



Original Article

A Novel AI-Based Machine Vision Approach for Detecting Thrips Damage Symptoms on Cucumber Leaves

Hossein Akhtari¹, Hossein Navid^{1*}, Roghaiyeh Karimzadeh², Nayer Etminanfar¹

1- Department of Biosystem Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran.

2- Department of Plant Protection, Faculty of Agriculture, University of Tabriz, Tabriz, Iran .

ARTICLE INFO

EXTENDED ABSTRACT

Keywords:

Cucumber Thrips,
Deep Learning,
Machine Vision,
Smart Agriculture,
Artificial Intelligence in
Agriculture

Introduction

The integration of artificial intelligence and machine vision into agriculture has opened new horizons for the early detection of pests and plant diseases. These technologies are particularly valuable in greenhouse environments, where rapid intervention is essential to minimize crop losses. Traditional approaches have predominantly relied on static image classification, which lacks the ability to capture temporal dynamics of symptoms such as progressive leaf damage. In this context, this study explores the use of video-based deep learning for the detection of thrips induced damage on cucumber leaves. By comparing the performance of two modern spatiotemporal models MovieNet and SlowFast, the research aims to identify a reliable solution for real-time, accurate detection of pest damage in greenhouse conditions.

Materials and Methods

This study aimed to investigate the effectiveness of deep learning models, particularly convolutional neural networks, in detecting thrips-infested cucumber leaves using video-based input rather than still images. To this end, a dataset of 606 images was collected from the research greenhouse of the University of Tabriz, including 274 images of healthy leaves and 332 images of thrips-infested leaves. Given the widespread presence of this pest in the greenhouse, images were captured under natural conditions from various angles and distances to enhance data diversity and improve the model's generalization to real-world scenarios. Care was also taken to ensure similar conditions when capturing images of healthy leaves to maintain class balance.

To simulate temporal dynamics and enable video-based learning, the collected images were converted into short video clips. Specifically, every four randomly selected images were combined sequentially to form one video. The frame rate was deliberately set to a low value of 3 frames per second to facilitate meaningful temporal feature extraction. After this preprocessing step and applying several offline data augmentation techniques, the final dataset comprised 909 videos, including 411 videos of healthy leaves and 498 videos of thrips-infested leaves.

For the learning task, two deep spatiotemporal architectures were employed MovieNet and SlowFast. Both models are known for their ability to capture motion and spatial patterns effectively. Prior to training, the video data were split into training (70%), validation (15%), and test (15%) sets using stratified sampling to preserve class distribution across subsets. All videos were resized and normalized according to the input requirements of the respective architectures. The models were trained with learning hyperparameters optimally tuned to ensure effective convergence and to minimize overfitting.

Received:
July 12, 2025

Revised:
February 25, 2026

Accepted:
February 25, 2026

* Corresponding author:
Navid@tabrizu.ac.ir

How to cite:

Akhtari, H. Navid, H. Karimzadeh, R. Etminanfar, N. (2025). *A Novel AI-Based Machine Vision Approach for Detecting Thrips Damage Symptoms on Cucumber Leaves*. Journal of Agricultural Mechanization, 10 (4):27-39.
<https://doi.org/10.22034/jam.2026.68067.1332>



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



Performance evaluation was conducted using common classification metrics, including accuracy, precision, recall, and F1-score, computed on the test set. Additionally, confusion matrices and training-validation loss curves were analyzed to further assess model behavior during training and generalization capability.

Results and Discussion

Training-validation loss curves highlighted key differences between the two models. In the case of MovieNet, the training and validation loss both decreased rapidly at the beginning, indicating effective learning. However, during later epochs, the validation loss diverged from the training loss, suggesting overfitting. The model achieved 100% test accuracy, but this was considered unreliable due to the relatively small test set and the model's tendency to memorize rather than generalize. Conversely, SlowFast demonstrated fluctuating loss values during the initial training phases, possibly due to its more complex architecture and optimization strategy. Despite the instability early on, both training and validation losses eventually converged, indicating improved generalization. This model achieved a final test accuracy of 99.27%, with a test loss of 0.0425, reflecting strong performance.

Detailed classwise evaluation revealed that the healthy leaf class achieved 98.41% precision and 100% recall, indicating that no healthy samples were misclassified. The thrips-damaged class recorded 100% precision and 98.67% recall, suggesting high detection accuracy with minimal false negatives. The overall F1-score, precision, and recall all exceeded 99%, confirming balanced and accurate performance across both classes.

The confusion matrix further validated these results. All 62 healthy samples were correctly classified, with zero misclassifications. Among the 75 thrips-damaged samples, 74 were correctly identified, with only one instance misclassified as healthy. This minimal error highlights the robustness of the SlowFast model in binary classification of pest damage.

Conclusion

This research demonstrates the efficacy of video-based deep learning methods for detecting thrips damage on cucumber leaves in greenhouse environments. Unlike conventional static image approaches, video enables the capture of dynamic changes and subtle visual cues over time, enhancing model accuracy and reliability.

Between the two models tested, SlowFast outperformed MovieNet, providing superior generalization and higher classification accuracy without overfitting. Its architectural design, particularly the dual-pathway temporal processing and ResNet-50 backbone, enabled it to achieve a final test accuracy of 99.27% and excellent precision-recall balance across both classes.

This video-based approach demonstrated several key advantages over traditional image-based methods, including enhanced accuracy through the capture of temporal symptom progression, reduced misclassification caused by static noise, and improved pattern recognition in dynamic real-world scenarios. These strengths highlight the potential of video-based deep learning techniques for integration into intelligent monitoring systems in modern greenhouses, offering farmers the ability to detect and respond to pest infestations more promptly and effectively.

Future work should explore multi-class detection of various pests and diseases, as well as the incorporation of attention mechanisms or transformer-based video models to further improve accuracy. Additionally, developing mobile or cloud-based platforms for model deployment could make this technology more accessible for real-world agricultural applications.

Acknowledgement

The authors would like to thank the students working in the greenhouse for their cooperation and for allowing data collection during their research activities.



رویکردی متفاوت در تشخیص علائم خسارت تریپس روی برگ خیار به کمک بینایی ماشین مبتنی بر هوش مصنوعی

حسین اختری^۱، حسین نوید^{۱*}، رقیه کریمزاده^۲، نیر اطمینان فر^۱

تاریخ دریافت: ۱۴۰۴/۰۴/۲۱ تاریخ بازنگری: ۱۴۰۴/۱۲/۰۶ تاریخ پذیرش: ۱۴۰۴/۱۲/۰۶

۱- گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران.
۲- گروه گیاهپزشکی، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران.

