



Semnan University

Journal of Modeling in Engineering

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



Research Article

A comparative study of two deep and shallow convolutional neural network architectures for classifying of cucumber leaf diseases

Hossein Akhtari ¹, Hossein Navid ^{1*}, Ali Gaffarnejad ¹, Nayer Etminanfar ¹

1. Biosystem Engineering department, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

*Corresponding Author: navid@tabrizu.ac.ir

PAPER INFO

Paper history:

Received:

Revised:

Accepted:

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.

© 2024 Published by Semnan University Press. All rights reserved.

DOI: <https://doi.org/>

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

حسین اختری^۱، حسین نوید^{۲*}، علی غفارنژاد^۳ و نیر اطمینان‌فر^۴

اطلاعات مقاله	چکیده
نوع مقاله:	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 به کار 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 کم عمق بسیار مناسب خواهد بود.
دریافت مقاله:	
بازنگری مقاله:	
پذیرش مقاله:	
واژگان کلیدی:	
کشاورزی دقیق،	
تشخیص بیماری گیاهی،	
یادگیری عمیق،	
شبکه عصبی پیچشی	
خیار	

۱-مقدمه

علف‌هرز، آفت و غیره در مزارع و حتی در محیط‌های گلخانه 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.

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،

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


۱. دانشجوی دکتری تخصصی، دانشکده کشاورزی، دانشگاه تبریز

۲. استاد، دانشکده کشاورزی، دانشگاه تبریز

۳. دانشجوی دکتری تخصصی، دانشکده کشاورزی، دانشگاه تبریز

۴. دانشجوی دکتری تخصصی، دانشکده کشاورزی، دانشگاه تبریز

عملیات تقطیع مبتنی بر آستانه می‌توان از تکنیک‌هایی نظیر هیستوگرام^۱ تصویر، خوشه‌بندی^۲، واترشد^۳ و ... استفاده نمود [۶].



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

ماشین‌بردار پشتیبان^۴ یکی از روش‌های معروف در حوزه یادگیری ماشین است که توسط جیان و همکاران [۷] جهت شناسایی بیماری برگ خیار استفاده شد. مراحل پیش‌پردازش شامل جداسازی برگ لکه‌دار از پس‌زمینه پیچیده با استفاده از فناوری برش تصویر، پاک کردن برخی نویزها از تصویر و در نهایت جداسازی لکه‌ها از برگ بود. علاوه بر این به علت کم بودن تعداد داده‌ها به جای نمونه برداری از هر برگ، هر نقطه از برگ را به عنوان نمونه انتخاب و استفاده شد. سه تابع طبقه‌بند شعاعی^۵، چندجمله‌ای^۶ و سیگموید^۷ برای مقایسه این روش در هر سه حالت نیز بهره گرفته شد. نتایج این تحقیق نشان داد که استفاده از تکنیک ماشین‌بردار پشتیبان با تابع شعاعی، عملکرد خوبی را در طبقه‌بندی سه نوع مختلف بیماری برگ خیار ارائه می‌دهد.

بنابراین شناسایی زود هنگام بیماری محصول تاثیر به‌سزایی در استفاده مقدار بهینه سم را خواهد داشت.

از سوی دیگر، طبقه‌بندی با استفاده از الگوریتم‌های مبتنی بر بینایی ماشین و یادگیری عمیق، به ویژه در صنعت کشاورزی، محبوبیت زیادی در میان محققین حوزه‌های مختلف به دست آورده است [۱]. به عنوان مثال، با هدف شناسایی صحیح انواع گونه‌های پشه برای کنترل انتشار برخی بیماری‌ها، زارع نظری و همکاران [۲]، با استفاده از مدل‌های مبتنی بر شبکه عصبی پیچشی عملیات قطعه‌بندی آناتومی و سپس طبقه‌بندی تصاویر پشه را انجام دادند. عملیات مذکور با ترکیب شبکه رزنت ۱۰۱ و MaskRCNN صورت گرفت. نتایج حاصله نشان داد که استفاده از روش‌های مبتنی بر یادگیری عمیق تاثیر به‌سزایی در شناسایی و تشخیص صحیح انواع گونه‌های پشه با هدف مذکور را دارد.

