



Machine Learning Algorithms in Cereal Yield Prediction: An Analytical Review

Leyla Nazari¹ & Khadijeh Alijani¹

¹ Crop and Horticultural Science Research Department, Fars Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Shiraz, Iran.

Corresponding author. E-mail: L.nazari@areeo.ac.ir

ABSTRACT

Introduction: Accurate crop yield prediction, particularly for cereal crops as the primary source of global food energy, plays a critical role in food security management, production planning, agricultural trade, and climate change adaptation. Although traditional approaches based on linear regression and classical statistical methods have been widely applied, they often face limitations when dealing with complex, nonlinear, multi-dimensional, and heterogeneous datasets. Recent advances in remote sensing technologies, field-based sensors, geographic information systems (GIS), and the rapid growth of agricultural data have accelerated the adoption of machine learning techniques in crop yield prediction. By capturing hidden patterns and nonlinear interactions among climatic, management, soil, and genetic factors, machine learning algorithms have emerged as powerful tools for predictive modeling in agriculture. This review aims to examine the application of the most widely used machine learning algorithms for predicting the yield of major cereal crops, including wheat, barley, rice, and maize, while analyzing the key stages of model development and highlighting current challenges and future research opportunities.

Materials and methods: This review synthesizes published studies on crop yield prediction using machine learning approaches. Commonly applied algorithms include multiple regression, regression trees, random forests, support vector machines (SVM), multilayer perceptrons (MLP), artificial neural networks (ANN), and deep learning architectures such as deep neural networks (DNN) and long short-term memory (LSTM) networks. The development of predictive models typically involves several sequential stages, including data acquisition, preprocessing, feature selection, model training, validation, and performance evaluation. In most studies, datasets are divided into training and testing subsets, and model performance is assessed using appropriate statistical and machine learning evaluation metrics.

Results: The reviewed studies indicate that input data quality, feature selection strategies, and validation procedures are among the most influential factors affecting prediction accuracy. Frequently used predictors include temperature, precipitation, soil moisture, soil physicochemical properties, remotely sensed vegetation indices, crop management practices, and plant genetic information. Data preprocessing procedures, including missing-value treatment, outlier detection, normalization, and dimensionality reduction, substantially improves model robustness and predictive performance. Furthermore, feature selection methods based on filter, wrapper, and embedded approaches help eliminate redundant variables and enhance model efficiency. Comparative analyses across studies revealed that tree-based algorithms, particularly Random Forest and Gradient Boosting methods, consistently achieve strong predictive performance under diverse environmental conditions. Deep learning models demonstrate superior capability in capturing complex nonlinear relationships when large-scale datasets are available. Model performance is commonly evaluated using metrics such as the coefficient of determination (R^2), root mean square error (RMSE), mean absolute error (MAE), accuracy, recall, and F1-score. In addition, cross-validation techniques, especially K-fold cross-validation, are widely employed to assess model stability and generalizability.

Conclusion: Machine learning offers substantial potential for improving crop yield prediction accuracy and supporting data-driven decision-making in precision agriculture. However, several challenges remain, including the limited availability of standardized long-term datasets, data heterogeneity, the high cost of data acquisition technologies, and the limited interpretability of complex predictive models. Future research should focus on the development of large-scale multi-source databases, the integration of climatic, soil, genetic, and remote sensing information, the adoption of advanced deep learning and explainable artificial intelligence (XAI) frameworks, and the validation of predictive models across diverse environmental and management conditions. Addressing these challenges will enhance the robustness, scalability, and practical applicability of machine learning-based crop yield prediction systems.

Keywords: Climatic Data, Deep Learning, Feature Selection, Precision Agriculture, Remote Sensing.

Article Type: Research Article

Article history: Received: 14 Dec 2025, Revised: 17 Feb 2026, Accepted: 03 Mar 2026, Published online: 28 Mar 2026

Cite this article: Nazari, L. & Alijani, K. (2026). Machine Learning Algorithms in Cereal Yield Prediction: An Analytical Review. *Cereal Biotechnology and Biochemistry*, 5(1), 147-165. DOI: [10.22126/cbb.2026.13903.1145](https://doi.org/10.22126/cbb.2026.13903.1145)



© The Author(s).
[10.22126/cbb.2026.13903.1145](https://doi.org/10.22126/cbb.2026.13903.1145)

Publisher: Razi University



الگوریتم‌های یادگیری ماشین در پیش‌بینی عملکرد غلات: یک مرور تحلیلی

لیلا نظری^۱ و خدیجه علیجانی^۱

^۱ بخش تحقیقات زراعی و باغی، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی فارس، سازمان تحقیقات، آموزش و ترویج کشاورزی، شیراز، ایران.
✉ نویسنده مسئول. رایانامه: l.nazari@areeo.ac.ir

چکیده

مقدمه: پیش‌بینی دقیق عملکرد محصولات زراعی، به‌ویژه غلات به‌عنوان اصلی‌ترین منبع تأمین انرژی غذایی جهان، نقشی کلیدی در مدیریت امنیت غذایی، برنامه‌ریزی تولید، تجارت محصولات کشاورزی و سازگاری با تغییرات اقلیمی ایفا می‌کند. روش‌های سنتی مبتنی بر مدل‌های رگرسیون خطی و آمار کلاسیک، اگرچه در بسیاری از مطالعات مورد استفاده قرار گرفته‌اند، اما در مواجهه با داده‌های پیچیده، غیرخطی، چندبعدی و ناهمگن با محدودیت‌هایی مواجه هستند. در سال‌های اخیر، پیشرفت فناوری‌های سنجش از دور، حسگرهای مزرعه‌ای، سامانه‌های اطلاعات جغرافیایی و افزایش حجم داده‌های کشاورزی، زمینه استفاده گسترده از روش‌های یادگیری ماشین را فراهم کرده است. این الگوریتم‌ها با قابلیت شناسایی الگوهای پنهان و روابط غیرخطی میان عوامل اقلیمی، مدیریتی، خاکی و ژنتیکی، به ابزارهای مؤثری برای پیش‌بینی عملکرد محصولات تبدیل شده‌اند. هدف این مقاله مروری، بررسی کاربرد رایج‌ترین الگوریتم‌های یادگیری ماشین در پیش‌بینی عملکرد گندم، جو، برنج و ذرت، تحلیل مراحل توسعه مدل‌های پیش‌بینی و تبیین چالش‌ها و فرصت‌های پژوهشی موجود در این حوزه است.

مواد و روش‌ها: در این مطالعه، پژوهش‌های منتشرشده در زمینه پیش‌بینی عملکرد محصولات زراعی با استفاده از یادگیری ماشین مورد بررسی قرار گرفتند. الگوریتم‌هایی نظیر رگرسیون چندمتغیره، درخت رگرسیون، جنگل تصادفی، ماشین بردار پشتیبان، پرسپترون چندلایه، شبکه‌های عصبی مصنوعی و مدل‌های یادگیری عمیق از جمله شبکه‌های عصبی عمیق و حافظه طولانی کوتاه‌مدت از پرکاربردترین روش‌های مورد استفاده در مطالعات مختلف هستند. توسعه مدل‌های پیش‌بینی شامل مراحل جمع‌آوری داده، پیش‌پردازش، انتخاب ویژگی، آموزش مدل، اعتبارسنجی و ارزیابی عملکرد است. در این فرآیند، داده‌ها به مجموعه‌های آموزشی و آزمایشی تقسیم شده و عملکرد مدل‌ها با استفاده از معیارهای آماری مناسب مورد ارزیابی قرار می‌گیرد.

یافته‌ها: نتایج مطالعات نشان می‌دهد که کیفیت داده‌های ورودی، انتخاب ویژگی‌های مناسب و روش ارزیابی مدل از مهم‌ترین عوامل مؤثر بر دقت پیش‌بینی هستند. متغیرهایی نظیر دما، بارش، رطوبت خاک، خصوصیات فیزیکی و شیمیایی خاک، شاخص‌های پوشش گیاهی حاصل از سنجش از دور، عملیات مدیریتی مزرعه و اطلاعات ژنتیکی گیاهان از مهم‌ترین متغیرهای مورد استفاده در مدل‌های پیش‌بینی عملکرد به شمار می‌روند. پیش‌پردازش داده‌ها شامل حذف داده‌های گمشده، شناسایی مقادیر پرت، نرمال‌سازی و کاهش ابعاد داده، نقش مهمی در بهبود کارایی مدل‌ها دارد. همچنین، انتخاب ویژگی با استفاده از روش‌های فیلتر، بسته‌بند و تعبیه‌شده موجب حذف متغیرهای غیرمؤثر و افزایش دقت پیش‌بینی می‌شود. بررسی مطالعات مختلف نشان داد که الگوریتم‌های مبتنی بر درخت مانند جنگل تصادفی و تقویت گرادایان، در بسیاری از شرایط عملکرد مطلوبی داشته‌اند، در حالی که مدل‌های یادگیری عمیق در صورت دسترسی به مجموعه داده‌های بزرگ، توانایی بیشتری در استخراج روابط پیچیده و بهبود دقت پیش‌بینی نشان داده‌اند. ارزیابی عملکرد مدل‌ها عمدتاً با استفاده از معیارهایی نظیر ضریب تبیین، ریشه میانگین مربعات خطا، میانگین خطای مطلق، دقت، فراخوانی و امتیاز F1 انجام می‌شود. همچنین، اعتبارسنجی متقابل، به‌ویژه روش K-fold، یکی از متداول‌ترین رویکردها برای ارزیابی قابلیت تعمیم مدل‌ها است.

