



Semnan University

Journal of Modeling in Engineering

Journal homepage: <https://modelling.semnan.ac.ir/>

ISSN: 2783-2538



Research Article

A Comparative Study of Two Deep and Shallow Convolutional Neural Network Architectures for Classifying of Cucumber Leaf Diseases

Hossein Akhtari ^a, Hossein Navid ^{a,*}, Ali Gaffarnejad ^a, Nayer Etminanfar ^a

^a Biosystem Engineering Department, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

PAPER INFO

Paper history:

Received: 2024-01-17

Revised: 2025-04-16

Accepted: 2025-05-10

Keywords:

Precision agriculture;
Deep learning;
Convolutional neural network;
Plant disease recognition cucumber.

ABSTRACT

Cucumber is one of the most consumed products. Performance and quality of the cucumber production is affected by various factors such as pests, insects, and various diseases. Diagnosing the diseases in early stages can reduce economic losses, and increase the quality of production. Agriculture is an important area for the implementation of common techniques based on AI-powered machine vision. Deep learning is one of the different types of common techniques in artificial intelligence, which has made significant contributions to the classification and identification of operations used in precision agriculture. In this research, Convolutional Neural Networks (CNN) based on deep learning were used to identify and classify healthy and unhealthy cucumber leaves. ReseNet-101 and MobileNet-v3 architectures were used to train healthy and unhealthy leaves of cucumber. The dataset was obtained from the Kaggle platform, and after appropriate preprocessing, it was trained and evaluated. Despite being shallow and with a small number of training parameters, MobileNet-v3 architecture provided significant results. The accuracy of the presented architecture identification and classification was equal to %98.64. The use of this type of architecture will be very suitable for use in smartphones and embedded systems due to its light and shallow structure.

DOI: <https://doi.org/10.22075/jme.2025.32983.2609>

© 2025 Published by Semnan University Press.

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

* Corresponding author.

E-mail address: navid@tabrizu.ac.ir

How to cite this article:

H. Akhtari , H. Navid , A. Gaffarnejad and N. Etminanfar, "A comparative study of two deep and shallow convolutional neural network architectures for classifying of cucumber leaf diseases," Journal of Modeling in Engineering, 23 83 (2025): 291-301, doi: 10.22075/jme.2025.32983.2609

بررسی مقایسه‌ای دو معماری ژرف و کم‌عمق شبکه‌های عصبی پیچشی در طبقه‌بندی بیماری‌های برگ خیار

حسین اختری^۱، حسین نوید^{۱*}، علی غفارنژاد^۱، نیر اطمینان‌فر^۱

اطلاعات مقاله	چکیده
دریافت مقاله: ۱۴۰۲/۱۰/۲۷ بازنگری مقاله: ۱۴۰۴/۰۱/۲۷ پذیرش مقاله: ۱۴۰۴/۰۲/۲۰	خیار یکی از پرمصرف‌ترین محصول در بین عموم مردم می‌باشد. تولید این محصول متناسب با نیاز مردم از اهمیت بالایی برخوردار است. در حالی که عملکرد محصول متأثر از عوامل مختلفی نظیر آفات و حشرات و بیماری‌های گوناگون می‌باشد. شناسایی و تشخیص بیماری در مراحل اولیه آن می‌تواند باعث کاهش زیان‌های اقتصادی و افزایش کیفیت تولید گردد. شناسایی بیماری محصول به کمک نیروی انسانی، فرآیندی بسیار زمان‌بر و پرهزینه است. با توجه به اینکه کشاورزی یک حوزه مهم برای پیاده‌سازی تکنیک‌های رایج مبتنی بر بینایی ماشین است لذا می‌توان برای شناسایی و تشخیص بیماری محصولات مختلف از این تکنیک‌ها بهره گرفت. یادگیری عمیق یکی از انواع مختلف تکنیک‌های رایج در بینایی ماشین و هوش مصنوعی است، که کمک‌های قابل توجهی به طبقه‌بندی و شناسایی عملیات به‌کار رفته در حوزه کشاورزی دقیق کرده است. در این تحقیق با هدف شناسایی و طبقه‌بندی محصول سالم و ناسالم برگ خیار، از شبکه‌های عصبی پیچشی مبتنی بر یادگیری عمیق استفاده شد. دو معماری معروف رزنت ۱۰۱ لایه و موبایل‌نت نسخه ۳ جهت آموزش برگ ناسالم و سالم محصول خیار اتخاذ شد. مجموعه داده از بستر کگل استخراج و پس از پیش‌پردازش‌های مناسب، مورد آموزش و آزمایش قرار گرفت. معماری موبایل‌نت نسخه ۳ با وجود کم عمق بودن و تعداد کم پارامترهای آموزشی نتایج قابل توجهی را از خود ارائه داد. دقت شناسایی و طبقه‌بندی معماری ارائه شده برابر با ۹۸/۶۴ درصد بود. استفاده از این نوع معماری‌ها جهت استفاده در گوشی‌های هوشمند و سامانه‌های تعبیه شده به دلیل ساختار سبک و کم‌عمق بسیار مناسب خواهد بود.

