

Monitoring chlorophyll in rice fields using Sentinel 2 and UAV images and applying machine learning

Abdollah Ehsanpour¹, **Ebadat Ghanbari Parmehr**^{*2}, **Shamim Amini**³

1- MSc. student Faculty of civil engineering, Babol Noshirvani University of Technology, Babol, Iran. Email: ph.ali.ehsanpour@gmail.com

2- (*Corresponding author) Assistant professor, Faculty of civil engineering, Babol Noshirvani University of Technology, Babol, Iran. Email: parmehr@nit.ac.ir

3- Advisor Natural resources and watershed management organization. Email: sh.amini.forestry@gmail.com

Article Info

Date of receive:

2024/11/15

Date of last review:

2025/05/15

Date of accept:

2025/07/08

Date of online publication:

2025/07/10

Keywords:

Rice,
Precision agriculture,
Chlorophyll,
NDVI,
Machine Learning
Algorithms,
Sentinel-2 Images,
UAV Images

Extended Abstract

Introduction

This study provides a comprehensive analysis of the relationship between vegetation indices and chlorophyll variation at different growth stages of rice fields in northern Iran, employing the latest advancements in remote sensing and precision agriculture technologies. Mineral nutrition plays a crucial role in plant growth and development, significantly influencing the yield and quality of rice crops. Understanding the dynamics of chlorophyll and its spatial distribution is crucial for optimizing fertilization practices, improving crop productivity, and ensuring sustainable agricultural practices.

Materials & Methods

In this research, a multifaceted approach that combined data from Sentinel-2 satellite imagery was utilized, UAV (Unmanned Aerial Vehicle) imagery equipped with RGB sensors, and ground-based SPAD (Soil Plant Analysis Development) measurements. Sentinel-2 imagery data is known for its high-resolution multispectral capabilities, which allow for detailed monitoring of vegetation health and land use changes over large geographical areas. The satellite's ability to capture multiple spectral bands enhances our capacity to assess various vegetation indices, including the Normalized Difference Vegetation Index (NDVI), which is widely used to evaluate plant health and growth conditions. UAV imagery complements the satellite data by providing high-resolution, fine-scale detail that can be captured at specific times during the crop's growth cycle. The flexibility of UAVs enables targeted data collection, allows monitoring critical growth stages and variations in chlorophyll levels that may not be detectable through satellite imagery alone. ... ► Page 08

How to Cite:

Ehsanpour, A. Ghanbari Parmehr, E. Amini, Sh. (2026). Monitoring chlorophyll in rice fields using Sentinel 2 and UAV images and applying machine learning. Scientific -Research Quarterly Geographical Data (SEPEHR). 34(136), 07-27.

By integrating both data sources, it is aimed to generate a comprehensive understanding of the relationship between chlorophyll and vegetation indices across different spatial and temporal dimensions. The primary objective was to develop predictive models for NDVI, a key indicator of vegetation health that correlates closely with chlorophyll concentration and fertilization need in plants. To achieve this, three machine learning algorithms: Random Forest Regression (RFR), Support Vector Regression (SVR), and Multi-Layer Perceptron Regression (MLPR) was employed. Each algorithm offers unique strengths in handling complex datasets and capturing non-linear relationships, which are common in agronomic data.

Results & Discussion

The results of analysis indicated that the RFR algorithm outperformed the other two models, achieving a correlation coefficient of 0.80 when predicting NDVI from UAV imagery. This strong correlation suggests that RFR effectively captures the intricate relationships between the spectral reflectance values obtained from UAV images and the underlying nutrition content in the rice fields. The high predictive accuracy of the RFR model highlights its potential for practical applications in precision agriculture, where timely and accurate assessments of crop health are essential for informed decision-making. In addition to predicting NDVI, the Kriging spatial interpolation technique was utilized to generate detailed chlorophyll distribution maps based on the SPAD data collected from the field. Kriging is a powerful geostatistical method that allows for optimal estimation of unmeasured locations based on observed data, providing insights into spatial variations in chlorophyll across the rice fields. The generated chlorophyll maps revealed significant correlations with NDVI, confirming that remote sensing techniques can effectively monitor nutrient dynamics and assess the overall health of crops. The findings of this research underscore the potential of integrating UAV and satellite data through machine learning techniques and advanced image processing methods for resource management in agriculture. By providing farmers with precise information regarding chlorophyll levels and vegetation health, these technologies enable more

informed decision-making processes. For instance, farmers can optimize fertilization strategies by applying mineral nutrition only where it is needed and in the appropriate amounts, thereby maximizing crop yield while minimizing environmental impacts. The integration of remote sensing and precision agriculture technologies can contribute to broader goals of sustainable agriculture. As the global population continues to rise, the demand for food production increases, necessitating innovative approaches to enhance agricultural productivity while conserving natural resources.

Conclusion

In conclusion, this study illustrates the effective use of remote sensing and machine learning technologies in analyzing the relationship between vegetation indices and chlorophyll variation in rice fields. The successful prediction of NDVI using the RFR algorithm, alongside the generation of chlorophyll distribution maps through Kriging, highlights the potential of these methods to enhance agricultural practices. Further research is needed to explore the applicability of these techniques across different crops and regions, paving the way for broader implementation of precision agriculture strategies. Ultimately, this research contributes to the growing body of knowledge on sustainable agricultural practices, emphasizing the role of technology in supporting farmers and promoting efficient resource management. By fostering greater collaboration between researchers, agricultural practitioners, and technology developers, the field of precision agriculture can advance and address the challenges faced by modern farming in a rapidly changing world.



صفحات ۲۷ - ۰۷

فصلنامه علمی - پژوهشی

اطلاعات جغرافیایی (سپهر) دوره ۳۴، شماره ۱۳۶، زمستان ۱۴۰۴



مقاله پژوهشی

doi <https://doi.org/10.22131/sepehr.2025.2045093.3102>

پایش کلروفیل مزارع برنج با استفاده از تصاویر سنتینل ۲ و پهپاد و به کارگیری یادگیری ماشین

عبداله احسانپور^۱، عبادت قنبری پر مهر*^۲، شمیم امینی^۳

۱- دانشجوی کارشناسی ارشد فتوگرامتری، دانشکده مهندسی عمران، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران ph.ali.ehsanpour@gmail.com
 ۲- (*نویسنده مسئول) استادیار دانشکده مهندسی عمران، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران parmehr@nit.ac.ir
 ۳- دانش آموخته دکتری تخصصی، سازمان منابع طبیعی و آبخیزداری کشور، ساری، ایران sh.amini.forestry@gmail.com

چکیده

پژوهش حاضر به بررسی ارتباط بین شاخص‌های گیاهی و تغییرات کلروفیل مزارع برنج در مراحل مختلف رشد در شمال ایران با استفاده از فناوری‌های سنجنش از دور و کشاورزی دقیق پرداخته است. در این تحقیق، از تصاویر ماهواره‌ای Sentinel-2، تصاویر پهپادی با سنجنده‌های RGB و داده‌های زمینی SPAD استفاده شده است. سه الگوریتم یادگیری ماشین شامل: رگرسیون جنگل تصادفی (RFR)، رگرسیون ماشین بردار پشتیبان (SVR) و رگرسیون پرسپترون چند لایه (MLPR) برای تخمین سبزیگی تصاویر پهپادی به کار گرفته شد. نتایج نشان داد که الگوریتم RFR با ضریب همبستگی ۰/۸۰، عملکرد بهتری در تخمین کلروفیل دارد. همچنین از تکنیک درون‌یابی مکانی Kriging برای استخراج نقشه‌های کلروفیل با استفاده از داده‌های SPAD استفاده شده است. نتایج نشان داد که همبستگی مناسبی بین نقشه‌های سبزیگی و SPAD وجود دارد. به طور کلی یافته‌های این پژوهش نشان داد که ادغام داده‌های پهپادی و ماهواره‌ای با استفاده از تکنیک یادگیری ماشین و روش‌های پیشرفته پردازش تصویر می‌تواند ابزار مؤثری برای مدیریت منابع و بهبود عملکرد مزارع باشد و به کشاورزان در تصمیم‌گیری‌های بهتر و به‌موقع کمک کند.

اطلاعات مقاله

تاریخ دریافت:

۱۴۰۳/۰۸/۲۵

تاریخ آخرین بازنگری:

۱۴۰۴/۰۲/۲۵

تاریخ پذیرش:

۱۴۰۴/۰۴/۱۷

تاریخ انتشار:

۱۴۰۴/۰۴/۱۹

واژه‌های کلیدی:

برنج؛

کشاورزی دقیق؛

سبزیگی؛

شاخص NDVI؛

الگوریتم‌های یادگیری

ماشین؛

تصاویر Sentinel-2؛

تصاویر پهپاد

استناد به این مقاله:

احسانپور، ع؛ قنبری پر مهر، ع؛ امینی، ش (۱۴۰۴) پایش کلروفیل مزارع برنج با استفاده از تصاویر سنتینل ۲ و پهپاد و به‌کارگیری یادگیری ماشین؛ فصلنامه علمی پژوهشی اطلاعات جغرافیایی (سپهر)، ۳۴ (۱۳۶)، ۲۷-۰۷.

۱- مقدمه

به سرعت مشکلات را شناسایی کرده و اقدامات لازم برای بهبود وضعیت گیاهان را انجام دهند.

هرچند اندازه‌گیری دقیق میزان مواد مغذی خاک و پوشش گیاهی از طریق روش‌های آزمایشگاهی دقیق است، این روش‌ها اغلب زمان‌بر و پرهزینه و در اراضی کشاورزی بزرگ، با توجه به تنوع مکانی بالا، با چالش‌های فراوانی روبرو هستند (Wei, Yan, & Xia, 2008). بازتاب طیفی گیاهان برنج پیش بینی کننده عملکرد است. این در مطالعات متعدد با استفاده از حسگرهای زمینی نشان داده شده است (Varinderpal-Singh et al., 2021, Chang et al., 2005). با این حال، روابط با مرحله رشد و رقم متغیر است (Varinderpal-Singh et al., 2021)

از این‌رو، کشاورزی دقیق (PA) به‌عنوان یک رویکرد نوین و کارآمد در کشاورزی مدرن معرفی شده است. کشاورزی دقیق به‌عنوان یکی از ده انقلاب برتر در کشاورزی شناخته می‌شود و نقش کلیدی در بهبود بهره‌وری و کاهش اثرات زیست‌محیطی نهاده‌ها دارد (Harwin & Lucieer, 2012). این رویکرد با استفاده از فناوری‌هایی همچون GPS، GIS و پهپادها، به کشاورزان امکان می‌دهد تا وضعیت محصولات خود را با دقت بیشتری بررسی کرده و نهاده‌های کشاورزی مانند کودهای معدنی را به‌صورت بهینه مدیریت کنند. فناوری پهپادها یکی از ابزارهای پیشرفته‌ای است که در کشاورزی دقیق برای پایش مزارع مورد استفاده قرار می‌گیرد. پهپادها با قابلیت پرواز در ارتفاعات مختلف و تهیه تصاویر با قدرت تفکیک بالا، می‌توانند داده‌های دقیق و به‌روز از وضعیت محصولات کشاورزی فراهم کنند. تصاویر پهپاد امکان ارزیابی تغییرات در میزان کلروفیل و در نتیجه نیاز به کود معدنی گیاهان را با هزینه کمتری نسبت به روش‌های سنتی و داده‌های ماهواره‌ای فراهم می‌کنند. در حالی که تصاویر ماهواره‌ای نیز قابلیت‌های بالایی در جمع‌آوری داده‌های طیفی و پایش مناطق وسیع دارند، اما به دلیل قدرت تفکیک مکانی و زمانی پایین‌تر، نمی‌توانند

