

## Research Paper

# Monitoring Nitrogen and Leaf sheath Moisture in Sugarcane Fields Using Satellite Images and Artificial Intelligence (Case Study: Amir Kabir Agro Industrial)

Elahe Zoratipour<sup>1</sup>, Aryan Heidari Motlagh<sup>1</sup>, Amir Soltani Mohammadi<sup>\*2</sup><sup>1</sup>Phd Student of Irrigation and Drainage, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

E-mail: e.zoratipour@yahoo.com

<sup>2</sup>Professor, Irrigation and Drainage Department, Shahid Chamran University of Ahvaz, Ahvaz, Iran. Email:A.soltani@scu.ac.ir

10.22125/iwe.2024.482662.1835

Received:

July 1, 2024

Accepted:

November 30, 2024

Available online:

December 26, 2024

**Keywords:****Remote Sensing,  
Sentinel 2, Vegetation  
index, Crop Monitoring**

## Abstract

The purpose of this research is to evaluate the amount of nitrogen and leaf sheath moisture using remote sensing and artificial intelligence models. For this purpose, three models of support vector machine, random forest and artificial neural network were used, and vegetation indices and single bands of sentinel 2 satellite were used as input to each model. The results showed that in the simulation of leaf nitrogen, single bands B2, B3, B4, B5, B6, B7, B11, B12 and NDVI vegetation index and in the simulation of leaf sheath moisture in bands B2, B3, B4, B5, B6, B7, B11, B12 and vegetation indices NDVI, NDMI and LAI are more important and were considered as inputs to the models. Also, among the models, the random forest model in nitrogen simulation with  $R^2$  equal to 0.88 and RMSE equal to 0.06 in the training phase and  $R^2$  equal to 0.93 and RMSE equal to 0.05 in the validation phase had the best performance. In addition, leaf sheath moisture with  $R^2$  equal to 0.88 and RMSE equal to 0.71 in the training phase and  $R^2$  equal to 0.92 and RMSE equal to 0.59 had a better performance in simulation.

## 1. Introduction

Measuring the parameters affecting the growth, including the percentage of nitrogen in the leaves and humidity, is necessary for scheduling and determining the irrigation time of crops. Therefore, in order to correctly and accurately schedule the irrigation of sugarcane fields, the main aim of this research is to estimate the amount of nitrogen and leaf sheath moisture in sugarcane fields using field information, remote sensing and its simulation with artificial intelligence.

## 2. Materials and Methods

In the current research, the amount of leaf nitrogen and the moisture content of the leaf sheath were investigated on certain days of the hot months of the year. Sentinel 2 satellite images were used so that the date of the satellite passage was consistent with the field data from the Amir Kabir Agriculture and Industry Unit. Bands B2, B3, B4, B5, B6, B7, B8, B9, B11 and B12 and Vegetation indices are used to monitor nitrogen and leaf sheath moisture parameters. Modeling of all measured and estimated parameters from satellite images was done with support vector machine (SVM), random forest (RF) and artificial neural network (ANN) models in MATLAB software. Then, the best model was used to

\* **Corresponding Author:** Amir Soltani Mohammadi

**Address:** Faculty of Water and Environmental  
Engineering, Shahid Chamran University of Ahvaz,  
Ahvaz, Iran.

**Email:** A.soltani@scu.ac.ir  
**Tel:** 09163064863

simulate leaf nitrogen content and leaf sheath moisture. Pearson's correlation was used to determine the most important input parameters of artificial intelligence models. The models were evaluated using statistical indicators.

### 3. Results

Based on Pearson correlation, the most important influencing input parameters are bands B2, B3, B4, B5, B6, B7, B11, B12 and NDVI plant index on leaf nitrogen and bands B2, B3, B4, B5, B6, B7, B11, B12 and Vegetation indices NDVI, NDMI and LAI are on leaf sheath moisture. The results of leaf nitrogen modeling showed that, in the training stage, RF model with R2 equal to 0.88, RMSE equal to 0.06 and rMBE equal to 0.19 compared to ANN and SVM models, respectively, with R2 equal to 0.63 and 0.53, RMSE equal to 0.08 and 0.1 and rMBE equal to -1.01 and zero have performed better. Also, in simulating leaf sheath moisture values, the RF model with R2 equal to 0.88, RMSE equal to 0.71 and rMBE equal to 0.09 had a better estimate than ANN and SVM models.

### 4. Discussion and Conclusion

The results showed that the most effective inputs of the models were in the simulation of leaf nitrogen values of bands B2, B3, B4, B5, B6, B7, B11, B12 and NDVI Vegetation index. In leaf sheath moisture modeling, bands B2, B3, B4, B5, B6, B7, B11, B12 and Vegetation indices NDVI, NDMI and LAI were identified as the most effective inputs of the models. Also, among all the simulation models, the random forest (RF) model had a better performance in the training and verification stages in simulating the amount of leaf nitrogen and leaf sheath moisture. Also, the distribution maps of actual amounts of nitrogen and leaf sheath moisture in the monitored fields show significant changes in nitrogen and leaf sheath moisture during the period under study. Finally, the use of artificial intelligence models, from the two categories of machine learning and deep learning, are able to predict with sufficient accuracy, and their use in agricultural studies is suggested.

### 5. Six important references

- 1) Soltanikazemi, M. Minaei, S, Shafizadeh Moghadam and A.R. Mahdavian. 2024. Comparison of four PLSR, RF, GRNN and SVR Algorithms to Estimate Sugarcane Sheath Moisture During Growing Season Using Sentinel-2 Satellite Imagery. *Iranian Journal of Remote Sensing & GIS*. 16 (3): 47-68.
- 2) Veysi, S, A.A. Naseri and S. Hamzeh. 2018. Relationship between leaf sheath moisture and crop water stress index (CWSI) using infrared thermometer. *Irrigation Sciences and Engineering*. 40 (4): 77-90.
- 3) Bernardino, P. N., R. S. Oliveira, K. Van Meerbeek, M. Hirota, M. N. Furtado, I. A. Sanches. and B. Somers. 2024. Estimating vegetation water content from Sentinel-1 C-band SAR data over savanna and grassland ecosystems. *Environmental Research Letters*, 19(3), 034019.
- 4) Chandrasekar, K., P. Srikanth, A. Chakraborty, K. Choudhary and K. V. Ramana. 2022. Response of crop water indices to soil wetness and vegetation water content. *Advances in Space Research*.
- 5) Virnodkar, S., V. K. Pachghare, V. C. Patil and S. K. Jha. 2021. Performance evaluation of RF and SVM for sugarcane classification using sentinel-2 NDVI time-series. In *Progress in Advanced Computing and Intelligent Engineering: Proceedings of ICACIE 2019, Volume 2* (pp. 163-174). Springer Singapore.
- 6) Liu, L. Y. Li and T. Wu. 2021. Monitoring of Leaf Nitrogen Content in A Citrus Orchard by Landsat 8 OLI Imagery. *Twelfth International Conference on Signal Processing Systems*. 11719(1171905).



## پایش ازت و رطوبت غلاف برگ نیشکر با استفاده از تصاویر ماهواره‌ای و هوش مصنوعی (مطالعه موردی: کشت و صنعت نیشکر امیرکبیر)

الهه ذرتی‌پور<sup>۱</sup>، آریین حیدری مطلق<sup>۲</sup>، امیر سلطانی محمدی<sup>۳</sup>

تاریخ ارسال: ۱۴۰۳/۰۴/۱۱

تاریخ پذیرش: ۱۴۰۳/۰۹/۱۰

مقاله پژوهشی

### چکیده

هدف از پژوهش حاضر ارزیابی میزان ازت و رطوبت غلاف برگ نیشکر با استفاده از سنجش از دور و مدل‌های هوش مصنوعی می‌باشد. بدین منظور از سه مدل رگرسیون بردار پشتیبان، جنگل تصادفی و شبکه عصبی مصنوعی استفاده و از شاخص‌های گیاهی و تک‌باندهای ماهواره سنتینل ۲ به‌عنوان ورودی هر یک از مدل‌ها استفاده گردید. نتایج نشان داد، در شبیه‌سازی ازت برگ، تک‌باندهای B2، B3، B4، B5، B6، B7، B11، B12 و شاخص گیاهی NDVI و در شبیه‌سازی رطوبت غلاف برگ باندهای B2، B3، B4، B5، B6، B7، B11، B12 و شاخص‌های گیاهی NDVI، NDMI، LAI اهمیت بیشتری دارند و به‌عنوان ورودی مدل‌ها در نظر گرفته شدند. همچنین از میان مدل‌ها، مدل جنگل تصادفی (RF) در شبیه‌سازی ازت با  $R^2$  برابر با ۰/۸۸، RMSE برابر با ۰/۰۶ و rMBE برابر با ۰/۱۹ در مرحله آموزش و  $R^2$  معادل ۰/۹۳، RMSE معادل ۰/۰۵ و rMBE برابر با ۰/۶۶- در مرحله صحت‌سنجی و رطوبت غلاف برگ با  $R^2$  برابر با ۰/۸۸، RMSE برابر با ۰/۷۱ و rMBE برابر با ۰/۰۹ در مرحله آموزش و  $R^2$  معادل ۰/۹۲، RMSE معادل ۰/۵۹ و rMBE برابر با ۰/۰۷- از عملکرد بهتری در شبیه‌سازی برخوردار بود.

واژه‌های کلیدی: سنجش از دور، سنتینل ۲، شاخص گیاهی، نظارت محصول

### مقدمه

گیاه و اندازه‌گیری رطوبت خاک متکی است (ژو و همکاران، ۲۰۲۱). همچنین، با فراهم نمودن میزان رطوبت مناسب گیاه، وضعیت ازت در گیاه با توجه به افزایش راندمان آبیاری، سهولت انتقال کود در محیط خاک اطراف

برنامه‌ریزی آبیاری عمدتاً به اندازه‌گیری مستقیم شاخص‌های فیزیولوژیکی همچون، سنجش پتانسیل آب

<sup>۱</sup> دانشجوی دکتری، گروه آبیاری و زهکشی، دانشکده مهندسی آب و محیط‌زیست، دانشگاه شهید چمران اهواز، اهواز، ایران (e.zoratipour@yahoo.com)

<sup>۲</sup> دانشجوی دکتری، گروه آبیاری و زهکشی، دانشکده مهندسی آب و محیط‌زیست، دانشگاه شهید چمران اهواز، اهواز، ایران (aryanheidari74@yahoo.com)

<sup>۳</sup>\* استاد، گروه آبیاری و زهکشی، دانشکده مهندسی آب و محیط‌زیست، دانشگاه شهید چمران اهواز، اهواز، ایران. (نویسنده مسئول). (A.soltani@scu.ac.ir)

رطوبتی گیاه نمی‌توان اقدام به بهبود تغذیه گیاه و ارائه توصیه کودی نمود (بهروان، ۱۳۸۶).

