

Анализ гиперспектральных данных дистанционного зондирования и урожайности пшеницы для задачи прогнозирования

О. А. Митрофанова¹, Е. П. Митрофанов^{1,2}, В. М. Буре^{1,2}

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

² Агрофизический научно-исследовательский институт
Санкт-Петербург, 195220, Россия

Одна из важных задач управления производством растениеводческой продукции — прогнозирование урожайности. При этом всё чаще для прогнозирования урожайности в качестве исходной информации используются данные дистанционного зондирования: спутниковые снимки и аэрофотосъёмка. Благодаря стремительному развитию информационных и инженерных технологий актуальным и доступным также становится применение специализированных вегетационных индексов. Объектами представленного исследования выступают опытные сельскохозяйственные поля, расположенные в Ленинградской области. Для работы были использованы данные, полученные на базе двух полигонов площадью 12 и 28 га, произрастающая культура — яровая пшеница. На каждом поле были заложены тестовые площадки — небольшие ровные участки с определённой внесённой дозой азотсодержащих удобрений. Аэрофотосъёмка опытных полигонов осуществлялась с помощью беспилотной авиационной системы DJI Matrice 600 Pro с гиперспектральной камерой Pika L (281 канал съёмки в диапазоне 400–1000 нм). В 2022 г. одновременно с полётами дополнительно отбирались образцы пшеницы с тестовых площадок и в полях были получены их спектральные характеристики с помощью переносного лабораторного гиперспектрометра. Результаты проведённого исследования продемонстрировали преимущество использования аэрофотосъёмки перед лабораторным гиперспектрометром. Наиболее перспективными для применения в задаче прогнозирования урожайности в поставленном опыте представляются каналы из видимого диапазона, при этом наблюдается высокая мультиколлинеарность объясняющих факторов. Кроме того, был проведён регрессионный анализ. В результате среди вегетационных индексов для дальнейшего исследования в рассмотренном опыте были выделены шесть комбинаций спектров. В качестве направления дальнейшей работы следует провести дополнительные полевые опыты, расширить датасет.

Ключевые слова: гиперспектральные данные дистанционного зондирования, аэрофотосъёмка, вегетационные индексы, корреляционный анализ, прогноз урожайности, пшеница

Одобрена к печати: 02.12.2024

DOI: 10.21046/2070-7401-2025-22-1-93-105

Введение

Существенная часть территории России относится к зонам рискованного земледелия, в том числе и Северо-Западный регион. Важной задачей для агрохозяйств представляется прогнозирование урожайности для оптимизации управления производственным процессом. Особенно это направление актуально для таких зон, где возникает больше негативных и сложно предсказуемых явлений.

В современных исследованиях для прогнозирования урожайности в качестве исходных факторов используется широкий круг параметров (метеоданные, архивные показатели и т.д.), коррелирующих с послеуборочными характеристиками (Schauburger et al., 2020). Причём для решения таких задач используется как многофакторный, так и однофакторный анализ.

Отдельно следует отметить, что пшеница — одна из самых широко распространённых возделываемых культур в мире (Fei et al., 2023). По данным FAO (*англ.* Food and Agriculture

Organization) в 2022 г. Россия вошла в тройку лидеров как по возделываемой площади, так и по объёму производства пшеницы (рис. 1), статистические данные представлены на сайте организации <https://www.fao.org/faostat/en/#home>. Кроме того, по сведениям того же источника, за 2022 г. пшеница заняла 38 % объёма производства основных сельскохозяйственных культур в России (рис. 2, см. с. 95).