پیش از این، تشخیص و شناسایی بیماری‌های گیاهی به‌صورت دستی و با تکیه بر مشاهدات بصری توسط کارشناسان و نیروی انسانی انجام می‌شد که فرآیندی زمان‌بر و پرهزینه به شمار می‌آمد. پیشرفت‌های اخیر در حوزه بینایی ماشین به‌خصوص یادگیری عمیق کار را برای محققین جهت تشخیص و شناسایی سریع و دقیق آفات، بیماری و علف‌های هرز هموارتر کرده است [۳]. علی‌رغم ارائه تحقیقات مختلف و پیشرفت‌های حاصل شده در زمینه تشخیص و شناسایی بیماری محصولات صیفی به کمک روش‌های سنتی نظیر یادگیری ماشین و پردازش تصویر [۴]، این روش‌ها دارای معایب مختلفی می‌باشند. از معایب این نوع روش‌ها می‌توان به زمان‌بر بودن آنها به دلیل روش چند مرحله‌ای که نیاز به مهندسی ویژگی‌ها و داده‌های پیچیده دارد، دقت طبقه‌بندی کم و تشخیص مشکل در تصاویر با پس‌زمینه‌های پیچیده و چالش برانگیز اشاره نمود [۵]. طرحواره کلی مراحل تشخیص و طبقه‌بندی 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 الگوریتم‌های متعدد در این حوزه است و براساس نیاز مسئله مستلزم پیاده‌سازی می‌باشد. به‌عنوان مثال برای

⁵ Radial Basis Function

⁶ Polynomial

⁷ Sigmoid

¹ Histogram

² Clustering

³ Watershed

⁴ Support Vector Machine

مقدار دقت برای داده‌های آزمایشی برای سه نوع مختلف بیماری برابر با ۶۶/۷، ۷۵ و ۶۶/۷ بود.

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 لوبنرگ مارکوات^۱ برای الگوریتم آموزشی نیز استفاده گردید. مقدار میانگین مربعات خطا^۲ 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 به خصوص 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^۳ 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 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 تصویر 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^۴ هرچه بهتر مدل خواهد گردید. شکل ۲ تناسب آموزش شبکه و تعداد داده در یادگیری ماشین و یادگیری عمیق را نشان می‌دهد [۱۲].

⁴ Generalization

¹ Levenberg-Marquardt

² Mean squared error


³ Transfer learning

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^۲ شود. در حالیکه که هدف از آموزش شبکه، شناسایی و طبقه‌بندی در شرایط بسیار متنوع از لحاظ جهت، موقعیت، مقیاس، روشنایی و غیره است. بنابراین برای این منظور از روش‌های مطرح داده‌افزایی به صورت آنلاین^۳ 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 به‌صورت 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 به‌صورت 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، به‌طور 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^۴

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



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

در این تحقیق از مجموعه تصاویر برگ خیار موجود در بستر کگل^۱ 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٪ برای آموزش و ۳۰٪ برای آزمون انتخاب شد. این روش به‌دلیل توزیع متناسب کلاس‌ها در داده‌های آموزش و آزمون، کاهش نیاز به منابع محاسباتی و عملکرد پایدار مدل بر روی داده‌های آزمون به‌کار 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 به‌همراه برچسب مربوط به هر کدام نشان داده شده است.




شکل ۳- دسته‌ای از تصاویر آموزشی به همراه برچسب آنها

³ Online Augmentation

⁴ ResNet-101

¹ Kaggle

² Overfitting



شکل ۴- ساختار و نحوه عملکرد شبکه موبایل نت نسخه ۳

۳-۲ آموزش و پیکربندی شبکه‌ها

پیکربندی شبکه‌های عصبی ذکر شده با استفاده از زبان برنامه‌نویسی پایتون و چهارچوب کاری محبوب و منبع باز پایتورچ صورت گرفت. در این تحقیق، از نسخه‌های پیش‌آموزش‌شده شبکه‌های موبایل نت ۳ و رزنت ۱۰۱ بر روی مجموعه داده ImageNet [۲۰] استفاده شد. این شبکه‌ها به عنوان نقطه شروع برای یادگیری انتقالی^۵ مورد استفاده قرار گرفتند، و لایه‌های انتهایی آن‌ها برای مسئله خاص تشخیص و طبقه‌بندی برگ محصول خیار تنظیم شدند. به عنوان مثال، لایه‌های تماماً متصل^۶ برای دسته‌بندی کلاس‌های جدید جایگزین شدند. این کار تأثیر قابل توجهی در کاهش زمان آموزش و بهبود دقت مدل‌ها داشته است. علت اصلی استفاده از شبکه‌های پیش‌آموزش داده شده بر روی مجموعه داده‌های مختلف و مدنظر در حوزه یادگیری عمیق به سبب همگرایی سریع‌تر این نوع شبکه‌ها می‌باشد [۲۱].

