

استفاده از یادگیری عمیق در تشخیص خودکار بیماری گیاهان بر اساس پردازش تصویر برگ

رویا راد^{۱*}، محمد موسوی^۲ و فاطمه وردی^۳

۱، ۲ و ۳- به ترتیب: استادیار؛ کارشناسی ارشد؛ و استادیار گروه مهندسی کامپیوتر و IT، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی، واحد پرند، تهران، ایران
تاریخ دریافت: ۹۸/۱۰/۳۰؛ تاریخ پذیرش: ۹۹/۴/۲

چکیده

تشخیص سریع بیماری‌های گیاهان همواره از چالش‌های مهم صنعت کشاورزی بوده است. یکی از رویکردهایی که در این زمینه مورد استقبال واقع شده، استفاده از روش‌های پردازش تصویر است. مزیت این روش‌ها در خودکار، سریع، کم‌هزینه، غیرتخریبی و دقیق بودن آنهاست. در این پژوهش، با پردازش تصویر برگ گیاهان و محصولات کشاورزی، ضمن تشخیص گیاهان سالم از ناسالم، نوع و شدت بیماری آنها نیز به صورت خودکار تشخیص داده می‌شود. برای این کار از روش‌های مبتنی بر یادگیری عمیق شامل چندین معماری مختلف از شبکه‌های عصبی پیچشی به همراه دسته‌بند ماشین بردار پشتیبان استفاده شده است. روش پیشنهادی در این پژوهش قابل تعمیم به گیاهان و محصولات مختلف و همین‌طور به چندین گیاه به طور همزمان است. شبکه‌های طراحی شده با استفاده از دو زیرمجموعه متفاوت از تصاویر مجموعه داده Plant Village آموزش داده شد و مورد ارزیابی قرار گرفت. در زیرمجموعه اول که مربوط به تشخیص بیماری درخت سیب در چهار کلاس مختلف بود، دقت ۹۵ درصد و در زیرمجموعه دوم که مربوط به چهار گیاه مختلف و در ۱۰ دسته بود، دقت ۹۶/۸ درصد به دست آمد. نتایج ارزیابی نشان داد ترکیب دسته‌بند ماشین بردار پشتیبان با شبکه‌های یادگیری عمیق، دقت تشخیص بیماری گیاهان را بهبود می‌بخشد.

واژه‌های کلیدی

دسته‌بندی، سامانه‌های کشاورزی، شبکه‌های عصبی پیچشی، یادگیری ژرف

مقدمه

آزمایشگاهی استفاده می‌شود. روش‌های سنتی مبتنی بر نیروی انسانی مشکلاتی را به همراه دارد از جمله اینکه زمان‌بر است، به آموزش و تربیت کارشناسان نیاز دارد و نظارت مداوم آنان بر محصولات را می‌طلبد. روش‌های آزمایشگاهی دقت بالایی دارند اما باعث تخریب گیاه می‌شوند و هزینه بالایی دارند. در مقابل، استفاده از روش‌های مکانیزه برای تشخیص بیماری گیاهان غیرمخرب و سریع

صنعت کشاورزی نیز مانند سایر صنایع چالش‌های مربوط به خود را دارد. بیماری‌های گیاهان باعث وارد کردن خسارات به کشاورزان، کاهش تولید محصول و ایجاد اختلال در چرخه غذایی و صنعت می‌شود. در حال حاضر برای تشخیص و دسته‌بندی این بیماری‌ها اغلب از روش‌های سنتی بازدید چشمی یا بررسی

است و نیاز به تخصص زیادی ندارد.

در این پژوهش با استفاده از تکنیک‌های هوش مصنوعی^۱ مبتنی بر پردازش تصویر و الگوریتم‌های یادگیری عمیق^۲، بیماری‌های گیاهان^۳ را تشخیص دادیم و آنها را دسته‌بندی کردیم تا با تشخیص به موقع و دقیق، سبب کاهش نیاز به نیروی خیره انسانی، تخریب کمتر، صرف انرژی و هزینه کمتر، کاهش تلفات و بهبود کیفیت محصولات کشاورزی شویم.