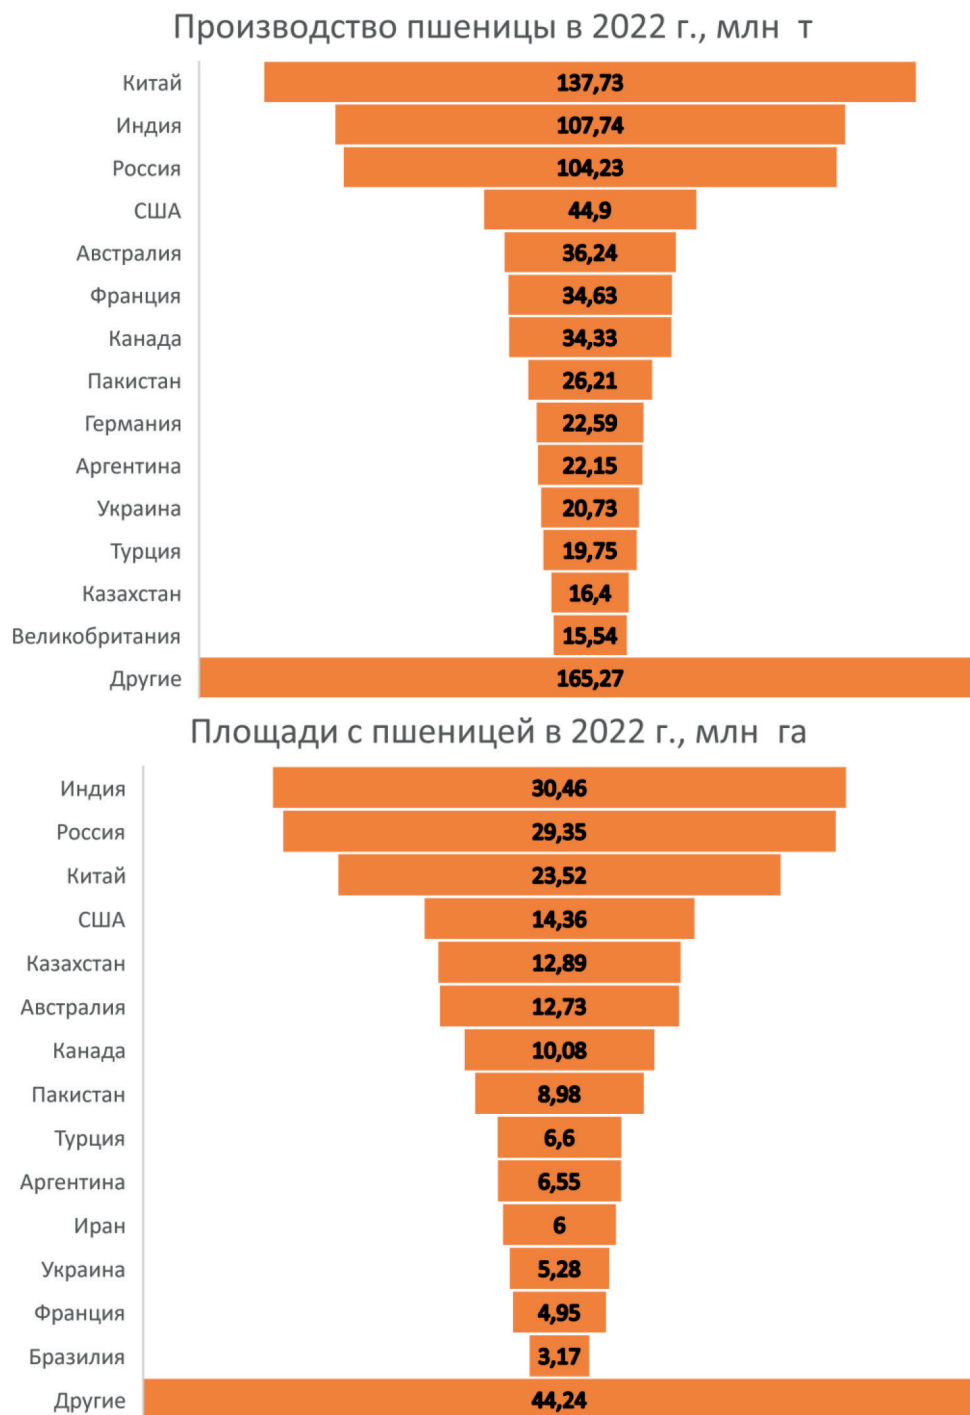


Рис. 1. Рейтинг стран-лидеров по возделываемой площади и объёму производства пшеницы за 2022 г.

В последние десятилетия всё чаще для прогнозирования урожайности в качестве исходной информации используются данные дистанционного зондирования: спутниковые снимки (Gavahi et al., 2021; Meroni et al., 2021; Nagy et al., 2018) и аэрофотосъёмка (Ma et al., 2023;

Moghimi et al., 2020; Yang W. et al., 2021). Благодаря стремительному развитию информационных и инженерных технологий актуальным и доступным также становится применение специализированных вегетационных индексов — различных комбинаций спектральных показателей (Li et al., 2022; Yang Z. et al., 2021). В табл. 1 представлены популярные индексы, используемые в мониторинге сельскохозяйственных полей.

Объём производства основных сельскохозяйственных культур в России в 2022 г.



Рис. 2. Объём производства основных сельскохозяйственных культур в России в 2022 г.

Таблица 1. Популярные индексы, используемые в мониторинге сельскохозяйственных полей

Спектральные индексы	Формула	Ссылка на источник
Нормализованный индекс феофитинизации (англ. Normalized Phaeophytinization Index — NPQI)	$(R_{415} - R_{435}) / (R_{415} + R_{435})$	(Penuelas et al., 1995)
Соотношение растительных пигментов (англ. Plant Pigment Ratio — PPR)	$(R_{550} - R_{450}) / (R_{550} + R_{450})$	(Metternicht, 2003)
Физиологический индекс отражения (англ. Physiological Reflectance Index — PRI1)	$(R_{550} - R_{530}) / (R_{550} + R_{530})$	(Ceccato et al., 2002)
Фотохимический индекс отражения (англ. Photochemical Reflectance Index — PRI2)	$(R_{531} - R_{570}) / (R_{531} + R_{570})$	(Gamon et al., 1997)
Индекс отражения антоцианов (англ. Anthocyanin Reflectance Index — ARI)	$(1/R_{550}) - (1/R_{700})$	(Gitelson et al., 2001)
Зелёный нормализованный разностный вегетационный индекс (англ. Green Normalized Difference Vegetation Index — GNDVI)	$(R_{750} - R_{550}) / (R_{750} + R_{550})$	(Gitelson, Merzlyak, 1996)
Индекс отражения азота (англ. Nitrogen Reflectance Index — NRI)	$(R_{570} - R_{670}) / (R_{570} + R_{670})$	(Bausch, Duke, 1996)
Индекс простого соотношения (англ. Simple Ratio — SR)	R_{761} / R_{651}	(Jordan, 1969)
Вегетационный индекс стресса растительности красного края (англ. Red-edge Vegetation Stress index — RVS)	$((R_{650} + R_{750}) / 2) - R_{733}$	(Merton, 1998)
Нормализованный разностный вегетационный индекс 761 (англ. Normalized Difference Vegetation Index 761 — NDVI ₇₆₁)	$(R_{761} - R_{651}) / (R_{761} + R_{651})$	(Raun et al., 2001)