شالیزارهای برنج با پوشش بیش از ۱۱ درصد از زمین‌های کشاورزی جهان، غذای اصلی بیش از سه میلیارد نفر از جمعیت جهان را تأمین و نقش مهمی در امنیت غذایی جهانی ایفا می‌کنند (Paliwal, Laborte, Nelson, & Singh, 2019; Qin et al., 2015; Q. Zhao et al., 2015; R. Zhao, Li, & Ma, 2021). ایران با رشد سریع جمعیت، بارش‌های نامنظم، زمین‌های محدود کشاورزی و منابع آبی کم، با چالش‌هایی جدی در تولید محصولات کشاورزی مواجه است. پیش‌بینی‌ها نشان می‌دهند که جمعیت ایران تا سال ۲۰۳۰ از ۹۰ میلیون نفر فراتر خواهد رفت که این امر اهمیت به‌کارگیری روش‌های کارآمدتر در کشاورزی را بیشتر می‌نماید (Soltani et al., 2020). امروزه افزایش بازده محصولات با توجه به گسترش زمین‌های غیرقابل کشت، به تنها گزینه برای تضمین امنیت غذایی جهانی تبدیل شده است. لیکن وضعیت رشد و سطح عملکرد برنج همواره نگران کننده بوده است؛ به همین دلیل نظارت دقیق و پیش از برداشت بر نحوه رشد و پیش‌بینی عملکرد برنج اهمیت زیادی در اجرای اقدامات مزرعه‌ای، تدوین سیاست و تعیین قیمت دارد (Luo, Jiang, Yang, Li, & Fang, 2022)

برای رشد بهینه گیاه، مواد مغذی باید به مقدار کافی و متعادل در دسترس باشند. اما این ذخایر عمدتاً به شکلی هستند که در دسترس گیاهان نیستند. در این راستا، کودهای معدنی به عنوان عنصر اساسی برای بهبود عملکرد برنج، بیشترین مصرف را در میان نهاده‌های کشاورزی دارد. وجود مواد مغذی رابطه مستقیم با میزان کلروفیل گیاه دارد و از پارامترهای مهم تغذیه‌ای و فیزیولوژیکی رشد گیاه است و به‌عنوان شاخصی مهم برای کوددهی و آبیاری گیاهان مورد استفاده قرار می‌گیرد. همچنین، کلروفیل می‌تواند به عنوان شاخصی مهم برای ارزیابی سلامت گیاهان مورد استفاده قرار گیرد. کاهش میزان کلروفیل ممکن است نشان‌دهنده بیماری‌ها، استرس‌های محیطی یا کمبود مواد مغذی باشد. با پایش منظم میزان کلروفیل، کشاورزان و محققان می‌توانند

همبستگی پیرسون $0/82$ بین مقادیر پیش‌بینی شده و مشاهده شده، دقت بالایی در برآورد کود نیتروژن ارائه داد (Eugenio *et al.*, 2023). در مطالعه‌ای دیگر، چن^۵ و همکاران در سال ۲۰۲۴ از پهپادهای مجهز به سنجنده‌های چندطیفی برای نمایش وضعیت کود نیتروژن در مزارع برنج استفاده کردند. مدل‌های استفاده شده شامل رگرسیون گام‌به‌گام^۶ و ماشین بردار پشتیبان^۷ (SVM) با R^2 بالای $0/85$ بودند (Yang *et al.*, 2024). نوآوری پژوهش حاضر در مقایسه با تحقیقات دیگر، محاسبه شاخص گیاهی با استفاده از تصاویر مرئی پهپاد و به کمک داده‌های ماهواره‌ای و ارزیابی آن با نقشه‌های کلروفیل حاصل از داده‌های نقاط برداشتی توسعه تجزیه و تحلیل خاک و گیاه SPAD^۸ است. استفاده از تصاویر مرئی پهپاد نقشه‌های سبزیگی دقیق و با قدرت تفکیک بالا را در اختیار کشاورزان و مدیران کشاورزی قرار می‌دهد که منجر به تصمیم‌گیری‌های دقیق‌تر و به موقع‌تری در زمینه کوددهی و مدیریت منابع شده و در نهایت موجب ارتقای امنیت غذایی و توسعه پایدار کشاورزی در کشور خواهد شد.

۲- مواد و روش‌ها

۲-۱- معرفی منطقه مورد مطالعه

این مطالعه در شهرستان آمل استان مازندران انجام شده است. استان مازندران به‌ویژه شهر آمل، به‌عنوان منطقه اصلی تولید برنج، از مزایای مهمی در شرایط اقلیمی و جغرافیایی برخوردار است (Darzi-Naftchali, 2016). شهرستان آمل در مرکز استان مازندران قرار دارد و با تولید بیش از پنج هزار تن شلتوک، ۳۰ درصد از برنج کشور را تأمین می‌کند. این منطقه مطالعاتی در زون ۳۹ شمالی در سیستم مختصات UTM و بین عرض جغرافیایی ۳۶ درجه و ۲۲ دقیقه تا ۳۶ درجه و ۲۳ دقیقه و همچنین طول جغرافیایی ۵۲ درجه و ۱۴ دقیقه تا ۵۲ درجه و ۲۹ دقیقه قرار دارد (نگاره ۱).

جزئیات دقیقی از مناطق کوچک یا زمین‌های کشاورزی کوچک ارائه دهند. با توجه به خرده مالکی شالیزارهای شمال و ابعاد کوچک مزارع برنج، استفاده از تصاویر با قدرت تفکیک یک متر برای شناسایی تنش گیاهان در سطح مزرعه و قدرت تفکیک ۱۰ متری تصاویر سنتینل ۲ استفاده از تصاویر پهپاد اجتناب‌ناپذیر است. تصاویر پهپاد تصاویر با قدرت تفکیک خیلی بالا و داده‌های طیفی که توسط پهپادها جمع‌آوری می‌شود، اطلاعات مهمی درباره وضعیت سلامت و تغذیه گیاهان ارائه می‌دهند گیاهان سالم نور مادون قرمز (NIR) را به شدت بازتاب می‌دهند و در عین حال نور قرمز را برای انجام فرایند فتوسنتز جذب می‌کنند. این تفاوت در بازتاب نور نشان‌دهنده سلامت گیاه و توانایی آن برای انجام فتوسنتز است. در حالی که گیاهان تحت تنش ناشی از کمبود کود یا تنش‌های محیطی دیگر بازتاب نور کمتری در باند NIR دارند. شاخص‌های گیاهی مانند شاخص نرمال‌شده تفاوت پوشش گیاهی^۲ (NDVI) که با استفاده از داده‌های بازتابی طیفی محاسبه می‌شوند، می‌توانند برای شناسایی نواحی تحت تنش و ارزیابی سلامت کلی گیاهان بسیار مفید باشند (Hawkesford, 2014).

هدف اصلی این پژوهش، بررسی امکان برآورد و تفسیر تغییرات سبزیگی محصول برنج با استفاده از تصاویر پهپادی و پایش تغییرات کلروفیل در طول فصل رشد است. در سال‌های اخیر، پژوهش‌های متعددی به بررسی و توسعه مدل‌های پیش‌بینی مبتنی بر یادگیری ماشین و داده‌های پهپادی برای برآورد وضعیت نیتروژن و عملکرد محصولات کشاورزی پرداخته‌اند. به عنوان نمونه، یوجنیو^۳ و همکاران در سال ۲۰۲۳ با استفاده از تصاویر چندطیفی پهپاد در مراحل مختلف رشد برنج، مدل‌های پیش‌بینی نیتروژن و عملکرد دانه را با الگوریتم پرسپترون چند لایه^۴ (MLP) توسعه دادند. این مطالعه نشان داد که مدل MLP با

5- Chen

6- Stepwise Regression

7- Support Vector Machine

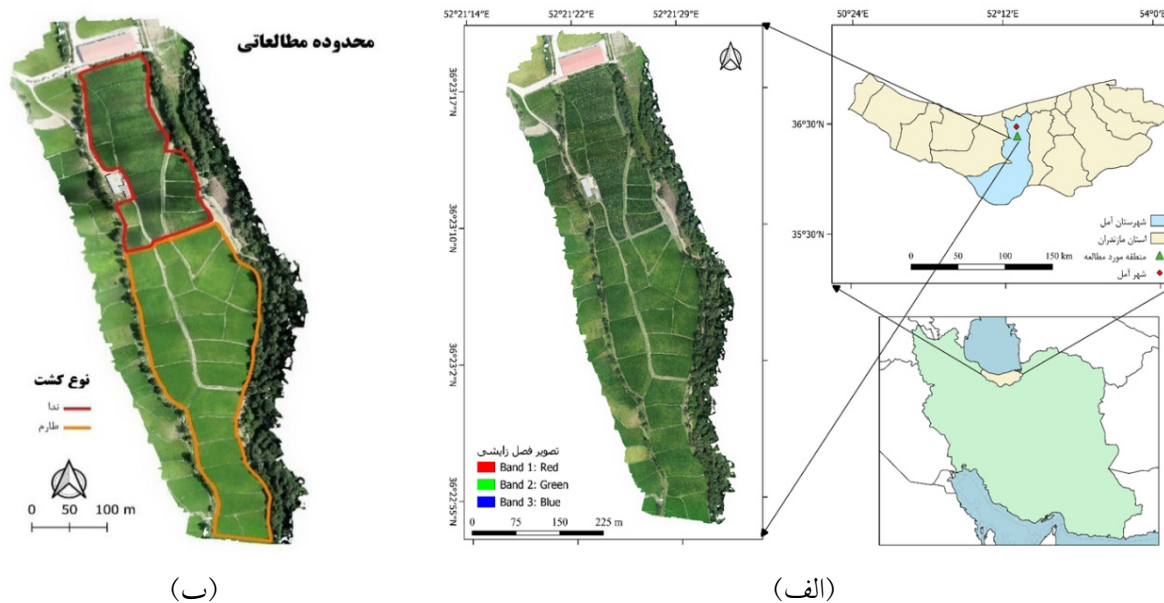
8- Soil and Plant Analysis Development

1- Near-Infrared

2- Normalized Difference Vegetation Index

3- Eugenio

4- Multi-Layer Perceptron



نگاره ۱: (الف) موقعیت جغرافیایی منطقه مورد مطالعه و (ب) محدوده کشت گونه‌های برنج طارم و ندا بر روی تصاویر پهپاد

منطقه مورد مطالعه دارای اقلیمی نیمه‌گرمسیری مرطوب (اقلیم نیمه‌حاره‌ای مرطوب) و میانگین بارندگی سالانه ۷۴۰ میلی‌متر هست که براساس سیستم طبقه‌بندی کوپن^۱ و ترورثا^۲ در گروه CFA قرار می‌گیرد (Beck et al., 2018; Habibi, Niknejad, Fallah, Dastan, & Tari, 2019). در فصل کشت برنج دما به ترتیب از ۱۹ تا ۲۵ درجه سانتی‌گراد و میزان بارش ۲۵ تا ۱۲۵ میلی‌متر متغیر است (FAO, 2023).

استفاده از سیستم پس پردازش^۳ (PPK) موقعیت‌یابی شد که داده‌هایی با دقت، در حد سانتی‌متر تولید شدند. پنج پرواز در مراحل مختلف رشد محصول شامل: دو پرواز در فصل رویشی و سه پرواز در فصل زایشی انجام شد که در جهت شمالی - جنوبی و در خلاف جهت باد انجام گرفت. عملیات تصویربرداری همزمان با بررسی‌های میدانی در پنج مرحله فنولوژیکی و بین ساعت ۱۰:۰۰ الی ۱۱:۰۰ صبح به وقت ایران انجام شدند (جدول ۱). برنامه پروازی Map Pilot در ارتفاع استاندارد ۶۰ متر با همپوشانی طولی و عرضی ۷۰ درصد بین تصاویر تنظیم شد (نگاره ۲). این ارتفاع و همپوشانی امکان دستیابی به فاصله نمونه زمینی GSD^۴ دو سانتی‌متری را فراهم نمود. مطالعات انجام شده توسط ژو^۵ و همکاران در سال ۲۰۱۸ نشان داد که وضوح مکانی سه سانتی‌متر برای نظارت بر تراکم مواد مغذی در برگ برنج (LNC)^۶ و کاربردهای متغیر مکانی کودهای معدنی مناسب است (Eugenio et al., 2023).