نتیجه‌گیری: یادگیری ماشین ظرفیت قابل‌توجهی برای افزایش دقت پیش‌بینی عملکرد محصولات زراعی و پشتیبانی از تصمیم‌گیری در کشاورزی دقیق دارد. با این حال، محدودیت‌هایی نظیر کمبود داده‌های استاندارد و بلندمدت، ناهمگنی داده‌ها، هزینه بالای فناوری‌های جمع‌آوری داده و تفسیرپذیری محدود برخی مدل‌های پیچیده همچنان از چالش‌های اصلی این حوزه محسوب می‌شوند. توسعه پایگاه‌های داده چندمنبعی، ادغام داده‌های اقلیمی، خاکی، ژنتیکی و سنجش از دور، بهره‌گیری از روش‌های یادگیری عمیق و هوش مصنوعی توضیح‌پذیر و همچنین اعتبارسنجی مدل‌ها در شرایط اقلیمی و مدیریتی متنوع، از مهم‌ترین اولویت‌های پژوهشی آینده برای افزایش قابلیت کاربرد و تعمیم‌پذیری مدل‌های پیش‌بینی عملکرد خواهند بود.

واژه‌های کلیدی: انتخاب ویژگی، داده‌های اقلیمی، سنجش از دور، کشاورزی دقیق، یادگیری عمیق.

نوع مقاله: مقاله پژوهشی

نوع مقاله دریافت: ۱۴۰۴/۰۹/۲۳ **اصلاح:** ۱۴۰۴/۱۱/۲۸ **پذیرش:** ۱۴۰۴/۱۲/۱۲، **انتشار آنلاین:** ۱۴۰۵/۰۱/۰۸

استناد: نظری، ل. و علیجانی، خ. (۱۴۰۵). الگوریتم‌های یادگیری ماشین در پیش‌بینی عملکرد غلات: یک مرور تحلیلی. *بیوتکنولوژی و بیوشیمی غلات*، ۵(۱)، ۱۴۷-۱۶۵

DOI: [10.22126/cbb.2026.13903.1145](https://doi.org/10.22126/cbb.2026.13903.1145)



© نویسندگان.

ناشر: دانشگاه رازی

مقدمه

پیش‌بینی دقیق عملکرد محصولات کشاورزی، به‌ویژه غلات، برای مقابله با چالش‌های امنیت غذایی و تغییرات اقلیمی ضروری است. این پیش‌بینی‌ها می‌توانند به کشاورزان در تصمیم‌گیری‌های مهمی مانند انتخاب محصول، زمان کاشت و مدیریت مزرعه کمک کنند. در سال‌های اخیر، رویکردهای مبتنی بر یادگیری ماشین (Machine Learning; ML) به‌دلیل توانایی در مدل‌سازی روابط پیچیده میان عملکرد محصول و عوامل مؤثر بر آن، توجه گسترده‌ای را به خود جلب کرده‌اند (Van Klompenburg et al., 2020; Liakos et al., 2018). یادگیری ماشین، به‌عنوان شاخه‌ای از هوش مصنوعی، با استخراج الگوها و روابط از داده‌ها، امکان پیش‌بینی و تصمیم‌گیری را بدون برنامه‌نویسی صریح فراهم می‌کند (Liakos et al., 2018). این فناوری در سال‌های اخیر در حوزه‌های مختلف کشاورزی، از جمله پیش‌بینی عملکرد، تشخیص بیماری‌های گیاهی، مدیریت آبیاری و کشاورزی دقیق، کاربرد گسترده‌ای یافته است (Van Klompenburg et al., 2020).

در یک مطالعه، ژنوتیپ‌های مختلف سورگوم بر اساس ویژگی‌های بافتی و پارامترهای هندسی دانه با استفاده از پردازش تصویر و الگوریتم‌های یادگیری ماشین با دقت ۹۹ درصد طبقه‌بندی شدند (Nazari et al., 2021). در مطالعه‌ای دیگر، با بهره‌گیری از تجزیه و تحلیل تصویر و مدل‌های یادگیری ماشین نشان دادند که دانه‌های سورگوم تولید شده تحت شرایط آبیاری نرمال و تنش

خشکی با دقتی نزدیک به ۱۰۰ درصد قابل تفکیک هستند. این یافته‌ها بیانگر ظرفیت بالای یادگیری ماشین در ارزیابی کیفیت دانه و شناسایی محصولات متأثر از تنش کم‌آبی پیش از ورود به زنجیره غذایی است (Ropelewska & Nazari, 2021).

مدل‌های یادگیری ماشین با شناسایی روابط میان داده‌های سنسوری، تصویری و محیطی، امکان پیش‌بینی ویژگی‌های فیزیولوژیک و بیوشیمیایی گیاه را فراهم کرده و می‌توانند فرایند انتخاب ژنوتیپ‌های برتر را تسریع کنند. در یک مطالعه، پژوهشگران از ویژگی‌های بافتی استخراج شده از تصاویر دانه و شبکه پرسپترون چندلایه (Multilayer Perceptron; MLP) برای پیش‌بینی ترکیبات فنلی کل، تانن و پروتئین دانه سورگوم استفاده کردند. نتایج نشان داد که مدل‌های MLP از دقت بالایی برخوردار بوده و همبستگی بین مقادیر اندازه‌گیری شده و پیش‌بینی شده برای این صفات بیش از ۰/۹۱۵ بود (Nazari et al., 2022).

یادگیری ماشین در حوزه‌های مختلف اومیکس، از جمله ژنومیکس، ترانسکریپتومیکس، پروتئومیکس، متابولومیکس و اپیژنتیک، به‌طور گسترده برای شناسایی الگوهای پنهان و روابط پیچیده میان ژن‌ها و صفات به‌کار گرفته می‌شود. در داده‌های ترانسکریپتومی، این روش‌ها امکان شناسایی و اولویت‌بندی ژن‌های کلیدی مرتبط با پاسخ به تنش‌های محیطی را فراهم می‌کنند. برای مثال، در یک مطالعه، ژن‌های مؤثر در پاسخ ذرت شیرین به

برخلاف مطالعات مرور نظام‌مند که بر پایه پروتکل‌های مشخص به شناسایی، غربالگری و تحلیل جامع مطالعات مرتبط می‌پردازند، این مقاله رویکردی تحلیلی و آموزشی دارد. در این راستا، مفاهیم، روش‌ها و مطالعات شاخص منتشرشده در زمینه پیش‌بینی عملکرد غلات بررسی شده‌اند. هدف نهایی، ارائه تصویری منسجم از وضعیت کنونی دانش و روندهای پژوهشی این حوزه است.

منابع مورد استفاده از پایگاه‌های اطلاعاتی Web of Science، Scopus، ScienceDirect و Google Scholar گردآوری شدند. جستجوی منابع با استفاده از کلیدواژه‌هایی نظیر Crop Yield Prediction، Cereal، Deep Machine Learning، Yield Prediction و Artificial Intelligence و نام غلات مهم شامل گندم، جو، ذرت و برنج انجام شد. مطالعات منتشرشده در بازه زمانی ۲۰۱۵ تا ۲۰۲۵ مورد بررسی قرار گرفتند. در مرحله نخست، ۱۵۴ مقاله شناسایی شد. پس از حذف منابع تکراری و مطالعات نامرتبط با پیش‌بینی عملکرد غلات، مقالات باقی‌مانده غربالگری شدند. سپس مطالعات بر اساس ارتباط موضوعی، اعتبار علمی، تعداد استنادها و نقش آن‌ها در تبیین مفاهیم، الگوریتم‌ها، روش‌های انتخاب ویژگی، معیارهای ارزیابی و کاربردهای پیش‌بینی عملکرد انتخاب شدند. در نهایت، ۱۸ مقاله برای تحلیل، مقایسه و استخراج نتایج مورد استفاده قرار گرفت.

یادگیری ماشین در پیش‌بینی عملکرد غلات

تنش تراکم با استفاده از روش لاسو (Least Absolute Shrinkage and Selection Operator; LASSO) انتخاب شدند و سپس واکنش گیاه بر اساس پروفایل بیان ژن با الگوریتم‌های مختلف یادگیری ماشین پیش‌بینی شد. مدل‌های توسعه‌یافته توانستند پاسخ به تنش را با دقت ۱۰۰ درصد پیش‌بینی کنند (Zeinalzadeh-Tabrizi & Nazari, 2025).

