



Original Article

Application of Machine Vision Method in Diagnosing Strawberry Diseases with YOLO 11

Nashmil Farhadi¹, Rahman Farrokhi Teimourlou^{1*}

1- Department of Mechanics Engineering of Biosystems, Faculty of Agriculture, Urmia University, Urmia, Iran

ARTICLE INFO

Keywords:

Deep learning,
Image processing,
Object detection,
Optimization,
Smart agriculture

Received:
June 27, 2025

Revised:
October 06, 2025

Accepted:
October 06, 2025

* Corresponding Author:
r.farrokhi@urmia.ac.ir

ABSTRACT

Introduction

Strawberries are one of the most important and valuable garden crops, widely supplied to global agro-markets, as well as food and pharmaceutical industries, due to their high nutritional and economic value, antioxidant compounds, and favorable taste. However, strawberry production is often accompanied by challenges, one of the most important of which is prevalence of plant diseases. Diseases of fungal or bacterial origin typically cause damage to the crop growth, which may reduce the yield, and in some cases, lead to the complete harvest failure and significant financial losses. Timely and accurate identification of these diseases plays a crucial role in effective farm management. Traditional methods, such as visual inspection, require considerable expertise, are time-consuming, prone to errors, and often yield suboptimal results. In recent years, advancements in technologies related to artificial intelligence and machine learning, particularly in machine vision models, have made it possible to automatically identify plant diseases with higher speed and accuracy. In this study, the YOLO algorithm, one of the most widely used and advanced methods in digital object recognition, was employed to identify various strawberry diseases, including angular leaf spots, anthracnose, gray mold, and powdery mildew. To improve the accuracy of the model, modifications were made to the network architecture and training process. In addition to high accuracy and appropriate speed, this method may reduce the costs related to monitoring and managing strawberry farms. The results obtained from this study demonstrate that the YOLO algorithm can be effectively utilized in smart agriculture, in conjunction with specific equipment and tools such as drones and image sensors, to control diseases and enhance production. This research represents a practical step toward utilizing modern technologies to manage plant diseases and enhance agricultural productivity.

Materials and Methods

The dataset used consisted of 2902 images of strawberry leaves and fruits collected from the Roboflow database. The whole dataset was divided into three distinct portions: training (70%), validation (20%), and test (10%). All images were set to 640×640 pixels, and the labeling process was performed according to YOLO standards. Eight disease classes, including angular leaf spot, anthracnose rot, blossom blight, gray mold, healthy leaves and fruits, leaf spot, powdery mildew on fruits, and powdery mildew on leaves, were included in the dataset. The YOLO11-Large (YOLO11L) model was trained using pre-trained weights and an object detection task. The Optuna algorithm was used to optimize the hyperparameters. The training process consisted of 200 epochs, utilizing an early stopping mechanism to prevent overfitting. The training batch size was set to 4, and other settings, such as data augmentation, including random rotation, scaling, horizontal and vertical inversion, random cropping, and image blending, were also applied. Finally, a deep learning model based on YOLO11L was used to identify and classify strawberry plant diseases. The final model consists of 190 layers and approximately 790,000 trainable parameters, which are distributed among three main parts of the network: about 480,000 parameters in the backbone (feature extraction),

How to cite:

Farhadi, N. and Farrokhi Teimourlou, R. (2025). *Application of Machine Vision Method in Diagnosing Strawberry Diseases with YOLO 11*. Journal of Agricultural Mechanization, 10 (3):43-56. <https://doi.org/10.22034/jam.2025.67883.1328>.



This is an open-access article under the CC BY NC license
(<https://creativecommons.org/licenses/by-nc/4.0/>)



285,000 in the neck (feature aggregation), and 25,000 in the head (detection output). The model's total computational complexity is approximately 6.86 GFLOPs. The processing speed of the model was measured to be 0.5 ms for preprocessing, 23.6 ms for inference, and 2.3 ms for postprocessing per image.

Results and Discussion

The results show that the evaluation accuracy of the model is the best in case of blossom blight class, where a precision of 0.951 and a full recall of 1.000 were obtained. This indicates the ability of the model to identify this disease without any omission errors. Additionally, the mAP@50 and mAP@50-95 values for this class are 0.995 and 0.882, respectively, which confirm the model's accuracy at all Intersection over union (IoU) thresholds. The angular leaf spot class also demonstrated good performance, falling just short of balance between precision (0.905) and recall (0.904). Additionally, the mAP@50 and mAP@50-95 values for this class are 0.927 and 0.760, respectively, indicating the practical identification of this disease at various levels of overlap. The leaf spot class with the highest number of samples (223) also exhibits strong performance, with a precision of 0.907, recall of 0.914, and mAP@50 of 0.943, confirming that the model has experienced improved learning and generalization with increasing data volume. On the other hand, some classes, such as anthracnose and gray mold, suffer from an imbalance in precision and recall. In the anthracnose class, the high precision (0.952) indicates the ability of the model to avoid type I errors, but the lower recall (0.800) indicates the possibility of undetected samples. Similarly, in the gray mold class, the precision is 0.897, and the recall is 0.812, indicating some challenges in extracting the unique features of this disease. The lower value of mAP@50-95 in this class (0.628) indicates that the model suffers from performance degradation at different levels of spatial accuracy. In the healthy class, the model has a perfect recall (0.942), indicating that almost all healthy samples are correctly identified. However, the lower precision in this class (0.799) suggests that some diseased samples are falsely diagnosed as healthy, which can be risky in real applications, especially in prevention processes. Finally, the fruit and leaf powdery mildew classes have the weakest performance among all available classes. The precision of 0.816 and recall of 0.725 for the fruit powdery mildew class indicate a serious challenge for the model in accurately diagnosing this disease. In particular, the mAP@50-95 value of 0.689 also highlights that the model lacks the necessary stability across different detection scales. Possible reasons for this poor performance may include the lack of data in the relevant classes, the apparent similarity with other classes, e.g., leaf powdery mildew and leaf spot, and the insufficient visual diversity in the dataset.

Conclusion

This study led to the development of an advanced strawberry disease detection system based on an updated YOLO11L architecture, which achieved an average precision of 90.9% in the mAP@50 benchmark. The proposed model performed very well in identifying diseases with distinct visual symptoms, such as blossom blight (99.5% precision) and leaf spot (94.3% precision). However, a relative decrease in accuracy was observed when classifying diseases with similar visual symptoms, such as fruit powdery mildew (82.7% precision) and gray mold (89.1% precision). This was mainly due to two key factors: (1) insufficient training data for recent, classes and (2) high overlap in visual patterns between them. From an applied perspective, the presented model has significant potential in improving plant disease management solutions, through applications such as intelligent monitoring of farms and greenhouses, integration with unmanned aerial systems for large-scale surveillance, and reducing untargeted pesticide use through accurate and situational disease detection.



کاربرد روش بینایی ماشین در تشخیص بیماری‌های توت‌فرنگی با YOLO 11

نشمیل فرهادی^{۱*}، رحمان فرخی تیمورلو^{۱*}

تاریخ دریافت: ۱۴۰۴/۰۴/۰۶ تاریخ بازنگری: ۱۴۰۴/۰۷/۱۴ تاریخ پذیرش: ۱۴۰۴/۰۷/۱۴

۱- گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران.

E-mail: r.farrokhi@urmia.ac.ir

* نویسنده مسئول

چکیده

تشخیص به موقع بیماری‌های گیاهی در محصولات کشاورزی، نقش حیاتی در افزایش بهره‌وری و کاهش خسارات اقتصادی دارد. روش‌های سنتی تشخیص بیماری‌ها، که مبتنی بر مشاهده چشمی و تجربه متخصصان هستند، اغلب زمان‌بر، پرهزینه و مستعد خطا می‌باشند. با پیشرفت فناوری‌های هوش مصنوعی و یادگیری ماشین، استفاده از مدل‌های مبتنی بر ماشین بینایی به عنوان راه‌حلی کارآمد برای تشخیص خودکار بیماری‌های گیاهی مطرح شده است. این پژوهش با بهره‌گیری از مدل YOLO11L، به تشخیص هفت دسته متفاوت از نوع و وضعیت بیماری در گیاه توت‌فرنگی، شامل لکه برگ، پوسیدگی آنتراکنوز میوه، سوختگی شکوفه، کپک خاکستری، لکه برگ، سفیدک پودری میوه و برگ، و همچنین نمونه‌های سالم و بدون بیماری پرداخته است. مجموعه داده مورد استفاده شامل ۲۹۰۲ تصویر از برگ‌ها و میوه‌های توت‌فرنگی بود که از پایگاه داده Roboflow جمع‌آوری و به سه بخش با نسبت‌های مختلف از کل داده‌ها شامل آموزش (۷۰ درصد)، اعتبارسنجی (۲۰ درصد) و آزمون (۱۰ درصد) تقسیم شد. آموزش مدل با استفاده از وزن‌های از پیش آموزش یافته و انواع بهینه‌سازی‌ها، از جمله افزایش داده‌ها و تنظیم هایپرپارامترها با روش Optuna، صورت پذیرفت. نتایج بیانگر آن بودند که مدل نهایی در تشخیص برخی بیماری‌ها مانند سوختگی شکوفه با میانگین متوسط دقت در آستانه پنجاه درصد ۰/۹۹۵ و بازخوانی کامل (۱/۰۰۰) دارای عملکردی قابل قبول است. این در حالی است که در بیماری‌هایی مانند سفیدک پودری میوه (۰/۸۲۷) و کپک خاکستری (۰/۸۹۱)، به دلیل وجود شباهت ظاهری و کمبود داده‌های آموزشی، چالش‌هایی وجود دارد. این مطالعه نشان می‌دهد که مدل‌های مبتنی بر YOLO می‌توانند به عنوان ابزاری کارآمد در کشاورزی هوشمند برای تشخیص سریع و دقیق بیماری‌های گیاهی مورد استفاده قرار گیرند. با این حال، بهبود عملکرد در دسته‌های کم‌نمونه و کاهش خطاهای تشخیصی از طریق افزایش داده‌های آموزشی و بهینه‌سازی معماری مدل، از جمله پیشنهادات این پژوهش برای تحقیقات آتی است. کاربرد این فناوری می‌تواند در ترکیب با پهپادها و حسگرهای تصویری، مدیریت بهینه مزارع و کاهش مصرف غیرضروری آفت‌کش‌ها را به همراه داشته باشد.

