



Identifying plant diseases in several crops using image processing and deep learning-based algorithms

Sajad Sabzi¹, Raziye Pourdarbani^{2*}, Mahan Masoumzade³

¹ Department of Biosystem Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran.

² Department of Biosystem Engineering, University of Mohaghegh Ardabili, Ardabil, Iran.

³ Department of Computer Engineering, Sharif University of Technology, Tehran, Iran.

Article history	Abstract	
Submitted: 2025/10/12	Visual recognition of disease symptoms in plant leaves involves observing changes in leaf appearance that can indicate disease or plant stress. These symptoms include spots, discoloration, wilting, leaf rust, abnormal growth, and abnormal leaf drop. These symptoms can be identified and managed using advanced visual tools, such as remote sensing and drone imagery, and artificial intelligence-based algorithms. Therefore, present paper aimed to identify plant diseases in different crops using image processing and deep learning algorithms. The models including RegNet, ShuffleNet, and DenseNet were evaluated based on criteria such as accuracy, precision, recall, F1 score, and ROC and accuracy-recall curves. The overall accuracy of the RegNet model is about 96%, indicating it successfully identifies most rice and wheat diseases. The overall accuracy of the ShuffleNet model was 94.4%, a promising result, though slightly lower than that of the previous model. The highest accuracy, 97.2%, was achieved with the DenseNet model.	
Revised: 2025/11/05		
Accepted: 2025/11/25		
Published online: 2025/12/21		
Keywords: Disease, Leaf, Image Processing, Deep Learning.		
*Corresponding author email: r_pourdarbani@uma.ac.ir		
ORCID:  0000-0003-0766-8305		
		

How to cite this paper:

(2025). Identifying plant diseases in several crops using image processing and deep learning-based algorithms. 37: 47-58. <https://dx.doi.org/10.22034/jrmam.2026.14802.740> (In Persian)



Authors retain, F. the copyright and full publishing rights. Published by [Shahrekord University](https://www.shahrekord.ac.ir). This article is an open access article licensed under the [Creative Commons Attribution 4.0 International \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/)

<https://dx.doi.org/10.22034/jrmam.2026.14802.740>

EXTENDED ABSTRACT

Introduction

The life cycle of agricultural products undergoes significant changes due to diseases. Visual recognition of disease symptoms in plant leaves involves observing changes in leaf appearance that can indicate disease or plant stress. These symptoms include spots, discoloration, wilting, leaf rust, abnormal growth, and abnormal leaf drop. These symptoms can be identified and managed using advanced visual tools, such as remote sensing and drone imagery, and artificial intelligence-based algorithms.

Meshram et al. (2021) reviewed the applications of machine learning algorithms in agriculture in three phases: pre-harvest, during-harvest, and post-harvest. This review found that machine learning algorithms have achieved significant results in solving agricultural problems. Their study showed that there is a need to follow the path of machine learning with standard empirical methods. Researchers should create their own datasets and make them available on different platforms so others can use them to test and validate their models. Rahmn et al. (2025) developed a real-time leaf disease detection system for 8 plant species (potato, tomato, bell pepper, apple, corn, grape, peach, and rice) using deep learning techniques, including Inception, VGG, MobileNet, and DenseNet. Their dataset consisted of 30,945 images and 35 disease classes. The highest accuracy for disease detection was 98% for tomatoes with the Inception model, 100% for bell peppers with the MobileNet model, 100% for apples with the MobileNet model, 99% for grapes with the VGG model, 100% for peaches with the VGG model, and 98% for rice with the DenseNet model.

Material and Methods

A total of 13,324 images of diseased leaves from 5 different crops, namely, cotton, potato, sugarcane, wheat, and rice (Figure 1), with different image sizes but a total of 4.79 GB, were obtained from the Kaggle site. Table 1

shows the setup and implementation features of the proposed model training.

Proposed Models

1. ShuffleNet Model

The ShuffleNet model is a convolutional neural network architecture with a lightweight computational structure and is less complex than models such as VGG and ResNet. Its disadvantages include its possible lower performance compared to models such as EfficientNet.

2. RegNet Model

The RegNet model is another convolutional neural network architecture that is highly flexible for computer vision applications such as image classification, object recognition, and segmentation. Compared to complex architectures such as VGG, the network is simple and efficient, and offers a better balance between accuracy and computational cost.

3- DenseNet Model

Unlike standard architectures that only connect between consecutive layers, the DenseNet model connects all layers together. This means that because each layer adds new learned features to subsequent layers, the number of parameters is reduced, and the model consumes less memory.

To evaluate the efficiency of the classifiers, the criteria of precision, accuracy, recall, and F-score were extracted from the confusion matrices, the operating characteristic curve diagram, and the precision-recall diagram.

Results and Discussion

The ResNet model does not overfit; both the training and validation datasets have good accuracy, and the training and validation errors have decreased and then stabilized. This means the model has been able to train on new data effectively. In the ShuffleNet classifier, it was observed that the training accuracy increased rapidly. The validation accuracy also increased but did not reach the training accuracy, indicating mild overfit. The DenseNet model also showed an increase in accuracy, but validation accuracy fluctuated and did not reach the desired value. This model was not stable in learning new data.

