии внесения удобрений. Также был проведён демонстрационный экспериментальный пример. Вычисления осуществлялись на наборе данных за 2022 г., так как в 2024 г. спектральные данные оказались неэффективны. За основу взяли ортофотоплан, построенный на базе мозаики мультиспектральных изображений.

Затем с использованием калькулятора растров в программе QGIS построили тепловую карту индекса GNDVI (один из выбранных информативных индексов на предыдущем этапе) (рис. 4).




Рис. 4. Тепловая карта индекса GNDVI




Рис. 5. Экспериментальная вариограмма с аппроксимирующей теоретической моделью

После этого с помощью программы SAGA сформировали набор из 119 точек, случайно, но равномерно распределённых по карте индекса, выгрузили данные в таблицу. Далее провели вариограммный анализ в среде RStudio. Набор данных был проанализирован на выполнение предположений геостатистики, а также на выбросы; пространственный тренд не наблюдался. Выбросы были устранены отсечением по 2,5 % двухсторонним квантилям.

После предварительного анализа и проверок построена экспериментальная вариограмма с аппроксимирующей теоретической моделью (рис. 5, см. с. 138).

На основе полученных параметров модели рассчитывается так называемый масштаб сельскохозяйственного поля:

$$\mu = \frac{0,011}{0,00216} = 5,09.$$

То есть размеры сельскохозяйственного поля существенно превосходят ранг вариограммной функции исследуемого параметра, из чего можно сделать вывод, что поле имеет достаточно большой масштаб μ . Соответственно, тогда $\nu = 1$ и вопрос об эффективности внутри-полевых дифференцированных агротехнологий может решаться исходя из значения ξ :

$$\xi = \frac{c_0}{c} = \frac{0,002281}{0,003556} = 0,64.$$

Видим, что именно на эту дату съёмки случайная вариабельность индекса, который коррелирует с азотным статусом, имеет высокий уровень, следовательно, применять на дату съёмки прецизионное внесение удобрений нецелесообразно.

Блок 3. Определение доз агрохимикатов. В рассматриваемом экспериментальном примере технологии точного земледелия оказались нецелесообразными, соответственно, более эффективным представляется традиционное равномерное внесение по всему полю. Однако в альтернативном случае, когда перспективной оказывается прецизионная стратегия, возникает дополнительный этап — построение карты-задания, где каждому элементарному (агротехнологическому) участку сельскохозяйственного поля определена доза необходимого для внесения агрохимиката. Хорошо изученным подходом для решения такой задачи представляются методы машинного обучения (контролируемая и неконтролируемая классификация). При этом для получения более точного результата необходимо закладывать специальные тестовые площадки; средние спектральные данные, полученные для таких участков, используются в качестве обучающей выборки.

Более новым и перспективным направлением представляются методы глубокого обучения. В рассматриваемом подходе в Блоке 3 предлагается использовать нейросетевые модели, которые позволяют определять обеспеченность растений полезными веществами с высокой точностью без закладки тестовых площадок (они необходимы только на этапе обучения таких моделей). Так, в предыдущих исследованиях, связанных с управлением азотным режимом пшеницы с применением методов глубокого обучения (Blekanov et al., 2023), были получены результаты, которые могут быть применены в предлагаемом подходе:

- модифицированные модели на базе архитектуры U-Net позволяют с высокой точностью определять обеспеченность посевов пшеницы азотом (модель Attention R2U-Net в проведённых экспериментах продемонстрировала точность 97,59–99,96 %);
- использование вегетационных индексов в комбинации исходных данных для анализа позволяет повысить точность и устойчивость нейросетевой модели (были исследованы различные комбинации данных, более эффективной оказалась комбинация данных RGB (видимый слой) + NIR (ближний инфракрасный) + NDVI).

Заключение

В работе предложен подход для интеллектуального управления азотным режимом пшеницы, состоящий из трёх основных блоков: определение наиболее информативных спектральных данных, определение эффективной стратегии агротехнологии, определение доз агрохимикатов. В ходе проведения вычислительных экспериментов, а также на основе ранее осуществлённых исследований были получены следующие основные результаты:

- выделены наиболее информативные вегетационные индексы (ChlRI, SIPI, GNDVI, NDVI761, NDVI850, NDVI780);

- подтверждена гипотеза о неэффективности использования спектральных данных в случае высокого уровня засорённости сельскохозяйственного поля;
- вариограммный анализ позволяет оценить вариабельность исследуемого параметра (например, обеспеченность растений азотом) и определить наиболее эффективную стратегию внесения агрохимикатов;
- для определения доз агрохимикатов перспективным представляется применение нейросетевых моделей (например, модификации на базе архитектуры U-Net);
- использование вегетационных индексов позволяет усилить качество обучения нейросетевой модели.