کلمات کلیدی: بهینه سازی، پردازش تصویر، تشخیص اشیاء، کشاورزی هوشمند، یادگیری عمیق

۲- مقدمه

بیماری‌های گیاهی ارائه شده‌اند که امکان تشخیص سریع و دقیق آن‌ها را فراهم می‌کنند (Shoib et al., 2023).

در سال‌های اخیر، مدل‌های یادگیری عمیق به‌عنوان ابزاری کارآمد برای تشخیص بیماری‌های گیاهی و شناسایی اجزای گیاه مورد استفاده قرار گرفته‌اند. در مطالعه‌ای پژوهشگران، مدل‌های AlexNet، SqueezeNet، GoogLeNet، ResNet-50 و نیز دو نسخه اصلاح‌شده SqueezeNet را برای تشخیص بیماری سفیدک پودری برگ‌های توت‌فرنگی با استفاده از تصاویر RGB مورد ارزیابی قرار دادند. نتایج این مطالعه نشان داد که مدل ResNet-50 با دقت ۹۸/۱۱ درصد بهترین عملکرد را داشته و سریع‌ترین زمان پردازش نیز متعلق به مدل AlexNet بوده است. نتایج همین پژوهش نشان داد که یادگیری عمیق می‌تواند جایگزینی کارآمد برای روش‌های سنتی پایش بیماری‌های گیاهی باشد و به کاهش مصرف غیرضروری قارچ‌کش‌ها کمک کند (Shin et al., 2021).

در مطالعه‌ای دیگر، یک روش بهبود یافته مبتنی بر YOLOv8 (یکی از نسخه‌های قبلی الگوریتم‌های تشخیص اشیاء) برای تشخیص برگ‌های توت‌فرنگی و لکه‌های بیماری سفیدک پودری در برگ‌های توت‌فرنگی و لکه‌های بیماری ارائه شده است. برای بررسی تأثیر اجزای مختلف مدل، آزمایش‌هایی تحت عنوان حذف مؤلفه‌ها^۵ انجام شد. نتایج این آزمایش‌ها نشان داد که مدل بهبودیافته، نسبت به نسخه پایه YOLOv8-seg عملکرد بهتری دارد. این مدل توانست به دقت تقسیم‌بندی ۹۲ درصد، بازخوانی ۸۵/۲ درصد و میانگین متوسط دقت^۶ (mAP) ۹۰/۴ درصد دست یابد که به ترتیب نشان‌دهنده ۴، ۲/۹ و ۴ درصد بهبود نسبت به مدل پایه است. این بهبودها منجر به کاهش میزان تشخیص‌های نادرست و بهبود دقت در مکان‌یابی اهداف شده است (Chen et al., 2025).

در مطالعه ون تران و همکاران (۲۰۲۴)، یک نرم افزار کاربردی ویژه تلفن همراه جهت شناسایی چهار نوع بیماری رایج در توت‌فرنگی با استفاده از یک مدل توسعه یافته با YOLOv8 طراحی شد. در این پژوهش، نسخه‌های مختلفی از YOLOv8 مورد ارزیابی قرار گرفتند و مدل YOLOv8n با دارا بودن تنها ۱۱ میلیون پارامتر، بالاترین دقت را با میانگین متوسط دقت برابر ۸۷/۹ درصد در تشخیص بیماری‌ها ارائه داد. این سامانه با بهره‌گیری از پردازش تصویر و یادگیری عمیق، توانست عملکرد قابل قبولی را از خود در شرایط نوری مختلف و در محیط‌های مزرع‌ای واقعی ارائه دهد و به عنوان گامی مؤثر در جهت به‌کارگیری بینایی ماشین در کشاورزی هوشمند شناخته شود (Van Tran et al., 2024).

توت فرنگی از مهم‌ترین محصولات باغی و گلخانه‌ای است که به‌دلیل ارزش غذایی و اقتصادی بالا، وجود ترکیبات آنتی اکسیدان و طعم مطلوب نه‌تنها در کشاورزی از اهمیت ویژه‌ای برخوردار است، بلکه در صنایع غذایی و دارویی نیز کاربردهای فراوانی دارد (Hernández-Martínez et al., 2023; Meyers et al., 2003). با این حال، تولید توت‌فرنگی با چالش‌های پرشماری مواجه است که از مهم‌ترین آن‌ها می‌توان به شیوع بیماری‌های گیاهی اشاره کرد. بیماری‌های گیاهی که اغلب توسط قارچ‌ها و باکتری‌ها ایجاد می‌شوند، می‌توانند بر رشد، کیفیت و کمیت محصول تأثیر بگذارند و در نهایت باعث کاهش عملکرد محصول و حتی در مواردی سبب از بین رفتن کل محصول قابل‌برداشت و وارد شدن خسارات اقتصادی قابل توجه به کشاورزان شوند (Samtani et al., 2019).

لکه برگ‌ی زایه‌دار، پوسیدگی آنتراکنوز میوه، سوختگی شکوفه و گل‌ها، کپک خاکستری، لکه برگ‌ی، سفیدک پودری میوه و برگ از جمله بیماری‌های رایج و خسارت‌زا در توت فرنگی هستند، که هر بیماری، علائم مختص به خود را بر روی برگ‌ها، گل‌ها و میوه‌های گیاه بر جای می‌گذارد (Dholi et al., 2023). باکتری زانتوموناس فراگاریه^۱ سبب به وجود آمدن لکه‌های زایه‌دار بر روی برگ‌ها می‌شود (Osdaghi, 2024). پوسیدگی آنتراکنوز میوه از قارچ کله‌تریکوم^۲ ناشی می‌شود که باعث پوسیدگی میوه‌ها و کاهش شدید کیفیت محصول می‌شود (Aljawasim et al., 2023). قارچ بوتریتیس سینره‌آ^۳ عامل اصلی سوختگی شکوفه و گل‌های گیاه و کپک خاکستری است که با آلوده کردن آن‌ها سبب کاهش میوه‌دهی و سپس باعث پوسیدگی میوه‌ها در طول دوره نگهداری و حمل و نقل محصول می‌شود (Maghsoodi et al., 2025). قارچ مایکوسفارا لا فراگاریه^۴ بیماری لکه برگ‌ی را ایجاد می‌کند و لکه‌های قهوه‌ای بر روی برگ‌ها بر جای می‌گذارد (Wai et al., 2025). سفیدک پودری میوه و برگ که توسط قارچ پودوسفیرا آفانیوس^۵ ایجاد می‌شوند، به ترتیب باعث ایجاد پوشش پودری سفید بر روی میوه‌ها و برگ‌ها می‌شوند (Carisse & Fall, 2021). شناسایی به موقع و دقیق این بیماری‌ها نقش کلیدی در مدیریت مؤثر بیماری‌ها، کاهش خسارات و افزایش بهره‌وری مزارع دارد. روش‌های سنتی شناسایی بیماری‌ها، مانند مشاهده چشمی، نیازمند تخصص بالا هستند، و در عین حال مستعد خطا و زمان‌بر می‌باشند. با پیشرفت فناوری‌های هوش مصنوعی و یادگیری ماشین، به‌ویژه مدل‌های مبتنی بر بینایی ماشین، روش‌های جدیدی برای تشخیص خودکار

⁵ Podosphaera aphanis

⁶ Ablation Studies

⁷ Mean average precision

¹ Xanthomonas fragariae

² Trichoderma

³ Botrytis cinerea

⁴ Mycosphaerella fragariae

در مطالعه‌ای، بای و همکاران (۲۰۲۴) یک مدل مبتنی بر مدل YOLO را معرفی کردند که با ادغام سر پیش‌بینی^۱ مبتنی بر ترنسفورمر پنجره‌ای^۲ و بهینه‌سازی معماری شبکه، عملکرد تشخیص را در محیط‌های پیچیده گلخانه‌ای به‌طور چشمگیری بهبود بخشید. این مدل بهبودیافته با دستیابی به مقادیر دقت ۹۲/۶ درصد، بازخوانی ۸۹/۶ درصد و میانگین دقت متوسط (mAP) ۹۲/۱ درصد، همراه با سرعت پردازش ۴۵ فریم بر ثانیه، نیازهای تشخیص بلادرنگ در سامانه‌های کشاورزی هوشمند را برآورده می‌کند. این پیشرفت‌ها نشان‌دهنده پتانسیل بالای یادگیری عمیق در خودکارسازی فرآیندهای کشاورزی در محیط‌های گلخانه‌ای است (Bai et al., 2024).

