



Early detection and prognosis of tomato early blight disease caused by fungal pathogen *Alternaria alternata* using visible and hyperspectral image analysis

Fatemeh Soltani Nezhad¹ | Kamran Rahnama² | Keyvan Asefpour Vakilian³ | Mohsen Yazdanian⁴ | Ali Afshari⁵

1. Department of Plant Protection, Faculty of Plant Production, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran. E-mail: fatemeh.soltaninezhad_s00@gau.ac.ir
2. Corresponding Author, Department of Plant Protection, Faculty of Plant Production, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran. E-mail: rahnama@gau.ac.ir
3. Department of Biosystems Engineering, Faculty of water and soil engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran. E-mail: keyvan.asefpour@gau.ac.ir
4. Department of Plant Protection, Faculty of Plant Production, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran. E-mail: mohsenyazdanian@gau.ac.ir
5. Department of Plant Protection, Faculty of Plant Production, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran. E-mail: afshari@gau.ac.ir

Article Info

Article type: Research Article

Article history:

Received: Aug. 6, 2025

Revised: Oct. 26, 2025

Accepted: Oct. 29, 2025

Published online: Autumn 2025

Keywords:

**Artificial intelligence,
Machine learning,
Metaheuristic algorithms,
Random forest,
Suspension inoculation**

ABSTRACT

Although previous studies have reported spectral signatures of some common fungal diseases of tomato for their early detection using hyperspectral image processing methods, these studies are generally limited to identifying the occurrence or absence of the disease and do not detect the severity of disease progression. Therefore, in this study, an attempt has been made to analyze RGB and hyperspectral images of plant leaf samples, in addition to the early detection of tomato leaf spot disease caused by *Alternaria alternata*, to predict the time elapsed since inoculation of the fungal spore suspension as the rate of disease progression. Visible and hyperspectral data were collected from leaves with two-day intervals for 18 days after inoculation and before the appearance of visible symptoms of the disease. The results showed that by extracting features from the disease's hyperspectral signature identified in previous research (450, 550, 650, and 900 nm), the random forest method optimized with the Harris hawk's algorithm can detect the occurrence of the disease only six days after inoculation with an accuracy, precision, and recall of 97, 92, and 94 %, respectively. Also, the random forest optimized with the particle swarm optimization was able to correctly predict the disease progression in the first eight days after inoculation with a coefficient of determination and mean squared error of 0.91 and 0.011, respectively. Compared to the performance of hyperspectral data, the data obtained from the analysis of visible images showed a much weaker performance. The findings of this study showed that hyperspectral image analysis can be a powerful tool in the early detection and prognosis of plant diseases.

Cite this article: Soltani Nezhad, F., Rahnama, K., Asefpour Vakilian, K., Yazdanian, M., Afshari, A., (2025) Early detection and prognosis of tomato early blight disease caused by fungal pathogen *Alternaria alternata* using visible and hyperspectral image analysis, *Iranian Journal of Biosystem Engineering*, 56 (3), <https://doi.org/10.22059/ijbse.2025.400162.665606>

© The Author(s).

Publisher: The University of Tehran Press.

DOI: <https://doi.org/10.22059/ijbse.2025.400162.665606>



EXTENDED ABSTRACT

Introduction:

Early blight caused by *Alternaria alternata*, is one of the most prevalent and destructive fungal disease in tomato plants. Timely and accurate detection is critical for minimizing yield losses. However, conventional and molecular diagnostic methods are often time-consuming, costly, or require visible symptom development. In recent years, hyperspectral imaging (HSI) has emerged as a powerful, non-destructive technique for early detection of plant stresses. Numerous studies have demonstrated the high accuracy of this method in detecting fungal diseases, including early blight. However, most of these investigations have primarily focused on the binary classification of disease presence or absence. The present study aimed to determine the occurrence and severity (prognosis) of the disease caused by a fungal pathogen, using RGB and hyperspectral imaging in tomato plants. The primary objective was to develop a robust and accurate predictive model by applying machine learning algorithms to features extracted from the image data, aiming to assess disease severity with high performance and minimal error.

Material and Methods

Tomato seedlings were grown under controlled greenhouse conditions and artificially inoculated with spore suspension of *Alternaria alternata*. From day 2 to day 18 after inoculation, hyperspectral and RGB images were captured from healthy and infected leaves at two-day intervals. Image data were pre-processed by background removal, disease region segmentation, and extraction of color, textural, and morphological features. Four key hyperspectral bands (450, 550, 650, and 900 nm), previously identified as effective for early disease detection, were selected for spectral signature. Three machine learning models—artificial neural network (ANN), random forest (RF), and support vector machine (SVM) were employed, and their hyperparameters were optimized using four metaheuristic algorithms: genetic algorithm, particle swarm optimization, whale optimization algorithm, and Harris hawks optimization. The objective was to maximize classification accuracy of disease presence and minimize prediction error for disease progression severity. Models were evaluated using five-fold cross-validation, and their performance was assessed based on accuracy, precision, and recall (in the detection of the occurrence of the disease), as well as mean squared error (MSE) and coefficient of determination (R^2) (in the detection of severity of the disease).

Results and Discussion

The results showed that by extracting features from the disease's hyperspectral signature identified in previous research (450, 550, 650, and 900 nm), the random forest method optimized with the Harris hawks algorithm can detect the occurrence of the disease only six days after inoculation with an accuracy, precision, and recall of 97, 92, and 94 %, respectively. Also, the random forest optimized with the particle swarm optimization was able to correctly predict the disease progression in the first eight days after inoculation with a coefficient of determination and mean squared error of 0.91 and 0.011, respectively. Compared to the performance of hyperspectral data, the data obtained from the analysis of RGB images showed a much weaker performance. RGB features were less sensitive at earlier stages of infection, whereas hyperspectral data enabled detection even before visible symptoms appeared. The detection accuracy with RGB images remained only around 70% even 18 days after disease transmission.

Conclusion

This study underscores the potential of integrating hyperspectral imaging with machine learning for the early and accurate detection of fungal diseases in tomato plants. In comparison with hyperspectral imaging, the outcomes of RGB image analysis exhibited markedly lower performance, emphasizing the critical role of hyperspectral data in the precise detection and monitoring of plant diseases. Based on the findings, the random forest model, optimized using the Harris hawks algorithm, demonstrated high efficiency in the early and rapid detection of the disease, potentially contributing significantly to informed management decisions and timely agricultural interventions.

Author Contributions

All authors contributed equally to the conceptualization of the article and writing of the original and subsequent drafts.

Data Availability Statement

Data available on request from the authors.

Acknowledgements

The authors gratefully acknowledge the support provided by the Gorgan University of Agricultural

Sciences and Natural Resources, which contributed significantly to the completion of this study.

Ethical considerations

The authors avoided data fabrication, falsification, plagiarism, and misconduct.

Conflict of interest

The author declares no conflict of interest.

پیش‌آگاهی و تشخیص میزان پیشرفت بیماری لکه‌موجی گوجه‌فرنگی با عامل قارچی *Alternaria alternata*

فاطمه سلطانی‌نژاد^۱ | کامران رهنما^۲ | کیوان آصف‌پور وکیلان^۳ | محسن یزدانیان^۴ | علی افشاری^۵

۱. گروه گیاه‌پزشکی، دانشکده تولید گیاهی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران. رایانامه:

fatemeh.soltaninezhad_s00@gu.ac.ir

۲. نویسنده مسئول، گروه گیاه‌پزشکی، دانشکده تولید گیاهی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران. رایانامه:

rahnama@gu.ac.ir

۳. گروه مهندسی مکانیک بیوسیستم، دانشکده مهندسی آب و خاک، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران. رایانامه:

keyvan.asefpour@gu.ac.ir

۴. گروه گیاه‌پزشکی، دانشکده تولید گیاهی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران. رایانامه:

mohsenyazdanian@gu.ac.ir

۵. گروه گیاه‌پزشکی، دانشکده تولید گیاهی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران. رایانامه: afshari@gu.ac.ir

چکیده

اطلاعات مقاله

اگرچه در تحقیقات پیشین امضای طیفی برخی بیماری‌های قارچی شایع گوجه‌فرنگی برای شناسایی زودهنگام آن‌ها به کمک روش‌های پردازش تصاویر فراطیفی گزارش شده‌است، این تحقیقات عموماً تنها به شناسایی وقوع یا عدم وقوع بیماری محدود هستند و شدت پیشرفت بیماری را تشخیص نمی‌دهند. بنابراین، در این تحقیق، سعی شده است به کمک تحلیل تصاویر رنگی RGB و فراطیفی نمونه‌های برگ گیاهان، علاوه بر تشخیص زودهنگام بیماری لکه موجی گوجه‌فرنگی با عامل قارچی *Alternaria alternata*، مدت زمان سپری شده از مایه‌زنی سوسپانسیون اسپور قارچ به‌عنوان میزان پیشرفت بیماری نیز پیش‌بینی شود. داده‌های مرئی و فراطیفی به مدت ۱۸ روز پس از مایه‌زنی و پیش از بروز علائم ظاهری بیماری، به‌صورت یک روز در میان از برگ‌ها جمع‌آوری گردید. نتایج نشان داد که به کمک استخراج ویژگی‌ها از امضای فراطیفی بیماری که در تحقیقات پیشین شناسایی شده است (۴۵۰، ۵۵۰، ۶۵۰ و ۹۰۰ نانومتر)، روش جنگل تصادفی بهینه‌شده با الگوریتم شاهین هریس می‌تواند وقوع بیماری را تنها پس از گذشت شش روز از مایه‌زنی با دقت، صحت و بازیابی به‌ترتیب ۹۷، ۹۲، و ۹۴ درصد تشخیص دهد. همچنین، الگوریتم جنگل تصادفی بهینه‌شده با الگوریتم توده نقاط، توانایی پیش‌بینی صحیح میزان پیشرفت بیماری در هشت روز اول پس از مایه‌زنی با ضریب تبیین و میانگین مربعات خطای به‌ترتیب ۰/۹۱ و ۰/۱۱ را نشان داد. در مقایسه با عملکرد داده‌های فراطیفی، داده‌های به دست آمده از تحلیل تصاویر مرئی عملکرد به مراتب ضعیف‌تری را نشان داد. نتایج این پژوهش نشان می‌دهد استفاده از تصاویر فراطیفی می‌تواند به‌عنوان ابزاری قدرتمند در پیش‌آگاهی و تشخیص میزان پیشرفت بیماری‌های گیاهی کارآمد باشد.

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۴/۵/۱۵

تاریخ بازنگری: ۱۴۰۴/۸/۴

تاریخ پذیرش: ۱۴۰۴/۸/۷

تاریخ انتشار: پاییز ۱۴۰۴

واژه‌های کلیدی:

الگوریتم‌های فراابتکاری،

جنگل تصادفی،

مایه‌زنی سوسپانسیون،

هوش مصنوعی،

یادگیری ماشین.

استناد: سلطانی‌نژاد، فاطمه، رهنما، کامران، آصف‌پور وکیلان، کیوان، یزدانیان، محسن، افشاری، علی، (۱۴۰۴) پیش‌آگاهی و تشخیص میزان پیشرفت بیماری لکه‌موجی گوجه‌فرنگی با عامل قارچی *Alternaria alternata* با استفاده از تحلیل تصاویر مرئی و فراطیفی، مجله مهندسی بیوسیستم ایران/ایران، ۵۶ (۳)،



© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

<https://doi.org/10.22059/ijbse.2025.400162.665606>

DOI: <https://doi.org/10.22059/ijbse.2025.400162.665606>

مقدمه

بیماری لکه‌موجی یکی از مهم‌ترین بیماری‌های گوجه‌فرنگی است که توسط گونه‌های مختلف قارچ *Alternaria spp.* ایجاد می‌شود. علائم این بیماری به‌صورت لکه‌های حلقوی قهوه‌ای تیره تا سیاه رنگ بر روی برگ‌ها ظاهر می‌شود و پس از آن، این لکه‌ها در بین رگبرگ‌ها خشک می‌شوند (Prasad and Upadhyay, 2010). اگرچه علائم بیماری ممکن است در بخش‌های مختلف گیاه دیده شود، اما عمدتاً برگ‌ها برای تشخیص بیماری مورد استفاده قرار می‌گیرند و این امر نیازمند حضور مداوم نیروی متخصص برای پایش مزرعه است (Mohammad Zamani et al., 2023). روش‌های تشخیص مولکولی، دقت بالایی در شناسایی بیماری‌های گیاهی دارند، اما زمان‌بر و پرهزینه هستند. از سوی دیگر، روش‌هایی مانند بینایی ماشین و پردازش تصویر که برای شناسایی و طبقه‌بندی بیماری‌های گیاهی براساس علائم ظاهری به‌کار می‌روند، تنها زمانی قابل استفاده هستند که بیماری در گیاه گسترش یافته باشد (Cruz et al., 2017; Momeni et al., 2022).