در سال‌های اخیر، داده کاوی به دلیل قابلیت محاسباتی آن برای حل مسائل مختلف نظارتی به‌عنوان یک استراتژی جامع به کار گرفته شده است. همچنین با پیشرفت اخیر در ترکیب علوم سنجش از دور و هوش مصنوعی، اطلاعات در مقیاس میدانی به طور دقیق کمی شده و داده‌های بزرگ به کمک ابزارهای مدیریتی پیش‌بینی می‌شوند. (ژانگ<sup>۷</sup> و همکاران، ۲۰۲۱). سنجش از دور گیاه شامل اندازه‌گیری در فرکانس‌های مرئی و مادون قرمز نزدیک است. که برای بازیابی سبزی، فرآیندهای فتوسنتزی، پوشش گیاهی و موارد دیگر مفید هستند (فلدمان<sup>۸</sup>، ۲۰۲۴؛ رانینگ<sup>۹</sup> و همکاران، ۲۰۰۴؛ تاکر<sup>۱۰</sup>، ۱۹۷۹). در این زمینه پژوهش‌های فراوانی انجام شده است، سلطانی کاظمی و همکاران (۱۴۰۳)، به بررسی مقایسه چهار الگوریتم  $PLSR^{11}$ ،  $RF^{12}$ ،  $GRNN^{13}$  و  $SVR^{14}$  به‌منظور برآورد رطوبت غلاف نیشکر در طول دوره رشد با استفاده از تصاویر ماهواره سنتینل ۲ پرداختند. آنها نشان دادند که مدل  $RF$  و  $SVR$  در مقایسه با سایر مدل‌ها توانایی بالاتری در تخمین رطوبت غلاف برگ داشتند. ویسی و همکاران (۱۳۹۵)، به بررسی رابطه بین رطوبت غلاف برگ گیاه نیشکر و شاخص تنش آبی با استفاده از دماسنج مادون قرمز پرداختند. نتایج نشان داد با افزایش سن گیاه هم‌بستگی بین شاخص تنش و رطوبت غلاف برگ کاهش یافت. چاندرسکار<sup>۱۵</sup> و همکاران (۲۰۲۲)، به بررسی پاسخ شاخص‌های طیفی غلات و سبزیجات، نسبت به محتوای آب پوشش گیاهی در ایالت تلانگاتا واقع در هند پرداختند. درنهایت شاخص‌های گیاهی به دلیل جذب قوی‌تر محتوای آب خاک/گیاهی با توجه به طول موج پایه ۸۶۲ نانومتر، محدوده دینامیکی بهتری را نشان دادند.

گیاه، توسعه شرایط رشد و افزایش توانایی جذب گیاه بهبود می‌یابد. براین اساس اولین گام در توصیه کودی بهبود آبیاری و رطوبت غلاف گیاه می‌باشد و بدون مدیریت شرایط رطوبتی گیاه نمی‌توان اقدام به بهبود تغذیه گیاه و ارائه توصیه کودی نمود (بهروان، ۱۳۸۶). از میان عوامل محیطی قابل کنترل توسط کشاورزان، آب و نیتروژن، اصلی‌ترین عوامل کنترل‌کننده رشد گیاه هستند. آبیاری و کاربرد کود در صورت استفاده کافی، بر رشد گیاه مؤثر واقع می‌شوند. (دوگو<sup>۱</sup> و همکاران، ۲۰۱۰). روش‌های مبتنی بر تاج‌پوشش گیاه اخیراً در پایش وضعیت آب محصول توصیه شده‌اند، زیرا نشانه‌های تنش تاج پوشش خیلی زودتر از نشانه‌های مبتنی بر خاک رخ می‌دهد. همچنین محتوای آب برگ به میزان دسترسی به آب توسط گیاه در خاک، دمای تاج پوشش، رطوبت غلاف برگ و سطح آبیاری در مزرعه بستگی دارد (روبن<sup>۲</sup> و همکاران، ۲۰۲۱). لذا محتوای آب گیاه ( $VWC^3$ ) یک پارامتر بیوفیزیکی حیاتی است، که برای درک رشد گیاه، پویایی اکوسیستم و چرخه آب و کربن ضروری است. با این حال، برای به دست آوردن تخمین‌های  $VWC$  مبتنی بر میدان، بنظر می‌رسد به دلایلی از جمله محدودیت‌های زمانی و منابع چالش‌هایی را نیز به‌دنبال داشته باشد (برناردینو<sup>۴</sup> و همکاران، ۲۰۲۴؛ چوات<sup>۵</sup> و همکاران ۲۰۱۸؛ کونینگز<sup>۶</sup> و همکاران ۲۰۲۱). نیشکر به‌دلیل دوره رشد طولانی، چندساله بودن و عملکرد بالای محصول نیاز به کوددهی و جبران عناصر جذب شده از خاک دارد. میزان و تاریخ مصرف کود ازت در مزارع براساس تجزیه ازت برگ و منحنی‌های استاندارد ازت انجام گرفته و علاوه بر آن به وضعیت آبیاری و رطوبت غلاف برگ نیز وابسته می‌باشد. براین اساس اولین گام در توصیه کودی، بهبود آبیاری و رطوبت غلاف گیاه می‌باشد و بدون مدیریت شرایط

<sup>9</sup> Running

<sup>10</sup> Tucker

<sup>11</sup> Partial Linear Square Regression

<sup>12</sup> Random Forest

<sup>13</sup> General Regression Neural Network

<sup>14</sup> Partial Linear Square Regression

<sup>15</sup> Chandrasekar

<sup>1</sup> Dugo

<sup>2</sup> Reuben

<sup>3</sup> Vegetation water content

<sup>4</sup> Bernardino

<sup>5</sup> Choat

<sup>6</sup> Konings

<sup>7</sup> Jung

<sup>8</sup> Feldman



رشد اعم از درصد ازت موجود در برگ و رطوبت جهت برنامه‌ریزی و تعیین زمان دقیق آبیاری محصولات ضروری می‌باشد. با توجه به مطالب گفته شده به‌منظور برنامه‌ریزی صحیح و دقیق آبیاری مزارع نیشکر، هدف اصلی این پژوهش، برآورد میزان ازت و رطوبت غلاف برگ مزارع نیشکر با استفاده از اطلاعات میدانی، سنجش از دور و شبیه‌سازی آن به کمک مدل‌های هوش مصنوعی می‌باشد. سپس نقشه خروجی ازت برگ و رطوبت غلاف برگ شبیه‌سازی شده در کل سطح مزارع کشت و صنعت امیرکبیر به کمک بهترین مدل حاصل از ارزیابی ارائه می‌گردد.

## مواد و روش‌ها

### معرفی منطقه مورد مطالعه

کشت و صنعت امیر کبیر یکی از هشت واحد زراعی مطرح و متخصص در زمینه کشت نیشکر در منطقه جنوب استان خوزستان است که مساحت ناخالص گسترده ای بالغ بر ۱۴۰۰۰ هکتار را پوشش می‌دهد. این منطقه در امتداد خلیج فارس واقع شده و دارای عرض جغرافیایی از ۳۱ درجه و ۱۵ دقیقه تا ۳۱ درجه و ۴۰ دقیقه و طول جغرافیایی بین ۴۸ درجه و ۱۲ دقیقه تا ۴۸ درجه و ۳۰ دقیقه با ارتفاع ۷ متر از سطح دریا است. کشت و صنعت نیشکر امیرکبیر، با مجموع مساحت خالص ۱۲ هزار هکتار اراضی در کیلومتر ۴۵ جاده اهواز- خرمشهر قرار دارد. همه این مزارع دارای اندازه یکسان ۲۵ هکتار است. در شرق کشت و صنعت امیرکبیر رودخانه بزرگ کارون واقع شده است. بر اساس داده‌های هواشناسی ایستگاه سینوپتیک در منطقه مورد مطالعه، این واحد دارای آب و هوای خشک است و در طبقه بندی اقلیم گاوسی به عنوان نیمه خشک طبقه بندی می‌شود. میانگین دمای سالانه ۲۵ درجه سانتی‌گراد و بافت خاک منطقه نیز سنگین می‌باشد. این منطقه بارندگی تابستانی ندارد و بیشترین بارندگی در فصل زمستان رخ می‌دهد. قابل ذکر است، ماه‌های خرداد، تیر، مرداد و شهریور بیشترین مصرف آب را دارند. شکل (۱) موقعیت جغرافیایی منطقه مطالعاتی را نشان می‌دهد:

ویرنودکار<sup>۱</sup> و همکاران (۲۰۲۱)، به ارزیابی عملکرد دو مدل RF و SVR در طبقه بندی نیشکر، به منظور ارائه نقشه مزارع، با استفاده از داده‌های سری زمانی NDVI و ماهواره Sentinel-2 در یک منطقه ناهمگن در سامپروود<sup>۲</sup> پرداختند. نتایج نشان داد، که RF دقت کلی بالاتری با ۸۸/۶۱ درصد، نسبت به SVR با دقت کلی ۸۱/۸۶ درصد به دست آورد. لیو<sup>۳</sup> و همکاران (۲۰۲۱)، از داده‌های سنجش از دور لندست ۸ برای تعیین میزان توزیع غلظت نیتروژن برگ (LNC) در یک باغ مرکبات واقع در شهر یوکسی، در جنوب غربی چین استفاده کرده و پنج روش مدل‌سازی به کار گرفته شد. نتایج نشان داد، در ارزیابی LNC، الگوریتم PLSR با ضریب تعیین ۰/۸۶۴ و ریشه میانگین مربعات خطا ۱/۲۱ درصد نسبت به سایر الگوریتم‌ها بهترین عملکرد می‌کند. میفوکاساپ<sup>۴</sup> و همکاران (۲۰۱۲)، برآورد غلظت نیتروژن تاج‌پوشش نیشکر با استفاده از تصویر برداری میدانی پرداختند. نتایج نشان داد که طول موج‌های طیفی حساس برای تعیین مقدار نیتروژن اساساً در نواحی مرئی، قرمز و مادون‌قرمز نزدیک طیف الکترومغناطیسی وجود دارند.