در یک پژوهش، ژن‌های کلیدی مرتبط با پاسخ ذرت به تنش‌های زیستی از طریق متاآنالیز داده‌های بیان ژن و با استفاده از روش انتخاب ویژگی مبتنی بر همبستگی (Correlation-based Feature Selection; CFS) شناسایی شدند (Nazari & Zinati, 2023). همچنین، در مطالعه‌ای دیگر، روش‌های یادگیری ماشین و یادگیری عمیق برای شناسایی ژن‌های مرتبط با مقاومت به تنش‌های زیستی در ذرت به کار گرفته شدند. نتایج نشان داد که با انتخاب ویژگی‌های مناسب، ژن‌های با بیان تفاضلی مرتبط با تنش‌های زیستی با دقت بالایی قابل شناسایی هستند و این رویکرد می‌تواند در توسعه ارقام مقاوم به بیماری مورد استفاده قرار گیرد (Nazari et al., 2023).

این مقاله با هدف ارائه مروری تحلیلی بر کاربرد الگوریتم‌های یادگیری ماشین در پیش‌بینی عملکرد غلات تدوین شده است. تمرکز اصلی آن بر معرفی الگوریتم‌های پرکاربرد، روش‌های انتخاب ویژگی، معیارهای ارزیابی مدل‌ها و چالش‌ها و چشم‌اندازهای این حوزه است.

مطالعات متعددی در زمینه پیش‌بینی عملکرد غلات با استفاده از یادگیری ماشین انجام شده است. برای مثال، خاکی و وانگ (Khaki & Wang, 2019) عملکرد ذرت هیبرید را با استفاده از یک شبکه عصبی عمیق (Deep Neural Network; DNN) پیش‌بینی کردند. داده‌های مورد استفاده شامل ۲۲۶۷ ژنوتیپ ارزیابی‌شده در ۲۲۴۷ مکان بود که توسط شرکت سینجنتا طی سال‌های ۲۰۰۸ تا ۲۰۱۶ جمع‌آوری شده بودند. نتایج نشان داد که شبکه عصبی عمیق دقت پیش‌بینی بالایی دارد. مقدار ریشه میانگین مربعات خطا (Root Mean Squared Error; RMSE) در مجموعه اعتبارسنجی با استفاده از داده‌های پیش‌بینی‌شده هواشناسی برابر با ۱۲ درصد عملکرد متوسط بود. با استفاده از داده‌های کامل هواشناسی، این مقدار به ۱۱ درصد کاهش یافت. همچنین، انتخاب ویژگی توانست ابعاد فضای ورودی را بدون کاهش معنی‌دار دقت مدل کاهش دهد. مقایسه الگوریتم‌ها نشان داد که DNN عملکرد بهتری نسبت به لاسو، شبکه عصبی کم‌عمق (Shallow Neural Network; SNN) و درخت رگرسیون دارد. نتایج این مطالعه همچنین بیانگر آن بود که عوامل محیطی نسبت به ژنوتیپ تأثیر بیشتری بر عملکرد محصول دارند (Khaki & Wang, 2019).

در مطالعه‌ای دیگر، مدل‌های پیش‌بینی زود هنگام عملکرد غلات در مقیاس مزرعه در دشت قیروان تونس ارزیابی شدند (Mohapatra et al., 2025). برای این منظور، از داده‌های چندمنظوره شامل شاخص‌های استخراج‌شده از تصاویر ماهواره‌های سنتینل-۱ و سنتینل-۲ استفاده شد.

داده‌های عملکرد محصول، بارندگی، دما، مصرف آفت‌کش‌ها و سال کشت طی سال‌های زراعی ۲۰۱۸-۲۰۱۷ و ۲۰۲۱-۲۰۲۰ جمع‌آوری شدند. پس از پیش‌پردازش و ادغام داده‌ها، مجموعه‌ای شامل ۱۲ ویژگی ایجاد شد. تحلیل اهمیت ویژگی‌ها نشان داد که می‌توان تعداد متغیرها را به هفت ویژگی کلیدی کاهش داد. سپس الگوریتم‌های مختلفی شامل رگرسیون تقویت گرادیانی، جنگل تصادفی، ماشین بردار پشتیبان و درخت رگرسیون برای پیش‌بینی عملکرد به کار گرفته شدند. نتایج نشان داد که رگرسیون تقویت گرادیانی با دقت ۹۳ درصد بهترین عملکرد را در میان مدل‌های بررسی‌شده داشته است.

پیش‌بینی عملکرد غلات و کلزا (دو تا سه ماه پیش از برداشت) در سطح منطقه‌ای در لهستان طی دوره ۲۰۰۹ تا ۲۰۲۴ با استفاده از مدل‌های یادگیری ماشین و روش‌های کلاسیک آماری بررسی شد (Okupska et al., 2025). در این مطالعه، شاخص پوشش گیاهی نرمال‌شده (Normalized Difference Vegetation Index; NDVI) استخراج‌شده از تصاویر ماهواره‌ای و تعادل آب اقلیمی (Climatic Water Balance; CWB) محاسبه‌شده از داده‌های هواشناسی، به عنوان متغیرهای پیش‌بین مورد استفاده قرار گرفتند. عملکرد سه الگوریتم یادگیری ماشین شامل جنگل تصادفی، شبکه عصبی عمیق و رگرسیون تقویت گرادیانی با مدل رگرسیون خطی چندگانه مقایسه شد. نتایج نشان داد که NDVI در اوایل مارس بیشترین همبستگی را با عملکرد نهایی

که تحقیقات آینده باید بر یکپارچه‌سازی منابع داده متنوع، افزایش مقیاس‌پذیری مدل‌ها و توسعه روش‌های کمی‌سازی عدم قطعیت تمرکز کنند. به اعتقاد آنان، رفع این چالش‌ها می‌تواند زمینه استفاده گسترده‌تر از هوش مصنوعی را در مدیریت کشاورزی، تخصیص بهینه منابع و ارتقای امنیت غذایی در شرایط تغییر اقلیم فراهم کند (De Clercq & Mahdi, 2025).

در یک مطالعه، مدل‌های مختلف پیش‌بینی عملکرد گندم شامل رگرسیون بردار پشتیبان، جنگل تصادفی، شبکه عصبی مصنوعی و شبکه حافظه کوتاه‌مدت طویل با استفاده از مجموعه داده‌های جهانی با دسترسی آزاد برای استان آنکارا در ترکیه توسعه و ارزیابی شدند (Akcapinar & Apaydin, 2025). در مجموع، ۱۸۰ مدل در قالب ۱۵ سناریوی مختلف و سه رویکرد بهینه‌سازی مورد بررسی قرار گرفت. نتایج نشان داد که مدل شبکه حافظه طولانی کوتاه‌مدت با ضریب تبیین حدود ۰/۹۶ بالاترین کارایی را داشته است. این مدل امکان پیش‌بینی عملکرد را حداقل سه ماه پیش از برداشت فراهم کرد. نویسندگان همچنین نتیجه‌گیری کردند که در شرایط محدودیت داده‌های محلی، مجموعه داده‌های بین‌المللی با دسترسی آزاد می‌توانند جایگزینی مناسب برای توسعه مدل‌های پیش‌بینی عملکرد باشند.

بررسی مطالعات منتخب نشان می‌دهد که کارایی الگوریتم‌های یادگیری ماشین در پیش‌بینی عملکرد غلات به نوع داده‌های ورودی، حجم مجموعه داده، مقیاس

محصول دارد. برای غلات، مدل رگرسیون خطی چندگانه با ضریب تبیین ۰/۷۷۷ بهترین کارایی را نشان داد. در مقابل، برای کلزا، مدل جنگل تصادفی با ضریب تبیین ۰/۶۵۴ برترین مدل بود. همچنین تفاوت معنی‌داری بین کارایی مدل‌های یادگیری ماشین و رگرسیون خطی مشاهده نشد. نویسندگان این موضوع را به حجم نسبتاً محدود مجموعه داده (۲۵۶ مشاهده) نسبت دادند. این نتایج نشان می‌دهد که در شرایط کمبود داده، مدل‌های کلاسیک آماری همچنان می‌توانند عملکردی رقابت‌پذیر داشته باشند. بنابراین، انتخاب مدل باید متناسب با حجم داده و نوع محصول انجام شود.