منطقه مورد مطالعه دارای اقلیمی نیمه‌گرمسیری مرطوب (اقلیم نیمه‌حاره‌ای مرطوب) و میانگین بارندگی سالانه ۷۴۰ میلی‌متر هست که براساس سیستم طبقه‌بندی کوپن^۱ و ترورثا^۲ در گروه CFA قرار می‌گیرد (Beck et al., 2018; Habibi, Niknejad, Fallah, Dastan, & Tari, 2019). در فصل کشت برنج دما به ترتیب از ۱۹ تا ۲۵ درجه سانتی‌گراد و میزان بارش ۲۵ تا ۱۲۵ میلی‌متر متغیر است (FAO, 2023).

۲-۲- روش تحقیق

در گام اول این پژوهش، از داده‌های ماهواره‌ای Sentinel-2 برای توسعه یک مدل مناسب بهره‌گرفته شد. همچنین، به منظور انجام عملیات تصویربرداری و اخذ داده در راستای برآورد شاخص گیاهی در محصول برنج، از پهپاد Phantom 4 Pro مجهز به دوربین RGB استفاده شد. این دوربین شامل باندهای طیفی در محدوده‌های قرمز (650±16nm)، سبز (560±16nm) و آبی (450±16nm) است. موقعیت جغرافیایی دقیق داده‌های تصویربرداری با

3- Post-Processing Kinematic

4- Ground Sampling Distance

5- Zhou


6- Leaf Nitrogen Content

1- Koppen

2-Tervartha

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (مژ)
 پایش کلروفیل مزارع برنج با استفاده از تصاویر سنتینل ۲ و پهپاد ... / ۱۳

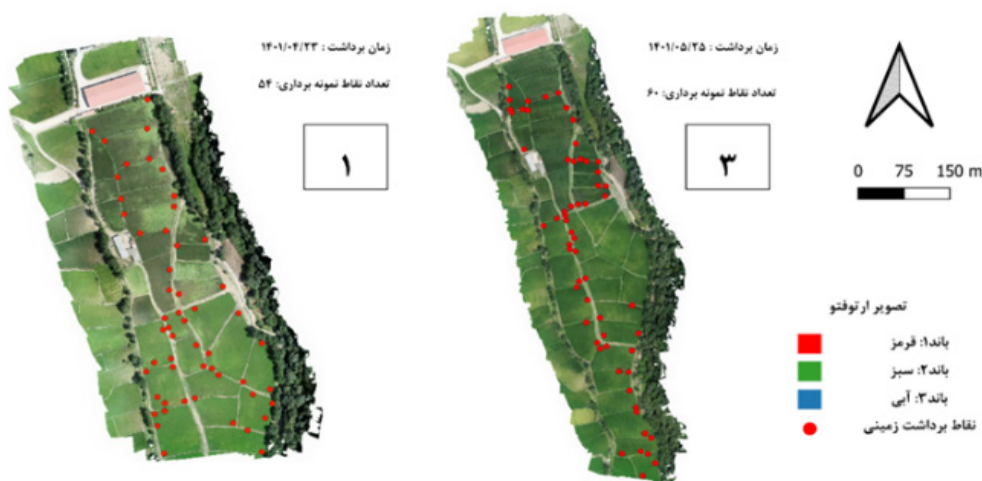
در این مطالعه، داده‌های میدانی مربوط به مزرعه شامل روش‌های اندازه‌گیری، تاریخ‌های کاربرد کودهای معدنی، تقسیم‌بندی مزرعه براساس گونه‌های مختلف برنج و میزان مصرف مواد معدنی به‌صورت فایل اکسل تهیه شد. این داده‌ها ضمن ثبت در یک طرح سری زمانی، دو گونه برنج در قسمت‌های شمالی و جنوبی مزرعه با شرایط کوددهی مشخص را نمایش دادند. در طول فصل‌های رویشی و زایشی، داده‌های آموزشی از دو گونه برنج تحت شرایط مشابه اما با استفاده از مواد معدنی متفاوت جمع‌آوری شده‌اند. دو نوبت اندازه‌گیری‌های میدانی، در طول فصل رشد برنج در غالب روش نمونه‌برداری غیرمخرب و با استفاده از دستگاه کلروفیل‌متر SPAD502 صورت گرفت. این دستگاه به‌عنوان یک ابزار معمول برای اندازه‌گیری غیرمخرب کلروفیل شناخته شده و قرائت‌های آن دارای همبستگی قوی با غلظت کلروفیل برگ است. در این مطالعه، از داده‌های میدانی برای بررسی توزیع و تنوع داده‌ها قبل از هر تجزیه و تحلیل استفاده شده‌است. نقاط نمونه‌برداری اشتباه شناسایی و حذف شده‌اند تا از نتایج گمراه‌کننده جلوگیری شده و تنها داده‌هایی که مرتبط با وضعیت سبزیگی برنج بوده‌اند مورد استفاده قرار گرفته‌اند. منطقه مورد مطالعه شامل ۳۷ قطعه با ابعاد و مساحت‌های



نگاره ۲: طراحی پرواز و مشخصات تصویربرداری در محدوده مطالعه

جدول ۱: برنامه زمانی اخذ تصاویر پهپاد و ماهواره سنتینل در بازه‌های زمانی حساس رشد برنج در فصل رویشی و زایشی

شماره مرحله	مرحله رشد	تاریخ اخذ تصاویر	
		تصویربرداری ماهواره Sentinel-2	تصویربرداری پهپاد
۱	آغاز فصل رویشی	۱۴۰۱/۰۴/۲۲	۱۴۰۱/۰۴/۲۳
۲	مرحله پنجه‌زنی	۱۴۰۱/۰۵/۱۱	۱۴۰۱/۰۵/۱۱
۳	آغاز گلدهی	۱۴۰۱/۰۵/۲۴	۱۴۰۱/۰۵/۲۵
۴	مرحله زایشی	۱۴۰۱/۰۶/۱۰	۱۴۰۱/۰۶/۰۹
۵	قبل از برداشت	۱۴۰۱/۰۶/۲۳	۱۴۰۱/۰۶/۲۴



نگاره ۳: پراکنش و تراکم نقاط نمونه‌برداری قرائت‌شده با استفاده از دستگاه SPAD-502 در هر دوره رشد

در تجزیه و تحلیل‌ها مورد استفاده قرار گرفتند (جدول ۲). بررسی‌ها نشان داد از شاخص‌های گیاهی حاصل از پهپاد نمی‌توان به‌طور عمومی استفاده کرد (Yuan, Wang, Shi, & Wang, 2022). شاخص تفاوت نرمال شده گیاهی یا NDVI در اوایل دهه هفتاد توسط روسی^۱ و همکارانش معرفی شد و محبوبیت زیادی یافت. این محبوبیت به دلیل توانایی NDVI در تمایز پوشش گیاهی از سایر مواد در تصاویر ماهواره‌ای چندطیفی است.

پوشش گیاهی سبز با انعکاس زیاد در حوزه مادون قرمز نزدیک (معمولاً ۵۰ تا ۸۰ درصد) و بازتاب بسیار کم در طول موج‌های قرمز به دلیل جذب کلروفیل مشخص می‌شود. NDVI به صورت رابطه (۱) تعریف می‌شود.

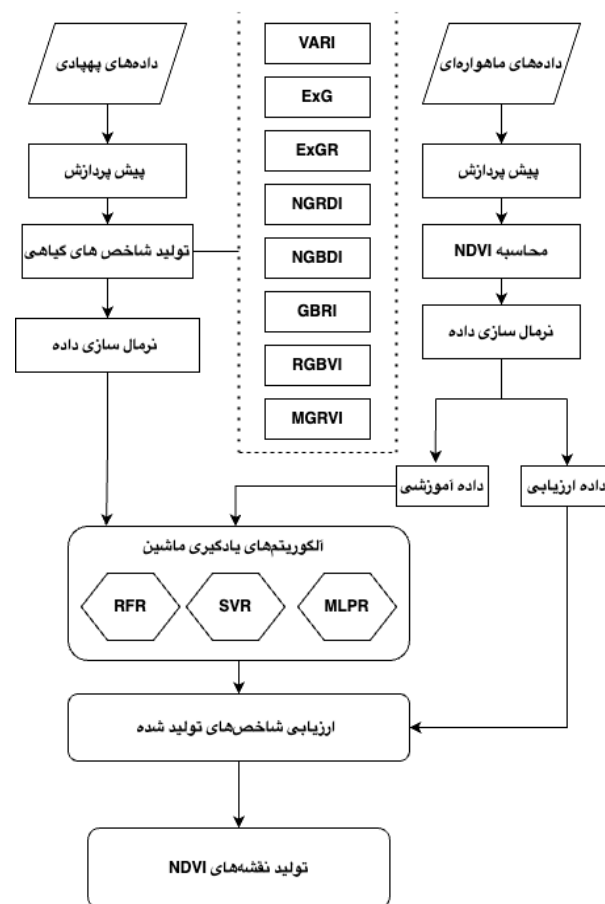
$$NDVI = \frac{NIR - Red}{NIR + Red} \quad \text{رابطه (۱)}$$

مقدار NDVI در محدوده [۱،-۱] است و هر چه این مقدار بیشتر باشد، احتمال مطابقت آن با پوشش گیاهی سبز بیشتر است (Rabatel, Gorretta, & Labbé). سپس این شاخص‌های گیاهی نرمال شده و بخشی از داده‌های Sentinel-2 برای آموزش مدل‌های یادگیری ماشین استفاده شد. در این تحقیق، از رویکرد ریز مقیاس‌سازی خطی استفاده شده است. ابتدا مقادیر ورودی شامل باندهای پهپادی و شاخص‌های تولیدی از این باندها، مطابق جدول (۲) تعیین شدند.

با استفاده از میانگین‌گیری، قدرت تفکیک این ویژگی‌ها به ۱۰ متر کاهش یافت. به این ترتیب در این بررسی مدلی برای پیش‌بینی مقادیر شاخص NDVI از تصاویر مرئی پهپاد با استفاده از داده‌های Sentinel-2 ارائه شده است. سپس، مطابق روابط (۲ و ۳) این مقادیر به عنوان ورودی الگوریتم‌های یادگیری ماشین استفاده شد.

$$NDVI_{10m} = f(Red_{10m}, Green_{10m}, Blue_{10m}, \dots) \quad \text{رابطه (۲)}$$

متفاوت بوده است. ۲۱ قطعه با مساحت پنج هکتار به گونه طارم و ۱۶ قطعه دیگر با مساحت ۶/۲ هکتار به گونه ندا اختصاص یافت. نقاط نمونه‌برداری به‌طور تصادفی انتخاب شدند و عملیات تصویربرداری همزمان با بررسی‌های میدانی در تصویربرداری اول و سوم انجام گرفت (نگاره ۳). فرایند کلی ارزیابی میزان سبزی‌نگی در مزارع برنج با استفاده از تصاویر پهپادی و ماهواره‌ای در نگاره ۴ نمایش داده شده است.