از آن‌جا که تشخیص زودهنگام و دقیق بیماری‌ها، نخستین گام حیاتی در کاهش خسارات ناشی از آن‌ها است، تصویربرداری فراطیفی^۱ در دو دهه اخیر به‌طور چشم‌گیری برای بررسی زودهنگام تنش‌های زیستی و غیرزیستی در محصولات کشاورزی توسعه یافته است (Abdulridha et al., 2022; Hariharan et al., 2023; Javidan et al., 2022; 2024). دوربین‌های تصویربرداری فراطیفی با ثبت منطقه وسیعی از طیف الکترومغناطیسی، ابزارهایی دقیق برای شناسایی، تشخیص، مدل‌سازی و طبقه‌بندی بیماری‌های گیاهی محسوب می‌شوند (Moghadam et al., 2017). این فناوری برای اولین بار در اواخر دهه ۷۰ میلادی در آمریکا مورد استفاده قرار گرفت و از سال ۱۹۸۹ استفاده از آن گسترش پیدا کرد (Gao and Smith, 2015). در میان روش‌های سنجش از راه دور بیماری‌های گیاهی، از جمله تصویربرداری طیفی، چندطیفی و فراطیفی، تصویربرداری فراطیفی به‌دلیل قدرت تفکیک مکانی و طیفی بالا، برتری قابل توجهی نسبت به سایر روش‌ها از جمله تصویربرداری RGB و چندطیفی دارد (Luvisi and Ampatzidis, 2016; Hariharan et al., 2019; Javidan et al., 2023). این فناوری می‌تواند با ادغام طیف و تصویر، پاسخ‌های بیوشیمیایی و فیزیولوژیکی برگ مانند رنگ‌دانه‌ها، ترکیبات شیمیایی و محتوای آب را تحلیل کرده و بین نواحی سالم و بیمار تمایز قائل شود (Xuan et al., 2022). تصویربرداری فراطیفی با ثبت صدها باند طیفی در نواحی مرئی و نزدیک مادون قرمز، امکان شناسایی حساس‌ترین طول موج‌ها را از طریق تلفیق با الگوریتم‌های انتخاب ویژگی فراهم می‌آورد. این امر، استخراج ویژگی‌هایی نظیر بازتاب طیفی، شاخص‌های گیاهی، شکل، آمار توصیفی و اطلاعات بافتی گیاه را ممکن می‌سازد که در نهایت با معرفی امضای طیفی بیماری‌های گیاهی، درک جامع‌تری از وضعیت بیماری ارائه می‌دهد و به مدیریت مؤثرتر آن کمک می‌کند (Ampatzidis and De Bellis, 2017). همچنین این روش با تلفیق طیف‌سنجی نوری و تحلیل تصویر، بررسی هم‌زمان ویژگی‌های فیزیولوژیکی و مورفولوژیکی گیاه را ممکن می‌سازد (Cheshkova, 2022).

در یکی از تحقیقات (Xie et al., 2015) با بررسی روش تحلیل داده‌های فراطیفی در تشخیص زودهنگام بیماری‌های لکه‌موجی و بادزدگی ناشی از *Phytophthora infestans* در گوجه‌فرنگی، آن‌را با دقت ۹۷/۱ تا ۱۰۰ درصد موفق دانستند. در تحقیق دیگری، (Yuan et al., 2019) در مطالعه‌ای روی بیماری آنتراکنوز چای، با تحلیل تصاویر در محدوده ۴۰۰-۱۰۰۰ نانومتر، طول موج‌های ۵۴۲، ۶۸۶ و ۷۵۴ نانومتر را به‌عنوان باندهای حساس شناسایی کردند. آن‌ها همچنین نشان دادند که دقت تشخیص، تحت تأثیر پس‌زمینه برگ‌ها قرار نمی‌گیرد. در مطالعه‌ای دیگر، (Pan et al., 2019) برای شناسایی بیماری لکه‌سیاه گلایی ناشی از قارچ *Alternaria alternata* از تصویربرداری فراطیفی استفاده کردند و مدل ماشین‌بردار پشتیبان^۲ را با دقت ۹۷/۵ درصد به‌عنوان مؤثرترین روش تحلیل این تصاویر معرفی نمودند.

همچنین، مطالعات متعددی از فناوری تصویربرداری فراطیفی برای تشخیص زودهنگام بیماری‌های مختلفی مانند لکه‌باکتریایی گوجه‌فرنگی (عباسی و همکاران، ۱۴۰۱)، بلایت سنبله گندم (*Fusarium spp.*) (Mahlein et al., 2019)، بیماری ناشی از قارچ *Burkholderia cepacia* در پیاز (Wang et al., 2012) و پوسیدگی ریشه چغندرقد با عامل *Rhizoctonia solani* (Barreto et al., 2020) بهره گرفتند. در همین راستا، (Abdulridha et al., 2020) با استفاده از تصویربرداری فراطیفی در محدوده ۳۸۰ تا ۱۰۲۰ نانومتر و الگوریتم یادگیری ماشین تابع پایه‌شعاعی^۳، بیماری سفیدک پودری کدو را با دقت ۸۹ درصد تشخیص دادند. همچنین

1. Hyperspectral
2. Support vector machine
3. Radial basis function

(Azadshahraki et al., 2022) با تحلیل مؤلفه‌های اصلی و شبکه عصبی مصنوعی، موفق به شناسایی بیماری لکه‌موجی گوجه‌فرنگی با دقت ۹۳ تا ۱۰۰ درصد شدند و این روش را به‌عنوان جایگزین مناسبی برای تشخیص بیماری‌های گوجه‌فرنگی پیشنهاد دادند. لیکن روند شدت میزان بیماری، مطالعه نگردید.

همچنین، (Javidan et al., 2024) رویکردی جدید برای تشخیص چهار بیماری قارچی شایع در گوجه‌فرنگی، شامل *Botrytis*، *Alternaria solani* و *A. alternata*، *Fusarium oxysporum*، *cinerea*، با استفاده از تصویربرداری RGB (مرئی) و فراطیفی (۴۰۰-۹۵۰ نانومتر) از برگ‌های گیاه در ۱۱ روز اول پس از انتقال بیماری ارائه دادند. مجموعه داده‌ها از نمونه‌های برگ تولید شدند و ویژگی‌های آماری، بافتی و شکلی برای آموزش مدل‌های یادگیری ماشین استخراج شدند. نتایج نشان داد برای تصاویر RGB، مدل جنگل تصادفی با نرخ طبقه‌بندی به‌ترتیب ۶۵، ۷۱، ۷۵، ۷۷، ۸۳ و ۸۷ درصد در روزهای ۱، ۳، ۵، ۷، ۹ و ۱۱ پس از مایه‌زنی توانایی تشخیص بیماری را دارد. برای تصاویر فراطیفی، دقت طبقه‌بندی از ۸۶ درصد در روز اول به ۹۸ درصد در روز یازدهم افزایش یافت. روش امتیاز لاپلاسی، ویژگی‌های کلیدی بافت تصویر، شامل انرژی در ۵۵۰ و ۸۴۱ نانومتر، آنتروپی در ۶۰۰ نانومتر، همبستگی در ۷۴۶ نانومتر و انحراف معیار در ۹۰۵ نانومتر را که بیشترین سهم را در تشخیص بیماری داشتند، شناسایی کرد.

مدل‌های یادگیری ماشین دارای آبرپارامترهایی هستند که انتخاب بهینه مقدار آن‌ها می‌تواند عملکرد مدل را در طی فرآیند یادگیری به‌طور چشمگیری ارتقا دهد (Schratz et al., 2019; Pannakkong et al., 2022). بهینه‌سازی مقادیر آبرپارامترها را می‌توان با استفاده از روش‌های مختلفی انجام داد. در سال‌های اخیر، روش‌های فراابتکاری مبتنی بر هوش جمعیتی به‌طور گسترده‌ای برای این منظور به‌کار گرفته شده‌اند (Asefpour Vakilian, 2022; 2023). الگوریتم ژنتیک از مجموعه‌ای از کروموزوم‌های تصادفی تشکیل شده است که راه‌حل‌های ممکن برای یک مسئله بهینه‌سازی را توصیف می‌کند. در طی تکرارهای متوالی که نسل نامیده می‌شوند، کروموزوم‌هایی که مقادیر مناسب‌تری از تابع برازندگی را ایجاد می‌کنند، زنده می‌مانند و برای تولید فرزندان جدید در نسل‌های بعدی که احتمالاً به راه‌حل بهینه نزدیک‌تر هستند، استفاده می‌شوند (Katoch et al., 2021). در الگوریتم توده نقاط، یک جمعیت اولیه از نقاط تصادفی در فضای پاسخ انتخاب می‌شوند. نقاطی که جواب مناسب‌تری را ارائه می‌دهند، به مقدار کمی در فضای پاسخ حرکت می‌کنند، در حالی که سایر نقاط با سرعت بیشتری به سمت این نقاط شروع به حرکت می‌کنند. این فرآیند در نهایت منجر به هم‌گرایی تمام نقاط به یک نقطه بهینه می‌شوند (Wang et al., 2018).

الگوریتم بهینه‌سازی نهنگ یک الگوریتم فراابتکاری مبتنی بر طبیعت است که از رفتار شکار نهنگ‌های کوهان‌دار الهام گرفته شده است. این الگوریتم شامل دو فاز اصلی است: احاطه کردن طعمه که طی آن نهنگ‌ها به دور طعمه (نمایانگر جواب بهینه مسئله) حرکت می‌کنند و آن را محاصره می‌کنند و حرکت مارپیچی به سمت طعمه که در آن، نهنگ‌ها با الگویی مارپیچی به سمت موقعیت طعمه حرکت کرده و موقعیت خود را نسبت به آن بهینه می‌کنند (Mirjalili and Lewis, 2016). الگوریتم بهینه‌سازی شاهین هریس نیز از رفتار شکار گروهی شاهین‌های هریس الهام گرفته است. این پرندگان به صورت گروهی، طعمه را محاصره و شکار می‌کنند و این الگوریتم نیز بر همین اساس طراحی شده است. الگوریتم بهینه‌سازی شاهین هریس دارای دو مرحله اصلی است: فاز جستجو که در آن به دنبال نواحی جدید و امیدوارکننده در فضای مسئله می‌گردد و فاز بهره‌برداری که در آن به دنبال بهبود جواب‌های یافت شده در فاز جستجو می‌پردازد. انتقال از مرحله جستجو به مرحله بهره‌برداری براساس متغیری کلیدی به نام شدت انرژی فرار طعمه صورت می‌گیرد. این الگوریتم، رفتارهای مختلف شاهین‌ها مانند تعقیب، محاصره و حمله به طعمه در مراحل مختلف شبیه‌سازی می‌کند تا بتواند به بهترین جواب دست یابد (Heidari et al., 2019).

بررسی تحقیقات پیشین نشان می‌دهد اگرچه پژوهش‌های فراوانی برای شناسایی زودهنگام بیماری‌های قارچی در دهه اخیر انجام شده است، این تحقیقات عموماً تنها به شناسایی وقوع یا عدم وقوع بیماری محدود هستند و شدت پیشرفت بیماری را تشخیص نمی‌دهند. با توجه به این که تشخیص میزان پیشرفت بیماری در کنار تشخیص صحیح بیماری‌های گیاهی، اولین گام حیاتی در کاهش خسارات ناشی از آن است و تشخیص نادرست می‌تواند منجر به تصمیم‌گیری‌های مدیریتی اشتباه، کاهش تولید محصول و بازده سلامتی شود (عباسی و همکاران، ۱۴۰۱)، این پژوهش با هدف شناسایی صحیح مدت‌زمان سپری شده از مایه‌زنی سوسپانسیون اسپور (هاگ) قارچ عامل بیماری لکه‌موجی گوجه‌فرنگی به‌عنوان نشانگر شدت پیشرفت بیماری با استفاده از تحلیل تصاویر حاصل از دوربین فراطیفی و RGB انجام شد.