واژگان کلیدی:

کشاورزی دقیق،
تشخیص بیماری گیاهی،
یادگیری عمیق،
شبکه عصبی پیچشی
خیار.

DOI: <https://doi.org/10.22075/jme.2025.32983.2609>

© 2025 Published by Semnan University Press.

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

۱- مقدمه

می‌باشد. چرا که ازدیاد در مصرف سموم باعث کاهش کیفیت و سلامت محصول، زیان‌های اقتصادی و از همه مهم‌تر افزایش آلودگی محیط زیست را در پی خواهد داشت. بنابراین شناسایی زود هنگام بیماری محصول تأثیر به‌سزایی در استفاده مقدار بهینه سم را خواهد داشت. از سوی دیگر، طبقه‌بندی با استفاده از الگوریتم‌های مبتنی


محصولات صیفی به خصوص خیار جزو محصولات پرمصرف در کشور ایران می‌باشد. بنابراین تامین نیاز این محصول در کشور مستلزم افزایش تولید است. از چالش‌های مطرح حال حاضر دنیا، استفاده بی‌رویه از سموم علیه بیماری‌ها، علف‌هرز، آفت و غیره در مزارع و حتی در محیط‌های گلخانه

* پست الکترونیک نویسنده مسئول: navid@tabrizu.ac.ir

۱. دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

استناد به این مقاله:

حسین اختری، حسین نوید، علی غفارنژاد و نیر اطمینان‌فر، "بررسی مقایسه‌ای دو معماری ژرف و کم‌عمق شبکه‌های عصبی پیچشی در طبقه‌بندی بیماری‌های برگ خیار"، مدل سازی در مهندسی، ۲۳ (۱۴۰۴): ۲۹۱-۳۰۱، doi: 10.22075/jme.2025.32983.2609



شکل ۱- طرحواره طرحواره کلی تشخیص و طبقه بندی برگ گیاه سالم از بیمار به کمک پردازش تصویر

ماشین بردار پشتیبان^۵ یکی از روش های معروف در حوزه یادگیری ماشین است که توسط جیان و همکاران [۷] جهت شناسایی بیماری برگ خیار استفاده شد. مراحل پیش پردازش شامل جداسازی برگ لکه دار از پس زمینه پیچیده با استفاده از فناوری برش تصویر، پاک کردن برخی نویزها از تصویر و در نهایت جداسازی لکه ها از برگ بود. علاوه بر این به علت کم بودن تعداد داده ها به جای نمونه برداری از هر برگ، هر نقطه از برگ را به عنوان نمونه انتخاب و استفاده شد. سه تابع طبقه بند شعاعی^۶، چندجمله ای^۷ و سیگموئید^۸ برای مقایسه این روش در هر سه حالت نیز بهره گرفته شد. نتایج این تحقیق نشان داد که استفاده از تکنیک ماشین بردار پشتیبان با تابع شعاعی، عملکرد خوبی را در طبقه بندی سه نوع مختلف بیماری برگ خیار ارائه می دهد. مقدار دقت برای داده های آزمایشی برای سه نوع مختلف بیماری برابر با ۶۶/۷، ۷۵ و ۶۶/۷ بود.

بر بنیابی ماشین و یادگیری عمیق، به ویژه در صنعت کشاورزی، محبوبیت زیادی در میان محققین حوزه های مختلف به دست آورده است [۱]. به عنوان مثال، با هدف شناسایی صحیح انواع گونه های پشه برای کنترل انتشار برخی بیماری ها، زارع نظری و همکاران [۲]، با استفاده از مدل های مبتنی بر شبکه عصبی پیچشی عملیات قطعه بندی آناتومی و سپس طبقه بندی تصاویر پشه را انجام دادند. عملیات مذکور با ترکیب شبکه رزنت ۱۰۱ و MaskRCNN صورت گرفت. نتایج حاصله نشان داد که استفاده از روش های مبتنی بر یادگیری عمیق تاثیر به سزایی در شناسایی و تشخیص صحیح انواع گونه های پشه با هدف مذکور را دارد.

