



## Research Article

Vol. 24, No. 2, Summer 2026, p. 205-231

## Calibration, Evaluation, and Validation of the Most Appropriate Machine Learning Algorithms for Predicting Corn (*Zea mays* L.) Seed Yield under Biofertilizer Applications: An Interdisciplinary Approach

M. Jahan<sup>1\*</sup>

1- Department of Agrotechnology, Faculty of Agriculture, Ferdowsi University of Mashhad, Mashhad, Iran

(\*- Corresponding author's Email: [jahan@ferdowsi.um.ac.ir](mailto:jahan@ferdowsi.um.ac.ir))

Received: 24 June 2025

Revised: 16 August 2025

Accepted: 29 September 2025

Available Online: 04 October 2025

**How to cite this article:**Jahan, M. (2026). Calibration, evaluation, and validation of the most appropriate machine learning algorithms for predicting corn (*Zea mays* L.) seed yield under biofertilizer applications: An Interdisciplinary Approach. *Iranian Journal of Field Crops Research*, 24(2), 205-231. (In Persian with English abstract)<https://doi.org/10.22067/jcesc.2025.94148.1410>

### Introduction

The escalating degradation of water and soil resources, coupled with global warming, population growth, and climate change, necessitates a reevaluation of food production systems. Corn (*Zea mays* L.), as the third most strategic crop worldwide, faces increasing demand due to rising food needs. Optimizing seed yield under varying environmental conditions is critical, with arbuscular mycorrhizal fungi (AMF) and plant growth-promoting rhizobacteria (PGPR) playing pivotal roles by enhancing nutrient uptake (e.g., phosphorus and nitrogen) and improving plant resilience to stresses and pathogens. However, the complex eco-physiological interactions influencing seed yield remain poorly understood, underscoring the need for advanced modeling tools. Traditional regression models often fail to capture non-linear and interactive relationships among factors such as photosynthesis rates, nutrient levels, and plant anatomical traits. Consequently, machine learning models like Deep Neural Networks (DNN) and Transformers have emerged as powerful alternatives for precision agriculture. This study aims to identify key features affecting corn seed yield using stepwise regression and compare eight machine learning algorithms, Enhanced DNN, Transformer, XGBoost, SVM, ANN, ANFIS, LightGBM, and SVR, to determine the most accurate model for predicting yield and unveiling hidden eco-physiological relationships.

### Materials and Methods

The experiments were conducted over two consecutive years at the research farm of Ferdowsi University of Mashhad, Iran (latitude 36°15'N, longitude 59°28'E, altitude 985 m), located in the Kashafrud River basin. The region features a semi-arid climate with an average annual rainfall of 252 mm and a mean temperature of 15°C, with loamy soil of moderate organic carbon content. The dataset comprised 96 samples and 73 features, collected over two growing seasons, including plant traits (e.g., leaf chlorophyll content via SPAD index, nitrogen concentration) and soil characteristics. Of these, 32 were primary features (e.g., photosynthesis rate, leaf area index, canopy temperature), and 41 were engineered interaction features (e.g., Pmax, Mean\_Leaf Area Index, Canopy Temp, 1\_Root Colonization), designed based on domain knowledge of agro-ecophysiology, soil ecology, AMF, and PGPR. Data were randomly split (random\_state = 42) into 70% training (67 samples), 15% validation (14 samples), and 15% test (15 samples) sets, with standardization applied using StandardScaler. Feature selection employed stepwise backward regression, reducing 73 features to 13 key variables (e.g., Canopy Temp\_3, % P plant) based on adjusted R<sup>2</sup>, multicollinearity, and variance inflation factor (VIF). Among the 15 machine learning algorithms evaluated, eight were configured with model-specific architectures, including an

Authors retain the copyright. This is an open access article distributed under [Creative Commons Attribution 4.0 International License \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/).<https://doi.org/10.22067/jcesc.2025.94148.1410>

Adaptive Neuro-Fuzzy Inference System (ANFIS) implemented using TensorFlow-based layers, a Transformer model with two attention heads, an Artificial Neural Network (ANN) with three hidden layers, and a Support Vector Regression (SVR) model with a radial basis function (RBF) kernel. Model performance was evaluated using the coefficient of determination ( $R^2$ ), root mean square error (RMSE), mean absolute error (MAE), and Willmott's index of agreement (d). In addition, the Shapiro–Wilk test was used to assess the normality of model residuals.

## Results and Discussion

Stepwise regression yielded a model with an adjusted  $R^2$  of 58.53% and a predictive  $R^2$  of 51.06%, identifying 13 features (e.g., Canopy Temp\_3, coefficient = 0.2451,  $p$  = 0.002). Machine learning results identified ANFIS ( $R^2$  = 0.555), the Transformer model ( $R^2$  = 0.545), and ANN ( $R^2$  = 0.518) as the top-performing models, whereas SVM ( $R^2$  = 0.325) exhibited the lowest performance. The Nemenyi diagram ranked ANN first (mean rank = 1.50, Willmott's  $d$  = 0.848), followed by the Transformer model, with a critical distance of 1.11 indicating significant differences ( $\alpha$  = 0.05) between the highest- and lowest-ranked models. Taylor diagrams highlighted the superior performance of the Transformer model (RMSE = 2.834,  $R^2$  = 0.545), with ANFIS and ANN performing similarly. SHAP plots revealed that interactions such as Leaf Area Index–Dry Matter Yield were among the most influential predictors, while SVR shared nine features with the regression model. Correlation analysis grouped the features into physiological (e.g., SPAD\_Mean) and yield-related (e.g., Dry Matter Yield) categories, with strong positive correlations (e.g., SPAD\_2 and cob diameter,  $r$  = 0.82) and strong negative correlations (e.g., Canopy Temp\_Mean and Root Colonization,  $r$  = -0.82). Skewed distributions in KDE plots underscored the need for non-linear models. Force plots (e.g., LightGBM sample) showed features like Leaf Area Index\_Dry Matter Yield (+280.047) driving predictions, while loss curves for Enhanced DNN indicated effective convergence.

## Conclusion

The study suggests that neural network-based models excel in capturing complex eco-physiological interactions, with canopy temperature and root-nitrogen interactions as key predictors, offering insights for sustainable corn production despite data size limitations.

**Keywords:** Arbuscular mycorrhizal fungi, Artificial Neural Network, Eco-physiological interactions, Feature engineering, Input efficiency, Plant growth-promoting rhizobacteria

محسن جهان <sup>۱</sup>id\*

تاریخ پذیرش: ۱۴۰۴/۰۷/۰۷

۱- گروه آگروتکنولوژی، دانشکده کشاورزی، دانشگاه فردوسی مشهد، مشهد، ایران  
 \*- نویسنده مسئول: (Email: [jahan@ferdowsi.um.ac.ir](mailto:jahan@ferdowsi.um.ac.ir))  
<https://doi.org/10.22067/jcscs.2025.94148.1410>

رشد گیاه، اغلب به دلیل تثبیت سریع در خاک‌های کشاورزی، محدود است و قارچ‌های میکوریزا آربوسکولار نقش مهمی در آزادسازی فسفر خاک و افزایش دسترسی آن برای گیاهان ایفا می‌کند (Mitra et al., 2023). به‌طور مشابه، ریزوباکتری‌های تحریک‌کننده رشد گیاه با حل کردن عناصر غذایی، تولید مواد محرک رشد و بهبود توسعه سیستم ریشه، به حاصلخیزی خاک کمک کرده و رشد و عملکرد گیاه را در شرایط نامطلوب بهبود می‌بخشد (Khoso et al., 2024). استفاده ترکیبی از قارچ‌های میکوریزا آربوسکولار و ریزوباکتری‌های تحریک‌کننده رشد گیاه نشان داده است که محتوای کلروفیل برگ را افزایش می‌دهد، بهره‌وری آب را بهبود می‌بخشد و دمای تاج‌پوشش را کاهش می‌دهد، که در نهایت منجر به عملکرد بالاتر گیاه زراعی و تحمل بهتر تنش‌ها می‌شود (Salvador et al., 2022). با این حال، سازوکارهای اکوفیزیولوژیکی که این تعاملات هم‌افزا را پشتیبانی می‌کنند، و همچنین پویایی‌های اکولوژیکی آن‌ها در سیستم‌های زراعی ذرت، هنوز به خوبی شناخته نشده‌اند و نیازمند ابزارهای پیشرفته برای کمی‌سازی مشارکت و بهینه‌سازی کاربرد آن‌ها است (Bao et al., 2022).

در این مطالعه، ابتدا بین ویژگی‌های رشد و نمو ذرت و ویژگی‌های خاک، ضرایب همبستگی محاسبه شدند. سپس، با استفاده از روش رگرسیون چند متغیره گام‌به‌گام پس‌رونده<sup>۴</sup>، مهم‌ترین تأثیرگذارترین متغیرها بر عملکرد دانه ذرت شناسایی شدند. در ادامه و به‌منظور بهره‌گیری از مزایای الگوریتم‌های یادگیری ماشین همچون شناسایی و تبیین روابط پیچیده غیرخطی، اعتبارسنجی متقابل، انتخاب دقیق‌ترین و پایدارترین مدل، و تعمیم‌پذیری بیشتر، هاپرپارامترهای ۱۵ الگوریتم یادگیری ماشین تنظیم و اجرا شدند. پس از ارزیابی‌های اولیه، هشت الگوریتم برتر شامل سه الگوریتم درختی و چهار الگوریتم مبتنی بر شبکه عصبی مصنوعی و یک الگوریتم بینابینی مورد واسنجی، ارزیابی و مقایسه قرار گرفتند. هدف نهایی این بود که تعیین شود کدام مدل با استفاده از ویژگی‌های تعاملی (اینتراکشن) می‌تواند بهترین دقت و کارایی را داشته باشد و روابط اکوفیزیولوژیکی پنهان در شکل‌گیری عملکرد دانه را آشکار سازد.

## مواد و روش‌ها

### مکان اجرای آزمایش

آزمایش‌ها طی دو سال متوالی در مزرعه تحقیقاتی دانشکده کشاورزی دانشگاه فردوسی مشهد (موقعیت: عرض جغرافیایی ۳۶ درجه و ۱۵ دقیقه شمالی، طول جغرافیایی ۵۹ درجه و ۲۸ دقیقه

محرک رشد گیاه<sup>۱</sup>، به دلیل پتانسیل آن‌ها در بهبود رشد گیاه، عملکرد و تحمل تنش بسیار مورد توجه قرار گرفته‌اند (Brar et al., 2024). قارچ‌های میکوریزا آربوسکولار و ریزوباکتری‌های محرک رشد گیاه با افزایش جذب عناصر غذایی مثل فسفر و نیتروژن، همچنین بهبود مقاومت گیاه به تنش‌ها و عوامل بیماری‌زا، نقش مهمی در بهبود عملکرد ذرت دارند. با وجود این، روابط پیچیده اکوفیزیولوژیکی بین این عوامل و عملکرد دانه، هنوز به خوبی شناخته نشده و نیاز به ابزارهای پیشرفته برای مدل‌سازی دارد.

پیش‌بینی دقیق عملکرد گیاهان زراعی از موضوعات کلیدی برای بهبود تولید غذا و پایداری اقتصادی می‌باشد. ذرت سومین گیاه زراعی مهم و راهبردی در سطح جهانی بوده و پیش‌بینی دقیق عملکرد دانه آن برای بهینه‌سازی روش‌های کشاورزی، مدیریت منابع و درک بهتر تعاملات اکوفیزیولوژیکی در سیستم‌های زراعی از اهمیت زیادی برخوردار است. با توجه به پیچیدگی داده‌های کشاورزی که شامل متغیرهای متعدد، روابط غیرخطی و نویز زیاد است، اخیراً استفاده از مدل‌های یادگیری ماشین به عنوان ابزاری قدرتمند برای افزایش دقت پیش‌بینی‌ها مطرح شده است (Fashoto et al., 2021; Nayak et al., 2022; Pentos et al., 2024; Wang et al., 2024). مدل‌های سنتی (رگرسیونی) معمولاً نمی‌توانند روابط غیرخطی و تعاملی بین عوامل اکوفیزیولوژیکی مثل نرخ فتوسنتز، سطح عناصر غذایی، و ویژگی‌های آناتومیک (ساختاری) گیاه را به خوبی شبیه‌سازی کنند (Khaki et al., 2020; Pentos et al., 2022). به همین دلیل، الگوریتم‌های یادگیری ماشین مثل شبکه‌های عصبی عمیق<sup>۲</sup> و الگوریتم‌های جدیدتر مثل ترنسفورمر<sup>۳</sup> به عنوان ابزارهای قدرتمند برای این کار شناخته شده‌اند (Nayak et al., 2022). علاوه بر این، تکنیک‌های تفسیری مانند تحلیل SHAP (SHapley Additive Model Explanations) بینش‌های عمیق‌تری درباره اهمیت هر ویژگی و اثرات علی تغییرات خاص ارائه می‌دهند (Abekoon et al., 2025). این روش‌ها به پژوهشگران اجازه می‌دهند که نه تنها عملکرد ذرت را پیش‌بینی کنند، بلکه درک کنند که چگونه کودهای زیستی و سایر نهاده‌های طبیعی بر ویژگی‌های فیزیولوژیکی کلیدی مانند نرخ فتوسنتز، شاخص سطح برگ و کارایی مصرف آب تحت شرایط مختلف محیطی تأثیر می‌گذارند.

قارچ‌های میکوریزا آربوسکولار با بیش از ۹۰ درصد گیاهان خشکی از جمله ذرت، رابطه هم‌زیستی متقابل برقرار می‌کنند و جذب عناصر غذایی (به‌ویژه فسفر (P)) را افزایش داده و مقاومت گیاه را در برابر تنش‌های محیطی بهبود می‌بخشند (Bhupenchandra et al., 2024). فراهمی فسفر، به عنوان دومین عنصر غذایی ضروری برای

- 1- Plant Growth Promoting Rhizobacteria (PGPR)
- 2- Deep Neural Networks (DNN)
- 3- Transformer

4- Bckward Elimination Stepwise Regression Method

تأثیر تنش دمایی بر کارکرد ریشه را مشخص کند. ۴۱ ویژگی اینتراکشن به ۳۲ ویژگی اصلی اضافه شد تا الگوریتم‌های یادگیری ماشین بتوانند الگوهای پنهان بین داده‌ها را دقیق‌تر پیدا کنند.