Спектральные индексы	Формула	Ссылка на источник
Нормализованный разностный вегетационный индекс 850 (англ. Normalized Difference Vegetation Index 850 — NDVI ₈₅₀)	$(R_{850} - R_{651}) / (R_{850} + R_{651})$	(Raun et al., 2001)
Вегетационный индекс с коррекцией по почве (англ. Soil-Adjusted Vegetation Index — SAVI)	$1,16((R_{800} - R_{670}) / (R_{800} + R_{670} + 0,16))$	(Rondeaux et al., 1996)
Нормализованный разностный индекс красного края (англ. Normalized Difference Red-Edge — NDRE)	$(R_{790} - R_{720}) / (R_{790} + R_{720})$	(le Maire et al., 2008)
Водный индекс (англ. Water Index — WI)	R_{900} / R_{970}	(Penuelas et al., 1997)

Примечание: R — отражение листа; цифры — длина волны отражённой радиации (в нм).

Целью настоящего исследования был анализ гиперспектральных данных дистанционного зондирования и показателя урожайности пшеницы для выделения наиболее информативных спектров и вегетационных индексов.

Объекты и методы




Рис. 3. Опытные поля с тестовыми площадками в 2022 и 2023 гг. Числами указаны дозы азота (в килограммах действующего вещества на гектар)

Объектами исследования стали опытные сельскохозяйственные поля, расположенные в Ленинградской области. Для работы использованы данные, полученные на базе двух полигонов площадью 12 и 28 га соответственно (рис. 3, см. с. 96), произрастающая культура — яровая пшеница. На каждом поле были заложены тестовые площадки — небольшие ровные участки с внесённой определённой дозой азотсодержащих удобрений. Соответственно, колориметрические характеристики и параметры урожайности на таких площадках должны достоверно отличаться, что подтверждается в том числе результатами предыдущих исследований (Якушев и др., 2022; Матвеевко и др., 2019).

Аэрофотосъёмка опытных полигонов осуществлялась с помощью беспилотной авиационной системы DJI Matrice 600 Pro, где в качестве полезной нагрузки использовалась гиперспектральная камера Pika L, позволяющая осуществлять съёмку в 281 канале в диапазоне 400–1000 нм. Повышение точности геопространственной привязки участков и опорных точек обеспечивалось системой RTK (англ. Real Time Kinematic), состоящей из базовой станции и ровера фирмы Emlid. Общая информация по проведению полевых опытов представлена в табл. 2. В 2022 г. одновременно с полётами дополнительно отбирались образцы пшеницы с тестовых площадок и в полях были получены их спектральные характеристики с помощью переносного лабораторного гиперспектрометра.

Таблица 2. Общая информация по полевым опытам

Полигон	Год	Фаза развития пшеницы	Аэрофотосъёмка	Наземный гиперспектрометр
Поле 1	2022	Кущение	+	+
		Трубкование		
		Цветение		
		Молочная спелость		
Поле 2	2023	Кущение		–
		Трубкование		
		Колошение		

Предварительная обработка исходных аэрофотоснимков осуществлялась в QGIS (англ. Quantum Geographic Information Systems) и Spectronon. В результате на каждый полёт были получены средние спектральные значения для каждой тестовой площадки. Соответственно в качестве исходных объясняющих факторов сформировали множество переменных X_i^j , где $i = 1, 281$ — номер переменной, $j = 1, 56$ — номер наблюдения. В качестве зависимой переменной при этом рассматривали соответствующие значения урожайности для каждого тестового участка Y^j .

Кроме того, на основе полученных спектральных характеристик были рассчитаны вегетационные индексы (см. табл. 1). Соответственно дополнительно был сформирован ещё один набор объясняющих переменных: {NPQI, PPR, PRI1, PRI2, ARI, GNDVI, NRI, SR, RVS, NDVI761, NDVI850, SAVI, NDRE, WI}. Для исследования статистической зависимости между зависимой переменной и объясняющими факторами применялся традиционный хорошо изученный корреляционный анализ, все вычисления проводились с помощью языка программирования R.

Результаты и их обсуждение

Анализ исходной информации осуществлялся в несколько этапов. В связи с тем, что в 2022 г. параллельно с полётами был выполнен сбор спектральных характеристик переносным гиперспектрометром, на первом шаге исследовались данные только за один год полевого опыта. В первую очередь рассматривался датасет аэрофотосъёмки. Максимальные коэффициенты

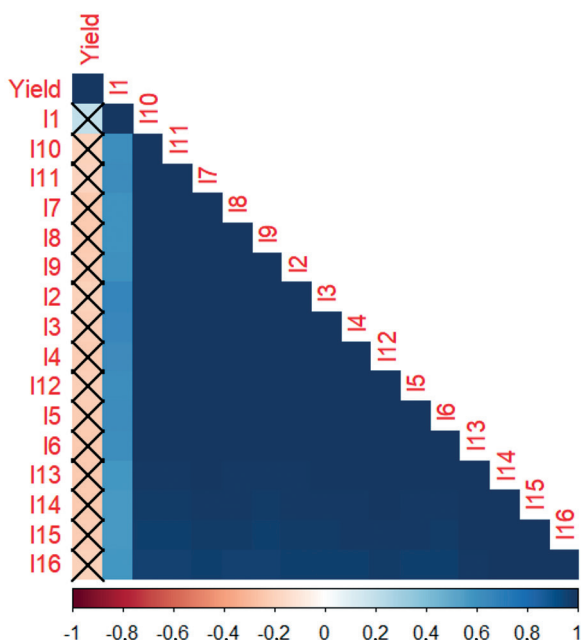


Рис. 5. Корреляционная матрица для выбранных спектральных диапазонов, полученных с использованием переносного гиперспектрметра в 2022 г.