In all models, most values lie on the main diagonal of the matrices, indicating that the models make correct predictions across classes. The model performs well across most classes but may be biased in some.

In all three proposed models, the lines for many classes are close to the upper right corner, indicating high precision and recall. This means that the model performs very well in recognizing most classes. Classes whose lines are not close to the upper corner may need improvement, which may be due to class similarity or data imbalance.

The overall accuracy of the RegNet model is about 96%, indicating it successfully identifies most rice and wheat diseases. The overall accuracy of the ShuffleNet model was 94.4%, a promising result, though slightly lower than that of the previous model. The highest accuracy, 97.2%, was achieved with the DenseNet model.

Conclusions

This study aimed to identify plant diseases in different crops using image processing and deep learning algorithms. The results showed that different models, including RegNet, ShuffleNet, and DenseNet, performed well at classifying plant diseases. The models were evaluated based on criteria such as accuracy, precision, recall, F1 score, and ROC and accuracy-recall curves.

- The RegNet model performed stably and showed the best balance between accuracy and recall.
- The ShuffleNet model had a slight overfit, but overall provided acceptable performance.
- The DenseNet model, despite its dense connections, had fluctuations in validation

accuracy in some cases and needs improvement.

- The ROC and accuracy-recall curves showed that the models performed very well in identifying most classes. Still, some classes need improvement, which may be due to feature similarity or data imbalance.

Finally, the results of this research confirm that the use of deep learning algorithms in plant disease identification can effectively increase agricultural productivity and be an important step towards smart agriculture.

Author Contributions

Sajad Sabzi: Conceptualization

Razyieh Pourdarbani: Writing

Mahan Masoumzade: Methodology

Data Availability Statement

"Not applicable".

Ethical Considerations

It is confirmed adherence to ethical standards, including avoidance of data fabrication, falsification, plagiarism, and misconduct.

Conflict of Interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper

Funding Statement

The author(s) received no specific funding for this research



شناسایی بیماری‌های گیاهی در چند نوع محصول با استفاده از پردازش تصویر و الگوریتم‌های مبتنی بر یادگیری عمیق

سجاد سبزی^۱، راضیه پوردربانی^{۲*} و ماهان معصوم زاده^۳

۱- گروه مهندسی بیوسیستم، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران

۲- گروه مهندسی بیوسیستم، دانشگاه محقق اردبیلی، اردبیل، ایران

۳- گروه مهندسی کامپیوتر، دانشگاه صنعتی شریف، تهران، ایران

تاریخچه مقاله	چکیده
دریافت: ۱۴۰۴/۰۷/۲۰	شناخت بصری علائم بیماری در برگ گیاهان شامل مشاهده تغییرات ظاهری است که می‌تواند نشانه‌ای از وجود بیماری یا استرس گیاه باشد. این علائم عبارت‌اند از لکه‌ها، تغییر رنگ، پژمردگی، خوردگی برگ، رشد غیرعادی و ریزش غیرطبیعی برگ. این علائم با استفاده از ابزارهای بصری پیشرفته نظیر حسگرهای سنجنش از دور و پهبادها و الگوریتم‌های مبتنی بر هوش مصنوعی، قابل شناسایی و مدیریت هستند. این مطالعه به بررسی شناسایی بیماری‌های گیاهی در محصولات مختلف با استفاده از پردازش تصویر و الگوریتم‌های یادگیری عمیق پرداخت. سه مدل مبتنی بر یادگیری عمیق با معماری RegNet، ShuffleNet و DenseNet برای طبقه‌بندی بیماری‌ها بر اساس داده‌های تصویری برگ‌های بیمار از ۵ محصول مختلف درخت، سیب زمینی، نیشکر، گندم و برنج ارزیابی شدند. نتایج نشان داد مدل RegNet عملکرد پایداری داشته و ShuffleNet با اورفیت خفیف، دقت قابل قبولی ارائه داده است. مدل DenseNet نوساناتی در دقت داشت و نیازمند بهبود است. معیارهای دقت، صحت، بازخوانی و منحنی‌های ROC و نمودار دقت-بازخوانی نشان دادند که مدل‌ها در شناسایی اکثر کلاس‌ها عملکرد خوبی دارند (نرخ شناسایی صحیح بالای ۹۷٪). چالش‌هایی مانند کمبود داده‌های متوازن و شباهت علائم بیماری‌ها نیز شناسایی شد. این تحقیق نتایج نویدبخشی را در راستای مدیریت بیماری‌های گیاهی توسط فناوری‌های نوین ارائه می‌دهد.
بازنگری: ۱۴۰۴/۰۸/۱۴	
پذیرش: ۱۴۰۴/۰۹/۰۴	
انتشار: ۱۴۰۴/۰۹/۳۰	
واژه‌های کلیدی:	
بیماری	
برگ	
پردازش تصویر	
یادگیری عمیق.	
*پست الکترونیکی نویسنده	
مسئول:	
r_pourdarbani@uma.ac.ir	
ORCID: 	
0000-0003-0766-8305	
	