### پیش‌پردازش

در مرحله آماده‌سازی داده‌ها، همه ویژگی‌های عددی با استفاده از ماژول StandardScaler در پایتون استاندارد شدند. این کار مقیاس ویژگی‌ها را یکسان کرده و باعث می‌شود که مدل‌هایی مثل SVR و Enhanced DNN که به مقیاس حساس هستند، عملکرد بهتری داشته باشند.

**انتخاب ویژگی‌ها (فیچرها):** از روش رگرسیون گام‌به‌گام پس‌رونده برای انتخاب ویژگی‌های مؤثر استفاده شد، به این ترتیب که ابتدا مدل با همه ۷۳ ویژگی اجرا شد و سپس طی چندین مرحله و به‌صورت تکراری<sup>۳</sup> ویژگی‌های کم‌اهمیت حذف شدند. در این مرحله، معیارهایی مثل ضریب تبیین، هم‌خطی چندگانه<sup>۴</sup> و فاکتور تورم واریانس<sup>۵</sup> در نظر گرفته شدند. در نهایت، از بین ۷۳ ویژگی، ۱۳ ویژگی مهم‌تر انتخاب شدند که فهرست آن‌ها در جدول ۱ آورده شده است.

دلیل اینکه با وجود مدل رگرسیونی گام‌به‌گام پس‌رونده، چندین الگوریتم یادگیری ماشین مورد استفاده و ارزیابی قرار گرفتند، این است که مدل‌های رگرسیونی به‌صورت جعبه سیاه عمل کرده و توانایی کشف روابط پیچیده و غیرخطی را ندارند. علاوه‌بر این، مدل‌های رگرسیونی همواره با خطر بیش‌برازش<sup>۶</sup> و کم‌برازش<sup>۷</sup> مواجه هستند.

### الگوریتم‌ها، تنظیمات و پارامترها

به‌منظور شناسایی الگوریتم‌های متناسب با مجموعه داده، ابتدا ۱۵ الگوریتم (۱۴ الگوریتم مستقل و یک الگوریتم ترکیبی) مورد بررسی و ارزیابی‌های اولیه قرار گرفتند. به این ترتیب که ابتدا هایپرپارامترهای این الگوریتم‌ها تنظیم شدند و سپس بر روی داده‌ها آموزش داده شدند. در ادامه، هایپرپارامترها<sup>۸</sup> از طریق روش‌هایی شامل تعیین اعتبار متقابل، گرید سرچ و آزمون و خطا بهینه شدند. در نهایت، خروجی این الگوریتم‌ها مورد واریسی و ارزیابی قرار گرفت. در ادامه، به سبب عدم

شرقی، ارتفاع ۹۸۵ متر از سطح دریا) انجام شد. این منطقه در حوضه رودخانه کشفرد در شمال شرق ایران قرار دارد. آب‌وهوای منطقه، نیمه‌خشک با میانگین بارندگی سالانه ۲۵۲ میلی‌متر و دمای متوسط ۱۵ درجه سانتی‌گراد می‌باشد. خاک محل آزمایش، لومی با محتوای کربن آلی متوسط بود.

### منشأ مجموعه داده

مجموعه داده شامل ۹۶ نمونه و ۷۳ ویژگی<sup>۱</sup> بود که طی دو فصل رشد اندازه‌گیری و ثبت شده بودند. این داده‌ها شامل ویژگی‌های گیاهی مثل محتوای کلروفیل برگ (شاخص SPAD)، غلظت نیتروژن گیاه و ویژگی‌های ریشه، به‌علاوه ویژگی‌های خاک بود (شرح کامل ویژگی‌ها به‌دلیل محدودیت صفحات در این متن آورده نشده است). از این ۷۳ ویژگی، ۳۲ ویژگی اصلی بودند (مثل نرخ فتوسنتز، شاخص سطح برگ و دمای تاج‌پوشش) و ۴۱ ویژگی، ویژگی‌های تعاملی (اینتراکشن) مهندسی‌شده بودند (مثل PmaxMean\_LeafAreaIndex و CanopyTemp1\_RootColonization). داده‌ها با استفاده از تقسیم تصادفی (random\_state=42) به ۷۰ درصد آموزش (۶۷ نمونه)، ۱۵ درصد اعتبارسنجی (۱۴ نمونه) و ۱۵ درصد تست (۱۵ نمونه) تقسیم شدند. برای استانداردسازی داده‌ها، از ماژول StandardScaler استفاده شد.

### مهندسی ویژگی‌های تعاملی (اینتراکشن)

ویژگی‌های اینتراکشن به‌منظور مدل‌سازی روابط پیچیده بین متغیرها ساخته شدند. در داده‌های زراعی، تعاملات بین متغیرها معمولاً غیرخطی و به هم وابسته است. مثلاً تأثیر دمای تاج‌پوشش روی عملکرد دانه ممکن است به‌میزان کولونیزاسیون ریشه بستگی داشته باشد. معیار انتخاب ویژگی‌های اینتراکشن، دانش حوزه‌ای<sup>۲</sup> و در نظر گرفتن روابط و دانش اکرواکوفیزیولوژیکی، اکولوژی خاک، اکوفیزیولوژی قارچ‌های میکوریز آربوسکولار و ریزوباکتری‌های محرک رشد گیاه (که جزو تیمارهای آزمایش بودند) بود (برای آگاهی از جزئیات آزمایش‌های مزرعه‌ای به منبع <https://doi.org/10.1007/s44396-025-00001-0> مراجعه شود). برای مثال، RootColonization\_SPAD1 تعامل بین کولونیزاسیون ریشه و محتوای کلروفیل را نشان می‌دهد، که رابطه بین جذب عناصر غذایی توسط ریشه و کارایی سیستم فتوسنتزی گیاه را منعکس می‌کند. CanopyTemp1\_RootColonization این ویژگی تعامل بین دمای تاج‌پوشش و کولونیزاسیون ریشه را نشان می‌دهد و می‌تواند

3- Iterative

4- Multicollinearity

5- Variance Inflation Factor (VIF)

6- Overfitting

7- Underfitting

۸- تنظیماتی هستند که قبل از آموزش مدل باید توسط کاربر تعیین شوند (و مدل برخلاف پارامترها، آن‌ها را از داده‌ها یاد نمی‌گیرد)، مثلاً تعداد لایه‌ها یا نورون‌ها در شبکه عصبی، نرخ یادگیری (Learning rate)، یا تعداد درخت‌ها در رندوم فورتست.

1- Feature

2- Domain knowledge

ترنسفورمر و اس وی آر بود، به دلیل مشابهت معیارهای ارزیابی آن با تک الگوریتم‌های سازنده آن، از مجموعه مورد بررسی حذف شد و تجزیه و تحلیل داده‌ها با هشت الگوریتم که شرح آن‌ها در ادامه می‌آید، انجام گرفت.

تناسب روش شناختی برخی الگوریتم‌ها با ماهیت مجموعه داده، شش الگوریتم شامل CNN (Convolutional Neural Network)، LSTM (Long Short-Term Memory)، Random Forest، CatBoost، TabNet، K-NN (K-Nearest Neighbors) حذف شدند. الگوریتم ترکیبی مورد بررسی که حاصل تلفیق دو الگوریتم

جدول ۱- سیزده ویژگی گیاهی-خاکی انتخاب شده توسط مدل رگرسیون گام به گام پس‌رونده

Table 1- Thirteen plant-soil features selected by the stepwise backward regression model

| ویژگی                                                    | Feature                                       |
|----------------------------------------------------------|-----------------------------------------------|
| دمای تاج‌پوشش در مرحله کاکل‌دهی                          | Canopy Temp_3                                 |
| درصد فسفر اندام‌های گیاهی                                | % P plant                                     |
| درصد نیتروژن کل خاک                                      | % N soil                                      |
| اثر متقابل ارتفاع بوته و تعداد بلال                      | PlantHeight_CobNumber                         |
| اثر متقابل درصد نیتروژن اندام‌های گیاهی و طول ویژه ریشه  | Nplant_SpecificRootLength                     |
| اثر متقابل شاخص سطح برگ و میانگین عدد اسپد               | Leaf Area Index_SPAD_Mean                     |
| اثر متقابل شاخص سطح برگ و عملکرد ماده خشک                | Leaf Area Index_Dry Matter Yield              |
| اثر متقابل درصد کلونیزاسیون ریشه و عملکرد ماده خشک       | Root Colonization_Dry Matter Yield            |
| اثر متقابل قطر ساقه و عملکرد ماده خشک                    | Stem Diameter_Dry Matter Yield                |
| مجدور طول ویژه ریشه                                      | (Specific Root Length) ^2                     |
| اثر متقابل مجذور میانگین دمای تاج‌پوشش و شاخص سطح برگ    | (Canopy Temp_Mean) ^2 * Leaf Area Index       |
| اثر متقابل مجذور درصد کلونیزاسیون ریشه و طول ویژه ریشه   | (Root Colonization) ^2 * Specific Root Length |
| اثر متقابل مجذور درصد کلونیزاسیون ریشه و عملکرد ماده خشک | (Specific Root Length) ^2 * Dry Matter Yield  |

#### ترنسفورمر (Transformer)

- معماری: دو لایه attention با دو سر (head) و feed-forward dimension<sup>4</sup> برابر با ۳۲
- نرخ Dropout<sup>5</sup> برابر با ۰/۱
- نرخ یادگیری: ۰/۰۰۱ با بهینه‌ساز AdamW
- تنظیمات: تعداد epochها برابر با ۱۵۰ با early stopping
- patience برابر با ۱۵ epoch
- نحوه تنظیم: تنظیم دستی برای تعداد لایه‌ها، نورون‌ها، نرخ

#### سیستم استنتاج فازی عصبی تطبیقی (Adaptive

#### (Neuro-Fuzzy Inference System (ANFIS)

- معماری: یک مدل ترکیبی با TensorFlow شامل:
- لایه ورودی با تعداد نورون‌های برابر با تعداد ویژگی‌ها (تعداد ستون‌های X)
- یک لایه مخفی با ۳۲ نورون و فعال‌ساز sigmoid (شبیه‌سازی توابع عضویت)
- یک لایه مخفی با ۱۶ نورون و فعال‌ساز ReLU<sup>1</sup> (قوانین فازی)
- لایه خروجی با یک نورون (بدون فعال‌ساز)
- نرخ یادگیری: ۰/۰۰۱ با بهینه‌ساز Adam
- تنظیمات: تعداد epochها ۱۰۰ با batch size<sup>3</sup> برابر ۸.

- تعداد نمونه‌هایی که در هر مرحله از آموزش به مدل داده می‌شود تا پارامترها به‌روزرسانی شوند. مثلاً اگر بچ ساز ۳۲ باشد، یعنی مدل هر بار روی ۳۲ نمونه داده آموزش می‌بیند. اگر بچ سائز کوچک‌تر باشد حافظه کمتری نیاز است، ولی آموزش ممکن است کندتر انجام گیرد.
- اندازه لایه مخفی در به شبکه عصبی پیش‌خور (Feed-Forward) یعنی در آن لایه ۳۲ نورون وجود دارد که داده‌ها را پردازش می‌کنند.
- درصد نورون‌هایی که در هر لایه شبکه عصبی به‌صورت تصادفی در حین آموزش غیرفعال (خاموش) می‌شوند تا از بیش‌برازش (Overfitting) جلوگیری شود، مثلاً نرخ ۰/۰۵ یعنی ۵۰ درصد نورون‌ها به‌طور تصادفی خاموش می‌شوند.
- یعنی اگر مدل به مدت ۱۵ دور آموزش (Epoch) روی داده‌های اعتبارسنجی (Validation) بهبود پیدا نکند (مثلاً خطا کم نشود)، آموزش متوقف می‌شود تا از بیش‌برازش (Overfitting) جلوگیری گردد.

- یک تابع فعال‌سازی (Rectified Linear Unit) که خروجی نورون را اگر مثبت باشد، همان عدد را برمی‌گرداند، و اگر منفی باشد صفر می‌کند مثلاً:  $f(x) = \max(0, x)$  یادگیری را به‌طور ساده و سریع بهتر می‌کند.
- در یادگیری ماشین، اپوک یعنی یک دور کامل که الگوریتم کل داده‌های آموزشی را یک بار می‌بیند و پردازش می‌کند. مثلاً اگر ۱۰۰۰ نمونه داده آموزشی داشته باشیم و Batch Size برابر با ۱۰۰ باشد، در هر اپوک مدل ۱۰ بار به‌روزرسانی می‌شود تا کل داده‌ها رو ببیند. بنابراین، تعداد اپوک‌ها نشان می‌دهد که مدل چند بار کل داده‌ها را مرور کرده است.

- پارامترها: تعداد estimators برابر با ۱۰۰، نرخ یادگیری ۰/۰۵، حداکثر عمق ۴
- تنظیمات: استفاده از  $L_2$  (regularization<sup>4</sup>) به منظور کاهش بیش‌برازش
- نحوه تنظیم: GridSearchCV برای نرخ یادگیری و تعداد estimators.

#### شبکه عصبی عمیق بهبودیافته (Enhanced Deep Neural Network (EDNN)

- معماری: پنج لایه مخفی با ۱۲۸، ۶۴، ۳۲، ۱۶، و ۸ نورون، تعداد epoch ۲۰۰
- استفاده از سازوکار ReduceLRonPlateau برای تنظیم نرخ یادگیری لایه‌های مخفی و خطی برای خروجی
  - نرخ Dropout برابر با ۰/۲ برای جلوگیری از بیش‌برازش
  - تنظیمات: استفاده از Batch Normalization<sup>5</sup> به منظور پایداری یادگیری، استفاده از بهینه‌ساز Adam<sup>6</sup> (نرخ یادگیری ۰/۰۰۰۱)، توقف زودهنگام Early stopping با صبر ۵۰ دوره
  - تنظیم هایپرپارامترها: با GridSearchCV برای نرخ یادگیری و تعداد نورون‌ها

#### رگرسیون بردار پشتیبان (Support Vector Machine (SVM)

معماری: کرنل خطی (linear) با پارامتر  $C=1.0$

۴- تکنیکی در یادگیری ماشین برای جلوگیری از بیش‌برازش است که با اضافه کردن یک جریمه به تابع خطا (Loss Function)، مدل را ساده‌تر نگه می‌دارد. مثلاً در رگرسیون،  $L_1$  (Lasso) یا  $L_2$  (Ridge) وزن‌های مدل را محدود می‌کند تا خیلی پیچیده نشود.