با توجه به اهمیت شناسایی بیماری‌های توت‌فرنگی و هزینه‌بر و زمان‌بر بودن روش‌های سنتی در این زمینه، نیاز به گسترش روش‌های فناورانه شناسایی بیماری‌ها، و به‌طور خاص روش‌های مبتنی بر هوش مصنوعی در این حوزه احساس می‌شود. پژوهش حاضر در راستای کاستن از شکاف موجود بین روش‌های سنتی و روش‌های نوین انجام شده است. در این پژوهش از مدل YOLO، به عنوان روشی پیشرفته در تشخیص اشیاء، همراه با بهسازی در معماری شبکه و فرآیند آموزش، برای شناسایی هفت نوع از بیماری‌های توت‌فرنگی بر اساس تصاویر اکتسابی از گیاه استفاده شده است. در مجموع هفت دسته هدف مطالعاتی مجزا توسط مدل نهایی مورد ارزیابی قرار گرفتند که شامل یک دسته میوه و برگ سالم و شش دسته بیماری بودند. هدف مدل تشخیص دقیق نمونه‌های سالم و آلوده است، که برای مدیریت به‌موقع بیماری‌ها و افزایش بهره‌وری محصول به کار گرفته خواهد شد.

در این تحقیق، ابتدا به شرح روش‌های به کار گرفته شده در انجام پژوهش خواهیم پرداخت که شامل انتخاب و آماده‌سازی مجموعه داده‌های مورد استفاده، از جمله فرآیند پیش‌برازش داده‌ها می‌باشد. سپس، به انتخاب مدل مناسب برای تشخیص اشیاء پرداخته و جزئیات مربوط به ساختار مدل، پارامترهای تنظیمی و نحوه آموزش مدل تشریح خواهد شد. در ادامه، نتایج حاصل از آموزش مدل روی مجموعه داده‌ها ارائه شده و معیارهای ارزیابی عملکرد مدل شامل دقت، حساسیت، و سایر شاخص‌های مربوطه تحلیل و بررسی خواهند شد. در نهایت، یافته‌های به‌دست آمده مورد بحث قرار گرفته و پیشنهادات و چشم‌اندازهای پژوهش‌های آتی بیان خواهد شد.

۳- مواد و روش‌ها

۳-۱- مجموعه داده‌ها و پیش‌پردازش

مجموعه داده‌های مورد استفاده شامل ۲۹۰۲ تصویر از برگ‌ها و میوه‌های توت‌فرنگی بود که از پایگاه داده Roboflow جمع‌آوری شد. این پایگاه داده یک زیرساخت برخط برای مدیریت و برچسب‌گذاری داده‌های تصویری است که امکان استفاده در پروژه‌های یادگیری عمیق و بینایی ماشین را فراهم می‌کند و شامل مجموعه‌های متنوعی در حوزه‌های مختلف است. مجموعه داده به سه بخش با نسبت‌های مختلف از کل داده‌ها شامل آموزش (۷۰ درصد)، اعتبارسنجی (۲۰ درصد) و آزمون (۱۰ درصد) تقسیم شد. جزئیات بیشتر در خصوص مجموعه داده‌های مورد استفاده در مدل‌سازی در جدول ۱ ارائه شده است.

تمامی تصاویر در ابعاد ۶۴۰×۶۴۰ پیکسل تنظیم شدند و فرآیند برچسب‌گذاری مطابق با استانداردهای YOLO انجام پذیرفت. هفت دسته بیماری شامل لکه برگی زاویه‌دار، پوسیدگی آنتراکروز میوه، سوختگی شکوفه، کپک خاکستری، لکه برگی، سفیدک پودری میوه و برگ به علاوه دسته مربوط به برگ و میوه سالم در این مجموعه داده لحاظ شده‌اند (شکل ۱). بر طبق اطلاعات ارائه شده توسط پایگاه داده مرجع، تمامی داده‌های مورد استفاده از منابع عمومی جمع‌آوری شده و دارای مجوز مناسب بوده‌اند.

جدول ۱- دسته‌بندی اهداف و ویژگی مجموعه داده‌های مورد

استفاده شده در آموزش، اعتبارسنجی و آزمون مدل

Table 1. Classification of targets and characteristics of the datasets used in the model training, validation, and testing

تعداد داده Data count			دسته Class
آزمون Test	اعتبارسنجی Validation	آموزش Training	
44	92	300	لکه برگی زاویه‌دار Angular Leaf Spot
16	26	65	پوسیدگی آنتراکروز میوه Anthracnose Fruit Rot
24	42	142	سوختگی شکوفه Blossom Blight
42	83	352	کپک خاکستری Gray Mold
42	87	302	برگ و میوه سالم Healthy Leaves & Fruits
68	114	393	لکه برگی Leaf Spot
17	29	89	سفیدک پودری میوه Powdery Mildew Fruit
58	108	367	سفیدک پودری برگ Powdery Mildew Leaf
311	581	2010	مجموع Total

² Swin Transformer

¹ Prediction Head

جلوگیری از بیش‌برازش، و توانایی تعمیم مدل به داده‌های جدید تأثیرگذار هستند. تنظیم غیربهمینه این پارامترها ممکن است منجر به آموزش ناقص یا عملکرد ناپایدار مدل گردد.

در این مطالعه به‌منظور تنظیم بهینه پارامترهای مدل YOLO11-Large از کتابخانه‌ی Optuna استفاده شد. Optuna یک چارچوب بهینه‌سازی خودکار^۴ مبتنی بر الگوریتم‌های جستجوی هوشمند است که برای بهینه‌سازی هایپرپارامترهای مدل‌های یادگیری ماشین طراحی شده است. این الگوریتم از روش جستجوی ترتیبی مبتنی بر بیزی^۵ بهره می‌برد و در آن، با استفاده از نتایج آزمایش‌های قبلی، مقادیر بهینه‌تری برای پارامترهای بعدی پیش‌بینی می‌شود.

در فرآیند بهینه‌سازی، Optuna با استفاده از یک تابع هدف، مدل را برای مجموعه‌ای از مقادیر تصادفی‌سازی‌شده‌ی هایپرپارامترها آموزش داده و عملکرد آن را ارزیابی می‌کند. سپس بر اساس معیار تعریف‌شده (در اینجا حداقل‌سازی خطا)، بهترین ترکیب پارامترها را انتخاب می‌کند. این رویکرد، نه تنها موجب صرفه‌جویی در زمان و منابع محاسباتی می‌شود، بلکه امکان یافتن پیکربندی‌هایی با عملکرد بالاتر نسبت به تنظیمات دستی را نیز فراهم می‌سازد.

مقدار اولیه نرخ یادگیری ۰/۰۰۵۷۶ به‌صورت خودکار توسط الگوریتم بهینه‌سازی Optuna انتخاب شد. در طول آموزش، نرخ یادگیری به‌تدریج کاهش یافت و در پایان فرآیند آموزش به مقدار ۰/۰۰۰۸۹۹۲۴ رسید. فرآیند آموزش در ۲۰۰ دوره^۶ با به‌کارگیری ساز و کار توقف زودهنگام^۷ (به‌معنای متوقف‌سازی آموزش در صورتی که عملکرد مدل بر داده‌های اعتبارسنجی برای چند دوره متوالی بهبود نیابد)، برای جلوگیری از بیش‌برازش انجام شد. اندازه دسته‌های آموزشی^۸ برابر با چهار تعیین گردید و سایر تنظیمات مانند افزایش داده^۹ شامل چرخش تصادفی، تغییر مقیاس، وارونگی افقی و عمودی، برش تصادفی و ترکیب تصاویر نیز به منظور بهبود تعمیم‌پذیری مدل اعمال شد.

استفاده از این تکنیک‌های افزایش داده، به ویژه در مواردی که حجم داده‌های آموزشی محدود است، از یادگیری ویژگی‌های نامربوط جلوگیری کرده و باعث می‌شود مدل بر ویژگی‌های اساسی و تغییرناپذیر اشیاء مورد نظر تمرکز کند. برای مثال، چرخش تصادفی به مدل می‌آموزد که جهت اشیاء نباید بر تشخیص آن تأثیر بگذارد، در حالی که تغییر مقیاس مدل را نسبت به اندازه‌های مختلف اشیاء مقاوم می‌سازد.