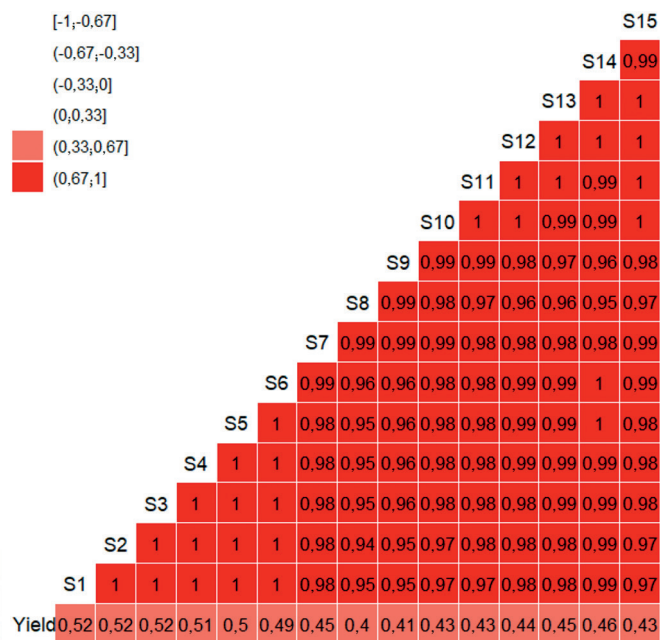


Рис. 6. Корреляционная матрица для выбранных спектральных диапазонов, полученных с использованием аэрофотосъёмки в 2022 и 2023 гг.

На следующем этапе формировался объединённый датасет исходной спектральной информации за 2022 и 2023 гг. В результате статистического анализа были получены следующие максимальные по модулю коэффициенты корреляции с урожайностью:

- в диапазоне 390,04–494,27 нм — 0,5–0,53;
- в диапазоне 496,34–535,73 нм — 0,41–0,49;
- в диапазоне 537,81–562,84 нм — 0,39–0,4;
- в диапазоне 564,93–694,06 нм — 0,41–0,47;
- в диапазоне 696,2–709,07 нм — 0,25–0,4.

В остальных диапазонах коэффициент корреляции оказался менее 0,25. Для упрощения вычислений выбранные спектры были разбиты на 15 равных отрезков, для которых рассчитывались средние значения. На рис. 6 представлена корреляционная матрица (на уровне значимости 0,0005). Из него видно, что корреляционная связь усилилась, кроме того, расширился диапазон информативных спектров.

На следующем этапе был проведён анализ корреляционной зависимости между показателями вегетационных индексов и урожайностью. На рис. 7 (см. с. 100) представлена полученная корреляционная матрица. При этом статистически незначимыми оказались коэффициенты между переменными PRI2 и Yield (показатель урожайности), а также между ARI и Yield.

Дополнительно была построена множественная регрессия по вегетационным индексам и урожайности, несмотря на то что уравнение оказалось статистически значимым в целом (p -value = 0,0003, коэффициент детерминации $R^2 = 0,58$), многие полученные коэффициенты были незначимы. После поочерёдного удаления незначимых переменных было построено следующее уравнение:

$$\text{Yield} = -173\text{PPR} + 532\text{PRI1} + 293\text{PRI2} + 61.$$

Для анализа статистической значимости вегетационных индексов как отдельных факторов с точки зрения их связи с урожайностью были также построены парные регрессии, результаты оценок полученных моделей представлены в табл. 3.

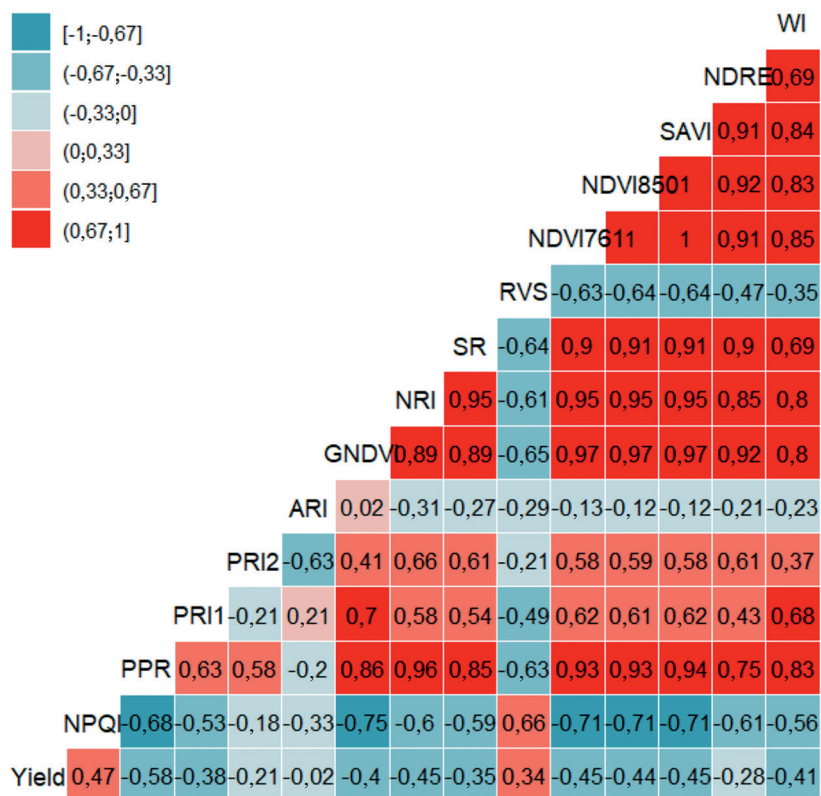


Рис. 7. Корреляционная матрица для выбранных вегетационных индексов

Таблица 3. Результаты построений парных регрессий зависимости урожайности от вегетационных индексов