پیش از این، تشخیص و شناسایی بیماری های گیاهی به صورت دستی و با تکیه بر مشاهدات بصری توسط کارشناسان و نیروی انسانی انجام می شد که فرآیندی زمان بر و پرهزینه به شمار می آمد. پیشرفت های اخیر در حوزه بنیابی ماشین به خصوص یادگیری عمیق کار را برای محققین جهت تشخیص و شناسایی سریع و دقیق آفات، بیماری و علف های هرز هموارتر کرده است [۳]. علی رغم ارائه تحقیقات مختلف و پیشرفت های حاصل شده در زمینه تشخیص و شناسایی بیماری محصولات صیفی به کمک روش های سنتی نظیر یادگیری ماشین و پردازش تصویر [۴]، این روش ها دارای معایب مختلفی می باشند. از معایب این نوع روش ها می توان به زمان بر بودن آنها به دلیل روش چند مرحله ای که نیاز به مهندسی ویژگی ها و داده های پیچیده دارد، دقت طبقه بندی کم و تشخیص مشکل در تصاویر با پس زمینه های پیچیده و چالش برانگیز اشاره نمود [۵]. طرحواره کلی مراحل تشخیص و طبقه بندی برگ سالم از بیمار به کمک پردازش تصویر در شکل (۱) نشان داده شده است که هر یک از مراحل موجود در این شکل در برگزیده الگوریتم های متعدد در این حوزه است و براساس نیاز مسئله مستلزم پیاده سازی می باشد. به عنوان مثال برای عملیات تقطیع مبتنی بر آستانه می توان از تکنیک هایی نظیر هیستوگرام^۲ تصویر، خوشه بندی^۳، واترشد^۴ و ... استفاده نمود [۶].

^۶ Radial Basis Function

^۷ Polynomial

^۸ Sigmoid

^۲ Histogram

^۳ Clustering

^۴ Watershed

^۵ Support Vector Machine

حسینی و همکاران [۸]، از الگوریتم‌های مطرح در حوزه پردازش تصویر و شبکه عصبی به ترتیب جهت استخراج ویژگی و طبقه‌بندی دو نوع بیماری قارچی در برگ خیار استفاده کردند. مجموعه داده‌ها شامل ۱۵۰ تصویر حاصل شده در شرایط آزمایشگاهی و کاملاً کنترل شده از نظر نور و فاصله برگ از دوربین، بود. پس از جمع‌آوری داده‌ها مراحل مطرح در پردازش تصویر مانند پیش‌پردازش، بخش‌بندی، استخراج ویژگی‌ها و طبقه‌بندی بر روی تصاویر لحاظ گردید. در نهایت از شبکه عصبی پرسپترون چند لایه با الگوریتم پس انتشار خطا جهت طبقه‌بندی سه حالت برگ خیار (سالم، قارچ سفیدک پودری و آنتراکنوز) استفاده شد. ۲۰،۷۰ و ۱۰ درصد از کل داده‌ها به ترتیب برای آموزش، اعتبارسنجی و ارزیابی شبکه، تقسیم‌بندی شد. از تابع لونیبرگ مارکوات^۹ برای الگوریتم آموزشی نیز استفاده گردید. مقدار میانگین مربعات خطا^{۱۰} برای شبکه یک لایه با چهار نورون به همراه الگوریتم آموزشی مذکور برابر ۰/۰۰۶ بود که در مقایسه با سایر شبکه‌ها مقدار بهینه را داشت.

در سال‌های اخیر مطرح شدن برخی تکنیک‌ها و الگوریتم‌های نوین در حوزه هوش مصنوعی به‌خصوص یادگیری عمیق، محققان را برای استفاده از این گونه تکنیک‌ها رهنمون می‌کند. شبکه‌های عصبی پیچشی (CNN) یکی از چند شبکه‌های مطرح و پرکاربرد در حوزه شناسایی و تشخیص اشیاء است [۹]. علاوه بر این شبکه‌های پیچشی در حوزه کشاورزی دقیق با اهداف مختلف می‌تواند پرکاربرد و مفید واقع شود. بنابراین با در نظر گرفتن شرایط خاص و پیچیده مزارع کشت برنج از شبکه‌های پیچشی برای طبقه‌بندی بیماری برگ این محصول استفاده شد. معماری معروف VGG-16 [۱۰] به کمک یادگیری انتقالی^{۱۱} با داده‌های حاصل شده از مزارع برنج مورد آموزش و ارزیابی قرار گرفت. مجموع داده‌ها به ترتیب شامل ۱۵۰۹ و ۶۴۷ تصویر برای آموزش و ارزیابی بود. دقت حاصل شده در طبقه‌بندی برگ بیمار و سالم در محصول برنج برابر با ۹۲/۴۶ بود [۱۱].

با پیشرفت‌های چشمگیر علم در حوزه بینایی ماشین، روش‌های مبتنی بر شبکه‌های عصبی و یادگیری عمیق به سرعت جایگاه ویژه‌ای در میان محققین حوزه‌های مختلف،

به‌ویژه در صنعت کشاورزی، پیدا کرده‌اند. این تکنیک‌ها با توانایی‌های خود در پردازش داده‌های پیچیده و شبیه‌سازی ویژگی‌های انسان در تشخیص الگوها، به‌طور قابل توجهی دقت و کارایی سیستم‌ها را افزایش داده‌اند. در این تحقیق، تلاش شده است تا با استفاده از روش‌های نوین و پیشرفته در حوزه یادگیری عمیق، عملیات طبقه‌بندی برگ‌های سالم و ناسالم خیار به‌صورت دقیق و خودکار انجام شود. علاوه بر این، به‌منظور ارزیابی دقت و عملکرد مدل‌ها، دو نوع مختلف از شبکه‌های عصبی پیچشی با معماری‌های متفاوت مورد بررسی قرار گرفت. در این پژوهش، همچنین معایب روش‌های پیشین که عمدتاً مبتنی بر پردازش تصویر سنتی بودند، از جمله مشکلاتی مانند نیاز به پردازش‌های چند مرحله‌ای، حساسیت به تغییرات نور و نیاز به استخراج ویژگی‌های دستی، مورد بحث قرار گرفته است. این چالش‌ها با استفاده از روش‌های یادگیری عمیق و شبکه‌های عصبی پیچشی قابل رفع بوده و مدل ارائه شده می‌تواند به‌طور خودکار و با دقت بالا به طبقه‌بندی تصاویر بپردازد.