نحوه استناد به این مقاله:

سبزی، س، پوردربانی، ر. و معصوم زاده، م. (۱۴۰۴). شناسایی بیماری‌های گیاهی در چند نوع محصول با استفاده از پردازش تصویر و الگوریتم‌های مبتنی بر یادگیری عمیق. نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی، ۳۷: ۴۷-۵۸. شناسه دیجیتال:

<https://dx.doi.org/10.22034/jrmam.2026.14802.740>

مقدمه

عوامل مختلفی نظیر آب و هوا، رطوبت، آبیاری، خاک، نور کافی و غیره در رشد و پرورش گیاهان دخیل می‌باشند. تغذیه گیاهان امروزه اهمیت بیشتری پیدا کرده است و عوامل زیادی در این امر تاثیرگذار هستند، از جمله عناصر معدنی موجود در خاک و آب و نور کافی و غیره (Bhardwaj, 2019).

چرخه زندگی محصولات کشاورزی به واسطه بیماری‌ها دستخوش تغییرات قابل توجهی می‌شود. از این رو، برای افزایش تولید محصولات سالم و تأمین امنیت غذایی، بهره‌گیری از فناوری‌های پیشرفته مبتنی بر هوش مصنوعی در کشاورزی، که قادر به پایش مداوم مراحل رشد گیاهان و مدیریت به موقع بیماری‌ها باشند، امری ضروری به نظر می‌رسد. فناوری‌های نوین اطلاعاتی نظیر تجزیه و تحلیل طیف‌های نوری جذبی گیاهان، سنجش از دور، و اینترنت اشیا، می‌توانند در تشخیص سریع و دقیق بیماری‌ها و اجرای برنامه‌های پیشگیرانه برای جلوگیری از شیوع آن‌ها نقش مؤثری ایفا کنند (Asghari et al, 2019).

شناخت بصری علائم بیماری در برگ گیاهان شامل مشاهده تغییرات ظاهری است که می‌تواند نشانه‌ای از وجود بیماری یا استرس گیاه باشد. این علائم عبارت‌اند از لکه‌ها (زرد-قهوهای و حلقه‌ای)، تغییر رنگ (رنگ پریدگی، قرمز یا بنفش شدن)، پژمردگی (خشکی حاشیه برگ یا کل برگ)، خوردگی برگ، رشد غیرعادی (پیچ خوردگی یا موج دار شدن) و ریزش غیرطبیعی برگ (Rahman et al, 2025). این علائم با استفاده از ابزارهای بصری پیشرفته نظیر حسگرهای سنجش از دور و پهبادها و الگوریتم‌های مبتنی بر هوش مصنوعی، قابل شناسایی و مدیریت هستند. هوش مصنوعی دیگر تنها یک ابزار تکنولوژیک نیست، بلکه به ستون فقرات کشاورزی مدرن تبدیل شده است.

کاربردهای گسترده هوش مصنوعی در کشاورزی از تشخیص بیماری‌ها گرفته تا کنترل خودکار ماشین آلات، به کشاورزان کمک می‌کند تا با صرف منابع کمتر، بهره‌وری بیشتری داشته باشند. در آینده‌ای نه چندان دور، کشاورزانی موفق خواهند بود که از این فناوری‌های نوین به خوبی بهره ببرند. هوش مصنوعی نه تنها می‌تواند بیماری‌ها را تشخیص دهد، بلکه می‌تواند شدت آن‌ها را نیز با دقت بالا ارزیابی کند (Zhang et al, 2019).

تحقیقات اخیر بر استفاده از تکنیک‌های پیشرفته پردازش تصویر و الگوریتم‌های یادگیری عمیق برای شناسایی

و دسته‌بندی بیماری‌های برگ متمرکز شده‌اند. شبکه‌های عصبی کانولوشنی به عنوان یکی از موفق‌ترین مدل‌ها برای تحلیل تصاویر، در این زمینه کاربرد گسترده‌ای دارند. این مدل‌ها قادرند با دریافت تصاویر برگ‌های آلوده، بیماری‌های مختلف را شناسایی کرده و شدت آن‌ها را ارزیابی کنند. علاوه بر این، داده‌های چندطیفی و فراطیفی نیز برای شناسایی علائم بیماری‌هایی که در مراحل اولیه ممکن است به صورت بصری قابل مشاهده نباشند، مورد استفاده قرار گرفته‌اند (Peng et al, 2022; Terentev et al, 2022). این داده‌ها می‌توانند تغییرات در ساختار و ترکیبات شیمیایی برگ را شناسایی کنند و دقت تشخیص را افزایش دهند (Rana et al, 2021).