۵- به اختصار BatchNorm یک تکنیک در یادگیری ماشین است که برای بهبود سرعت و پایداری آموزش شبکه‌های عصبی استفاده می‌شود. به‌طور خلاصه: در هر لایه شبکه عصبی، خروجی‌ها را در هر دسته (Batch) نرمال‌سازی می‌کند، یعنی میانگین آن‌ها را نزدیک صفر و واریانس را نزدیک یک می‌کند. سپس، با دو پارامتر (مقیاس و جابجایی) که یاد گرفته می‌شوند، خروجی را تنظیم می‌کند. این کار باعث می‌شود که گرادینت‌ها پایدارتر شوند، آموزش سریع‌تر انجام گیرد و مدل کمتر به مقادیر اولیه حساس باشد. معمولاً در شبکه‌های عمیق مثل CNN‌ها قبل یا بعد از لایه‌های فعال‌ساز مثل ReLU استفاده می‌شود. استفاده از بچ نورمالیزاسیون کاهش مشکلاتی مثل ناپدید شدن گرادینت، کاهش بیش‌برازش و امکان استفاده از نرخ یادگیری بالاتر را به دنبال دارد.

۶- یک الگوریتم بهینه‌سازی مبتنی بر گرادینت که ترکیبی از مونتوم و تطبیق نرخ یادگیری است. این الگوریتم، به‌جای یک نرخ یادگیری ثابت، برای هر پارامتر نرخ یادگیری را به‌صورت تطبیقی تنظیم می‌کند. سریع و کارآمد است و برای شبکه‌های عصبی عمیق مورد استفاده قرار می‌گیرد.

یادگیری، تعداد سرها و feed-forward dimension (بدون استفاده از GridSearchCV یا جست‌وجوی تصادفی).

#### شبکه عصبی مصنوعی (Artificial Neural Network (ANN)

- معماری: سه لایه مخفی با ۶۴، ۳۲ و ۱۶ نورون
- نرخ یادگیری ۰/۰۰۱، فعال‌ساز ReLU برای لایه‌های مخفی، بدون فعال‌ساز برای لایه خروجی
  - نرخ Dropout برابر با ۰/۲ به منظور کاهش بیش‌برازش
  - آموزش با ۱۰۰ epoch و batch size برابر ۸
  - بهینه‌سازی برای نرخ یادگیری و تعداد لایه‌ها، با استفاده از GridSearchCV

#### بردار پشتیبان رگرسیون (Support Vector Regression (SVR)

معماری: کرنل RBF (Radial Basis Function)

- پارامترها  $C=1.0$ ،  $\epsilon=0.1$
- تنظیمات: مقیاس‌بندی داده‌ها قبل از آموزش
- نحوه تنظیم GridSearchCV: برای C و epsilon

#### لایت جی بی ام (LightGBM)

- پارامترها: تعداد estimators برابر با ۲۰۰، نرخ یادگیری ۰/۱، حداکثر عمق ۵
- تنظیمات: استفاده از تکنیک early stopping با ۵۰ دور صبر
- نحوه تنظیم: جست‌وجوی تصادفی (Random Search<sup>2</sup>) برای تعداد estimators<sup>3</sup> و عمق.

#### ایکس جی بوست (Extrem Gradient Boosting (XGBoost)

۱- جست‌جوی شبکه‌ای با اعتبارسنجی متقابل GridSearch Cross Validation: تمام ترکیب‌های ممکن از پارامترهای الگوریتم (مثلاً عمق درخت، تعداد درخت، نرخ یادگیری و غیره) را تولید کرده و آن‌ها را تست می‌کند و در ادامه بهترین آن‌ها را بر اساس دقت (مثلاً  $R^2$ ) برای متغیر هدف (مثلاً عملکرد دانه) پیدا می‌کند.

۲- با انتخاب تصادفی اما هدفمند، امکان بهینه‌سازی سریع‌تر را در مسائل با فضای پارامتر گسترده فراهم می‌سازد.

۳- مدل‌ها یا الگوریتم‌هایی که در یادگیری ماشین برای پیش‌بینی یا برآورد کردن استفاده می‌شوند. مثلاً در یک جنگل تصادفی، هر درخت تصمیم یک برآوردگر است، در Scikit-learn، برآوردگرها اشیایی هستند که داده را می‌گیرند و با متدهایی مثل fit و predict کار می‌کنند.



- تنظیمات: مقیاس‌بندی داده‌ها (StandardScaler) قبل از آموزش. مدل با داده‌های استاندارد شده آموزش دید.
- نحوه تنظیم: تنظیم دستی برای کرنل و مقدار C، بدون استفاده از GridSearchCV یا جست‌وجوی تصادفی.

### ارزیابی و تعیین اعتبار

عملکرد مدل‌ها با  $R^2$  (ضریب تعیین)، RMSE (جذر میانگین مربعات خطا)، MAE (میانگین قدرمطلق خطا) و Willmott's d (شاخص توافق ویلموت) سنجیده شد. به‌منظور تحلیل خطاها، از آزمون شاپیرو-ویلک<sup>۱</sup> برای بررسی نرمال بودن باقی‌مانده‌ها استفاده شد.

### نرم‌افزارهای مورد استفاده

تحلیل‌ها با استفاده از پایتون نسخه ۳/۹ در محیط Spyder (Scientific PYthon Development EnviRonment) 6.0.4 انجام شد و از کتابخانه‌هایی مانند TensorFlow برای ساخت و آموزش مدل‌ها، scikit-learn برای پیش‌پردازش داده‌ها و تقسیم‌بندی آن‌ها، و Matplotlib و Pandas برای تولید نمودارها بهره گرفته شد. استانداردسازی داده‌ها با استفاده از StandardScaler از کتابخانه scikit-learn انجام شد تا ویژگی‌ها میانگین صفر و انحراف معیار یک داشته باشند، که این موضوع برای آموزش مؤثر شبکه‌های عصبی ضروری است. تفسیر خروجی‌های الگوریتم‌ها و رسم نمودارهای وابستگی جزئی و نمودارهای تصمیم با استفاده از کتابخانه SHAP (Shapley Additive exPlanations) صورت گرفت.

### نتایج و بحث

به‌منظور توسعه یک مدل رگرسیون خطی برای پیش‌بینی عملکرد دانه در گیاه ذرت، از روش رگرسیون گام‌به‌گام حذفی پس‌رونده با سطح اهمیت حذف<sup>۲</sup> ۰/۰۵ استفاده شد. ابتدا مجموعه داده‌ای با ۷۳ ویژگی شامل متغیرهای فیزیولوژیکی، مورفولوژیکی، و شیمیایی خاک و گیاه جمع‌آوری شد. برای کاهش هم‌خطی‌چندگانه و بهبود تعمیم‌پذیری مدل، مدل‌های مختلف ارزیابی و مقایسه شدند تا این که مدل نهایی با ۱۳ ویژگی انتخاب شد (جدول ۲). این مدل ضریب تعیین تعدیل‌شده<sup>۳</sup> برابر ۶۴/۲۰ درصد و ضریب تعیین پیش‌بینی<sup>۴</sup> برابر ۵۱/۰۶ درصد را به دست آورد، که نشان‌دهنده دقت قابل قبول و تعمیم‌پذیری مناسب مدل است. معادله رگرسیونی و

ضرایب ویژگی‌ها در معادله<sup>۱</sup> نشان داده شده است. ضرایب ویژگی‌ها به همراه اشتباه استاندارد ضرایب، پی ویلیو و مقدار عامل تورم واریانس هر ویژگی و ضریب تبیین مدل به‌ترتیب در جدول‌های ۲ و ۳ نشان داده شده است. از آنجا که قبل از تحلیل، داده‌ها استاندارد شدند بنابراین، ضرایب رگرسیونی قابل مقایسه با یکدیگر بوده و میزان اهمیت هر متغیر در پیش‌بینی عملکرد دانه را نشان می‌دهند.

### ضرایب همبستگی بین ویژگی‌های تشخیص داده‌شده توسط مدل رگرسیونی

ضرایب همبستگی بین ۱۳ ویژگی برتر تشخیص داده‌شده توسط مدل گام‌به‌گام پس‌رونده، به همراه دندروگرام حاصل از خوشه‌بندی سلسله مراتبی متغیرها و نمودار پراکندگی و توزیع‌های تخمین چگالی هسته‌ای<sup>۵</sup> آن‌ها در شکل ۱ نشان داده شده است. این شکل، الگوها، گروه‌بندی‌ها و وابستگی‌های بین متغیرها را به‌خوبی نشان می‌دهد.

### کلاسترینگ سلسله‌مراتبی (دندروگرام)

ترتیب کلاسترینگ (از چپ به راست در دندروگرام) شباهت در الگوهای همبستگی را منعکس می‌کند، به‌طوری که ویژگی‌های نزدیک به هم در یک خوشه گروه‌بندی شده‌اند. دندروگرام حاصل، ویژگی‌ها را در دو خوشه، مطابق دانش اکوفیزیولوژی گروه‌بندی کرد:

- **خوشه ۱:** شامل SPAD\_Mean، SPAD\_2 و Nplant\_SpecificRootLength است. این متغیرها که به خصوصیات فیزیولوژیکی گیاه (مثل محتوای کلروفیل و ویژگی‌های ریشه) مربوط هستند، ارتباط قوی‌ای با یکدیگر دارند.

### • خوشه ۲: شامل Leaf Area، Dry Matter Yield

Index\_SPAD\_Mean و Seed Yield است. این خوشه متغیرهای مرتبط با عملکرد ماده خشک، محتوای کلروفیل برگ‌ها و شاخص سطح برگ را گروه‌بندی می‌کند و وابستگی متقابل آن‌ها را مورد تأکید قرار می‌دهد.

- 1- Shapiro-Wilk
- 2- Alpha to remove
- 3- R-squared adjusted
- 4- R-squared predicted

5- Kernel density estimation (KDE)



(۱)

$$\begin{aligned} \text{Seed yield} = & 0.0000 + 0.2451 \text{ Canopy Temp}_3 - 0.488 \% \text{ P plant} + 0.395 \% \text{ N soil} \\ & + 0.3387 \text{ PlantHeight\_CobNumber} + 0.298 \text{ Nplant\_SpecificRootLength} \\ & + 0.479 \text{ Leaf Area Index\_SPAD\_Mean} - 0.911 \text{ Leaf Area Index\_Dry Matter Yield} \\ & + 0.669 \text{ Root Colonization\_Dry Matter Yield} + 0.642 \text{ Stem Diameter\_Dry Matter Yield} \\ & + 0.742 (\text{Specific Root Length})^2 + 0.453 (\text{Canopy Temp\_Mean})^2 \times \text{Leaf Area Index} - \\ & 0.643 (\text{Root Colonization})^2 \times \text{SpecificRootLength} - 0.531 (\text{Specific Root Length})^2 \times \text{Dry Matter Yield} \end{aligned}$$

جدول ۲- ضرایب ویژگی‌ها به همراه اشتباه استاندارد ضرایب، پی‌ولیو و مقدار عامل تورم واریانس<sup>۱</sup> هر ویژگی و ضریب تبیین مدل  
Table 2- Feature coefficients with standard errors, p-values, and variance inflation factors for each feature and the model's coefficient of determination

| عامل تورم واریانس | مقدار پی | مقدار تی | خطای استاندارد ضریب | ضریب   | جمله                                                                                                               |
|-------------------|----------|----------|---------------------|--------|--------------------------------------------------------------------------------------------------------------------|
| VIF               | P-value  | T-value  | SE Coef             | Coef   | Term                                                                                                               |
|                   | 1.000    | 0.00     | 0.0657              | 0.0000 | ثابت<br>Constant                                                                                                   |
| 1.31              | 0.002    | 3.24     | 0.0757              | 0.2451 | دمای تاج‌پوشش در مرحله کاکل‌دهی<br>Canopy Temp <sub>3</sub>                                                        |
| 5.77              | 0.003    | -3.07    | 0.159               | -0.488 | درصد فسفر اندام‌های گیاهی<br>% P plant                                                                             |
| 6.40              | 0.021    | 2.36     | 0.167               | 0.395  | درصد نیتروژن کل خاک<br>%N soil                                                                                     |
| 1.56              | 0.000    | 4.11     | 0.0824              | 0.3387 | اثر متقابل ارتفاع بوته و تعداد بلال<br>PlantHeight_CobNumber                                                       |
| 3.97              | 0.026    | 2.27     | 0.132               | 0.298  | اثر متقابل درصد نیتروژن اندام‌های گیاهی و طول ویژه ریشه<br>Nplant_SpecificRootLength                               |
| 3.86              | 0.000    | 3.69     | 0.130               | 0.479  | اثر متقابل شاخص سطح برگ و میانگین عدد اسپد<br>Leaf Area Index_SPAD_Mean                                            |
| 27.88             | 0.011    | -2.61    | 0.349               | -0.911 | اثر متقابل شاخص سطح برگ و عملکرد ماده خشک<br>Leaf Area Index_Dry Matter Yield                                      |
| 15.86             | 0.013    | 2.54     | 0.263               | 0.669  | اثر متقابل درصد کلونیزاسیون ریشه و عملکرد ماده خشک<br>Root Colonization_Dry Matter Yield                           |
| 14.53             | 0.013    | 2.55     | 0.252               | 0.642  | اثر متقابل قطر ساقه و عملکرد ماده خشک<br>Stem Diameter_Dry Matter Yield                                            |
| 23.40             | 0.023    | 2.32     | 0.320               | 0.742  | مجذور طول ویژه ریشه<br>(Specific Root Length) <sup>2</sup>                                                         |
| 8.50              | 0.021    | 2.35     | 0.193               | 0.453  | اثر متقابل مجذور میانگین دمای تاج‌پوشش و شاخص سطح برگ<br>(Canopy Temp_Mean) <sup>2</sup> × Leaf AreaIndex          |
| 14.09             | 0.011    | -2.59    | 0.248               | -0.643 | اثر متقابل مجذور درصد کلونیزاسیون ریشه و طول ویژه ریشه<br>(Root Colonization) <sup>2</sup> × SpecificRootLength    |
| 14.35             | 0.037    | -2.12    | 0.250               | -0.531 | اثر متقابل مجذور درصد کلونیزاسیون ریشه و عملکرد ماده خشک<br>(Specific Root Length) <sup>2</sup> × Dry Matter Yield |

جدول ۳- ضریب تبیین تعدیل شده و پیش‌بینی مدل رگرسیونی گام‌به‌گام در پیش‌بینی عملکرد دانه ذرت

Table 3- Adjusted and predicted coefficients of determination for the stepwise regression model in predicting corn grain yield

| S        | R-sq   | R-sq(adj) | R-sq(pred) |
|----------|--------|-----------|------------|
| 0.643993 | 64.20% | 58.53%    | 51.06%     |

را به زیرگروه‌های معنی‌دار تقسیم کرده‌اند.