۲- مواد و روش‌ها

۲-۱- جمع‌آوری داده

جمع‌آوری داده‌ها یکی از گام‌های اساسی و حیاتی در فرآیند آموزش و ارزیابی شبکه‌ها در یادگیری عمیق است. کیفیت و تعداد داده‌ها تأثیر زیادی بر عملکرد مدل دارند، به‌طوری که هرچه داده‌های بیشتری از لحاظ کمیت و کیفیت برای آموزش شبکه فراهم شود، امکان یادگیری بهتر ویژگی‌ها و الگوها فراهم می‌شود. به‌طور کلی، تعداد داده‌ها مستقیماً بر دقت و کارایی مدل در فرآیند آموزش و تست اثر می‌گذارد. علاوه بر این، تنوع در تصاویر از نظر شدت نور، زاویه عکس‌برداری و غیره سبب تعمیم‌پذیری^{۱۲} هرچه بهتر مدل خواهد گردید. شکل (۲) تناسب آموزش شبکه و تعداد داده در یادگیری ماشین و یادگیری عمیق را نشان می‌دهد [۱۲]. در این تحقیق از مجموعه تصاویر برگ خیار موجود در بستر کگل^{۱۳} استفاده شده است که شامل ۳۴۱ تصویر برگ سالم و ۳۵۰ تصویر برگ بیمار با انواع مختلف بیماری ویروسی و آفت حاصل از حشرات بود. تصاویر با وضوح بالا، اندازه‌های گوناگون و تحت شرایط نوری متفاوت تهیه شده بودند. برای تقسیم‌بندی داده‌ها، روش ساده Hold-Out به نسبت ۷۰٪

¹² Generalization

¹³ Kaggle

⁹ Levenberg-Marquardt

¹⁰ Mean squared error

¹¹ Transfer learning


جهت، موقعیت، مقیاس، روشنایی و غیره است. بنابراین برای این منظور از روش‌های مطرح داده‌افزایی به صورت آنلاین^{۱۵} در حوزه یادگیری عمیق استفاده شد. تکنیک‌های استفاده شده برای داده‌افزایی در این تحقیق شامل تغییر اندازه، قرینه‌سازی و مقیاس خاکستری بود که بر روی دسته تصاویر ورودی آموزش شبکه اعمال شد. عملیات داده‌افزایی با هدف غلبه بر کمبود داده‌های آموزشی در نتیجه رهایی از برازش بیش از حد شبکه مورد استفاده قرار می‌گیرند [۱۴]. در داده‌افزایی از نوع آنلاین داده‌ها به صورت همزمان با فرآیند آموزش مدل تغییر می‌کنند. این یعنی در هر دسته تصاویر آموزشی که به مدل داده می‌شود، تغییرات و تبدیلات مذکور اعمال می‌گردد. استفاده از تکنیک‌های افزایش داده به صورت آنلاین موجب افزایش تنوع و گوناگونی داده‌ها در شرایط مختلف می‌شود، بدون آنکه نیاز به ذخیره‌سازی تصاویر تغییر یافته در کنار تصاویر اصلی وجود داشته باشد، همانند آنچه که در روش‌های آفلاین معمول است. افزایش داده آنلاین با تطبیق خودکار با وضعیت مدل و حذف نیاز به آموزش آفلاین، به طور همزمان کارایی بالاتر و انعطاف‌پذیری بیشتری را در مقایسه با روش‌های آفلاین فراهم می‌کند [۱۵].

۲-۲- شبکه‌های عصبی پیچشی


۲-۲-۱- رزنت ۱۰۱ لایه^{۱۶}

شبکه‌ای با نام Residual Network است که در سال ۲۰۱۶ توسط تیمی از شرکت مایکروسافت ارائه گردید [۱۶]. ایده کار این شبکه ارائه راه‌کاری برای فرآیند آموزش آسان‌تر با وجود عمیق‌تر بودن شبکه بود. یک شبکه ۱۵۲ لایه رزنت، ۸ برابر عمیق‌تر از شبکه پیچشی VGG می‌باشد ولی ساختار آن پیچیدگی کمتری نسبت به شبکه VGG دارد. شبکه رزنت متشکل از ماژول‌های Residual دارای تعداد ۲ یا ۳ لایه پیچشی متصل به هم می‌باشد که نحوه عملکرد این ماژول‌ها سبب آموزش آسان‌تر شبکه می‌شود. انواع مختلف شبکه رزنت از نظر معماری و تعداد لایه‌ها وجود دارد. رزنت ۳۴، ۵۰ و ۱۰۱ لایه جزو محبوب‌ترین شبکه‌های پیچشی هستند که مورد استفاده بیشتر محققان قرار می‌گیرند. در این تحقیق با هدف پیاده‌سازی و بررسی عملکرد یک شبکه ژرف برای تشخیص بیماری برگ گیاه از رزنت ۱۰۱ استفاده گردید. تفاوت رزنت ۱۰۱ لایه با سایر