با وجود مزایای زیاد پیاده‌سازی هوش مصنوعی برای شناسایی بیماری‌های گیاهی، اما چالش‌های مهمی نیز همراه است از جمله اینکه آموزش مدل‌های هوش مصنوعی، به مجموعه داده‌های بزرگ و متنوعی از تصاویر برگ‌های سالم و آلوده نیاز دارد. ناکافی بودن تصاویر مربوط به برخی بیماری‌ها نسبت به بقیه که می‌تواند مدل را به سمت پیش‌بینی نادرست سوق دهد. دقت مدل با تصاویر با وضوح پایین یا پس‌زمینه پیچیده می‌تواند کاهش یابد. علایم برخی بیماری‌ها شبیه هم است که باعث چالش مدل شناسایی می‌شود. مدل‌های یادگیری عمیق مانند شبکه‌های عصبی کانولوشنی نیازمند منابع محاسباتی بالا و سخت‌افزارهای قدرتمند هستند. توسعه و پیاده‌سازی سیستم‌های هوش مصنوعی در کشورهای در حال توسعه می‌تواند هزینه‌بر باشد. مدل‌های هوش مصنوعی معمولاً برای بیماری‌های شناخته‌شده آموزش داده می‌شوند و ممکن است در تشخیص بیماری‌های جدید یا نادر ناتوان باشند. جمع‌آوری تصاویر و داده‌های کشاورزی ممکن است با مسائل مربوط به حریم خصوصی و امنیت روبه‌رو شود. مدل‌های هوش مصنوعی ممکن است برای شرایط خاص آموزش داده شوند و در محیط‌های مختلف عملکرد خوبی نداشته باشند (Botero-Valencia et al, 2025).

Meshram و همکاران (۲۰۲۱) به مطالعه مروری کاربردهای الگوریتم‌های یادگیری ماشین در حوزه کشاورزی در سه فاز قبل از برداشت، حین برداشت و پس از برداشت پرداختند. در این مطالعه مروری مشاهده شد که الگوریتم‌های یادگیری ماشین نتایج قابل توجهی برای حل مسائل مربوط به کشاورزی به دست آورده‌اند. مطالعه آنها نشان داد که نیاز به دنبال کردن مسیر یادگیری ماشین با روش‌های تجربی



شکل ۱- نمونه هایی از برگهای بیمار در هر کلاس از هر محصول مورد مطالعه

مدل‌های پیشنهادی به عنوان طبقه بند برگ سالم از آلوده

۲-۲-۱. مدل ShuffleNet

مدل ShuffleNet یکی از معماری‌های شبکه عصبی کانولوشنی است که دارای ساختار محاسباتی سبک است و پیچیدگی آن به نسبت مدل‌هایی همچون VGG و ResNet کمتر است. در دو نسخه یک بعدی و دوبعدی موجود است که نسخه دوبعدی دارای عملکرد بهتری است. از معایب آن می‌توان به پایین بودن احتمالی عملکرد آن نسبت به مدل‌هایی همچون EfficientNet اشاره کرد (Zhang et al, 2018).

۲-۲-۲. مدل RegNet

مدل RegNet یکی دیگر از معماری‌های شبکه عصبی کانولوشنی است که برای در کاربردهای بینایی کامپیوتری مانند طبقه‌بندی تصاویر، تشخیص اشیا و بخش‌بندی دارای انعطاف‌پذیری بالا هست. به نسبت به معماری‌های پیچیده همچون VGG، شبکه ساده و کارآمدی است و تعادل بهتری بین دقت و هزینه محاسباتی ارائه می‌دهد. از معایب آن

استاندارد وجود دارد. محققان باید مجموعه داده‌های خود را ایجاد کرده و آن را از طریق پلتفرم‌های مختلف در دسترس دیگران قرار دهند تا دیگران بتوانند از آن برای آزمایش و اعتبارسنجی مدل‌های خود استفاده کنند.

Rahmn و همکاران (۲۰۲۵) یک سیستم شناسایی بلادرنگ بیماری برگ ۸ نوع گیاه (سیب‌زمینی، گوجه‌فرنگی، فلفل دلمه‌ای، سیب، ذرت، انگور، هلو و برنج) را با استفاده از تکنیک‌های یادگیری عمیق شامل Inception، VGG، DenseNet، MobileNet توسعه دادند. مجموعه داده‌های آنها شامل ۳۰۹۴۵ تصویر و ۳۵ کلاس بیماری بود. بالاترین میزان دقت برای تشخیص بیماری ۹۸٪ برای گوجه‌فرنگی با مدل Inception، ۱۰۰٪ برای فلفل دلمه‌ای با مدل MobileNet، ۱۰۰٪ برای سیب با مدل MobileNet، ۹۹٪ برای انگور با مدل VGG، ۱۰۰٪ برای هلو با مدل VGG، و ۹۸٪ برای برنج با مدل DenseNet بدست آمد. Shettigere Krishna و همکاران (۲۰۲۵) مدل‌های شبکه عصبی کانولوشنی EfficientNet و ResNet را برای شناسایی بیماری گیاهی توسعه دادند.