Уравнение	Уровень значимости коэффициента при независимой переменной в уравнении	Уровень значимости свободного коэффициента в уравнении	p-value	Коэффициент детерминации R ²
Yield = 286NPQI + 42	0,0003	<0,0001	0,0003	0,2200
Yield = -56PPR + 45	<0,0001		<0,0001	0,3300
Yield = -207PRI1 + 38	0,0040		0,0040	0,1400
Yield = -59PRI2 + 20	0,1260		0,1260	0,0400
Yield = -3704ARI + 22	0,8580		0,8580	0,0006
Yield = -37GNDVI + 43	0,0030		0,0030	0,1600
Yield = -31NRI + 28	0,0005		0,0005	0,2000
Yield = -SR + 29	0,0090		0,0090	0,1200
Yield = 0,009RVS + 32	0,0110		0,0110	0,1100
Yield = -24NDVI ₇₆₁ + 38	0,0005		0,0005	0,2000
Yield = -27NDVI ₈₅₀ + 41	0,0007		0,0007	0,2000
Yield = -22SAVI + 40	0,0005		0,0005	0,2000
Yield = -37NDRE + 32	0,0400		0,0400	0,0800
Yield = -52WI + 78	0,0020		0,0020	0,1600

На основании полученных результатов сформированы следующие выводы:

- Информативность спектральных характеристик в задаче прогнозирования урожайности пшеницы варьируется ввиду природного характера исходных данных. Так, например, в опыте 2022 г. на тестовых площадках присутствовала засорённость, что также

могло повлиять и на отсутствие корреляционных связей между наземными измерениями гиперспектрометра и урожайностью, ведь при этом обследовались исключительно растения пшеницы и не учитывались такие факторы, как засорённость или проективное покрытие, более эффективным источником информации оказались данные аэрофотосъёмки.

- Наиболее перспективными для использования в задаче прогнозирования урожайности в проведённом опыте представляются каналы из видимого диапазона, при этом наблюдается высокая мультиколлинеарность объясняющих факторов.
- Наибольший интерес среди вегетационных индексов для дальнейшего исследования в рассмотренном опыте представляют следующие комбинации спектров: NPQI, PPR, NRI, NDVI₇₆₁, NDVI₈₅₀, SAVI.
- В качестве направления дальнейшей работы следует провести дополнительные полевые опыты, расширить датасет. Так, например, в 2023 г. был также осуществлён более масштабный опыт на том же поле. По всему полигону были распределены 100 точек, где в каждую фазу развития растений отбирались образцы и осуществлялась аэрофотосъёмка (рис. 8). Для каждой точки (площадка 50×50 см) были получены показатели структуры урожайности: длина стебля, колоса; масса стебля, колоса, зерна; количество зёрен для каждого растения из пробы. Целесообразно провести канонический корреляционный анализ полученного датасета, где в качестве одного набора переменных будут показатели урожайности и её структуры, а в качестве второго — спектральные характеристики. Кроме того, необходимо дополнительно исследовать данные отдельно по фазам развития растений, поскольку имеются научные работы, в которых выявлена существенная разница в колориметрических характеристиках на разных стадиях (Zhang et al., 2022).




Рис. 8. Схема опыта 2023 г. для дальнейшего развития исследования

Заключение

В работе представлен анализ зависимостей гиперспектральных данных дистанционного зондирования и показателей урожайности пшеницы, полученных с тестовых площадок в ходе проведения полевых опытов в 2022 и 2023 гг. Результаты продемонстрировали преимущество аэрофотосъёмки перед использованием лабораторного переносного гиперспектрометра. В качестве наиболее информативных каналов выделены спектры из видимого диапазона для последующего применения в задаче прогнозирования урожайности. Кроме того, определены наиболее перспективные вегетационные индексы, сформированы основные направления дальнейшего исследования.

Исследование выполнено за счёт гранта Российского научного фонда № 24-21-00231, <https://rscf.ru/project/24-21-00231/>.