Исследование выполнено за счёт гранта Российского научного фонда № 24-16-00203 «Методология обработки данных дистанционного зондирования получаемых при мультиспектральной съёмке посевов зерновых культур и сопряжённых полевых измерений», <https://rscf.ru/project/24-16-00203/>.

Литература

1. Евстифорова А. В., Денисова А. Ю. Анализ влияния почвенных характеристик на результаты регрессионного моделирования урожайности озимой пшеницы по данным вегетационного индекса NDVI // 4-я Международ. конф. и молодеж. шк. «Информ. технологии и нанотехнологии» (ИТНТ-2018): сб. тр. Самара: Новая техника, 2018. С. 664–673.
2. Митрофанова О. А., Митрофанов Е. П., Блеканов И. С., Молин А. Е. Специализированный датасет мультиспектральных аэрофотоснимков для решения задач точного земледелия с применением методов искусственного интеллекта // Современные проблемы дистанционного зондирования Земли из космоса. 2023. Т. 20. № 6. С. 67–79. <https://doi.org/10.21046/2070-7401-2023-20-6-67-79>.
3. Якушев В. П., Жуковский Е. Е., Петрушин А. Ф., Якушев В. В. Вариограммный анализ пространственной неоднородности сельскохозяйственных полей для целей точного земледелия: метод. пособие. СПб: АФИ, 2010. 52 с.
4. Якушев В. П., Канаиш Е. В., Якушев В. В. и др. Новые возможности автоматизации процесса обнаружения внутриполевой неоднородности по гиперспектральным снимкам и оптическим критериям // Современные проблемы дистанционного зондирования Земли из космоса. 2019. Т. 16. № 3. С. 24–32. <https://doi.org/10.21046/2070-7401-2019-16-3-24-32>.
5. Якушев В. П., Буре В. М., Митрофанова О. А., Митрофанов Е. П. (2020а) К вопросу автоматизации построения вариограмм в задачах точного земледелия // Вестн. Санкт-Петербургского ун-та. Прикладная математика. Информатика. Процессы управления. 2020. Т. 16. № 2. С. 177–185. <https://doi.org/10.21638/11701/spbu10.2020.209>.
6. Якушев В. П., Буре В. М., Митрофанова О. А. и др. (2020б) Оценка внутриполевой изменчивости посевов с помощью вариограммного анализа спутниковых данных для точного земледелия // Современные проблемы дистанционного зондирования Земли из космоса. 2020. Т. 17. № 2. С. 114–122. <https://doi.org/10.21046/2070-7401-2020-17-2-114-122>.
7. Bausch W. C., Duke H. R., Iremonger C. J. Assessment of plant nitrogen in irrigated corn // Proc. 3rd Intern. Conf. Precision Agriculture. Madison, WI, USA: American Soc. of Agronomy, Crop Science Soc. of America, Soil Science Soc. of America. 1996. P. 23–32. <https://doi.org/10.2134/1996.precisionagproc3.c3>.
8. Blekanov I., Molin A., Zhang D. et al. Monitoring of grain crops nitrogen status from uav multispectral images coupled with deep learning approaches // Computers and Electronics in Agriculture. 2023. V. 212. Article 108047. <https://doi.org/10.1016/j.compag.2023.108047>.
9. Budzko V., Medennikov V. Mathematical modeling of evaluating the effectiveness of using RSD data in precision farming // Procedia Computer Science. 2021. V. 190. P. 122–129. <https://doi.org/10.1016/j.procs.2021.06.015>.
10. Bure V. M., Mitrofanova O. A., Mitrofanov E. P., Petrushin A. F. Remote sensing data processing for plant production control // Stability and Control Processes. Proc. 4th Intern. Conf. Dedicated to the Memory of Professor Vladimir Zubov. Cham, 2022. P. 753–758. https://doi.org/10.1007/978-3-030-87966-2_86.
11. Deepak M., Keski-Saari S., Fauch L. et al. Spectral reflectance in silver birch genotypes from three provenances in Finland // Remote Sensing. 2020. V. 12. Article 2677. <https://doi.org/10.3390/rs12172677>.
12. Galioto F., Raggi M., Viaggi D. Assessing the potential economic viability of precision irrigation: a theoretical analysis and pilot empirical evaluation // Water. 2017. V. 9. No. 12. P. 990–1009. <https://doi.org/10.3390/w9120990>.