تکنیک‌های پیشرفته افزایش داده، مانند نویز گاوسی، برای بهبود تعمیم‌پذیری استفاده شدند. نتایج نشان داد EfficientNet با ترکیب داده‌ها به دقت ۸۰.۱۹٪ رسید و امتیازهای F1 برای بیماری‌های خاص بالای ۹۰٪ بود. Sujatha و همکاران (۲۰۲۵) برای شناسایی بیماری‌های گیاهی از روی تصاویر برگ موز، برگ و میوه سیب، برگ انجیر و برگ سیب زمینی به کمک شبکه‌های عصبی کانولوشنی VGG و Inception بهره جستند. نتایج نشان داد که ترکیب مدل Inception با SVM برای مجموعه داده برگ موز و سیب زمینی، و ترکیب مدل VGG با KNN برای سیب بهترین عملکرد را ارائه دادند.

مواد و روش‌ها

جمع آوری داده‌ها و پیاده سازی طبقه بندها

مجموع ۱۳۳۲۴ تصویر برگهای بیمار از ۵ محصول مختلف درت، سیب زمینی، نیشکر، گندم و برنج (شکل ۱) با سایز تصویر متفاوت ولی ۴۰۷۹ گیگابایت در مجموع، از سایت کگل تهیه شدند^۱. جدول ۱ ویژگی‌های راه اندازی و پیاده سازی آموزش مدل‌های پیشنهادی آورده شده است.

1 <https://www.kaggle.com/datasets/shubham2703/five-crop-diseases-dataset/data>.

می‌شود که مدل ResNet اورفیت ندارد و دو مجموعه داده آموزشی و اعتبارسنجی دقت خوبی دارند و خطای آموزش و اعتبارسنجی کاهش یافته و سپس تثبیت شده است. این بدان معناست که مدل توانسته است که داده های جدید را بخوبی آموزش ببیند. در طبقه بند ShuffleNet مشاهده شد که دقت آموزش سریع افزایش یافت. دقت اعتبارسنجی نیز افزایش یافت اما به دقت آموزش نرسید که بیانگر اورفیت خفیف است. مدل DenseNet نیز ابتدا افزایش دقت را داشا اما نوساناتی در دقت اعتبارسنجی مشاهده شد که به مقدار مطلوب نرسید. این مدل در یادگیری داده های جدید دارای پایداری نبود.

جدول ۲- معیارهای ارزیابی کارایی طبقه بندها

فرمول و توصیف آن
$Precision = TP / (TP + FP)$ دقت مجموعه‌ای از اندازه‌گیری‌ها به صورت میزان نزدیکی نتایج آن اندازه‌گیری‌ها به یکدیگر تعریف می‌شود.
$Accuracy = (TP + TN) / (TP + FP + TN + FN)$ نسبت کل نمونه‌هایی که به درستی توسط مدل پیش‌بینی شده‌اند (چه مثبت و چه منفی) به کل نمونه‌های موجود
$Recall = TP / (TP + FN)$ بازخوانی نشان می‌دهد که چند درصد از نمونه‌های مثبت واقعی توسط مدل به درستی مثبت تشخیص داده شده‌اند.
$F1 = 2 \times (Precision \times Recall) / (Precision + Recall)$ تعداد بین دقت و فراخوانی
ROC (Receiver Operating Characteristic) معیاری از توانایی مدل در تمایز بین کلاس‌ها است. هرچه بالاتر باشد، مدل در تمایز کلاس‌های مثبت و منفی بهتر عمل می‌کند.
PR (Precision-Recall) نمایش گرافیکی است که عملکرد یک مدل طبقه‌بند را با رسم نمودار دقت در برابر فراخوانی برای آستانه‌های احتمال مختلف ارزیابی می‌کند.

شکل ۳ نمودار منحنی ROC را در راستای ارزیابی عملکرد مدل‌های پیشنهادی نمایش می‌دهد. از آنجایی که در تمامی کلاسها (بیماریها)، منحنی نزدیک به ۱ هستند بنابراین مدلها در تشخیص کلاسها خوب عمل کرده اند. برای مثال، "Corn" و "Rice" دارای $AUC = 1.00$ هستند، به این معنی که مدل در طبقه‌بندی این کلاسها عملکرد کاملاً دقیق دارد. شکل ۴ نمودار دقت-بازخوانی برای ارزیابی عملکرد طبقه بندها در شناسایی بیماریها (کلاسها) نمایش می‌دهد. هر رنگ نشان‌دهنده عملکرد مدل برای یک کلاس خاص (مانند Corn، Rice، Wheat و ...) است. خطوط برای بسیاری از

می‌توان پایین بودن عملکردش در وظایف پیچیده مثل شناسایی اشیا با وضوح بالا ذکر کرد (Radosavovic et al, 2020).