نیشکر (*Saccharum spp.*) دارای پتانسیل خوبی برای تولید شکر و بیواتانول است. دو فاکتور مهم ازت برگ و رطوبت غلاف برگ نیشکر در رشد و توسعه آن اهمیت فراوان دارد و با توجه به تغییرات زمانی و مکانی متفاوت این دو فاکتور، چگونگی توزیع و پراکندگی در سطح مزارع نیشکر اهمیت دارد. همچنین شاخص‌های متنوعی برای تشخیص میزان رطوبت و نیتروژن گیاه توسعه داده شده و شواهدی مبنی بر استفاده از فناوری سنجش از دور برای تشخیص وضعیت رطوبتی و نیتروژن گیاه به‌منظور برنامه‌ریزی آبیاری و نیاز کود ازت می‌باشند. به‌خصوص این‌که فناوری سنجش از دور کمک شایانی به دستیابی سریع، کم‌هزینه و دقیق اطلاعات به لحاظ ابعاد زمانی و مکانی گسترده می‌نماید. اندازه‌گیری پارامترهای مؤثر بر

<sup>3</sup> Liu

<sup>4</sup> Miphokasap

<sup>1</sup> Virnodkar

<sup>2</sup> Sameerwadi

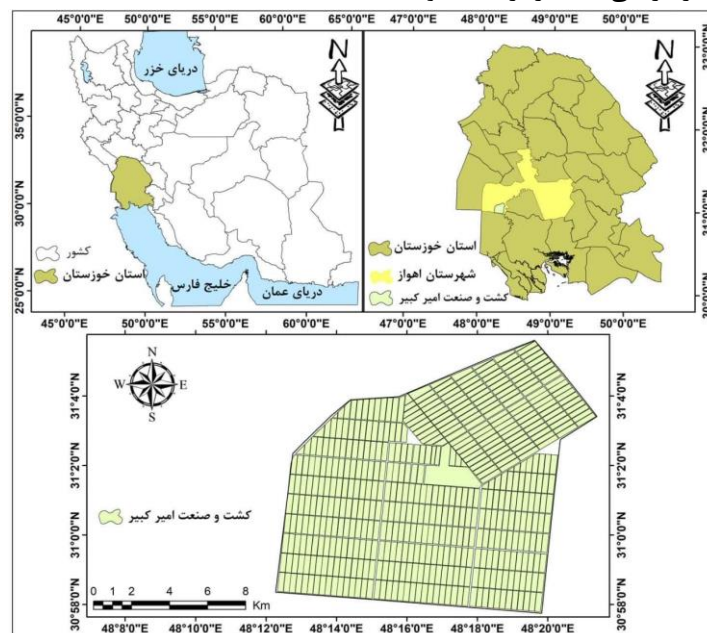
### داده‌های مورد استفاده

در کلیه مزارع کشت و صنعت جهت نظارت و مدیریت بهتر و برنامه‌ریزی دقیق‌تر آبیاری از نمایه گیاهی استفاده می‌شود، که به آن عملیات کراپ‌لاگ می‌گویند. نقاط کراپ‌لاگ شامل ۵ نقطه که به فواصل مشخص از همدیگر قرار داشته و هر نقطه از لبه ابتدا و انتهای مزرعه به طور تقریبی ۶۰ متر فاصله دارد. در این نقاط میزان ازت برگ، درصد رطوبت غلاف برگ و ارتفاع گیاه نیشکر به صورت هفتگی توسط مراکز کشت و صنعت با اعزام نمونه‌برداران به ایستگاه‌های تعیین شده در ایستگاه‌های شاخص (نقاط کراپ‌لاگ) اندازه‌گیری می‌گردد. در پژوهش حاضر اطلاعات ازت برگ، رطوبت غلاف برگ و ارتفاع گیاه نیشکر از ۷۵ مزرعه کراپ‌لاگ کشت و صنعت نیشکر امیرکبیر، در گرم‌ترین ماه‌های سال شامل خرداد، تیر، مرداد و شهریورماه سال ۱۴۰۲ شامل واریته‌های CP73، CP48، CP69 جمع‌آوری و مورد بررسی قرار گرفت. قابل بیان است، ارقام نیشکر مورد استفاده، واریته‌های تجاری متداول بوده و بیشترین سطح زیرکشت در اراضی نیشکر را به خود

اختصاص داده‌اند (عباسی و شینی‌دشتگل، ۱۳۹۵). مختصات نقاط آزمایشی به طور میانگین برای هر مزرعه از طریق GPS برداشت گردید. مطابق روال پایش سالانه مزارع کراپ‌لاگ کشت و صنعت نیشکر امیرکبیر از اواسط اردیبهشت ماه تا انتهای شهریورماه، براساس نوع واریته و سن مزارع نمونه‌برداری انجام می‌گیرد. در هر مزرعه کراپ‌لاگ پنج ایستگاه مشخص و نمونه‌گیری صورت گرفته، سپس با میانگین‌گیری از پارامترها در هر یک از ایستگاه‌های مذکور، مقادیر آن پارامتر را به مزارع زیرمجموعه تعمیم می‌دهند.

### تصاویر ماهواره‌ای مورد استفاده

در مزارع کشت و صنعت، گیاه نیشکر در سطح وسیعی کشت می‌گردد. این نوع گیاه بدلیل حساسیت در مقابل تنش آبی در ماه‌های گرم سال از جمله فصل تابستان، از خرداد ماه تا شهریور ماه، با نیاز آبی بیشتری مواجه گردیده و به ازای آن میزان مصرفی آب هم افزایش پیدا خواهد کرد.



شکل (۱): موقعیت منطقه مطالعاتی

از ماه‌های گرم سال مورد بررسی قرار گرفت. تاریخ روزهای تحت پایش مزارع کراپ‌لاگ همزمان با گذر ماهواره سنتینل ۲ به شرح زیر می‌باشد (جدول ۱).

براین اساس با توجه به تقارن زمانی گذر ماهواره سنتینل ۲ از منطقه مطالعاتی در بازه زمانی اشاره شده، میزان ازت برگ و رطوبت غلاف برگ در روزهایی مشخص

جدول (۱): تاریخ گذر ماهواره همزمان با داده‌برداری زمینی

ماه	تاریخ شمسی	تاریخ میلادی
-----	------------	--------------



۲۰۲۳/۰۶/۰۳	۱۴۰۲/۳/۱۴	خرداد
۲۰۲۳/۰۶/۲۴	۱۴۰۲/۴/۴	تیر
۲۰۲۳/۰۷/۲۹	۱۴۰۲/۵/۷	مرداد
۲۰۲۳/۰۹/۱۶	۱۴۰۲/۶/۲۶	شهریور

### داده‌های سنجنش از دور مورد استفاده

تصاویر سری زمانی نوری Sentinel-2 دارای وضوح بالا در نقشه‌برداری زمین‌های زراعی بوده و در کشاورزی پایدار موضوعی کلیدی محسوب می‌شود (ویروندوکار و همکاران، ۲۰۲۱). در پژوهش حاضر از تصاویر ماهواره‌ای سنتینل ۲ به طوری که روز گذر ماهواره منطبق بر داده‌های میدانی از واحد کشت و صنعت امیرکبیر باشد، استفاده گردید. تصاویر از سایت [www.earthexplorer.usgs.gov](http://www.earthexplorer.usgs.gov) (سازمان زمین شناسی ایالات متحده) با لحاظ تصاویری بدون پوشش ابر در منطقه مورد مطالعه به صورت رایگان قابل ذخیره می‌باشند. از آنجایی که داندود داده‌ها در فواصل زمانی کم حجم زیادی در برداشته و پس از داندود لازم به انجام تصحیحات و پیش‌پردازش‌های ماهواره‌ای جهت افزایش وضوح تصاویر می‌باشد، لذا استفاده از سامانه گوگل ارث انجین ضمن برطرف نمودن این مسائل، سرعت پردازش و آماده‌سازی تصاویر را با دقت بالایی رقم می‌زند. براین اساس به منظور آماده‌سازی تصاویر و تجزیه و تحلیل نتایج از نرم‌افزارهای ArcGIS و Google Earth Engine استفاده شد. تصاویر سنتینل ۲ نیز معمولاً در یک چرخه بازدید ۵-۴ روزه در دسترس قرار می‌گیرند که دارای ۱۳ باند طیفی، شامل باندهای طیفی RGB (قرمز، سبز و آبی)، NIR (مادون قرمز نزدیک) با وضوح مکانی ۱۰ متر می‌باشند. توان تفکیک مکانی این سنجنده ۱۰، ۲۰ و ۶۰ متر بوده که در مطالعات کشاورزی کاربرد فراوان دارد. لذا در مطالعه حاضر به منظور بررسی تک‌باندهای طیفی مؤثر بر پارامترهای تحت مطالعه از باندهای B2، B3، B4، B5، B6، B7، B8، B9، B11 و B12 استفاده می‌شود.

### شاخص‌های گیاهی

شاخص‌های طیفی گیاه توابع ریاضی ناشی از بازتاب مرئی و مادون قرمز نزدیک بوده که می‌توانند به طور مؤثر ظرفیت فتوسنتزی تاج‌پوشش را نشان دهند (وینا<sup>۱</sup> و

همکاران، ۲۰۱۱). شایان توجه است که ترکیب باندهای مختلف و استفاده از شاخص‌های طیفی گوناگون در تعیین ارتباط میان فاکتورهای اساسی همچون میزان ازت برگ و رطوبت غلاف برگ نقش مهمی ایفا کرده و در نهایت کمک به تعیین برنامه‌ریزی آبیاری می‌کنند. به منظور بررسی میزات ازت و رطوبت غلاف برگ گیاه نیشکر براساس مطالعات اخیر از شاخص‌های طیفی متعددی استفاده می‌گردد، که در جدول (۲) نشان داده شده است.

### مدلسازی

محققان در تلاش‌ند تا میان مدل‌های سنجنش از دور و هوش مصنوعی پیوندی قوی برقرار کرده و در نتیجه آن، امکان شبیه‌سازی محصولات متعدد در راستای توسعه برنامه‌های کشاورزی دیجیتال را در مناطق با وسعتی گسترده داشته باشند. لذا مدل‌سازی پارامترها بر پایه اصول هوش مصنوعی و ماشین‌های یادگیری در پیش‌بینی و تولید مدل بهینه بسیار مؤثر بوده و با توجه به اهمیت مباحث آبیاری دقیق در کشاورزی، بررسی مدل‌های هوش مصنوعی و یا مدل‌های ماشین یادگیری می‌توانند به بهترین وجه کمک به تعیین زمانبندی و برنامه‌ریزی آبیاری و نهایتاً مدیریت آب داشته باشند. بنابراین براساس مطالعات انجام شده، به منظور مدل‌سازی کلیه پارامترهای اندازه‌گیری شده و برآورد شده از تصاویر ماهواره‌ای شامل میزان ازت برگ و رطوبت غلاف برگ از مدل‌های رگرسیون بردار پشتیبان (SVR)، جنگل تصادفی (RF) و شبکه عصبی مصنوعی (ANN)، با استفاده از نرم‌افزار متلب استفاده گردید. سپس بهترین مدل در شبیه‌سازی میزان ازت برگ و رطوبت غلاف برگ به کار گرفته شد. در هر سه مدل، از ۷۰ درصد داده‌ها برای آموزش و از ۳۰ درصد باقیمانده برای مرحله صحت‌سنجی استفاده گردید.