13. Gitelson A. A., Kaufman Y. J., Merzlyak M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS // Remote sensing of Environment. 1996. V. 58. No. 3. P. 289–298. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7).
14. Jia M., Li W., Wang K. et al. A newly developed method to extract the optimal hyperspectral feature for monitoring leaf biomass in wheat // Computers and Electronics in Agriculture. 2019. V. 165. Article 104942. <https://doi.org/10.1016/j.compag.2019.104942>.
15. Li J., Ge Y., Puntel L. A. et al. Integrating UAV hyperspectral data and radiative transfer model simulation to quantitatively estimate maize leaf and canopy nitrogen content // Intern. J. Applied Earth Observation and Geoinformation. 2024. V. 129. Article 103817. <https://doi.org/10.1016/j.jag.2024.103817>.
16. Loures L., Chamizo A., Ferreira P. et al. Assessing the effectiveness of precision agriculture management systems in Mediterranean small farms // Sustainability. 2020. V. 12. Article 3765. <https://doi.org/10.3390/su12093765>.
17. Merzlyak M. N., Solovchenko A. E., Smagin A. I., Gitelson A. A. Apple flavonols during fruit adaptation to solar radiation: spectral features and technique for non-destructive assessment // J. Plant Physiology. 2005. V. 162. Iss. 2. P. 151–160. <https://doi.org/10.1016/j.jplph.2004.07.002>.
18. Mitrofanova O., Yakushev V., Zakharova E., Terleev V. An alternative approach to managing the nitrogen content of cereal crops // Robotics, Machinery and Engineering Technology for Precision Agriculture: Proc. 14th Intern. Scientific Conf. “INTERAGROMASH 2021”. Springer Nature Switzerland AG, 2022. P. 481–491. https://doi.org/10.1007/978-981-16-3844-2_44.
19. Mizik T. How can precision farming work on a small scale? A systematic literature review // Precision Agriculture. 2023. V. 24. P. 384–406. <https://doi.org/10.1007/s11119-022-09934-y>.
20. Munipalle V. K., Nelakuditi U. R., Kumar M. C. V. S. S., Nidamanuri R. R. Ultra-high-resolution hyperspectral imagery datasets for precision agriculture applications // Data in Brief. 2024. V. 55. Article 110649. <https://doi.org/10.1016/j.dib.2024.110649>.
21. Nino P., D’Urso G., Vanino S. et al. Nitrogen status of durum wheat derived from Sentinel-2 satellite data in central Italy // Remote Sensing Applications: Society and Environment. 2024. V. 36. Article 101323. <https://doi.org/10.1016/j.rsase.2024.101323>.
22. Penuelas J., Baret F., Filella I. Semi-empirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance // Photosynthetica. 1995. V. 31. No. 2. P. 221–230.
23. Peñuelas J., Marino G., LLusia J. et al. Photochemical reflectance index as an indirect estimator of foliar isoprenoid emissions at the ecosystem level // Nature Communications. 2013. V. 4. Article 2604. <https://doi.org/10.1038/ncomms3604>.
24. Prasad B., Carver B. F., Stone M. L. et al. Potential use of spectral reflectance indices as a selection tool for grain yield in winter wheat under great plains conditions // Crop Science. 2007. V. 47. Iss. 4. P. 1426–1440. <https://doi.org/10.2135/cropsci2006.07.0492>.
25. Ram B. G., Oduor P., Igathinathane C. et al. A systematic review of hyperspectral imaging in precision agriculture: Analysis of its current state and future prospects // Computers and Electronics in Agriculture. 2024. V. 222. Article 109037. <https://doi.org/10.1016/j.compag.2024.109037>.
26. Richardson A. D., Duigan S. P., Berlyn G. P. An evaluation of noninvasive methods to estimate foliar chlorophyll content // New Phytologist. 2002. V. 153. Iss. 1. P. 185–194. <https://doi.org/10.1046/j.0028-646X.2001.00289.x>.
27. Segarra J., Rezzouk F. Z., Aparicio N. et al. Multiscale assessment of ground, aerial and satellite spectral data for monitoring wheat grain nitrogen content // Information Processing in Agriculture. 2023. V. 10. Iss. 4. P. 504–522. <https://doi.org/10.1016/j.inpa.2022.05.004>.
28. Sims D. A., Gamon J. A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages // Remote Sensing of Environment. 2002. V. 81. Iss. 2–3. P. 337–354. [https://doi.org/10.1016/S0034-4257\(02\)00010-X](https://doi.org/10.1016/S0034-4257(02)00010-X).
29. Vecchio Y., De Rosa M., Pauselli G. et al. The leading role of perception: the FACOPA model to comprehend innovation adoption // Agricultural and Food Economics. 2022. V. 10. Article 5. 19 p. <https://doi.org/10.1186/s40100-022-00211-0>.
30. Wang J., Zhang S., Lizaga I. et al. UAS-based remote sensing for agricultural Monitoring: Current status and perspectives // Computers and Electronics in Agriculture. 2024. V. 227. Article 109501. <https://doi.org/10.1016/j.compag.2024.109501>.