دکلرک و مهدی (De Clercq & Mahdi, 2025) با بررسی ۱۵۶ مطالعه، رویکردهای داده‌محور مورد استفاده در پیش‌بینی عملکرد برنج را ارزیابی کردند. نتایج نشان داد که شبکه‌های عصبی مصنوعی و جنگل تصادفی از پرکاربردترین الگوریتم‌های این حوزه هستند. همچنین، داده‌های ماهواره‌ای همراه با متغیرهای اقلیمی، به‌ویژه بارش و دما، مهم‌ترین متغیرهای ورودی در بیشتر مطالعات بوده‌اند. با وجود پیشرفت‌های قابل توجه، این مرور چند چالش اساسی را شناسایی کرد. محدودیت دسترسی به داده‌های باکیفیت، بیش‌برازش در مدل‌های پیچیده و دشواری تعمیم مدل‌ها به مناطق جغرافیایی و ارقام مختلف برنج از مهم‌ترین این چالش‌ها بودند. نبود استاندارد واحد برای ارزیابی مدل‌ها و دشواری تلفیق داده‌های زمینی با مدل‌های یادگیری ماشین نیز از دیگر شکاف‌های پژوهشی گزارش شد. نویسندگان تأکید کردند

مکانی و زمانی مطالعه و ویژگی‌های محصول وابسته است و هیچ الگوریتمی را نمی‌توان به‌عنوان بهترین روش معرفی کرد. با این حال، شبکه‌های عصبی عمیق، مدل‌های حافظه طولانی کوتاه‌مدت (Long Short-Term Memory; LSTM)، جنگل تصادفی (Random Forest; RF) و روش‌های تقویت گرادیانی (Gradient Boosting; GB) از پرکاربردترین و موفق‌ترین رویکردهای سال‌های اخیر بوده‌اند. توانایی این الگوریتم‌ها در مدل‌سازی روابط غیرخطی و برهم‌کنش‌های پیچیده میان عوامل محیطی، مدیریتی و ژنتیکی از مهم‌ترین دلایل کاربرد گسترده آن‌ها در مطالعات پیش‌بینی عملکرد محسوب می‌شود (Khaki & Wang, 2019).

مقایسه نتایج مختلف نشان می‌دهد که مزیت مدل‌های یادگیری عمیق عمدتاً در شرایطی آشکار می‌شود که داده‌های حجیم، چندساله و چندمکانی در دسترس باشند. در چنین شرایطی، این مدل‌ها قادرند الگوهای پنهان و روابط پیچیده موجود در داده‌ها را با دقت بیشتری شناسایی کنند. در مقابل، در مجموعه‌داده‌های کوچک یا کم‌تنوع، الگوریتم‌های مبتنی بر درخت و مدل‌های آماری کلاسیک می‌توانند عملکردی مشابه یا گاه بهتر از مدل‌های پیچیده ارائه دهند. این یافته‌ها نشان می‌دهد که افزایش پیچیدگی مدل لزوماً به بهبود دقت پیش‌بینی منجر نمی‌شود و انتخاب الگوریتم باید متناسب با ویژگی‌های داده‌ها انجام شود (Okupska et al., 2025; Akcapinar & Apaydin, 2025).

از منظر داده‌های ورودی، متغیرهای اقلیمی نظیر دما، بارش و شاخص‌های مرتبط با وضعیت رطوبتی، در کنار شاخص‌های پوشش گیاهی حاصل از سنجش از دور، از مهم‌ترین عوامل مؤثر در پیش‌بینی عملکرد غلات هستند. مطالعات مختلف نشان داده‌اند که تلفیق داده‌های هواشناسی، تصاویر ماهواره‌ای و اطلاعات مدیریتی مزرعه معمولاً به افزایش دقت پیش‌بینی منجر می‌شود. این موضوع بیانگر آن است که یکپارچه‌سازی منابع داده‌ای مختلف، در مقایسه با اتکا به یک منبع اطلاعاتی منفرد، می‌تواند توان پیش‌بینی مدل‌ها را به‌طور قابل‌توجهی افزایش دهد (Mohapatra et al., 2025; Okupska et al., 2025).

با وجود پیشرفت‌های قابل توجه، چالش‌هایی نظیر محدودیت دسترسی به داده‌های باکیفیت، خطر بیش‌برازش در مدل‌های پیچیده، ناهمگونی معیارهای ارزیابی و محدود بودن اعتبارسنجی مدل‌ها به یک منطقه یا فصل زراعی همچنان وجود دارد. این مسائل مقایسه مستقیم نتایج مطالعات و ارزیابی قابلیت تعمیم مدل‌ها را دشوار می‌سازد. بنابراین، توسعه مدل‌های قابل انتقال به شرایط اقلیمی، مدیریتی و ژنتیکی مختلف، همراه با استفاده از چارچوب‌های استاندارد ارزیابی، از مهم‌ترین اولویت‌های پژوهشی آینده در این حوزه محسوب می‌شود (De Clercq & Mahdi, 2025; Van Klompenburg et al., 2020). جدول ۱ خلاصه‌ای از مطالعات منتخب، الگوریتم‌های مورد استفاده و مهم‌ترین نتایج گزارش‌شده در پیش‌بینی عملکرد غلات را ارائه می‌کند.

جدول ۱- کارآیی الگوریتم‌های یادگیری ماشین مورد استفاده در پیش‌بینی عملکرد غلات بر اساس مطالعات منتخب

Table 1- Performance of Machine Learning Algorithms Used in Cereal Yield Prediction Based on Selected Studies

گروه الگوریتم	مطالعات منتخب	عملکرد گزارش شده	جمع‌بندی
یادگیری عمیق (DNN, LSTM)	Khaki & Wang, 2019 Akcapanar & Apaydin, 2025	RMSE≈11-12% R ² ≈0.96	عملکرد بسیار مناسب در داده‌های بزرگ و روابط پیچیده
مبتنی بر درخت (RF, GBR)	Mohapatra <i>et al.</i> , 2025 Okupska <i>et al.</i> , 2025	Accuracy=93% R ² =0.652	عملکرد پایدار و مناسب برای داده‌های ناهمگن
مدل‌های خطی	Okupska <i>et al.</i> , 2025	R ² =0.777	در برخی شرایط می‌توانند با مدل‌های پیچیده رقابت کنند.

مقادیر گزارش شده از مطالعات مختلف استخراج شده‌اند و به دلیل تفاوت در داده‌ها، مقیاس مطالعات و معیارهای ارزیابی، صرفاً برای مقایسه کیفی ارائه شده‌اند.

عملکرد و ویژگی‌های الگوریتم‌های پرکاربرد به صورت مستقل بررسی می‌شوند.

روش‌شناسی: مراحل پیش‌بینی عملکرد

پیش‌بینی عملکرد محصولات زراعی با استفاده از روش‌های یادگیری ماشین یک فرایند داده‌محور و چندمرحله‌ای است. موفقیت این فرایند به کیفیت و تنوع داده‌های ورودی، پیش‌پردازش داده‌ها، انتخاب ویژگی، الگوریتم مدل‌سازی و روش‌های اعتبارسنجی بستگی دارد. اگرچه انتخاب الگوریتم مناسب نقش مهمی در افزایش دقت پیش‌بینی ایفا می‌کند، پیچیدگی بیشتر مدل لزوماً به معنای کارایی بالاتر نیست. در بسیاری از موارد، تناسب میان ویژگی‌های مجموعه داده و روش مدل‌سازی تأثیر

بیشتری بر نتایج نهایی دارد (De Clercq & Mahdi, 2025). شکل ۱ چارچوب کلی توسعه مدل‌های پیش‌بینی عملکرد را از جمع‌آوری و آماده‌سازی داده‌ها تا انتخاب ویژگی، آموزش مدل و ارزیابی عملکرد نشان می‌دهد.

تحلیل مطالعات منتخب (جدول ۱) نشان می‌دهد که مدل‌های یادگیری عمیق نظیر DNN و LSTM به مقادیر R² حدود ۰/۹۶ و RMSE حدود ۱۱ تا ۱۲ درصد دست یافته‌اند که نشان‌دهنده توان بالای آن‌ها در مدل‌سازی روابط پیچیده و داده‌های حجیم است. در مقابل، الگوریتم‌های مبتنی بر درخت مانند جنگل تصادفی و تقویت گرادیانی مقادیر R² حدود ۰/۶۵ و دقت پیش‌بینی تا ۹۳ درصد را گزارش کرده‌اند و عملکردی پایدار در داده‌های ناهمگن نشان داده‌اند. همچنین در برخی مطالعات، مدل‌های خطی کلاسیک با R² برابر ۰/۷۷۷ عملکردی قابل رقابت با مدل‌های پیچیده‌تر ارائه کرده‌اند.

در مجموع، نتایج مطالعات مرور شده بیانگر آن هستند که موفقیت مدل‌های پیش‌بینی عملکرد بیش از انتخاب الگوریتم، به کیفیت داده‌ها، انتخاب متغیرهای مناسب و طراحی صحیح فرایند مدل‌سازی وابسته است. در بخش‌های بعدی، مراحل توسعه مدل‌های پیش‌بینی

دستیابی به پیش‌بینی‌های دقیق مستلزم اجرای منظم تمامی این مراحل است.