جدول ۱- ویژگی های نصب و راه اندازی مدل های آموزشی

پیشنهادی	مدلها
ShuffleNet v2 x0 5, RegNet X 400MF, DenseNet 121, random color jitter, resize to 256 x 256 pixels, vertical and horizontal flip	تبدیل داده آموزش ^۱
۳۲	اندازه دسته ^۲
۳۰	اپوک
Adam	بهینه ساز
٪۶۰	آموزش
٪۲۰	اعتبارسنجی
٪۲۰	تست
۰.۰۰۰۱	نرخ یادگیری

۳-۲-۲- مدل DenseNet

مدل DenseNet برخلاف معماری‌های استاندارد که فقط بین لایه‌های متوالی ارتباط برقرار میکند، تمام لایه‌ها را به یکدیگر متصل می‌کند. این بدان معنا هست که به دلیل اینکه هر لایه ویژگی‌های جدید یاد گرفته‌شده را به لایه‌های بعدی اضافه می‌کند، لذا تعداد پارامترها کاهش می‌یابد و حافظه کمتری مصرف می‌کند. اما هرچند که تعداد پارامترها کاهش می‌یابد، اما می‌تواند حافظه GPU را تحت فشار قرار دهد زیرا نیاز به ذخیره‌سازی خروجی‌های متعدد لایه‌ها دارد (Huang et al, 2017).

۳-۲-۲- معیارهای ارزیابی طبقه بندها

مطابق جدول ۲، برای ارزیابی کارایی طبقه بندها از معیارهای دقت، صحت، بازخوانی، امتیاز اف که از ماتریس سردرگمی طبقه بندها استخراج میشود و نمودار منحنی مشخصه عملیاتی و نمودار دقت-بازخوانی استفاده شد (Sokolova & Lapalme, 2009).


۳. نتایج و بحث

نمودارهای خطای آموزش-اعتبارسنجی طبقه بندها


شکل ۲ نمودار خطای آموزش-اعتبارسنجی برای هر سه طبقه‌بند پیشنهادی را نمایش می‌دهد. مطابق شکل مشاهده

کلاس‌هایی که خطوط آنها نزدیک به گوشه بالا نیستند، ممکن است نیاز به بهبود داشته باشند که ممکن است به دلیل شباهت کلاس‌ها یا عدم توازن داده باشد.


کلاس‌ها نزدیک به گوشه بالا سمت راست قرار دارند، که نشان‌دهنده دقت و بازخوانی بالا است. این بدان معناست که مدل در تشخیص اکثر کلاس‌ها عملکرد بسیار خوبی دارد.




شکل ۲- نمودار خطای آموزش-اعتبارسنجی برای هر سه طبقه بند پیشنهادی




الف




الف




ب



ب



ج




ج

شکل ۴ - نمودار منحنی دقت-بازخوانی برای ارزیابی عملکرد طبقه بندیهای پیشنهادی در شناسایی بیماریها (کلاسها): (الف) مدل DenseNet (ب) مدل ShuffleNet و (ج) مدل RegNet


شکل ۳ - نمودار منحنی ROC برای ارزیابی عملکرد طبقه بندیهای پیشنهادی در شناسایی بیماریها (کلاسها): (الف) مدل RegNet، (ب) مدل ShuffleNet و (ج) مدل DenseNet

شکل ۵ ماتریس سردرگمی طبقه‌بندی‌های مختلف برای کلاس‌های مختلف را نشان می‌دهد. این ماتریس‌ها به صورت رنگی ارائه شده‌اند و نشان‌دهنده تعداد نمونه‌های درست یا نادرست طبقه‌بندی‌شده برای هر کلاس هستند. محور افقی بیانگر کلاس‌هایی که مدل به عنوان خروجی پیش‌بینی کرده است و محور عمودی بیانگر کلاس‌های واقعی داده‌ها می‌باشد. مقادیر روی قطر اصلینشان‌دهنده تعداد پیش‌بینی‌های درست هستند. بیشتر مقادیر روی قطر اصلی ماتریس‌ها قرار دارند که نشان‌دهنده پیش‌بینی‌های درست مدل برای کلاس‌های مختلف است. مدل در بیشتر کلاس‌ها عملکرد خوبی دارد، اما ممکن است در برخی کلاس‌ها دچار خطا شده باشد. مقادیر دیگر پارامترهای ارزیابی همچون دقت، صحت و بازخوانی از روی ماتریس سردرگمی طبق جدول ۳ استخراج شد.

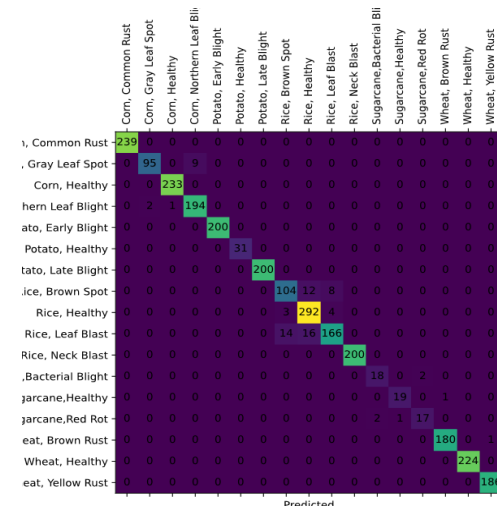
مطابق جدول ۳، دقت کلی مدل RegNet حدود ۹۶٪ است که در شناسایی اکثر بیماری‌های برنج و گندم موفق عمل کرد. دقت کلی مدل ۹۴.۴٪ ShuffleNet بود که نتیجه امیدبخشی است اگرچه از مدل قبلی کمی کمتر است. بالاترین دقت با ۹۷.۲٪ مربوط به مدل Dense Net بود