Application of hyperspectral remote sensing data and geostatistical methods to nitrogen status management in grain crops

V. P. Yakushev¹, O. A. Mitrofanova¹, V. M. Bure¹, E. P. Mitrofanov¹,
A. A. Smolina¹, Ya. B. Pankratova¹, V. V. Yakushev²

¹ Saint Petersburg State University, Saint Petersburg 199034, Russia
E-mail: o.a.mitrofanova@spbu.ru

² Saint Petersburg State Agrarian University, Pushkin, Saint Petersburg 196601, Russia

The relevance of the study is due to the need for operational and non-destructive monitoring of nitrogen supply to grain crops for effective agricultural management. Modern remote sensing technologies (hyperspectral and multispectral imaging using unmanned aerial vehicles and satellites) provide extensive data, but require the development of analysis methods to identify informative features and substantiate fertilization strategies. The aim of the work is to develop methodological approaches to statistical and variogram analysis of data on the search for informative channels in multi- and hyperspectral imaging of agricultural crops using the example of the problem of managing the nitrogen regime of grain crops. The experimental part of the study was conducted in the fields of the Leningrad Region (2022–2024). The most informative for assessing the nitrogen status of wheat were the vegetation indices ChlRI (Chlorophyll Reflectance Index), SIPI (Structure Insensitive Pigment Index), GNDVI (Green Normalized Difference Vegetation Index), NDVI761 (Normalized Difference Vegetation Index 761), NDVI850 (Normalized Difference Vegetation Index 850) and NDVI780 (Normalized Difference Vegetation Index 780), demonstrating significant correlations with nitrogen levels. At the same time, the hypothesis about the inefficiency of spectral methods in conditions of high contamination of fields was confirmed: correlations between remote sensing data and nitrogen availability turned out to be statistically insignificant in an experiment with high contamination. A key tool for choosing agricultural technology was variogram analysis, which makes it possible to estimate the proportion of random micro-components (ξ) in the spatial heterogeneity of the field. It was found that at $\xi > 0.5$ (for example, $\xi = 0.64$ in the 2022 experiment), the use of differentiated technologies is impractical due to the predominance of uncontrolled variability. To calculate the doses of agrochemicals, the use of neural network models (U-Net modifications) has been recognized as a promising direction, providing accuracy of up to 99.96 % when combining RGB, near-infrared data and vegetation indices. The proposed three-stage methodology integrates spectral data analysis, spatial heterogeneity assessment and technological decision-making, increasing the efficiency of nitrogen nutrition management for crops.

Keywords: hyperspectral imaging, remote sensing data, nitrogen regime, wheat, variogram analysis, precision agriculture, neural network technologies

Accepted: 21.07.2025

DOI: 10.21046/2070-7401-2025-22-5-129-144

References

1. Evstiforova A. V., Denisova A. Yu., Analysis of the impact of soil properties on the results of regression modeling of winter wheat yield based on the NDVI vegetation index, *4-ya Mezhdunarodnaya konferentsiya i molodezhnaya shkola "Informatsionnye tekhnologii i nanotekhnologii": sbornik trudov (ITNT-2018)* (Proc. 4th Intern. Conf. and Youth School "Information Technologies and Nanotechnologies" (ITNT-2018)), Samara: Novaya Tekhnika, 2018, pp. 664–673 (in Russian).
2. Mitrofanova O. A., Mitrofanov E. P., Blekanov I. S., Molin A. E., Specialized dataset of multispectral aerophotos for solving precision farming problems using artificial intelligence methods, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2023, V. 20, No. 6, pp. 67–79 (in Russian), <https://doi.org/10.21046/2070-7401-2023-20-6-67-79>.
3. Yakushev V. P., Zhukovsky E. E., Petrushin A. F., Yakushev V. V., *Variogramnyi analiz prostranstvennoi neodnorodnosti sel'skokhozyaistvennykh polei dlya tselei tochnogo zemledeliya* (Variogram analysis of the spatial heterogeneity of agricultural fields for precision farming purposes: A methodological guide), Saint Petersburg, AFI, 2010, 52 p. (in Russian).
4. Yakushev V. P., Kanash E. V., Yakushev V. V. et al., Advanced features of automated detection of within-field variability based on hyperspectral images and optical criteria, *Sovremennye problemy dis-*