مواد و روش‌ها

کاشت گیاه


ابتدا گیاهچه‌های گوجه‌فرنگی پس از آماده سازی اولیه مراحل ذیل در گلخانه تحقیقاتی دانشگاه علوم کشاورزی و منابع طبیعی گرگان کشت داده شدند. بذرهای گوجه‌فرنگی رقم سی‌اچ‌فلات به مدت ۶۰ ثانیه با محلول هیپوکلریت سدیم ۰/۵ درصد ضدعفونی شده و با آب مقطر استریل شستشو داده شدند. سپس بذرها در سینی نشا حاوی خاک استریل (اتوکلاو شده در دمای ۱۲۱ درجه سلسیوس در ۲ روز متوالی به مدت ۳۰ دقیقه) کاشته شدند. خاک مورد استفاده شامل ماسه، خاک برگ و خاک مزرعه به نسبت مساوی بود. پس از گذشت ۲ هفته، نشاها به گلدان‌های یک کیلوگرمی منتقل شدند و در گلخانه با رطوبت ۸۰ درصد و دمای ۱۸ تا ۲۵ درجه سلسیوس نگهداری شدند تا سطح برگ مناسبی برای نمونه‌برداری پیدا کنند (شکل ۱ الف).

تهیه قارچ بیمارگر

به منظور تهیه و جداسازی قارچ بیمارگر، ابتدا نمونه‌های مشکوک به بیماری لکه‌موجی از مزارع گوجه‌فرنگی اطراف شهر گرگان جمع‌آوری شدند. نمونه‌ها پس از انتقال به آزمایشگاه، بر روی تشک‌های پتری حاوی محیط‌کشت سیب‌زمینی دکستروز آگار (PDA) کشت داده شدند. سپس در انکوباتور در دمای ۲۵ درجه سلسیوس به مدت ۳ تا ۵ روز نگهداری شدند (شکل ۱ ب). از بین نمونه‌های کشت داده شده، قارچ *A. alternata* با استفاده از کلید شناسایی و روش مولکولی THENG-tsp (Hatamzadeh et al., 2023) شناسایی شد که برای مطالعه گلخانه‌ای از آن استفاده شد.

انتقال بیماری به گیاه گوجه‌فرنگی در گلخانه

به‌منظور انتقال بیماری به گیاهان گوجه‌فرنگی در مرحله ۶ تا ۸ برگی، سوسپانسیون قارچ بیمارگر *A. alternata* با غلظت 10^5 اسپور (هاگ) در میلی‌لیتر روی اندام‌های هوایی برگ گیاه که خراش سطحی داده شده بودند، محلول‌پاشی شد. در تیمار شاهد، آب مقطر سترون روی بوته‌ها پاشیده شد. برای استقرار بهتر اسپورها در سطح اندام‌های هوایی گیاه، توئین ۲۰ به میزان ۰/۰۵ درصد به سوسپانسیون اسپور بیمارگر اضافه شد و تا سه روز پس از محلول‌پاشی، گلدان‌ها با پلاستیک شفاف از جنس پلی‌اتیلن پوشانده شدند تا رطوبت آن‌ها حفظ شود (شکل ۱ ج). برای انجام آزمایش، ۵۰ گلدان برای تیمار حاوی قارچ بیمارگر و ۵۰ گلدان برای شاهد سالم، در نظر گرفته شد.



شکل ۱. (الف) گیاهان گوجه‌فرنگی دو هفته پس از انتقال نشاء به گلدان‌های اصلی در گلخانه، (ب) پرگنه قارچ *A. alternata* در محیط‌کشت سیب‌زمینی دکستروز آگار و (ج) پوشش‌دهی گلدان‌ها با پلاستیک پلی‌اتیلن پس از محلول‌پاشی با سوسپانسیون اسپور *A. alternata*

تهیه تصاویر مرئی RGB و فراطیفی

برای تهیه تصاویر، از روز دوم پس از مایه‌زنی سوسپانسیون اسپور قارچ بیمارگر تا روز هجدهم که علائم ظاهری لکه‌موجی مشاهده شد (شکل ۲)، به‌صورت یک روز در میان، تعداد ۲۰ برگ سالم و ۲۰ برگ آلوده به آزمایشگاه منتقل شده و با استفاده از دوربین فراطیفی (Hyspim HSI-Vis_Nir-15fps، سوئد) با محدوده طیفی ۴۰۰ تا ۹۵۰ نانومتر مورد عکسبرداری قرار گرفتند. همچنین، تصاویر RGB از برگ‌ها با یک تلفن همراه مجهز به دوربین ۱۲ مگاپیکسل (گلکسی S20، سامسونگ، کره جنوبی) گرفته شد. نورپردازی برای هر دو نوع تصویربرداری توسط دو منبع هالوژن نصب شده در بالای برگ تأمین شد و از یک پس‌زمینه تیره برای نمونه‌ها استفاده شد. برای جلوگیری از تداخل نوری، یک محفظه تاریک کوچک آماده شد که دوربین و لامپ‌های هالوژن در داخل آن قرار گرفتند. فاصله بین

نمونه‌های برگ و دوربین ۲۵ سانتی‌متر بود تا کل مساحت هر برگ در تصاویر ثبت‌شده قابل مشاهده باشد. برای جلوگیری از ایجاد سایه در تصاویر، لامپ‌های هالوژن در زاویه ۴۵ درجه نسبت به سطح افقی نصب شدند (شکل ۳). برای کالیبره کردن بازتاب برگ، از کاغذ سفید استاندارد که توسط شرکت سازنده دوربین فراطیفی توصیه شده بود، استفاده شد. هر ۱۰ دقیقه یک‌بار از این کاغذ سفید عکس گرفته می‌شد تا دوربین مجدداً کالیبره شود، زیرا شدت تابش منبع نور ممکن بود با گذشت زمان تغییر کند.



شکل ۲. (الف) برگ شاهد سالم و (ب) برگ بیمار گیاه گوجه‌فرنگی پس از گذشت هجده روز از مایه‌زنی با سوسپانسیون اسپور قارچ بیمارگر و بروز علائم ظاهری بیماری



شکل ۳. عکس‌برداری از برگ‌های گیاه گوجه‌فرنگی با دوربین فراطیفی (Hyspim HSI-Vis_Nir-15fps، سوئد)

بخش‌بندی بیماری در تصاویر RGB

حذف پس‌زمینه، یک گام بسیار مهم در استخراج ویژگی‌های تصویر برای یادگیری ماشین است. هدف این مرحله، حذف هرگونه نوفه احتمالی در ویژگی‌های استخراج شده از تصویر است. در این مطالعه، ترکیبی از خوشه‌بندی پیکسلی و تشخیص لبه برای حذف خودکار پس‌زمینه انجام شد. برای حذف پس‌زمینه، ابتدا تنها باند رنگ سبز از تصاویر استخراج شد و سپس از الگوریتم Canny برای تشخیص لبه‌ها استفاده شد. پس از آن، از عملیات مورفولوژیکی اتساع برای پر کردن فضاهای خالی در تصویر استفاده شد. در مرحله بعد، حفره‌های باقی‌مانده در تصویر پر شد تا تصویری بدون پس‌زمینه به‌دست آید. برای بخش‌بندی نواحی سالم و بیمار برگ‌ها، از الگوریتم خوشه‌بندی K-means استفاده شد. این روش بر اساس کمینه‌سازی مجموع مربعات فاصله بین هر شی در تصویر و مرکز خوشه مربوطه عمل می‌کند. در این مطالعه، انتخاب ناحیه مورد نظر^۲ (ROI) در خوشه‌بندی K-means (شماره خوشه نشان‌دهنده بیماری) به‌صورت خودکار و مشابه روش ارائه‌شده توسط (Javidan et al., 2024) به‌دست آمد که شامل آستانه‌گذاری بین رنگ ناحیه بیماری (علائم) و رنگ ناحیه سالم برگ است.

به‌کارگیری امضای طیفی بیماری در تصاویر فراطیفی

تحلیل تصاویر فراطیفی به‌دلیل حجم بسیار زیاد داده نیاز به چندین مرحله پیش‌پردازش دارد. از آنجا که امضای طیفی بیماری قارچی مورد مطالعه در این تحقیق توسط (Javidan et al., 2024) به‌گونه‌ای گزارش گردیده است که مؤثرترین ویژگی‌های تشخیص زودهنگام

1. Noise
2. Region of interest


بیماری در طیف‌های ۴۵۰، ۵۵۰، ۶۵۰ و ۹۰۰ نانومتر شناسایی شده‌اند، باندهای مذکور از تصاویر فراطیفی استخراج گردید تا ویژگی‌های تصویر در این باندها محاسبه شوند.

استخراج ویژگی‌ها

در این پژوهش، ویژگی‌های آماری توصیفی سطح خاکستری (میانگین، بیشینه، انحراف معیار، میانه) و ویژگی‌های بافتی استخراج شده از ماتریس هم‌پیشامد سطوح خاکستری^۱ (GLCM) مانند کنتراست، همبستگی، انرژی، یکنواختی، میانگین، انحراف معیار، آنتروپی، میانگین مربع ریشه، واریانس، نرمی، کشیدگی^۲، چولگی^۳ از باندهای چهارگانه تصاویر فراطیفی و از هر باند رنگی در مدل RGB استخراج شدند. همچنین، ویژگی‌های شکلی نظیر مساحت، محیط، تعداد اشیاء، طول محور اصلی و فرعی لکه‌ها، شاخص کشیدگی، دایره‌ای بودن، شاخص دایره‌ای، شاخص فشردگی نیز استخراج شدند. در حین استخراج ویژگی‌های بافتی از ماتریس GLCM، فاصله و جهت همسایگی برابر با ۱ پیکسل و صفر درجه در نظر گرفته شد (Asefpour Vakilian and Massah, 2017).

روش‌های یادگیری ماشین

در این مطالعه برای تشخیص وقوع بیماری و سنجش شدت پیشرفت آن به‌ترتیب از روش‌های طبقه‌بندی و رگرسیون بهره گرفته شد. طبقه‌بندی یکی از زیرشاخه‌های اصلی در داده‌کاوی و یادگیری ماشین محسوب می‌شود و برای آموزش نحوه اختصاص برچسب کلاس به نمونه‌های ورودی استفاده می‌شود، در حالی که از رگرسیون برای پیش‌بینی یک متغیر پیوسته استفاده می‌شود و هدف آن کم کردن خطای بین داده پیش‌بینی شده و داده مشاهداتی است. در این مطالعه، از سه مدل شبکه عصبی مصنوعی^۴، جنگل تصادفی^۵ و ماشین بردار پشتیبان^۶ که هم برای طبقه‌بندی و هم برای رگرسیون کاربرد دارند، استفاده شد (شکل ۴).



شکل ۴. روش یادگیری ماشین مورد استفاده در این مطالعه

یک شبکه سه‌لایه از نوع پرسپترون با الگوریتم یادگیری لوبز مارکوارت^۷ به‌عنوان شبکه عصبی مصنوعی در نظر گرفته شد. برای توسعه مدل ماشین بردار پشتیبان از کرنل^۸ تابع پایه شعاعی (گاوسی)^۸ بهره گرفته شد. همچنین، الگوریتم جنگل تصادفی با حداکثر ۲۰ سطح هرس به‌کار گرفته شد (Samadi et al., 2024). در این مطالعه، تعداد نرون‌ها در لایه یادگیرنده و نرخ یادگیری در شبکه عصبی مصنوعی، پارامتر کرنل و ضریب هزینه در ماشین بردار پشتیبان و همچنین کمینه تعداد برگ‌ها و والدین در الگوریتم جنگل تصادفی، به‌عنوان آبرپارامترها بهینه شدند. در این پژوهش، چهار الگوریتم فراابتکاری شامل الگوریتم ژنتیک، الگوریتم توده نقاط، الگوریتم نهنگ، و

1. Grey-level co-occurrence matrix
2. Kurtosis
3. Skewness
4. Artificial neural network
5. Random forest
6. Levenberg-Marquardt learning algorithm
7. Kernel
8. Gaussian kernel

الگوریتم شاهین هریس برای بهینه‌سازی مورد استفاده قرار گرفتند.