* نویسنده مسئول: E-mail: Navid@tabrizu.ac.ir

چکیده

خیار از جمله محصولات پرطرفداری است که نقش مهمی در سبد غذایی مردم دارد. به همین دلیل، تولید آن باید همگام با میزان تقاضای جامعه مدیریت شود. با این حال، فرایند تولید خیار با چالش‌های متعددی همراه است. یکی از چالش‌های مطرح در این حوزه، خسارات ناشی از انواع آفات و بیماری‌ها می‌باشد. شناسایی سریع و دقیق آفات و بیماری‌ها نقش مهمی در مدیریت بهینه و افزایش عملکرد محصول خواهد داشت. استفاده از فناوری‌های پیشرفته بینایی ماشین و هوش مصنوعی می‌تواند جایگزین مؤثری برای تشخیص بیماری‌ها توسط نیروی انسانی باشد. در این پژوهش، برخلاف بسیاری از تحقیقات پیشین که بر طبقه‌بندی بیماری‌ها بر اساس تصاویر ثابت متمرکز بودند، رویکردی نوین مبتنی بر پردازش ویدئو بر اساس شبکه‌های عصبی کانولوشنی (CNNs) مورد بررسی قرار گرفته است. مجموعه تصاویر برگ خیار شامل برگ‌های سالم و برگ‌هایی با علائم ناشی از آلودگی به تریپس، به عنوان یکی از آفات رایج این گیاه، بود. پس از اعمال چند تکنیک پیش پردازش بر روی تصاویر، از دو مدل مبتنی بر شبکه عصبی کانولوشنی MovieNet و SlowFast برای آموزش و ارزیابی طبقه‌بندی برگ سالم و برگ آلوده استفاده گردید. پیش پردازش شامل تکنیک‌های داده افزایی و نرمال‌سازی و چند فرآیند جهت تغذیه به مدل‌های مذکور بود. علاوه بر این، تقسیم بندی داده‌ها به زیرمجموعه‌های آموزش، اعتبارسنجی و آزمایش از دیگر عملیات مربوط به پیش پردازش داده‌ها بود. تنظیم فرآیندها و بهینه‌سازی توابع مختلف از جمله کارهایی بود که در حین آموزش مدل‌ها مورد بررسی قرار گرفت. تحلیل نتایج در مراحل آموزش و ارزیابی نشان داد که مدل SlowFast عملکرد بسیار دقیقی در شناسایی و طبقه‌بندی علائم خسارت تریپس از برگ‌های سالم دارد. این مدل با دستیابی به دقت ۹۹/۲۷ درصد روی داده‌های آزمایشی، توانست بهترین عملکرد را ارائه و در مقایسه با مدل MovieNet نتایج برتری از خود نشان دهد.

کلمات کلیدی: تریپس خیار، یادگیری عمیق، بینایی ماشین، کشاورزی هوشمند، هوش مصنوعی در کشاورزی

۱- مقدمه

توصیه می‌شود. در موارد آلودگی شدید، استفاده از حشره‌کش‌های مناسب نیز ممکن است ضروری باشد (Cloyd, 2009). با توجه به اهمیت شناسایی دقیق و زودهنگام این آفت، بهره‌گیری از فناوری‌های پیشرفته مانند بینایی ماشین و یادگیری عمیق می‌تواند در تشخیص سریع و دقیق تریپس‌ها مؤثر باشد و به مدیریت بهینه گلخانه‌های خیار کمک کند.

یک الگوریتم بینایی هوشمند بر اساس تبدیل فوریه دوبعدی (2DFT) برای شمارش آفات روی کارت‌های چسبیده توسعه داده شد. برخلاف روش‌های سنتی که به شمارش دستی آفات متکی هستند، این روش جدید، آفات به دام افتاده را به‌عنوان نویز در تصویر در نظر می‌گیرد و از 2DFT به‌عنوان یک جمع‌کننده نویز استفاده می‌کند. برای ارزیابی این روش، دو آزمایش انجام شد. در آزمایش اول، الگوهای شامل تعداد و توزیع‌های مختلف آفات شبیه‌سازی شدند و در آزمایش دوم، کارایی این روش روی آفات واقعی شامل و تریپس گل غربی و یک نوع آفت دیگر روی کارت‌های آبی چسبیده (BSTs) بررسی شد. نتایج نشان داد که روش پیشنهادی دقت بالایی در شمارش آفات دارد ($R^2=1$ در آزمایش شبیه‌سازی و $R^2 \approx 0.999$ در شمارش آفات واقعی) و مستقل از نحوه توزیع آفات روی کارت‌ها عمل می‌کند (Sun et al., 2017). در پژوهشی دیگر به بررسی یک الگوریتم شناسایی و شمارش آفات گلخانه‌ای خیار بر اساس پردازش تصویر و روش ماشین بردار پشتیبان^۵ (SVM) در حوزه یادگیری ماشین^۶ (ML) (Hearst et al., 1998) پرداخته شده است. هدف این روش، پایش تنوع و تعداد آفات گلخانه‌ای مانند سفید بالک گلخانه و تریپس روی کارت‌های چسبیده و پیش‌بینی روند رشد آن‌ها است. در این روش، تصاویر آفات با استفاده از دوربین‌های پایش خودکار گرفته شده و پس از بخش‌بندی^۷ ناحیه‌ی آفات از پس‌زمینه، ویژگی‌های رنگی و مورفولوژیکی^۸ استخراج شدند. برای بهبود تفکیک لبه‌ها، از ترکیب تصاویر باینری^۹ در فضای رنگی Lab و HSI همراه با تکنیک‌های Prewitt و Canny استفاده شد (Rahmawati et al., 2021). در مجموع، ۱۴ ویژگی شامل ۵ ویژگی مورفولوژیکی (مساحت، محیط، پیچیدگی و...) و ۹ ویژگی رنگی (مولفه‌های رنگی LAB و HSV) (Bora et al., 2015) استخراج و به‌عنوان ورودی ماشین بردار پشتیبان برای شناسایی آفات مورد استفاده قرار گرفتند. نتایج نشان داد که الگوریتم ماشین بردار پشتیبان عملکرد بهتری نسبت به شبکه عصبی پس‌انتشار^{۱۰} (BP) (Hecht-Nielsen, 1992) دارد و از بین توابع هسته^{۱۱} مختلف، هسته خطی بهترین دقت و پایداری را ارائه می‌دهد. میانگین دقت شناسایی این مدل ۹۳/۵ درصد گزارش شد، در حالی که دقت تشخیص سفیدبالک و تریپس به ترتیب ۹۶ و ۹۱ درصد

خیار از محصولات کشاورزی با ارزش اقتصادی بالا است که تأثیر قابل‌توجهی بر بهبود ساختار کشاورزی و افزایش سودآوری برای کشاورزان دارد (Yang et al., 2016). بنابراین مدیریت صحیح در تولید خیار، به‌ویژه در محیط گلخانه، از اهمیت زیادی برخوردار است. از طرفی با توجه به پیش‌بینی‌های افزایش جمعیت در سال‌های آینده (Gerland et al., 2014)، افزایش تولید محصولات صیفی از جمله خیار جزو الزامات در صنعت کشاورزی می‌باشد. آفات و بیماری‌ها از عوامل اصلی کاهش عملکرد و کیفیت محصولات کشاورزی در سطح جهان محسوب می‌شوند (Ma et al., 2018). سیستم‌های مدیریتی در کشاورزی هوشمند به خصوص در گلخانه‌ها، قادر به حل چالش‌هایی مانند شناسایی و تشخیص انواع آفات و بیماری‌ها هستند. یکی از مهم‌ترین راهکارهای مطرح در این زمینه، بهره‌گیری از یادگیری عمیق^۱ (DL) مبتنی بر هوش مصنوعی^۲ و بینایی ماشین^۳ است (Akbar et al., 2020; Escamilla-García et al., 2020). استفاده از تکنیک‌های یادگیری عمیق در مدیریت گلخانه‌ها موجب بهبود تولید و افزایش عملکرد خواهد شد.

شناسایی آفات و بیماری‌های گیاهی عمدتاً بر اساس مشاهدات بصری و تجربه کارشناسان و کشاورزان انجام می‌شود، که این امر فرآیندی زمان‌بر و خطا پذیر بود. با این حال، پیشرفت‌های چشمگیر در حوزه بینایی ماشین، به‌ویژه در زمینه یادگیری عمیق، به محققان کمک کرده است تا روش‌های کارآمدتری برای شناسایی و تشخیص آفات و بیماری‌ها توسعه دهند. پیشرفت‌های اخیر در حوزه هوش مصنوعی، افق‌های تازه‌ای را برای بهبود و تسریع فرآیند تشخیص آفات و بیماری‌های گیاهی گشوده و به افزایش بهره‌وری در کشاورزی کمک کرده است.