شکل ۱- چارچوب کلی توسعه مدل‌های یادگیری ماشین برای پیش‌بینی عملکرد محصولات زراعی

Figure 1- General framework for the development of machine learning models for crop yield prediction

برآورد می‌شوند. سپس، داده‌های دیده نشده برای ارزیابی

کارایی مدل و سنجش قابلیت تعمیم آن مورد استفاده

قرار می‌گیرند (Van Klompenburg et al., 2020). در

این چارچوب، داده‌ها معمولاً به دو گروه اصلی شامل

توصیف مجموعه داده

مدل‌های پیش‌بینی عملکرد به دو مجموعه شامل

داده‌های آموزشی (Training Data) و داده‌های آزمایشی

(Testing Data) نیاز دارند. مدل با استفاده از ویژگی‌های

ورودی آموزش می‌بیند و پارامترهای آن در مرحله آموزش

هوا، داده‌های تصویری و برخی شاخص‌های تابشی است که در دسته‌های اصلی قرار نمی‌گیرند و در مطالعات پیش‌بینی عملکرد کمتر مورد استفاده واقع شده‌اند.

پیش‌پردازش داده‌ها

پیش‌پردازش داده‌ها یکی از مراحل کلیدی توسعه مدل‌های یادگیری ماشین است که بر کارایی مدل تأثیر مستقیم دارد. در پیش‌بینی عملکرد، داده‌های حاصل از منابع مختلف اقلیمی، خاکی، گیاهی و سنجش از دور معمولاً پیش از مدل‌سازی تحت فرایندهایی مانند مدیریت داده‌های گمشده، حذف داده‌های پرت و استانداردسازی قرار می‌گیرند تا دقت پیش‌بینی و قابلیت تعمیم مدل افزایش یابد (Van Klompenburg et al., 2020; Montesinos-López et al., 2024).

انتخاب ویژگی

در مطالعات پیش‌بینی عملکرد، متغیرهای ورودی طیف گسترده‌ای از صفات ژنتیکی، فنوتیپی و فیزیولوژیکی گیاه، ویژگی‌های خاک، عوامل اقلیمی و مدیریتی، داده‌های سنجش از دور و اطلاعات مولکولی را شامل می‌شوند (Van Klompenburg et al., 2020). با این حال، استفاده از تعداد زیاد متغیرها لزوماً به بهبود عملکرد مدل منجر نمی‌شود و می‌تواند موجب افزایش پیچیدگی محاسباتی، بیش‌برازش و کاهش قابلیت تعمیم مدل شود (Li et al., 2017). از این‌رو، انتخاب ویژگی به‌عنوان یکی از مراحل مهم توسعه مدل‌های یادگیری ماشین، با هدف شناسایی مؤثرترین متغیرها، کاهش ابعاد داده‌ها و بهبود

ویژگی‌ها (Features) و متغیر هدف (Target Variable) تقسیم می‌شوند.

جمع‌آوری داده‌ها

متغیرهای ورودی مورد استفاده در مدل‌های یادگیری ماشین برای پیش‌بینی عملکرد عمدتاً شامل داده‌های اقلیمی، ویژگی‌های خاک و اطلاعات مدیریتی هستند. این متغیرها را می‌توان در چند گروه اصلی طبقه‌بندی کرد (Van Klompenburg et al., 2020):

الف- گروه «اطلاعات خاک و گیاه» شامل ویژگی‌هایی مانند نوع و نقشه خاک، pH، ظرفیت تبادل کاتیونی، صفات فنوتیپی گیاه، مراحل رشد، تراکم کاشت و برخی شاخص‌های رشد نظیر شاخص سطح برگ است. ب- ویژگی‌های مرتبط با «رطوبت» شامل بارندگی، آبیاری و سایر شاخص‌های مرتبط با تأمین آب گیاه، از جمله بارش پیش‌بینی‌شده، هستند. ج- گروه «عناصر غذایی» شامل غلظت عناصر موجود در خاک و نیز مقادیر مصرف‌شده در قالب کودهای شیمیایی یا آلی است. مهم‌ترین متغیرهای این گروه شامل نیتروژن، فسفر، پتاسیم، منیزیم، گوگرد، کلسیم، روی، منگنز و بور هستند. د- گروه «مدیریت مزرعه» شامل متغیرهایی مانند برنامه‌های آبیاری، کوددهی و سایر تصمیمات مدیریتی کشاورزان است. ه- از ویژگی‌های محاسبه‌شده می‌توان به شاخص پوشش گیاهی نرمال‌شده و شاخص پوشش گیاهی تقویت‌شده (Enhanced Vegetation Index; EVI) اشاره کرد. پ- گروه «سایر» شامل متغیرهایی مانند سرعت باد، فشار

دقت پیش‌بینی به کار می‌رود (Montesinos-López *et al.*, 2024). روش‌های انتخاب ویژگی معمولاً در سه گروه فیلتر (Filter)، بسته‌بند (Wrapper) و تعبیه‌شده (Embedded) طبقه‌بندی می‌شوند که ویژگی‌های اصلی آن‌ها در جدول ۲ ارائه شده است. در مطالعات پیش‌بینی عملکرد، روش‌های تعبیه‌شده به دلیل توانایی همزمان در انتخاب ویژگی و آموزش مدل، کاربرد گسترده‌تری یافته‌اند (Pudjihartono *et al.*, 2022).

جدول ۲- مقایسه ویژگی‌ها، مزایا و محدودیت‌های روش‌های اصلی انتخاب ویژگی در یادگیری ماشین
Table 2- Comparison of the characteristics, advantages, and limitations of the main feature selection methods in machine learning

روش	رویکرد انتخاب ویژگی	مزایا	محدودیت‌ها	نمونه روش‌ها
فیلتر	ارزیابی ویژگی‌ها مستقل از مدل	سریع، کم‌هزینه، مناسب برای داده‌های با ابعاد بالا	عدم در نظر گرفتن تعامل بین ویژگی‌ها	Correlation Chi-square Information Gain
بسته‌بند	ارزیابی زیرمجموعه ویژگی‌ها بر اساس عملکرد مدل	دقت بالا و انتخاب ویژگی‌های بهینه	هزینه محاسباتی زیاد و زمان آموزش طولانی	RFE Sequential Selection
تعبیه‌شده	انتخاب ویژگی در فرآیند آموزش مدل	تعادل مناسب بین دقت و کارایی محاسباتی	وابستگی به الگوریتم مورد استفاده	LASSO XGBoost Random Forest

همان‌گونه که در جدول ۲ مشاهده می‌شود، هر یک از روش‌های انتخاب ویژگی دارای مزایا و محدودیت‌های خاص خود هستند. روش‌های فیلتر برای غربالگری اولیه داده‌ها مناسب‌اند، در حالی که روش‌های بسته‌بند معمولاً دقت بیشتری ارائه می‌کنند اما هزینه محاسباتی بالاتری دارند. روش‌های تعبیه‌شده نیز با انجام همزمان انتخاب ویژگی و آموزش مدل، تعادل مناسبی میان دقت پیش‌بینی و کارایی محاسباتی برقرار می‌کنند.

معرفی الگوریتم‌های یادگیری متداول

الگوریتم‌های متعددی از جمله رگرسیون چندمتغیره، جنگل تصادفی، ماشین بردار پشتیبان، پرسپترون چندلایه، درخت تصمیم و شبکه‌های عصبی مصنوعی برای پیش‌بینی عملکرد محصولات زراعی به کار گرفته شده‌اند (Khaki & Wang, 2019; Van Klompenburg *et al.*, 2020). در سال‌های اخیر، استفاده از مدل‌های یادگیری عمیق به‌عنوان زیرمجموعه‌ای از یادگیری ماشین در این حوزه گسترش یافته است. این مدل‌ها با بهره‌گیری از داده‌های میدانی و چندمنبعی قادرند الگوهای پیچیده موجود در داده‌ها را استخراج کرده و عملکرد محصول را تحت شرایط مختلف اقلیمی پیش‌بینی کنند. شبکه‌های عصبی کانولوشنی (Convolutional Neural Network; CNN)، حافظه طولانی کوتاه‌مدت و شبکه‌های عصبی عمیق از پرکاربردترین معماری‌های یادگیری عمیق در مطالعات کشاورزی محسوب می‌شوند. این مدل‌ها توانایی بالایی در مدل‌سازی روابط غیرخطی و استخراج الگوهای پنهان از

داده‌های پیچیده دارند (Kamilaris & Prenafeta-
 Boldú, 2018). الگوریتم‌های مورد استفاده در پیش‌بینی
 داده، قابلیت تفسیر و حوزه کاربرد تفاوت‌های قابل توجهی
 دارند (جدول ۳).
 عملکرد محصولات زراعی از نظر پیچیدگی، نیازمندی‌های