شکل ۱- نمونه تصاویر توت‌فرنگی‌های سالم و بیمار: (الف) لکه برگ‌ی زاویه‌دار؛ (ب) پوسیدگی آنتراکنوز میوه؛ (پ) سوختگی شکوفه؛ (ت) کپک خاکستری؛ (ث) میوه سالم؛ (ج) برگ سالم؛ (چ) لکه برگ؛ (ح) سفیدک پودری میوه؛ (خ) سفیدک پودری برگ
Fig 1. Sample images of healthy and infected strawberry plants: (a) Angular leaf spot; (b) Anthracnose fruit rot; (c) Blossom blight; (d) Gray mold; (e) Healthy fruit; (f) Healthy leaf; (g) Leaf spot; (h) Powdery mildew (fruit); (i) Powdery mildew (leaf).

۳-۲- آموزش مدل

مدل YOLO^۱ یکی از روش‌های پیشرفته و پرکاربرد در حوزه تشخیص اشیاء است که با استفاده از یک شبکه عصبی واحد، کل تصویر را تنها در یک مرحله^۲ پردازش کرده و موقعیت و کلاس اشیاء را به‌صورت هم‌زمان پیش‌بینی می‌کند. این رویکرد برخلاف الگوریتم‌های چندمرحله‌ای مانند R-CNN، منجر به افزایش چشمگیر سرعت پردازش می‌شود و آن را برای کاربردهای بلادرنگ^۳ بسیار مناسب می‌سازد. مدل YOLO11-Large (YOLO11L) با استفاده از وزن‌های از پیش‌آموزش‌یافته و هدف تشخیص اشیاء آموزش داده شد.

هایپرپارامترها نقش حیاتی در عملکرد نهایی مدل‌های یادگیری عمیق ایفا می‌کنند. پارامترهایی مانند نرخ یادگیری، اندازه دسته‌های آموزشی، تعداد دوره‌های آموزش، نرخ کاهش یادگیری و سایر تنظیمات مربوط به افزایش داده، مستقیماً بر سرعت همگرایی،

⁶ Epoch

⁷ Early Stopping

⁸ Batch size

⁹ Data augmentation

¹ You Only Look Once

² Single forward pass

³ Real-time

⁴ AutoML

⁵ Bayesian Optimization

از سوی دیگر، برای بهبود عملکرد مدل در بخش طبقه‌بندی دسته‌ها، تابع زیان متمرکز^۲ به کار گرفته شد. این تابع با تمرکز بیشتر روی نمونه‌های دشوار و کم‌نمایش^۳ و کاهش وزن نمونه‌های آسان، باعث می‌شود مدل بهتر بتواند دسته‌های نادر یا دشوار تشخیص داده شده را یاد بگیرد و از عدم تعادل داده‌ها جلوگیری کند.


همچنین، برای تنظیم بهینه نرخ یادگیری در طی فرایند آموزش، ساز و کار کاهش کسینوسی^۴ به کار گرفته شد. این روش به‌طور پویا نرخ یادگیری را کاهش می‌دهد و به مدل اجازه می‌دهد تا به تدریج به سمت نقاط بهینه‌تر فضای پارامترها حرکت کند، بدون اینکه گرفتار کمینه‌های محلی شود.

فعال‌سازی مکانیزم پوشش منطق^۵ و تنظیم پارامترهای آن، مانند تعیین اندازه پوشش برابر با چهار که نشان‌دهنده میزان گسترش ناحیه همپوشانی یا حساسیت به نزدیکی جعبه‌های محدودکننده است، باعث شد دقت مدل در تفکیک نواحی آلوده از مناطق سالم به طور محسوسی بهبود یابد. این مکانیزم با ایجاد ارتباط هندسی دقیق‌تر بین جعبه‌های محدودکننده پیش‌بینی شده و جعبه‌های واقعی، امکان تطابق بهتر و کاهش خطاهای ناشی از اختلاف موقعیت و اندازه جعبه‌ها را فراهم می‌کند و در نتیجه مدل توانایی بالاتری در شناسایی دقیق نواحی هدف پیدا می‌کند.

در نهایت، به منظور افزایش تعمیم‌پذیری مدل و جلوگیری از بیش‌برازش، تکنیک حذف تصادفی^۶ در بخش‌های مختلف شبکه عصبی اعمال شد. این روش با غیرفعال‌سازی تصادفی برخی نوره‌ها در هر مرحله آموزش، مدل را مجبور می‌کند تا وابستگی کمتری به برخی ویژگی‌ها پیدا کند و در نتیجه عملکرد بهتری روی داده‌های ناشناخته داشته باشد.

۳-۴- معماری مدل و محیط اجرا

در این پژوهش، به‌منظور شناسایی و طبقه‌بندی انواع بیماری‌های گیاه توت‌فرنگی، از مدل یادگیری عمیق مبتنی بر الگوریتم YOLO11-Large (YOLO11L) استفاده شد. فرایند پیاده‌سازی و تحلیل داده‌ها با استفاده از زبان برنامه‌نویسی Python نسخه ۳.۱۰.۱۱ و کتابخانه‌های PyTorch 2.6.0، OpenCV 4.11.0 و Ultralytics 8.3.92 صورت گرفت. مدل بر روی کارت گرافیک NVIDIA GeForce RTX 4050 Laptop GPU با ۶۱۴۰ مگابایت حافظه گرافیکی اجرا شد. مدل نهایی شامل ۱۹۰ لایه و تقریباً ۷۹۰۰۰۰ پارامتر قابل آموزش است که بین سه بخش اصلی شبکه حدود ۴۸۰۰۰۰ پارامتر در ستون فقرات (استخراج ویژگی)، ۲۸۵۰۰۰ در گردن (تجمیع ویژگی) و ۲۵۰۰۰ در سر



شکل ۲- نتایج تحلیل آماری جامع تصاویر برچسب‌خورده در

مجموعه داده‌های آموزش

Fig 2. Results of comprehensive statistical analysis on labeled images in training dataset

پس از انجام افزایش داده‌ها، تحلیل آماری جامعی بر روی تصاویر ویر قرار دارنبرچسب‌خورده در مجموعه آموزش انجام شد. نتایج این تحلیل در شکل ۲ ارائه شده است. شکل ۲-الف، پراکندگی مکانی جعبه‌های محدودکننده^۱ را نمایش می‌دهد که نشانگر آن است که بیشتر نواحی تحت تأثیر بیماری در مرکز تصاد. شکل ۲-ب، توزیع فراوانی نمونه‌ها در هر دسته را نشان می‌دهد که بیانگر نامتوازن بودن مجموعه داده‌ها و فراوانی بیشتر برخی از دسته‌ها مانند لکه برگی و سفیدک پودری برگ است. نقشه حرارتی شکل ۲-پ توزیع عرض و ارتفاع ناحیه‌ها را نشان می‌دهد. در حالی که نقشه حرارتی شکل ۲-ت، چگالی مختصات مراکز ناحیه‌ها (x و y) را نشان می‌دهد. این تحلیل‌ها درک بهتری از ویژگی‌های فضایی و دسته‌ای داده‌ها را فراهم می‌کنند و می‌توانند در بهینه‌سازی طراحی و آموزش مدل مورد استفاده قرار گیرند.

۳-۳- بهینه‌سازی و تنظیمات مدل

برای بهبود دقت مدل، چندین تکنیک بهینه‌سازی و تنظیم پارامترها به کار گرفته شد. ابتدا، در بخش تشخیص جعبه‌های محدودکننده، از تابع زیان Smooth L1 Loss استفاده شد که مزیت آن ترکیب ویژگی‌های توابع L1 و L2 است؛ این تابع باعث می‌شود که مدل در مقابل خطاهای بزرگ مقاوم‌تر باشد و در عین حال بهبودهای جزئی را به صورت نرم‌تر اعمال کند. این امر به بهینه‌تر شدن پیش‌بینی محل دقیق اشیاء کمک می‌کند.

⁴ Cosine Annealing

⁵ Aligned Intersection over Union – Aligned IoU

⁶ Dropout

¹ Bounding Boxes

² Focal Loss

³ hard examples

مقادیر $mAP@50$ و $mAP@50-95$ برای این دسته به ترتیب $۰/۹۹۵$ و $۰/۸۸۲$ هستند که این امر دقت مناسب مدل در تمام آستانه‌های IoU را تأیید می‌کند.

دسته لکه زاویه‌دار نیز عملکرد مناسبی از خود نشان داده و با دقت $۰/۹۰۵$ و بازخوانی $۰/۹۰۴$ ، در مرز تعادل بین دقت و بازخوانی قرار گرفته است. همچنین، مقدار $mAP@50$ این دسته برابر $۰/۹۲۷$ و مقدار $mAP@50-95$ نیز $۰/۷۶۰$ بوده که نشان از شناسایی مؤثر این بیماری در سطوح مختلف هم‌پوشانی دارد. دسته لکه برگ با تعداد نمونه بالا (۲۲۳) نیز دارای عملکرد مناسب با دقت $۰/۹۰۷$ و بازخوانی $۰/۹۱۴$ و $mAP@50$ $۰/۹۴۳$ است، که این موضوع مؤید آن است که مدل با افزایش حجم داده‌ها، بهبود یادگیری و تعمیم‌پذیری را تجربه کرده است.