تریپس غربی گل (*Frankliniella occidentalis*) و تریپس پیاز (*Thrips tabaci*) از آفات رایج در گلخانه‌های خیار می‌باشند که با تغذیه از شیر گیاه، موجب ایجاد لکه‌های نقره‌ای روی برگ‌ها و میوه‌ها، تغییر شکل آن‌ها و کاهش کیفیت محصول می‌شود (Nateq et al., 2021). علاوه بر خسارات کمی، کیفی و اقتصادی (Golestan et al., 2021; Deligeorgidis et al., 2006; Shipp et al., 2000)، این آفت ناقل ویروس‌های گیاهی است که می‌تواند سلامت گیاهان را به‌شدت تهدید کند. برای کنترل و مدیریت تریپس در گلخانه‌های خیار، استفاده از روش‌های تلفیقی مانند پایش جمعیت با کارت‌های زرد و سفید چسبیده، کنترل بیولوژیکی^۴ نظیر کنه‌های شکارگر، حفظ بهداشت گلخانه و جلوگیری از ورود آفت از طریق نصب توری و کنترل تهویه

⁷ Segmentation

⁸ Morphological

⁹ Binary

¹⁰ Back Propagation

¹¹ Kernel

¹ Deep Learning

² Artificial Intelligence

³ Machine Vision

⁴ Biological Control

⁵ Support Vector Machine

⁶ Machine Learning

نسبت به روش‌های سنتی عملکرد بهتری در تشخیص بیماری‌های خیار دارند (Mia et al., 2021).

از یک معماری^۸ بر پایه شبکه عصبی کانولوشنی سبک‌وزن^۹ برای تخمین شدت بیماری‌های خیار در پس‌زمینه‌های پیچیده استفاده شد. مدل پیشنهادی، DM-BiSeNet، با استفاده از BiSeNet V2 (Yu et al., 2021) به عنوان شبکه پایه طراحی شد و برای بهبود دقت، بلوک‌های کانولوشن تفکیکی عمقی^{۱۰} در شاخه‌ی جزئیات و یک نسخه‌ی ساده‌شده از MobileNetV3 (Howard et al., 2019) در شاخه‌ی معنایی به کار گرفته شد. بهینه‌سازی^{۱۱} مدل با الگوریتم AdamW (Loshchilov & Hutter, 2017) باعث تسریع فرآیند آموزش^{۱۲} شد که در نتیجه با ضریب تبیین^{۱۳} ۹۴ درصد برتری خود را نسبت به سایر روش‌های مقایسه‌ای نشان داد. این مطالعه نشان داد که می‌توان با سفارشی‌سازی^{۱۴} و بهینه‌سازی معماری‌های موجود، آن‌ها را برای اهداف مختلف از جمله تشخیص و تخمین شدت آفات و بیماری‌ها حتی در شرایط پیچیده‌تر سازگار کرد (Li et al., 2024).

بررسی تحقیقات مختلف نشان می‌دهد که مدل‌های مبتنی بر یادگیری عمیق و ماشین به‌طور گسترده برای شناسایی آفات و بیماری‌های خیار در حوزه‌های طبقه‌بندی^{۱۵} (Hussain et al., 2022)، تشخیص^{۱۶} (Ozguven, 2020; Uoc et al., 2022) و بخش‌بندی (Lin et al., 2019; Zhang et al., 2021) به کار رفته‌اند.

با این حال، بخش عمده این مطالعات بر استفاده از تصاویر ایستا متمرکز بوده و بررسی مبتنی بر داده‌های ویدئویی در تشخیص آفات و بیماری‌های گیاهی هنوز محدود است (Pandian, J et al., 2022). در سال‌های اخیر، محدود پژوهش‌هایی به استفاده از ویدئو برای تحلیل بیماری‌ها و خسارت‌های گیاهی پرداخته‌اند. برای مثال، برخی مطالعات تشخیص آفات و بیماری‌ها را بر اساس ویدئوهای گیاه برنج انجام داده و نشان داده‌اند که اطلاعات زمانی موجود در توالی فریم‌ها می‌تواند به بهبود دقت تشخیص کمک کند (Li, D. et al, 2020). همچنین، رویکردهای نوین‌تری با استفاده از ویدئو و ردیابی زمانی برگ‌ها برای تحلیل میزان خسارت گیاهی پیشنهاد شده‌اند که بر اهمیت ترکیب اطلاعات مکانی-زمانی در تشخیص دقیق‌تر تأکید دارند (Marques, M. eta al, 2024). این مطالعات نشان می‌دهند که استفاده از ویدئو در حوزه کشاورزی هوشمند یک مسیر نوظهور و در حال توسعه است.

در این پژوهش، برخلاف روش‌های پیشین، یک رویکرد نوین برای طبقه‌بندی ویدئویی گیاهان خیار آلوده به تریپس ارائه شده است که

بود. این روش می‌تواند به‌عنوان ابزاری برای پایش خودکار آفات گلخانه‌ای، هشدارهای اولیه و اتخاذ تدابیر کنترلی به‌موقع مورد استفاده قرار گیرد (Yang et al., 2018).

با وجود تحقیقات گسترده در زمینه‌ی تشخیص آفات و بیماری‌های گیاهان صیفی، به‌ویژه خیار، و بهره‌گیری از روش‌های سنتی مانند یادگیری ماشین و پردازش تصویر^۱ (Kainat et al., 2021; Zhang et al., 2017)، این فناوری‌ها همچنان با چالش‌های متعددی روبه‌رو هستند. علی‌رغم دستیابی به نتایج قابل‌توجه در بسیاری از پژوهش‌ها، این روش‌ها معمولاً به استخراج ویژگی‌های پیچیده و تنظیم دقیق پارامترها وابسته‌اند که فرآیند پردازش را زمان‌بر و نیازمند دانش تخصصی می‌کند. علاوه بر این، در تصاویر دارای پس‌زمینه‌های شلوغ و متغیر، دقت شناسایی کاهش می‌یابد، چرا که تفکیک ناحیه‌ی آلوده از سایر بخش‌های گیاه دشوار می‌شود. همچنین، برخی از روش‌های سنتی در شرایط نوری متفاوت یا در سناریوهای خاص، نظیر مراحل اولیه‌ی آفت زدگی و یا بیماری، کارایی مطلوبی ندارند (Liu & Wang, 2020). این چالش‌ها نشان‌دهنده‌ی نیاز به توسعه‌ی روش‌های پیشرفته‌تر، نظیر مدل‌های یادگیری عمیق، برای افزایش دقت، کاهش وابستگی به مهندسی ویژگی و بهبود قابلیت تعمیم^۲ (Rohlf, 2025) در شرایط مختلف محیطی است.

با توجه به اینکه خیار به‌عنوان یک محصول کشاورزی اقتصادی و یکی از سبزیجات مهم در کشور بنگلادش شناخته می‌شود، اما بیماری‌های مختلف تأثیر منفی بر تولید آن دارند، به بررسی روش‌های مختلف برای تشخیص بیماری‌های خیار با استفاده از یادگیری ماشین سنتی و یادگیری عمیق پرداخته شده است. تشخیص زودهنگام این بیماری‌ها می‌تواند از گسترش آن‌ها جلوگیری کرده و با شناسایی دقیق نوع بیماری، خسارات محصولات را از طریق درمان‌های خاص کاهش دهد. در روش یادگیری ماشین کلاسیک، پس از جمع‌آوری تصاویر، پردازش اولیه شامل تغییر اندازه^۳، فیلترگذاری^۴ و بهبود کنتراست^۵ انجام شده و سپس ویژگی‌های مرتبط استخراج گردید. الگوریتم جنگل تصادفی^۶ (RF) (Loupe, 2014) با دقت ۸۹/۹۳ درصد بهترین عملکرد را در این روش داشته است. در روش یادگیری عمیق، مدل‌های مختلف انتقال یادگیری^۷ مانند InceptionV3 (Szegedy et al., 2016) و MobileNetV2 (Sandler et al., 2018) و VGG16 (Simonyan & Zisserman, 2014) مقایسه شدند که در این میان، MobileNetV2 با دقت ۹۳/۲۳ درصد بالاترین عملکرد را به دست آورده است. نتایج نشان می‌دهد که روش‌های مبتنی بر یادگیری عمیق،

⁹ lightweight

¹⁰ Depthwise Separable Convolution

¹¹ Optimization

¹² Train

¹³ Coefficient of determination

¹⁴ Customization

¹⁵ Classification

¹⁶ Detection

¹ Image Processing

² Generalization

³ Resize

⁴ Filtering

⁵ Contrast

⁶ Random Forests

⁷ Transfer learning

⁸ Architecture

سالام و آلوده به تریپس برقرار باشد. تصاویر با استفاده از گوشی سامسونگ^۲ S21 FE با مشخصه دوربین اصلی ۱۲ مگاپیکسلی^۳، لنز با دیافراگم^۴ $f/1.8$ و فاصله کانونی^۵ ۲۶ میلی‌متر (واپد^۶) گرفته شد.