- **توزیع‌های چندوجهی:** ویژگی‌هایی مثل Canopy Temp\_Mean و Temp و Leaf چندین قله دارند که نشان‌دهنده وجود زیرگروه‌های متمایز (شامل تیمارها و شرایط آزمایشی مختلف) در داده‌ها است.
- **توزیع‌های آریب:** ویژگی‌هایی مثل Seed Yield و Dry Matter Yield توزیع‌های آریب دارند، که نشان‌دهنده غیرخطی بودن روابط این داده‌ها است و حاکی از آن است که برای مدل‌سازی نیاز به مدل‌های قوی‌تر (مانند مدل‌های یادگیری ماشین) می‌باشد.
- **نمودارهای پراکندگی در نیمه پایینی ماتریس (روابط زوجی)**
- **روندهای خطی قوی:** نمودار پراکندگی بین SPAD\_Mean و SPAD\_2 یک رابطه خطی قوی را نشان می‌دهد که با همبستگی بالای این دو ویژگی سازگار است.
- **الگوهای پراکنده:** نمودار پراکندگی بین Canopy Temp\_Mean و Seed Yield پراکندگی بیشتری دارد که نشان‌دهنده یک رابطه ضعیف‌تر یا غیرخطی هست (با وجود همبستگی منفی).

### نتیجه‌گیری و توصیه‌ها

- **تأثیرات مثبت:** Leaf Area و Dry Matter Yield Index\_SPAD\_Mean همبستگی‌های مثبتی با عملکرد دانه دارند که نشان می‌دهد زیست‌توده بالاتر و سطح برگ / محتوای کلروفیل بیشتر، به افزایش تولید دانه کمک می‌کند.
- **تأثیرات منفی:** Canopy Temp\_Mean همبستگی منفی با عملکرد دانه دارد، که حاکی از آن است دماهای بالای سایه‌انداز (احتمالاً به دلیل تنش گرمایی) ممکن است عملکرد را کاهش دهد.
- **روابط ضعیف:** متغیرهایی مثل P plant End Season و RootColonization\_PplantEndSeason همبستگی‌های ضعیف‌تری با عملکرد دانه دارند که نشان‌دهنده تأثیر مستقیم و محدود روی عملکرد می‌باشد.
- به‌طور کلی، نمودار همبستگی زوجی با کلاسترینگ، روابط

### تحلیل ضرایب همبستگی (نیمه بالای ماتریس)

ضرایب همبستگی و مقادیر p-value روابط معنی‌دار را نشان می‌دهند. بر این اساس، همبستگی‌ها در سه گروه به شرح زیر قابل تفسیر هستند:

- **همبستگی‌های مثبت قوی:** بین محتوای کلروفیل در مرحله خروج برگ پرچم (SPAD\_2) و قطر بلال و درصد فسفر گیاه در انتهای فصل رشد، همبستگی‌های قوی وجود داشت (به ترتیب  $r=0.80$  و  $r=0.82$ ). SPAD\_Dry و Leaf Area Index\_SPAD\_Mean:  $r = 0.37$ ،  $p < 0.001$ . این همبستگی مثبت متوسط، تولید زیست‌توده را با سطح برگ و محتوای کلروفیل مرتبط می‌کند.
- **همبستگی‌های منفی قوی:** Canopy Temp\_Mean و  $p < 0.001$ ،  $r = -0.82$  Root Colonization: حاکی از آن است که دماهای بالاتر سایه‌انداز گیاهی به شدت با کاهش کلونیزاسیون ریشه مرتبط است، که احتمالاً به دلیل تنش گرمایی بر کارکرد کلی گیاه از جمله کاهش میزان فتوسنتز و تولید آسمیلات‌ها و به دنبال آن کاهش تراوشات ریشه ای مؤثر بر فعالیت و جمعیت‌های ریزجانداران ساکن ریزوسفر تأثیر می‌گذارد. در منابع متعدد به نقش قارچ‌های میکوریزا آربوسکولار در بهبود روابط آب- خاک- گیاه و به دنبال آن میزان تبخیر و تعرق اشاره شده است (Bao et al., 2022, Bhupenchandra et al., 2024; Brar et al., 2024).
- **همبستگی‌های متوسط:** وجود همبستگی بین SPAD\_2 و Nplant\_SpecificRootLength ( $r = 0.60$ ،  $p < 0.001$ ) که نشان‌دهنده رابطه منطقی بین طول مخصوص ریشه (ریخت‌شناسی ریشه) و محتوای کلروفیل می‌باشد. افزایش طول مخصوص ریشه و نیز محتوای کلروفیل برگ به عنوان نتیجه کاربرد ریزوباکتری‌های تحریک‌کننده رشد گیاه، از سوی محققان متعدد مورد تأکید قرار گرفته است (Bhupenchandra et al., 2024).


### نمودارهای KDE در قطر (توزیع چگالی احتمال)

نمودارهای KDE با دو خوشه رنگی نشان داده شده‌اند که کلاسترینگ تجمعی با  $n\_clusters=2$  را منعکس می‌کنند و داده‌ها

پیچیده‌ای بین ۱۳ ویژگی را آشکار می‌کند:

- **انتخاب ویژگی:** متغیرهایی با همبستگی بالا (مثل Dry Matter Yield، SPAD\_Mean) گزینه‌های مناسبی برای مدل‌سازی پیش‌بینی عملکرد دانه هستند.
- **بینش‌های خوشه‌ای:** دو خوشه اصلی، خصوصیات فیزیولوژیکی (خوشه ۱) را از معیارهای مرتبط با عملکرد

- (خوشه ۲) جدا می‌کنند، که این موضوع می‌تواند به‌نوبه خود زمینه لازم برای تحلیل‌ها یا مداخلات هدفمند (مدیریت اگر واکولوژیک از جمله نوع و میزان نهاده) را فراهم آورد.
- **ملاحظات مدل‌سازی:** توزیع‌های اُریب و الگوهای چندوجهی نشان می‌دهند که برای توضیح دقیق این روابط، نیاز به تبدیل داده‌ها یا مدل‌های غیرخطی هست.




شکل ۱- ماتریس ضرایب همبستگی، نمودار توزیع چگالی و دندروگرام بین ۱۳ ویژگی مؤثر بر عملکرد دانه ذرت (شرح کامل متغیرها در جدول ۱ آورده شده است)

Figure 1- Matrix of correlation coefficients, kernel density estimation plots, and dendrogram among thirteen features influencing corn grain yield (Full descriptions of variables shown in table 1)

## نمودار شیب ویولونی اهمیت نسبی ۱۳ متغیر تشخیص داده شده توسط مدل رگرسیونی

شکل ۲، نمودار ویولن پلات توزیع و اهمیت نسبی ۱۳ ویژگی کلیدی شناسایی شده توسط مدل رگرسیونی گام به گام پس رونده، را برای پیش بینی عملکرد دانه ذرت نشان می دهد. این ویژگی ها شامل متغیرهای فیزیولوژیکی و ریخت شناختی هستند که پراکندگی داده ها و میانگین اهمیت آن ها نشان داده شده است. محور عمودی نشان دهنده اهمیت نسبی ویژگی ها است و محور افقی نام ویژگی ها

را نشان می دهد. ویژگی هایی مانند "Canopy Temp\_3"، "Root Colonization\_Dry" و "PlantHeight\_CobNumber" Matter Yield دارای پراکندگی گسترده تری هستند که بیانگر تنوع بیشتر تأثیر آن ها در مدل های مختلف است. همچنین میانه داده های هر ویژگی با خط قرمز مشخص شده که نشان می دهد برخی ویژگی ها مانند "%N soil" و "Root Colonization\_Dry" Matter Yield دارای پراکنش بیشتر داده های با مقادیر منفی هستند.



شکل ۲- نمودار شیب ویولونی اهمیت نسبی ۱۳ متغیر تشخیص داده شده توسط مدل رگرسیونی گام به گام (شرح کامل متغیرها در جدول ۱ آورده شده است)

Figure 2- SHAP violin plot shows relative importance of 13 features identified via Stepwise Elimination Regression (Full descriptions of variables shown in table 1)

انتخاب شده، این موارد با مقادیر صفر پُر شده اند، که منجر به شکل گیری ویولن های تک بعدی شده است.

## ارزیابی دقت و توان الگوریتم های یادگیری ماشین در پیش بینی عملکرد دانه ذرت

در حوزه علوم داده و یادگیری ماشین، مفاهیم ارزیابی مدل، اعتبارسنجی مدل، دقت مدل و توان مدل از جمله اصطلاحات کلیدی هستند که علی رغم ارتباط مفهومی، دارای تمایزات ساختاری

برای سه ویژگی ترکیبی (انتهای سمت راست نمودار)، شامل  $(\text{Canopy Temp\_Mean})^2 \times \text{Leaf Area Index}$ ،  $(\text{Root Colonization})^2 \times \text{Specific Root Length}$  و  $(\text{Specific Root Length})^2 \times \text{Dry Matter Yield}$ ، مشاهده می شود که ویولن پلات ها به صورت خطوط افقی صاف رسم شده اند. این پدیده ناشی از پراکندگی بسیار کم یا عدم وجود داده های معنی دار در این ویژگی ها پس از استانداردسازی است. در فرآیند رگرسیون گام به گام حذفی، این فیچرها ممکن است به دلیل همبستگی ضعیف با متغیر هدف (عملکرد دانه ذرت) یا داده های ناقص حذف شده باشند. بالاین حال، برای حفظ یکپارچگی تحلیل و نمایش کامل ۱۳ فیچر

بیشتر از ۵۰٪ به‌عنوان الگوریتم‌های برتر در پیش‌بینی عملکرد دانه ذرت شناخته شدند. مور و همکاران (Moore et al., 2013) دامنه زیر را برای تفسیر ضریب تبیین (شاخصی از نکویی برازش<sup>۵</sup>) پیشنهاد کرده‌اند:  $R^2 < 0.25$ : بسیار ضعیف؛  $0.25 \leq R^2 < 0.50$ : ضعیف؛  $0.50 \leq R^2 < 0.75$ : متوسط؛  $R^2 \geq 0.75$ : قابل توجه. براساس راهنمای کوهن و جانسون، ضرایب تبیین مساوی یا بزرگ‌تر از ۰/۲۶ در محدوده قابل توجه<sup>۶</sup> قرار می‌گیرند. اگرچه ضریب تبیین به‌طور گسترده‌ای به‌عنوان شاخصی از برازش مدل در رگرسیون خطی و چندگانه به‌کار می‌رود، اما تفسیر آن در زمینه یادگیری ماشین به‌ویژه با الگوریتم‌های غیرخطی باید با احتیاط صورت گیرد. دلیل این امر آن است که  $R^2$  لزوماً ظرفیت پیش‌بینی یا توان تعمیم مدل‌های پیچیده را به‌طور کامل نشان نمی‌دهد و در برخی موارد ممکن است خوش‌بینانه یا گمراه‌کننده باشد، به‌ویژه در شرایطی با ابعاد بالا یا بیش‌برازش. بنابراین توصیه می‌شود که علاوه بر  $R^2$ ، از شاخص‌هایی مانند RMSE، MAE یا اعتبارسنجی متقابل برای ارزیابی جامع‌تر عملکرد مدل استفاده گردد (Kuhn & Johnson, 2013).

### نمودار نمایی<sup>۷</sup>

**شکل ۳:** نمودار نمایی برای مقایسه هشت مدل یادگیری ماشین را براساس معیارهای  $R^2$ ، Willmott's d، MAE و RMSE نشان می‌دهد. محور افقی میانگین رتبه<sup>۸</sup> هر مدل را نشان می‌دهد. رتبه کمتر یعنی عملکرد بهتر (زیرا معیارهای مثل  $R^2$  و Willmott's d که هرچه بالاتر باشند بهتر هستند، رتبه پایین‌تر می‌گیرند، و معیارهایی مثل MAE و RMSE که هرچه پایین‌تر باشند بهتر هستند، نیز در رتبه پایین‌تر قرار می‌گیرند). در محور عمودی اسم مدل‌ها نشان داده شده است، از بهترین (بالا) به ضعیف‌ترین (پایین). خطوط افقی آبی فاصله بحرانی<sup>۹</sup> را نشان می‌دهند. اگر خط افقی مربوط به دو مدل هم‌پوشانی نداشته باشد، تفاوت عملکرد آن‌ها از نظر آماری معنی‌دار است (با  $\alpha=0.05$ ).