مجموعه تصاویر برگ خیار برچسب گذاری شده به عنوان ورودی برای آموزش این شبکه‌ها استفاده شدند. آموزش

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 شبکه‌های هم‌نوع نظیر ۳۴ و ۵۰ لایه در تعداد ماژول‌ها و لایه‌های استفاده شده در ساختار آن است که این کار با هدف استخراج ویژگی‌ها بیشتر از تصویر ارائه شده است.

۲-۲-۲ موبایل نت نسخه ۳

موبایل نت، یک شبکه پیچشی کم عمق می‌باشد که با هدف استفاده برای موبایل‌ها و سامانه‌های تعبیه شده^۲ ارائه شده است. نسخه اولیه آن توسط تیمی از شرکت گوگل در سال ۲۰۱۷ مطرح شد و سپس مورد استفاده قرار گرفت [۱۷]. اساس کار این نوع شبکه‌ها Depth-wise Separable Convolution است. این شبکه از پیچش به منظور کاهش بار محاسبات از دو لایه با نام‌های پیچش عمقی^۳ و پیچش نقطه^۴ به جای پیچش استاندارد و معمولی استفاده می‌کند. نسخه سوم این شبکه نیز بر همین اساس در کنار برخی تغییرات از قبیل حذف لایه‌های با پارامترهای آموزشی زیاد و سنگین و استفاده از تابع غیرخطی h-swish به جای در ReLU در برخی از لایه‌های پیچشی، ارائه شد.

با توجه به هدف مورد نیاز آموزش شبکه از نظر منابع مورد استفاده، شبکه موبایل نت نسخه ۳ در دو معماری کوچک و بزرگ مطرح شد. شکل ۴ ساختار کلی و نحوه عملکرد مربوط به شبکه موبایل نت نسخه ۳ کوچک و بزرگ را نشان می‌دهد با این تفاوت که معماری کوچک آن ۴ لایه کمتر از معماری بزرگ می‌باشد [۱۹، ۱۸].

⁴ Pointwise convolution

⁵ Transfer Learning

⁶ Fully Connected Layers

¹ MobileNetV3

² Embedded systems

³ Depthwise convolution

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	$\frac{precision \times recall}{precision + recall} \times 2$

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

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

برای طبقه‌بندی برگ خیار نشان داده شده است. با توجه به نتایج حاصل شده، هر دو شبکه عملکرد مطلوبی را از خود نشان داده‌اند.

شبکه‌ها نیز در ابزار محبوب تحت‌وب تجزیه تحلیل داده و یادگیری ماشین گوگل کولب^۱ صورت گرفت. علاوه بر این، آموزش شبکه‌ها توسط منبع محاسباتی گرافیکی رایگان NVIDIA Tesla T4-16GB موجود در محیط کولب انجام شد. در این فرایند از قابلیت‌های پیش‌فرض پردازش موازی پلتفرم برنامه‌نویسی CUDA[®] نسخه ۱۲ برای بهره‌گیری از توان پردازشی بالا و بهینه‌سازی زمان آموزش شبکه‌ها استفاده شده است. لازم به ذکر است که در این پژوهش، تکنیک خاصی برای سفارشی‌سازی یا موازی‌سازی کدها ارائه نشده و تمرکز بر استفاده از قابلیت‌های موجود در معماری CUDA برای افزایش کارایی بوده است. برای آموزش و کنترل هرچه بهتر شبکه‌ها از نظر خطا و دقت آموزش، برخی مولفه‌ها باید تعیین و استفاده شوند. اتخاذ این نوع مولفه‌ها متناسب با نیاز مسئله و با بررسی عملکرد شبکه در طول آموزش توسط مهندس طراح تعیین و استفاده می‌گردد. در علم یادگیری عمیق به این نوع مولفه‌ها، هایپرپارامتر^۲ 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 ^۳	۱۰۰
داده‌های ورودی هر دوره ^۴ (دسته)	۱۰۰
تابع بهینه‌ساز ^۵	SGD (Stochastic Gradient Descent)
مومنوم ^۶	۰/۹
نرخ آموزش ^۷	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



^۵ Optimization function^۶ Momentum^۷ Learning rate^۱ Google Colab^۲ Hyper-parameter^۳ Training epochs^۴ Batch-size