نگاره ۴: فرایند ارزیابی سبزی‌نگی در مزارع برنج با استفاده از تصاویر پهپاد و ماهواره‌ای

بعد از پیش‌پردازش داده‌های پهپاد و ماهواره‌ای، با استفاده از اطلاعات باندهای مرئی تصاویر پهپاد، شاخص‌های گیاهی (VIs) استخراج شدند. با بررسی تحقیقات پیشین چندین شاخص گیاهی که از باندهای RGB محاسبه شده بودند،

جدول ۲: شاخص‌های محاسبه میزان سبزی‌نگی با استفاده از داده‌های پهپاد RGB

منبع	فرمول	مخفف	شاخص
(Gitelson, Kaufman, Stark, & Rundquist, 2002)	$\frac{(G-R)}{(G+R-B)}$	VARI	visible atmospheric resistant index
(Woebbecke, Meyer, Von Bargaen, & Mortensen, 1995)	$2 \times G - R - B$	ExG	Excess green
(Meyer & Neto, 2008)	$ExG - (1.4 \times R - G)$	ExGR	Excess green minus excess red
(Woebbecke, Meyer, Von Bargaen, & Mortensen)	$\frac{(G-R)}{(G+R)}$	NGRDI	Normalized green-red difference index
(Woebbecke et al)	$\frac{(G-B)}{(G+B)}$	NGBDI	Normalized blue-red difference index
(Gamon & Surfus, 1999)	$\frac{R}{G}$	RGRI	Red green ratio index
(Sellaro et al., 2010)	$\frac{B}{G}$	GBRI	Green blue ratio index
(Possoch et al., 2016)	$\frac{(G^2 - B \times R^2)}{(G^2 + B \times R^2)}$	RGBVI	Red green blue vegetation indices
(Bendig et al., 2015)	$\frac{(G^2 - R^2)}{(G^2 + R^2)}$	MGRVI	Modified green red vegetation indices

و ویژگی‌های استخراج شده از این تصاویر، طبق جدول (۳)، برای برآورد NDVI پهپادی با قدرت تفکیک یک متری به الگوریتم‌های یادگیری ماشین ارائه شد. به منظور ارزیابی مدل‌های یادگیری ماشین، ۷۰ درصد از داده‌ها برای آموزش مدل و ۳۰ درصد برای اعتبارسنجی و ارزیابی مدل‌ها مورد استفاده قرار گرفته‌اند. هاپرپارامترهای مدل‌های یادگیری ماشین با استفاده از تکنیک جستجوی شبکه‌ای تنظیم شدند. به منظور ارزیابی تصاویر پیش‌بینی شده شاخص NDVI،

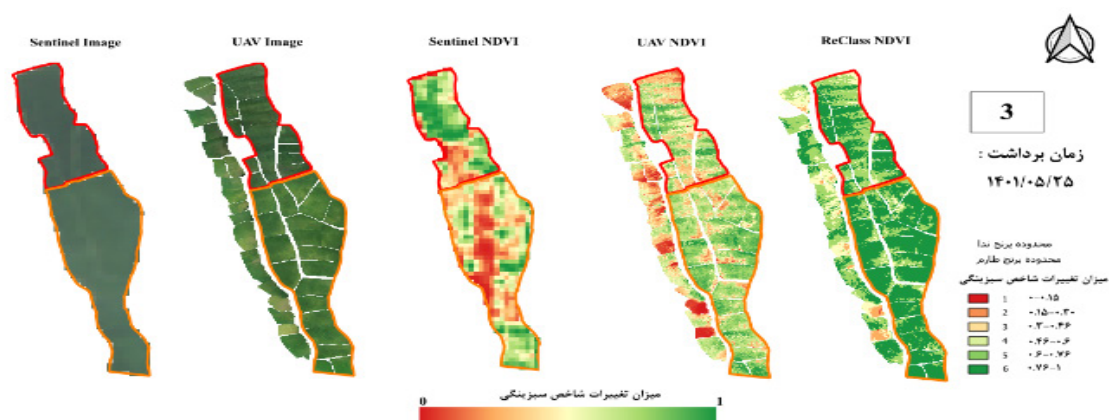
$$NDVI_{1m} = f(Red_{1m}, Green_{1m}, Blue_{1m}, \dots \dots \dots)$$

رابطه (۳)

در این پژوهش، از سه مدل یادگیری ماشین شامل: الگوریتم رگرسیون ماشین بردار پشتیبان (SVR)، جنگل تصادفی (RFR) و پرسپترون چندلایه (MLPR) برای پیش‌بینی مقادیر NDVI از داده‌های پهپادی (مقادیر باندها و شاخص‌های گیاهی) استفاده شده است. پس از آموزش مدل و تعیین پارامترهای شبکه (وزن‌های شبکه) تصاویر پهپادی

جدول ۳: پارامترها و مقادیر مورد آزمایش با استفاده از تکنیک جستجوی شبکه‌ای

منبع	مقادیر مورد آزمایش	پارامتر	الگوریتم
(Sandunil, Bennour, Ben Mahmud, & Giwelli)	[200, 100, 50, 10]	n_estimator	جنگل تصادفی (RFR)
	[None, 10, 50, 100]	max_depth	
	[4, 2, 1]	Min_sample_leaf	
	[10, 5, 2]	Min_Sample_split	
(Penalun, Hermawan, & Avianto, 2023)	'linear', 'poly', 'rbf', 'sigmoid'	Kernel	ماشین بردار پشتیبان (SVR)
	'scale', 'auto'	Gamma	
	[1, 1, 10, 0]	C	
(Elansari, Ouanan, & Bourray, 2023)	[(100,100),(50,50),(,100), (,50)]	hidden_layer_sizes	پرسپترون چند لایه (MLR)
	'tanh', 'relu'	activation	
	sgd', 'adam''	solver	
	200,500,1000	Max_iter	



نگاره ۵: ریز مقیاس سازی تصویر ماهواره Sentinel-2 و بهبود وضوح مکانی آن به کمک تصاویر پهپاد

ارتباط و همبستگی آن‌ها با شاخص‌های NDVI حاصل از داده‌های Sentinel-2 بررسی و بهترین مدل برای تولید نقشه NDVI از داده‌های پهپادی انتخاب شد. بررسی اهمیت ویژگی‌های ورودی به مدل‌ها، با استفاده از تکنیک پرموتاسیون^۱ یا جایگشت انجام شد. در این فرآیند، کاهش در میزان پارامتر ارزیابی (مانند دقت کلی، R^2 ، RMSE و ...) مدل، زمانی که یک مقدار ویژگی منفرد به‌طور تصادفی مخلوط شد، محاسبه شد (Breiman, 2001) کاهش در مقدار پارامتر ارزیابی مدل نشان‌دهنده میزان وابستگی مدل به هر یک از ویژگی‌ها است (Pedregosa et al., 2011) برای اجرای این تکنیک از بسته نرم‌افزاری Scikit-Learn و در محیط برنامه‌نویسی پایتون استفاده شده است.

سپس در مرحله پس‌انتشار خطا، خطای پیش‌بینی شده محاسبه می‌شود و با استفاده از گرادینان نزولی، وزن‌ها برای بهبود دقت مدل اصلاح می‌شوند (Gardner & Dorling, 1998). توابع فعال‌ساز مانند سیگموئید، تانژانت هیپربولیک و ReLU به نورون‌ها کمک می‌کنند تا داده‌های غیرخطی را مدل کنند. رگرسیون پرسپترون چندلایه به دلیل توانایی‌اش در تقریب توابع غیرخطی و تعمیم‌پذیری بالا، در پیش‌بینی و مسائل رگرسیونی کاربرد گسترده‌ای دارد و تنظیم دقیق هایپرپارامترهای آن (تعداد لایه‌ها و نورون‌ها) می‌تواند عملکرد مدل را بهبود دهد (Verma & Kumar, 2020).

۲-۲-۲- رگرسیون ماشین بردار پشتیبان (SVR)

رگرسیون ماشین بردار پشتیبان یک الگوریتم پیش‌بینی و رگرسیون است که با هدف یافتن یک ابرصفحه بهینه در فضای ویژگی‌ها کار می‌کند؛ این ابرصفحه رابطه بین متغیرهای ورودی و هدف را به بهترین شکل تقریب می‌زند. بردارهای پشتیبان نقشی کلیدی در تعیین موقعیت و جهت ابرصفحه دارند (Drucker, Burges, Kaufman, Smola, & Vapnik, 1996). با استفاده از توابع هسته‌ای مانند خطی، چندجمله‌ای و شعاعی، رگرسیون ماشین بردار پشتیبان قادر است مرزهای غیرخطی ایجاد کند و داده‌ها را به فضای با ابعاد بالاتر نگاشت کند، به طوری که بتواند روابط پیچیده و غیرخطی را مدل‌سازی نماید (Ouyang et al., 2016). هایپرپارامترهای کلیدی

۲-۲-۱- رگرسیون پرسپترون چندلایه (MLPR)

رگرسیون پرسپترون چندلایه یک شبکه عصبی پیش‌خور است که با استفاده از یادگیری نظارت‌شده و روش پس‌انتشار خطا برای به‌روزرسانی وزن‌ها و بایاس‌ها آموزش می‌بیند. این شبکه از سه بخش اصلی شامل لایه ورودی، لایه‌های پنهان و لایه خروجی تشکیل شده است که هر کدام از نورون‌های آن به‌طور کامل به نورون‌های لایه قبل و بعد متصل هستند. در مرحله پیش‌خور، ورودی‌ها از طریق این لایه‌ها عبور می‌کنند و به خروجی می‌رسند؛

1- Permutation feature importance

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (ص ۱۷)

بایش کلروفیل مزارع برنج با استفاده از تصاویر سنتینل ۲ و پهپاد ... / ۱۷

به حداقل برسد. این الگوریتم توسط یک مهندس فرانسوی، برای اولین بار در ۱۹۵۰ میلادی معرفی شد (Metheron, 1963). کریجینگ در ابتدا برای ارزیابی منابع معدنی توسعه یافت، اما به دلیل دقت و کارایی آن، در بسیاری از زمینه‌های دیگر از جمله کشاورزی هوشمند نیز مورد استفاده قرار گرفته است. این استراتژی یک روش بسیار کارآمد و پرکاربرد در بسیاری از زمینه‌های علمی است، مانند: بازسازی داده‌ها (Eugenio et al., 2023)، تخمین شدت بارندگی (Bilonick, 1991)، مدل‌سازی فضایی دما، تنوع ترکیب خاک (Swan, 1998). الگوریتم کریجینگ براساس تئوری واریوگرام^۲ عمل می‌کند که به بررسی میزان شباهت یا تفاوت مقادیر یک متغیر در فواصل مختلف مکانی می‌پردازد. کریجینگ به دنبال یافتن تابعی است که بر اساس واریوگرام، مقادیر ناشناخته را برآورد کند. چندین روش متفاوت کریجینگ وجود دارد و همه به عنوان انواع کریجینگ ساده توسعه یافته‌اند. از جمله این روش‌ها می‌توان به کریجینگ ساده، کریجینگ معمولی و کریجینگ جهانی اشاره کرد. به طور کلی، الگوریتم کریجینگ به عنوان یک ابزار قدرتمند در زمین‌آمار، توانسته است جایگاه ویژه‌ای در کشاورزی هوشمند پیدا کند.

۳- نتایج تحقیق

در این بررسی از دو رویکرد برای آموزش و ارزیابی مدل‌ها استفاده شده است. در رویکرد اول، مدل‌های یادگیری ماشین برای هر مرحله از رشد گیاه (پنج زمان برداشت تصویر در مراحل مختلف رشد گیاه برنج) به صورت جداگانه آموزش دیده و ارزیابی شدند. این ارزیابی با استفاده از ۳۰ درصد داده‌های باقی مانده انجام شد. این رویکرد به مدل‌ها اجازه می‌دهد تا ویژگی‌های خاص هر مرحله از رشد گیاه را به خوبی یاد بگیرند و پیش‌بینی‌های دقیقی ارائه دهند. اما یکی از محدودیت‌های این رویکرد این است که ممکن است مدل‌ها نتوانند تغییرات میان‌مرحله‌ای را به خوبی یاد بگیرند. در رویکرد دوم، تمامی داده‌های دریافت شده از

شامل پارامتر تنظیم CCC (کنترل بیش‌برازش)، حساسیت خطا (تعیین محدوده خطا)، و نوع کرنل مورد استفاده است. مزیت رگرسیون ماشین بردار پشتیبان در دقت بالا و پیچیدگی محاسباتی کمتر آن است، که آن را برای مسائل پیش‌بینی سری‌های زمانی و داده‌های محدود مناسب می‌کند (Mountrakis, Im, & Ogole, 2011) (Suykens & Vandewalle, 1999).