Литература

1. Матвеевко Д. А., Якушев В. В., Якушев В. П. Прецизионное управление азотным режимом яровой пшеницы на основе дистанционного зондирования посевов // Современные проблемы дистанционного зондирования Земли из космоса. 2019. Т. 16. № 3. С. 79–86. <https://doi.org/10.21046/2070-7401-2019-16-3-79-86>.
2. Якушев В. П., Канаиш Е. В., Русаков Д. В. и др. Корреляционные зависимости между вегетационными индексами, урожаем зерна и оптическими характеристиками листьев пшеницы при разном содержании в почве азота и густоте посева // Сельскохозяйственная биология. 2022. Т. 57. № 1. С. 98–112. <https://doi.org/10.15389/agrobiology.2022.1.98rus>.
3. Bausch W. C., Duke H. R. Remote sensing of plant nitrogen status in corn // Trans. ASAE. 1996. V. 39, Iss. 5. P. 1869–1875. <https://doi.org/10.13031/2013.27665>.
4. Ceccato P., Gobron N., Flasse S. et al. Designing a spectral index to estimate vegetation water content from remote sensing data: Part 1: Theoretical approach // Remote Sensing of Environment. 2002. V. 82. Iss. 2–3. P. 188–197. [https://doi.org/10.1016/S0034-4257\(02\)00037-8](https://doi.org/10.1016/S0034-4257(02)00037-8).
5. Fei S., Hassan M. A., Xiao Y. et al. UAV-based multi-sensor data fusion and machine learning algorithm for yield prediction in wheat // Precision Agriculture. 2023. V. 24. P. 187–212. <https://doi.org/10.1007/s11119-022-09938-8>.
6. Gamon J. A., Serrano L., Surfus J. S. The photochemical reflectance index: an optical indicator of photosynthetic radiation use efficiency across species, functional types, and nutrient levels // Oecologia. 1997. V. 112. P. 492–501. <https://doi.org/10.1007/s004420050337>.
7. Gavahi K., Abbaszadeh P., Moradkhani H. DeepYield: A combined convolutional neural network with long short-term memory for crop yield forecasting // Expert Systems with Applications. 2021. V. 184. Article 115511. <https://doi.org/10.1016/j.eswa.2021.115511>.
8. Gitelson A. A., Merzlyak M. N. Signature analysis of leaf reflectance spectra: algorithm development for remote sensing of chlorophyll // J. Plant Physiology. 1996. V. 148. Iss. 3–4. P. 494–500. [https://doi.org/10.1016/S0176-1617\(96\)80284-7](https://doi.org/10.1016/S0176-1617(96)80284-7).
9. Gitelson A. A., Merzlyak M. N., Chivkunova O. B. Optical properties and nondestructive estimation of anthocyanin content in plant leaves // Photochemistry and Photobiology. 2001. V. 74. P. 38–45. [https://doi.org/10.1562/0031-8655\(2001\)074%3C0038:OPANEO%3E2.0.CO;2](https://doi.org/10.1562/0031-8655(2001)074%3C0038:OPANEO%3E2.0.CO;2).
10. Jordan C. F. Derivation of leaf-area index from quality of light on the forest floor // Ecology. 1969. V. 50. Iss. 4. P. 663–666. <https://doi.org/10.2307/1936256>.
11. Li Z., Chen Z., Cheng Q. et al. UAV-based hyperspectral and ensemble machine learning for predicting yield in winter wheat // Agronomy. 2022. V. 12. Article 202. <https://doi.org/10.3390/agronomy12010202>.
12. le Maire G., François C., Soudani K. et al. Calibration and validation of hyperspectral indices for the estimation of broadleaved forest leaf chlorophyll content, leaf mass per area, leaf area index and leaf canopy biomass // Remote Sensing of Environment. 2008. V. 112, Iss. 10. P. 3846–3864. <https://doi.org/10.1016/j.rse.2008.06.005>.
13. Ma J., Liu B., Ji L. et al. Field-scale yield prediction of winter wheat under different irrigation regimes based on dynamic fusion of multimodal UAV imagery // Intern. J. Applied Earth Observation and Geoinformation. 2023. V. 118. Article 103292. <https://doi.org/10.1016/j.jag.2023.103292>.
14. Meroni M., Waldner F., Seguíni L. et al. Yield forecasting with machine learning and small data: What gains for grains? // Agricultural and Forest Meteorology. 2021. V. 308–309. Article 108555. <https://doi.org/10.1016/j.agrformet.2021.108555>.
15. Merton R. N. Monitoring community hysteresis using spectral shift analysis and the red-edge vegetation stress index // Proc. 7th Annu. JPL Airborne Earth Science Workshop. NASA, Jet Propulsion Laboratory, Pasadena, California, USA, 12–16 Jan. 1998. 1998. Article 702.
16. Metternicht G. Vegetation indices derived from high-resolution airborne videography for precision crop management // Intern. J. Remote Sensing. 2003. V. 24. P. 2855–2877. <https://doi.org/10.1080/01431160210163074>.
17. Moghimi A., Yang C., Anderson J. A. Aerial hyperspectral imagery and deep neural networks for high-throughput yield phenotyping in wheat // Computers and Electronics in Agriculture. 2020. V. 172. Article 105299. <https://doi.org/10.1016/j.compag.2020.105299>.
18. Nagy A., Feher J., Tamas J. Wheat and maize yield forecasting for the Tisza river catchment using MODIS NDVI time series and reported crop statistics // Computers and Electronics in Agriculture. 2018. V. 151. P. 41–49. <https://doi.org/10.1016/j.compag.2018.05.035>.