برای آموزش و ۳۰٪ برای آزمون انتخاب شد. این روش به دلیل توزیع متناسب کلاس‌ها در داده‌های آموزش و آزمون، کاهش نیاز به منابع محاسباتی و عملکرد پایدار مدل بر روی داده‌های آزمون به کار گرفته شده است. نتایج حاصل نشان داد که این روش برای ارزیابی مدل کافی بوده و نیاز به استفاده از روش‌های پیچیده‌تر مانند K-Fold را برطرف می‌کند [۱۳]. در شکل (۳) دسته‌ای از تصاویر داده‌های آموزش به همراه برچسب مربوط به هر کدام نشان داده شده است.



شکل ۲- عملکرد یادگیری ماشین و یادگیری عمیق با تعداد داده



شکل ۳- دسته‌ای از تصاویر آموزشی به همراه برچسب آنها

مجموعه داده‌هایی که برای آموزش و ارزیابی مدل‌های یادگیری عمیق جمع‌آوری می‌شوند، ممکن است از نظر شرایط تهیه تصاویر محدودیت‌هایی داشته باشند یا تعداد آن‌ها به اندازه کافی زیاد نباشد. چرا که کمبود داده‌ها در فرآیند آموزش شبکه‌های عصبی مبتنی بر یادگیری عمیق می‌تواند منجر به مشکلاتی نظیر عدم آموزش کافی و به‌ویژه بیش‌برازش^{۱۴} شود. در حالیکه که هدف از آموزش شبکه، شناسایی و طبقه‌بندی در شرایط بسیار متنوع از لحاظ

¹⁶ ResNet-101

¹⁴ Overfitting

¹⁵ Online Augmentation

۳- نتایج و بحث

ارزیابی عملکرد مدل‌های آموزش داده شده بر روی داده‌های آزمایشی، با استفاده از برخی معیارهای مطرح در این حوزه مورد بحث و بررسی قرار گرفت. این معیارها قادر به ارائه میزان موثر بودن مدل‌ها در شناسایی و طبقه‌بندی برگ سالم از ناسالم با توجه به داده‌های استفاده شده برای آموزش می‌باشند. در جدول ۳ معیارهای ارزیابی شبکه‌های مطرح در این تحقیق برای طبقه‌بندی برگ خیار نشان داده شده است. با توجه به نتایج حاصل شده، هر دو شبکه عملکرد مطلوبی را از خود نشان داده‌اند.

جدول ۳- مقادیر معیار ارزیابی شبکه‌ها

مدل	Precision (%)	Recall (%)	F1score (%)	Accuracy (%)
رژنت ۱۰۱	۹۶/۹	۱۰۰	۹۸/۴	۹۸/۲
موبایل‌نت نسخه ۳	۹۸/۴	۹۹/۲	۹۸/۸	۹۸/۶۴

با وجود اینکه رزنت ۱۰۱ فراخوانی بالاتری (۱۰۰٪) نسبت به موبایل‌نت ۳ (۹۹.۲٪) دارد، مدل موبایل‌نت ۳ در معیارهای Precision (۹۸.۴٪ در مقابل ۹۶.۹٪) و F1-Score (۹۸.۸٪ در مقابل ۹۸.۴٪) و دقت (۹۸/۶۴٪ در مقابل ۹۸/۲٪) عملکرد بهتری ارائه داده است. این نتایج نشان می‌دهد که موبایل‌نت ۳، با وجود سبک‌تر بودن معماری، توانسته عملکردی تقریباً مشابه و حتی بهتر از رزنت ۱۰۱ در اکثر معیارها ارائه دهد. سبک‌وزن بودن موبایل‌نت ۳ به دلیل طراحی بهینه آن، مانند استفاده از تکنیک‌های ذکر شده، باعث کاهش تعداد پارامترها و هزینه محاسباتی شده است. این ویژگی‌ها، موبایل‌نت ۳ را به گزینه‌ای مناسب برای کاربردهای کشاورزی هوشمند و سیستم‌های مبتنی بر اینترنت اشیا تبدیل می‌کند، جایی که منابع محاسباتی محدود هستند. در مجموع، این مدل نه تنها دقت بالایی ارائه می‌دهد، بلکه با بهینه‌سازی منابع محاسباتی، امکان استفاده در دستگاه‌های کم‌قدرت و کاربردهای تعبیه‌شده را نیز فراهم می‌کند.