۲-۲-۳- رگرسیون جنگل تصادفی (RFR)

رگرسیون جنگل تصادفی یک الگوریتم یادگیری مجموعه‌ای برای مسائل رگرسیون است که با ترکیب چندین درخت تصمیم نتایج پیش‌بینی قوی‌تری تولید می‌کند. این الگوریتم از روش بسته‌بندی^۱ استفاده می‌کند و در هر درخت، گره‌ها به طور تصادفی بر اساس بهترین زیرمجموعه پیش‌بینی‌کننده‌ها تقسیم می‌شوند (Ho, 1998). برای پیش‌بینی نهایی، میانگین‌گیری از خروجی‌های درختان به کار می‌رود (در مسائل طبقه‌بندی، از رأی‌گیری استفاده می‌شود). این ساختار به جنگل تصادفی امکان می‌دهد تا در برابر نویز و داده‌های نامعتبر مقاوم باشد و از بیش‌برازش جلوگیری کند. رگرسیون جنگل تصادفی همچنین می‌تواند هزاران ویژگی ورودی را پردازش کرده و اهمیت آن‌ها را تعیین کند. تنظیمات کلیدی شامل تعداد درختان و تعداد ویژگی‌ها برای تقسیم گره‌ها است. به دلیل قابلیت‌های قوی در مدیریت داده‌های پیچیده و حفظ دقت بالا، رگرسیون جنگل تصادفی یکی از ابزارهای قدرتمند در مسائل یادگیری ماشین به‌شمار می‌رود (Breiman, 2001).

۲-۲-۴- الگوریتم درون‌یابی مکانی Kriging


کریجینگ یک روش رگرسیون است که وابستگی تصادفی بین داده‌ها را در نظر می‌گیرد. در این روش، برای تخمین در یک موقعیت مشخص، به مشاهدات نزدیک‌تر وزن بیشتر و به مشاهدات دورتر وزن کمتری داده می‌شود. وزن داده‌ها به گونه‌ای انتخاب می‌شود که واریانس تخمین

جدول ۴: نتایج پارامترهای آماری حاصل از اجرای الگوریتم‌های یادگیری ماشین

	مرحله اول تصویربرداری			مرحله دوم تصویربرداری			مرحله سوم تصویربرداری			مرحله چهارم تصویربرداری			مرحله پنجم تصویربرداری		
	SVR	MLP	RF	SVR	MLP	RF	SVR	MLP	RF	SVR	MLP	RF	SVR	MLP	RF
Number	307			421			404			419			447		
RMSE	0.11	0.12	0.12	0.10	0.11	0.11	0.14	0.14	0.14	0.13	0.14	0.13	0.12	0.13	0.12
MBE	-0.0008	-0.0004	-0.0062	-0.0058	-0.0153	-0.0036	0.0012	-0.0014	0.0021	0.0005	-0.0030	-0.0006	0.0049	0.0129	0.0088
NRMSE	0.14	0.16	0.15	0.11	0.17	0.15	0.09	0.18	0.12	0.16	0.18	0.15	0.19	0.2	0.19
R	0.80	0.76	0.79	0.81	0.75	0.77	0.60	0.58	0.60	0.78	0.75	0.79	0.82	0.8	0.83

مقادیر بیشتری از MLPR داشت (جدول ۴). به‌طور کلی، در مراحل اول و چهارم، عملکرد RFR عملکرد بهتری در مقایسه با SVR و MLPR داشت. با این حال، تغییرات جزئی پارامترهای ارزیابی در این سه مدل یادگیری ماشین نشان‌دهنده عملکرد مشابه آن‌ها در تخمین میزان NDVI با استفاده از تصاویر پهپادی است. عملکرد بهتر دو مدل SVR و RFR نسبت به MLPR می‌تواند به علت مدیریت بهتر این مدل‌ها در مواجهه با نویز موجود در داده‌های مورد استفاده باشد.

مطابق نگاره ۶ در مرحله سوم، مدل‌های SVR و RFR عملکرد مشابه و بهتری نسبت به MLPR دارند. ضریب همبستگی پایین‌تر و خطاهای بالاتر در این مرحله نشان می‌دهد که پیش‌بینی مقادیر NDVI در این مرحله چالش‌برانگیزتر بوده است.



نگاره ۶: نمودار پارامترهای آماری الگوریتم‌های یادگیری ماشین در مراحل رشد گیاه برنج

پنج نوبت رشد گیاه به‌صورت یکجا برای آموزش مدل‌ها استفاده شده است.

برای بررسی قدرت و عملکرد الگوریتم‌های یادگیری ماشین در تخمین مقدار NDVI از تصاویر پهپاد، در این بررسی از سه الگوریتم یادگیری ماشین: رگرسیون جنگل تصادفی (RFR)، رگرسیون ماشین بردار پشتیبان (SVR)، و رگرسیون پرسپترون چندلایه (MLPR) استفاده شده است.

در رویکرد اول و بر اساس نتایج به‌دست‌آمده (نگاره ۶)، در مرحله اول تصویربرداری که در تاریخ ۲۳ تیر ۱۴۰۱ انجام شد، میزان پارامتر NRMSE برای SVR و MLPR تقریباً مشابه بود، در حالی که RFR کمی بالاتر از دو الگوریتم دیگر بود. مقادیر پارامتر R برای هر سه مدل تقریباً یکسان است (جدول ۴). در مرحله دوم تصویربرداری که در تاریخ ۱۱ مرداد ۱۴۰۱ انجام شد، مقدار پارامتر NRMSE برای MLPR به‌طور قابل‌توجهی بیشتر از SVR و RFR بود و مقادیر همبستگی هر سه مدل تقریباً مشابه بودند. با این حال، عملکرد الگوریتم RFR کمی بهتر از دو الگوریتم دیگر در این مرحله بوده است. در مرحله سوم تصویربرداری که در تاریخ ۲۵ مرداد ۱۴۰۱ انجام شد، عملکرد الگوریتم MLPR نسبتاً بهتر از دو الگوریتم دیگر بود و همچنان میزان پارامتر R برای هر سه مدل تقریباً یکسان بود. در مرحله چهارم که در تاریخ ۹ شهریور ۱۴۰۱ تصویربرداری شد، مدل RFR عملکرد بهتری نسبت به دو مدل یادگیری دیگر داشت. در مرحله پنجم، پارامتر NRMSE برای SVR و RFR

(نگاره ۷) نتایج پیش‌بینی مدل‌های مختلف یادگیری ماشین برای پیش‌بینی NDVI پهپادی از NDVI ماهواره‌ای نمایش داده شده است.

در مدل رگرسیون پرسپترون چند لایه، ضریب همبستگی (R) برابر با ۰/۷۲ است که همبستگی مناسبی بین مقادیر NDVI پهپادی و NDVI ماهواره‌ای را نشان می‌دهد (نگاره ۷، الف). ریشه مربعات خطا (RMSE) و خطای میانگین مطلق نیز نشان‌دهنده دقت نسبتاً خوب این مدل است. در مدل رگرسیون ماشین بردار پشتیبان، ضریب همبستگی (R) برابر با ۰/۷۶ است که همبستگی بهتر این مدل در مقایسه با مدل رگرسیون پرسپترون چند لایه را نشان می‌دهد (نگاره ۷، ب). همچنین، RMSE کمتر و خطای میانگین مطلق، کمتر نشان‌دهنده دقت بالاتر این مدل نسبت به مدل رگرسیون پرسپترون چند لایه است. در مدل رگرسیون جنگل تصادفی، ضریب همبستگی (R) برابر با ۰/۸۰ است که قوی‌ترین همبستگی بین NDVI پهپادی و NDVI ماهواره‌ای را نشان می‌دهد (نگاره ۷، ج). همچنین، RMSE کمتر و خطای میانگین مطلق تقریباً صفر در این مدل مؤید دقت بالای مدل رگرسیون جنگل تصادفی نسبت به دو مدل دیگر است. بنابراین، می‌توان نتیجه گرفت که در مجموع مدل رگرسیون جنگل تصادفی بهترین عملکرد را در پیش‌بینی NDVI پهپادی از NDVI ماهواره‌ای داشته و در مقابل مدل رگرسیون پرسپترون چند لایه کمترین دقت را در بین سه مدل نشان داد. به‌طورکلی، رگرسیون جنگل تصادفی به دلیل قابلیت‌های خود در مدیریت پیچیدگی‌های داده، کاهش خطر بیش‌برازش، مدیریت نویز و ویژگی‌های بی‌اهمیت و همچنین انعطاف‌پذیری بالا، عملکرد بهتری در پیش‌بینی مقادیر NDVI پهپادی از مقادیر NDVI ماهواره‌ای داشته است. این ویژگی‌ها باعث می‌شوند تا رگرسیون جنگل تصادفی انتخاب مناسبی برای مدل‌سازی داده‌های پیچیده و غیرخطی باشد.

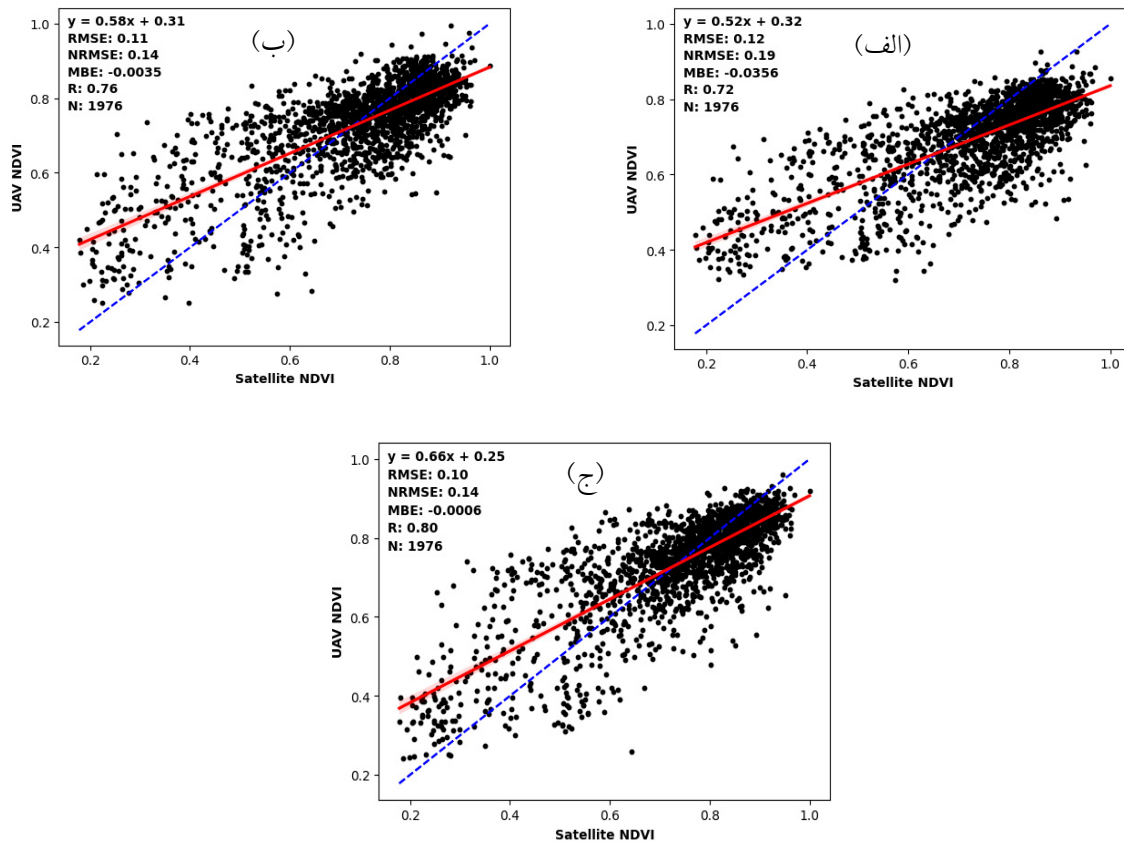
در این بررسی علاوه بر باندهای RGB تصاویر پهپادی از شاخص‌های مختلفی که از ترکیب این باندها استفاده