### انتخاب ویژگی

<sup>1</sup> Vina

مهم‌ترین متغیرهای ورودی که بیشترین تأثیر را بر ازت برگ و رطوبت غلاف برگ دارند، انتخاب و به عنوان ورودی‌های هر یک از مدل‌های هوش مصنوعی بکار گرفته شدند. براین اساس از همبستگی پیرسون (معادله ۱) به منظور تعیین مهم‌ترین پارامترهای مؤثر بر ازت و رطوبت غلاف برگ به منظور فراخوانی عوامل ورودی مدل‌های هوش مصنوعی تحت مطالعه استفاده شد.

به منظور تعیین و شناسایی مهم‌ترین عوامل تأثیرگذار بر ازت و رطوبت غلاف برگ، از میان پارامترهای ارتفاع گیاه، تک‌بند‌های تحت بررسی و شاخص‌های گیاهی مرتبط، از فرآیند انتخاب ویژگی استفاده شد. این فرآیند به دلیل کاهش پیچیدگی در فراخوانی ورودی مدل و همچنین افزایش دقت و سرعت کافی در اجرای مدل مورد توجه قرار گرفته است. در این مطالعه به کمک فرآیند انتخاب ویژگی

جدول (۲): شاخص‌های طیفی مورد مطالعه در ارتباط با برآورد ازت برگ و رطوبت غلاف برگ

منبع	فرمول	شاخص‌های گیاهی (VI <sup>1</sup> )
Hurcom and Harrison (1988)	$NDVI = (R_{NIR} - R_{RED}) / (R_{NIR} + R_{RED})$	شاخص تفاضلی پوشش گیاهی نرمال شده (NDVI <sup>1</sup> )
Wang et al. (2011)	$NDMI = (R_{Vegetation\ Red\ Edge} - R_{SWIR}) / (R_{Vegetation\ Red\ Edge} + R_{SWIR})$	شاخص ماده خشک نرمال شده (NDMI <sup>3</sup> )
Allen et al. (2002)	$LAI = ((\ln((0.69 - SAVI) / 0.59)) / 0.91)$	شاخص سطح برگ (LAI <sup>4</sup> )

R<sub>NIR</sub>: بازتابندگی محدوده قرمز، R<sub>RED</sub>: بازتابندگی بخش مادون قرمز نزدیک، R<sub>Vegetation Red Edge</sub>: بازتابندگی محدوده لبه قرمز طیف الکترومغناطیس، R<sub>SWIR</sub>: بازتابندگی فروسرخ طول موج کوتاه، SAVI: شاخص گیاهی تعدیل یافته خاک

$$R^2 = \left[ \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2 \sum_{i=1}^N (Y_i - \bar{Y})^2}} \right]^2 \quad (۴)$$

$$r = \frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sum_{i=1}^n (O_i - \bar{O}) \sum_{i=1}^n (P_i - \bar{P})} \quad (۱)$$

به طوری که O<sub>i</sub> داده‌های میدانی ازت و رطوبت غلاف برگ را نشان می‌دهد و P<sub>i</sub> نشان‌دهنده کلیه متغیرهای مستقل (شامل ارتفاع گیاه و شاخص‌های گیاهی و باند‌های ماهواره سنتینل ۲) می‌باشد.

ارزیابی مدل‌ها با استفاده از شاخص‌های آماری

به منظور ارزیابی دقت و کارایی مدل‌ها، از آماره‌های ریشه میانگین مربعات خطا (RMSE<sup>5</sup>)، میانگین نسبی خطا (rMBE<sup>6</sup>) و ضریب تعیین (R<sup>2</sup>)<sup>۷</sup> به صورت زیر استفاده شد.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - Y_i)^2} \quad (۲)$$

$$rMBE = \left[ \frac{\sum_{i=1}^N (x_i - Y1) * (100)}{\sum_{i=1}^N (x_i)} \right] \quad (۳)$$

در روابط بالا، X<sub>i</sub> و Y<sub>i</sub> به ترتیب مقادیر محاسباتی و مشاهداتی در گام زمانی i ام، N تعداد گام‌های زمانی،  $\bar{X}$  و  $\bar{Y}$  نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی می‌باشد. آماره ریشه میانگین مربعات خطا (RMSE) همواره مثبت بوده و بهترین حالت عملکرد زمانی است که مقدار به صفر نزدیک شود. شاخص میانگین نسبی خطا (rMBE) به منظور بیش‌برآوردی یا کم‌برآوردی مدل‌ها نسبت به مقدار اندازه‌گیری شده، مورد استفاده قرار گرفت. با این حال اگر rMBE بین ±۲۵ در طبقه عالی چنانچه بین ±۲۵ تا ±۴۰ قرار گیرد خوب و در صورتی که بین ±۴۰ تا ±۷۰ متوسط و اگر بالاتر از ±۷۰ ضعیف می‌باشد. شاخص ضریب تعیین نشانگر دقت تخمین است که مقداری همواره بین منفی یک و مثبت یک دارد که علامت + و -

<sup>۱</sup> - Root Mean Square Error

<sup>۶</sup> Relative Mean Bias Error

<sup>۷</sup> Coefficient of Determination

<sup>۱</sup>Vegetation index

<sup>۲</sup> Normalized difference vegetation index

<sup>۳</sup> Normalized dry matter index

<sup>۴</sup> Leaf Aarea index



همچنین از میان شاخص‌های گیاهی نیز دو شاخص NDMI و LAI نسبت به ازت برگ از همبستگی پایینی برخوردار بوده، لذا در مرحله فراخوانی ورودی مدل‌ها، جهت شبیه‌سازی مقادیر ازت واقعی از این دو شاخص طیفی نیز صرف‌نظر گردید. همچنین، جهت شبیه‌سازی رطوبت غلاف برگ با توجه به همبستگی قابل توجه شاخص‌های گیاهی برابر با ۰/۲۹، ۰/۱۹ و ۰/۱۵ به ترتیب برای شاخص‌های NDVI، LAI و NDMI هر سه شاخص در فراخوانی ورودی مدل‌ها در نظر گرفته شدند. قابل بیان است، در شبیه‌سازی پارامترهای تحت مطالعه، باندهای B5، B6، B11، B12 و از میان شاخص‌های گیاهی، شاخص NDVI بیشترین اثر را از خود نشان دادند. بنا به تحقیقات صورت گرفته، باندهای مادون قرمز، قرمز و فروسرخ کارایی قابل توجهی نسبت به کمبود محتوای آب گیاه دارند (بالستر<sup>۱</sup> و همکاران، ۲۰۱۹؛ سلطانی کاظمی و همکاران، ۱۴۰۳). همچنین، برآورد نیتروژن با استفاده از باند لبه قرمز و شاخص‌های گیاهی در مطالعات گوناگون مورد توجه قرار گرفته است (کلورز<sup>۲</sup> و گیتلسون<sup>۳</sup>، ۲۰۱۳). شکل (۲) نیز مقایسه مقادیر واقعی ازت و رطوبت غلاف برگ را نسبت به وضعیت استاندارد این دو پارامتر در کل دوره تحت بررسی نشان می‌دهد. براین اساس تغییرات مقادیر ازت از پراکندگی بیشتری برخوردار بوده است، به طوری که در ابتدای دوره تحت مطالعه، از خرداد ماه تا تیرماه، مقادیر ازت واقعی به طور میانگین از مقادیر ازت استاندارد بیشتر بوده است، از تیر ماه تا مرداد ماه روند کاهشی و سپس از مرداد تا شهریور ماه روند تغییرات ازت بسیار به حالت استاندارد نزدیک می‌باشد. در نهایت در ادامه نیز روند کاهشی به خود گرفته است.

بیانگر همبستگی مثبت یا منفی است و هرچه به یک نزدیک باشد نشان از همبستگی بیشتر بین مقادیر مشاهداتی و محاسباتی دارد (حیدری مطلق و همکاران، ۱۴۰۱).

## نتایج و بحث

### تحلیل حساسیت متغیرهای ورودی به مدل‌های

#### هوش مصنوعی

در این مطالعه به کمک فرایند انتخاب ویژگی، مهم‌ترین متغیرهای ورودی که بیشترین تأثیر را بر فاکتورهای تحت بررسی داشته، انتخاب و به عنوان ورودی‌های هر یک از مدل‌های هوش مصنوعی بکار گرفته شد. بدین منظور از روش همبستگی پیرسون جهت تعیین مؤثرترین فاکتورهای ورودی ازت و رطوبت غلاف برگ استفاده گردید. با توجه به جدول (۳)، مهم‌ترین پارامترهای ورودی اثرگذار به ترتیب، شامل باندهای B2، B3، B4، B5، B6، B7، B11، B12 و شاخص گیاهی NDVI بر ازت برگ و باندهای B2، B3، B4، B5، B6، B7، B11، B12 و شاخص‌های گیاهی NDVI، NDMI و LAI بر رطوبت غلاف برگ می‌باشند. قابل ذکر است، ملاک انتخاب مهم‌ترین عوامل براساس، بیشترین و کمترین میزان ضریب همبستگی پیرسون، به ترتیب به درجه اهمیت بالا و پایین بوده و عواملی که درصد بالاتری داشته باشند، به عنوان مهم‌ترین عوامل مؤثر معرفی می‌گردند. لذا با توجه به نتایج دریافتی مقادیر باندهای B8 و B9 و ماهواره سنتینل ۲ به ترتیب با میزان همبستگی ۰/۱۸ و ۰/۰۸ نسبت به ازت برگ و ۰/۱۴ و ۰/۱۴ نسبت به رطوبت غلاف برگ همبستگی معنی داری نداشته است و از متغیرهای ورودی مدل حذف شدند.