۲-۲- پیش‌پردازش^۷ داده‌ها

هدف اصلی پیش‌پردازش داده‌ها ارتقای کیفیت و افزایش دقت مدل‌های یادگیری عمیق است (Ranganathan, 2021). در این پژوهش، فرآیند پیش‌پردازش به دو بخش اصلی تقسیم شده است که هر یک شامل تکنیک‌ها و روش‌های متفاوتی هستند. بخش نخست مربوط به مراحل پیش از آموزش بوده که در گام اول با توجه به اهمیت تنوع و حجم بالای داده‌ها در بهبود دقت مدل‌های یادگیری عمیق، از چندین تکنیک داده‌افزایی^۸ استفاده شد. این تکنیک‌ها شامل چرخش تصاویر در زوایای مختلف، قرینه‌سازی افقی و عمودی، تغییرات جزئی در روشنایی و کنتراست، و برش تصادفی نواحی مختلف برگ‌ها بودند که با هدف افزایش تنوع فضایی و نوری داده‌ها اعمال شدند. این روش موجب افزایش تعداد تصاویر برگ‌های سالم و برگ‌های آلوده به تریپس به ۱۶۴۴ و ۱۹۹۲ نمونه شد. شکل ۱ نمونه‌هایی از تصاویر برگ خیار در کلاس‌های سالم و آلوده به تریپس را پس از اعمال تکنیک‌های مختلف داده‌افزایی نمایش می‌دهد که تنوع ایجاد شده در الگوهای ظاهری و ساختار بافت برگ‌ها را نشان می‌دهد. رویکرد این پژوهش بررسی عملکرد مدل‌های مبتنی بر یادگیری عمیق، به‌ویژه شبکه‌های عصبی کانولوشنی، در تشخیص آلودگی برگ خیار به تریپس از روی ویدئو بود. به‌منظور ایجاد توالی‌های ویدئویی، از میان فریم‌های متوالی ثبت‌شده، چهار فریم با حفظ ترتیب زمانی انتخاب شدند. انتخاب فریم‌ها به‌صورت تصادفی اما درون یک بازه زمانی پیوسته انجام گرفت تا ضمن جلوگیری از سوگیری داده‌ها، پیوستگی زمانی میان فریم‌ها حفظ شود. برای تسهیل فرآیند استخراج ویژگی‌ها در ویدئوها، نرخ فریم بر ثانیه روی مقدار پایین و برابر با ۳ تنظیم گردید تا مدل بر تغییرات تدریجی بافت و الگوهای ناشی از خسارت تریپس تمرکز کند. مجموعه داده نهایی شامل ۴۱۱ ویدئو از برگ‌های سالم و ۴۹۸ ویدئو از برگ‌های آلوده به تریپس بود. در مرحله پایانی بخش اول پیش‌پردازش، داده‌های ویدئویی به نسبت‌های ۷۰ درصد برای آموزش، ۱۵ درصد برای اعتبارسنجی^۹ و ۱۵ درصد برای آزمایش^{۱۰} تقسیم‌بندی شدند.

در بخش دوم پیش‌پردازش که هم‌زمان با شروع فرآیند آموزش انجام شد، چندین عملیات پردازشی بر روی داده‌ها صورت گرفت. از جمله این موارد می‌توان به نرمال‌سازی^{۱۱} داده‌ها، تنظیم قالب تصاویر برای ورود به مدل‌های یادگیری عمیق، و تبدیل آن‌ها به قالب‌های

از شبکه‌های عصبی کانولوشنی^۱ بهره می‌برد (O'shea & Nash, 2025; Liu, J. et al, 2015). در این چارچوب، ویدئوها به‌صورت توالی فریم‌های پیوسته به مدل‌ها وارد شده و اطلاعات زمانی میان فریم‌ها به‌صورت ضمنی در فرآیند یادگیری لحاظ شده است. به‌ویژه، در معماری SlowFast، مسیر Fast با نرخ نمونه‌برداری بالاتر مسئول استخراج تغییرات سریع زمانی و مسیر Slow مسئول یادگیری ویژگی‌های مکانی پایدار بوده که ترکیب آن‌ها امکان مدل‌سازی هم‌زمان اطلاعات مکانی-زمانی را فراهم می‌کند. این روش امکان پایش لحظه‌ای گیاهان در گلخانه‌های هوشمند حتی به صورت زمان واقعی را فراهم کرده و می‌تواند در ربات‌های گلخانه‌ای به کار گرفته شود تا با تحلیل پیوسته‌ی تغییرات در ویدئوها، دقت تشخیص آفات و بیماری‌ها افزایش یابد و مداخلات کشاورزی بهینه‌تر صورت گیرد. بر این اساس، پس از جمع‌آوری تصاویر دو شبکه نوین MovieNet (Huang et al., 2020) (Mobile Video Network) و SlowFast (Feichtenhofer et al., 2019) مورد آموزش، ارزیابی و تحلیل قرار گرفتند. جمع‌آوری داده‌ها نقش اساسی و حیاتی در فرآیند آموزش و ارزیابی مدل‌های یادگیری عمیق ایفا می‌کند. موفقیت یک مدل به شدت وابسته به کیفیت و کمیت داده‌های ورودی آن است. هرچه مجموعه داده از لحاظ حجم و تنوع غنی‌تر باشد، مدل توانایی بیشتری در یادگیری الگوهای پیچیده خواهد داشت. این امر نه‌تنها موجب افزایش دقت مدل می‌شود، بلکه باعث می‌شود عملکرد آن در شرایط جدید و داده‌های ناشناخته نیز بهبود یابد و تعمیم‌پذیری بالاتری داشته باشد. بنابراین، تأمین داده‌های متنوع و باکیفیت، یکی از مهم‌ترین گام‌ها در توسعه مدل‌های یادگیری عمیق به شمار می‌آید که در این تحقیق مورد توجه قرار گرفت (Guo et al., 2020).

۲- مواد و روش‌ها

۲-۱- جمع‌آوری داده

مجموعه داده‌ی مورد استفاده شامل ۶۰۶ تصویر از برگ‌های سالم و برگ‌های آلوده به تریپس بود که از گلخانه‌ی دانشگاه تبریز جمع‌آوری شدند. در این مجموعه، ۲۷۴ تصویر مربوط به برگ‌های سالم و ۳۳۲ تصویر متعلق به برگ‌های آلوده به تریپس بودند. با توجه به شیوع بالای این آفت در گلخانه‌ی مذکور، سعی بر آن شد تصویربرداری در شرایط طبیعی و در زوایا و فواصل مختلف انجام شود تا تنوع داده‌ها افزایش یافته و مدل بتواند الگوهای آفت زده را با دقت بیشتری شناسایی کند. لازم به ذکر است برای تصاویر با برگ‌های سالم نیز این شرایط حتی الامکان رعایت شد تا توازن دو کلاس برگ

⁷ Preprocessing

⁸ Augmentation

⁹ Validation

¹⁰ Test

¹¹ Normalization

¹ Convolutional Neural Networks

² Samsung

³ Megapixel

⁴ Diaphragm

⁵ Focal length

⁶ Wide

باشد. در این تحقیق، از مدل MovieNet-A0-Base برای آموزش در راستای طبقه‌بندی تریپس و برگ‌های سالم خیار استفاده شده است. این شبکه می‌تواند با دریافت ورودی‌های ویدئویی از برگ‌های خیار، ویژگی‌های مکانی و زمانی را تحلیل کرده و برگ‌های آلوده به تریپس را از برگ‌های سالم متمایز کند. بهره‌گیری از این شبکه باعث افزایش دقت تشخیص شده و امکان پردازش سریع ویدئوها را نیز فراهم کرده است.