جدول ۲- جزئیات عملکرد مدل بر اساس دسته‌های هدف مختلف
Table 2. Details of model performance based on different target classes

دسته Class	دقت Precision	بازخوانی Recall	میانگین متوسط دقت $mAP@50-95$	میانگین $mAP@50$
لکه برگ زاویه‌دار Angular Leaf Spot	0.905	0.904	0.927	0.760
پوسیدگی آنتراکنوز میوه Anthracnose Fruit Rot	0.952	0.800	0.893	0.717
سوختگی شکوفه Blossom Blight	0.951	1.000	0.995	0.882
کپک خاکستری Gray Mold	0.897	0.812	0.891	0.628
برگ و میوه سالم Healthy Leaves & Fruits	0.799	0.942	0.915	0.774
لکه برگ Leaf Spot	0.907	0.914	0.943	0.872
سفیدک پودری میوه Powdery Mildew Fruit	0.816	0.725	0.827	0.689
سفیدک پودری برگ Powdery Mildew Leaf	0.867	0.908	0.879	0.786
همه دسته‌ها All classes	0.886	0.863	0.909	0.763

از سوی دیگر، برخی دسته‌ها مانند پوسیدگی آنتراکنوز میوه و کپک خاکستری دچار عدم تعادل در دقت و بازخوانی هستند. در دسته پوسیدگی آنتراکنوز میوه، دقت بالا ($۰/۹۵۲$) نشان‌دهنده توانایی بالای مدل در اجتناب از خطاهای نوع اول است، اما بازخوانی پایین‌تر ($۰/۸۰۰$) احتمال وجود نمونه‌های شناسایی نشده را نشان می‌دهد.

(خروجی تشخیص) توزیع شده‌اند؛ و توان محاسباتی معادل $۸۶/۶$ گیگافلاپس^۱ را داراست. سرعت پردازش مدل برابر $۰/۵$ میلی‌ثانیه برای پیش‌پردازش، $۲۳/۶$ میلی‌ثانیه برای استنتاج، و $۲/۳$ میلی‌ثانیه برای پس‌پردازش به ازای هر تصویر اندازه‌گیری شد.

۳-۵- معیارهای ارزیابی مدل

برای ارزیابی عملکرد مدل، از شاخص‌های دقت، بازخوانی و میانگین دقت متوسط استفاده شد. دقت نشان می‌دهد از میان تمام پیش‌بینی‌های مثبت مدل، چه نسبتی واقعاً صحیح بوده‌اند. این معیار به‌ویژه در کاهش خطای نوع اول (تشخیص اشتباه نمونه سالم به‌عنوان بیمار) اهمیت دارد. بازخوانی نسبت نمونه‌های مثبت درست‌شناسایی شده به کل نمونه‌های مثبت موجود را بیان می‌کند و معیاری کلیدی برای کاهش خطای نوع دوم (عدم شناسایی نمونه بیمار) است. میانگین دقت متوسط، شاخصی ترکیبی است که دقت مدل را در سطوح مختلف هم‌پوشانی^۲ (نسبت مساحت بخش مشترک بین جعبه پیش‌بینی شده و جعبه واقعی، به مساحت کل محدوده پوشش داده‌شده توسط هر دو جعبه) می‌سنجد. مقدار $mAP@50$ بیانگر میانگین دقت در آستانه هم‌پوشانی ۵۰ درصد است و بیشتر بر صحت کلی شناسایی متمرکز است. در مقابل، $mAP@50-95$ میانگین دقت در آستانه‌های هم‌پوشانی ۵۰ تا ۹۵ درصد (با گام ۵ درصد) را محاسبه می‌کند و توانایی مدل در شناسایی دقیق محل و ابعاد اشیاء را در شرایط سخت‌تر می‌سنجد.

۴- نتایج و بحث

در شکل ۳، خروجی مدل پیشنهادی برای تشخیص بیماری‌های مختلف برگ و میوه توت‌فرنگی نشان داده شده است. در هر تصویر، نوع بیماری به همراه میزان اطمینان مدل مشخص شده است. همان‌طور که مشاهده می‌شود، مدل توانسته است با دقت مناسبی نواحی مبتلا را شناسایی و تفکیک کند.


۴-۱- تحلیل عملکرد مدل بر اساس معیارهای آماری طبقه‌بندی

ارزیابی عملکرد مدل بر اساس جدول معیارهای ارزیابی نشان می‌دهد که مدل طراحی شده توانسته است با دقت و بازخوانی بالا در اغلب دسته‌ها، عملکردی قابل قبول از خود ارائه دهد.

نتایج جدول ۲ نشان می‌دهد که دسته سوختگی شکوفه با دقت معادل $۰/۹۵۱$ و بازخوانی کامل $۱/۰۰$ ، به‌عنوان بهترین دسته از لحاظ دقت ارزیابی شناخته می‌شود که نشان از توانایی مدل در شناسایی کامل این بیماری بدون هیچ خطای حذف دارد. همچنین،

² Intersection over Union

¹ Giga Floating-point Operations Per Second



شکل ۳- نتایج عملکرد مدل بر روی تصاویر واقعی برگ و میوه توت‌فرنگی
Fig 3. Model performance results on real images of strawberry leaves and fruits

پیشگیری از بیماری، مخاطره‌آمیز باشد. برای بهبود عملکرد مدل در تشخیص این دسته، می‌توان ضریب اهمیت کلاس سالم را در تابع زیان افزایش داد تا خطاهای مربوط به پیش‌بینی نادرست این دسته جریمه‌ی بیشتری دریافت کنند، یا از معماری‌هایی با توان تفکیک بالاتر بهره گرفت.

در نهایت، ضعیف‌ترین عملکرد مدل در بین کلیه دسته‌ها هدف، در دو دسته سفیدک پودری میوه و برگ مشاهده شد. دقت ۰/۸۱۶ و بازخوانی ۰/۷۲۵ برای دسته سفیدک پودری میوه نشان‌دهنده چالش جدی مدل در تشخیص دقیق این بیماری است. به‌ویژه، مقدار $mAP@50-95$ برابر با ۰/۶۸۹ تأکید می‌کند که مدل در مقیاس‌های مختلف تشخیص بیماری، دارای پایداری لازم نیست. این عملکرد ضعیف می‌تواند به طور احتمالی ناشی از کمبود حجم داده در دسته‌های مربوطه، شباهت ظاهری با سایر دسته‌ها (از جمله

به‌طور مشابیه، در دسته کپک خاکستری، دقت ۰/۸۹۷ و بازخوانی ۰/۸۱۲ مشاهده می‌شود، که بیانگر وجود برخی چالش‌ها در استخراج ویژگی‌های منحصر به فرد این بیماری است. مقدار پایین‌تر $mAP@50-95$ در این دسته (۰/۶۲۸) نیز بیانگر آن است که مدل در سطوح مختلف دقت مکانی با افت عملکرد مواجه شده است.

در دسته سالم، مدل بازخوانی بسیار بالایی (۰/۹۴۲) دارد، به این معنا که تقریباً تمام نمونه‌های سالم موجود در مجموعه آزمون به‌درستی شناسایی شده‌اند. با این حال، دقت پایین‌تر (۰/۷۹۹) نشان می‌دهد که در میان نمونه‌هایی که مدل به‌عنوان سالم پیش‌بینی کرده، تعدادی در واقع بیمار بوده‌اند. این وضعیت بیانگر آن است که مدل در شناسایی همه نمونه‌های سالم موفق است، اما بخشی از نمونه‌های بیمار را نیز به اشتباه در این دسته قرار می‌دهد. این مسأله می‌تواند در کاربردهای واقعی، به‌ویژه در فرآیندهای

از سوی دیگر، دسته‌هایی نظیر سفیدک پودری میوه با $mAP@50$ برابر ۰/۸۲۷ و کپک خاکستری با مقدار ۰/۸۹۱، دارای عملکرد ضعیف‌تری نسبت به سایر دسته‌ها هستند. نمودار دقت-بازخوانی این دسته‌ها نشان می‌دهد که در بازه‌هایی از بازخوانی، افت قابل توجهی در دقت رخ می‌دهد، که می‌تواند ناشی از شباهت ظاهری علائم این بیماری‌ها با سایر بیماری‌ها یا برگ‌های سالم، و همچنین کمبود نمونه‌های آموزشی در این دسته‌ها باشد. پایین بودن مقدار میانگین متوسط دقت در این دسته‌ها می‌تواند موجب تشخیص‌های نادرست شود که در کاربردهای واقعی منجر به تصمیم‌گیری‌های اشتباه خواهد شد.

میانگین $mAP@50$ برای تمامی دسته‌های هدف برابر با ۰/۹۰۹ گزارش شده است. این عدد نشان از عملکرد کلی مناسب مدل دارد و تأیید می‌کند که مدل در شناسایی بیماری‌های مختلف، به‌ویژه در بازه‌های دقت و بازخوانی بالا، قادر به ارائه پیش‌بینی‌هایی با اطمینان بالا است.