19. *Penuelas J., Filella I., Lloret P. et al.* Reflectance assessment of mite effects on apple trees // Intern. J. Remote Sensing. 1995. V. 16. P. 2727–2733. <https://doi.org/10.1080/01431169508954588>.
20. *Penuelas J., Pinol J., Ogaya R., Filella I.* Estimation of plant water concentration by the reflectance water index WI (R900/R970) // Intern. J. Remote Sensing. 1997. V. 18. Iss. 13. P. 2869–2875. <https://doi.org/10.1080/014311697217396>.
21. *Raun W.R., Solie J.B., Johnson G.V. et al.* In-season prediction of potential grain yield in winter wheat using canopy reflectance // Agronomy J. 2001. V. 93. Iss. 1. P. 131–138. <https://doi.org/10.2134/agnonj2001.931131x>.
22. *Rondeaux G., Steven M., Baret F.* Optimization of soil-adjusted vegetation indices // Remote Sensing of Environment. 1996. V. 55. Iss. 2. P. 95–107. [https://doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7).
23. *Schauberger B., Jagermeyr J., Gornott C.* A systematic review of local to regional yield forecasting approaches and frequently used data resources // European J. Agronomy. 2020. V. 120. Article 126153. <https://doi.org/10.1016/j.eja.2020.126153>.
24. *Yang W., Nigon T., Hao Z. et al.* Estimation of corn yield based on hyperspectral imagery and convolutional neural network // Computers and Electronics in Agriculture. 2021. V. 184. Article 106092. <https://doi.org/10.1016/j.compag.2021.106092>.
25. *Yang Z., Tian J., Feng K. et al.* Application of a hyperspectral imaging system to quantify leaf-scale chlorophyll, nitrogen and chlorophyll fluorescence parameters in grapevine // Plant Physiology and Biochemistry. 2021. V. 166. P. 723–737. <https://doi.org/10.1016/j.plaphy.2021.06.015>.
26. *Zhang Y., Yang Y., Chen C. et al.* Modeling leaf color dynamics of winter wheat in relation to growth stages and nitrogen rates // J. Integrative Agriculture. 2022. V. 21. Iss. 1. P. 60–69. [https://doi.org/10.1016/S2095-3119\(20\)63319-6](https://doi.org/10.1016/S2095-3119(20)63319-6).

Analysis of hyperspectral remote sensing data and wheat yield for the forecasting task

O. A. Mitrofanova¹, E. P. Mitrofanov^{1,2}, V. M. Bure^{1,2}

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

² Agrophysical Research Institute, Saint Petersburg 195220, Russia

One of the important tasks of crop production management is crop yield forecasting. Currently, remote sensing data such as satellite images and aerial photography are increasingly used as source information for crop forecasting. Due to the rapid development of information and engineering technologies, the use of specialized vegetation indices is also becoming relevant and accessible. The objects of the presented research are experimental agricultural fields located in Leningrad Region. The data obtained on the basis of two polygons with an area of 12 and 28 hectares were used for the work, the growing crop is spring wheat. Test sites were laid on each field — small flat areas with a certain applied dose of nitrogen-containing fertilizers. Aerial photography of experimental polygons was carried out using the DJI Matrice 600 Pro unmanned aerial system (UAS) with a Pika L hyperspectral camera (281 shooting channels in the range of 400–1000 nm). In 2022, wheat samples were additionally taken from test sites simultaneously with the flights and their spectral characteristics were obtained in the fields using a portable laboratory hyperspectrometer. The results of the study demonstrated the advantage of using aerial photography over laboratory hyperspectrometer. Channels from the visible range appear to be the most promising for use in the task of forecasting yields in the conducted experiment, whereas a high multicollinearity of explanatory factors is observed. In addition, a regression analysis was performed. As a result, among the vegetation indices six combinations of spectra were identified for further study in the considered experiment. As a direction for further work, additional field experiments should be conducted and the dataset expanded.

Keywords: hyperspectral remote sensing data, aerial photography, vegetation indices, correlation analysis, yield forecast, wheat