فرآیند آموزش هر دو معماری در ۱۰۰ دوره صورت گرفت. شکل (۵) و شکل (۶) به ترتیب نمودارهای مربوط به اتلاف

و استفاده می‌گردد. در علم یادگیری عمیق به این نوع مولفه‌ها، هایپرپارامتر^{۲۴} گفته می‌شود. در جدول ۱ برخی از هایپرپارامترهای استفاده شده در این تحقیق قابل مشاهده است.

جدول ۱- هایپرپارامترهای تعیین شده

هایپرپارامتر	مقدار یا روش
تعداد دوره آموزش ^{۲۵}	۱۰۰
داده‌های ورودی هر دوره ^{۲۶} (دسته)	۱۰۰
تابع بهینه‌ساز ^{۲۷}	SGD (Stochastic Gradient Descent)
مومنوم ^{۲۸}	۰/۹
نرخ آموزش ^{۲۹}	۰/۰۰۰۱

برای بررسی و ارزیابی عملکرد شبکه‌های آموزش داده شده برخی از معیارهای ارزیابی مطرح در این حوزه استفاده می‌شود. معیارهایی نظیر Precision، Recall، F1 Score و Accuracy اغلب برای ارزیابی عملکرد وظایف طبقه‌بندی مورد استفاده قرار می‌گیرند. در این تحقیق نیز از این معیارها جهت بررسی عملکرد شبکه‌های آموزش داده شده استفاده گردید. در جدول ۲ روابط مربوط به محاسبه معیارهای ارزیابی مذکور نشان داده شده است. که در آن TP پیش‌بینی درست نمونه مثبت، TN پیش‌بینی درست نمونه منفی، FP پیش‌بینی اشتباه نمونه مثبت و FN پیش‌بینی اشتباه نمونه منفی می‌باشد.

جدول ۲- روابط مربوط به معیارهای ارزیابی

Accuracy	$\frac{TP + TN}{TP + TN + FP + FN}$
Precision	$\frac{TP}{TP + FP}$
Recall	$\frac{TP}{TP + FN}$
F1-score	$\frac{precision \times recall}{precision + recall} \times 2$

²⁷ Optimization function

²⁸ Momentum


²⁹ Learning rate

²⁴ Hyper-parameter


²⁵ Training epochs

²⁶ Batch-size

منفی در کاربردهای عملی داشته باشد، خصوصاً در سناریوهایی که هزینه خطا در تشخیص نادرست نمونه‌های سالم بالاست.



شکل ۵- نمودارهای اتلاف و صحت آموزش شبکه رزنت ۱۰۱ لایه



شکل ۶- نمودارهای اتلاف و صحت آموزش شبکه موبایل‌نت نسخه ۳

و دقت آموزش شبکه رزنت با ۱۰۱ لایه و موبایل‌نت نسخه ۳ را ارائه می‌کند. بررسی نمودارها نشان می‌دهد رفتار اتلاف و دقت آموزش و آزمایش مربوط به شبکه موبایل‌نت نسخه ۳ تقریباً پس از گذشت ۹۵ دوره تقریباً همگرا شده و به نقطه ثابتی رسیده است. در مقابل آن با توجه به نمودارهای شبکه رزنت ۱۰۱ لایه، رفتار نمودارها دارای نوسان زیاد بوده و از همگرایی کم‌تری برخوردار است. علت این نتیجه می‌تواند از متناسب نبودن تعداد داده‌ها با عمق و پارامترهای آموزشی شبکه باشد. علاوه بر این، آموزش شبکه‌های کم‌عمق نظیر موبایل‌نت نسخه ۳ عموماً مصرف کمتر منابع محاسباتی را دارند که باعث می‌شود به داده‌های کم‌تری نیاز داشته باشند و برای آموزش سریع‌تر باشند. بنابراین شبکه‌های کم‌عمق برای سناریوهایی با منابع محاسباتی محدود مناسب‌تر هستند. رفتار نمودارها نشان دهنده کافی بودن ۱۰۰ دوره برای آموزش شبکه‌ها در این تحقیق می‌باشد.

شکل (۷) نشان دهنده ماتریس در هم ریختگی^{۳۰} هردو شبکه می‌باشد. این ماتریس عملکرد شبکه‌ها را مورد بررسی قرار می‌دهد. با توجه به اینکه از مجموع ۲۲۲ تصویر آزمایشی، تصاویر برگ سالم و بیمار به ترتیب برابر ۹۹ و ۱۲۳ تصویر بود، موبایل‌نت^{۳۱} ۳ توانسته است ۱۲۱ نمونه بیمار را به درستی شناسایی کند (مثبت صادق^{۳۲}) و تنها ۱ نمونه بیمار را به اشتباه سالم پیش‌بینی کرده است (منفی کاذب^{۳۳}). همچنین، از میان نمونه‌های سالم، ۹۸ نمونه به درستی شناسایی شده‌اند (منفی صادق^{۳۴}) و تنها ۲ نمونه سالم به اشتباه بیمار تشخیص داده شده‌اند (مثبت کاذب^{۳۴}). این عملکرد نشان‌دهنده تعادل خوبی میان فراخوانی (توانایی شناسایی صحیح نمونه‌های بیمار) و دقت (پیش‌بینی صحیح نمونه‌های سالم) است.