جدول (۳): میزان همبستگی شاخص‌های ورودی مدل

۱	رطوبت غلاف برگ	ازت برگ
NDMI	۰/۱۵	۰
LAI	۰/۱۹	-۰/۰۴
NDVI	۰/۲۹	-۰/۱۲
B12	۰/۳۹	۰/۴۳
B11	۰/۴۴	۰/۴۸
B9	۰/۱۴	۰/۰۸



<sup>3</sup> Gitelson

<sup>1</sup> Ballester

<sup>2</sup> Clevers

B8	۰/۱۸	۰/۱۸
B7	۰/۳۸	۰/۳۸
B6	۰/۵۷	۰/۵۵
B5	۰/۶۱	۰/۵۵
B4	۰/۳۶	۰/۳۴
B3	۰/۵	۰/۴۹
B2	۰/۳۲	۰/۳

-۱



شکل (۲): مقایسه مقادیر واقعی و استاندارد ازت و رطوبت غلاف برگ

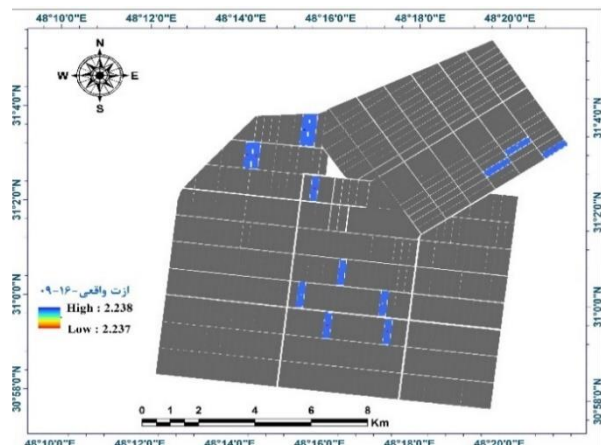

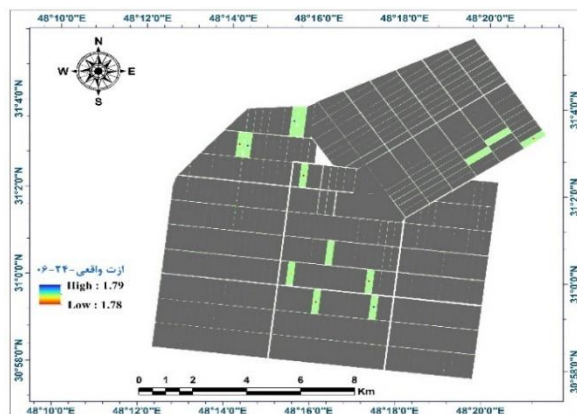
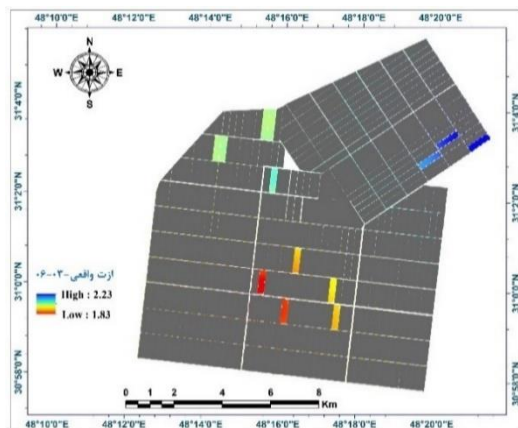
بازتاب سطوح کافی و بالای نیتروژن رفتار مشابهی را نشان می‌دهد و بیشتر از بازتاب سطح پایین نیتروژن می‌باشد. در دو باند کوتاه مادون قرمز، میزان بازتاب با کاهش نیتروژن افزایش می‌یابد. علاوه بر این، اختلاف طیفی بین سه سطح زیاد، کافی و کم نیتروژن در این دو باند بیشتر از باند مادون قرمز نزدیک می‌باشد (لیو و همکاران، ۲۰۲۱). نسبت‌های بازتاب تصاویر ماهواره‌ای معمولاً می‌توانند در برابر اثرات جذب اتمسفری و تابش متغیر بین تصاویر گرفته‌شده مقداری نرمال‌سازی ایجاد کنند. شاخص‌های گیاهی با ترکیب یک یا چند باند مختلف طیفی قادر به پردازش داده‌های ماهواره‌ای در سطح وسیع و با دقت بالا بوده و برای ارزیابی دقیق و گسترده پارامترهای تحت بررسی و برقراری ارتباط میان آن‌ها مؤثر واقع می‌گردند (لیو و همکاران، ۲۰۲۱). براین اساس، شکل (۳) نقشه‌های توزیع مقادیر واقعی ازت و رطوبت غلاف برگ را در مزارع تحت پایش به ترتیب در روزهای گذر ماهواره نشان می‌دهد. مقادیر ازت واقعی نیشکر در تاریخ‌های نمونه برداری بین

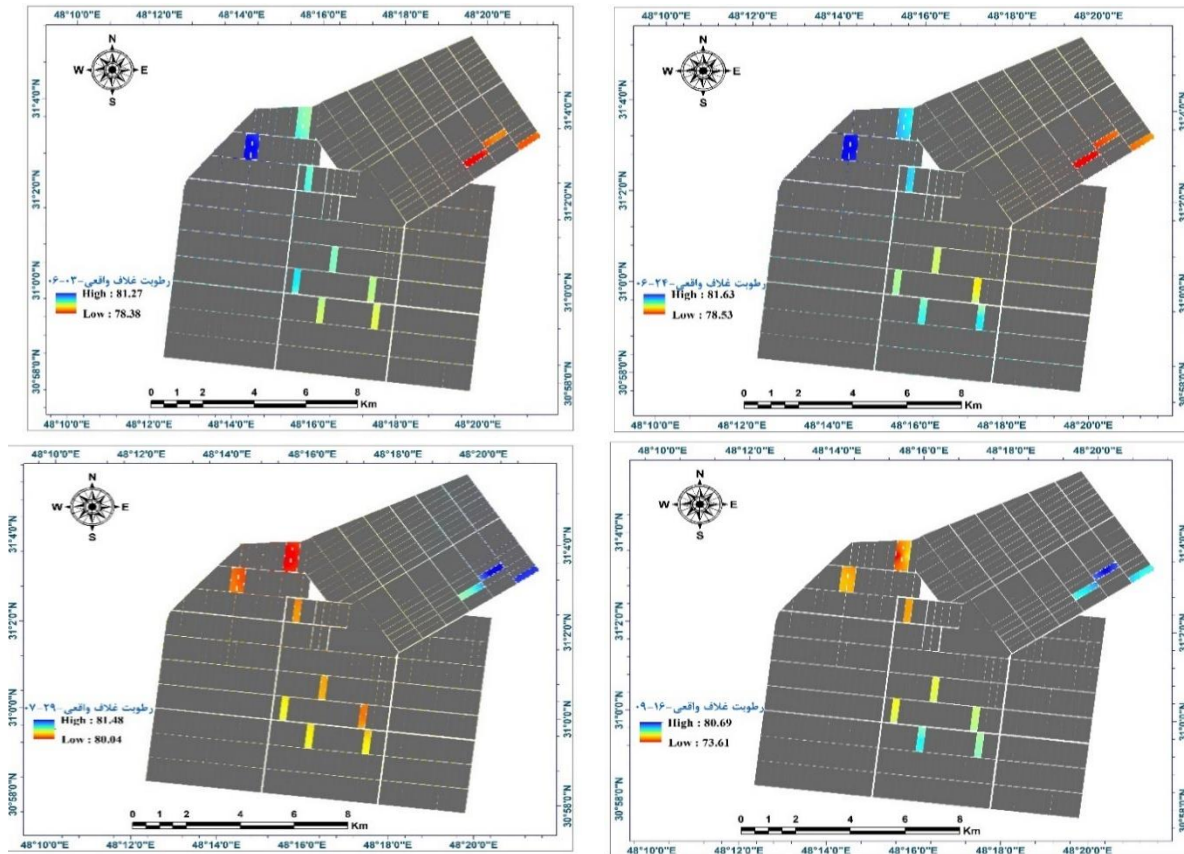
اندازه‌گیری کمبود نیتروژن و تنش آبی یک پیش‌نیاز برای ارزیابی کمی نیازهای محصول و مدیریت آبیاری و کاربرد کود است، لذا اثرات کمبود آب بر تقاضای نیتروژن قابل بررسی می‌باشد (دوگو و همکاران، ۲۰۱۰). تغییرات رطوبت غلاف برگ واقعی نیز در کل دوره تحت بررسی کمتر و گاهی بسیار نزدیک به مقادیر رطوبت در حالت استاندارد بوده و با فاصله گرفتن از حالت استاندارد، به تدریج مزارع با تنش آبی مواجه می‌گردند. قابل ذکر است که شاخص تنش آبی برای نیشکر در فواصل آبیاری در محدوده ۲/۷-۰/۱ متغیر می‌باشد (ویسی و همکاران، ۲۰۱۷). همچنین، هرگاه رطوبت غلاف برگ به کمتر از ۷۵ درصد برسد نشان‌دهنده وقوع تنش بالا در مزارع نیشکر می‌باشد (ویسی و همکاران، ۱۳۹۶). از دیگر موارد قابل ذکر می‌توان اشاره کرد، همبستگی قوی بین نیتروژن برگ و کلروفیل در گونه‌های مختلف گیاهان است (بارت<sup>۱</sup> و همکاران، ۲۰۰۷). نیتروژن نیز عامل مهمی در ساخت مولکول کلروفیل گیاه است، در باند مادون قرمز نزدیک، مقادیر

<sup>1</sup> Baret

همزمان با گذر ماهواره، بیشترین و کمترین مقدار رطوبت غلاف برگ در قسمت غرب و شمال مزارع نیشکر نمایان می‌باشد. در ادامه نیز، هرچه به انتهای فصل رشد نیشکر نزدیک شده، بیشترین مقدار رطوبت غلاف برگ در قسمت شمال نیشکر و کمترین مقدار در قسمت غرب مزارع دیده می‌شود، که می‌تواند ناشی از تنوع سن گیاه نیشکر در مزارع تحت پایش باشد. در این باره می‌توان افزود، در کل دوره تابستان، با افزایش سن گیاه همبستگی بین تنش و رطوبت غلاف برگ در سن‌های مختلف کاهش می‌یابد. از دلایل این امر می‌توان به تأخیر افتادن فرآیند جذب آب توسط گیاه و در پی آن تأخیر در فرآیند تبخیر و تعرق اشاره نمود (ویسی و همکاران، ۱۳۹۶).