علاوه بر این، از یک شبکه دیگر تحت عنوان SlowFast نیز برای آموزش و ارزیابی طبقه‌بندی برگ خیار استفاده گردید. این معماری با بهره‌گیری از دو مسیر مجزا، پردازش بهینه‌ای از ویژگی‌های مکانی و زمانی ارائه می‌دهد. مسیر آهسته^۴ با نرخ فریم پایین، اطلاعات ساختاری و جزئیات مکانی را استخراج کرده، در حالی که مسیر سریع^۵ با نرخ فریم بالا، تغییرات زمانی کوتاه مدت را ثبت می‌کند. ترکیب این دو مسیر باعث بهبود درک دینامیک‌های ویدئویی شده و موجب افزایش دقت در شناسایی تریپس بر اساس توالی‌های ویدئویی برگ‌های خیار می‌شود. شبکه عصبی کانولوشنی رزنت ۵۰ لایه (He et al., 2016) به‌عنوان بخش استخراج ویژگی در مدل SlowFast مورد استفاده قرار گرفت. این ترکیب به شبکه امکان می‌دهد که ویژگی‌های مذکور را به‌صورت بهینه از داده‌های ویدئویی استخراج کند. رزنت ۵۰ لایه در هر دو مسیر آهسته و سریع به‌کار گرفته می‌شود تا اطلاعات سطح بالا از برگ‌های خیار را برای تشخیص برگ‌های آلوده به تریپس و برگ‌های سالم استخراج کند.

پس از پیکربندی^۶ مدل‌های ذکر شده، مراحل سفارشی‌سازی هر دو مدل به‌طور دقیق و متناسب با نیازهای خاص مسئله انجام شد. این فرآیند شامل تنظیم و اصلاح معماری مدل‌ها، انتخاب ساختارهای مناسب برای لایه‌های شبکه و بهینه‌سازی عملکرد آن‌ها بر اساس نوع داده‌ها و اهداف تحقیق بود. پس از آن، با استفاده از آزمون و خطاهای مکرر، فرآیند بهینه‌سازی^۷ مهم مدل‌ها بهینه‌سازی گردید. این فرآیند شامل دسته‌بندی تصاویر ورودی^۸، دوره‌های آموزش^۹، نرخ یادگیری^{۱۰} و ... می‌باشند. این مراحل به‌طور مداوم و با ارزیابی دقیق مدل در هر مرحله، باعث بهبود دقت پیش‌بینی‌ها و کاهش خطای مدل شد و در نهایت سبب بهینه عملکرد مدل برای شناسایی برگ‌های سالم و آلوده گردید.

۲-۴-۲- ارزیابی مدل‌ها

مهم‌ترین و نهایی‌ترین گام در فرآیند پروژه‌های مربوط به یادگیری عمیق، ارزیابی مدل آموزش‌دیده با استفاده از داده‌های آزمایشی است. در این مرحله، قابلیت مدل برای پیش‌بینی و تشخیص دقیق داده‌های جدید بررسی می‌شود تا مشخص شود آیا مدل توانایی عمومی‌سازی و

استاندارد مناسب اشاره کرد. این فرآیندها به منظور بهبود کیفیت داده‌های ورودی و افزایش دقت مدل در شناسایی آلودگی برگ خیار اجرا شدند.



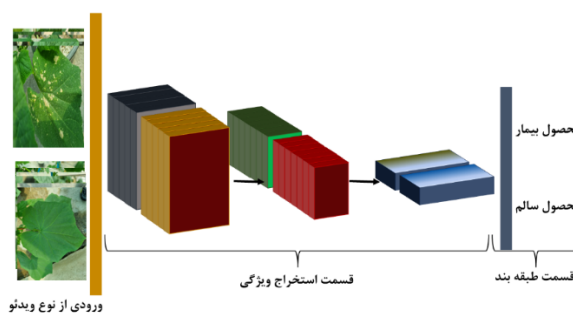
شکل ۱- نمونه ای از تصاویر مجموعه داده پس از اعمال

تکنیک‌های داده‌افزایی

Fig 1. Example of dataset images after applying data augmentation techniques

۲-۳- مدل

ارائه یک مدل مناسب و همسو با هدف تحقیق، یکی از مراحل کلیدی در پژوهش‌های مبتنی بر یادگیری عمیق است. از این‌رو، در این تحقیق مدل‌هایی مورد بررسی قرار گرفتند که قابلیت تحلیل و استخراج ویژگی‌ها از داده‌های ویدئویی را داشته باشند. به بیان دیگر، مدل پیشنهادی باید قادر باشد تنسورهای سه‌بعدی^۱ را پردازش کرده و وزن‌های خود را در حین آموزش به‌روزرسانی کند. در شکل ۲ طرحواره کلی مربوط به طبقه‌بندی با ویدئو نشان داده شده است.



شکل ۲- طرحواره کلی مربوط به فرآیند طبقه‌بندی ویدئویی

Fig 2. General schema related to the video classification process

معماری‌های مبتنی بر پایه شبکه MovieNet مدل‌های پیشرفته برای پردازش ویدئو هستند که به‌طور خاص برای طبقه‌بندی ویدئویی بلادرنگ^۲ طراحی شده‌اند. شبکه MovieNet با استفاده از معماری سه‌بعدی کانولوشنی (3D CNNs) (Li et al., 2020) و توجه زمانی^۳ قادر است ویژگی‌های مهم را از دنباله‌های ویدئویی استخراج کند و در عین حال، سبک و بهینه برای پردازش روی دستگاه‌های کم‌مصرف

⁶ Configuration

⁷ Hyperparameters

⁸ Batch-size

⁹ Epochs

¹⁰ Learning rate

¹ 3D Tensors

² Real-time

³ Temporal Attention

⁴ Slow Path

⁵ Fast Path

آموزش ارزیابی شد. نمودارهای ارائه شده در شکل ۳، روند آموزش و اعتبارسنجی دو شبکه مورد بررسی را نمایش می دهند.

نمودار سمت چپ روند کاهش اتلاف^۲ در طول دوره های آموزش و اعتبارسنجی شبکه MovieNet را نشان می دهد. در مراحل ابتدایی، مقدار اتلاف برای هر دو مجموعه داده بالا است، اما با افزایش تعداد دوره ها کاهش می یابد. با این حال، در دوره های پایانی، اختلاف بین منحنی های آموزش و اعتبارسنجی افزایش یافته که نشان دهنده وقوع بیش برآزش^۳ در این مدل است. بررسی نتایج آزمایشی نیز تأیید می کند که MovieNet دقت کلی ۱۰۰ درصد روی داده های تست نشان داده است، که این مقدار، به ویژه با توجه به اندازه نسبتاً کوچک مجموعه تست، می تواند نشانه ای از حفظ^۴ داده های آموزشی به جای یادگیری تعمیم پذیر باشد. بنابراین، این مدل احتمالاً در مواجهه با داده های جدید عملکرد ضعیف تری خواهد داشت.