میانگین $mAP@50$ برای تمامی کلاس‌های هدف برابر با ۰/۹۰۹ گزارش شده است که بیانگر عملکرد کلی قابل قبول مدل در تشخیص بیماری‌های مختلف توت‌فرنگی است. این مقدار نشان می‌دهد که مدل توانسته تعادل مناسبی بین دقت و بازخوانی برقرار کند و در بازه‌هایی که هر دو معیار در سطوح بالایی قرار دارند، پیش‌بینی‌هایی با اطمینان بالا ارائه دهد. این میزان دقت کلی برای یک مدل شناسایی تصویر در حوزه کشاورزی قابل قبول بوده و نشان می‌دهد که مدل طراحی شده توانسته است ویژگی‌های تمایزدهنده بین دسته‌های مختلف را به‌خوبی آموزش ببیند.

۴-۳- تحلیل عملکرد مدل بر اساس ماتریس آشفستگی


برای ارزیابی دقت عملکرد مدل در تشخیص بیماری‌های گیاهی، از ماتریس آشفستگی^۱ استفاده شد. این ماتریس یکی از ابزارهای کلیدی در تحلیل نتایج مدل‌های طبقه‌بندی چندکلاسه است که با نمایش تعداد پیش‌بینی‌های صحیح و نادرست برای هر کلاس، امکان بررسی دقیق عملکرد مدل را فراهم می‌کند. با استفاده از ماتریس آشفستگی، می‌توان به نقاط قوت و ضعف مدل در تفکیک هر دسته پی برد و خطاهای طبقه‌بندی را شناسایی کرد.

نتایج شکل ۵ نشان می‌دهد که مدل در تشخیص برخی دسته‌ها نظیر لکه برگ، لکه برگ زایه‌دار و سفیدک پودری برگ از دقت بالایی برخوردار بوده و بخش عمده‌ای از نمونه‌های این دسته‌ها به درستی طبقه‌بندی شدند. برای نمونه، دسته لکه برگ با ۲۰۸ پیش‌بینی صحیح و تنها یک مورد اشتباه از دقت چشم‌گیری

سفیدک پودری برگ و لکه برگ و عدم تنوع ظاهری کافی در مجموعه داده‌ها باشد.

۴-۲- منحنی دقت-بازخوانی مدل

شکل ۴، منحنی دقت-بازخوانی مدل توسعه یافته را برای شناسایی بیماری‌های مختلف گیاه توت‌فرنگی نشان می‌دهد. این منحنی یکی از ابزارهای کلیدی برای ارزیابی عملکرد مدل‌های یادگیری ماشین در مسائل عدم تعادل داده‌ها، به‌ویژه در حوزه تشخیص اشیاء و بیماری‌های گیاهی است. هر منحنی در این نمودار نمایانگر عملکرد مدل در تشخیص یکی از دسته‌ها یا بیماری‌های گیاهی بوده و مقدار دقت نسبت به بازخوانی را برای دسته تحت بررسی نشان می‌دهد.



شکل ۴- منحنی دقت-بازخوانی (Precision-Recall Curve) مدل برای شناسایی بیماری‌های مختلف گیاه توت‌فرنگی

Fig 4. Precision-Recall Curve of the Model for Detecting Different strawberry Plant Diseases

بر اساس نتایج، مدل در تشخیص دسته سوختگی شکوفه با مقدار $mAP@50$ برابر ۰/۹۹۵ عملکرد بسیار مطلوبی دارد. این عدد نزدیک به یک، نشان از توانایی بسیار بالای مدل در تشخیص صحیح این بیماری دارد، به طوری که در بیشتر موارد، با دقت و بازخوانی بالا این بیماری را تشخیص داده است. دسته‌های دیگری همچون لکه برگ، لکه برگ زایه‌دار و سالم نیز عملکرد مناسبی از خود نشان داده‌اند. این سطوح بالا از $mAP@50$ بیانگر آن است که مدل در تمایز میان برگ‌های سالم و دارای بیماری عملکرد دقیق و قابل قبولی داشته است.

¹ Confusion Matrix

از منظر تحلیلی، شباهت ظاهری میان دسته‌های سالم و لکه برگی نیز باعث بروز اشتباهات شده، به گونه‌ای که ۲۷ نمونه از دسته سالم به اشتباه به عنوان لکه برگی پیش‌بینی شده‌اند. این میزان خطا حاکی از آن است که مدل در تمایزگذاری میان بافت‌های سالم و آلوده به بیماری به‌ویژه در مراحل اولیه شیوع بیماری، دقت کافی ندارد. این موضوع می‌تواند ناشی از کمبود نمونه‌های متنوع و با کیفیت در مجموعه داده‌های آموزش یا پیچیدگی ظاهری بیماری در شرایط طبیعی باشد.


اگرچه در مجموعه داده‌های این مطالعه، کلاس پس‌زمینه به‌صورت صریح تعریف نشده است، اما در فرآیند پیش‌بینی، مدل در هر موقعیت مکانی از تصویر باید تصمیم بگیرد که آن ناحیه به یکی از کلاس‌های تعریف‌شده تعلق دارد یا اینکه هیچ اشیاء معتبری در آن وجود ندارد. این حالت عدم وجود اشیاء، به‌صورت ضمنی به‌عنوان یک کلاس پس‌زمینه در نظر گرفته می‌شود. در هنگام ارزیابی مدل، این کلاس ضمنی به ماتریس آشفتگی افزوده می‌شود تا عملکرد مدل در تشخیص‌های صحیح^۱ و نادرست^۲ نیز قابل اندازه‌گیری باشد.

در سطح کلی، ماتریس آشفتگی نشان می‌دهد که مدل عملکرد نسبتاً مطلوبی در طبقه‌بندی دسته‌های غالب، یعنی کلاس‌هایی که بیشترین تعداد نمونه را در مجموعه داده داشته و به همین دلیل مدل در فرآیند آموزش با آن‌ها مواجهه بیشتری داشته است، ارائه کرده است. با این حال، در مورد دسته‌هایی با هم‌پوشانی^۳ ظاهری بالا، عملکرد بهینه‌ای ارائه نکرده است. در این مطالعه، منظور از هم‌پوشانی شباهت بالای ویژگی‌های ظاهری بین برخی کلاس‌هاست، به گونه‌ای که در تصاویر نمونه، مرزهای بین آن‌ها از نظر رنگ، بافت یا شکل به خوبی قابل تفکیک نبوده و بخش‌هایی از تصویر ویژگی‌های مشترکی با بیش از یک کلاس داشته است. چنین شرایطی که می‌تواند ناشی از شباهت زیستی نمونه‌ها یا شرایط مشابه تصویربرداری (مانند نور، زاویه دید یا پس‌زمینه) باشد، منجر به افزایش خطای مدل در تمایز این دسته‌ها شده است.

۴-۴- تحلیل عملکرد مدل بر اساس ماتریس آشفتگی نرمال شده

ماتریس آشفتگی نرمال شده^۴ به منظور کاهش اثر نامتوازن بودن تعداد نمونه‌ها در کلاس‌های مختلف استفاده می‌شود. در این ماتریس، هر مقدار در ردیف مربوط به یک کلاس بر مجموع کل نمونه‌های همان کلاس تقسیم می‌شود. این فرآیند، مقادیر را به صورت درصد یا نسبت نمایش می‌دهد که نشان می‌دهد مدل چه نسبتی از نمونه‌های هر کلاس را به درستی یا نادرستی طبقه‌بندی کرده است. استفاده از ماتریس نرمال شده باعث می‌شود که عملکرد مدل در کلاس‌هایی که تعداد نمونه‌های آنها کمتر است به درستی

برخوردار بوده و نشان از قابلیت بالای مدل در تمایزگذاری بین نمونه‌های این دسته و سایر برچسب‌ها دارد. به‌طور مشابه، دسته لکه برگی زاویه دار با ۵۰ مورد پیش‌بینی صحیح و حداقل خطا نیز عملکرد بسیار مطلوبی داشته است.



شکل ۵- نمودار ماتریس آشفتگی مدل آموزش‌دیده
Fig 5. Confusion Matrix of the Trained Model

در مجموعه داده‌های مورد استفاده، علاوه بر کلاس‌های مربوط به بیماری‌های مختلف، بخشی از تصاویر شامل مناطق پس‌زمینه است که به نواحی غیرمرتبط با علائم بیماری اشاره دارد. این مناطق می‌توانند شامل سایر عناصر محیطی موجود در تصویر به غیر از نواحی برچسب‌گذاری شده باشند. توانایی مدل در تمایز صحیح این پس‌زمینه‌ها از مناطق بیمار، اهمیت بالایی دارد، زیرا اشتباه در شناسایی پس‌زمینه به عنوان نمونه‌های بیماری می‌تواند موجب کاهش دقت طبقه‌بندی شود.