بازه ۱/۷۸ تا ۲/۲۳ متغیر می‌باشد. همان‌طور که مشاهده می‌شود، از تاریخ ۲۰۲۳/۰۶/۲۴ دامنه تغییرات در مزارع مورد پایش دارای نوسان کمتری بوده است. با گذر زمان و نزدیک شدن به انتهای فصل رشد نیشکر گستردگی توزیع مقادیر ازت در مزارع مورد پایش به حداقل تغییرات خود می‌رسد. تخمین غلظت نیتروژن غلاف برگ به طور گسترده برای نظارت بر وضعیت رشد محصول در زمان واقعی استفاده می‌شود (لیو و همکاران، ۲۰۲۱). قابل بیان است، نقشه‌های رطوبت غلاف برگ نیشکر نیز دستخوش تغییرات قابل توجهی بوده است به گونه‌ای که، مقادیر رطوبت غلاف برگ در تاریخ‌های نمونه برداری بین بازه ۷۳/۶۱ تا ۸۱/۶۳ در نوسان می‌باشد. همچنین در اوایل دوره تحت بررسی





شکل (۳): مقادیر واقعی ازت و رطوبت غلاف برگ مزارع تحت پایش

برگ نیز مدل RF با  $R^2$  برابر با ۰/۸۸، RMSE برابر با ۰/۷۱ و rMBE برابر با ۰/۰۹ نسبت به مدل‌های ANN و SVR برآورد بهتری داشت. قابل بیان است، مدل ANN نیز با  $R^2$  برابر با ۰/۷۳، RMSE برابر با ۰/۸۲ و rMBE برابر با ۰/۲۲ با اختلاف اندک نسبت به مدل RF از قابلیت خوبی در شبیه‌سازی رطوبت غلاف برگ برخوردار بود. همچنین مدل SVR با  $R^2$  برابر با ۰/۶۲، RMSE برابر با ۱/۱۲ و rMBE برابر با صفر کارایی مناسبی در شبیه‌سازی نشان داد. نمودار پراکندگی میزان ازت و رطوبت غلاف برگ برآورد شده و واقعی، حاصل از مرحله صحت‌سنجی نیز براساس سه مدل مذکور در شکل (۵) نشان داده شده است. با توجه به شکل (۵)، در مرحله صحت‌سنجی، مدل RF عملکرد بسیار بهتری نسبت به دو مدل دیگر در شبیه‌سازی ازت و رطوبت غلاف برگ داشته است.



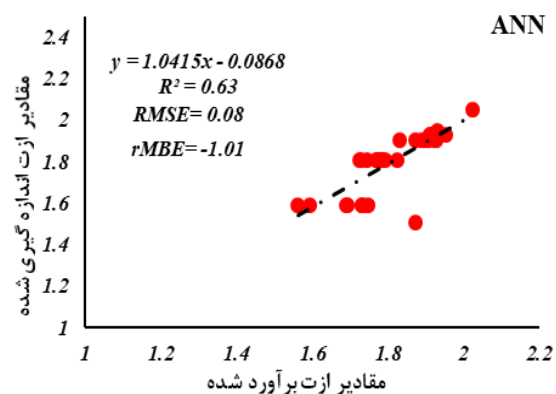

لذا RF با  $R^2$  معادل ۰/۹۳، RMSE معادل ۰/۰۵ و rMBE معادل ۰/۰۶۶- در شبیه‌سازی ازت واقعی برگ و  $R^2$  معادل ۰/۹۲، RMSE معادل ۰/۵۹ و rMBE معادل ۰/۰۷-

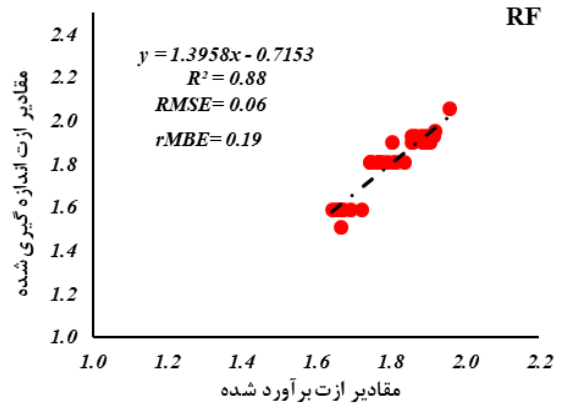

شکل (۴) نیز نمودار پراکندگی میزان ازت و رطوبت غلاف برگ برآورد شده در مقابل مقادیر واقعی را با استفاده از مدل‌های شبکه عصبی مصنوعی (ANN)، رگرسیون بردار پشتیبان (SVR) و جنگل تصادفی (RF) در مرحله آموزش نشان می‌دهد. اجرای مدل شبکه عصبی مصنوعی در مرحله آموزش، از طریق گره‌های لایه پنهان و یک گره خروجی و با در نظر گرفتن توابع مختلف انتقال برای لایه پنهان و خروجی و تکرارهای ۱۰۰۰۰ صورت گرفت. همچنین مدل رگرسیون بردار پشتیبان نیز با ضریب گاما ۰/۳۲ برای ازت برگ و ۰/۹۸ برای رطوبت غلاف برگ و مدل جنگل تصادفی با تعداد درخت برابر با ۴۰۰ در بهترین حالت به مدلسازی پارامترها پرداختند. نتایج مدلسازی ازت برگ نشان داد، در مرحله آموزش مدل RF با  $R^2$  برابر با ۰/۸۸، RMSE برابر با ۰/۰۶ و rMBE برابر با ۰/۱۹ نسبت به دو مدل ANN و SVR به ترتیب با  $R^2$  برابر با ۰/۶۳ و ۰/۵۳، RMSE برابر با ۰/۰۸ و ۰/۱ و rMBE برابر با ۱/۰۱- و صفر عملکرد بهتری داشته است. همچنین در شبیه‌سازی مقادیر رطوبت غلاف






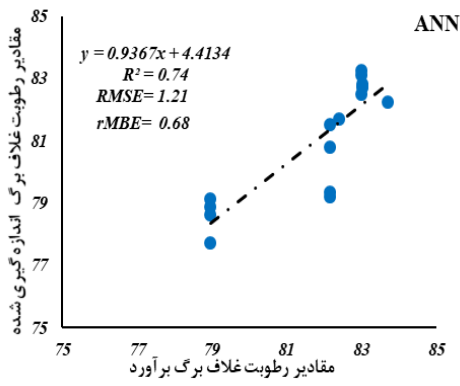
جزئی برخوردار هستند (سلطانی کاظمی و همکاران، ۱۴۰۳). کاربرد مدل‌های یادگیری ماشین مخصوص انواع مدل‌های درختی شامل درخت تصمیم و جنگل تصادفی در مدلسازی پارامترهای مؤثر بر عملکرد محصول و نظارت بر تنش آبی محصول و نیاز آبی گیاه بسیار مورد توجه قرار گرفته است (کاتیمبو و همکاران، ۲۰۲۳). لذا استفاده از مدل جنگل تصادفی از دسته مدل‌های یادگیری ماشین در شبیه‌سازی ازت و رطوبت غلاف برگ نتایج مطلوبی ارائه داده و از قابلیت بالاتری نسبت به سایر مدل‌های هوش مصنوعی برخوردار می‌باشند

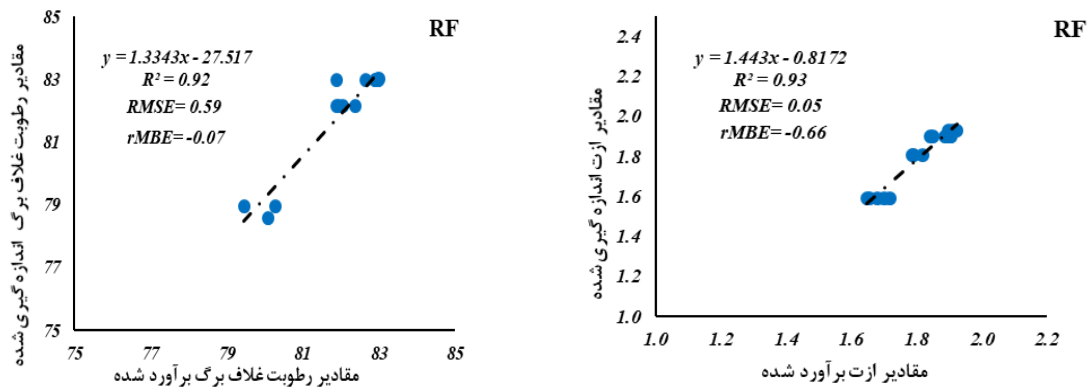
در شبیه‌سازی رطوبت غلاف برگ از کارایی بالاتری نسبت به دو مدل دیگر برخوردار بود. دو مدل ANN و SVR نیز با  $R^2$  معادل ۰/۶۸ و ۰/۶۴، RMSE معادل ۰/۱۱ و rMBE معادل ۲/۱۷- و ۰/۷۸ با عملکردی نزدیک به هم، توانایی قابل قبولی در شبیه‌سازی ازت برگ نشان دادند. همچنین در مدلسازی رطوبت غلاف برگ نتایج دو مدل مذکور بسیار مشابه بوده، به گونه‌ای که ANN با  $R^2$  معادل ۰/۷۴، RMSE معادل ۱/۲۱، rMBE معادل ۰/۶۸- و SVR نیز با  $R^2$  معادل ۰/۶۹، RMSE معادل ۱ و rMBE معادل ۰/۰۱- از برآورد نسبتاً مناسبی برخوردار بودند. مدل SVR در مواقع کاربرد ترکیبی شاخص‌های طیفی و مقادیر تک‌باند‌های ماهواره سنتینل ۲ و مدل RF به هنگام کاربرد مجزای شاخص‌ها و مقادیر تک‌باند از قابلیت بالاتری در شبیه‌سازی مقادیر رطوبت غلاف برگ نیشکر، با اختلاف