جدول ۳- مقایسه الگوریتم‌های رایج در پیش‌بینی عملکرد محصولات زراعی

Table 3- Comparison of commonly used algorithms for crop yield prediction

الگوریتم	نقاط قوت	محدودیت‌ها	مناسب برای
رگرسیون خطی Linear Regression	ساده، سریع، تفسیرپذیری بالا، نیاز به داده کم	محدودیت در مدل‌سازی روابط غیرخطی و برهم‌کنش‌های پیچیده	داده‌های کم، روابط خطی و مطالعات تبیینی
رگرسیون حداقل مربعات جزئی PLS	مناسب برای داده‌های همبسته و چندمتغیره	محدودیت در مدل‌سازی روابط پیچیده	داده‌های طیفی و سنجش از دور
درخت تصمیم Decision Tree	تفسیر آسان، عدم نیاز به فرضیات آماری	حساس به تغییرات داده و بیش‌برازش	داده‌های کوچک تا متوسط
ماشین بردار پشتیبان SVM/SVR	عملکرد مناسب در داده‌های با ابعاد بالا و نمونه‌های محدود، توانایی مدل‌سازی غیرخطی	تنظیم پارامترها دشوار، هزینه محاسباتی بالا در داده‌های بزرگ	داده‌های متوسط و چندمتغیره
جنگل تصادفی RF	مقاوم به نویز و بیش‌برازش، تخمین اهمیت متغیرها، عملکرد پایدار	تفسیرپذیری کمتر نسبت به مدل‌های خطی	داده‌های کوچک تا متوسط، داده‌های کشاورزی چندمنبعی
Gradient Boosting	دقت بالا، توانایی مدل‌سازی روابط پیچیده	حساس به تنظیم پارامترها و زمان آموزش بیشتر	داده‌های ساختاریافته
XGBoost	سرعت و دقت بالا، مدیریت داده‌های گمشده، کنترل بیش‌برازش	نیاز به تنظیم دقیق پارامترها	پیش‌بینی عملکرد با داده‌های اقلیمی، فنوتیپی و سنجش از دور
شبکه عصبی مصنوعی ANN/MLP	مدل‌سازی روابط غیرخطی پیچیده	نیاز به داده بیشتر و خطر بیش‌برازش	داده‌های متوسط تا بزرگ
شبکه عصبی عمیق DNN	استخراج ویژگی‌های پیچیده و چندلایه	نیازمند حجم زیاد داده و توان پردازشی بالا	کلان‌داده‌ها و سامانه‌های کشاورزی هوشمند
شبکه کانولوشنی CNN	استخراج خودکار ویژگی‌های مکانی از تصاویر	نیاز به داده تصویری زیاد	تصاویر پهپاد، ماهواره و فنوتیپ‌برداری
LSTM	مدل‌سازی وابستگی‌های زمانی و روند رشد گیاه	پیچیدگی بالا و نیاز به داده زمانی فراوان	داده‌های چندزمانه، شاخص‌های پوشش گیاهی و اقلیم
BiLSTM	استفاده همزمان از اطلاعات گذشته و آینده در سری زمانی	هزینه محاسباتی بیشتر نسبت به LSTM	پیش‌بینی عملکرد با سری‌های زمانی پیچیده
CNN-LSTM	ترکیب اطلاعات مکانی و زمانی، دقت بالا در داده‌های سنجش از دور	نیاز به داده و توان پردازشی زیاد	تصاویر ماهواره‌ای چندزمانه و پیش‌بینی عملکرد در مقیاس منطقه‌ای

تفاوت‌ها نشان می‌دهد که انتخاب الگوریتم باید متناسب با ویژگی‌های داده و هدف مطالعه انجام شود و هیچ الگوریتمی در تمامی شرایط برتری مطلق ندارد.

ارزیابی عملکرد مدل: معیارهای ارزیابی

ارزیابی عملکرد مدل‌ها یکی از مراحل کلیدی در توسعه و مقایسه روش‌های یادگیری ماشین است. برای سنجش کارایی مدل‌های رگرسیونی و طبقه‌بندی از معیارهای مختلفی استفاده می‌شود که هر یک جنبه متفاوتی از دقت، خطا یا قابلیت تفکیک مدل را اندازه‌گیری می‌کنند. انتخاب معیار مناسب به نوع مسئله، هدف تحلیل و ماهیت داده‌ها بستگی دارد. مهم‌ترین معیارهای ارزیابی مورد استفاده در مطالعات پیش‌بینی عملکرد غلات، همراه با فرمول‌های مربوطه، در جدول ۴ ارائه شده‌اند.

همان‌طور که در جدول ۳ مشاهده می‌شود، الگوریتم‌های مبتنی بر درخت مانند جنگل تصادفی و روش‌های تقویت گرادیانی به دلیل توانایی در مدل‌سازی روابط غیرخطی و مقاومت نسبی در برابر نویز، در بسیاری از مطالعات کشاورزی مورد استفاده قرار گرفته‌اند. در مقابل، مدل‌های یادگیری عمیق نظیر شبکه عصبی عمیق و مدل‌های مبتنی بر حافظه طولانی کوتاه‌مدت اگرچه قادر به استخراج الگوهای پیچیده‌تر هستند، اما برای دستیابی به عملکرد مطلوب به حجم بیشتری از داده و توان محاسباتی بالاتر نیاز دارند. از سوی دیگر، روش‌هایی مانند رگرسیون خطی و ماشین بردار پشتیبان همچنان در برخی شرایط، به‌ویژه در مجموعه داده‌های کوچک یا زمانی که تفسیرپذیری مدل اهمیت دارد، کاربرد خود را حفظ کرده‌اند. این

جدول ۴- مهم‌ترین معیارهای ارزیابی مورد استفاده در مدل‌های یادگیری ماشین

Table 4- Common evaluation metrics used in machine learning models

منبع	فرمول	نام انگلیسی	معیار ارزیابی	نوع مسئله
Hastie et al., 2009	$MSE = \frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2$	Mean Squared Error	میانگین مربعات خطا	رگرسیون
de Myttenaere et al., 2016	$MAPE = \frac{100}{n} \sum_{j=1}^n \left \frac{y_j - \hat{y}_j}{y_j} \right $	Mean Absolute Percentage Error	میانگین درصد خطای مطلق	رگرسیون
Hastie et al., 2009	$MAE = \frac{1}{n} \sum_{j=1}^n y_j - \hat{y}_j $	Mean Absolute Error	میانگین خطای مطلق	رگرسیون
Hastie et al., 2009	$R^2 = 1 - \frac{\sum_{j=1}^n (y_j - \hat{y}_j)^2}{\sum_{j=1}^n (y_j - \bar{y})^2}$	Coefficient of Determination (R^2)	ضریب تبیین	رگرسیون
Hastie et al., 2009	$MedAE = \text{madian}(y_i - \hat{y}_i)$	Median Absolute Error	میان خطای مطلق	رگرسیون
Hastie et al., 2009	$RMSE = \sqrt{\frac{\sum_{j=1}^n (y_j - \hat{y}_j)^2}{n}}$	Root Mean Squared Error	ریشه میانگین مربعات خطا	رگرسیون
Sokolova & Lapalme, 2009	$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$	Accuracy	صحت	طبقه‌بندی
Sokolova & Lapalme, 2009	$Precision = \frac{TP}{TP+FP}$	Precision	دقت	طبقه‌بندی
Sokolova & Lapalme, 2009	$Recall = \frac{TP}{TP+FN}$	Recall	فراخوانی	طبقه‌بندی
Sokolova & Lapalme, 2009	$F_1 = 2 \times \frac{Precision \cdot Recall}{Precision + Recall}$	F ₁ score	امتیاز F ₁	طبقه‌بندی
Fawcett, 2006	نمایانگر رابطه بین نرخ مثبت واقعی و	ROC curve and	منحنی ROC	طبقه‌بندی

AUC و		Area under curve	نرخ مثبت کاذب است. AUC
طبقه‌بندی	خطای طبقه‌بندی	Classification Error	مساحت زیر این منحنی است.
طبقه‌بندی	ماتریس آشفتگی	Confusion Matrix	تعداد پیش‌بینی‌های درست و نادرست برای هر کلاس
Sokolova & Lapalme, 2009		Error Rate=1-Accuracy	
Sokolova & Lapalme, 2009			

مورد استفاده در مطالعات یادگیری ماشین است (Hastie

et al., 2009).