در مقابل، عملکرد مدل در طبقه‌بندی دسته‌هایی نظیر سفیدک پودری میوه، کپک خاکستری، و به‌ویژه پس‌زمینه با چالش‌هایی مواجه بوده است. در دسته سفیدک پودری میوه، تنها ۳۰ مورد به درستی تشخیص داده شدند و میزان بالایی از اشتباهات در ارتباط با دسته‌های مشابه و پس‌زمینه مشاهده شد. این یافته‌ها احتمال اشتراک ویژگی‌های ظاهری میان این دسته‌ها را مطرح می‌سازد که موجب سردرگمی مدل در فرآیند پیش‌بینی شده است. همچنین دسته پس‌زمینه به دلیل تنوع ساختاری بالا و احتمال وجود اطلاعات گمراه‌کننده در داده‌های پس‌زمینه، یکی از منابع اصلی بروز خطا محسوب می‌شود. در این دسته، علاوه بر پیش‌بینی صحیح تنها ۳۴ مورد، تعداد قابل توجهی از نمونه‌های سایر دسته‌ها به اشتباه به عنوان پس‌زمینه طبقه‌بندی شده‌اند. این امر نشان‌دهنده دشواری مدل در تشخیص دقیق مرز میان اطلاعات پس‌زمینه و نشانه‌های بیماری است.

³ Overlap

⁴ Normalized Confusion Matrix

¹ True Negatives

² False Positives

عملکرد مدل محسوب می‌شود. برای نمونه، مقادیر غیرقابل چشم‌پوشی از نمونه‌های مربوط به دسته‌های کپک خاکستری (۱۷ درصد)، سفیدک پودری میوه (۲۵ درصد) و حتی گیاه سالم (۵ درصد) به اشتباه به عنوان پس زمینه طبقه‌بندی شده‌اند. این خطا می‌تواند ناشی از شباهت‌های ظاهری میان نواحی سالم یا کم‌علائم با پس‌زمینه‌های گیاهی یا محیطی باشد. همچنین ۲۸ درصد از موارد دسته پس زمینه نیز به اشتباه در دسته سالم قرار گرفته‌اند که احتمال کم‌رنگ بودن علائم در تصاویر پس‌زمینه یا عدم تنوع کافی داده‌ها را مطرح می‌کند.

از منظر عملکرد کلی، مدل در تفکیک دسته‌های غالب و مشخص عملکرد مطلوبی دارد، اما در مواجهه با دسته‌های با ویژگی‌های همپوشان یا کم‌نمونه (مانند سفیدک پودری میوه و پس زمینه) دچار کاهش دقت شده است. این وضعیت می‌تواند با راهکارهایی همچون افزایش حجم داده برای دسته‌های کم‌نمونه، استفاده از روش‌های افزایش داده، پیاده‌سازی مدل‌های تشخیص مبتنی بر نواحی توجه و یا بهره‌گیری از توابع زیان وزن‌دار نظیر تابع زیان متمرکز بهبود یابد.

در مجموع، نتایج حاصل از ماتریس آشفتگی نرمال شده تأیید می‌کند که مدل از توانمندی بالایی در تشخیص دسته‌های بارز، یعنی کلاس‌هایی که ویژگی‌های ظاهری آن‌ها (مانند رنگ، بافت یا شکل) نسبت به سایر دسته‌ها متمایز و قابل تفکیک‌تر است، برخوردار است. با این حال، به‌منظور افزایش قابلیت اعتماد مدل در شرایط واقعی و داده‌های پیچیده‌تر، بهینه‌سازی‌های هدفمند در طراحی و آموزش مدل توصیه می‌شود.


مدل در طبقه‌بندی بیماری‌هایی با داده کافی و ویژگی‌های ظاهری بارز عملکرد بسیار خوبی داشته است، اما در طبقه‌بندی دسته‌هایی با داده‌های کمتر یا شباهت ساختاری با سایر دسته‌ها با چالش‌هایی روبه‌روست.

۴-۵- مقایسه عملکرد مدل‌های مختلف

جهت ارزیابی عملکرد مدل پیشنهادی YOLO11L، عملکرد آن با چهار نسخه از مدل YOLOv8 (n, m, l, x) و مدل بهینه‌شده Van Tran et al., 2024; Wu et al., 2025) مقایسه شد. معیارهای ارزیابی شامل میانگین دقت در آستانه ۰/۵ (mAP@50)، بازخوانی و دقت می‌باشند. نتایج حاصل از آزمایش‌ها در جدول ۳ خلاصه شده است.

مدل YOLO11L، که در این مطالعه آموزش داده شده است، در هر سه معیار ارزیابی مدنظر عملکرد بهتری نسبت به سایر مدل‌ها ارائه داده است. این مدل توانست به mAP@50 معادل ۰/۹۰۹ دست یابد که بالاترین مقدار در میان تمامی مدل‌های مقایسه‌شده است. همچنین میزان بازخوانی ۰/۸۶۳ و دقت ۰/۸۸۶ مدل این

قابل ارزیابی باشد و از تاثیر غالب بودن کلاس‌های پر تعداد در ماتریس خام جلوگیری شود. به عبارت دیگر، این روش امکان مقایسه عادلانه و دقیق‌تر بین کلاس‌ها را فراهم می‌کند و تحلیل‌های مربوط به نقاط قوت و ضعف مدل را عمیق‌تر و قابل فهم‌تر می‌سازد.



شکل ۶- نمودار ماتریس آشفتگی نرمال شده مدل آموزش‌دیده

Fig 6. Normalized Confusion Matrix of the Trained Model

بررسی ماتریس آشفتگی نرمال شده نشان می‌دهد که مدل پیشنهادی از دقت مناسبی در طبقه‌بندی و تشخیص اکثر دسته‌های بیماری برخوردار بوده است. به‌طور مشخص، دسته‌های سوختگی شکوفه، لکه برگ‌ی زایه‌دار، گیاهان سالم و لکه برگ‌ی با مقادیر دقت نرمال شده به ترتیب برابر با ۱/۰۰، ۰/۹۴، ۰/۹۴ و ۰/۹۳، عملکرد بسیار مطلوبی از خود نشان داده‌اند (شکل ۶). این نتایج بیانگر آن هستند که مدل توانسته است الگوهای ظاهری و ویژگی‌های متمایز این بیماری‌ها را به خوبی فرا گیرد و با دقت بالا از سایر دسته‌ها تفکیک نماید.

با این حال، عملکرد مدل در برخی دسته‌های دیگر با چالش همراه بوده است. به عنوان نمونه، دسته پوسیدگی آنتراکنوز میوه با دقت نرمال شده ۰/۸۰ و دسته کپک خاکستری با دقت ۰/۸۳، نشان‌دهنده کاهش نسبی دقت در مقایسه با دسته‌هایی مانند دسته‌های غالب یا بارز هست که مدل در آن‌ها عملکرد مطلوب‌تری داشته است. به‌ویژه، توجه به وضعیت عملکرد مدل در دسته سفیدک پودری میوه با دقت تنها ۰/۷۵ و سفیدک پودری برگ با ۰/۸۲، بیانگر آن است که مدل در تشخیص صحیح این دو دسته که از لحاظ ویژگی‌های ظاهری دارای تشابه و گاه دچار هم‌پوشانی هستند، سردرگم عمل کرده است. این مسأله احتمالاً به دلیل شباهت بافتی، رنگی و ساختاری بین نواحی آلوده به بیماری و پس‌زمینه‌های مشابه رخ داده است.

از طرف دیگر، دسته پس زمینه با دقت پایین و پراکندگی بالا در پیش‌بینی اشتباه برای سایر دسته‌ها، چالش‌برانگیزترین بخش از

مطالعه بیانگر قابلیت بالای آن در تشخیص کامل و دقیق اشیاء در تصاویر ورودی می‌باشد.

جدول ۳- مقایسه عملکرد چند مدل تشخیص بیماری‌های

توت‌فرنگی

Table 3. Comparison of the performance of strawberry disease detection models

مدل	دقت (P)	بازخوانی (R)	میانگین متوسط دقت
Model	Precision	Recall	mAP@50
YOLOv8n	0.850	0.845	0.879
YOLOv8m	0.768	0.828	0.868
YOLOv8l	0.809	0.809	0.865
YOLOv8x	0.819	0.819	0.860
D-YOLO	0.876	0.854	0.905
YOLO11L	0.886	0.863	0.909

در مقایسه با مدل‌های YOLOv8، مشاهده می‌شود که اگرچه افزایش اندازه مدل‌ها از نسخه نانو (YOLOv8n) به نسخه‌های بزرگ‌تر (YOLOv8x) باعث بهبود نسبی در بازخوانی می‌شود، اما این روند همواره با کاهش یا نوسان در دقت همراه بوده است. به عنوان مثال، مدل YOLOv8m با وجود افزایش پیچیدگی نسبت به YOLOv8n، دقت کمتری (۰/۷۶۸) دارد.

مدل D-YOLO نیز عملکرد قابل قبولی از خود نشان داده و با mAP@50 معادل ۰/۹۰۵، نزدیک‌ترین مدل به YOLO11L از نظر میانگین متوسط دقت محسوب می‌شود. با این حال، YOLO11L در هر سه شاخص ارزیابی، عملکرد بهتری داشته که نشان‌دهنده بهبود معماری و اثربخشی روش‌های به‌کاررفته در آموزش مدل پیشنهادی است.