جدول ۳-مقادیر معیار ارزیابی شبکه ها

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



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




شکل ۶-نمودارهای اتلاف و صحت آموزش شبکه موبایل نت نسخه ۳

با وجود اینکه رژنت ۱۰۱ فراخوانی بالاتری (۱۰۰٪) نسبت به موبایل نت ۳ (۹۹.۲٪) دارد، مدل موبایل نت 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 می دهد که موبایل نت ۳، با وجود سبک تر بودن معماری، توانسته عملکردی تقریباً مشابه و حتی بهتر از رژنت ۱۰۱ در اکثر معیارها ارائه دهد. سبک وزن بودن موبایل نت ۳ به دلیل طراحی بهینه آن، مانند استفاده از تکنیک های ذکر شده، باعث کاهش تعداد پارامترها و هزینه محاسباتی شده است. این ویژگی ها، موبایل نت ۳ را به گزینه ای مناسب برای کاربردهای کشاورزی هوشمند و سیستم های مبتنی بر اینترنت اشیا تبدیل می کند، جایی که منابع محاسباتی محدود هستند. در مجموع، این مدل نه تنها دقت بالایی ارائه می دهد، بلکه با بهینه سازی منابع محاسباتی، امکان استفاده در دستگاه های کم قدرت و کاربردهای تعبیه شده را نیز فراهم می کند.


فرآیند آموزش هر دو معماری در ۱۰۰ دوره صورت گرفت. شکل ۵ شکل ۶ به ترتیب نمودارهای مربوط به اتلاف و دقت آموزش شبکه رژنت ۱۰۱ لایه و موبایل نت نسخه ۳ را ارائه می کند. بررسی نمودارها نشان می دهد رفتار اتلاف و دقت آموزش و آزمایش مربوط به شبکه موبایل نت 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 رژنت ۱۰۱ لایه، رفتار نمودارها دارای نوسان زیاد بوده و از همگرایی کمتری برخوردار است.

علت این نتیجه می تواند از متناسب نبودن تعداد داده ها با عمق و پارامترهای آموزشی شبکه باشد. علاوه بر این، آموزش شبکه های کم عمق نظیر موبایل نت نسخه ۳ عموماً مصرف کمتر منابع محاسباتی را دارند که باعث می شود به داده های کمتری نیاز داشته باشند و برای آموزش سریع تر باشند. بنابراین شبکه های کم عمق برای سناریوهایی با منابع محاسباتی محدود مناسب تر هستند. رفتار نمودارها نشان دهنده کافی بودن ۱۰۰ دوره برای آموزش شبکه ها در این تحقیق می باشد.



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

شکل ۷ نشان دهنده ماتریس درهم ریختگی^۱ هر دو 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^۳ توانسته است ۱۲۱ نمونه بیمار را به درستی شناسایی کند (مثبت صادق^۲) و تنها ۱ نمونه بیمار را به اشتباه سالم پیش‌بینی کرده است (منفی کاذب^۳). همچنین، از میان نمونه‌های سالم، ۹۸ نمونه به درستی شناسایی شده‌اند (منفی صادق^۴) و تنها ۲ نمونه سالم به اشتباه بیمار تشخیص داده شده‌اند (مثبت کاذب^۵). 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 منفی در کاربردهای عملی داشته باشد، خصوصاً در سناریوهایی که هزینه خطا در تشخیص نادرست نمونه‌های سالم بالاست.

⁴ True negative

⁵ False positive

¹ Confusion matrix

² True positive

³ False Negative

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 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 موبایل نت عملیات شناسایی و طبقه‌بندی را تا چند برابر سریع تر می‌کند. استفاده از شبکه‌های عمیق تر وابستگی عملیات طبقه‌بندی به سیستم پردازشی رده بالا را افزایش می‌دهد که منجر به تولید هزینه‌های محاسباتی زیادی می‌شود. معماری موبایل نت نسخه ۳ با صحت ۹۸/۶۴ درصد، به عنوان معماری مطلوب برای شناسایی و طبقه‌بندی برگ سالم از ناسالم محصول خیار معرفی شد.

اختصاص برچسب و دخالت دادن نوع بیماری در طبقه‌بندی، طراحی سخت افزار مناسب جهت آزمایش شبکه‌ها به صورت زمان واقعی^۱، 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.