در مقابل، نمودار سمت راست مربوط به روند کاهش اتلاف در شبکه SlowFast است. برخلاف MovieNet، در این مدل مقدار اتلاف در طول آموزش و اعتبارسنجی دارای نوسانات بیشتری است، اما در دوره های پایانی، دو منحنی به یکدیگر نزدیک شده و همگرا می شوند. این همگرایی نشان می دهد که مدل توانسته است تعمیم بهتری روی داده های اعتبارسنجی داشته باشد و دچار بیش برآزش نشده است. نوسانات مشاهده شده در مراحل ابتدایی و میانی آموزش را می توان به ماهیت معماری دو مسیری SlowFast نسبت داد که به صورت هم زمان اطلاعات مکانی و زمانی را از توالی فریم های ویدئویی استخراج می کند. این ویژگی باعث می شود فرآیند بهینه سازی در مقایسه با مدل های تک مسیره حساس تر بوده و تغییرات بیشتری در مقدار اتلاف ایجاد شود.

علاوه بر این، استفاده از داده های ویدئویی به جای تصاویر ایستا و تنوع حرکتی موجود در توالی فریم ها، می تواند منجر به نوسانات طبیعی در منحنی اتلاف شود. با این حال، کاهش تدریجی دامنه نوسانات و همگرایی نهایی منحنی های آموزش و اعتبارسنجی نشان می دهد که فرآیند یادگیری به درستی انجام شده و مدل به یک حالت پایدار رسیده است.

استفاده از آموخته های قبلی را برای تحلیل نمونه های ناشناخته دارد یا خیر. این ارزیابی کمک می کند تا کارایی واقعی مدل در شرایط واقعی و در مواجهه با داده هایی که در طول فرآیند آموزش مشاهده نشده اند، مورد سنجش قرار گیرد.

هدف این تحقیق تشخیص و طبقه بندی برگ آلوده به تریپس و برگ سالم در محصول خیار به کمک ویدئو بود. بنابراین از چند معیار^۱ ارزیابی مهم و مطرح در این حوزه استفاده شد. معیارهایی مانند Precision، Recall و F1 Score معمولاً برای ارزیابی عملکرد مدل های طبقه بندی به کار می روند. در این تحقیق نیز از این معیارها برای سنجش دقت و کارایی شبکه های آموزش دیده استفاده شده است. علاوه بر این، برخی از معیارهای ارزیابی در حین آموزش، برای داده های آموزشی و اعتبارسنجی نیز مورد بررسی قرار گرفته اند. فرمول های مربوط به دو معیار اصلی Precision و Recall به ترتیب در رابطه (۱) و (۲) ارائه شده است.

$$\text{Precision} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positives}} \quad (1)$$

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}} \quad (2)$$

TP (True Positive) تعداد برگ های آلوده است که مدل به درستی به عنوان برگ آلوده شناسایی کرده است. FP (False Positive) به برگ های سالمی اشاره دارد که مدل به اشتباه به عنوان برگ آلوده تشخیص داده است. همچنین، FN (False Negative) نشان دهنده برگ های آفت زده است که مدل نتوانسته آن ها را شناسایی کند و به اشتباه سالم در نظر گرفته است. حالت معکوس این شرایط نیز برای برگ های سالم امکان پذیر است.

۳- نتایج و بحث

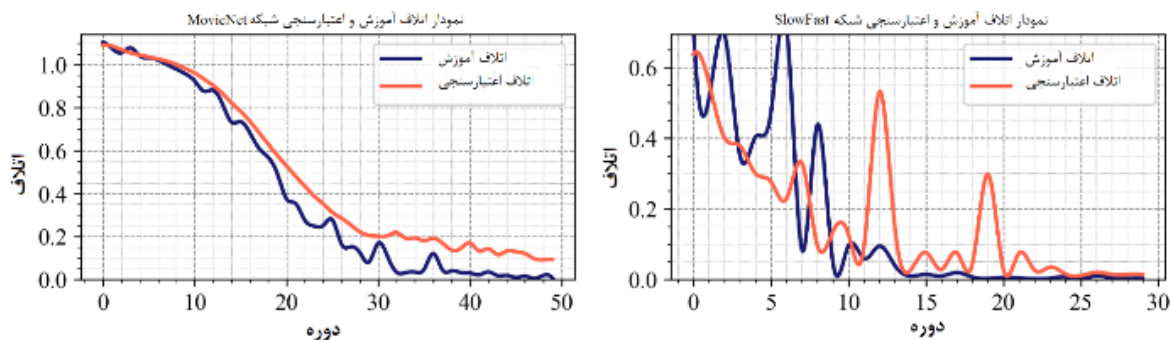
همان طور که پیش تر اشاره شد، بررسی و تحلیل نتایج را می توان به دو بخش حین آموزش و پس از آموزش تقسیم کرد. در مرحله نخست، میزان خطای داده های آموزشی و اعتبارسنجی در طول فرآیند

³ Overfitting

⁴ Memorization

¹ Criteria

² Loss



شکل ۳- روند آموزش و اعتبارسنجی دو شبکه ارائه شده

Fig 3. Training and validation process of the two presented networks

Score نیز همگی بالای ۹۹ درصد هستند، که نشان‌دهنده تعادل مناسب مدل در تشخیص صحیح نمونه‌ها بدون خطای چشمگیر است. با توجه به این نتایج و همچنین تحلیل منحنی‌های اتلاف در مراحل مختلف آموزش، مشخص شد که شبکه SlowFast برخلاف MovieNet دچار بیش‌برازش نشده و توانسته است تعمیم مناسبی روی داده‌های جدید داشته باشد. بنابراین، این شبکه می‌تواند گزینه‌ای مناسب برای استفاده در کاربردهای مرتبط با تشخیص علائم خسارت آفات گیاهی در ویدئو باشد.

بر اساس بررسی‌های انجام‌شده، شبکه SlowFast به‌عنوان مدل موفق در این مطالعه شناخته شد. این شبکه در آزمون نهایی به دقت ۹۹/۲۷ درصد دست یافت که نشان‌دهنده عملکرد قوی آن در تشخیص کلاس‌های مختلف است. همچنین، مقدار اتلاف آزمایشی برابر با ۰/۰۴۲۵ بوده که مقدار کمی است و نشان می‌دهد که مدل به‌خوبی روی داده‌های آزمایشی تعمیم یافته است. همان‌طور که در **Error!** **Reference source not found.** دارای دقت ۹۸/۴۱ درصد و بازخوانی ۱۰۰ درصد بوده است، که به معنای عدم وجود نمونه‌های از دست رفته در این کلاس است. از طرف دیگر، کلاس مربوط به آفت تریپس دقت ۱۰۰ درصد و بازخوانی ۹۸/۶۷ درصد دارد، که نشان می‌دهد مدل تقریباً تمامی نمونه‌های این کلاس را به‌درستی شناسایی کرده است. میانگین کلی دقت، بازخوانی و F1-

جدول ۱- نتایج مربوط به شبکه موفق

Table 1. Results for the successful network

معیار ارزیابی Evaluation criteria	دقت Precision	بازخوانی Recall	F1-Score	صحت Accuracy	اتلاف آزمایش Test waste
کلاس Class					
برگ سالم	98.4%	100%	99.2%	99.27%	0.0425
برگ آلوده به تریپس	100%	98.6%	99.3%		


ماتریس اغتشاش^۱ مربوط به مدل SlowFast نشان‌دهنده عملکرد مدل در تشخیص دو کلاس برگ سالم و آلوده توسط تریپس است. در این ماتریس، عدد ۶۲ نشان‌دهنده تعداد نمونه‌های صحیح طبقه‌بندی شده به عنوان برگ سالم است، در حالی که عدد صفر نشان می‌دهد هیچ نمونه‌ای از کلاس سالم به اشتباه به کلاس تریپس تعلق نگرفته است. همچنین، عدد ۱ نشان‌دهنده یک نمونه از کلاس تریپس است که به اشتباه به عنوان سالم طبقه‌بندی شده است، و عدد ۷۴ نشان‌دهنده تعداد نمونه‌های صحیح طبقه‌بندی شده به عنوان تریپس است. این ماتریس نشان می‌دهد که مدل ارائه شده در تشخیص کلاس‌ها عملکرد بسیار دقیقی داشته است (شکل ۴).