مرحله سوم مربوط به یک دوره انتقالی یا بحرانی در رشد گیاه برنج است که در آن تغییرات فیزیولوژیکی خاصی رخ می‌دهد. با توجه به اینکه مرحله سوم پس از دومین مرحله کوددهی (۳۰ تیر) قرار دارد، ممکن است تأثیر کوددهی در این مرحله به‌طور متفاوتی بر روی گیاه برنج اثر بگذارد. مدل‌های یادگیری ماشین ممکن است در این مرحله خاص به‌خوبی تنظیم نشده و نیاز به بهینه‌سازی بیشتری داشته باشند. به همین منظور، برای تخمین بهتر NDVI، این مرحله به داده‌های آموزشی بیشتری نیازمند است. در مرحله چهارم، عملکرد هر سه مدل بهبود یافته است، اما SVR و RFR بهترین عملکرد را داشته‌اند. همبستگی بالاتر و خطاهای کمتر نشان‌دهنده این است که مدل‌ها در این مرحله توانسته‌اند مقادیر NDVI را بهتر پیش‌بینی کنند. به‌طورکلی، این تحلیل نشان می‌دهد که در مراحل مختلف رشد گیاه، مدل‌های SVR و RFR عملکرد بهتری ارائه داده‌اند و مقادیر NDVI را با دقت بیشتری پیش‌بینی کرده‌اند.

با توجه به تحلیل‌های انجام‌شده، می‌توان نتیجه گرفت که مدل‌های SVR و RFR به‌طورکلی در پیش‌بینی مقادیر NDVI عملکرد بهتری دارند و می‌توانند به‌عنوان مدل‌های برتر در این مقاله در نظر گرفته شوند. MLPR نیز عملکرد مناسبی دارد، اما به داده‌های آموزشی بیشتری نیازمند است تا بتواند با سایر مدل‌ها رقابت کند.

در رویکرد دوم تمامی داده‌های دریافت‌شده از پنج نوبت تصویربرداری با هم ادغام شده و پس از حذف داده‌های نامعتبر، از تست سه سیگما برای شناسایی و حذف داده‌های اشتباه استفاده شد. این فرآیند پیش‌پردازش به بهبود کیفیت داده‌ها کمک کرده و داده‌های پاک‌سازی‌شده برای ارزیابی مدل‌های یادگیری ماشین مورد استفاده قرار گرفتند. سه مدل مختلف شامل رگرسیون ماشین بردار پشتیبان، رگرسیون جنگل تصادفی و پرسپترون چند لایه مورد بررسی قرار گرفته‌اند.

برای هر مدل، معیارهای آماری مختلفی مانند خطای ریشه مربع (RMSE)، خطای میانگین مطلق (MAE)، ضریب همبستگی (R) و تعداد نمونه‌ها (N) گزارش شده است. در

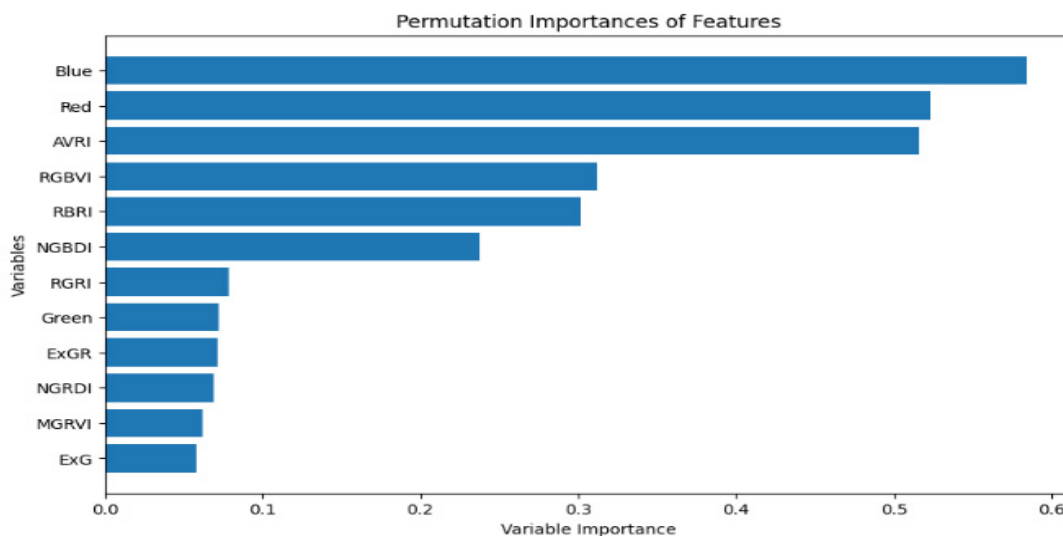


نگاره ۷: ارزیابی و مقایسه مدل‌های مختلف یادگیری ماشین برای پیش‌بینی NDVI پهپادی از NDVI ماهواره‌ای رگرسیون پرسپترون چند لایه یا MLPR (الف)، رگرسیون ماشین بردار پشتیبان یا SVR (ب) و رگرسیون جنگل تصادفی یا RFR (ج)

می‌شود برای پیش‌بینی NDVI پهپادی با استفاده از NDVI ماهواره‌ای استفاده شده است. در این بررسی از تکنیک Permutation Importance برای رتبه‌بندی ویژگی‌های ورودی به مدل‌های یادگیری ماشین استفاده شد. با توجه به نتایج بهتر الگوریتم رگرسیون جنگل تصادفی از این مدل برای این تکنیک استفاده شده است. در ادامه به بررسی نتایج این تکنیک پرداخته شد.

نگاره (۸) نشان می‌دهد که باند آبی بیشترین اهمیت را در مدل رگرسیون جنگل تصادفی دارد. این باند معمولاً نشان‌دهنده میزان بازتاب نور آبی از سطح گیاه است که می‌تواند به تشخیص وضعیت سلامت گیاه کمک کند. باند قرمز دومین شاخص مهم در این روش و مدل رگرسیون جنگل تصادفی است. این باند به ویژه در بررسی فرآیند

فتوسنتز گیاه اهمیت دارد و کاهش یا افزایش آن می‌تواند نشان‌دهنده تغییرات در سلامت گیاه باشد. علاوه بر این باند قرمز یکی از باندهایی است که در شاخص NDVI (رابطه ۱) استفاده می‌شود و از اهمیت بالایی برخوردار است. شاخص‌های ترکیبی مانند VARI، RGBVI و RBRI نیز اهمیت بالایی دارند و نشان‌دهنده تأثیر قابل توجه آن‌ها در ارزیابی وضعیت سلامت و رشد گیاهان است. این شاخص‌ها با ترکیب اطلاعات باندهای مختلف (جدول ۲) به بهبود دقت پیش‌بینی‌ها کمک می‌کنند. استفاده از این شاخص‌ها در مدل‌های یادگیری ماشین می‌تواند به بهبود مدیریت مزارع و تصمیم‌گیری‌های بهتر در زمینه کوددهی و مدیریت منابع منجر شود. پس از آموزش مدل‌های یادگیری ماشین عملیات پیش‌بینی برای کل منطقه مورد مطالعه انجام

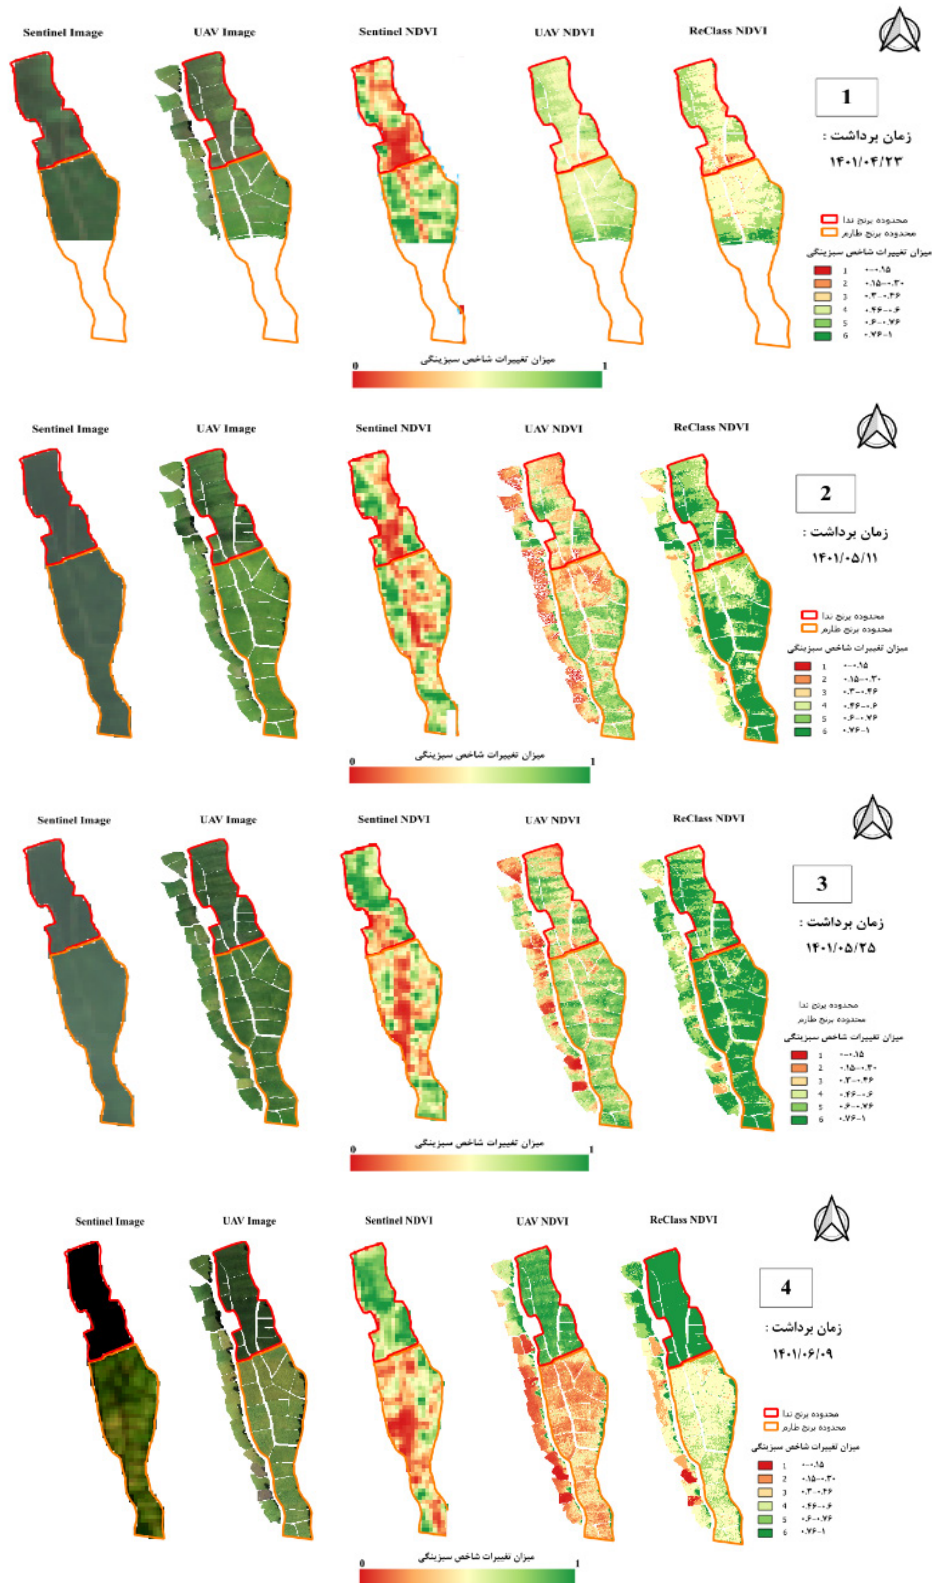


نگاره ۸: اهمیت هر ویژگی با استفاده از روش انتخاب جایگشتی و بر اساس پارامتر R در مدل RFR