الف



ب



ج

شکل ۵ – ماتریس سردرگمی برای ارزیابی عملکرد طبقه‌بندی‌های پیشنهادی در شناسایی بیماری‌ها (کلاسها): (الف) مدل RegNet، (ب)

مدل ShuffleNet و (ج) مدل DenseNet

جدول ۳- معیارهای ارزیابی طبقه بندها مستخرج از ماتریس سردرگمی

نام مدل	کلاس	امتیاز اف (%)	بازخوانی (%)	دقت (%)	صحت (%)
RegNet	ذرت، زنگ معمولی	۱۰۰	۱۰۰	۱۰۰	۹۶/۵
	ذرت، لکه خاکستری برگ	۱۰۰	۱۰۰	۱۰۰	
	ذرت، سالم	۱۰۰	۱۰۰	۱۰۰	
	ذرت، بلایت برگ شمالی	۱۰۰	۱۰۰	۱۰۰	
	سیب زمینی، بلایت اولیه	۹۷/۹	۱۰۰	۹۵/۹	
	سیب زمینی، بلایت دیررس	۹۷/۹	۱۰۰	۹۵/۹	
	برنج، لکه قهوه‌ای	۹۰	۹۰	۹۰	
	برنج، سالم	۱۰۰	۱۰۰	۱۰۰	
	برنج، بلایت گردنی	۱۰۰	۱۰۰	۱۰۰	
	نیشکر، سالم	۹۷/۹	۱۰۰	۹۵/۹	
	نیشکر، قرمزی ریشه	۹۷/۹	۱۰۰	۹۵/۹	
	گندم، سالم	۹۰	۹۰	۹۰	
	گندم، زنگ زرد	۹۷/۹	۱۰۰	۹۵/۹	
	ذرت، زنگ معمولی	۱۰۰	۱۰۰	۱۰۰	
	ذرت، لکه خاکستری برگ	۱۰۰	۱۰۰	۱۰۰	
	ذرت، سالم	۱۰۰	۱۰۰	۱۰۰	
SuffleNet	ذرت، بلایت برگ شمالی	۹۷/۹	۱۰۰	۹۵/۹	۹۴/۴
	سیب زمینی، بلایت اولیه	۹۰	۹۰	۹۰	
	سیب زمینی، بلایت دیررس	۹۷/۹	۱۰۰	۹۵/۹	
	برنج، لکه قهوه‌ای	۹۰	۹۰	۹۰	
	برنج، سالم	۱۰۰	۱۰۰	۱۰۰	
	برنج، بلایت گردنی	۹۷/۹	۱۰۰	۹۵/۹	
	نیشکر، سالم	۱۰۰	۱۰۰	۱۰۰	
	نیشکر، قرمزی ریشه	۹۷/۹	۱۰۰	۹۵/۹	
	گندم، سالم	۹۰	۹۰	۹۰	
	گندم، زنگ زرد	۹۷/۹	۱۰۰	۹۵/۹	
	ذرت، زنگ معمولی	۱۰۰	۱۰۰	۱۰۰	
	ذرت، لکه خاکستری برگ	۱۰۰	۱۰۰	۱۰۰	
	ذرت، سالم	۱۰۰	۱۰۰	۱۰۰	
	ذرت، بلایت برگ شمالی	۱۰۰	۱۰۰	۱۰۰	
	سیب زمینی، بلایت اولیه	۹۷/۹	۱۰۰	۹۵/۹	
	سیب زمینی، بلایت دیررس	۱۰۰	۱۰۰	۱۰۰	
DenseNet	برنج، لکه قهوه‌ای	۱۰۰	۱۰۰	۱۰۰	۹۷/۲
	برنج، سالم	۱۰۰	۱۰۰	۱۰۰	
	برنج، بلایت گردنی	۱۰۰	۱۰۰	۱۰۰	
	نیشکر، سالم	۱۰۰	۱۰۰	۱۰۰	
	نیشکر، قرمزی ریشه	۱۰۰	۱۰۰	۱۰۰	
	گندم، سالم	۱۰۰	۱۰۰	۱۰۰	
	گندم، زنگ زرد	۱۰۰	۱۰۰	۱۰۰	

نتیجه‌گیری

این مطالعه با هدف شناسایی بیماری‌های گیاهی در محصولات مختلف با استفاده از پردازش تصویر و الگوریتم‌های یادگیری عمیق انجام شد. نتایج نشان داد که مدل‌های مختلف از جمله ShuffleNet, RegNet و DenseNet عملکرد مناسبی در طبقه‌بندی بیماری‌های گیاهی داشته‌اند. مدل‌ها بر اساس معیارهایی نظیر دقت، صحت، بازخوانی، امتیاز F1 و منحنی‌های ROC و دقت-بازخوانی مورد ارزیابی قرار گرفتند.