و کارکردی مشخص می‌باشند. ارزیابی مدل<sup>۱</sup>، فرآیند جامع سنجش عملکرد مدل با به‌کارگیری معیارهای کمی مختلف (نظیر  $R^2$ ، MAE، RMSE) بر روی مجموعه داده‌های آزمایشی است و هدف‌های آن تعیین قابلیت تعمیم‌پذیری مدل در شرایط عملیاتی و سنجش اثربخشی مدل در حل مسئله هدف می‌باشد. ارزیابی، با تمامی مفاهیم دیگر مرتبط است، چرا که چارچوبی جامع برای سنجش کیفیت مدل ارائه می‌دهد و دربرگیرنده سنجه‌هایی مانند دقت مدل می‌باشد. ارزیابی، رویکردی کل‌نگر دارد و به یک جنبه خاص محدود نمی‌شود و عموماً در مرحله نهایی توسعه مدل اجرا می‌شود. اعتبارسنجی<sup>۲</sup>، فرآیند نظام‌مند تنظیم هاپرپارامترها و ارزیابی مقدماتی مدل بر روی مجموعه داده‌های اعتبارسنجی به‌منظور جلوگیری از بروز پدیده بیش‌برازش می‌باشد. اهداف آن، بهینه‌سازی ساختار مدل پیش از ارزیابی نهایی و اطمینان از تعادل میان پیچیدگی و تعمیم‌پذیری مدل است. همچون ارزیابی مدل، از داده‌های مستقل استفاده می‌کند (ممکن است معیارهای دقت را در فرآیند خود به کار گیرد). برخلاف ارزیابی، اعتبارسنجی ماهیتاً فرآیندی تکرارشونده و اصلاحی است و تمرکز اصلی آن بر تنظیم مدل و نه قضاوت نهایی است. دقت مدل<sup>۳</sup>، معیار کمی خاصی است که میزان انطباق پیش‌بینی‌های مدل با مقادیر واقعی را اندازه‌گیری می‌کند. در مسائل رگرسیون عموماً از  $R^2$ ، RMSE و در مسائل طبقه‌بندی از Accuracy استفاده می‌شود. هدف، سنجش کارایی پیش‌بینی مدل و ارائه معیاری عینی برای مقایسه مدل‌های مختلف است. زیرمجموعه‌ای از فرآیند ارزیابی مدل محسوب می‌شود و ممکن است در فرآیند اعتبارسنجی نیز مورد استفاده قرار گیرد. دقت، نگاهی تک‌بعدی به عملکرد مدل دارد و فاقد جنبه‌های فرآیندی دیگر مفاهیم است. توان مدل<sup>۴</sup>، عبارت است از ظرفیت ذاتی مدل در یادگیری الگوهای پیچیده و انطباق با داده‌ها که تابعی از پارامترهای ساختاری نظیر تعداد لایه‌ها، نورون‌ها و عمق شبکه می‌باشد. اهداف آن شامل تعیین پتانسیل مدل در حل مسائل پیچیده و ایجاد تعادل میان انعطاف‌پذیری و خطر بیش‌برازش است. با معماری مدل در ارتباط است و بر معیارهای عملکردی مانند دقت تأثیر مستقیم دارد. به‌طور کلی، توان مدل ماهیتاً توصیف‌کننده ویژگی‌های ذاتی مدل است و برخلاف سایر مفاهیم، بیشتر متمرکز بر پتانسیل مدل است تا عملکرد آن.

ضریب تبیین، جذر میانگین مربعات خطا، قدر مطالب خطا و شاخص توافق هشت مدل مورد بررسی در **جدول ۴** نشان داده شده‌اند. سه الگوریتم آنفیس، ترنسفورمر و ای ان ان، با ضریب تبیین

5- Goodness-of-fit  
6- Substantial  
7- Nemenyi diagram  
8- Mean rank  
9- Critical distance


1- Model evaluation  
2- Model validation  
3- Model accuracy  
4- Model capacity



جدول ۴- ضریب تبیین، جذرمیانگین مربعات خطا، قدر مطلق خطا و شاخص توافق هشت مدل یادگیری ماشین در پیش‌بینی عملکرد دانه ذرت

Table 4- Coefficient of determination, root mean square error, mean absolute error, and Willmott's d index for eight machine learning models to predict corn grain yield

| الگوریتم<br>Algorithm                                                      | ضریب تبیین<br>R <sup>2</sup> | جذر میانگین مربعات خطا<br>RMSE | میانگین مطلق خطا<br>MAE | دی ویلموت<br>Willmott's d |
|----------------------------------------------------------------------------|------------------------------|--------------------------------|-------------------------|---------------------------|
| انفیس<br>ANFIS (Adaptive Neuro-Fuzzy Inference System)                     | 0.555                        | 2.804                          | 2.368                   | 0.826                     |
| ترنسفورمر<br>Transformer                                                   | 0.545                        | 2.834                          | 2.331                   | 0.837                     |
| شبکه عصبی مصنوعی<br>Artificial Neural Network (ANN)                        | 0.518                        | 2.917                          | 2.254                   | 0.848                     |
| رگرسیون بردار پشتیبان<br>Support Vector Regression (SVR)                   | 0.452                        | 3.111                          | 2.381                   | 0.758                     |
| لاست جی بی ام<br>LightGBM                                                  | 0.385                        | 3.296                          | 2.617                   | 0.727                     |
| ایکس جی بوست<br>XGBoost                                                    | 0.339                        | 3.417                          | 2.780                   | 0.689                     |
| ماشین بردار پشتیبان<br>Support Vector Machine (SVM)                        | 0.325                        | 2.96                           | 2.37                    | 0.796                     |
| شبکه عصبی عمیق ارتقاء یافته<br>Enhanced Deep Neural Network (Enhanced DNN) | 0.321                        | 3.462                          | 3.313                   | 0.674                     |



شکل ۳- نمودار نمینی مقایسه هشت الگوریتم یادگیری ماشین در پیش‌بینی عملکرد دانه ذرت

Figure 3- Nemeni plot comparing eight machine learning algorithms in predicting corn grain yield

#### تفسیر نمودار نمینی

نشان می‌دهد عملکرد آن خیلی به Transformer نزدیک بوده و تفاوت آماری معنی‌داری با آن ندارد (چون خطوط آن‌ها هم‌پوشانی دارند).

- مدل SVR (با میانگین رتبه ۳) رتبه سوم را به خود اختصاص داد، اگرچه که از ANN و Transformer کمی ضعیف‌تر است، با این حال خوب عمل کرده است.
- LightGBM (4.00) کاهش قابل توجه نشان داد و عملکرد آن از SVR کمتر شد.

#### ۱- رتبه‌بندی کلی: مدل ANN با میانگین رتبه ۱/۵۰ و

شاخص دی برابر ۰/۸۴۸ بهترین عملکرد را نشان می‌دهد، که نشان‌دهنده توافق بالای پیش‌بینی‌ها با داده‌های واقعی است.

- مدل Transformer با ضریب تبیین ۰/۵۴۵ و میانگین رتبه ۱/۵۰ نیز عملکرد بسیار خوبی دارد.
- مدل ANN هم‌رتبه با Transformer است که

می‌کنند. مدل‌هایی که به نقطه مرجع نزدیک‌تر هستند، عملکرد بهتری دارند (نقطه مرجع در نمودار تیلور، نقطه‌ای با انحراف معیار بالا و ضریب همبستگی نزدیک به یک است که به‌عنوان معیار ایده‌آل عملکرد مدل‌ها در نظر گرفته می‌شود). نمودار تیلور نشان می‌دهد که مدل Transformer با  $RMSE=2.834$  و  $R^2=0.545$  بهترین عملکرد را در بین هشت مدل دارد. مدل‌های ANN ( $RMSE=2.917$ ,  $R^2=0.518$ ) و ANFIS ( $RMSE=2.884$ ,  $R^2=0.529$ )، در رتبه‌های بعدی قرار دارند. در مقابل، مدل‌های XGBoost و LightGBM ( $RMSE=3.296$ ,  $R^2=0.385$ ) و EnhancedDNN ( $RMSE=3.417$ ,  $R^2=0.339$ ) و SVM ( $RMSE=3.442$ ,  $R^2=0.321$ ) و  $R^2=0.329$  ضعیف‌ترین عملکرد را نشان می‌دهند.

در ادامه، تحلیل مفصلی از نمودار تیلور ارائه می‌شود:

۱- **انحراف معیار:** انحراف معیار مدل‌ها در محدوده تقریبی ۲/۵۷ تا ۳/۵۸ قرار دارد. مدل‌ای که با انحراف معیار ۲/۵۷۳ کمترین تغییرپذیری را در پیش‌بینی‌های خود نشان می‌دهد، درحالی‌که مدل‌های آنفیس (۲/۶۰۰) و ترنسفورمر (۲/۶۲۷) نیز انحراف معیار پایینی دارند. در مقابل، مدل انهنسد دی ان ان (۳/۵۸۲) و ایکس جی بوست (۳/۳۱۷) بالاترین انحراف معیار را دارند، که نشان‌دهنده پراکندگی بیشتر خطاها در پیش‌بینی‌ها می‌باشد.

۲- **ضریب همبستگی:** در نمودار تیلور، ضریب همبستگی واقعی بین پیش‌بینی‌های مدل و داده‌های واقعی (مرجع)، روی قوس (قطاع دایره) نمایش داده می‌شود. اعداد روی محور افقی و عمودی (فاصله شعاعی از مبدأ در کمان‌های هم‌مرکز) نشان‌دهنده انحراف معیار (نسبت انحراف معیار مدل به انحراف معیار مرجع) هستند. در این نمودار خاص، برخلاف شیوه مرسوم، محورهای استانداردسازی (نرمال‌سازی) نشده‌اند و مقادیر انحراف معیار به‌صورت واقعی (Raw) رسم شده‌اند. گواه این موضوع آن است که نقطه مرجع (Reference) که نشان‌دهنده داده‌های واقعی است، روی محور افقی در فاصله ۴/۳ از مبدأ قرار دارد که همان انحراف معیار واقعی مشاهدات است. نقطه مرجع، بهترین حالت ممکن را نشان می‌دهد: ضریب همبستگی ۱ و انحراف معیار ۴/۳. هرچه مدلی به این نقطه نزدیک‌تر باشد، عملکرد بهتری دارد. خطوط نقطه‌چینی که از نقطه مرجع شروع و به‌صورت قوس‌هایی به سمت محور عمودی کشیده شده‌اند، کمان‌های RMSD ثابت هستند. RMSD

- (5.00) XGBoost عملکردی متوسط را از خود نشان داد.
- (6.25) EnhancedDNN نسبت به مدل‌های مبتنی بر شبکه عصبی ساده (مثل ANN) ضعیف‌تر عمل کرد.
- (6.75) ANFIS نزدیک به Enhanced DNN است.
- (8.00) SVM با بالاترین میانگین رتبه، ضعیف‌ترین عملکرد را از خود نشان داد که با ضریب تبیین ۰/۳۲۵ و شاخص دی ۰/۷۹۶ هم‌خوانی دارد.

## ۲- فاصله بحرانی

**فاصله بحرانی:** فاصله بحرانی برابر با ۵/۱۱ نشان می‌دهد که مدل‌هایی که تفاوت میانگین رتبه آن‌ها بیشتر از این مقدار است (مثل ANN و SVM)، تفاوت آماری معنی‌داری با یکدیگر دارند. مدل‌هایی که خط افقی آن‌ها بیشتر از این فاصله از هم جدا شده باشد (مثل Transformer و SVM)، با یکدیگر تفاوت آماری معنی‌دار دارند. ANN و Transformer با یکدیگر هم‌پوشانی دارند، ولی SVM با هیچ‌کدام از مدل‌های بالا هم‌پوشانی ندارد، یعنی ضعیف‌تر بودن آن معنی‌دار است.

## ۳- الگوهای مشاهده‌شده

**الگوهای مشاهده‌شده:** مدل‌های مبتنی بر شبکه عصبی (ANN, Transformer, Enhanced DNN) به‌طور کلی عملکرد بهتری نسبت به مدل‌های درختی (XGBoost, LightGBM) و مدل‌های فازی (ANFIS) دارند. این ممکن است به‌دلیل توانایی آن‌ها در مدل‌سازی روابط پیچیده و غیرخطی در داده‌های ذرت باشد. مدل‌های درختی مثل XGBoost و LightGBM در میانه جدول هستند که نشان می‌دهد در این دیتاست عملکرد متوسطی دارند. اس وی آر، جزء هیچ یک از الگوریتم‌های درختی و شبکه عصبی محسوب نمی‌شود، بلکه یک مدل مبتنی بر Support Vector Machine هست که با کرنل‌ها (مثل RBF) عمل می‌کند.

## نمودار تیلور<sup>۱</sup>

نمودار تیلور (شکل ۴)، هشت مدل یادگیری ماشین مورد بررسی را براساس انحراف معیار، ضریب همبستگی، جذرمیانگین مربعات خطا، ضریب تبیین و شاخص توافق ویلموت مقایسه می‌کند. این نمودار تعادل بین انحراف معیار و ضریب همبستگی را نشان می‌دهد، درحالی‌که معیارهای  $RMSE$  و  $R^2$  دقت پیش‌بینی‌ها را ارزیابی

2- Correlation Coefficient


3- Reference

1- Taylor Diagram



فاصله هر مدل از نقطه مرجع در امتداد این کمان‌ها، خطای کلی آن مدل را مشخص می‌کند.

در این نمودار معادل RMSE (جذر میانگین مربعات خطا) است، با این تفاوت ظریف که در بافت نمودار تیلور، معمولاً به مؤلفه تصادفی خطا (پس از حذف سوگیری) اشاره دارد.



شکل ۴- نمودار تیلور مقایسه هشت الگوریتم یادگیری ماشین در پیش‌بینی عملکرد دانه ذرت

Figure 4- Taylor diagram comparing eight machine learning algorithms in predicting corn grain yield

#### مدل‌های با عملکرد بهتر (نزدیک‌تر به نقطه مرجع و

#### RMSE پایین‌تر):

مدل‌های ANN (انحراف معیار ۲/۵۷۳، RMSE برابر ۲/۹۱۷)، ANFIS (انحراف معیار ۲/۶۰۰، RMSE برابر ۲/۸۸۴) و Transformer (انحراف معیار ۲/۶۲۷، RMSE برابر ۲/۸۳۴) دارای مقادیر RMSE نسبتاً پایینی هستند و در نمودار تیلور به نقطه مرجع نزدیک‌ترند. این مدل‌ها همچنین ضرایب تبیین بالاتری دارند (ANFIS: 0.529، Transformer: 0.545) که تأییدکننده دقت بهتر پیش‌بینی‌های آن‌ها است. نزدیکی این سه مدل در نمودار تیلور (به‌ویژه قرارگیری ANFIS در زیر دو مدل دیگر به دلیل انحراف معیار نزدیک‌تر) نشان‌دهنده عملکرد مشابه و نسبتاً خوب آن‌ها است.