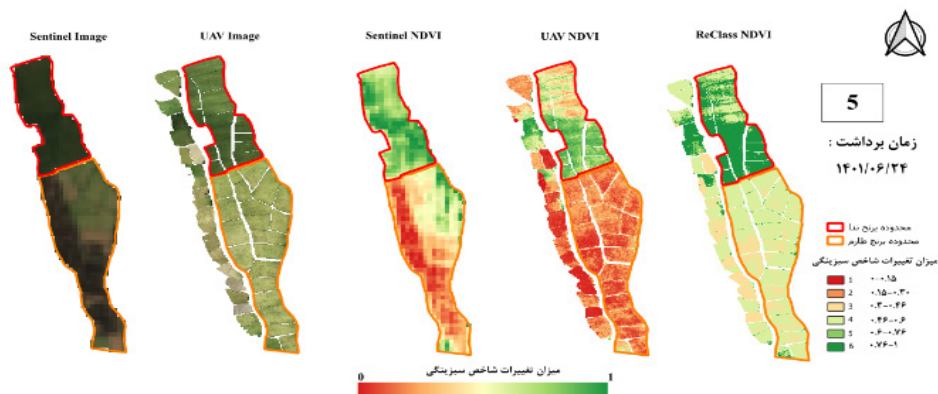
۷ تا ۱۰ روز بعد از استفاده مشاهده شود البته شرایط آب و هوایی در مدت زمان اثر کوددهی تأثیرگذار است (Cui *et al.*, 2024). تاریخ ۲۵ مرداد (مرحله سوم تصویربرداری) از زمان‌هایی است که می‌توان اثرات کوددهی را در زمین کشاورزی مورد تجزیه و تحلیل قرار داد. در این دو تاریخ، تصاویر پهپادی و NDVI پیش‌بینی شده توسط مدل به خوبی بهبود نسبی سبزی‌نگی در منطقه مورد مطالعه را نشان می‌دهند اما در قسمت‌هایی از زمین کشاورزی (جنوب محدوده برنج ندا و شمال محدوده طارم) هنوز مقادیر NDVI پایین مشاهده می‌شود. این مناطق در ابتدا هم از نظر سبزی‌نگی مقادیر پایین‌تری نسبت به سایر مناطق داشته‌اند. این موضوع نشان می‌دهد که شرایط اولیه زمین کشاورزی اهمیت بسیار زیادی در افزایش میزان رشد گیاه برنج دارد. در تاریخ ۹ و ۲۴ شهریور (مرحله چهارم و پنجم تصویربرداری) گیاه برنج در فاز زایشی قرار دارد. این مرحله از رشد گیاه برنج مربوط به خوشه‌دهی گیاه برنج است و مقادیر NDVI در این مرحله کاهش می‌یابد، زیرا گیاه انرژی خود را به تولید خوشه‌های برنج اختصاص می‌دهد.

شد. با توجه به عملکرد بهتر الگوریتم رگرسیون جنگل تصادفی از این مدل برای پیش‌بینی NDVI حاصل از تصاویر پهپادی استفاده شد. مطابق نگاره ۷-۶ تصاویر NDVI پهپادی با NDVI حاصل از ماهواره Sentinel-2 همخوانی مکانی مناسبی دارند و جزئیات در تصاویر NDVI پهپادی بهبود چشم‌گیری یافته است. در تاریخ ۲۳ تیر (مرحله اول تصویربرداری) که اولین تصویر پهپادی از منطقه مورد مطالعه بوده است به وضوح اختلاف NDVI در منطقه مورد مطالعه مشاهده می‌شود. کمترین مقدار NDVI مربوط به بخش جنوبی محدوده برنج ندا است. مقادیر پایین NDVI در این ناحیه و در این تاریخ می‌تواند ناشی از ضعف گیاه برنج یا وضعیت بد زمینی از لحاظ شخم زدن و مهیا نبودن بستر برای کشت برنج و همین‌طور لزوم کوددهی دوباره (با توجه به کوددهی در تاریخ ۳۰ خرداد) یا سایر کودهای معدنی برای این مناطق باشد.

مقادیر پایین NDVI در این منطقه در تاریخ ۱۱ مرداد (مرحله دوم تصویربرداری) هم مشاهده می‌شود. تصویربرداری در تاریخ ۱۱ مرداد (مرحله دوم تصویربرداری) پس از ۱۲ روز از آخرین کوددهی انجام شد. با توجه به تحقیقات گذشته، اثرات کوددهی ممکن است در عرض



نگاره ۹: مقایسه تصاویر نتایج نقشه‌های تولیدی در الگوریتم جنگل تصادفی و تصاویر پهپادی و ماهواره‌ای



ادامه نگاره ۹: مقایسه تصاویر نتایج نقشه‌های تولیدی در الگوریتم جنگل تصادفی و تصاویر پهپادی و ماهواره‌ای

(R) به $0/75$ افزایش یافت، در حالی که میانگین خطای بایاس (MBE) به $0/18$ رسید. خطای ریشه‌ای نرمال‌شده (NRMSE) به $0/17$ کاهش یافته و خطای ریشه‌ای میانگین (RMSE) به $1/24$ رسید. این نتایج نشان‌دهنده بهبود قابل توجهی در دقت مدل در مرحله سوم نسبت به مرحله اول هستند، که اهمیت انتخاب و ارزیابی دقیق مدل‌های زمین‌آمار را در تجزیه و تحلیل داده‌ها تأکید می‌کند. نقشه SPAD تولیدشده در تاریخ ۲۳ تیر، در این نقشه‌ها نشان می‌دهند که بخش جنوبی دارای مقادیر NDVI بالاتر و سلامت بهتر گیاهان است. مقادیر SPAD در این منطقه بین 35 تا 40 بوده که نشان‌دهنده سطح بالای کلروفیل است. در مقابل، شمال شرق نقشه مقادیر SPAD پایین‌تری (بین 29 تا 32) را نشان می‌دهد که به معنای کلروفیل کمتر و کمبود کود معدنی در آنجا است. همبستگی مثبت بین مقادیر بالای NDVI و SPAD در جنوب و مقادیر پایین‌تر در شمال شرق مشاهده می‌شود. نقشه SPAD تولیدشده در تاریخ ۲۵ مرداد، در این تاریخ، میانگین مقادیر NDVI در گونه طارم بالا بوده که نشان‌دهنده سلامت بهتر گیاهان است. همچنین، مناطق شمال شرق و جنوب غربی در گونه ندا دارای مقادیر NDVI کمتری هستند و وضعیت ضعیف‌تری دارند. مقادیر SPAD در گونه طارم بین 36 تا 43 است که همبستگی خوبی با NDVI دارد. در مقابل، مناطق با مقادیر پایین‌تر SPAD (بین 36 تا 38) به معنای کمبود کود هستند.

۳-۱- تحلیل و ارزیابی نقشه‌های SPAD با استفاده از الگوریتم Kriging

در این بخش، به تحلیل و ارزیابی نقشه‌های تولیدی از داده‌های SPAD (میزان کلروفیل برگ‌های گیاه) با استفاده از تکنیک زمین‌آماري Kriging پرداخته شده است. هدف اصلی این تحلیل، بررسی الگوهای مکانی و توزیع میزان کود معدنی موجود در گیاه برنج در منطقه مورد مطالعه است. به دلیل محدودیت در تعداد داده‌های زمینی SPAD و عدم امکان برداشت بیشتر این داده‌ها به علت عدم اجازه کشاورز برای ورود به بخش‌های مرکزی زمین کشاورزی، روش‌های درون‌یابی مکانی برای تولید نقشه‌های SPAD مورد استفاده قرار گرفته‌اند.

در مرحله اول تصویربرداری، با استفاده از روش کریجینگ معمولی^۱ و مدل نمایی^۲، و در نظر گرفتن حداکثر فاصله 220 و $29/25$ Lag (h)، مقادیر دقت مختلفی به دست آمد. ضریب همبستگی (R) برابر با $0/70$ بود که نشان‌دهنده همبستگی نسبتاً خوب با داده‌ها است. همچنین، خطای میانگین بایاس، معادل منفی $0/03$ ، خطای ریشه‌ای نرمال‌شده (NRMSE) برابر با $0/9$ و خطای ریشه‌ای میانگین (RMSE) برابر با $2/81$ محاسبه شد. در مرحله سوم تصویربرداری، با همان روش و مدل، و با حفظ حداکثر فاصله 220 و $27/41$ Lag (h)، مقادیر دقت بهبودیافته‌ای به دست آمد. ضریب همبستگی

1- Ordinary Kriging

2- Exponential

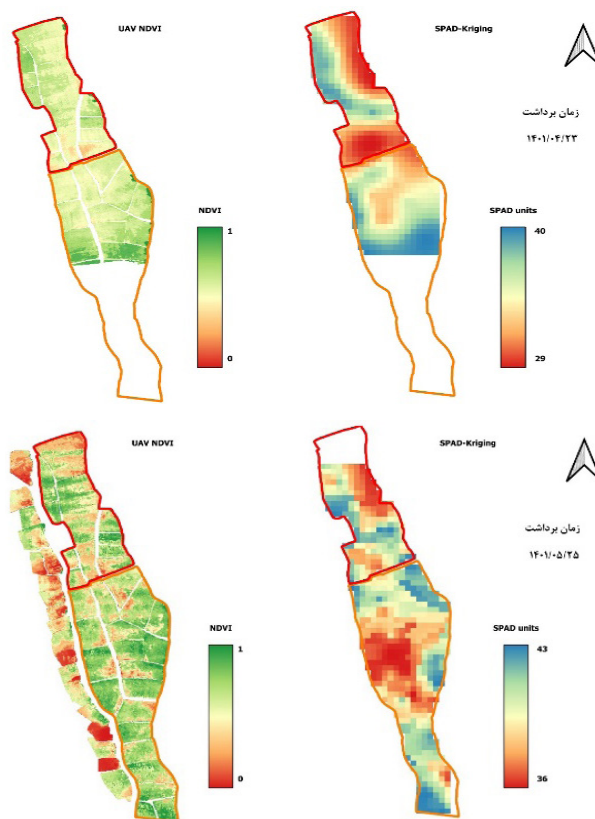
تصادفی داشته است.

علاوه بر این، باند قرمز و شاخص‌های ترکیبی مانند AVRI، RGBVI و RBRI نیز به ترتیب اهمیت بالایی در برآورد NDVI در این تحقیق دارند. تفسیر نقشه‌های NDVI تولید شده با استفاده از مدل رگرسیون جنگل تصادفی نشان داد که شرایط اولیه زمین کشاورزی در رشد گیاه برنج اهمیت بسیاری دارد و آسیب به گیاه برنج از مراحل اولیه کاشت تا برداشت، بر میزان سبزینگی آن تأثیر می‌گذارد. همچنین، تغییرات NDVI در مرحله آخر فاز رویشی و اول زایشی بسیار زیاد و تأثیر میزان کوددهی در این مرحله قابل مشاهده و بررسی است.