در این پژوهش، تابع برازندگی برای الگوریتم‌های بهینه‌سازی به گونه‌ای تعریف شد که هدف آن بهینه‌سازی دقت طبقه‌بندی صحیح تشخیص وقوع بیماری و کمینه‌سازی خطای تفاوت بین شدت واقعی پیشرفت بیماری و مقدار پیش‌بینی شده آن باشد. پیاده‌سازی الگوریتم‌های یادگیری ماشین در محیط برنامه‌نویسی نرم‌افزار MATLAB انجام شد. برای آموزش و ارزیابی مدل‌ها، از روش اعتبارسنجی متقابل پنج‌تایی استفاده گردید. در این روش، تمامی داده‌های پایگاه داده به پنج بخش مساوی تقسیم می‌شوند و در مرحله اول، یک بخش از این داده‌ها به عنوان آزمون انتخاب شده، در حالی که چهار بخش دیگر برای آموزش ماشین به کار گرفته می‌شوند. در مرحله دوم، بخش دیگری به عنوان آزمون انتخاب می‌شود و مابقی داده‌ها مجدداً برای آموزش استفاده می‌شوند. این فرآیند پنج بار تکرار می‌شود تا هر بخش، یک‌بار به عنوان آزمون در نظر گرفته شده باشد. مزیت این روش نسبت به روش‌های دیگر مانند انتخاب تصادفی داده‌های آزمون این است که تمامی داده‌های موجود حداقل یک‌بار در فرآیند آزمون مورد استفاده قرار می‌گیرند، که موجب افزایش اعتبار نتایج ارزیابی می‌شود. عملکرد ماشین از میانگین عملکردها برای هر بخش به دست می‌آید. نزدیک بودن عملکرد مدل برای تمام بخش‌ها نشان‌دهنده عدم وقوع بیش‌برازش و عدم گیر افتادن مدل در کمینه‌های موضعی است. از آنجا که شبکه عصبی مصنوعی، برخلاف سایر مدل‌ها، علاوه بر داده‌های آموزش و آزمون به داده‌های اعتبارسنجی برای تنظیم و پایش فرآیند آموزش نیاز دارد، در هر تکرار، ۲۰ درصد از داده‌های آموزش به فرآیند اعتبارسنجی اختصاص یافت. برای ارزیابی عملکرد مدل‌ها در طبقه‌بندی از معیارهای دقت^۱ (رابطه ۱)، صحت^۲ (رابطه ۲) و بازیابی^۳ (رابطه ۳) استفاده شد. همچنین، در مسائل رگرسیون، میانگین مربعات خطا (MSE) (رابطه ۴) و ضریب تبیین (R^2) (رابطه ۵) به عنوان شاخص‌های ارزیابی عملکرد ماشین‌ها مورد استفاده قرار گرفتند (Li and Asefpour Vakilian, 2025).

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (\text{رابطه ۱})$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (\text{رابطه ۲})$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (\text{رابطه ۳})$$

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (x_p - x_0)^2 \quad (\text{رابطه ۴})$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_p - x_0)^2}{\sum_{i=1}^n (x_0 - \bar{x}_0)^2} \quad (\text{رابطه ۵})$$

که در این روابط، TP پیش‌بینی درست برای نمونه‌های آلوده به بیماری، TN پیش‌بینی درست برای نمونه‌های منفی، FP پیش‌بینی اشتباه مثبت برای نمونه‌های بدون آلودگی، و FN پیش‌بینی اشتباه منفی برای نمونه‌های آلوده به بیماری قارچی، x_0 مقدار مشاهداتی است که باید توسط ماشین پیش‌بینی شود (مدت زمان سپری شده از مایه‌زنی بر حسب روز)، x_p مقدار پیش‌بینی شده این مدت زمان توسط ماشین است، و n تعداد کل نمونه‌ها است. از آنجا که از روش اعتبارسنجی متقابل پنج‌تایی برای آموزش و آزمون ماشین‌ها استفاده شد، پنج عدد برای هر یک از این معیارهای ارزیابی به دست آمد که برای مقایسه ماشین‌ها، میانگین این اعداد در این تحقیق گزارش گردید.

نتایج و بحث

نتایج طبقه‌بندی بیماری به کمک تصاویر فراطیفی و RGB

پس از استخراج ویژگی‌های آماری توصیفی رنگ، بافت و شکل از تصاویر فراطیفی و RGB، مجموعه داده‌هایی برای هر دو گروه از تصاویر ساخته شد و طبقه‌بندی برای شناسایی برگ‌های بیمار و سالم انجام گرفت. جدول ۱، معیارهای ارزیابی طبقه‌بندی بیماری را با استفاده از مدل‌های مختلف یادگیری ماشین و بر پایه داده‌های تصویربرداری فراطیفی و RGB در روزهای اول تا هجدهم نشان می‌دهد.

جدول ۱ میانگین معیارهای ارزیابی مدل برای پنج بخش در فرآیند اعتبارسنجی متقابل ۵ تایی را در روزهای پس از انتقال بیماری نشان می‌دهد. مقادیر این معیارها برای هر پنج بخش تقریباً مشابه یکدیگر بود که تأییدکننده عدم وقوع بیش‌برازش در حین یادگیری مدل است. براساس نتایج جدول ۱، طبقه‌بندی با استفاده از داده‌های فراطیفی در تمام مدل‌های یادگیری ماشین مورد بررسی، عملکرد بهتری نسبت به داده‌های RGB داشته است. همچنین، عملکرد طبقه‌بندی در تمامی مدل‌ها با گذشت زمان بهبود یافته است، که این به دلیل پیشرفت و گسترش بیماری در گیاهان آلوده و افزایش ناحیه‌های آلوده در سطح برگ‌ها است. از روز شانزدهم به بعد، هر سه معیار ارزیابی طبقه‌بندی بیماری با استفاده از تصاویر فراطیفی در هر سه مدل شبکه عصبی مصنوعی، جنگل تصادفی و ماشین بردار پشتیبان به بیش از ۹۰ درصد رسیده است. برای تصاویر RGB، معیارهای طبقه‌بندی حتی پس از ۱۸ روز به عددی تقریباً برابر با ۷۰ درصد رسیده است. جدول ۱ نشان می‌دهد که به کمک داده‌های فراطیفی، روش جنگل تصادفی بهینه‌شده با الگوریتم شاهین هریس می‌تواند وقوع بیماری را تنها پس از گذشت شش روز از مایه‌زنی با دقت، صحت و بازیابی به ترتیب ۹۷، ۹۲، و ۹۴ درصد تشخیص دهد. به نظر می‌رسد ویژگی‌های محدودی که در این مطالعه از تصاویر استخراج شد، توانایی مناسبی در تعیین بیماری در تصاویر فراطیفی داشتند. در مطالعه (Xie et al., 2015) که بر هشت ویژگی بافتی استخراج‌شده از تصاویر فراطیفی برای دو بیماری گوجه‌فرنگی (لکه‌موجی و لکه دیررس) متمرکز بود، به دقت طبقه‌بندی حدود ۷۸ درصد دست یافتند. با این حال، آن‌ها تنها ویژگی‌های بافتی را بررسی کرده بودند و تحلیل روزانه از روند بیماری نداشتند و همچنین عملکرد تصاویر RGB و فراطیفی را با یکدیگر مقایسه نکردند. به‌طور کلی، این پژوهش نشان می‌دهد که استفاده از تصاویر فراطیفی همراه با استخراج جامع ویژگی‌ها (رنگ، بافت و شکل) و استفاده از مدل جنگل تصادفی می‌تواند به طبقه‌بندی بسیار دقیق‌تر و مؤثرتری از بیماری‌های گیاهی منجر شود.

جدول ۱. معیارهای ارزیابی طبقه‌بندی بیماری لکه‌موجی با استفاده از مدل‌های مختلف یادگیری ماشین و بر پایه داده‌های تصویربرداری مرئی و فراطیفی در روزهای اول تا هجدهم پس از انتقال بیماری در گلخانه. تمام اعداد بر حسب درصد هستند.

نوع تصویر	مدل یادگیری ماشین	نوع بهینه‌سازی ماشین	معیار ارزیابی	روزهای پس از انتقال بیماری								
				دوم	چهارم	ششم	هشتم	دهم	دوازدهم	چهاردهم	شانزدهم	هجدهم
فراطیفی	شبکه عصبی مصنوعی	الگوریتم ژنتیک	دقت	۷۱	۸۰	۸۸	۹۳	۹۳	۹۴	۹۴	۹۴	۹۵
			صحت	۵۳	۸۰	۸۹	۹۱	۹۰	۹۰	۹۰	۹۱	۹۰
			بازیابی	۵۵	۸۰	۸۶	۸۶	۹۳	۹۳	۹۴	۹۴	۹۴
		الگوریتم توده نقاط	دقت	۵۱	۷۹	۸۸	۸۹	۹۰	۹۶	۹۷	۹۷	۹۸
			صحت	۵۳	۷۷	۸۵	۸۷	۸۸	۸۹	۹۴	۹۴	۹۴
			بازیابی	۶۱	۸۵	۸۷	۸۷	۸۷	۸۸	۹۵	۹۶	۹۶
		الگوریتم شاهین هریس	دقت	۶۸	۷۸	۹۰	۹۱	۹۱	۹۶	۹۶	۹۶	۹۵
			صحت	۵۴	۷۹	۸۵	۸۶	۸۹	۸۸	۸۹	۹۰	۹۴
			بازیابی	۷۳	۸۰	۸۵	۸۷	۹۱	۹۰	۹۰	۹۵	۹۵
		الگوریتم نهنگ	دقت	۶۶	۸۵	۸۷	۸۸	۸۷	۸۷	۹۰	۹۱	۹۱
			صحت	۶۸	۸۵	۸۹	۸۷	۸۸	۸۸	۹۲	۹۶	۹۶
			بازیابی	۵۸	۸۴	۸۸	۹۲	۹۳	۹۳	۹۳	۹۳	۹۳
	جنگل تصادفی	الگوریتم ژنتیک	دقت	۷۱	۸۶	۹۴	۹۴	۹۵	۹۷	۹۸	۹۸	۹۸
			صحت	۶۲	۸۶	۹۰	۹۱	۹۰	۹۴	۹۴	۹۷	۹۹
			بازیابی	۶۲	۸۳	۹۳	۹۳	۹۳	۹۵	۹۵	۹۵	۹۵
		الگوریتم توده نقاط	دقت	۵۵	۸۲	۹۳	۹۴	۹۸	۹۸	۹۷	۹۸	۹۸
			صحت	۵۸	۸۶	۹۱	۹۱	۹۴	۹۰	۹۵	۹۸	۹۷
			بازیابی	۶۳	۸۵	۹۱	۹۳	۹۳	۹۵	۹۶	۹۶	۹۶
		الگوریتم شاهین هریس	دقت	۷۲	۸۶	۹۷	۹۷	۹۸	۹۹	۹۹	۹۹	۹۹
			صحت	۶۳	۸۸	۹۲	۹۲	۹۴	۹۴	۹۷	۹۸	۹۹
			بازیابی	۷۸	۸۷	۹۴	۹۵	۹۵	۹۵	۹۶	۹۶	۹۶
		الگوریتم نهنگ	دقت	۷۱	۸۵	۹۵	۹۶	۹۶	۹۶	۹۷	۹۸	۹۸
			صحت	۷۰	۸۷	۹۲	۹۲	۹۴	۹۴	۹۵	۹۷	۹۷
			بازیابی	۶۲	۸۷	۹۴	۹۳	۹۳	۹۴	۹۶	۹۵	۹۶