در مقابل، مدل رزنت ۱۰۱ توانسته است تمام تصاویر بیمار (۱۲۳ نمونه) را به درستی شناسایی کند (مثبت صادق) و هیچ نمونه بیمار را به اشتباه سالم پیش‌بینی نکرده است (منفی کاذب). از طرف دیگر، ۹۵ نمونه سالم به درستی شناسایی شده‌اند (منفی صادق) و ۴ نمونه سالم به اشتباه بیمار پیش‌بینی شده‌اند (مثبت کاذب). در حالی که این مدل فراخوانی بالاتری نسبت به موبایل‌نت^۳ ارائه می‌دهد، افزایش خطای پیش‌بینی نمونه‌های سالم ممکن است تأثیر

³³ True negative

³⁴ False positive

³⁰ Confusion matrix

³¹ True positive

³² False Negative

عمیق می‌تواند ابزاری موثر و کارآمد برای شناسایی و طبقه‌بندی انواع مختلف محصولات در حوزه کشاورزی باشد. علاوه بر این دوربین‌های مجهز شده با این نوع تکنیک‌ها می‌تواند جایگزین بهتری برای عملیات بصری انسان باشد. همانطوری که مشاهده شد استفاده از شبکه‌های سبک و کم عمق نظیر موبایل‌نت عملیات شناسایی و طبقه‌بندی را تا چند برابر سریع‌تر می‌کند. استفاده از شبکه‌های عمیق‌تر وابستگی عملیات طبقه‌بندی به سیستم پردازشی رده بالا را افزایش می‌دهد که منجر به تولید هزینه‌های محاسباتی زیادی می‌شود. معماری موبایل‌نت نسخه ۳ با صحت ۹۸/۶۴ درصد، به‌عنوان معماری مطلوب برای شناسایی و طبقه‌بندی برگ سالم از ناسالم محصول خیار معرفی شد. اختصاص برچسب و دخالت دادن نوع بیماری در طبقه‌بندی، طراحی سخت‌افزار مناسب جهت آزمایش شبکه‌ها به صورت زمان واقعی^{۳۵}، آموزش و ارزیابی نوع دیگر معماری‌های مطرح در این حوزه و مقایسه آنها و جمع‌آوری و استفاده از پایگاه داده قدرتمند جهت ایجاد شبکه‌ای قدرتمند در این حوزه، از جمله کارهایی است که می‌توان در آینده مورد بحث و بررسی قرار داد.

تقدیر و تشکر

از تمامی عزیزانی که با نظرات فنی و ویرایشی خود به غنای این مقاله افزودند، صمیمانه قدردانی می‌شود.

تعارض منافع

نویسندگان اعلام می‌کنند که در مورد انتشار این مقاله تعارض منافع وجود ندارد.

تاییدیه اخلاقی

نویسندگان متعهد می‌شوند که این مقاله پیش از این در هیچ نشریه‌ای منتشر نشده و به‌طور همزمان به مجله دیگری ارسال نگردیده است.

حسین اختری: ایده‌پردازی، طراحی پژوهش و نگارش مقاله.


حسین نوید: راهنمای پژوهش و نظاره‌گر.

علی غفارنژاد: نگارش و بازبینی متن.

نیر اطمینان‌فر: نگارش و بازبینی متن.


منابع مالی

نویسندگان اعلام می‌دارند که برای انجام این پژوهش، هیچ‌گونه حمایت مالی دریافت نکرده‌اند.



شکل ۷- ماتریس درهم ریختگی (الف) موبایل‌نت نسخه ۳ (ب) رزنت ۱۰۱ لایه

نمونه‌ای از پیش‌بینی‌ها و طبقه‌بندی شبکه موفق در این تحقیق در شکل (۸) نشان داده شده است. این تصاویر، تصاویری است که هیچ گونه دخالتی در حین آموزش شبکه‌ها نداشته‌اند و صرفاً جهت ارزیابی مورد استفاده قرار گرفتند. صحت حاصل شده برای هر دو برگ سالم و ناسالم در این تصاویر برابر ۱۰۰ درصد بود.