¹ Confusion Matrix

تشخیص چندین آفت و بیماری هم‌زمان را در سیستم توسعه داد تا دامنه کاربرد آن افزایش یابد. علاوه بر این، پیاده‌سازی این مدل در یک سامانه آنلاین یا اپلیکیشن موبایلی برای کشاورزان و گلخانه‌داران، می‌تواند باعث افزایش کارایی و سهولت در استفاده از این فناوری شود.

سپاس‌گزاری

نویسندگان از دانشجویانی که در گلخانه مشغول فعالیت پژوهشی بودند و در فرآیند جمع‌آوری داده‌ها همکاری کردند، صمیمانه قدردانی می‌کنند.



شکل ۴- ماتریس اغتشاش طبقه بندی برگ سالم از تریپس

Fig 4. Confusion matrix of healthy leaf classification from thrips

۴- نتیجه‌گیری نهایی

رویکردهای مبتنی بر هوش مصنوعی و بینایی ماشین، به ویژه روش‌های یادگیری عمیق، پتانسیل چشمگیری در حل چالش‌های مرتبط با کشاورزی دارند. یکی از چالش‌های مهم در این حوزه، تشخیص سریع و دقیق آفات و بیماری‌ها است. برخلاف تحقیقات پیشین که بیشتر بر تشخیص و طبقه‌بندی آفات و بیماری‌ها از طریق تصاویر ثابت تمرکز داشتند، این پژوهش از ویدئو برای بهبود دقت و عملکرد سیستم تشخیصی بهره برده است. در این راستا، دو شبکه MovieNet و SlowFast مورد بررسی قرار گرفتند که در نهایت، شبکه SlowFast با بهره‌گیری از استخراج ویژگی مبتنی بر رزنت ۵۰ لایه عملکرد قابل توجهی را ارائه داد. این مدل توانست با دقت ۹۹/۲۷ درصد، برگ‌های دارای علائم آلودگی به تریپس را از برگ‌های سالم تفکیک کند و به عنوان مدل برگزیده این تحقیق انتخاب شود.

به‌کارگیری ویدئو به‌جای تصویر در تشخیص آفات و بیماری‌ها، مزایای متعددی دارد که از جمله آن‌ها می‌توان به افزایش دقت، کاهش خطای ناشی از تصاویر ایستا، امکان تحلیل تغییرات در طول زمان و بهبود قابلیت شناسایی الگوهای پیچیده اشاره کرد. برخلاف تصاویر ایستا که تنها اطلاعات مکانی را در یک لحظه ثبت می‌کنند، داده‌های ویدئویی شامل توالی فریم‌ها هستند که امکان استخراج ویژگی‌های زمانی مانند تغییرات تدریجی بافت برگ، گسترش لکه‌ها و الگوهای پویای ناشی از فعالیت آفات را فراهم می‌سازند. همچنین، این رویکرد می‌تواند در سیستم‌های نظارتی هوشمند برای کنترل سلامت گیاهان در مقیاس وسیع، به‌ویژه در گلخانه‌های مدرن، بسیار کارآمد باشد و به کشاورزان در مدیریت بهینه محصولات کمک کند.

در ادامه تحقیقات، پیشنهاد می‌شود از روش‌های ترکیبی مانند استفاده هم‌زمان از شبکه‌های سه‌بعدی و مدل‌های مبتنی بر توجه برای بهبود دقت تشخیص بهره گرفته شود. همچنین، می‌توان قابلیت

منابع

- Hecht-Nielsen, R. (1992). *Theory of the backpropagation neural network*. In *Neural networks for perception* (pp. 65-93). Elsevier. <https://doi.org/10.1016/B978-0-12-741252-8.50010-8>
- Howard, A., Sandler, M., Chu, G., Chen, L.-C., Chen, B., Tan, M., Wang, W., Zhu, Y., Pang, R., & Vasudevan, V. (2019). *Searching for mobilenetv3*. Proceedings of the IEEE/CVF international conference on computer vision, <https://doi.org/10.48550/arXiv.1905.02244>
- Huang, Q., Xiong, Y., Rao, A., Wang, J., & Lin, D. (2020). *Movienet: A holistic dataset for movie understanding*. Computer Vision–ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part IV 16, <https://doi.org/10.48550/arXiv.2007.10937>
- Hussain, N., Khan, M. A., Tariq, U., Kadry, S., Yar, M. A. E., Mostafa, A. M., Alnuaim, A. A., & Ahmad, S. (2022). *Multiclass Cucumber Leaf Diseases Recognition Using Best Feature Selection*. Computers, Materials & Continua, 70(2). <https://doi.org/10.32604/cmc.2022.019036>
- Kainat, J., Sajid Ullah, S., Alharithi, F. S., Alroobaea, R., Hussain, S., & Nazir, S. (2021). *Blended Features Classification of Leaf-Based Cucumber Disease Using Image Processing Techniques*. Complexity, 2021(1), 9736179. <https://doi.org/10.1155/2021/9736179>
- Li, D., Wang, R., Xie, C., Liu, L., Zhang, J., Li, R., ... & Liu, W. (2020). *A recognition method for rice plant diseases and pests video detection based on deep convolutional neural network*. Sensors, 20(3), 578. <https://doi.org/10.3390/s20030578>
- Li, J., Zhang, H., Wan, W., & Sun, J. (2020). *Two-class 3D-CNN classifiers combination for video copy detection*. Multimedia Tools and Applications, 79(7), 4749-4761. <https://doi.org/10.1007/s11042-018-6047-9>
- Li, K., Song, Y., Zhu, X., & Zhang, L. (2024). *A severity estimation method for lightweight cucumber leaf disease based on DM-BiSeNet*. Information Processing in Agriculture. <https://doi.org/10.1016/j.inpa.2024.03.003>
- Lin, K., Gong, L., Huang, Y., Liu, C., & Pan, J. (2019). *Deep learning-based segmentation and quantification of cucumber powdery mildew using convolutional neural network*. Frontiers in plant science, 10, 155. <https://doi.org/10.3389/fpls.2019.00155>
- Liu, J., & Wang, X. (2020). *Tomato diseases and pests detection based on improved Yolo V3 convolutional neural network*. Frontiers in plant science, 11, 898. <https://doi.org/10.3389/fpls.2020.00898>
- Liu, J., Wang, X., Chen, Q., Yan, P., & Liu, X. (2025). *Deep learning method for cucumber disease detection in complex environments for new*
- Akbar, J. U. M., Kamarulzaman, S. F., Muzahid, A. J. M., Rahman, M. A., & Uddin, M. (2024). *A comprehensive review on deep learning assisted computer vision techniques for smart greenhouse agriculture*. IEEE Access, 12, 4485-4522. <https://doi.org/10.1109/ACCESS.2024.3349418>
- Bora, D. J., Gupta, A. K., & Khan, F. A. (2015). *Comparing the performance of L* A* B* and HSV color spaces with respect to color image segmentation*. arXiv preprint arXiv:1506.01472. <https://doi.org/10.48550/arXiv.1506.01472>
- Cloyd, R. A. (2009). *Western flower thrips (Frankliniella occidentalis) management on ornamental crops grown in greenhouses: have we reached an impasse*. Pest Technology, 3(1), 1-9.
- Deligeorgidis, P., Ipsilandis, C., Kaltsoudas, G., Giakalis, L., Petkou, D., & Deligeorgidis, N. (2006). *The evaluation of damage caused by Frankliniella occidentalis (Pergande)(Thysanoptera: Thripidae) on cucumber grown in glass greenhouse*. <https://doi.org/10.3923/jc.2006.124.129>
- Escamilla-García, A., Soto-Zarazúa, G. M., Toledano-Ayala, M., Rivas-Araiza, E., & Gastélum-Barríos, A. (2020). *Applications of artificial neural networks in greenhouse technology and overview for smart agriculture development*. Applied Sciences, 10(11), 3835. <https://doi.org/10.3390/app10113835>
- Feichtenhofer, C., Fan, H., Malik, J., & He, K. (2019). *Slowfast networks for video recognition*. Proceedings of the IEEE/CVF international conference on computer vision, <https://doi.org/10.48550/arXiv.1812.03982>
- Gerland, P., Raftery, A. E., Ševčíková, H., Li, N., Gu, D., Spoorenberg, T., Alkema, L., Fosdick, B. K., Chunn, J., & Lalic, N. (2014). *World population stabilization unlikely this century*. science, 346(6206), 234-237. <https://doi.org/10.1126/science.1257469>
- Guo, Q., Jin, S., Li, M., Yang, Q., Xu, K., Ju, Y., Zhang, J., Xuan, J., Liu, J., & Su, Y. (2020). *Application of deep learning in ecological resource research: Theories, methods, and challenges*. Science China Earth Sciences, 63, 1457-1474. <https://doi.org/10.1007/s11430-019-9584-9>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). *Deep residual learning for image recognition*. Proceedings of the IEEE conference on computer vision and pattern recognition, <https://doi.org/10.48550/arXiv.1512.03385>
- Hearst, M. A., Dumais, S. T., Osuna, E., Platt, J., & Scholkopf, B. (1998). *Support vector machines*. IEEE Intelligent Systems and their applications, 13(4), 18-28. <https://doi.org/10.1109/5254.708428>