- مدل RegNet عملکرد پایداری داشته و بهترین تعادل بین دقت و بازخوانی را نشان داده است.
 - مدل ShuffleNet دارای اورفیت خفیف بود اما در مجموع عملکرد قابل‌قبولی ارائه داد.
 - مدل DenseNet با وجود اتصالات متراکم، در برخی موارد نوساناتی در دقت اعتبارسنجی داشت و نیاز به بهبود دارد.
 - منحنی‌های ROC و دقت-بازخوانی نشان دادند که مدل‌ها در شناسایی اکثر کلاس‌ها عملکرد بسیار خوبی دارند، اما برخی کلاس‌ها نیازمند بهبود هستند که ممکن است به دلیل شباهت ویژگی‌ها یا عدم توازن داده‌ها باشد.
- در نهایت، نتایج این تحقیق تأیید می‌کند که استفاده از الگوریتم‌های یادگیری عمیق در شناسایی بیماری‌های گیاهی می‌تواند به‌طور مؤثری بهره‌وری کشاورزی را افزایش داده و گامی مهم در جهت کشاورزی هوشمند باشد.

مشارکت نویسندگان

نحوه و میزان مشارکت نویسندگان در انجام این پژوهش به صورت زیر است:

- سجاد سبزی: مفهوم سازی و نظارت
- راضیه پوردربانی: نوشتار مقاله
- ماهان معصوم زاده: مواد و روش

دسترسی به داده‌ها

همه اطلاعات و نتایج در متن مقاله ارائه شده است.

اصول اخلاقی

نویسندگان اصول اخلاقی را در انجام و انتشار این اثر علمی رعایت نموده‌اند و این موضوع مورد تأیید همه آنها است.

تضاد منافع نویسندگان

نویسندگان اعلام می‌کنند که هیچ گونه منافع مالی رقابتی یا روابط شخصی شناخته‌شده‌ای که ممکن است بر کار گزارش شده در این مقاله تأثیر گذاشته باشد، ندارند.

حمایت مالی

نویسنده(ها) هیچ حمایت مالی خاصی برای انجام این پژوهش دریافت نکرده‌اند.

منابع

- Asghari P., Rahmani A.M., & Seyyed Javadi H.H. (2019). Internet of things applications: a systematic review. *Computer Net works* 148: 241-261. [DOI:10.1016/j.comnet.2018.12.008](https://doi.org/10.1016/j.comnet.2018.12.008)
- Bhardwaj, R. (2019). Environmental Factors Affecting the Crops' Growth and Development: An Analytical Study. *International Journal of Psychosocial Rehabilitation*. 1160-1167. [DOI:10.53555/V23I1/400051](https://doi.org/10.53555/V23I1/400051).
- Botero-Valencia, J., García-Pineda, V., Valencia-Arias, A., Valencia, J., Reyes-Vera, E., Mejia-Herrera, M., & Hernández-García, R. (2025). Machine Learning in Sustainable Agriculture: Systematic Review and Research Perspectives. *Agriculture*, 15(4), 377. <https://doi.org/10.3390/agriculture15040377>
- Huang, G., Liu, Z., van der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708)
- Peng, Y., Dallas, M.M., Ascencio-Ibáñez, J.T., Hoyer, J.S., Legg, J., Hanley-Bowdoin, L., Grieve, B., & Yin, H. (2022). Early detection of plant virus infection using multispectral imaging and spatial-spectral machine learning. *Scientific Reports*, 12(1), 3113.
- Radosavovic, I., Kosaraju, R. P., Girshick, R., He, K., & Dollár, P. (2020). Designing network design spaces. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 10428-10436)
- Rahman, K.N., Chandra Banik, S., Islam, R., Al Fahim, A. A real time monitoring system for accurate plant leaves disease detection using deep learning, *Crop Design*, Volume 4, Issue 1, 2025, 100092, <https://doi.org/10.1016/j.crope.2024.100092>.
- Rana, A., Choudhury, D., & Ray, D. (2021). A review of deep learning techniques in precision agriculture: Current and future perspectives. *Environmental Monitoring and Assessment*, 193(4), 1-21.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for

- Zhang J, Huang Y, Pu R, Gonzalez-Moreno P, Yuan L, Wu K, Huang W. Monitoring plant diseases and pests through remote sensing technology: A review. *Computers and Electronics in Agriculture*. 2019; 165: 104943.
- Zhang, X., Zhou, X., Lin, M., & Sun, J. (2018). ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- classification tasks. *Information Processing & Management*, 45(4), 427-437.
- Sujatha R., Krishnan S., Chatterjee J.M., Gandomi . A.H. Advancing plant leaf disease detection integrating machine learning and deep learning. *Scientific Reports*. (2025) 15:11552, <https://doi.org/10.1038/s41598-024-72197-2>
- Terentev, A., Dolzhenko, V., Fedotov, A., & Eremenko, D. (2022). Current State of Hyperspectral Remote Sensing for Early Plant Disease Detection: A Review. *Sensors*, 22(3), 757.