روش‌های ارائه شده در این تحقیق، بر اساس نوع و ساختار مزارع برنج در استان مازندران و برنج طارم و ندا بوده و طوری طراحی شده‌اند که بیشترین دقت را در شناسایی میزان مواد معدنی در این مزارع داشته باشند. یکی از مهم‌ترین اهداف این تحقیق بررسی پتانسیل استفاده از تصاویر پهپاد در شناسایی میزان و تأثیرگذاری مواد معدنی در مقیاس بزرگ است. این تحقیق می‌تواند مبنای تحقیقات گسترده‌ای در آینده بر پایه تصاویر پهپاد باشد. الگوریتم پیشنهادی در این تحقیق توانست با دقت قابل قبولی میزان مواد معدنی را در مزارع برنج شناسایی کند. اما روش پیشنهادی مانند هر روش دیگری چالش‌هایی دارد که قابل بهبود است.

تعارض منافع

در این پژوهش، حامی مالی و تعارض منافع وجود ندارد.



نگاره ۱۰: مقایسه تصاویر نتایج نقشه‌های تولیدی در الگوریتم جنگل تصادفی و تصاویر پهپادی

۴- نتیجه‌گیری

مقادیر NDVI در کل مراحل رشد گیاه تخمین زده شد. در این رویکرد، الگوریتم رگرسیون جنگل تصادفی با میزان همبستگی (R) ۰/۸ و مقدار RMSE ۰/۱ بهترین عملکرد را در بین سه الگوریتم یادگیری ماشین در این تحقیق نشان داد. به‌طورکلی، رگرسیون جنگل تصادفی به دلیل قابلیت‌های خود در مدیریت پیچیدگی‌های داده، کاهش خطر بیش‌برازش، مدیریت نویز و انعطاف‌پذیری بالا، عملکرد بهتری در پیش‌بینی مقادیر NDVI پهپادی از مقادیر NDVI ماهواره‌ای داشته است. در این تحقیق از روش Permutation Importance برای بررسی ویژگی‌های ورودی در فرایند برآورد NDVI استفاده شد. طبق نتایج، باند آبی بیشترین اهمیت را در مدل رگرسیون جنگل

<https://www.fao.org/3/w8595t/w8595t05.htm>

12- Gamon, J. A., & Surfus, J. S. (1999). Assessing leaf pigment content and activity with a reflectometer. *The New Phytologist*, 143(1), 105-117.

13- Gardner, M. W., & Dorling, S. R. (1998). Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric environment*, 32(14-15), 2627-2636.

14- Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002). Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, 80(1), 76-87. doi:[https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9)

15- Habibi, E., Niknejad, Y., Fallah, H., Dastan, S., & Tari, D. B. (2019). Life cycle assessment of rice production systems in different paddy field size levels in north of Iran. *Environmental Monitoring and Assessment*, 191(4), 202. doi:10.1007/s10661-019-7344-0

16- Harwin, S., & Lucieer, A. (2012). Assessing the accuracy of georeferenced point clouds produced via multi-view stereopsis from unmanned aerial vehicle (UAV) imagery. *Remote Sensing*, 4(6), 1573-1599.

17- Hawkesford, M. J. (2014). Reducing the reliance on nitrogen fertilizer for wheat production. *Journal of cereal science*, 59(3), 276-283.

18- Ho, T. K. (1998). The random subspace method for constructing decision forests. *IEEE transactions on pattern analysis and machine intelligence*, 20(8), 832-844.

19- Janssen, B. H. (1998). Efficient use of nutrients: an art of balancing. *Field Crops Research*, 56(1-2), 197-201.

20- Ju, X. T., Kou, C. L., Zhang, F. S., & Christie, P. (2006). Nitrogen balance and groundwater nitrate contamination: comparison among three intensive cropping systems on the North China Plain. *Environmental pollution*, 143(1), 117-125.

21- Li, Z., Jin, X., Yang, G., Drummond, J., Yang, H., Clark, B., . . . Zhao, C. (2018). Remote sensing of leaf and canopy nitrogen status in winter wheat (*Triticum aestivum* L.) based on N-PROSAIL model. *Remote Sensing*, 10(9), 1463.

22- Luo, S., Jiang, X., Yang, K., Li, Y., & Fang, S. (2022).

References

1- Ata-Ul-Karim, S. T., Liu, X., Lu, Z., Zheng, H., Cao, W., & Zhu, Y. (2017). Estimation of nitrogen fertilizer requirement for rice crop using critical nitrogen dilution curve. *Field Crops Research*, 201, 32-40.

2- Beck, H. E., Zimmermann, N. E., McVicar, T. R., Vergopolan, N., Berg, A., & Wood, E. F. (2018). Present and future Köppen-Geiger climate classification maps at 1-km resolution. *Scientific Data*, 5(1), 180214. doi:10.1038/sdata.2018.214

3- Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., . . . Bareth, G. (2015). Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, 39, 79-87.

4- Bilonick, R. A. (1991). An introduction to applied geostatistics. In: Taylor & Francis.

5- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.

6- Cui, P., Sheng, X., Chen, Z., Ning, Q., Zhang, H., Lu, H., & Zhang, H. (2024). Optimizing One-Time Nitrogen Fertilization for Rice Production Using Controlled-Release Urea and Urease Inhibitors. *Agronomy*, 14(1). doi:10.3390/agronomy14010067

7- Darzi-Naftchali, A. (2016). Rice Cultivation Management in Mazandaran Province under. *Water Research in Agriculture*, 14.

8- Drucker, H., Burges, C. J., Kaufman, L., Smola, A., & Vapnik, V. (1996). Support vector regression machines. *Advances in neural information processing systems*, 9.

9- Elansari, T., Ouanan, M., & Bourray, H. (2023). Modeling of Multilayer Perceptron Neural Network Hyperparameter Optimization and Training.

10- Eugenio, F. C., Grohs, M., Schuh, M., Venancio, L. P., Schons, C., Badin, T. L., . . . Fantinel, R. A. (2023). Estimated flooded rice grain yield and nitrogen content in leaves based on RPAS images and machine learning. *Field Crops Research*, 292, 108823. doi:<https://doi.org/10.1016/j.fcr.2023.108823>

11- FAO. (2023). RICE SCENARIO. Retrieved from

- MODIS imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 105, 220-233.
- 32- Rabatel, G., Gorretta, N., & Labbé, S. (2011). Getting NDVI spectral bands from a single standard RGB digital camera: a methodological approach.
- 33- Sandunil, K., Bennour, Z., Ben Mahmud, H., & Giwelli, A. (2023). Effects of Tuning Hyperparameters in Random Forest Regression on Reservoir's Porosity Prediction. Case Study: Volve Oil Field, North Sea.
- 34- Sellaro, R., Crepy, M., Trupkin, S. A., Karayekov, E., Buchovsky, A. S., Rossi, C., & Casal, J. J. (2010). Cryptochrome as a sensor of the blue/green ratio of natural radiation in Arabidopsis. *Plant physiology*, 154(1), 401-409.
- 35- Soltani, A., Alimgham, S. M., Nehbandani, A., Torabi, B., Zeinali, E., Zand, E., . . . van Ittersum, M. K. (2020). Future food self-sufficiency in Iran: A model-based analysis. *Global Food Security*, 24, 100351. doi:<https://doi.org/10.1016/j.gfs.2020.100351>
- 36- Suykens, J. A. K., & Vandewalle, J. (1999). Least squares support vector machine classifiers. *Neural processing letters*, 9, 293-300.
- 37- Swan, A. (1998). GOOVAERTS, P. 1997. *Geostatistics for Natural Resources Evaluation*. Applied Geostatistics Series. xiv+ 483 pp. New York, Oxford: Oxford University Press. Price£ 46.95 (hard covers). ISBN 0 19 511538 4. *Geological Magazine*, 135(6), 819-842.
- 38- Verma, A., & Kumar, D. (2020). Multilayer Perceptron Artificial Neural Network: A Review. In (pp. 1-38).
- 39- Wei, F., Yan, Z., & Xia, Y. (2008). Monitoring plant nitrogen accumulation dynamics with hyperspectral remote sensing in wheat. *Scientia Agricultura Sinica*.
- 40- Woebbecke, D. M., Meyer, G. E., Von Bargaen, K., & Mortensen, D. A. (1993). Plant species identification, size, and enumeration using machine vision techniques on near-binary images.
- 41- Woebbecke, D. M., Meyer, G. E., Von Bargaen, K., & Mortensen, D. A. (1995). Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*, 38(1), 259-269.
- Multispectral remote sensing for accurate acquisition of rice phenotypes: Impacts of radiometric calibration and unmanned aerial vehicle flying altitudes. *Frontiers in Plant Science*, 13, 958106.
- 23- Matheron, G. (1963). Principles of geostatistics, economic geology. *Economic Geology*, 58(8), 1246-1266.
- 24- Meyer, G. E., & Neto, J. C. (2008). Verification of color vegetation indices for automated crop imaging applications. *Computers and Electronics in Agriculture*, 63(2), 282-293.
- 25- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247-259.
- 26- Ouyang, Q., Lu, W., Xin, X., Zhang, Y., Cheng, W., & Yu, T. (2016). Monthly rainfall forecasting using EEMD-SVR based on phase-space reconstruction. *Water resources management*, 30, 2311-2325.
- 27- Paliwal, A., Laborte, A., Nelson, A., & Singh, R. (2019). Salinity stress detection in rice crops using time series MODIS VI data. *International journal of remote sensing*, 40(21), 8186-8202.
- 28- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., . . . Dubourg, V. (2011). Scikit-learn: Machine learning in Python. *the Journal of machine Learning research*, 12, 2825-2830.
- 29- Penalun, F. E., Hermawan, A., & Avianto, D. (2023). Perbandingan Random Forest Regression dan Support Vector Regression Pada Prediksi Laju Penguapan. *JURNAL FASILKOM*, 13(02), 104-111.
- 30- Possoch, M., Bieker, S., Hoffmeister, D., Bolten, A., Schellberg, J., & Bareth, G. (2016). Multi-temporal crop surface models combined with the RGB vegetation index from UAV-based images for forage monitoring in grassland. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41, 991-998.
- 31- Qin, Y., Xiao, X., Dong, J., Zhou, Y., Zhu, Z., Zhang, G., . . . Wang, J. (2015). Mapping paddy rice planting area in cold temperate climate region through analysis of time series Landsat 8 (OLI), Landsat 7 (ETM+) and

- 42- Wolfe, A. H., & Patz, J. A. (2002). Reactive nitrogen and human health: acute and long-term implications. *Ambio: A journal of the human environment*, 31(2), 120-125.
- 43- Yang, G., Li, Y., Yuan, S., Zhou, C., Xiang, H., Zhao, Z., . . . Xu, L. (2024). Enhancing direct-seeded rice yield prediction using UAV-derived features acquired during the reproductive phase. *Precision Agriculture*, 25(2), 1014-1037.
- 44- Yuan, Y., Wang, X., Shi, M., & Wang, P. (2022). Performance comparison of RGB and multispectral vegetation indices based on machine learning for estimating *Hopea hainanensis* SPAD values under different shade conditions. *Frontiers in Plant Science*, 13, 928953.
- 45- Zhao, Q., Lenz-Wiedemann, V. I. S., Yuan, F., Jiang, R., Miao, Y., Zhang, F., & Bareth, G. (2015). Investigating Within-Field Variability of Rice from High Resolution Satellite Imagery in Qixing Farm County, Northeast China. *ISPRS International Journal of Geo-Information*, 4(1), 236-261. doi:10.3390/ijgi4010236
- 46- Zhao, R., Li, Y., & Ma, M. (2021). Mapping paddy rice with satellite remote sensing: a review. *Sustainability*, 13(2), 503.

COPYRIGHTS

©2026 by the authors. Published by National Geographical Organization. This article is an open access article distributed under the terms and conditions of the Creative Commons [Attribution-NoDerivs 4.0 International \(CC BY-ND 4.0\)](https://creativecommons.org/licenses/by-nd/4.0/)