Accepted: 02.12.2024

DOI: 10.21046/2070-7401-2025-22-1-93-105

References

1. Matveenکو D. A., Yakushev V. V., Yakushev V. P., Precision management of the nitrogen status of spring wheat crops based on remote sensing data, *Sovremennyye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2019, V. 16, No. 3, pp. 79–86 (in Russian), <https://doi.org/10.21046/2070-7401-2019-16-3-79-86>.
2. Yakushev V. P., Kanash E. V., Rusakov D. V. et al., Correlation dependences between crop reflection indices, grain yield and optical characteristics of wheat leaves at different nitrogen level and seeding density, *Sel'skokhozyaystvennaya biologiya*, 2022, V. 57, No. 1, pp. 98–112 (in Russian), <https://doi.org/10.15389/agrobiology.2022.1.98rus>.
3. Bausch W. C., Duke H. R., Remote sensing of plant nitrogen status in corn, *Trans. ASAE*, 1996, V. 39, Iss. 5, pp. 1869–1875, <https://doi.org/10.13031/2013.27665>.
4. Ceccato P., Gobron N., Flasse S. et al., Designing a spectral index to estimate vegetation water content from remote sensing data: Part 1: Theoretical approach, *Remote Sensing of Environment*, 2002, V. 82, Iss. 2–3, pp. 188–197, [https://doi.org/10.1016/S0034-4257\(02\)00037-8](https://doi.org/10.1016/S0034-4257(02)00037-8).
5. Fei S., Hassan M. A., Xiao Y. et al., UAV-based multi-sensor data fusion and machine learning algorithm for yield prediction in wheat, *Precision Agriculture*, 2023, V. 24, pp. 187–212, <https://doi.org/10.1007/s11119-022-09938-8>.
6. Gamon J. A., Serrano L., Surfus J. S., The photochemical reflectance index: an optical indicator of photosynthetic radiation use efficiency across species, functional types, and nutrient levels, *Oecologia*, 1997, V. 112, pp. 492–501, <https://doi.org/10.1007/s004420050337>.
7. Gavahi K., Abbaszadeh P., Moradkhani H., DeepYield: A combined convolutional neural network with long short-term memory for crop yield forecasting, *Expert Systems with Applications*, 2021, V. 184, Article 115511, <https://doi.org/10.1016/j.eswa.2021.115511>.
8. Gitelson A. A., Merzlyak M. N., Signature analysis of leaf reflectance spectra: algorithm development for remote sensing of chlorophyll, *J. Plant Physiology*, 1996, V. 148, Iss. 3–4, pp. 494–500, [https://doi.org/10.1016/S0176-1617\(96\)80284-7](https://doi.org/10.1016/S0176-1617(96)80284-7).
9. Gitelson A. A., Merzlyak M. N., Chivkunova O. B., Optical properties and nondestructive estimation of anthocyanin content in plant leaves, *Photochemistry and Photobiology*, 2001, V. 74, pp. 38–45, [https://doi.org/10.1562/0031-8655\(2001\)074%3C0038:OPANEO%3E2.0.CO;2](https://doi.org/10.1562/0031-8655(2001)074%3C0038:OPANEO%3E2.0.CO;2).
10. Jordan C. F., Derivation of leaf-area index from quality of light on the forest floor, *Ecology*, 1969, V. 50, Iss. 4, pp. 663–666, <https://doi.org/10.2307/1936256>.
11. Li Z., Chen Z., Cheng Q. et al., UAV-based hyperspectral and ensemble machine learning for predicting yield in winter wheat, *Agronomy*, 2022, V. 12, Article 202, <https://doi.org/10.3390/agronomy12010202>.
12. le Maire G., François C., Soudani K. et al., Calibration and validation of hyperspectral indices for the estimation of broadleaved forest leaf chlorophyll content, leaf mass per area, leaf area index and leaf canopy biomass, *Remote Sensing of Environment*, 2008, V. 112, Iss. 10, pp. 3846–3864, <https://doi.org/10.1016/j.rse.2008.06.005>.
13. Ma J., Liu B., Ji L. et al., Field-scale yield prediction of winter wheat under different irrigation regimes based on dynamic fusion of multimodal UAV imagery, *Intern. J. Applied Earth Observation and Geoinformation*, 2023, V. 118, Article 103292, <https://doi.org/10.1016/j.jag.2023.103292>.
14. Meroni M., Waldner F., Seguini L. et al., Yield forecasting with machine learning and small data: What gains for grains?, *Agricultural and Forest Meteorology*, 2021, V. 308–309, Article 108555, <https://doi.org/10.1016/j.agrformet.2021.108555>.
15. Merton R. N., Monitoring community hysteresis using spectral shift analysis and the red-edge vegetation stress index, *Proc. 7th Annu. JPL Airborne Earth Science Workshop, NASA, Jet Propulsion Laboratory, Pasadena, California, USA, 12–16 Jan. 1998*, 1998, Article 702.
16. Metternicht G., Vegetation indices derived from high-resolution airborne videography for precision crop management, *Intern. J. Remote Sensing*, 2003, V. 24, pp. 2855–2877, <https://doi.org/10.1080/01431160210163074>.
17. Moghimi A., Yang C., Anderson J. A., Aerial hyperspectral imagery and deep neural networks for high-throughput yield phenotyping in wheat, *Computers and Electronics in Agriculture*, 2020, V. 172, Article 105299, <https://doi.org/10.1016/j.compag.2020.105299>.
18. Nagy A., Feher J., Tamas J., Wheat and maize yield forecasting for the Tisza river catchment using MODIS NDVI time series and reported crop statistics, *Computers and Electronics in Agriculture*, 2018, V. 151, pp. 41–49, <https://doi.org/10.1016/j.compag.2018.05.035>.
19. Penuelas J., Filella I., Lloret P. et al., Reflectance assessment of mite effects on apple trees, *Intern. J. Remote Sensing*, 1995, V. 16, pp. 2727–2733, <https://doi.org/10.1080/01431169508954588>.
20. Penuelas J., Pinol J., Ogaya R., Filella I., Estimation of plant water concentration by the reflectance water index WI (R900/R970), *Intern. J. Remote Sensing*, 1997, V. 18, Iss. 13, pp. 2869–2875, <https://doi.org/10.1080/014311697217396>.

21. Raun W.R., Solie J.B., Johnson G.V. et al., In-season prediction of potential grain yield in winter wheat using canopy reflectance, *Agronomy J.*, 2001, V. 93, Iss. 1, pp. 131–138, <https://doi.org/10.2134/agronj2001.931131x>.
22. Rondeaux G., Steven M., Baret F., Optimization of soil-adjusted vegetation indices, *Remote Sensing of Environment*, 1996, V. 55, Iss. 2, pp. 95–107, [https://doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7).
23. Schauburger B., Jagermeyr J., Gornott C., A systematic review of local to regional yield forecasting approaches and frequently used data resources, *European J. Agronomy*, 2020, V. 120, Article 126153, <https://doi.org/10.1016/j.eja.2020.126153>.
24. Yang W., Nigon T., Hao Z. et al., Estimation of corn yield based on hyperspectral imagery and convolutional neural network, *Computers and Electronics in Agriculture*, 2021, V. 184, Article 106092, <https://doi.org/10.1016/j.compag.2021.106092>.
25. Yang Z., Tian J., Feng K. et al., Application of a hyperspectral imaging system to quantify leaf-scale chlorophyll, nitrogen and chlorophyll fluorescence parameters in grapevine, *Plant Physiology and Biochemistry*, 2021, V. 166, pp. 723–737, <https://doi.org/10.1016/j.plaphy.2021.06.015>.
26. Zhang Y., Yang Y., Chen C. et al., Modeling leaf color dynamics of winter wheat in relation to growth stages and nitrogen rates, *J. Integrative Agriculture*, 2022, V. 21, Iss. 1, pp. 60–69, [https://doi.org/10.1016/S2095-3119\(20\)63319-6](https://doi.org/10.1016/S2095-3119(20)63319-6).