#### مدل‌های با انحراف معیار و RMSE بالاتر (عملکرد

#### ضعیف‌تر):

مدل‌های LightGBM (انحراف معیار ۳/۱۵۳، RMSE برابر

ضریب همبستگی بالاتر (مثلاً ۰/۷۵۸ برای Enhanced DNN)

به‌معنای تطابق بهتر مدل با داده‌های مرجع است. ضرایب

همبستگی مدل‌ها به شرح زیر هستند:

ANFIS: 0.550, ANN: 0.544, Transformer: 0.555, SVR: 0.621, LightGBM: 0.667, XGBoost: 0.701, EnhancedDNN: 0.758, SVM: 0.648

مدل انهنسد دی ان ان با ضریب همبستگی ۰/۷۵۸ بالاترین

مقدار را دارد که نشان‌دهنده همبستگی قوی‌تر با داده‌های واقعی است. در مقابل، مدل‌های ای ان ان (۰/۵۴۴) و ترنسفورمر (۰/۵۵۵) به دلیل ضریب همبستگی پایین‌تر، همبستگی ضعیف‌تری با داده‌های مرجع دارند و از این نظر عملکرد ضعیف‌تری نشان می‌دهند.

#### تحلیل عملکرد مدل‌ها براساس نمودار تیلور: همبستگی

بالا به‌تنهایی برای قضاوت در مورد عملکرد یک مدل کافی نیست، بلکه باید همراه با انحراف معیار و RMSE/RMSD (فاصله از نقطه مرجع) تفسیر شود. بر این اساس، مدل‌ها به دو گروه تقسیم می‌شوند:

برتر تشخیص داده‌شده توسط چهار مدل برتر (که ضریب تبیین بالای ۰/۵۰ داشتند) در شکل ۶ نشان داده شده است.

مدل آنفیس در پنج ویژگی با ۱۳ ویژگی تشخیص داده‌شده توسط مدل گام‌به‌گام مشترک بود (دمای تاج‌پوشش ۳ و ۴، نیتروژن گیاه در طول مخصوص ریشه، طول مخصوص ریشه در عملکرد ماده خشک، شاخص سطح برگ در عدد اسپد میانگین).

مدل ترنسفورمر در پنج ویژگی با ۱۳ ویژگی تشخیص داده‌شده توسط مدل گام‌به‌گام مشترک بود (دمای تاج‌پوشش ۳ و ۴، ارتفاع گیاه در تعداد بلال، مجذور کلونیزاسیون ریشه در طول مخصوص ریشه، دمای تاج‌پوشش میانگین).

شش ویژگی مشترک مدل ای ان با مدل گام‌به‌گام عبارت بودند از: ارتفاع گیاه در تعداد بلال، دمای تاج‌پوشش ۴ و ۲، محتوای نیتروژن گیاه در طول مخصوص ریشه، مجذور طول مخصوص ریشه در عملکرد ماده خشک، شاخص سطح برگ در عدد اسپد میانگین.

مدل اس وی آر بیشترین تعداد ویژگی مشترک با مدل گام‌به‌گام را دارا بود (نه ویژگی) که عبارتند از: دمای تاج‌پوشش ۴، ۳ و ۲، ارتفاع گیاه در تعداد بلال، شاخص سطح برگ در عدد اسپد میانگین، شاخص سطح برگ در عملکرد ماده خشک، مجذور دمای تاج‌پوشش میانگین در شاخص سطح برگ، درصد کلونیزاسیون ریشه در عملکرد ماده خشک، درصد نیتروژن گیاه در طول مخصوص ریشه.

در جدول ۵، ویژگی‌های مشترک بین چهار الگوریتم ماشین برتر آورده شده است.

از بین ۱۳ ویژگی تشخیص داده‌شده توسط مدل رگرسیونی گام‌به‌گام پس‌رونده، ۵، ۲، ۶ و ۵ ویژگی به‌ترتیب در مدل‌های آنفیس، ترنسفورمر، ای ان و اس وی آر نیز تشخیص داده شدند. الگوریتم اس وی آر با سادگی و به‌کارگیری کرنل RBF، عملکرد خوبی ( $R^2 = 0.452$ ) از خود نشان داد. ویژگی دمای تاج‌پوشش در مرحله پُر شدن دانه، به‌عنوان ویژگی مؤثر و با اهمیت بالا در پیش‌بینی عملکرد دانه، توسط چهار الگوریتم برتر تشخیص داده شد. سه برهم‌کنش شامل محتوای نیتروژن گیاه و طول ویژه ریشه، شاخص سطح برگ و عدد اسپد، ارتفاع بوته و تعداد بلال و اثر ساده دمای تاج‌پوشش در مرحله کاکل‌دهی در سه الگوریتم برتر حضور داشتند که با مبانی اکوفیزیولوژیکی رشد و نمو گیاهان زراعی هم‌خوانی دارد (Taiz et al., 2018).

XGBoost (انحراف معیار ۳/۳۱۷، RMSE برابر ۲/۶۱۷)، SVM (انحراف معیار ۳/۰۶۳، RMSE برابر ۲/۳۸۱) و Enhanced DNN (انحراف معیار ۳/۵۸۲، RMSE برابر ۳/۱۳۶) انحراف معیار و RMSE بالاتری دارند که نشان‌دهنده پراکندگی بیشتر خطاها و دقت پایین‌تر پیش‌بینی‌ها است. این مدل‌ها  $R^2$  پایین‌تری نیز دارند (LightGBM: 0.385، Enhanced DNN: SVM: 0.329، XGBoost: 0.339) که عملکرد ضعیف‌تر آن‌ها را تأیید می‌کند.

نکته قابل توجه در مورد مدل Enhanced DNN این است که این مدل با وجود داشتن RMSE گزارش‌شده ۳/۱۳۶، در نمودار تیلور به خط نقطه‌چین RMSD صفر (که از نقطه مرجع به مرکز مختصات کشیده شده) از همه مدل‌ها نزدیک‌تر است. این نزدیکی نشان می‌دهد که براساس معیار اصلی نمودار تیلور (فاصله از نقطه مرجع)، Enhanced DNN عملکرد بهتری نسبت به آنچه اعداد RMSE نشان می‌دهند، دارد. این مدل با ضریب همبستگی ۰/۷۵۸ بالاترین تطابق الگو با داده‌های مرجع را نشان می‌دهد و انحراف معیار آن (۳/۵۸۲) نسبت به نقطه مرجع (۴/۳) تفاوت کمتری دارد. عدم تطابق بین RMSE گزارش‌شده و موقعیت نقطه در نمودار تیلور ممکن است ناشی از تفاوت RMSE کل (شامل سوگیری) با RMSD مرکززدایی‌شده در نمودار تیلور باشد. براساس خود نمودار، نزدیکی به نقطه مرجع معیار نهایی عملکرد است و Enhanced DNN در این معیار جایگاه برجسته‌ای دارد.

## تحلیل و بحث نتایج الگوریتم‌های یادگیری ماشین


### ۱- نمودار پراکنش نقاط پیش‌بینی‌شده در برابر نقاط

مشاهده‌شده: نمودار پراکنش نمونه‌های پیش‌بینی‌شده در مقابل نمونه‌های مشاهده‌شده برای هشت مدل مورد ارزیابی در شکل ۵ نشان داده شده است.


فاشوتو و همکاران (Fashoto et al., 2021) اظهار داشتند که مدل‌های یادگیری ماشین در برآورد عملکرد محصول ذرت نسبت به روش‌های سنتی (رگرسیون خطی چندگانه و حذف معکوس) برتری دارند. گزارش شده است که مدل جنگل تصادفی در تخمین فعالیت‌های آنزیمی خارج‌سلولی خاک در زمین‌های شور ساحلی بازسازی‌شده کشاورزی عملکرد بهتری نسبت به رگرسیون‌های خطی چندگانه داشته است (Xie et al., 2021).

### ۱- نمودارهای شیب ویولونی اهمیت نسبی ۲۰ ویژگی


A) ANFIS




B) Transformer




C) ANN




D) SVR




E) LGBM




F) XGBoost



G) SVM



H) EDNN




شکل ۵- نمودار پراکنش و خط رگرسیونی مقادیر پیش‌بینی شده عملکرد دانه ذرت در برابر مقادیر مشاهده‌شده

Figure 5- Scatter plot and regression line of predicted versus observed corn grain yield values

A: آنفیس، B: ترنسفورمر، C: ای‌ان‌ان، D: اس وی آر، E: لایت جی بی ام، F: ایکس جی بوست، G: اس وی ام، H: انهنس دی ان ان

A: ANFIS, B: Transformer, C: ANN, D: SVR, E: LightGBM, F: XGBoost, G: SVM, H: DNN



شکل ۶- نمودارهای شیب ویولونی اهمیت نسبی ۲۰ ویژگی برتر تشخیص داده‌شده توسط چهار الگوریتم برتر (شرح کامل متغیرها در جدول ۱ آورده شده است)

Figure 6- SHAP violin plots of the relative importance of the top 20 features identified by the four best algorithms (Full descriptions of variables shown in table 1)

A: آنفیس، B: ترنسفورمر، C: ای ان ان، D: اس وی آر  
A: ANFIS, B: Transformer, C: ANN, D: SVR

جدول ۵- ویژگی‌های مشترک در چهار الگوریتم ماشین برتر با مدل رگرسیون گام‌به‌گام (به تفکیک هر الگوریتم)  
Table 5- Common features among the four top machine learning algorithms and the stepwise regression model (by algorithm)

|   | رگرسیون بردار پشتیبان<br>SVR                                            | شبکه عصبی مصنوعی<br>ANN                                                              | ترنسفورمر<br>Transformer                                                                    | انفیس<br>ANFIS                                                                                     |
|---|-------------------------------------------------------------------------|--------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------|
| 1 | دمای تاج‌پوشش در مرحله دانه بندی<br>Canopy_Temp4                        | اثر متقابل ارتفاع بوته و تعداد بلال<br>PlantHeight_CobNumber                         | دمای تاج‌پوشش در مرحله دانه بندی<br>Canopy_Temp4                                            | دمای تاج‌پوشش در مرحله دانه بندی<br>Canopy_Temp4                                                   |
| 2 | اثر متقابل ارتفاع بوته و تعداد بلال<br>PlantHeight_CobNumber            | دمای تاج‌پوشش در مرحله دانه بندی<br>Canopy_Temp4                                     | دمای تاج‌پوشش در مرحله کاکل‌دهی<br>Canopy_Temp3                                             | اثر متقابل درصد نیتروژن اندام‌های گیاهی و طول ویژه ریشه<br>Nplant_SpecificRootLength               |
| 3 | اثر متقابل شاخص سطح برگ و میانگین عدد اسپد<br>Leaf Area Index_SPAD_Mean | اثر متقابل درصد نیتروژن اندام‌های گیاهی و طول ویژه ریشه<br>Nplant_SpecificRootLength | اثر متقابل ارتفاع بوته و تعداد بلال<br>PlantHeight_CobNumber                                | اثر متقابل شاخص سطح برگ و عملکرد ماده خشک<br>(Specific Root Length) <sup>2</sup> *Dry Matter Yield |
| 4 | عملکرد ماده خشک<br>Leaf Area Index_Dry Matter Yield                     | ریشه و عملکرد ماده خشک<br>(Specific Root Length) <sup>2</sup> *Dry Matter Yield      | ریشه و طول ویژه ریشه<br>(Root Colonization) <sup>2</sup> *SpecificRootLength                | میانگین عدد اسپد<br>Leaf Area Index_SPAD_Mean                                                      |
| 5 | (Canopy Temp_Mean) <sup>2</sup> *Leaf Area                              | اثر متقابل شاخص سطح برگ و میانگین عدد اسپد<br>Leaf Area Index_SPAD_Mean              | اثر متقابل کلونیزاسیون ریشه و محتوای فسفر در انتهای فصل رشد<br>Colonization_PplantEndSeason | دمای تاج‌پوشش در مرحله برگ پرچم<br>Canopy_Temp2                                                    |
| 6 | Root Colonization_Dry Matter Yield                                      | Canopy_Temp2                                                                         |                                                                                             |                                                                                                    |
| 7 | Canopy_Temp3                                                            |                                                                                      |                                                                                             |                                                                                                    |
| 8 | Nplant_SpecificRootLength                                               |                                                                                      |                                                                                             |                                                                                                    |
| 9 | Canopy_Temp2                                                            |                                                                                      |                                                                                             |                                                                                                    |

بنابراین، می‌توان این ویژگی‌ها را مهم‌ترین متغیرهای شکل‌دهنده عملکرد دانه ذرت دانست. عمده ویژگی‌های تشخیص داده‌شده نشان‌دهنده اهمیت تعامل بین کلونیزاسیون ریشه و سیستم فتوسنتزی بود که با مطالعات قبلی هم‌خوانی دارد. تشخیص دو برهم‌کنش مجذور درصد کلونیزاسیون ریشه و طول ویژه ریشه، و درصد کلونیزاسیون ریشه و عملکرد ماده خشک توسط الگوریتم‌های ترنسفورمر و اس وی آر، می‌تواند نشان‌دهنده توانایی این دو الگوریتم در کشف اثرات پنهان کاربرد کودهای بیولوژیک بر عملکرد دانه ذرت باشد. در مطالعه‌ای مشخص شد که TempMax به‌عنوان پنجمین ویژگی مهم در پیش‌بینی عملکرد گندم زمستانه با استفاده از مقدار SHAP شناسایی شده است (Srivastava et al., 2022). گزارش شده است که تحلیل SHAP نشان داد که مقادیر بالای ویژگی‌های تعداد روزهای رشد و میانگین سطح برگ گیاه تأثیر منفی بر پیش‌بینی عناصر غذایی داشته‌اند، درحالی‌که مقادیر بالای تعداد برگ‌ها و ارتفاع گیاه اثر مثبتی بر پیش‌بینی عناصر غذایی داشته‌اند (Abekoon et al., 2025).