شکل(۴): مدلسازی مقادیر ازت و رطوبت غلاف برگ در مرحله آموزش

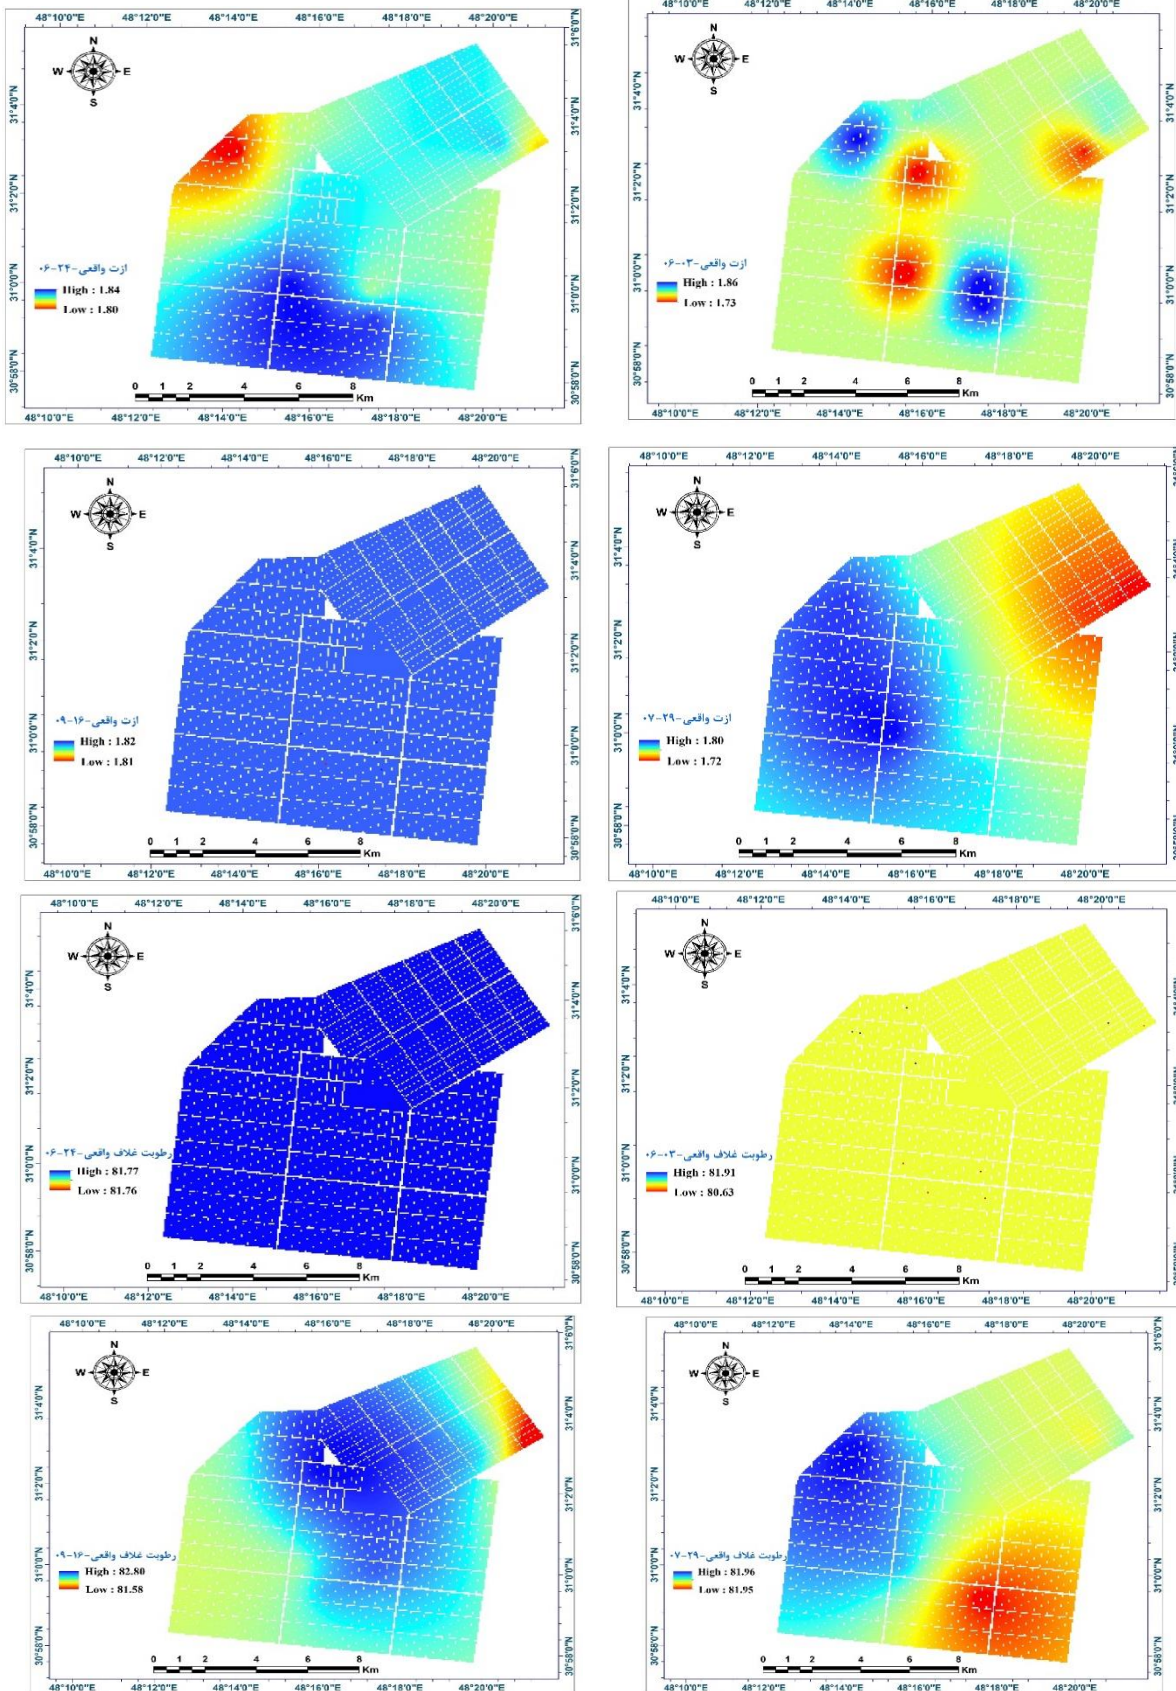




شکل (۵): مدلسازی مقادیر ازت و رطوبت غلاف برگ در مرحله صحت‌سنجی

براساس یافته‌های حاصل از مدلسازی، میزان ازت برگ نیشکر در بازه ۱/۷۲ تا ۱/۸۶ در نوسان می‌باشد. در اوایل دوره تحت مطالعه همزمان با روزهای گذر ماهواره با توجه به اینکه سبزی‌نگی گیاه کاملاً به حد بالای خود نرسیده است، میزان تغییرات در کل مزارع نیشکر دارای نوسان می‌باشد. براین اساس هر چه به انتهای فصل رشد نیشکر نزدیک شده، با توجه به مقدار سبزی‌نگی کامل در کل مزارع، میزان تغییرات به حداقل مقدار خود می‌رسد. همچنین دامنه تغییرات مقادیر رطوبت غلاف برگ نیشکر نیز، در تاریخ‌های نمونه‌برداری معادل با ۸۰/۶۳ تا ۸۲/۸۰ می‌باشد. همان‌طور که از نتایج مشاهده می‌گردد، در اوایل دوره تابستان، توزیع یکنواختی از میزان رطوبت غلاف برگ در کل منطقه مورد مطالعه دیده می‌شود، ولی با گذشت زمان و رسیدن به دوره انتهایی رشد، میزان تغییرات در سطح مزارع افزایش پیدا می‌کند. لذا در روزهای انتهایی دوره تحت بررسی، بیشترین میزان رطوبت غلاف برگ در بخش‌های مرکزی و غرب مزارع نیشکر مشاهده می‌گردد

مطالعات فراوانی پتانسیل تصاویر Sentinel-2 را در پایش محصولاتی از جمله نیشکر با استفاده از روش‌های یادگیری ماشین همچون RF و SVR مورد ارزیابی قرار داده و استفاده از الگوریتم‌های یادگیری ماشین را در نقشه‌برداری زمین‌های زراعی تأیید می‌کنند (ویراندوکار و همکاران، ۲۰۲۱). با توجه به نتایج دریافتی حاصل از ارزیابی مدل‌های هوش مصنوعی (اشکال ۴ و ۵) مشخص گردید، مدل جنگل تصادفی (RF) در هر دو مرحله آموزش و صحت‌سنجی مدل، بیشترین هم‌خوانی را با مقادیر واقعی ازت و رطوبت غلاف برگ داشته و از کارایی بالاتری در شبیه‌سازی برخوردار بوده است، لذا به‌عنوان بهترین مدل از میان سه مدل تحت مطالعه در پژوهش حاضر انتخاب گردیده و نقشه مقادیر ازت و رطوبت غلاف برگ شبیه‌سازی شده در کل سطح مزارع کشت و صنعت امیرکبیر براساس مدل RF ارائه می‌گردد. براین اساس، شکل (۶)، نقشه‌های توزیع مقادیر ازت و رطوبت غلاف برگ شبیه‌سازی شده براساس مدل جنگل تصادفی (RF)، همزمان در روزهای گذر ماهواره نشان داده می‌شود.



شکل (۶): شبیه‌سازی مقادیر ازت و رطوبت غلاف برگ براساس مدل جنگل تصادفی



## نتیجه گیری

رطوبت غلاف برگ در دوره تحت مطالعه بوده، لذا نقشه‌های توزیع مقادیر شبیه‌سازی شده ازت و رطوبت غلاف برگ براساس مدل جنگل تصادفی (RF)، همزمان در روزهای گذر ماهواره در کل سطح مزارع کشت و صنعت امیرکبیر ارائه گردید. در نهایت با توجه به برآورد نزدیک و قابل قبول داده‌های شبیه‌سازی شده در مقایسه با مقادیر واقعی ازت و رطوبت غلاف برگ، استفاده از مدل‌های هوش مصنوعی، از دو دسته ماشین‌های یادگیری و شبکه عصبی قادر به پیش‌بینی با دقت کافی بوده و براین اساس کاربرد فناوری سنجش از دور و هوش مصنوعی در پایش فاکتورهای مؤثر بر عملکرد محصول، نیاز آبی و جنبه‌های متنوع کشاورزی دقیق پیشنهاد می‌گردد.

## تشکر و قدردانی

این مقاله مستخرج از طرح پژوهشی با شماره ۱۳۶۴ از محل پژوهانه است که نویسندگان از حمایت مالی دانشگاه شهید چمران اهواز با شماره پژوهانه SCU.WI1402.273 تشکر می‌کنند.