جدول ۱. ادامه

نوع تصویر	مدل یادگیری ماشین	نوع بهینه سازی ماشین	معیار ارزیابی	روزهای پس از انتقال بیماری							
				دوم	چهارم	ششم	هشتم	دهم	دوازدهم	چهاردهم	شانزدهم
فراطیفی	ماشین بردار پشتیبان	الگوریتم ژنتیک	دقت	۷۰	۸۵	۹۳	۹۳	۹۴	۹۴	۹۳	۹۴
			صحت	۵۴	۸۵	۸۳	۸۳	۸۴	۸۹	۸۸	۹۴
			بازیابی	۵۷	۸۱	۹۰	۹۳	۹۲	۹۲	۹۲	۹۲
		الگوریتم توده نقاط	دقت	۵۰	۷۸	۹۱	۹۴	۹۵	۹۵	۹۵	۹۴
			صحت	۵۷	۸۶	۸۷	۹۰	۹۰	۹۰	۹۲	۹۷
			بازیابی	۵۵	۷۶	۸۵	۸۷	۸۶	۸۹	۹۲	۹۴
		الگوریتم شاهین هریس	دقت	۶۶	۷۷	۹۰	۹۰	۹۸	۹۷	۹۷	۹۷
			صحت	۶۰	۸۴	۸۳	۸۶	۸۵	۸۶	۸۹	۹۴
			بازیابی	۷۳	۸۳	۸۵	۸۸	۸۸	۹۰	۹۵	۹۵
		الگوریتم نهنگ	دقت	۶۷	۸۲	۹۰	۹۱	۹۲	۹۳	۹۵	۹۶
			صحت	۷۰	۷۸	۹۰	۹۰	۹۰	۹۰	۹۴	۹۵
			بازیابی	۶۰	۸۴	۸۵	۸۶	۸۹	۹۰	۹۴	۹۴
شبکه عصبی مصنوعی	شبکه عصبی مصنوعی	الگوریتم ژنتیک	دقت	۳۰	۳۶	۴۱	۴۱	۴۷	۴۷	۴۷	۷۵
			صحت	۴۱	۴۳	۴۱	۴۳	۵۲	۵۵	۵۶	۶۶
			بازیابی	۴۸	۴۷	۵۴	۵۶	۵۶	۵۸	۵۹	۶۸
		الگوریتم توده نقاط	دقت	۳۷	۴۵	۴۵	۴۵	۴۷	۵۰	۵۹	۷۶
			صحت	۵۴	۵۵	۵۶	۵۶	۵۷	۵۸	۵۹	۶۳
			بازیابی	۴۹	۵۱	۵۲	۵۷	۵۸	۵۷	۵۹	۶۹
		الگوریتم شاهین هریس	دقت	۲۷	۲۹	۳۱	۴۵	۴۸	۴۸	۴۷	۶۵
			صحت	۴۵	۴۵	۴۴	۴۴	۵۳	۵۵	۵۳	۵۶
			بازیابی	۴۶	۴۴	۴۷	۵۱	۵۰	۵۴	۵۵	۶۳
		الگوریتم نهنگ	دقت	۳۹	۳۸	۳۷	۴۳	۴۴	۴۴	۴۴	۶۹
			صحت	۴۴	۴۷	۵۱	۴۹	۴۹	۵۱	۵۷	۶۰
			بازیابی	۴۵	۴۶	۵۲	۵۳	۵۹	۶۴	۶۱	۶۵
RGB	جنگل تصادفی	الگوریتم ژنتیک	دقت	۳۶	۳۹	۴۴	۴۹	۴۹	۵۰	۵۰	۷۶
			صحت	۵۰	۵۰	۴۸	۵۲	۵۸	۵۸	۵۷	۶۳
			بازیابی	۵۰	۵۳	۵۸	۵۸	۶۲	۶۴	۶۵	۶۹
		الگوریتم توده نقاط	دقت	۴۳	۴۵	۴۵	۴۹	۵۰	۵۴	۵۴	۷۶
			صحت	۵۶	۵۶	۵۷	۵۷	۵۹	۶۳	۶۳	۶۷
			بازیابی	۵۵	۵۴	۵۹	۵۹	۶۵	۶۵	۶۵	۷۳
		الگوریتم شاهین هریس	دقت	۳۳	۳۱	۳۵	۴۵	۴۴	۵۰	۵۲	۶۸
			صحت	۴۵	۴۵	۴۵	۴۹	۵۴	۵۵	۵۶	۵۹
			بازیابی	۴۸	۴۸	۵۰	۵۷	۵۶	۵۹	۶۰	۶۹
		الگوریتم نهنگ	دقت	۴۱	۴۲	۴۳	۴۸	۴۸	۴۸	۵۱	۷۵
			صحت	۵۰	۵۱	۵۲	۵۳	۵۳	۵۹	۶۲	۶۶
			بازیابی	۵۳	۵۳	۵۹	۵۹	۶۵	۶۶	۷۰	۷۱
ماشین بردار پشتیبان	ماشین بردار پشتیبان	الگوریتم ژنتیک	دقت	۳۳	۳۳	۳۷	۴۲	۴۲	۴۲	۴۵	۷۵
			صحت	۴۳	۴۳	۴۵	۴۵	۵۱	۵۵	۵۳	۵۷
			بازیابی	۴۵	۴۹	۵۰	۵۰	۵۷	۵۵	۵۷	۶۳
		الگوریتم توده نقاط	دقت	۴۱	۴۰	۴۰	۴۰	۵۰	۴۸	۵۲	۶۹
			صحت	۵۶	۵۶	۵۷	۵۷	۵۸	۵۸	۵۹	۵۹
			بازیابی	۴۸	۵۰	۵۷	۵۷	۶۴	۶۵	۶۵	۶۴
		الگوریتم شاهین هریس	دقت	۳۱	۳۲	۳۵	۴۰	۳۸	۴۲	۴۷	۶۱
			صحت	۴۱	۴۴	۴۴	۴۸	۵۰	۵۲	۵۴	۵۴
			بازیابی	۴۲	۴۲	۴۷	۵۶	۵۵	۵۹	۶۰	۶۴
		الگوریتم نهنگ	دقت	۳۸	۳۸	۳۷	۴۴	۴۴	۴۵	۴۶	۷۵
			صحت	۴۳	۴۳	۴۵	۴۶	۵۲	۵۳	۶۰	۶۶
			بازیابی	۵۰	۵۰	۵۱	۵۱	۶۵	۶۶	۶۶	۷۰

ویژگی‌های بافتی و رنگی نقش مؤثری در تشخیص بیماری‌های قارچی گیاهی دارند. انرژی، آنژی، آنتری و انحراف معیار از مهم‌ترین ویژگی‌ها در فرآیند تشخیص بیماری هستند. انرژی به دلیل سنجش شدت سیگنال طیفی در فرکانس‌های مختلف، در تشخیص و طبقه‌بندی بیماری‌های گیاهی مفید است، زیرا تغییر در بافت و ساختار برگ، ساقه یا ریشه گیاه ناشی از بیماری‌ها می‌تواند باعث تغییر در توزیع انرژی داده‌های طیفی شود. مقادیر بالای انرژی معمولاً نشان‌دهنده گیاهان سالم است، در حالی که مقادیر پایین‌تر می‌تواند نشانه گیاهان بیمار یا آسیب‌دیده باشد. آنتری و نیز با سنجش میزان بی‌نظمی یا آشفتگی در داده‌های طیفی برگ، ساقه یا ریشه، در تشخیص بیماری‌های گیاهی کاربرد دارد. مقادیر بالاتر آنتری ممکن است نشان‌دهنده تنوع رنگ در گیاهان به دلیل تغییرات ناشی از بیماری باشد. انحراف معیار، با اندازه‌گیری پراکندگی داده‌ها حول مقدار میانگین، در شناسایی تغییرات طیفی مرتبط با بیماری‌ها کاربرد دارد.

مطالعه‌ای توسط (Cen et al., 2022) برای تشخیص بیماری پژمردگی باکتریایی گوجه‌فرنگی روی برگ و ساقه نشان داد که دقت تشخیص در ساقه (در حدود ۹۳ درصد) بیشتر از برگ (در حدود ۹۱ درصد) است. در مطالعات پیشین نیز از ترکیب ویژگی‌های طیفی و بافتی برای ساخت مدل‌های تشخیص بیماری استفاده شده است. ویژگی‌های رنگی مانند میانه، بیشینه و میانگین نیز در تحلیل تصاویر RGB و فرایطیفی کاربرد زیادی دارند. میانه به عنوان یک معیار مقاوم از گرایش مرکزی نسبت به میانگین، کمتر تحت تأثیر داده‌های پرت قرار می‌گیرد. در شناسایی بیماری گیاهان، میانه می‌تواند بازتاب متوسط طیفی گیاه سالم را به خوبی نشان دهد و مقادیر پایین‌تر میانه در گیاهان بیمار به خوبی تغییرات طیفی را نمایان می‌سازد. بیشینه، بیشترین مقدار بازتاب است و می‌تواند نواحی با پوشش گیاهی شدید یا متغیر را شناسایی کند. میانگین نیز می‌تواند به عنوان معیار عمومی برای تغییرات طیفی گیاهان بیمار به کار رود. تحقیقات گذشته بیشتر بر ویژگی‌های بافتی متمرکز بوده‌اند. (Pourreza et al., 2014) در بررسی بیماری‌های توت‌فرنگی از تصاویر فرایطیفی در طول موج ۵۹۱ نانومتر برای استخراج ویژگی‌های بافتی استفاده کردند، اما بر این باور بودند که استفاده از فقط یک طول موج ممکن است برخی ویژگی‌های بافتی مفید را نادیده بگیرد. بنابراین پیشنهاد کردند که تمامی طول‌موج‌ها بررسی و از الگوریتم‌های انتخاب ویژگی برای انتخاب بهترین‌ها استفاده شود. ویژگی‌های شکلی، کمتر در مطالعات تشخیص بیماری‌های گیاهی استفاده شده‌اند. با این حال، در شرایط نوری و تصویربرداری ثابت، ویژگی‌هایی مانند محیط و مساحت می‌توانند اطلاعات کیفی درباره اندازه، شکل و وسعت ناحیه آلوده در تصاویر فرایطیفی فراهم کرده و در تفکیک گیاهان سالم از بیمار کمک‌کننده باشند.

نتایج تشخیص پیشرفت بیماری به کمک تصاویر فرایطیفی و RGB

جدول ۲ عملکرد مدل‌های یادگیری ماشین در پیش‌بینی پیشرفت بیماری لکه‌موجی با استفاده از تصاویر فرایطیفی و RGB در روزهای اول تا هجدهم را نشان می‌دهد. دو معیار آماری R^2 و MSE برای سنجش عملکرد پیش‌بینی استفاده شده است. نتایج نشان می‌دهند که تصاویر فرایطیفی نسبت به تصاویر RGB عملکرد بهتری در پیش‌بینی پیشرفت بیماری داشته است. در تصاویر فرایطیفی، مدل جنگل تصادفی بهینه‌شده با الگوریتم توده نقاط توانست میزان پیشرفت بیماری را تنها پس از هشت روز از انتقال بیماری با ضریب تبیین و میانگین مربعات خطای به ترتیب ۰/۹۱ و ۰/۰۱۱ را تشخیص دهد. این در حالی است که در تصاویر RGB، مدل‌های مورد بررسی حتی پس از گذشت ۱۸ روز از انتقال بیماری به حداکثر مقدار ضریب تبیین ۰/۸۲ و میانگین مربعات خطا ۰/۰۲۴ رسیده است. یک مقایسه میان پیشرفت واقعی بیماری و مقادیر پیش‌بینی شده توسط مدل جنگل تصادفی بهینه‌شده توسط الگوریتم توده نقاط با داشتن تصاویر فرایطیفی در شکل ۵ آورده شده است. در هر روز ارزیابی، برچسب نمونه‌ها دو دسته بود: مدت زمان سپری شده از انتقال بیماری (۲، ۴، ۶، ... تا ۱۸) و صفر (برای نمونه‌های سالم). به طور کلی، اغلب مقادیر پیش‌بینی اختلاف کمی با روز صحیح پیشرفت بیماری دارند که حول یک خط با معادله $y = x$ (برای نمونه‌های بیمار) و یا یک خط با معادله $y = 0$ (برای نمونه‌های سالم) پراکنده شده‌اند. در روزهای ابتدایی، نمونه‌ها پراکندگی بیشتری از این دو خط دارند. اما مشاهده می‌شود که از روز هشتم، عملکرد مدل در پیش‌بینی شدت بیماری مناسب بوده است و با پیشرفت بیماری، این عملکرد بهبود یافته است.

در میان مدل‌های مختلف، مدل‌های بهینه‌شده با الگوریتم‌های فراابتکاری مانند نهنگ و شاهین هریس عملکرد مطلوبی داشتند. در اکثر موارد، الگوریتم توده نقاط یا الگوریتم ژنتیک عملکردی نسبتاً ضعیف‌تر از خود نشان دادند که باعث کاهش میانگین مربعات خطا شد. همچنین مشاهده می‌شود که با گذشت زمان از روز دوم تا هجدهم، دقت پیش‌بینی در اغلب مدل‌ها افزایش یافته است، که این موضوع به گسترش تدریجی علائم بیماری و واضح‌تر شدن تفاوت بین نمونه‌های سالم و بیمار مرتبط است. در مجموع، نتایج جدول ۲ نشان می‌دهند که استفاده از داده‌های طیفی و بهره‌گیری از ترکیب الگوریتم‌های یادگیری ماشین با بهینه‌سازی‌های فراابتکاری می‌تواند ابزار دقیقی برای پایش سریع و دقیق بیماری‌های گیاهی فراهم آورد. نتایج حاکی آن است که حتی در مراحل اولیه آلودگی (مثلاً از روز هشتم به بعد)،




پیش‌بینی نسبتاً دقیقی از شدت بیماری با ضریب تبیین بالاتر از ۰/۹ قابل دستیابی است که از لحاظ مدیریتی برای تصمیم‌گیری زود هنگام در کنترل بیماری بسیار ارزش خواهد بود.