۱- نمودارهای شیب دسیژن پلات برای نمونه‌های تست توسط چهار مدل برتر در شکل ۷ نشان داده شده

است. محور عمودی، ترتیب ویژگی‌ها به ترتیب تأثیرگذاری روی تصمیم مدل را نشان می‌دهد (یعنی برای هر نمونه، مدل چه‌طور برای خروجی نهایی تصمیم گرفته است). محور افقی، خروجی مدل (پیش‌بینی عملکرد دانه) را نشان می‌دهد. خطوط رنگی (هر خط نشان‌دهنده یک نمونه است) نشان‌دهنده تغییر مقدار خروجی مدل برای نمونه‌های مختلف بر اثر ورود تدریجی هر ویژگی است. به عبارت دیگر، خط از بالا (ویژگی اول) شروع می‌شود و در هر مرحله، ویژگی بعدی باعث بالا رفتن یا پایین رفتن مقدار خروجی مدل می‌شود. در پایان (پایین‌ترین نقطه)، خروجی نهایی مدل برای آن نمونه مشخص شده است. رنگ خطوط، آبی نشان‌دهنده خروجی پایین‌تر، و قرمز نشان‌دهنده خروجی بالاتر است. تحلیل ویژگی‌ها از بالا به پایین صورت می‌گیرد و تحلیل خروجی، از چپ به راست تا برسد به خط پایه که پیش‌بینی نهایی است. به‌طور کلی، تحلیل تصمیم مدل، براساس ترتیب ویژگی‌ها (از بالا به پایین) و اثر نهایی هر ویژگی روی پیش‌بینی (از چپ به راست) انجام می‌شود.

باعث افزایش خروجی (رنگ قرمز)، و برای برخی سبب کاهش خروجی شده است. این بدان معنی است که بسته به مقدار آن، عملکرد این ویژگی متغیر خواهد بود. اثر متقابل ارتفاع بوته و تعداد بلال، در اکثر موارد باعث افزایش خروجی شده که نشان‌دهنده اثر مثبت و مستقیم آن بر رشد گیاه است. درصد نیتروژن خاک و درصد فسفر گیاه، اثر متعادل دارند، زیرا نمودار خطوط در این سطوح زیاد جابه‌جا نشدند (خط‌ها صاف‌تر شدند). اثرات متقابل عملکرد ماده خشک و طول مخصوص ریشه و درصد کلونیزاسیون ریشه، به‌میزان قابل توجهی خروجی را تحت تأثیر قرار دادند و سبب افزایش آن شده‌اند. همین مطلب در مورد اثر متقابل مجذور طول مخصوص ریشه و عملکرد ماده خشک نیز صادق است. دمای تاج‌پوشش یک (در مرحله خروج برگ پرچم)، آخرین ویژگی است و اثر خنثی دارد، زیرا خط‌ها در این قسمت تغییر چندانی ندارند. در مجموع می‌توان گفت که مدل ترنسفورمر مقدار عملکرد دانه ذرت را با ویژگی‌های ریشه، سیستم فتوسنتزی و عملکرد ماده خشک انجام می‌دهد.

از شرح مفصل نتایج نمودارهای تصمیم مدل‌های ای ان ان و اس وی آر صرف نظر شده و تنها به سازوکار نهایی آن‌ها در پیش‌بینی اشاره می‌شود (به سبب محدودیت برای تعداد صفحات مقاله). الگوریتم ای ان ان (شکل ۷ C) به‌وضوح نشان می‌دهد که با ترکیب ویژگی‌هایی شامل دمای تاج‌پوشش و خصوصیات فیزیولوژیکی برگ (نسبت فلورسانس کلروفیل متغیر به بیشینه دو؛ در مرحله کاکل‌دهی) و نیز ویژگی‌های ساختاری شامل قطر بلال می‌تواند پیش‌بینی نهایی را بالا یا پایین ببرد. در مجموع می‌توان نتیجه گرفت که الگوریتم ای ان ان، عملکرد دانه ذرت را با ویژگی‌های مرتبط با تنش (فیزیولوژیک) پیش‌بینی می‌کند.

نمودار مسیر الگوریتم اس وی آر (شکل ۷ D) نشان می‌دهد که تعداد بلال، دمای تاج‌پوشش چهار (در مرحله پر شدن دانه) و اثر متقابل کلونیزاسیون ریشه و محتوای فسفر گیاه در انتهای فصل رشد سبب افزایش پیش‌بینی شدند. این الگوریتم نیز همانند ترنسفورمر بر تأثیر برهم‌کنش میزان کلونیزاسیون ریشه و محتوای فسفر گیاه در انتهای فصل رشد، بر عملکرد دانه تأکید نمود. همچنین هر دو الگوریتم، طول ویژه ریشه (همانند درصد


در مدل آنفیس (شکل ۷ A)، اثر متقابل عملکرد ماده خشک و میانگین قرائت اسپد و شاخص سطح برگ، مهم‌ترین اثر تعاملی بوده و باعث افزایش شدید عملکرد دانه شده است (خط رنگی از سمت چپ (حدود ۹) به بالای محور (حدود ۱۱) می‌رسد). دومین ویژگی، فتوسنتز ماکسیمم یک، است که تأثیر مثبت ملایم روی مقدار خروجی دارد، اما نسبت به اولی، اثرش کمتر بوده و نمودار آن در حوالی خروجی ۹/۵ متمرکز شده است. ویژگی سوم، اثر متقابل شاخص سطح برگ و قرائت اسپد میانگین است، که اثر آن مثبت و متوسط است. ویژگی چهارم، عملکرد ماده خشک است که همانند ویژگی سوم، اثر مثبت ملایمی دارد. ویژگی پنجم، اثر متقابل ارتفاع بوته و تعداد بلال است که اثر مثبت بر عملکرد دانه داشته و سبب افزایش آن شده است. ویژگی‌های ششم (درصد فسفر گیاه) و هفتم (دمای برگ) تأثیر متوسط (متعادل) بر عملکرد دانه دارند. ویژگی هشتم، مجذور طول مخصوص ریشه است که اثر آن تقریباً خنثی بود. ویژگی نهم (درصد فسفر خاک) و دهم (طول بلال) در انتهای لیست یعنی با کمترین اهمیت نسبی یا اثر ضعیف بر عملکرد دانه واقع شده‌اند. به‌طور کلی می‌توان گفت که در مدل آنفیس، ترکیب شاخص سطح برگ، قرائت اسپد و عملکرد ماده خشک، مهم‌ترین پیش‌بینی‌کننده عملکرد دانه تشخیص داده شده است. ویژگی‌های منفرد مثل فتوسنتز ماکزیمم یک و عملکرد ماده خشک، اثر متقابل شاخص سطح برگ و قرائت اسپد و همچنین اثر متقابل ارتفاع بوته و تعداد بلال، اثر افزایشی بر عملکرد دانه دارند. با در نظر گرفتن مسیر این ویژگی‌ها، می‌توان گفت که مدل آنفیس براساس ویژگی‌های فیزیولوژیکی (سرعت فتوسنتز ماکزیمم و قرائت اسپد) و مورفولوژیک (شاخص سطح برگ و ارتفاع بوته) پیش‌بینی می‌کند.

در مدل ترنسفورمر (شکل ۷ B)، اثر متقابل درصد کلونیزاسیون ریشه و محتوای فسفر گیاه در انتهای فصل رشد، اولین و مهم‌ترین ویژگی است، و برای بیشتر نمونه‌ها، اثر منفی دارد (خطوط آبی به چپ حرکت کرده‌اند). کاهش خروجی، اگرچه برای برخی نمونه‌ها، اثر خنثی یا مثبت هم دیده می‌شود (رنگ به بنفش یا قرمز نزدیک شده). نرخ فتوسنتز ماکزیمم یک، اثر دوگانه دارد، به این صورت که برای برخی نمونه‌ها




(Khosro et al., 2024) را به عنوان ویژگی مهم و تأثیرگذار بر پیش بینی عملکرد دانه تشخیص دادند.


کلونیزاسیون ریشه) که نتیجه مستقیم کاربرد کودهای زیستی است (Bao et al., 2022; Brar et al., 2024)




A) ANFIS



B) Transformer



C) ANN



D) SVR

شکل ۷- نمودارهای شیب دسیژن پلات برای نمونه‌های تست توسط چهار الگوریتم برتر (شرح کامل متغیرها در جدول ۱ آورده شده است)

**Figure 7- SHAP Decision Plots for test samples by the four best algorithms (Full descriptions of variables shown in table 1)**

A: آنفیس، B: ترنسفورمر، C: ای ان ان، D: اس وی آر  
A: ANFIS, B: Transformer, C: ANN, D: SVR

در شرایط خاص مثلاً در مراحل پُر شدن دانه که مصادف با روزهای گرم تابستان است، از نظر فیزیولوژیکی قابل توجیه باشد. با این حال، این رابطه ممکن است ناشی از وابستگی غیرمستقیم متغیر با صفات دیگر باشد و باید با احتیاط تفسیر شود.

گزارش شده است که الگوریتم CNN-RNN برای پیش‌بینی عملکرد محصول سه ویژگی برجسته دارد که آن را به روشی بالقوه مفید برای مطالعات دیگر پیش‌بینی عملکرد محصول تبدیل می‌کند. ۱- الگوریتم CNN-RNN برای ضبط وابستگی‌های زمانی عوامل محیطی و بهبود ژنتیکی بذرها در طول زمان بدون نیاز به اطلاعات ژنوتیپ طراحی شده بود. ۲- مدل توانایی تعمیم پیش‌بینی عملکرد به محیط‌های آزمایش نشده را بدون کاهش قابل توجه دقت پیش‌بینی نشان داد. ۳- همراه با روش بک‌پروپگیشن، مدل توانست نشان دهد که شرایط آب‌وهوایی، دقت پیش‌بینی آب‌وهوا، شرایط خاک و روش‌های مدیریت تا چه حد قادر به توضیح تغییرات در عملکرد محصولات هستند (Khaki et al., 2020).

#### ۱- نمودار فورس پلات برای مدل لایت جی بی ام

به عنوان نمونه، با هدف نمایش ساختار این نوع نمودارها آورده شده است (این مدل عملکرد نسبتاً ضعیفی با  $R^2=0.385$  دارد) (شکل ۹). این نمودار برای یک نمونه منفرد نشان می‌دهد که مدل از چه مقداری (مقدار پایه<sup>۴</sup>) شروع کرده و هر ویژگی چه طور روی خروجی نهایی اثر گذاشته و باعث افزایش یا کاهش خروجی شده است (شکل ۹). محور افقی نشان‌دهنده مقدار پیش‌بینی نهایی مدل است (در اینجا حدوداً ۱۴/۸ در انتهای نمودار). مقدار پایه حدود ۵/۳ است. رنگ آبی برای ویژگی‌هایی است که باعث افزایش مقدار پیش‌بینی شده‌اند و هرچه پیکان آبی کشیده‌تر باشد، سهم آن ویژگی در افزایش خروجی بیشتر است. رنگ قرمز برای ویژگی‌هایی است که باعث کاهش مقدار پیش‌بینی شده‌اند. در شکل ۹ سمت چپ نمودار (قرمزها) اثر منفی دارند، و خیلی کوچک هستند. برهم‌کنش شاخص سطح برگ و عملکرد ماده خشک، بزرگ‌ترین اثر مثبت را روی خروجی مدل دارد (Leaf Area Index\_Dry Matter Yield = 280.047)، به عبارت دیگر، مقدار بالای این ویژگی باعث افزایش چشمگیر عملکرد دانه (خروجی مدل) شده است. میانگین نرخ فتوسنتز بیشینه اثر افزایشی قوی دارد (PmaxMean = 4.5) که نشان‌دهنده اهمیت آن برای مدل می‌باشد. طول بلال زیاد باعث تقویت خروجی مدل شده است

#### ۳- نمودارهای وابستگی جزئی<sup>۱</sup> چهار ویژگی منتخب از ۱۰

ویژگی برتر تشخیص داده‌شده توسط مدل اس وی آر در شکل ۸ نشان داده شده است (ده ویژگی برتر در جدول ۵ خلاصه شده‌اند). این نمودارها کمک می‌کنند به فهم اینکه یک ویژگی خاص چگونه به تنهایی (به صورت میانگین گرفته‌شده روی تمام نمونه‌ها) بر خروجی یک مدل یادگیری ماشین تأثیر می‌گذارد. محور افقی مقدار نرمال شده<sup>۲</sup> ویژگی مورد نظر را نشان می‌دهد و محور عمودی وابستگی جزئی که نشان‌دهنده اثر مستقیم این ویژگی بر خروجی مدل است، را بدون اثر سایر متغیرها نشان می‌دهد. خطوط عمودی کوتاه<sup>۳</sup> توزیع داده‌های واقعی در آن ویژگی را نشان می‌دهند.

همان گونه که در شکل ۸ا مشاهده می‌شود، با افزایش ویژگی برهم‌کنشی درصد نیتروژن گیاه و طول ویژه ریشه، مقدار عملکرد دانه نیز به طور صعودی و غیرخطی افزایش می‌یابد که این موضوع نشان‌دهنده اهمیت تغذیه نیتروژنی گیاه و تأثیر متقابل آن بر توسعه سیستم ریشه می‌باشد. نمودار ۸ب نشان می‌دهد که برهم‌کنش درصد کلونیزاسیون ریشه و محتوای فسفر گیاه در انتهای فصل رشد، مقدار عملکرد دانه را به صورت تصاعدی و غیرخطی افزایش می‌دهد که این موضوع تأییدی بر نقش مثبت همزیستی قارچ‌های میکوریز آربوسکولار در بهبود کلی رشد و نمو و عملکرد دانه ذرت می‌باشد (Bao et al., 2022; Brar et al., 2024; Khoso et al., 2024).

همان طور که در نمودار مشخص است، میزان اثر در مقادیر بالاتر محسوس‌تر است. نمودار ۸c رابطه صعودی و غیرخطی برهم‌کنش میانگین نرخ فتوسنتز بیشینه و شاخص سطح برگ و عملکرد دانه را نشان می‌دهد. شیب خط در ابتدا کم و به تدریج تندتر می‌شود؛ به ویژه از مقدار نرمال شده حدود ۰/۵ به بعد شتاب افزایش عملکرد دانه زیاد می‌شود. بیشتر مشاهدات واقعی در نواحی بین ۱- تا ۱ قرار دارند، این به این معنی است که اکثر گیاهان در مجموعه داده دارای این ویژگی در محدوده نسبتاً متوسط هستند. تأثیر این ویژگی بر عملکرد دانه در مقادیر بالاتر، شدیدتر می‌شود. به عبارت دیگر، حتی افزایش‌های کوچک در این ویژگی می‌تواند در دامنه بالا تأثیر زیادی بر عملکرد دانه داشته باشد، که این موضوع از نظر فیزیولوژیکی کاملاً منطقی به نظر می‌رسد (Taiz et al., 2018). نمودار ۸d رابطه برهم‌کنش میانگین دمای تاج‌پوشش و تعداد بلال بر عملکرد دانه ذرت را نشان می‌دهد که رابطه‌ای است صعودی و غیرخطی. تأثیر مستقیم افزایش دمای تاج‌پوشش بر عملکرد دانه ممکن است

1- Partial Dependence


2- Z-score

3- Tick marks

4- Base value

متغیر آموخته باشد، مثل همبستگی غیرخطی) (Canopy Temp\_4 = 40.8). به طور کلی، مدل از مقدار پایه ۵/۳ تن در هکتار عملکرد دانه شروع کرده و با تأثیر مثبت متغیرهای کلیدی (مثل عملکرد ماده خشک، شاخص سطح برگ، طول بلال و شدت فتوسنتز بیشینه)، خروجی را به مقدار نهایی حدود ۱۴/۸ تن در هکتار عملکرد دانه رسانده است و ویژگی‌های با اثر منفی، اندک و کم‌اثر بوده‌اند.