چالش‌ها و محدودیت‌ها

کاربرد روش‌های یادگیری ماشین در پیش‌بینی عملکرد محصولات زراعی با چالش‌های متعددی روبه‌رو است. یکی از مهم‌ترین این چالش‌ها، دسترسی محدود به داده‌های باکیفیت، استاندارد و بلندمدت است. هرچند الگوریتم‌های یادگیری ماشین قادر به مدل‌سازی روابط پیچیده میان عوامل مؤثر بر عملکرد محصول هستند، اما دقت پیش‌بینی و قابلیت اطمینان نتایج این مدل‌ها به عواملی مانند کیفیت داده‌های ورودی، حجم نمونه، شیوه نمونه‌برداری و وجود داده‌های ناقص یا پرت وابسته است. در بسیاری از مناطق، داده‌های جامع و چندساله مربوط به عملکرد محصول، ویژگی‌های خاک، مدیریت مزرعه و شرایط اقلیمی در دسترس نیست. در نتیجه، توسعه سامانه‌های پیش‌بینی پایدار و قابل استفاده در شرایط متنوع با چالش‌های قابل توجهی مواجه می‌شود (Van Klompenburg et al., 2020).

علاوه بر محدودیت دسترسی به داده‌ها، هزینه جمع‌آوری، پردازش و یکپارچه‌سازی اطلاعات حاصل از حسگرها، تصاویر ماهواره‌ای، سامانه‌های هواشناسی و پایگاه‌های داده

اعتبارسنجی متقابل (Cross-Validation)

علاوه بر معیارهای ارزیابی، از روش‌های اعتبارسنجی نیز برای سنجش قابلیت تعمیم مدل‌های یادگیری ماشین استفاده می‌شود که اعتبارسنجی متقابل یکی از رایج‌ترین آن‌ها است. در رویکرد متداول، داده‌ها به دو بخش آموزشی و آزمایشی تقسیم می‌شوند؛ مدل با استفاده از داده‌های آموزشی توسعه یافته و عملکرد آن بر روی داده‌های آزمایشی ارزیابی می‌شود. با این حال، در صورت محدود بودن حجم داده‌ها، این تقسیم‌بندی ممکن است موجب استفاده ناکامل از اطلاعات موجود و افزایش واریانس برآورد عملکرد مدل شود. برای غلبه بر این محدودیت، از روش اعتبارسنجی متقابل K-fold استفاده می‌شود. در این روش، مجموعه داده به K زیرمجموعه تقسیم شده و در هر تکرار، یکی از زیرمجموعه‌ها برای ارزیابی و K-1 زیرمجموعه دیگر برای آموزش مدل استفاده می‌شوند. این فرایند تا زمانی ادامه می‌یابد که تمامی زیرمجموعه‌ها یکبار در نقش مجموعه آزمایشی قرار گیرند و در نهایت، عملکرد مدل بر اساس میانگین نتایج حاصل از تمام تکرارها گزارش می‌شود. اعتبارسنجی متقابل ۱۰ برابری (10-fold) از متداول‌ترین روش‌های

کشاورزی نیز از موانع مهم گسترش کاربرد یادگیری ماشین در کشاورزی محسوب می‌شود. همچنین، مدیریت حجم بالای داده‌های ناهمگون و به‌روزرسانی مستمر پایگاه‌های اطلاعاتی، نیازمند زیرساخت‌های محاسباتی و تخصص فنی قابل توجهی است (Liakos et al., 2018). این محدودیت‌ها به‌ویژه در کشورهای در حال توسعه، که دسترسی به زیرساخت‌های داده‌ای و سامانه‌های پایش مزرعه محدودتر است، اهمیت بیشتری پیدا می‌کنند.

از سوی دیگر، انتخاب روش مدل‌سازی باید متناسب با ویژگی‌های داده‌ها و نیازهای کاربردی انجام شود. الگوریتم‌های مختلف از نظر نیازمندی‌های محاسباتی، زمان آموزش، پیچیدگی پیاده‌سازی و حساسیت به حجم داده‌ها تفاوت قابل توجهی دارند. در بسیاری از کاربردهای کشاورزی، محدودیت منابع محاسباتی و حجم داده‌های در دسترس می‌تواند بر انتخاب مدل مناسب تأثیرگذار باشد. از این رو، انتخاب الگوریتم نباید صرفاً بر اساس بالاترین دقت پیش‌بینی انجام شود، بلکه لازم است عواملی مانند هزینه محاسباتی، سهولت توسعه و امکان استفاده عملی از مدل نیز مورد توجه قرار گیرد (Kamilaris & Prenafeta-Boldú, 2018; Van Klompenburg et al., 2020).

در کنار ملاحظات فنی، تفسیرپذیری نتایج یکی از چالش‌های مهم در به‌کارگیری یادگیری ماشین در کشاورزی محسوب می‌شود. بسیاری از مدل‌های پیشرفته، به‌ویژه روش‌های مبتنی بر یادگیری عمیق، اگرچه از دقت بالایی برخوردارند، اما سازوکار تصمیم‌گیری آن‌ها برای

کاربران به‌سادگی قابل درک نیست. این موضوع می‌تواند استفاده از خروجی مدل‌ها را در فرایندهای تصمیم‌گیری مدیریتی و زراعی با محدودیت مواجه سازد. به همین دلیل، در سال‌های اخیر توجه فزاینده‌ای به توسعه روش‌های یادگیری ماشین تفسیرپذیر و ابزارهای توضیح‌پذیری مدل معطوف شده است تا علاوه بر پیش‌بینی دقیق، امکان شناسایی عوامل مؤثر بر نتایج و افزایش اعتماد کاربران نیز فراهم شود (Arrieta et al., 2020; Mohan et al., 2025).

با وجود این چالش‌ها، گسترش کشاورزی دقیق، افزایش دسترسی به داده‌های چندمنبعی و پیشرفت فناوری‌های سنجش از دور، فرصت‌های جدیدی برای توسعه کاربردهای یادگیری ماشین در پیش‌بینی عملکرد محصولات زراعی ایجاد کرده است. تلفیق داده‌های حاصل از حسگرها، سامانه‌های پایش مزرعه، تصاویر ماهواره‌ای و منابع اقلیمی، امکان پایش پویای وضعیت مزرعه و استخراج اطلاعات دقیق‌تر برای تصمیم‌گیری مدیریتی را فراهم می‌سازد. همچنین، توسعه چارچوب‌های استاندارد برای مدیریت داده، ارزیابی مدل و تبادل اطلاعات می‌تواند به افزایش قابلیت استفاده از این فناوری در مقیاس‌های مختلف کمک کند. در مجموع، موفقیت کاربردهای یادگیری ماشین در کشاورزی آینده نه تنها به پیشرفت الگوریتم‌ها، بلکه به دسترسی به داده‌های قابل اعتماد، زیرساخت‌های مناسب و ادغام دانش تخصصی کشاورزی با علوم داده وابسته خواهد بود (Liakos et al., 2018; Van Klompenburg et al., 2020).

نتیجه‌گیری و چشم‌انداز آینده

یادگیری ماشین در سال‌های اخیر به یکی از مهم‌ترین رویکردهای داده‌محور برای پیش‌بینی عملکرد محصولات زراعی تبدیل شده است. توانایی این روش‌ها در تحلیل حجم بالایی از داده‌های ناهمگون و مدل‌سازی روابط پیچیده میان عوامل اقلیمی، خاکی، مدیریتی و ژنتیکی، زمینه توسعه سامانه‌های پیش‌بینی دقیق‌تر را فراهم کرده است. مرور مطالعات انجام‌شده نشان داد که الگوریتم‌های مختلف یادگیری ماشین، از جمله جنگل تصادفی، روش‌های تقویت گرادیانی، شبکه‌های عصبی مصنوعی، شبکه‌های عصبی عمیق و مدل‌های مبتنی بر حافظه طولانی کوتاه‌مدت، در شرایط مختلف برای پیش‌بینی عملکرد غلات به کار گرفته شده‌اند و نتایج امیدوارکننده‌ای ارائه کرده‌اند (Van Klompenburg *et al.*, 2020).

با این حال، شواهد موجود نشان می‌دهد که کارایی مدل‌های پیش‌بینی بیش از آنکه به پیچیدگی الگوریتم وابسته باشد، به کیفیت داده‌های ورودی، تناسب روش مدل‌سازی با مسئله مورد مطالعه و نحوه تلفیق منابع اطلاعاتی مختلف بستگی دارد. در بسیاری از پژوهش‌ها، ترکیب داده‌های هواشناسی، سنجش از دور و اطلاعات مدیریتی مزرعه موجب بهبود دقت پیش‌بینی شده است که اهمیت استفاده از رویکردهای چندمنبعی را در توسعه سامانه‌های پیش‌بینی عملکرد نشان می‌دهد (De Clercq & Mahdi, 2025; Javed & Murad, 2024).

مرور مطالعات همچنین چند چالش و شکاف پژوهشی مهم را آشکار ساخت. بسیاری از مدل‌های توسعه‌یافته در شرایط محدود مکانی و زمانی ارزیابی شده‌اند و شواهد اندکی درباره پایداری عملکرد آن‌ها در محیط‌های جدید و خارج از دامنه آموزش وجود دارد. افزون بر این، نبود استانداردهای یکسان برای ارزیابی مدل‌ها، مقایسه مستقیم نتایج مطالعات مختلف را دشوار ساخته است. از سوی دیگر، اگرچه مدل‌های یادگیری عمیق دقت بالایی ارائه می‌کنند، محدودیت در تفسیرپذیری و شفافیت فرایند تصمیم‌گیری آن‌ها همچنان یکی از موانع کاربرد گسترده این روش‌ها در کشاورزی به شمار می‌رود.