جدول ۲. معیارهای ارزیابی تعیین پیشرفت بیماری لکه‌موجی با استفاده از مدل‌های مختلف یادگیری ماشین و بر پایه داده‌های تصویربرداری فراطیفی در روزهای اول تا هجدهم پس از انتقال بیماری در گلخانه

نوع تصویر	مدل یادگیری ماشین	نوع بهینه‌سازی ماشین	معیار ارزیابی	روزهای پس از انتقال بیماری								
				دوم	چهارم	ششم	هشتم	دهم	دوازدهم	چهاردهم	شانزدهم	هجدهم
فراطیفی	شبکه عصبی مصنوعی	الگوریتم ژنتیک	R ²	۰/۲۱	۰/۵۹	۰/۷۲	۰/۸۰	۰/۸۴	۰/۸۵	۰/۸۵	۰/۸۵	۰/۸۹
			MSE	۰/۰۹۸	۰/۰۵۱	۰/۰۳۵	۰/۰۲۵	۰/۰۲۰	۰/۰۱۸	۰/۰۱۸	۰/۰۱۸	۰/۰۱۳
		الگوریتم توده نقاط	R ²	۰/۲۸	۰/۷۲	۰/۷۹	۰/۸۱	۰/۸۲	۰/۸۲	۰/۸۶	۰/۸۸	۰/۸۸
			MSE	۰/۱۲۵	۰/۰۳۵	۰/۰۲۶	۰/۰۲۳	۰/۰۲۲	۰/۰۲۲	۰/۰۱۷	۰/۰۱۸	۰/۰۱۵
		الگوریتم شاهین هریس	R ²	۰/۲۳	۰/۵۹	۰/۶۷	۰/۷۹	۰/۸۵	۰/۸۵	۰/۸۴	۰/۸۲	۰/۸۴
			MSE	۰/۰۹۶	۰/۰۵۱	۰/۰۴۱	۰/۰۲۶	۰/۰۱۸	۰/۰۱۸	۰/۰۲۰	۰/۰۲۲	۰/۰۲۰
	جنگل تصادفی	الگوریتم نهنگ	R ²	۰/۳۷	۰/۷۲	۰/۷۵	۰/۸۶	۰/۸۶	۰/۸۵	۰/۸۴	۰/۸۶	۰/۸۶
			MSE	۰/۰۹۱	۰/۰۳۵	۰/۰۳۱	۰/۰۱۷	۰/۰۱۷	۰/۰۱۸	۰/۰۲۰	۰/۰۱۷	۰/۰۱۷
		الگوریتم ژنتیک	R ²	۰/۳۱	۰/۶۹	۰/۷۸	۰/۸۹	۰/۸۹	۰/۸۹	۰/۸۹	۰/۸۹	۰/۹۰
			MSE	۰/۰۸۶	۰/۰۳۸	۰/۰۲۲	۰/۰۱۳	۰/۰۱۳	۰/۰۱۳	۰/۰۱۴	۰/۰۱۲	۰/۰۱۳
		الگوریتم توده نقاط	R ²	۰/۳۶	۰/۷۵	۰/۸۳	۰/۹۱	۰/۹۱	۰/۹۱	۰/۹۲	۰/۹۲	۰/۹۳
			MSE	۰/۰۷۷	۰/۰۳۲	۰/۰۳۲	۰/۰۱۱	۰/۰۱۱	۰/۰۱۱	۰/۰۱	۰/۰۰۹	۰/۰۰۹
ماشین بردار پشتیبان	الگوریتم شاهین هریس	R ²	۰/۲۵	۰/۶۴	۰/۶۸	۰/۸۷	۰/۸۷	۰/۸۷	۰/۸۷	۰/۸۷	۰/۸۹	
		MSE	۰/۰۹۳	۰/۰۴۵	۰/۰۴۰	۰/۰۱۶	۰/۰۱۶	۰/۰۱۶	۰/۰۱۷	۰/۰۱۶	۰/۰۱۳	
	الگوریتم نهنگ	R ²	۰/۲۹	۰/۷۲	۰/۸۲	۰/۸۹	۰/۸۴	۰/۸۶	۰/۸۶	۰/۸۷	۰/۸۸	
		MSE	۰/۰۸۸	۰/۰۳۵	۰/۰۲۲	۰/۰۱۳	۰/۰۲۰	۰/۰۱۷	۰/۰۱۷	۰/۰۱۶	۰/۰۱۵	
	الگوریتم ژنتیک	R ²	۰/۲۸	۰/۵۹	۰/۷۷	۰/۸۲	۰/۸۷	۰/۸۸	۰/۸۷	۰/۸۸	۰/۸۸	
		MSE	۰/۰۹۰	۰/۰۵۱	۰/۰۲۸	۰/۰۲۶	۰/۰۱۶	۰/۰۱۵	۰/۰۱۶	۰/۰۱۶	۰/۰۱۵	
RGB	شبکه عصبی مصنوعی	الگوریتم توده نقاط	R ²	۰/۳	۰/۷۳	۰/۷۶	۰/۸۵	۰/۸۵	۰/۸۴	۰/۸۴	۰/۸۴	۰/۸۵
			MSE	۰/۰۸۷	۰/۰۳۳	۰/۰۳	۰/۰۱۸	۰/۰۱۸	۰/۰۲۰	۰/۰۲۰	۰/۰۲۰	۰/۰۱۸
		الگوریتم شاهین هریس	R ²	۰/۱۸	۰/۶۰	۰/۶۰	۰/۷۹	۰/۷۸	۰/۸۰	۰/۸۱	۰/۸۳	۰/۸۳
			MSE	۰/۱۰۸	۰/۰۵۰	۰/۰۵۰	۰/۰۲۶	۰/۰۲۷	۰/۰۲۵	۰/۰۲۳	۰/۰۲۱	۰/۰۲۱
		الگوریتم نهنگ	R ²	۰/۲۸	۰/۶۴	۰/۷۴	۰/۸۲	۰/۸۲	۰/۸۳	۰/۸۴	۰/۸۴	۰/۸۴
			MSE	۰/۰۹۰	۰/۰۴۵	۰/۰۳۲	۰/۰۲۲	۰/۰۲۲	۰/۰۲۱	۰/۰۲۰	۰/۰۲۰	۰/۰۲۰
	شبکه عصبی مصنوعی	الگوریتم ژنتیک	R ²	۰/۲۶	۰/۶۶	۰/۷۴	۰/۷۸	۰/۷۹	۰/۸۰	۰/۸۱	۰/۸۱	۰/۸۲
			MSE	۰/۰۹۲	۰/۰۴۲	۰/۰۳۲	۰/۰۲۷	۰/۰۲۶	۰/۰۲۵	۰/۰۲۳	۰/۰۲۳	۰/۰۲۶
		الگوریتم توده نقاط	R ²	۰/۳۴	۰/۷۴	۰/۷۵	۰/۷۸	۰/۷۹	۰/۸۱	۰/۸۲	۰/۸۲	۰/۸۳
			MSE	۰/۰۸۲	۰/۰۳۲	۰/۰۳۱	۰/۰۲۷	۰/۰۲۶	۰/۰۲۳	۰/۰۲۲	۰/۰۲۲	۰/۰۲۱
		الگوریتم شاهین هریس	R ²	۰/۳۴	۰/۶۳	۰/۶۵	۰/۸۲	۰/۸۲	۰/۸۳	۰/۸۱	۰/۸۲	۰/۸۵
			MSE	۰/۰۹۵	۰/۰۴۶	۰/۰۴۳	۰/۰۲۲	۰/۰۲۲	۰/۰۲۱	۰/۰۲۳	۰/۰۲۲	۰/۰۱۸
الگوریتم نهنگ	R ²	۰/۲۶	۰/۶۷	۰/۷۳	۰/۷۵	۰/۷۸	۰/۷۹	۰/۸۲	۰/۸۲	۰/۸۳		
	MSE	۰/۰۹۲	۰/۰۴۱	۰/۰۳۳	۰/۰۳۱	۰/۰۲۸	۰/۰۲۶	۰/۰۲۷	۰/۰۲۱	۰/۰۲۱		

جدول ۲. ادامه

نوع تصویر	مدل یادگیری ماشین	نوع بهینه‌سازی ماشین	معیار ارزیابی	روزهای پس از انتقال بیماری							
				دوم	چهارم	ششم	هشتم	دهم	دوازدهم	چهاردهم	شانزدهم
RGB	جنگل تصادفی	الگوریتم ژنتیک	R^2	۰/۲۱	۰/۴۳	۰/۵۶	۰/۷۴	۰/۷۴	۰/۷۷	۰/۷۸	۰/۷۸
			MSE	۰/۰۹۸	۰/۰۷۱	۰/۰۵۵	۰/۰۳۲	۰/۰۳۲	۰/۰۲۸	۰/۰۲۷	۰/۰۲۷
		الگوریتم توده نقاط	R^2	۰/۳۳	۰/۶۴	۰/۷۴	۰/۷۶	۰/۷۷	۰/۷۷	۰/۷۸	۰/۷۹
			MSE	۰/۰۸۳	۰/۰۴۵	۰/۰۳۲	۰/۰۳۰	۰/۰۲۸	۰/۰۲۸	۰/۰۲۵	۰/۰۲۶
		الگوریتم شاهین هریس	R^2	۰/۲۳	۰/۵۹	۰/۶۴	۰/۷۷	۰/۸۰	۰/۸۰	۰/۷۹	۰/۸۱
			MSE	۰/۰۹۶	۰/۰۵۱	۰/۰۴۵	۰/۰۲۸	۰/۰۲۵	۰/۰۲۵	۰/۰۲۶	۰/۰۲۳
		الگوریتم نهنگ	R^2	۰/۲۱	۰/۶۲	۰/۷۲	۰/۷۱	۰/۷۴	۰/۷۶	۰/۸۰	۰/۷۹
			MSE	۰/۰۹۸	۰/۰۴۷	۰/۰۳۵	۰/۰۳۶	۰/۰۳۲	۰/۰۳۰	۰/۰۲۵	۰/۰۲۶
	ماشین بردار پشتیبان	الگوریتم ژنتیک	R^2	۰/۲۴	۰/۶۲	۰/۷۳	۰/۷۵	۰/۷۴	۰/۷۵	۰/۷۶	۰/۷۷
			MSE	۰/۰۹۵	۰/۰۴۷	۰/۰۳۳	۰/۰۳۱	۰/۰۳۳	۰/۰۳۱	۰/۰۳۰	۰/۰۲۸
		الگوریتم توده نقاط	R^2	۰/۳۰	۰/۷۳	۰/۷۲	۰/۷۶	۰/۷۸	۰/۷۸	۰/۷۸	۰/۸۱
			MSE	۰/۰۸۷	۰/۰۳۳	۰/۰۳۵	۰/۰۳۰	۰/۰۲۷	۰/۰۲۷	۰/۰۲۷	۰/۰۲۵
		الگوریتم شاهین هریس	R^2	۰/۲۲	۰/۵۹	۰/۶۰	۰/۸۰	۰/۸۱	۰/۸۲	۰/۸۰	۰/۸۰
			MSE	۰/۰۹۷	۰/۰۵۱	۰/۰۰۵	۰/۰۲۵	۰/۰۲۳	۰/۰۲۲	۰/۰۲۵	۰/۰۲۵
		الگوریتم نهنگ	R^2	۰/۲۳	۰/۶۶	۰/۷۲	۰/۷۲	۰/۷۵	۰/۷۴	۰/۷۸	۰/۸۰
			MSE	۰/۰۹۶	۰/۰۴۲	۰/۰۳۵	۰/۰۳۵	۰/۰۳۱	۰/۰۳۲	۰/۰۲۷	۰/۰۲۵



شکل ۵. میزان پیشرفت بیماری پیش‌بینی شده با جنگل تصادفی بهینه‌شده با الگوریتم توده نقاط