شکل ۸- پیش‌بینی شبکه موبایل‌نت نسخه ۳ بر روی داده‌های آزمایشی

۴- نتیجه‌گیری

شناسایی و طبقه‌بندی به موقع، دقیق و سریع بیماری، می‌تواند عامل بسیار مهمی در بهبود رشد محصولات باشد. اگرچه این عملیات می‌تواند با چشم غیرمسلح و بر اساس تجارب و نظارت مستمر امکان پذیر باشد ولی منجر به صرف هزینه زیاد و زمان طولانی خواهد شد. نتایج این تحقیق نشان داد که شبکه‌های عصبی پیچشی مبتنی بر یادگیری

³⁵ Real-time

مراجع

- [1] Gao, Xue. "The Application of Computer Vision Technology in the Field of Agricultural Automation." *International Journal of Advance in Applied Science Research* 4, no. 1 (2025): 1-5.
- [2] Zare Nazari, Marzieh, Mohsen Sardari Zarchi, Sima Emadi, and Hadi Pourmohammadi. "Deep learning framework to extract anatomy for mosquito image classification." *Journal of Modeling in Engineering* 20, no. 70 (2022): 107-120. (in Persian)
- [3] Wang, Shaohua, Dachuan Xu, Haojian Liang, Yongqing Bai, Xiao Li, Junyuan Zhou, Cheng Su, and Wenyu Wei. "Advances in deep learning applications for plant disease and pest detection: A review." *Remote Sensing* 17, no. 4 (2025): 698.
- [4] Lee, Wan-Bum, and Bong-Hyun Kim. "Machine learning innovations for precise plant disease detection: A review." *Legume Research* 47, no. 10 (2024): 1633-1638.
- [5] Liu, Jun, and Xuwei Wang. "Tomato diseases and pests detection based on improved Yolo V3 convolutional neural network." *Frontiers in Plant Science* 11 (2020): 898.
- [6] Dhingra, Gittaly, Vinay Kumar, and Hem Dutt Joshi. "Study of digital image processing techniques for leaf disease detection and classification." *Multimedia Tools and Applications* 77, no. 15 (2018): 19951-20000.
- [7] Jian, Zhang, and Zhang Wei. "Support vector machine for recognition of cucumber leaf diseases." In *2010 2nd International Conference on Advanced Computer Control*, vol. 5, pp. 264-266. IEEE, 2010.
- [8] Hosseini, Hadi, Zamani D. Mohammad, and Abbas Arbab. "A recognition system to detect Powdery Mildew and Anthracnose fungal disease of cucumber leaf using image processing and artificial neural networks technique." (2018): 15-28.
- [9] Zhao, Xia, Limin Wang, Yufei Zhang, Xuming Han, Muhammet Deveci, and Milan Parmar. "A review of convolutional neural networks in computer vision." *Artificial Intelligence Review* 57, no. 4 (2024): 99.
- [10] Simonyan, Karen, and Andrew Zisserman. "Very deep convolutional networks for large-scale image recognition." *arXiv Preprint arXiv:1409.1556* (2014).
- [11] Ghosal, Shreya, and Kamal Sarkar. "Rice leaf diseases classification using CNN with transfer learning." In *2020 IEEE Calcutta Conference (Calcon)*, pp. 230-236. IEEE, 2020.
- [12] Alom, Md Zahangir, Tarek M. Taha, Chris Yakopcic, Stefan Westberg, Paheding Sidike, Mst Shamima Nasrin, Mahmudul Hasan, Brian C. Van Essen, Abdul AS Awwal, and Vijayan K. Asari. "A state-of-the-art survey on deep learning theory and architectures." *Electronics* 8, no. 3 (2019): 292.
- [13] Reitermanova, Zuzana. "Data splitting." In *WDS*, vol. 10, pp. 31-36. Prague: Matfyzpress, 2010.
- [14] Islam, Md Monirul, Md Belal Hossain, Md Nasim Akhtar, Mohammad Ali Moni, and Khondokar Fida Hasan. "CNN based on transfer learning models using data augmentation and transformation for detection of concrete crack." *Algorithms* 15, no. 8 (2022): 287.
- [15] Tang, Zhiqiang, Yunhe Gao, Leonid Karlinsky, Prasanna Sattigeri, Rogerio Feris, and Dimitris Metaxas. "OnlineAugment: Online data augmentation with less domain knowledge." In *European conference on computer vision*, pp. 313-329. Cham: Springer International Publishing, 2020.
- [16] He, Kaiming, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. "Deep residual learning for image recognition." In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770-778. 2016.
- [17] Howard, Andrew G., Menglong Zhu, Bo Chen, Dmitry Kalenichenko, Weijun Wang, Tobias Weyand, Marco Andreetto, and Hartwig Adam. "Mobilenets: Efficient convolutional neural networks for mobile vision applications." *arXiv Preprint arXiv:1704.04861* (2017).
- [18] Howard, Andrew, Mark Sandler, Grace Chu, Liang-Chieh Chen, Bo Chen, Mingxing Tan, Weijun Wang et al. "Searching for mobilenetv3." In *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp. 1314-1324. 2019.
- [19] Qian, Siying, Chenran Ning, and Yuepeng Hu. "MobileNetV3 for image classification." In *2021 IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE)*, pp. 490-497. IEEE, 2021.
- [20] Deng, Jia, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, and Li Fei-Fei. "Imagenet: A large-scale hierarchical image database." In *2009 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 248-255. Ieee, 2009.

[21] Oquab, Maxime, Leon Bottou, Ivan Laptev, and Josef Sivic. "Learning and transferring mid-level image representations using convolutional neural networks." In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 1717-1724. 2014.