نتایج نشان داد مؤثرترین ورودی‌های مدل‌ها، در شبیه‌سازی مقادیر ازت برگ باندهای B2، B3، B4، B5، B6، B7، B11، B12 و شاخص گیاهی NDVI بوده و در مدلسازی رطوبت غلاف برگ باندهای B2، B3، B4، B5، B6، B7، B11، B12 و شاخص‌های گیاهی NDVI، NDMI و LAI می‌باشند. همچنین از میان کلیه مدل‌های شبیه‌سازی، مدل جنگل تصادفی (RF) با  $R^2$  برابر با ۰/۸۸، RMSE برابر با ۰/۰۶ و rMBE برابر با ۰/۱۹ در مرحله آموزش و با  $R^2$  معادل ۰/۹۳، RMSE معادل ۰/۰۵ و rMBE معادل ۰/۶۶- در مرحله صحت‌سنجی در شبیه‌سازی مقدار ازت برگ از عملکرد بهتری برخوردار بود. همچنین در شبیه‌سازی رطوبت غلاف برگ نیز دارای دقت بالاتری نسبت به سایر مدل‌ها با  $R^2$  برابر با ۰/۸۸، RMSE برابر با ۰/۷۱ و rMBE برابر با ۰/۰۹ در مرحله آموزش و با  $R^2$  معادل ۰/۹۲، RMSE معادل ۰/۵۹ و rMBE معادل ۰/۰۷- بود. در انتها نیز نقشه‌های توزیع مقادیر واقعی ازت و رطوبت غلاف برگ در مزارع تحت پایش و در روزهای گذر ماهواره نشان‌دهنده تغییرات قابل توجه مقادیر ازت و

## منابع

- بهروان، ح. ر. ۱۳۸۶. نقش درصد رطوبت غلاف برگ نیشکر در توصیه‌های کودی با سیستم کراپ‌لاگ (Croplogging). مجموعه مقالات دهمین کنگره علوم خاک ایران.
- بهی، فر، الف، م. حدادی و ف. متکان. ۱۳۹۸. ارزیابی اثر اشباع شاخص‌های گیاهی در محاسبه شاخص سطح برگ محصولات زراعی. نشریه سنجش از دور و GIS ایران، ۱۱(۱)، ۳۳-۴۸.
- حیدری مطلق، آ، نصرالهی، ع، ویسی، ش و شریفی پور، م. ۱۴۰۱. تاثیر به‌کارگیری الگوریتم‌های مختلف دمای سطح زمین در برآورد مقادیر تبخیر-تعرق واقعی. تحقیقات آب و خاک ایران، ۵۳ (۱۲)، ۲۷۲۰-۲۷۰۱.
- سلطانی کاظمی، م.، س. مینایی، ح. شفیع زاده مقدم و ع.ر. مهدویان. ۱۴۰۳. مقایسه چهار الگوریتم GRNN، RF، PLSR و SVR به منظور برآورد رطوبت غلاف نیشکر در طول دوره رشد با استفاده از تصاویر ماهواره سنتینل-۲. نشریه سنجش از دور و GIS ایران، ۱۶(۳)، ۴۷-۶۸.
- عباسی، ف. و شینی‌دشتگل، ع. ۱۳۹۵. توصیه‌هایی برای مصرف بهینه کود در مزارع نیشکر. نشر آموزش کشاورزی، چاپ اول.
- ویسی، ش.، ع. ناصر و س. حمزه. ۱۳۹۷. رابطه بین رطوبت غلاف برگ گیاه نیشکر و شاخص تنش آبی با استفاده از دماسنج مادون قرمز. علوم و مهندسی آبیاری، ۴۰(۴)، ۷۷-۹۰.



- Asrar, G.Q., M. Fuchs, E.T. Kanemasu, and J.L. Hatfield. 1984, Estimating Absorbed Photosynthetic Radiation and Leaf Area Index from Spectral Reflectance in Wheat 1. *Agronomy journal*, 76(2), 300-306.
- Baret, F., V. Houlès, M. Guérif. 2007. Quantification of plant stress using remotesensing observations and crop models: the case of nitrogen management. *J.Exp. Bot.* 58, 869–880.
- Ballester, C., J. Brinkhoff, W.C. Quayle and J. Hornbuckle. 2019. Monitoring the Effects of Water Stress in Cotton Using the Green Red Vegetation Index and Red Edge Ratio. *Remote Sensing*. 11: 7. 873: 1-21
- Bernardino, P. N., R. S. Oliveira, K. Van Meerbeek, M. Hirota, M. N. Furtado, I. A. Sanches. and B. Somers. 2024. Estimating vegetation water content from Sentinel-1 C-band SAR data over savanna and grassland ecosystems. *Environmental Research Letters*, 19(3), 034019.
- Bo, W., B. Fu, G. Qin, G. Xing. and Y. Wang 2017. Evaluation of drought resistance in *Iris germanica* L. based on subordination function and principal component analysis. *Emirates Journal of Food and Agriculture (EJFA)*, 29(10).
- Breiman, L. 1996. Bagging predictors. *Mach Learn.* 26,123–140.
- Choat, B., T.J. Brodribb, C.R. Brodersen, R.A. R. Duursma, López and B.E. Medlyn. 2018 Triggers of tree mortality under drought. *Nature*, 558 531–9.
- Chandrasekar, K., P. Srikanth, A. Chakraborty, K. Choudhary and K. V. Ramana. 2022. Response of crop water indices to soil wetness and vegetation water content. *Advances in Space Research*.
- Chen, S., C. He, Z. Huang, X. Xu, T. Jiang, Z. He, ... and J. He. 2022. Using support vector machine to deal with the missing of solar radiation data in daily reference evapotranspiration estimation in China. *Agricultural and Forest Meteorology*, 316, 108864.
- Chen, H., J. Jeanne Huang and E. McBean. 2019. Partitioning of daily evapotranspiration using a modified shuttleworthwallace model, random Forest and support vector regression, for a cabbage farmland. *Agricultural Water Management*. 105923, 1-12.
- Clevers, J.G and A.A.Gitelson. 2013. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and .3 -*International Journal of Applied Earth Observation and Geoinformation*, 23, 344-351.
- Dugo, V., J.L. Durand and F. Gastal. 2010. Water deficit and nitrogen nutrition of crops. A review. *Agronomy for Sustainable Development*. 30, 529-544.
- Feldman, A. F. 2024. Emerging methods to validate remotely sensed vegetation water content. *Geophysical Research Letters*, 51(14), e2024GL110505.
- Hurcom, S. J and A. R. Harrison. 1998. The NDV<sub>شکل</sub> and spectral decomposition for semi-arid vegetation abundance estimation. *International Journal of Remote Sensing*, 19(16), 3109 -3125.
- Jung, J., M. Maeda, A. Chang, M. Bhandari, A. Ashapure and J. Landivar-Bowles. 2021. The potential of remote sensing and artificial intelligence as tools to improve the resilience of agriculture production systems. *Current Opinion in Biotechnology*, 70, 15-22.
- Katimbo, A., D. R. Rudnick, J. Zhang, Y. Ge, K. C. DeJonge, T. E. Franz ... and J. Duan. 2023. Evaluation of artificial intelligence algorithms with sensor data assimilation in estimating crop evapotranspiration and crop water stress index for irrigation water management. *Smart Agricultural Technology*, 4, 100176.
- Konings, A.G. 2021. Detecting forest response to droughts with global observations of vegetation water content *Glob. Change Biol.* 27 6005–24.
- Liu, L. Y. Li and T. Wu. 2021. Monitoring of Leaf Nitrogen Content in A Citrus Orchard by Landsat 8 OLI Imagery. *Twelfth International Conference on Signal Processing Systems*. 11719(1171905).
- Miphokasap, P., K. Honda, C. Vaiphasa, M. Souris and M. Nagai. 2012. Estimating canopy nitrogen concentration in sugarcane using field imaging spectroscopy. *Remote Sensing*, 4(6), 1651-1670.
- Reuben Mwinuka, P., B. Mbilinyi, W. Mbungu, S. Mourice, H.F. Mahoo and P. Schmitter. 2021. The feasibility of hand-held thermal and UAV-based multispectral imaging for canopy water status assessment and yield prediction of irrigated African eggplant (*Solanum aethopicum* L). *Agricultural Water Management*. 245(106584): 1-11.
- Running, S. W., R. R. Nemani, F. A. Heinsch, M. Zhao, M. Reeves and H. Hashimoto. 2004. A continuous satellite-derived measure of global terrestrial primary production. *BioScience*, 54(6), 547–560.

- Sheng Chou, J., C. Kuo Chiu, M. Farfoura and I. Al-Taharwa. 2011. Optimizing the Prediction Accuracy of Concrete Compressive Strength Based on a Comparison of Data-Mining Techniques. *Journal of Computing in Civil Engineering*. 25,242-253.
- Tucker, C. J. 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150.
- Vapnik, V.N. 1996. The nature of statistical learning theory. *Technometrics* 38 (4), 409.
- Veysi, S., A. A. Naseri, S. Hamzeh and H. Bartholomeus. 2017. A satellite based crop water stress index for irrigation scheduling in sugarcane fields. *Agricultural water management*, 189, 70-86.
- Virnodkar, S., V. K. Pachghare, V. C. Patil and S. K. Jha. 2021. Performance evaluation of RF and SVM for sugarcane classification using sentinel-2 NDVI time-series. In *Progress in Advanced Computing and Intelligent Engineering: Proceedings of ICACIE 2019, Volume 2* (pp. 163-174). Springer Singapore.
- Viña, A., A.A. Gitelson, A.L. Nguy-Robertson, Y. Peng. 2011. Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. *Remote Sensing of Environment*, 115(12), 3468-3478.
- Wang, L., J.J. Qu, X. Hao and E.R. Hunt. 2011. Estimating dry matter content from spectral reflectance for green leaves of different species. *International Journal of Remote Sensing*. 32, 7097–7109.
- Wu, W., M. FenLi, X. Xu, X. PingTang, C. Yang and H. Bin Liu. 2021. The transferability of random forest and support vector machine for estimating daily global solar radiation using sunshine duration over different climate zones. *Theoretical and Applied Climatology*. 1-11.
- Zahedian, A., A. Aboutalebi Jahromi, A. Zakerin, V. Abdossi and A. Mohammadi Torkashv. 2021. Nitroxin bio-fertilizer improves growth parameters, physiological and biochemical attributes of cantaloupe (*Cucumis melo* L.) under water stress conditions. *Journal of the Saudi Society of Agricultural Sciences*. 1-13.
- Zhen-wen, Z and Q. Yao. 2005. Application of the principle component analysis on mango storage characteristic. *Subtropical Plant Science*, 34(02), 25.
- Zhou, Z., Y. Majeed, G. Diverres Naranjo and E. Gambacorta. 2021. Assessment for crop water stress with infrared thermal imagery in precision agriculture: A review and future prospects for deep learning applications. *Computers and Electronics in Agriculture*. 182(106019): 1-10.