(Cob Length = 12.8). عدد بالای مربوط به برهم‌کنش ارتفاع گیاه و تعداد بلال اثر افزایشی بر عملکرد دانه داشت (PlantHeight\_CobNumber = 11603.3). برهم‌کنش شاخص سطح برگ  $\times$  میانگین SPAD نیز اثر مثبتی بر خروجی مدل گذاشته است (Leaf Area Index\_SPAD\_Mean = 108.45). دمای بالای پوشش گیاهی در مرحله پُر شدن دانه اثر مثبت دارد (این کمی نامعمول است و ممکن است مدل رفتار خاصی را از این



شکل ۸- نمودارهای وابستگی جزئی (A) اثر متقابل درصد نیتروژن گیاه و طول مخصوص ریشه، (B) اثر متقابل درصد کلونی‌زاسیون ریشه و درصد فسفر گیاه در انتهای فصل رشد، (C) اثر متقابل میانگین دمای تاج‌پوشش و تعداد بلال ذرت حاصل الگوریتم اس وی آر


Figure 8- Partial dependence plots: A) Interaction of plant nitrogen percentage and specific root length, B) Interaction of root colonization percentage and plant phosphorus content at the end of the growing season, C) Interaction of mean maximum photosynthesis rate and leaf area index, D) Interaction of mean canopy temperature and cob number from the SVR algorithm

برای تفسیر خروجی‌های مدل پیشنهادی CNN استفاده شده که بیش‌های کلیدی در توضیح نتایج پیش‌بینی عملکرد (اهمیت


سیرواستاوا و همکاران (Srivastava et al., 2022) پیشنهاد کردند که فراتر از پیش‌بینی، از نمودارهای SHAP و فورس پلات

به‌عنوان مهم‌ترین ویژگی‌هایی که بر خروجی مدل در تکنیک توصیه محصول در کشاورزی هوشمند تأثیر دارند، شناسایی شده‌اند (Abekoon et al., 2025).

متغیرها برحسب زمان ارائه داد. آن‌ها DUL، سرعت باد در هفته دهم، و مقدار تابش در هفته هفتم را به‌عنوان مهم‌ترین ویژگی‌ها در پیش‌بینی عملکرد گندم زمستانه یافتند. گزارش شده است که رطوبت، فسفر (P)، پتاسیم (K)، دما، بارندگی، نیتروژن (N)، و pH



شکل ۹- نمودار فورس پلات تولی شده توسط مدل لایت جی بی ام (شرح کامل متغیرها در جدول ۱ آورده شده است)  
Figure 9- Force plot generated by the LightGBM model (Full descriptions of variables shown in table 1)



شکل ۱۰- نمودار زیان در هر اپوک مدل شبکه عصبی عمیق ارتقاء یافته  
Figure 10- Loss per epoch plot for the enhanced deep neural network model

هم‌گرایی زیان آموزش و اعتبارسنجی می‌باشد که تأکیدی بر یادگیری مؤثر توسط الگوریتم است.

### نتیجه‌گیری

**یافته‌ها:** آنفیس و ترنسفورمر به‌ترتیب با ضریب تبیین برابر با ۰/۵۴۴ و ۰/۵۴۵ و جذر میانگین مربعات خطا ۲/۸۳۹ و ۲/۸۳۴ به‌دلیل به‌کارگیری سازوکار ترکیبی TensorFlow (در آنفیس) و Attention (در ترنسفورمر) و همچنین استفاده از بهینه‌ساز Adam در هر دو الگوریتم، تعاملات پیچیده را به‌خوبی مدل‌سازی کردند و به‌عنوان برترین الگوریتم‌های یادگیری ماشین در پیش‌بینی عملکرد دانه ذرت شناخته شدند. در رتبه بعدی، الگوریتم‌های آن‌ان قرار گرفت که با معماری سه لایه، فعال‌ساز ReLU و استفاده از بهینه‌ساز GriedSearch با تعیین اعتبار متقابل، روابط غیرخطی را

### نمودار زیان در هر اپوک

اپوک<sup>۱</sup> یک دوره کامل از پردازش تمام داده‌های آموزشی توسط مدل در فرآیند یادگیری ماشین است. نمودار زیان در هر اپوک<sup>۲</sup> نشان‌دهنده میزان خطای مدل در طول فرآیند یادگیری در هر دوره یا اپوک است. با افزایش تعداد اپوک‌ها، معمولاً مقدار زیان کاهش می‌یابد که نشان‌دهنده بهبود عملکرد مدل است، مگر اینکه مدل بیش از حد به داده‌های آموزشی وابسته شود (اصطلاحاً اُورفیتینگ یا بیش‌برازش رخ دهد). این نمودار برای ارزیابی و تنظیم فرآیند یادگیری ماشین استفاده می‌شود. نمودار زیان در هر اپوک مدل شبکه عصبی عمیق ارتقاء یافته در شکل ۱۰ نشان داده شده است. انطباق بسیار نزدیک دو نمودار به‌ویژه از اپوک ۱۰۰ به بعد حاکی از

1- Epoch  
2- Loss per Epoch

**محدودیت‌ها:** محدودیت‌هایی مثل اندازه نسبتاً کوچک مجموعه داده‌ها و تمرکز روی یک منطقه خاص وجود دارد که در تحقیقات آینده می‌تواند برطرف شود، با این حال، در تفسیر نتایج برای آزمایش‌هایی با داده‌های کمتر، جانب احتیاط باید رعایت شود. نتایج این مطالعه می‌تواند زمینه‌های لازم برای مدیریت زراعی مؤثر در جهت افزایش کارایی نهاده‌ها و سازگاری با شرایط تنش و تغییرات اقلیمی در تولید ذرت دانه‌ای را فراهم آورد.

**توصیه‌ها:** استفاده از RF برای سیستم‌های پشتیبانی تصمیم کشاورزی و ادغام داده‌های ماهواره‌ای برای پوشش مکانی بهتر، می‌تواند دقت و کارایی مدل‌ها را افزایش دهد.

به‌خوبی مدل‌سازی کرد و عملکردی بسیار نزدیک به آنفیس و ترنسفورمر از خود نشان داد ( $R^2 = 0.518$ ). ویژگی‌های دمای تاج‌پوشش در مرحله پُر شدن دانه، محتوای نیتروژن گیاه و طول ویژه ریشه، شاخص سطح برگ و عدد اسپد، ارتفاع بوته و تعداد بلال و اثر ساده دمای تاج‌پوشش در مرحله کاکل‌دهی به‌عنوان مهم‌ترین متغیرهای شکل‌دهنده عملکرد دانه ذرت، توسط چهار الگوریتم برتر تشخیص داده شد. عمده ویژگی‌های تشخیص داده‌شده نشان‌دهنده اهمیت تعامل بین کولونیزاسیون ریشه و سیستم فتوسنتزی بود که با مطالعات قبلی هم‌خوانی دارد. این الگوریتم‌ها نشان دادند که با یادگیری الگوهای پنهان در داده‌ها، می‌توانند روابط اکوفیزیولوژیکی دخیل در شکل‌گیری عملکرد دانه ذرت را مشخص کرده و پیش‌بینی دقیق‌تر آن را ممکن سازند.

## References

- Abekoon, T., Sajindra, H., Rathnayake, N., Ekanayake, I., Jayakody, A. (2025). A novel application with explainable machine learning (SHAP and LIME) to predict soil N, P, and K nutrient content in cabbage cultivation. *Smart Agricultural Technology*, 11, 100879. <https://doi.org/10.1016/j.atech.2025.100879>
- Bao, X., Zou, J., Zhang, B., Wu, L., Yang, T., & Huang, Q. (2022). Arbuscular mycorrhizal fungi and microbes interaction in rice mycorrhizosphere. *Agronomy*, 12(6), 1277. <https://doi.org/10.3390/agronomy12061277>
- Bhupenchandra, I., Chongtham, S. K., Devi, A. G., & Dutta, P. (2024). Unlocking the potential of arbuscular mycorrhizal fungi: exploring role in plant growth promotion, nutrient uptake mechanisms, biotic stress alleviation, and sustaining agricultural production systems. *Journal of Plant Growth Regulation*. <https://doi.org/10.1007/s00344-024-11467-9>
- Bracho-Mujica, G., Rötter, R. P., Haakana, M., Palosuo, T., Fronzek, S., Asseng, S., Yi, C., Gaiser, T., Kassie, B., Paff, K., Eyshi Rezaei, E., Rodriguez, A., Ruiz-Ramos, M., Srivastava, A. K., Stratonovich, P., Tao, F., & Semenov, M. A. (2024). Effects of changes in climatic means, variability, and agro-technologies on future wheat and maize yields at 10 sites across the globe. *Agricultural and Forest Meteorology*, 346, 109887. <https://doi.org/10.1016/j.agrformet.2024.109887>
- Brar, B., Bala, K., Saharan, B. S., Kumar Sadh, P., & Duhan, J. S. (2024). Bio-boosting agriculture: Harnessing the potential of fungi-bacteria-plant synergies for crop improvement. *Discover Plants*, 1, 21. <https://doi.org/10.1007/s44372-024-00023-0>
- Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences*, 2nd Ed. New York: Routledge.
- Fashoto, S., Mbunge, E., Opeyemi, O. G., & Van Den Burg, J., (2021). Implementation of machine learning for predicting maize crop yields using multiple linear regression and backward elimination. *Malaysian Journal of Computing*, 6, 679–697.
- Godfray, H. C. J., Poore, J., & Ritchie, H. (2024). Opportunities to produce food from substantially less land. *BMC Biology*, 22,138. <https://doi.org/10.1186/s12915-024-01936-8>
- Khaki, S., Wang, A., & Archontoulis, A. V. (2020). A CNN-RNN Framework for Crop Yield Prediction. *Front. Plant Sci. Sec. Computational Genomics*, <https://doi.org/10.3389/fpls.2019.01750>
- Khoso, M. A., Wagan, S., Alam, I., Hussain, A., Ali, Q., Saha, S., Poudel, T. R., Manghwar, H., & Liu, F. (2024). Impact of plant growth-promoting rhizobacteria (PGPR) on plant nutrition and root characteristics: Current perspective. *Plant Stress*, 11, 100341. <https://doi.org/10.1016/j.stress.2023.100341>.
- Kuhn, M., & Johnson, K. (2013). *Applied Predictive Modeling*. Springer Science & Business Media, 600 p. ISBN: 978-1-4614-6848-6. <https://doi.org/10.1007/978-1-4614-6849-3>
- Mitra, D., Panneerselvam, P., Senapati, A., Chidambaranathan, P., Nayak, A. K., & Mohapatra, P. K. D. (2023). Arbuscular mycorrhizal fungi response on soil phosphorus utilization and enzymes activities in aerobic rice under phosphorus-deficient conditions. *Life (Basel)*. 30,3(5), 1118. <https://doi.org/10.3390/life13051118>
- Moore, D. S., Notz, W. I., & Flinger, M. A. (2013). *The Basic Practice of Statistics* (6th ed.). New York, NY: W. H. Freeman and Company. 138 p.
- Nayak, H. S., Silva, J. V., Parihar, C. M., Krupnik, T. J., Sena, D. R., Kakraliya, S. K., Jat, H. S., Sidhu, H. S., Sharma, P. C., Jat, M. L., Sapkota, T. B. (2022). Interpretable machine learning methods to explain on-farm yield variability of high productivity wheat in Northwest India. *Field Crops Research*, 287, 108640. <https://doi.org/10.1016/j.fcr.2022.108640>

15. Pentos, K., Mbah, J. T., Pieczarka, K., Niedbała, G., & Wojciechowski, T. (2022). Evaluation of multiple linear regression and machine learning approaches to predict soil compaction and shear stress based on electrical parameters. *Applied Sciences*, 12(17), 8791. <https://doi.org/10.3390/app12178791>
16. Salvador, G. L. O., Araj, F. F., Pereira, A. P. A., Bonofacio, A., & Araujo, A. S. F. (2022). Rhizobacteria and arbuscular mycorrhizal fungus presented distinct and specific effects on soybean growth when inoculated with organic compost. *Rhizosphere*, 22, 100513. <https://doi.org/10.1016/j.rhisph.2022.100513>
17. Srivastava, A. K., Safaei, N., Khaki, S., Lopez, G., Zeng, W., Ewert, F. Gaiser, T., & Rahimi, J. (2022). Winter wheat yield prediction using convolutional neural networks from environmental and phenological data. *Scientific Reports*, 12(1). <https://doi.org/10.1038/s41598-022-06249-w>
18. Taiz, L., Moller, I. M., Murphy, A., & Peer, W.A. (2018). *Fundamentals of Plant Physiology*. New York, USA: Oxford University. Press. ISBN 978160535790
19. Wang, Y., Zhang, Q., Yu, F., Zhang, N., Zhang, X., Li, Y., Wang, M., & Zhang, J. (2024). Progress in research on deep learning-based crop yield prediction. *Agronomy*, 14(10), 2264. <https://doi.org/10.3390/agronomy14102264>
20. Xie, X., Wu, T., Zhu, M., Jiang, G., Xu, Y., Wang, X., & Pu, L. (2021). Comparison of random forest and multiple linear regression models for estimation of soil extracellular enzyme activities in agricultural reclaimed coastal saline land. *Ecological Indicators*, 120, 106925. <https://doi.org/10.1016/j.ecolind.2020.106925>