- tantsionnogo zondirovaniya Zemli iz kosmosa*, 2019, V. 16, No. 3, pp. 24–32 (in Russian), <https://doi.org/10.21046/2070-7401-2019-16-3-24-32>.
5. Yakushev V. P., Bure V. M., Mitrofanova O. A., Mitrofanov E. P. (2020a), On the issue of semivariograms constructing automation for precision agriculture problems, *Vestnik Sankt-Peterburgskogo Universiteta. Prikladnaya Matematika, Informatika, Protssy Upravleniya*, 2020, V. 16, No. 2, pp. 177–185 (in Russian), <https://doi.org/10.21638/11701/spbu10.2020.209>.
6. Yakushev V. P., Bure V. M., Mitrofanova O. A. et al. (2020b), Within-field variability estimation based on variogram analysis of satellite data for precision agriculture, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2020, V. 17, No. 2, pp. 114–122 (in Russian), <https://doi.org/10.21046/2070-7401-2020-17-2-114-122>.
7. Bausch W. C., Duke H. R., Iremonger C. J., Assessment of plant nitrogen in irrigated corn, *Proc. 3rd Intern. Conf. Precision Agriculture*, Madison, WI, USA: American Soc. of Agronomy, Crop Science Soc. of America, Soil Science Soc. of America, 1996, pp. 23–32, <https://doi.org/10.2134/1996.precisionagproc3.c3>.
8. Blekanov I., Molin A., Zhang D. et al., Monitoring of grain crops nitrogen status from uav multispectral images coupled with deep learning approaches, *Computers and Electronics in Agriculture*, 2023, V. 212, Article 108047, <https://doi.org/10.1016/j.compag.2023.108047>.
9. Budzko V., Medennikov V., Mathematical modeling of evaluating the effectiveness of using RSD data in precision farming, *Procedia Computer Science*, 2021, V. 190, pp. 122–129, <https://doi.org/10.1016/j.procs.2021.06.015>.
10. Bure V. M., Mitrofanova O. A., Mitrofanov E. P., Petrushin A. F., Remote sensing data processing for plant production control, *Stability and Control Processes, Proc. 4th Intern. Conf. Dedicated to the Memory of Professor Vladimir Zubov*, Cham, 2022, pp. 753–758, https://doi.org/10.1007/978-3-030-87966-2_86.
11. Deepak M., Keski-Saari S., Fauch L. et al., Spectral reflectance in silver birch genotypes from three provenances in Finland, *Remote Sensing*, 2020, V. 12, Article 2677, <https://doi.org/10.3390/rs12172677>.
12. Galioto F., Raggi M., Viaggi D., Assessing the potential economic viability of precision irrigation: a theoretical analysis and pilot empirical evaluation, *Water*, 2017, V. 9, No. 12, pp. 990–1009, <https://doi.org/10.3390/w9120990>.
13. Gitelson A. A., Kaufman Y. J., Merzlyak M. N., Use of a green channel in remote sensing of global vegetation from EOS-MODIS, *Remote sensing of Environment*, 1996, V. 58, No. 3, pp. 289–298, [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7).
14. Jia M., Li W., Wang K. et al., A newly developed method to extract the optimal hyperspectral feature for monitoring leaf biomass in wheat, *Computers and Electronics in Agriculture*, 2019, V. 165, Article 104942, <https://doi.org/10.1016/j.compag.2019.104942>.
15. Li J., Ge Y., Puntel L. A. et al., Integrating UAV hyperspectral data and radiative transfer model simulation to quantitatively estimate maize leaf and canopy nitrogen content, *Intern. J. Applied Earth Observation and Geoinformation*, 2024, V. 129, Article 103817, <https://doi.org/10.1016/j.jag.2024.103817>.
16. Loures L., Chamizo A., Ferreira P. et al., Assessing the effectiveness of precision agriculture management systems in Mediterranean small farms, *Sustainability*, 2020, V. 12, Article 3765, <https://doi.org/10.3390/su12093765>.
17. Merzlyak M. N., Solovchenko A. E., Smagin A. I., Gitelson A. A., Apple flavonols during fruit adaptation to solar radiation: spectral features and technique for non-destructive assessment, *J. Plant Physiology*, 2005, V. 162, Iss. 2, pp. 151–160, <https://doi.org/10.1016/j.jplph.2004.07.002>.
18. Mitrofanova O., Yakushev V., Zakharova E., Terleev V., An alternative approach to managing the nitrogen content of cereal crops, *Robotics, Machinery and Engineering Technology for Precision Agriculture, Proc. 14th Intern. Scientific Conf. "INTERAGROMASH 2021"*, Springer Nature Switzerland AG, 2022, pp. 481–491, https://doi.org/10.1007/978-981-16-3844-2_44.
19. Mizik T., How can precision farming work on a small scale? A systematic literature review, *Precision Agriculture*, 2023, V. 24, pp. 384–406, <https://doi.org/10.1007/s11119-022-09934-y>.
20. Munipalle V. K., Nelakuditi U. R., Kumar M. C. V. S. S., Nidamanuri R. R., Ultra-high-resolution hyperspectral imagery datasets for precision agriculture applications, *Data in Brief*, 2024, V. 55, Article 110649, <https://doi.org/10.1016/j.dib.2024.110649>.
21. Nino P., D'Urso G., Vanino S. et al., Nitrogen status of durum wheat derived from Sentinel-2 satellite data in central Italy, *Remote Sensing Applications: Society and Environment*, 2024, V. 36, Article 101323, <https://doi.org/10.1016/j.rsase.2024.101323>.
22. Penuelas J., Baret F., Filella I., Semi-empirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance, *Photosynthetica*, 1995, V. 31, No. 2, pp. 221–230.
23. Peñuelas J., Marino G., LLusia J. et al., Photochemical reflectance index as an indirect estimator of foliar isoprenoid emissions at the ecosystem level, *Nature Communications*, 2013, V. 4, Article 2604, <https://doi.org/10.1038/ncomms3604>.
24. Prasad B., Carver B. F., Stone M. L. et al., Potential use of spectral reflectance indices as a selection tool for grain yield in winter wheat under great plains conditions, *Crop Science*, 2007, V. 47, Iss. 4, pp. 1426–1440, <https://doi.org/10.2135/cropsci2006.07.0492>.