- Ranganathan, G. (2021). *A study to find facts behind preprocessing on deep learning algorithms*. Journal of Innovative Image Processing, 3(1), 66-74. <https://doi.org/10.36548/jiip.2021.1.006>
- Rohlf, C. (2025). *Generalization in neural networks: A broad survey*. Neurocomputing, 611, 128701. <https://doi.org/10.1016/j.neucom.2024.128701>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). *Mobilenetv2: Inverted residuals and linear bottlenecks*. Proceedings of the IEEE conference on computer vision and pattern recognition, <https://doi.org/10.48550/arXiv.1801.04381>
- Shipp, J., Wang, K., & Binns, M. (2000). *Economic injury levels for western flower thrips (Thysanoptera: Thripidae) on greenhouse cucumber*. Journal of economic entomology, 93(6), 1732-1740. <https://doi.org/10.1603/0022-0493-93.6.1732>
- Simonyan, K., & Zisserman, A. (2014). *Very deep convolutional networks for large-scale image recognition*. arXiv preprint arXiv:1409.1556. <https://doi.org/10.48550/arXiv.1409.1556>
- Sun, Y., Cheng, H., Cheng, Q., Zhou, H., Li, M., Fan, Y., Shan, G., Damerow, L., Lammers, P. S., & Jones, S. B. (2017). *A smart-vision algorithm for counting whiteflies and thrips on sticky traps using two-dimensional Fourier transform spectrum*. Biosystems Engineering, 153, 82-88. <https://doi.org/10.1016/j.biosystemseng.2016.11.001>
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). *Rethinking the inception architecture for computer vision*. Proceedings of the IEEE conference on computer vision and pattern recognition, <https://doi.org/10.48550/arXiv.1512.00567>
- Uoc, N., Duong, N., Son, L., & Thanh, B. (2022). *A novel automatic detecting system for cucumber disease based on the convolution neural network algorithm*. GMSARN Int. J, 16(3), 295-301.
- Yang, L., Huang, B., Mao, M., Yao, L., Niedermann, S., Hu, W., & Chen, Y. (2016). *Sustainability assessment of greenhouse vegetable farming practices from environmental, economic, and socio-institutional perspectives in China*. Environmental Science and Pollution Research, 23, 17287-17297. <https://doi.org/10.1007/s11356-016-6937-1>
- Yang, X., Liu, M., Xu, J., Zhao, L., Wei, S., Li, W., Chen, M., Chen, M., & Li, M. (2018). *Image segmentation and recognition algorithm of greenhouse whitefly and thrip adults for automatic monitoring device*. Transactions of the Chinese Society of Agricultural Engineering, 34(1), 164-*agricultural productivity*. BMC Plant Biology, 25(1), 888. <https://doi.org/10.1186/s12870-025-06841-y>
- Loshchilov, I., & Hutter, F. (2017). *Decoupled weight decay regularization*. arXiv preprint arXiv:1711.05101. <https://doi.org/10.48550/arXiv.1711.05101>
- Louppe, G. (2014). *Understanding random forests: From theory to practice Universite de Liege (Belgium)*. <https://doi.org/10.48550/arXiv.1407.7502>
- Ma, J., Du, K., Zheng, F., Zhang, L., Gong, Z., & Sun, Z. (2018). *A recognition method for cucumber diseases using leaf symptom images based on deep convolutional neural network*. Computers and electronics in agriculture, 154, 18-24. <https://doi.org/10.1016/j.compag.2018.08.048>
- Marques, M. J. M., Mingxin, L., Shiojiri, K. T., Hagiwara, T., Hirose, K., Shiojiri, K., & Umezu, S. (2024). *Plant Doctor: A hybrid machine learning and image segmentation software to quantify plant damage in video footage*. arXiv preprint arXiv:2407.02853. <https://doi.org/10.48550/arXiv.2407.02853>
- Mia, M. J., Maria, S. K., Taki, S. S., & Biswas, A. A. (2021). *Cucumber disease recognition using machine learning and transfer learning*. Bulletin of Electrical Engineering and Informatics, 10(6), 3432-3443. <https://doi.org/10.11591/EEI.V10I6.3096>
- Nateq Golestan, M., Shafaghi, F., & Sheikhi Gorjan, A. (2021). *Efficacy of several insecticides against western flower Thrips Frankliniella occidentalis by introducing its Two new effectiveness indices in greenhouse cucumber*. Journal of Applied Research in Plant Protection, 10(4), 17-23. <https://doi.org/10.22034/arp.2021.12905>
- O'shea, K., & Nash, R. (2015). *An introduction to convolutional neural networks*. arXiv preprint arXiv:1511.08458. <https://doi.org/10.48550/arXiv.1511.08458>
- Ozguven, M. M. (2020). *Deep learning algorithms for automatic detection and classification of mildew disease in cucumber*. Fresenius Environ Bull, 29(8), 7081-7087.
- Pandian, J. A., Kumar, V. D., Geman, O., Hnatiuc, M., Arif, M., & Kanchanadevi, K. (2022). *Plant disease detection using deep convolutional neural network*. Applied Sciences, 12(14), 6982. <https://doi.org/10.3390/app12146982>
- Rahmawati, S., Devita, R., Zain, R. H., Rianti, E., Lubis, N., & Wanto, A. (2021). *Prewitt and canny methods on inversion image edge detection: an evaluation*. Journal of Physics: Conference Series, <https://doi.org/10.1088/1742-6596/1933/1/012039>

170. <https://doi.org/10.11975/j.issn.1002-6819.2018.01.022>

Yu, C., Gao, C., Wang, J., Yu, G., Shen, C., & Sang, N. (2021). *Bisenet v2: Bilateral network with guided aggregation for real-time semantic segmentation*. International journal of computer vision, 129, 3051-3068. <https://doi.org/10.48550/arXiv.2004.02147>

Zhang, J., Rao, Y., Man, C., Jiang, Z., & Li, S. (2021). *Identification of cucumber leaf diseases using deep learning and small sample size for agricultural Internet of Things*. International Journal of Distributed Sensor Networks, 17(4), 15501477211007407. <https://doi.org/10.1177/15501477211007407>

Zhang, S., Wu, X., You, Z., & Zhang, L. (2017). *Leaf image based cucumber disease recognition using sparse representation classification*. Computers and electronics in agriculture, 134, 135-141. <https://doi.org/10.1016/j.compag.2017.01.014>