¹ Real-time

مراجع

- [۱] Gao, X. (2025). The Application of Computer Vision Technology in the Field of Agricultural Automation. *International Journal of Advance in Applied Science Research*, 4(1), 1-5.
- [۲] زارع نظری، سرداری زارچی، عمادی، پورمحمدی & هادی. (۲۰۲۲). چارچوبی برای استخراج آناتومی و طبقه بندی تصاویر پشه با رویکرد یادگیری عمیق. *مدل سازی در مهندسی*. 20(70), 107-120.
- [۳] Wang, S., Xu, D., Liang, H., Bai, Y., Li, X., Zhou, J., ... & Wei, W. (2025). Advances in Deep Learning Applications for Plant Disease and Pest Detection: A Review. *Remote Sensing*, 17(4), 698.
- [۴] Lee, W. B., & Kim, B. H. (2024). Machine learning innovations for precise plant disease detection: A review. *Legume Research*, 47(10), 1633-1638.
- [۵] Liu J, Wang X. "Tomato diseases and pests detection based on improved Yolo V3 convolutional neural network", *Frontiers in plant science*, 16, 11.898, Jun 2020.
- [۶] Dhingra G, Kumar V, Joshi HD. "Study of digital image processing techniques for leaf disease detection and classification", *Multimedia Tools and Applications*, 77, August 2018, pp.19951-20000.
- [۷] Jian Z, Wei Z. "Support vector machine for recognition of cucumber leaf diseases", In 2010 2nd international conference on advanced computer control, Vol. 5, 27 March 2017, pp. 264-266. IEEE.
- [۸] Hosseini H, Mohmmadzamani D, Arbab A. "A recognition system to detect Powdery Mildew and Anthracnose fungal disease of cucumber leaf using image processing and artificial neural networks technique", *Plant Protection (Scientific Journal of Agriculture)*, 40.4, 22 December 2017, pp.15-28.
- [۹] Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M., & Parmar, M. (2024). A review of convolutional neural networks in computer vision. *Artificial Intelligence Review*, 57(4), 99.
- [۱۰] Simonyan K, Zisserman A. "Very deep convolutional networks for large-scale image recognition", arXiv preprint arXiv, 1409.1556, 4 September 2014.
- [۱۱] Ghosal, S. and Sarkar, K., 2020, February. "Rice leaf diseases classification using CNN with transfer learning", In 2020 IEEE Calcutta Conference (CALCON), pp. 230-236. IEEE.
- [۱۲] Alom MZ, Taha TM, Yakopcic C, Westberg S, Sidike P, Nasrin MS, Hasan M, Van Essen BC, Awwal AA, Asari VK. "A state-of-the-art survey on deep learning theory and architectures", *electronics*, 8.3,292, March 2019.
- [۱۳] Reitermanova, Z. (2010, June). Data splitting. In *WDS* (Vol. 10, pp. 31-36). Prague: Matfyzpress.
- [۱۴] Islam MM, Hossain MB, Akhtar MN, Moni MA, Hasan KF. "CNN based on transfer learning models using data augmentation and transformation for detection of concrete crack", *Algorithms*, 15, 15.8, 287, 15 August 2022.
- [۱۵] Tang, Z., Gao, Y., Karlinsky, L., Sattigeri, P., Feris, R., & Metaxas, D. (2020). OnlineAugment: Online data augmentation with less domain knowledge. In *Computer Vision–ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part VII 16* (pp. 313-329). Springer International Publishing.

- [۱۶] He K, Zhang X, Ren S, Sun J. "Deep residual learning for image recognition", In Proceedings of the IEEE conference on computer vision and pattern recognition, 2016 , pp. 770-778.
- [۱۷] Howard AG, Zhu M, Chen B, Kalenichenko D, Wang W, Weyand T, Andreetto M, Adam H. "Mobilenets: Efficient convolutional neural networks for mobile vision applications", arXiv preprint arXiv:1704.04861. 17 April 2017.
- [۱۸] Howard, A., Sandler, M., Chu, G., Chen, L.C., Chen, B., Tan, M., Wang, W., Zhu, Y., Pang, R., Vasudevan, V. and Le, Q.V., 2019. "Searching for mobilenetv3", In Proceedings of the IEEE/CVF international conference on computer vision, pp. 1314-1324.
- [۱۹] Qian, S., Ning, C. and Hu, Y. "MobileNetV3 for image classification", In 2021 IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE), March 2021, pp. 490-497. IEEE.
- [۲۰] Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., & Fei-Fei, L. (2009, June). Imagenet: A large-scale hierarchical image database. In *2009 IEEE conference on computer vision and pattern recognition* (pp. 248-255). Ieee.
- [۲۱] Oquab M, Bottou L, Laptev I, Sivic J. "Learning and transferring mid-level image representations using convolutional neural networks", In Proceedings of the IEEE conference on computer vision and pattern recognition, 2014, pp. 1717-1724.