25. Ram B. G., Oduor P., Igathinathane C. et al., A systematic review of hyperspectral imaging in precision agriculture: Analysis of its current state and future prospects, *Computers and Electronics in Agriculture*, 2024, V. 222, Article 109037, <https://doi.org/10.1016/j.compag.2024.109037>.
26. Richardson A. D., Duigan S. P., Berlyn G. P., An evaluation of noninvasive methods to estimate foliar chlorophyll content, *New Phytologist*, 2002, V. 153, Iss. 1, pp. 185–194, <https://doi.org/10.1046/j.0028-646X.2001.00289.x>.
27. Segarra J., Rezzouk F. Z., Aparicio N. et al., Multiscale assessment of ground, aerial and satellite spectral data for monitoring wheat grain nitrogen content, *Information Processing in Agriculture*, 2023, V. 10, Iss. 4, pp. 504–522, <https://doi.org/10.1016/j.inpa.2022.05.004>.
28. Sims D. A., Gamon J. A., Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages, *Remote Sensing of Environment*, 2002, V. 81, Iss. 2–3, pp. 337–354, [https://doi.org/10.1016/S0034-4257\(02\)00010-X](https://doi.org/10.1016/S0034-4257(02)00010-X).
29. Vecchio Y., De Rosa M., Pauselli G. et al., The leading role of perception: the FACOPA model to comprehend innovation adoption, *Agricultural and Food Economics*, 2022, V. 10, Article 5, 19 p., <https://doi.org/10.1186/s40100-022-00211-0>.
30. Wang J., Zhang S., Lizaga I. et al., UAS-based remote sensing for agricultural Monitoring: Current status and perspectives, *Computers and Electronics in Agriculture*, 2024, V. 227, Article 109501, <https://doi.org/10.1016/j.compag.2024.109501>.