به‌طور کلی، نتایج مدل‌سازی نشان می‌دهد که مدل YOLO11L با ترکیب مناسب از دقت بالا و بازخوانی مطلوب، نسبت به مدل‌های پایه و بهینه‌شده موجود عملکرد برتری دارد و می‌تواند در کاربردهای عملی تشخیص اشیاء، به‌ویژه در سناریوهایی که دستیابی به دقت بالا در آن‌ها ضروری است، مورد استفاده قرار گیرد.

۵- نتیجه‌گیری نهایی

این مطالعه به توسعه یک سامانه پیشرفته تشخیص بیماری‌های توت‌فرنگی مبتنی بر معماری به‌روز YOLO11L منجر شد که موفق به دستیابی به میانگین متوسط دقت ۹۰/۹ درصد در آستانه پنجاه درصد (mAP@50) شد. مدل پیشنهادی، در شناسایی بیماری‌هایی با علائم ظاهری مشخص از جمله سوختگی شکوفه (دقت ۹۹/۵ درصد) و لکه برگ (دقت ۹۴/۳ درصد) عملکردی بسیار

مطلوبی را از خود نشان داد. با این حال، در طبقه‌بندی بیماری‌ها با نشانه‌های ظاهری مشابه نظیر سفیدک پودری میوه (دقت ۸۲/۷ درصد) و کپک خاکستری (دقت ۸۹/۱ درصد)، افت نسبی در میزان دقت مشاهده شد که عمدتاً ناشی از دو عامل کلیدی بود: (۱) ناکافی بودن داده‌های آموزشی برای این دسته‌ها و (۲) هم‌پوشانی بالا در الگوهای ظاهری میان آن‌ها.

از منظر فنی، این پژوهش چندین نوآوری قابل‌توجه را ارائه نموده است. نخست، طراحی و پیاده‌سازی موفق چارچوبی مبتنی بر YOLO11L که توانایی شناسایی الگوهای پیچیده تصویری در داده‌های گیاهی را داراست. دوم، بهینه‌سازی جامع فرآیند آموزش مدل از طریق به‌کارگیری تکنیک‌های پیشرفته‌ای نظیر داده‌افزایی هدفمند، تنظیم خودکار هایپرپارامترها با بهره‌گیری از الگوریتم جستجوی Optuna، و استفاده از توابع زیان تخصصی با هدف افزایش دقت و پایداری مدل. سوم، انجام تحلیل‌های دقیق و نظام‌مند پیرامون عملکرد مدل در سناریوهای مختلف تشخیص، به منظور شناسایی نواحی قوت و ضعف معماری پیشنهادی.

در ادامه این پژوهش، پیشنهاد می‌شود که دامنه داده‌های آموزشی با تنوع بیشتری از شرایط نوری، پس‌زمینه‌ها و مراحل مختلف رشد توت‌فرنگی گسترش یابد تا مدل YOLO11 بتواند در محیط‌های واقعی و مزارع گوناگون عملکرد بهتری داشته باشد. علاوه بر این، استفاده از تصاویر چندطیفی^۱ یا فراتطیفی^۲ می‌تواند به شناسایی علائم اولیه بیماری‌ها که با چشم غیرمسلح قابل مشاهده نیستند، کمک کند. ادغام YOLO11 با روش‌های پس‌پردازش تصویر و الگوریتم‌های تحلیل زمانی^۳ نیز می‌تواند به پایش پیوسته سلامت گیاه و پیش‌بینی روند پیشرفت بیماری منجر شود. در زمینه بهبود عملکرد مدل، بررسی نسخه‌های بهینه‌شده YOLO با استفاده از الگوریتم‌های کاهش وزن شبکه^۴ و کوانتیزاسیون^۵ برای پیاده‌سازی در دستگاه‌های کم‌قدرت نظیر پهپادها یا ربات‌های مزرعه‌ای توصیه می‌شود. همچنین، توسعه یک سامانه هشدار هوشمند که بتواند نتایج شناسایی را به‌صورت آنی به کشاورزان ارسال کند، می‌تواند کاربرد عملی این پژوهش را در مدیریت هوشمند مزارع به میزان قابل توجهی افزایش دهد.

از دیدگاه کاربردی، سامانه ارائه‌شده ظرفیت قابل‌توجهی در بهبود راهکارهای مدیریت بیماری‌های گیاهی از طریق کاربردهایی نظیر پایش هوشمند مزارع و گلخانه‌ها، تلفیق با سامانه‌های هابرد بدون سرنشین جهت نظارت در مقیاس وسیع، و همچنین کاهش مصرف غیرهدفمند آفت‌کش‌ها به واسطه تشخیص دقیق و موقعیتی بیماری‌ها دارد.

⁴ Model Compression

⁵ Quantization

¹ Multispectral

² Hyperspectral

³ Temporal Analysis

منابع

- Samtani, J. B., Rom, C. R., Friedrich, H., Fennimore, S. A., Finn, C. E., Petran, A., Wallace, R. W., Pritts, M. P., Fernandez, G., & Chase, C. A. (2019). *The status and future of the strawberry industry in the United States*. HortTechnology, 29(1), 11–24. <https://doi.org/10.21273/HORTTECH04135-18>
- Shin, J., Chang, Y. K., Heung, B., Nguyen-Quang, T., Price, G. W., & Al-Mallahi, A. (2021). *A deep learning approach for RGB image-based powdery mildew disease detection on strawberry leaves*. Computers and Electronics in Agriculture, 183, 106042. <https://doi.org/10.1016/j.compag.2021.106042>
- Shoaib, M., Shah, B., Ei-Sappagh, S., Ali, A., Ullah, A., Alenezi, F., Gechev, T., Hussain, T., & Ali, F. (2023). *An advanced deep learning models-based plant disease detection: A review of recent research*. Frontiers in Plant Science, 14, 1158933. <https://doi.org/10.3389/fpls.2023.1158933>
- Van Tran, T., Do Ba, Q.-H., Tran, K. T., Nguyen, D. H., Dang, D. C., & Dinh, V.-L. (2024). *Designing a Mobile Application for Identifying Strawberry Diseases with YOLOv8 Model Integration*. International Journal of Advanced Computer Science & Applications, 15(3). <https://doi.org/10.14569/ijacsa.2024.0150351>
- Wai, T. T., Aye, M., & Hla, T. T. (2025). *Comparative Evaluation of Inception V3 and YOLOv8 for Strawberry Plant Diseases Classification Using Deep Learning Models*. The Indonesian Journal of Computer Science, 14(1). <https://doi.org/10.33022/ijcs.v14i1.4750>
- Wu, E., Ma, R., Dong, D., & Zhao, X. (2025). *D-YOLO: A Lightweight Model for Strawberry Health Detection*. Agriculture, 15(6). <https://doi.org/10.3390/agriculture15060570>
- Aljawasim, B. D., Samtani, J. B., & Rahman, M. (2023). *New insights in the detection and management of anthracnose diseases in strawberries*. Plants, 12(21), 3704. <https://doi.org/10.3390/plants12213704>
- Bai, Y., Yu, J., Yang, S., & Ning, J. (2024). *An improved YOLO algorithm for detecting flowers and fruits on strawberry seedlings*. Biosystems Engineering, 237, 1–12. <https://doi.org/10.1016/j.biosystemseng.2023.11.008>
- Carisse, O., & Fall, M. L. (2021). *Decision Trees to Forecast Risks of Strawberry Powdery Mildew Caused by Podosphaera aphanis*. Agriculture, 11(1). <https://doi.org/10.3390/agriculture11010029>
- Chen, M., Zou, W., Niu, X., Fan, P., Liu, H., Li, C., & Zhai, C. (2025). *Improved YOLOv8-Based Segmentation Method for Strawberry Leaf and Powdery Mildew Lesions in Natural Backgrounds*. Agronomy, 15(3), 525. <https://doi.org/10.3390/agronomy15030525>
- Dholi, P. K., Khatiwada, P., Basnet, B., & Bhandari, S. (2023). *An Extensive Review of Strawberry (Fragaria × ananassa) Diseases and Integrated Management Approaches: Current Understanding and Future Directions*. Fundamental and Applied Agriculture, 8(4), 655–667. <https://doi.org/10.5455/faa.136385>
- Hernández-Martínez, N. R., Blanchard, C., Wells, D., & Salazar-Gutiérrez, M. R. (2023). *Current state and future perspectives of commercial strawberry production: A review*. Scientia Horticulturae, 312, 111893. <https://doi.org/10.1016/j.scienta.2023.111893>
- Maghsoodi, F., Taheri, P., & Tarighi, S. (2025). *Isolation, characterization and control of Botrytis spp. pathogenic on strawberry in Iran*. Heliyon, 11(2). <https://doi.org/10.1016/j.heliyon.2025.e42037>
- Meyers, K. J., Watkins, C. B., Pritts, M. P., & Liu, R. H. (2003). *Antioxidant and antiproliferative activities of strawberries*. Journal of Agricultural and Food Chemistry, 51(23), 6887–6892. <https://doi.org/10.1021/jf034506n>
- Osdaghi, E. (2024). *Xanthomonas fragariae (angular leaf spot of strawberry)*. <https://doi.org/10.1079/cabicompendium.56934>