تغییرات در رنگ‌دانه‌های گیاهی در طول بروز بیماری می‌تواند به دلیل کاهش فتوسنتز و تغییرات در فرآیندهای بیوشیمیایی گیاه رخ دهد. در مراحل پیشرفت بیماری، برگ‌ها ممکن است دچار نکروز شوند که باعث از بین رفتن کلروفیل و کاهش رنگ سبز برگ می‌شود (Trifunovic-Momcilov et al., 2021). رنگ‌دانه‌ها شامل ترکیبات شیمیایی مانند کلروفیل، کاروتنوئیدها و آنتوسیانین‌ها هستند که برای فتوسنتز و رنگ برگ ضروری‌اند. این رنگ‌دانه‌ها تحت تأثیر عوامل بیماری‌زا می‌توانند تغییر کرده و ویژگی‌های نوری برگ را دگرگون می‌کنند (Wang et al., 2022; Ashikhmin et al., 2023). ویژگی‌های طیفی برگ‌ها ویژگی‌های ثابتی نیستند، بلکه تحت تأثیر عواملی مانند رشد، پیری، فساد و پیشرفت بیماری تغییر می‌کنند (Anderegg et al., 2020). علی‌رغم پتانسیل بالای تصویربرداری فراطیفی برای تشخیص بیماری‌های گیاهی، پیچیدگی داده‌های فراطیفی و نیاز به روش‌های پردازش مؤثر، چالش‌های مهمی در بهره‌برداری کامل از این فناوری هستند (Reis Pereira et al., 2024). تهیه داده‌های تصویری با دقت و وضوح بالا به حسگر اجازه می‌دهد تا اطلاعات دقیقی از طیف الکترومغناطیسی ثبت کند. اما تعداد زیاد ویژگی‌ها و طول موج‌های اندازه‌گیری‌شده باعث تولید داده‌های با ابعاد بالا می‌شود که پردازش

آن‌ها برای استخراج اطلاعات مرتبط پیچیده است (Zahra et al., 2024). علاوه بر این، شباهت یا هم‌پوشانی اطلاعات در باندهای مجاور می‌تواند منجر به افزونگی داده‌ها و افزایش خطر بیش‌برازش در مدل‌های یادگیری ماشین شود (McCrine et al., 2024). برای مقابله با این چالش‌ها، روش‌های انتخاب ویژگی توسعه یافته‌اند تا ویژگی‌های طیفی متمایز و مؤثر را بدون از دست دادن اطلاعات حیاتی شناسایی کنند.

در سال‌های اخیر، استفاده از سامانه‌های بینایی طیفی مبتنی بر یادگیری ماشین برای تشخیص بیماری‌های گیاهی افزایش یافته است. این سامانه‌ها با هدف افزایش دقت تشخیص، بر مدل‌های یادگیری ماشین برای تحلیل داده‌های فراطیفی متکی هستند (Salamai et al., 2023). با این حال، پیچیدگی مدل‌ها و نیاز به روش‌های پردازشی بهینه برای تولید نتایج دقیق و قابل تفسیر، همچنان از چالش‌های اصلی در بهره‌برداری کامل از تصویربرداری فراطیفی برای مدیریت بهتر بیماری‌های گیاهی است (Gonzales-Rodriguez et al., 2024). تشخیص بیماری‌هایی با علائم مشابه یکی دیگر از چالش‌های مهم در طبقه‌بندی است. نتایج به‌دست‌آمده نشان داد که ترکیب ویژگی‌های مختلف مانند بافت، رنگ و شکل نقش اساسی در طبقه‌بندی دقیق دارند. همچنین، عدم تشخیص بیماری در روزهای ابتدایی و محدود بودن طیف رنگی دوربین‌های RGB از دیگر محدودیت‌هاست. استفاده از دوربین‌های فراطیفی به کاربران کمک می‌کند تا بیماری‌ها را در مراحل اولیه تشخیص داده و از گسترش آن‌ها در مزرعه جلوگیری کنند. یکی از چالش‌های قابل توجه در تحقیقات پیشین، کمبود مجموعه داده‌های بزرگ برای استفاده در روش‌های یادگیری عمیق مانند شبکه‌های عصبی پیچشی بوده است (Wang et al., 2019). روش‌های یادگیری عمیق معمولاً به‌عنوان روش‌های جعبه سیاه در نظر گرفته می‌شوند، به این معنا که ویژگی‌های استخراج‌شده توسط شبکه به‌طور مستقیم قابل انتخاب توسط کاربر نیستند. بنابراین، در شرایطی که مجموعه داده‌های بزرگ در دسترس نیست، استخراج دقیق و هدفمند ویژگی‌های اصلی مانند بافت، رنگ و شکل از تصاویر برگ‌های بیمار برای آموزش مدل‌های یادگیری ماشین رویکرد مؤثرتر محسوب می‌شود (Zhang et al., 2023; Javidan et al., 2023).

دوربین‌های فراطیفی به دلیل قیمت بالا و نیاز به اپراتور متخصص، در مقایسه با دوربین‌های RGB که با یک تلفن همراه نیز قابل ثبت هستند، دسترسی‌پذیری کمتری دارند. اگرچه مدل‌های مبتنی بر یادگیری ماشین در برخی کاربردها عملکرد قابل توجهی از خود نشان داده‌اند، اما همچنان برای تشخیص دقیق بیماری‌های گیاهی نیازمند داده‌های آموزشی گسترده و الگوریتم‌های دقیق هستند. همچنین، استفاده از این روش‌ها به سخت‌افزار، نرم‌افزار و تخصص فنی مناسب نیاز دارد که ممکن است برای برخی کاربران محدودکننده باشد. یکی از محدودیت‌های اصلی در استفاده از فناوری تشخیص بیماری گیاهان با پردازش تصاویر فراطیفی و RGB، مربوط به جمع‌آوری و مدیریت حجم زیادی از داده‌های باکیفیت مورد نیاز برای آموزش مدل‌های یادگیری ماشین است. با این وجود، تحلیل دیجیتال تصاویر هنوز یک حوزه نوظهور و امیدوارکننده در تشخیص و ارزیابی بیماری‌های گیاهی محسوب می‌شود و انتظار می‌رود با تحقیقات و توسعه بیشتر، دقت و کارایی آن بهبود یابد (Javidan et al., 2024).

نتیجه‌گیری

بر اساس یافته‌های حاصل از این پژوهش، بهره‌گیری از ویژگی‌های استخراج‌شده از امضای طیفی مشخصه بیماری، که پیش‌تر در مطالعات پیشین در طول موج‌های ۴۵۰، ۵۵۰، ۶۵۰ و ۹۰۰ نانومتر شناسایی شده‌اند، نقش تعیین‌کننده‌ای در تشخیص زودهنگام بیماری ایفا می‌کند. در این راستا، مدل یادگیری ماشین جنگل تصادفی، که به‌واسطه الگوریتم بهینه‌سازی شاهین هریس بهبود یافته است، توانست بیماری مورد نظر را تنها شش روز پس از انجام مایه‌زنی با سطوح بالایی از دقت، صحت و نرخ بازیابی به‌ترتیب معادل ۹۷، ۹۲ و ۹۴ درصد شناسایی کند. این نتایج نشان‌دهنده توانمندی بالای مدل در تشخیص سریع و مؤثر بیماری در مراحل اولیه بروز آن است، که می‌تواند در فرآیند تصمیم‌گیری مدیریتی و مداخلات زراعی به‌موقع نقش بسزایی ایفا کند.

همچنین، مدل مذکور در زمینه پیش‌بینی روند پیشرفت بیماری نیز عملکرد قابل توجهی از خود نشان داد؛ به‌طوری‌که در بازه زمانی هشت روز نخست پس از مایه‌زنی، ضریب تبیین معادل ۰/۹۱ و میانگین مربعات خطا برابر با ۰/۰۱۱ حاصل گردید. این ارقام حاکی از دقت بالایی الگوریتم در تخمین شدت پیشرفت بیماری در مراحل اولیه آن است. در مقایسه با داده‌های حاصل از حسگرهای فراطیفی، نتایج به‌دست‌آمده از تحلیل تصاویر مرئی به‌مراتب از دقت و کارایی کمتری برخوردار بودند، که بر اهمیت استفاده از داده‌های فراطیفی در تشخیص و پایش دقیق بیماری‌ها تأکید دارد. دقت شناسایی با تصاویر RGB حتی پس از ۱۸ روز از انتقال بیماری تنها در حدود ۷۰ درصد بود. این موضوع نشان می‌دهد که می‌توان دستگاه طیف‌سنجی دستی کم‌هزینه‌ای با استفاده از دیودهای نورافشان و فوتودیودهایی در این بازه‌ها

طراحی کرد تا داده‌های لازم برای تشخیص بیماری لکه‌موجی گوجه‌فرنگی فراهم شود. در این شرایط، از یک دستگاه قابل حمل یا مبتنی بر پهپاد می‌توان به‌جای انتقال نمونه‌ها به آزمایشگاه و استفاده از تجهیزات پرهزینه، برای تشخیص استفاده کرد. همچنین به‌جای به‌کارگیری واحد پردازش تصمیم‌گیری در لحظه مبتنی بر یادگیری ماشین در خود دستگاه (که هزینه‌ها را افزایش می‌دهد)، می‌توان داده‌های طیفی حسگر را از طریق پلتفرم اینترنت اشیا (IoT) به یک سرور مجهز به پردازنده قدرتمند منتقل و نتایج تشخیص بیماری را در زمان نزدیک به واقعی برای کاربر فراهم کرد.

منابع

عباسی، حanie، شیرزادی فر، علی‌محمد، نصیری، سیدمهدی، تقوی، محسن، نعمت‌اللهی، محمدامین. کاظمی، فاطمه و زارعی، صادق. (شهریور ۱۴۰۱). امکان سنجی کاربرد تصاویر فراطیفی برای شناسایی بیماری لکه‌باکتریایی گوجه‌فرنگی. چهاردهمین کنگره ملی مهندسی مکانیک بیوسیستم و مکانیزاسیون ایران، کرمانشاه، ایران.

REFERENCES

- Abbasi, h., Shirzadifar, A., Nassiri, S. M., Taghavi, S. M., Nematollahi, M., Kazemi, F., & Zarei, S. (2022, September). Feasibility study on application of hyperspectral imaging to identify the tomato bacterial spot disease. In *14th National Congress of Mechanical Engineering of Biosystems & Mechanization of Iran*, Kermanshah, Iran. (In persian).
- Abdulridha, J., Ampatzidis, Y., Roberts, P., & Kakarla, S. C. (2020). Detecting powdery mildew disease in squash at different stages using UAV-based hyperspectral imaging and artificial intelligence. *Biosystems Engineering*, 197, 135-148. <https://doi.org/10.1016/j.biosystemseng.2020.07.001>.
- Abdulridha, J., Ampatzidis, Y., Qureshi, J., & Roberts, P. (2022). Identification and classification of downy mildew severity stages in watermelon utilizing aerial and ground remote sensing and machine learning. *Frontiers in plant science*, 13, 791018. <https://doi.org/10.3389/fpls.2022.791018>.
- Ampatzidis, Y., De Bellis, L., & Luvisi, A. (2017). Pathology: robotic applications and management of plants and plant diseases. *Sustainability*, 9(6), 1010. <https://doi.org/10.3390/su9061010>.
- Anderegg, J., Yu, K., Aasen, H., Walter, A., Liebisch, F., & Hund, A. (2020). Spectral vegetation indices to track senescence dynamics in diverse wheat germplasm. *Frontiers in plant science*, 10. <https://doi.org/10.3389/fpls.2019.01749>.
- Ashikhmin, A., Bolshakov, M., Pashkovskiy, P., Vereshchagin, M., Khudyakova, A., Shirshikova, G., Kozhevnikova, A., Kosobryukhov, A., Kreslavski, V., Kuznetsov, V., & Allahverdiev, S. I. (2023). The adaptive role of carotenoids and anthocyanins in *Solanum lycopersicum* pigment mutants under high irradiance. *cells*, 12(21), 2569. <https://doi.org/10.3390/cells12212569>.
- Asefpour Vakilian, K., & Massah, J. (2017). A farmer-assistant robot for nitrogen fertilizing management of greenhouse crops. *Computers and Electronics Agriculture*, 139, 153-163. <https://doi.org/10.1016/j.compag.2017.05.012>.
- Asefpour Vakilian, K. (2022, December). Optimization methods can increase the durability of smart electrochemical biosensors. In *8th Iranian Conference on Signal Processing and Intelligent Systems*. Behshahr, Iran.
- Asefpour Vakilian, K. (2023, November). A smart electrochemical biosensor for arsenic detection in water. In *13th International Conference on Computer and Knowledge Engineering*. Mashhad, Iran.
- Azadshahraki, F., Sharifi, K., Jamshidi, B., Karimzadeh, R., & Naderi, H. (2022). Diagnosis of early blight disease in tomato plant based on visible/near-infrared spectroscopy and principal components analysis - artificial neural network prior to visual disease symptoms. *journal of agricultural machinery*, 12(1), 81-94. <https://doi.org/10.22067/jam.2021.67436.1001>.
- Barreto, A., Paulus, S., Varrelmann, M., & Mahlein A. K. (2020). Hyperspectral imaging of symptoms induced by *Rhizoctonia solani* in sugar beet: comparison of input data and different machine learning algorithms. *Journal of Plant Disease Protection*, 127, 441-451. <https://doi.org/10.1007/s41348-020-00344-8>.
- Cheshkova, A. F. (2022). A review of hyperspectral image analysis techniques for plant disease detection and identification. *Vavilov Journal of Genetics and Breeding*, 26(2), 202-213. <https://doi.org/10.18699/VJGB-22-25>.
- Cruz, A. C., Luvisi, A., De Bellis, L., & Ampatzidis, Y. (2017). Vision-based plant disease detection system using transfer and deep learning. In *Proceedings of ASABE Annual International Meeting*. At: Spokane, Washington, USA. <https://doi.org/10.13031/aim.201700241>.