در آینده، توسعه مدل‌های قابل اعتماد در شرایط اقلیمی و مدیریتی متنوع، استفاده از رویکردهای هوش مصنوعی تفسیرپذیر، استانداردسازی فرایندهای ارزیابی و گسترش بهره‌گیری از داده‌های چندمنبعی از مهم‌ترین محورهای پژوهشی این حوزه خواهد بود. همچنین، ادغام داده‌های ژنومی، فنوتیپی، سنجش از دور و سامانه‌های پایش هوشمند می‌تواند افق‌های جدیدی برای توسعه سامانه‌های تصمیم‌یار و پیش‌بینی دقیق‌تر عملکرد محصولات زراعی فراهم کند.

در مجموع، یادگیری ماشین ظرفیت بالایی برای تحول سامانه‌های پیش‌بینی عملکرد محصولات زراعی دارد، اما تحقق کامل این ظرفیت مستلزم دسترسی به داده‌های استاندارد و قابل اعتماد، توسعه مدل‌های قابل تعمیم و

تعامل مؤثر میان علوم کشاورزی، سنجش از دور، علم داده و هوش مصنوعی خواهد بود. ■ انتخاب ویژگی بهتر است با روش‌های تعبیه‌شده مانند اهمیت متغیرها در Random Forest، XGBoost یا LASSO آغاز شود.

توصیه‌های عملی برای توسعه مدل‌های پیش‌بینی عملکرد ترکیب داده‌های چندمنبعی شامل اطلاعات اقلیمی، خاک، سنجش از دور و مدیریت مزرعه معمولاً موجب افزایش دقت پیش‌بینی می‌شود. ■

برای افزایش قابلیت تعمیم مدل، ارزیابی آن در چندین منطقه، سال زراعی و شرایط محیطی مختلف ضروری است. ■ در مجموعه‌داده‌های کوچک (کمتر از ۵۰۰ نمونه)، استفاده از مدل‌های خطی، ماشین بردار پشتیبان یا جنگل تصادفی همراه با اعتبارسنجی متقاطع توصیه می‌شود.

استفاده از معیارهای ارزیابی متعدد مانند R^2 ، RMSE و MAE می‌تواند تصویر جامع‌تری از عملکرد مدل ارائه دهد. ■ در مجموعه‌داده‌های بزرگ و دارای ساختار مکانی-زمانی، مدل‌های یادگیری عمیق نظیر DNN، LSTM و CNN-LSTM می‌توانند عملکرد بهتری ارائه دهند.

References

- Akcapinar, M.C., & Apaydin, H. 2025. Early yield estimation in wheat using open access global datasets and artificial intelligence. *Computers and Electronics in Agriculture*, 237, 110486. <https://doi.org/10.1016/j.compag.2025.110486>
- Arrieta, A.B., Díaz-Rodríguez, N., Del Ser, J., Benetot, A., Tabik, S., Barbado, A., García, S., Gil-López, S., Molina, D., Benjamins, R. & Chatila, R. 2020. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information fusion*, 58, pp.82-115. <https://doi.org/10.1016/j.inffus.2019.12.012>
- De Clercq, D., & Mahdi, A. 2025. Modern computational approaches for rice yield prediction: A systematic review of statistical and machine learning-based methods. *Computers and Electronics in Agriculture*, 231, 109852. <https://doi.org/10.1016/j.compag.2024.109852>
- de Myttenaere, A., Golden, B., Le Grand, B., & Rossi, F. 2016. Mean absolute percentage error for regression models. *Neurocomputing*, 192, 38-48. <https://doi.org/10.1016/j.neucom.2015.12.114>
- Fawcett, T. 2006. An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861-874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Hastie, T., Tibshirani, R., & Friedman, J. 2009. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer, New York, NY. <https://doi.org/10.1007/978-0-387-84858-7>

- Jabed, M.A., & Murad, M.A.A. 2024. Crop yield prediction in agriculture: A comprehensive review of machine learning and deep learning approaches, with insights for future research and sustainability. *Heliyon*, 10(24): e40836. <https://doi.org/10.1016/j.heliyon.2024.e40836>
- Kamilaris, A. & Prenafeta-Boldú, F.X. 2018. Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Khaki, S., & Wang, L. 2019. Crop yield prediction using deep neural networks. *Frontiers in Plant Science*, 10, 621. <https://doi.org/10.3389/fpls.2019.00621>
- Li, J., Cheng, K., Wang, S., Morstatter, F., Trevino, R.P., Tang, J., & Liu, H. 2017. Feature selection: A data perspective. *ACM Computing Surveys*, 50(6), 94. <https://doi.org/10.1145/3136625>
- Liakos, K.G., Busato, P., Moshou, D., Pearson, S. & Bochtis, D. 2018. Machine learning in agriculture: A review. *Sensors*, 18(8), 2674. <https://doi.org/10.3390/s18082674>
- Mohan, R. N. V. J., Rayanoothala, P. S., and Sree, R. P. 2025. Next-gen agriculture: Integrating AI and XAI for precision crop yield predictions. *Frontiers in Plant Science*, 15, 1451607. <https://doi.org/10.3389/fpls.2024.1451607>
- Mohapatra, S.K., Asmare, B., Kekeba, K., & Deferisha, A.D. 2025. Cereal crop yield prediction using machine learning techniques. In: Singh, S., Sood, V., Srivastav, A.L., & Ampatzidis, Y. (Eds.), *Hyperautomation in Precision Agriculture* (pp. 97–112). Academic Press. ISBN: 9780443241390.
- Montesinos-López, O.A., Crespo-Herrera, L., Pierre, C.S., Cano-Paez, B., Huerta-Prado, G.I., Mosqueda-González, B.A., Ramos-Pulido, S., Gerard, G., Alnowibet, K., Fritsche-Neto, R., Montesinos-López, A. & Crossa, J. 2024. Feature engineering of environmental covariates improves plant genomic-enabled prediction. *Frontiers in Plant Science*, 15, 1349569. <https://doi.org/10.3389/fpls.2024.1349569>
- Nazari, L., & Zinati, Z. 2023. Gene expression classification for biomarker identification in maize subjected to various biotic stresses. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 20(3), 2170-2176. <https://doi.org/10.1109/TCBB.2022.3233844>
- Nazari, L., Aslan, M.F., Sabanci, K., & Ropelewska, E. 2023. Integrated transcriptomic meta-analysis and comparative artificial intelligence models in maize under biotic stress. *Scientific Reports*, 13(1), 1-12. <https://doi.org/10.1038/s41598-023-42984-4>
- Nazari, L., Khazaei, A., & Ropelewska, E. 2022. Prediction of tannin, protein, and total phenolic content of grain sorghum using image analysis and machine learning. *Cereal Chemistry*, 99(4), 843-849. <https://doi.org/10.1002/cche.10542>
- Nazari, L., Shaker, M., Karimi, A., & Ropelewska, E. 2021. Identification of sorghum genotypes using a machine vision system. *Journal of Food Process Engineering*, 44 (5), e13673. <https://doi.org/10.1111/jfpe.13673>
- Okupska, E., Gozdowski, D., Pudełko, R., & Wójcik-Gront, E. 2025. Cereal and rapeseed yield forecast in Poland at regional level using machine learning and classical statistical models. *Agriculture*, 15(9), 984. <https://doi.org/10.3390/agriculture15090984>
- Pudjihartono, N., Fadason, T., Kempa-Liehr, A.W. & O'Sullivan, J.M. 2022. A review of feature selection methods for machine learning-based disease risk prediction. *Frontiers in Bioinformatics*, 2:927312. <https://doi.org/10.3389/fbinf.2022.927312>
- Ropelewska, E. & Nazari, L. 2021. The effect of drought stress of sorghum grains on the textural features evaluated using machine learning. *European Food Research and Technology*, 247, 2787-2798. <https://doi.org/10.1007/s00217-021-03832-9>

- Sokolova, M., & Lapalme, G. 2009. A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427-437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Van Klompenburg, T., Kassahun, A., & Catal, C. 2020. Crop yield prediction using machine learning: A systematic literature review. *Computers and Electronics in Agriculture*, 177, 105709. <https://doi.org/10.1016/j.compag.2020.105709>
- Zeinalzadeh-Tabrizi, H., & Nazari, L. 2025. Machine learning-based transcriptome mining to discover key genes for density stress in sweet corn. *Ecological Genetics and Genomics*, 35(100349), 1-17. <https://doi.org/10.1016/j.egg.2025.100349>