- Gao, L., & Smith, R. T. (2015). Optical hyperspectral imaging in microscopy and spectroscopy—a review of data acquisition. *Journal of biophotonics*, 8(6), 441-56. <https://doi.org/10.1002/jbio.201400051>.
- Cen, Y., Huang, Y., Hu, S., Zhang, L., & Zhang, J. (2022). Early Detection of Bacterial Wilt in Tomato with Portable Hyperspectral Spectrometer. *Remote Sensing*, 14(12), 2882. <https://doi.org/10.3390/rs14122882>.
- Gonzalez-Rodriguez, V.E., Izquierdo-Bueno, I., Cantoral, J. M., Carbu, M., & Garrido, C. (2024). Artificial intelligence: a promising tool for application in phytopathology. *Horticulturae*, 10(3), 197. <https://doi.org/10.3390/horticulturae10030197>.
- Hariharan, J., Fuller, J., Ampatzidis, Y., Abdulridha, J., & Lerwill, A. (2019). Finite difference analysis and bivariate correlation of hyperspectral data for detecting laurel wilt disease and nutritional deficiency in avocado. *Remote Sensing*, 11(15), 1748. <https://doi.org/10.3390/rs11151748>.
- Hariharan, J., Ampatzidis, Y., Abdulridha, J., & Batuman, O. (2023). An AI-based spectral data analysis process for recognizing unique plant biomarkers and disease features. *Computers and Electronics Agriculture*, 204, 107574. <https://doi.org/10.1016/j.compag.2022.107574>.
- Hatamzadeh, S., Akbari Oghaz, N., Rahnama, K., Noori, F. (2023). Combination of a hierarchical and thermal shock process with a specific aqueous buffer: a safe, rapid and reliable DNA extraction method for plant endophytic fungi. *Biologia*, 79(10), 597–604.
- Heidari, A. A., Mirjalili, S., Faris, H., Aljarah, I., Mafarja, M., & Chen, H. (2019). Harris hawks optimization: Algorithm and applications. *Future generation computer systems*, 97, 849-872. <https://doi.org/10.1016/j.future.2019.02.028>.
- Javidan, S. M., Banakar, A., Asefpour Vakilian, K., & Ampatzidis, Y. (2022, December). A feature selection method using slime mould optimization algorithm in order to diagnose plant leaf diseases, in: *The 8th Iranian Conference on Signal Processing and Intelligent Systems (ICSPIS)*. <https://doi.org/10.1109/ICSPIS56952.2022.10043928>.
- Javidan, S. M., Banakar, A., Asefpour Vakilian, K., & Ampatzidis, Y. (2023). Diagnosis of grape leaf diseases using automatic K-means clustering and machine learning. *Smart Agricultural Technology*, 3, 100081. <https://doi.org/10.1016/j.atech.2022.100081>.
- Javidan, S. M., Banakar, A., Asefpour Vakilian, K., Ampatzidis, Y., & Rahnama, K. (2024). Early detection and spectral signature identification of tomato fungal diseases (*Alternaria alternata*, *Alternaria solani*, *Botrytis cinerea*, and *Fusarium oxysporum*) by RGB and hyperspectral image analysis and machine learning. *Heliyon*, 10(19). <https://doi.org/10.1016/j.heliyon.2024.e38017>.
- Katoch, S., Chauhan, S. S., & Kumar, V. (2021). A review on genetic algorithm: past, present, and future. *Multimedia tools and applications*, 80, 8091-8126. <https://doi.org/10.1007/s11042-020-10139-6>.
- Li, Z., & Asefpour Vakilian, K. (2025). Detecting the type and severity of mineral nutrient deficiency in rice plants based on an intelligent microRNA biosensing platform. *Sensors*, 25(16), 5189. <https://doi.org/10.3390/s25165189>.
- Luvisi, A., Ampatzidis, Y., & De Bellis, L. (2016). Plant pathology and information technology: opportunity for management of disease outbreak and applications in regulation frameworks. *Sustainability*, 8(8), 831. <https://doi.org/10.3390/su8080831>.
- McCraine, D., Samiappan, S., Kohler, L., Sullivan, T., & Will, D. J. (2024). Automated hyperspectral feature selection and classification of wildlife using uncrewed aerial vehicles. *Remote Sensing*, 16(2), 406. <https://doi.org/10.3390/rs16020406>.
- Mahlein A. K., Alisaac E., Masri A. A., Behmann J., Dehne H. W., & Oerke E. C. (2019). Comparison and combination of thermal, fluorescence, and hyperspectral imaging for monitoring *Fusarium* head blight of wheat on spikelet scale. *Sensors*, 19, 2281. <https://doi.org/10.3390/s19102281>.
- Mirjalili, S., & Lewis, A. (2016). The whale optimization algorithm. *Advances in engineering software*, 95, 51-67. <https://doi.org/10.1016/j.advengsoft.2016.01.008>.
- Moghadam, P., Ward, D., Goan, E., Jayawardena, S., Sikka, P., & Hernandez, E. (2017, November). Plant disease detection using hyperspectral imaging. *International conference on digital image computing: Techniques and applications*. Australia, Sydney.
- Mohammad Zamani, D., Javidan, S. M., Zand, M., & Rasouli, M. (2023). Detection of cucumber fruit on plant image using artificial neural network. *Journal of Agricultural Machinery*, 13(1), 27–39. <https://doi.org/10.22067/jam.2022.73827.1077>.
- Momeni, M., Jahanbakhshi, A., Neshat, A. A., Hadipour-Rokni, R., Zhang, Y. D., & Ampatzidis, Y. (2022). Detection of citrus black spot disease and ripeness level in orange fruit using learning-to-augment incorporated deep networks. *Ecological Informatics*, 71, 101829.

- <https://doi.org/10.1016/j.ecoinf.2022.101829>.
- Pan, T. T., Chyngyz, E., Sun, D. W., Paliwal, J., & Pu, H. (2019). Pathogenetic process monitoring and early detection of pear black spot disease caused by *Alternaria alternata* using hyperspectral imaging. *Postharvest Biology and Technology*, 154, 96-104. <https://doi.org/10.1016/j.postharvbio.2019.04.005>.
- Pannakkong, W., Thiwa-Anont, K., Singthong, K., Parthanadee, P., & Buddhakulsomsiri, J. (2022). Hyperparameter tuning of machine learning algorithms using response surface methodology: A Case Study of ANN, SVM, and DBN. *Mathematical Problems in Engineering*, 2022, Article ID 8513719.
- Pourreza, A., W.S. Lee, W.S., Ehsani, E.R., & Etxeberria, E. (2014). Citrus huanglongbing detection using narrow-band imaging and polarized illumination, in: In Transactions of the ASABE. *American Society of Agricultural and Biological Engineers (ASABE)*, 259–272. <https://doi.org/10.13031/trans.57.10147>.
- Prasad, V., & Upadhyay, R. (2010). *Alternaria alternata* f.sp. lycopersici and its toxin trigger production of H₂O₂ and ethylene in tomato. *Journal of plant pathology*, 92(1). <https://doi.org/10.4454/jpp.v92i1.19>.
- Reis Pereira, M., Verrelst, J., Tosin, R., Rivera Caicedo, J. P., Tavares, F., Neves dos Santos, F., & Cunha, M. (2024). Plant disease diagnosis based on hyperspectral sensing: comparative analysis of parametric spectral vegetation indices and nonparametric Gaussian process classification approaches. *Agronomy*, 14(3), 493. <https://doi.org/10.3390/agronomy14030493>.
- Salamai, A. A., Ajabnoor, N., Khalid, W. E., Ali, M. M., & Murayr, A. A. (2023). Lesion-aware visual transformer network for Paddy diseases detection in precision agriculture. *European journal of agronomy*, 148, 126884. <https://doi.org/10.1016/j.eja.2023.126884>.
- Samadi, S. M., Asefpour Vakilian, K., & Javidan, S. M. (2025). Combining miRNA concentrations and optimized machine-learning techniques: An effort for the tomato storage quality assessment in the agriculture 4.0 framework. *Journal of Agriculture and Food Research*, 19, 101605. <https://doi.org/10.1016/j.jafr.2024.101605>.
- Schratz, P., Muenchow, J., Iturritxa, E., Richter, J., & Brenning, A. (2019). Hyperparameter tuning and performance assessment of statistical and machine-learning algorithms using spatial data. *Ecological Modelling*, 406, 109–120. <https://doi.org/10.1016/j.ecolmodel.2019.06.002>.
- Trifunovic-Momcilov, M., Milosevic, S., Markovic, M., Đuric, M., Jevremovic, S., Dragicevic, I.C., & Subotic, A. R. (2021). Changes in photosynthetic pigments content in non-transformed and AtCKX transgenic centaury (*Centaurea erythraea* Rafn) shoots grown under salt stress in vitro. *Agronomy*, 11(10), 2056. <https://doi.org/10.3390/agronomy11102056>.
- Wang, W., Li, C., Tollner, E. W., Gitaitis, R. D., & Rains, G. C. (2012). Shortwave infrared hyperspectral imaging for detecting sour skin (*Burkholderia cepacia*)-infected onions. *Journal of Food Engineering*, 109(1), 38-48. <https://doi.org/10.1016/j.jfoodeng.2011.10.001>.
- Wang, D., Tan, D., & Liu, L. (2018). Particle swarm optimization algorithm: an overview. *Soft computing*, 22(2), 387-408. <https://doi.org/10.1007/s00500-016-2474-6>.
- Wang, D., R. Vinson, R., Holmes, M., Seibel, G., Bechar, A., Nof, S., & Tao, Y. (2019). Early detection of tomato spotted wilt virus by hyperspectral imaging and outlier removal auxiliary classifier generative adversarial nets (OR-AC-GAN). *Scientific Reports*, 9(1). <https://doi.org/10.1038/s41598-019-40066-y>.
- Wang, Y. M., Ostendorf, B., Gautam, D., Habili, N., & Pagay, V. (2022). Plant viral disease detection: from molecular diagnosis to optical sensing technology a multidisciplinary review. *Remote Sensing*, 14(7), 1542. <https://doi.org/10.3390/rs14071542>.
- Xie, C., Shao, Y., Li, X., & He, Y. (2015). Detection of early blight and late blight diseases on tomato leaves using hyperspectral imaging. *Scientific Reports*, 5, 16564. <https://doi.org/10.1038/srep16564>.
- Xuan, G., Gao, Ch., & Shao, Y. (2022). Spectral and image analysis of hyperspectral data for internal and external quality assessment of peach fruit, *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 272, 121016. <https://doi.org/10.1016/j.saa.2022.121016>.
- Yuan, P., Yan, W., Han, Y., Huang, B., Wang, J., Zhang, H., & Zhang, Z. (2019). Detection of anthracnose in tea plants based on hyperspectral imaging. *Computers and Electronics Agriculture*, 167, 105039. <https://doi.org/10.1016/j.compag.2019.105039>.
- Zahra, A., Qureshi, R., Sajjad, M., Sadak, F., Nawaz, M., Khan, H A., & Uzair, M. (2024). Current advances in imaging spectroscopy and its state-of-the-art applications. *Expert Systems with Applications*, 238, 122172. <https://doi.org/10.1016/j.eswa.2023.122172>.
- Zhang, X., Wang, Y., Zhou, Z., Zhang, Y., & Wang, X. (2023). Detection method for tomato leaf mildew based on hyperspectral fusion terahertz technology. *Foods*, 12(3), 535. <https://doi.org/10.3390/foods12030535>.