پژوهش‌هایی که تا کنون روی تصویر گیاهان صورت گرفته بیشتر در مورد دسته‌بندی نوع گیاه بوده و تعداد پژوهش‌ها برای تشخیص بیماری گیاه اندک است. در میان این پژوهش‌های اندک، طرز برخورد با مسأله یا به صورت دو دسته‌ای، تنها برای تشخیص گیاه بیمار از گیاه سالم یا به صورت چند دسته‌ای، برای تشخیص انواع بیماری مربوط به یک نوع گیاه بوده است. همچنین، روش‌های مورد استفاده در این پژوهش‌ها اغلب به صورت الگوریتم‌های قدیمی و شهودی، مانند قطعه‌بندی^۴ و لبه‌یابی لکه‌های بیمار از روی تصویر برگ بوده است. این روش‌ها معمولاً از هر گیاه به گیاه دیگر و از هر بیماری به بیماری دیگر متفاوت‌اند، علاوه بر آن برای ترکیبی از گیاهان مناسب نیستند. در حالی که می‌توان گفت که روش پیشنهادی در این پژوهش برای انواع مختلف گیاهان و ترکیبی از آنها قابل توسعه است.

یادگیری عمیق یا یادگیری ژرف، زیرشاخه‌ای است از یادگیری ماشین و بر مبنای مجموعه‌ای از الگوریتم‌های مبتنی بر شبکه عصبی با تعداد زیادی لایه‌های پنهان. انگیزه نخستین در به وجود آوردن

الگوریتم‌های شبکه عصبی و یادگیری عمیق از ساختار عصبی در مغز انسان الهام گرفته شده است که در آن یاخسته‌های عصبی با فرستادن پیام به یکدیگر، درک را امکان‌پذیر می‌کنند. الگوریتم‌ها در تلاش هستند ویژگی‌های انتزاعی سطح بالا در مجموعه داده‌ها را با استفاده از یک گراف عمیق مدل کنند که دارای چندین لایه پردازشی و متشکل از چندین لایه تبدیلات خطی و غیر خطی هستند. ویژگی‌هایی که از شبکه‌های مبتنی بر یادگیری عمیق استخراج می‌شود، نسبت به ویژگی‌های متداولی مانند لبه، SIFT^۵، BoW^۵، (Ng & Henikoff, 2003) هیستوگرام رنگ از نظر معنا سطح بالاتری دارند و نزدیک‌تر به درک انسان محسوب می‌شوند، بنابراین، استفاده از آنها در دسته‌بندی منجر به نتایج مطلوب‌تری می‌شود. برای مثال، شبکه عمیق مبتنی بر تصاویر چهره ممکن است منجر به استخراج ویژگی‌های معناداری مانند شکل‌های چشم، بینی، فاصله ابروها و غیره شود. یکی از انواع شبکه‌های مبتنی بر یادگیری عمیق، شبکه عصبی پیچشی^۶ (CNN) است که به خصوص در حوزه پردازش تصویر نتایج بسیار خوبی ارائه کرده است. با توجه به قدرت فوق‌العاده یادگیری عمیق و دسته‌بند ماشین بردار پشتیبان^۷ یا SVM به طور مجزا، انتظار می‌رود با ترکیب این دو الگوریتم، بتوان به دقت بالاتری در تشخیص رسید که نتایج این پژوهش نیز همین نظریه را ثابت می‌کند.

در ادامه چندین پژوهش در زمینه تشخیص خودکار بیماری گیاهان بررسی شده است. پیمان و همکاران (Peyman et al., 2016) به تشخیص بیماری‌های سطح برگ برنج شامل دو

1- Artificial Intelligence

3- Plant Diseases

5- Bag-of-words

7- Support Vector Machine (SVM)

2- Deep Learning

4- Segmentation

6- Convolutional Neural Networks

قاسمی ورجانی و همکاران (Ghasemi et al., 2018) در پژوهشی یک مدل ترکیبی شبکه عصبی را به منظور تشخیص سه بیماری برگ درخت سیب (بیماری‌های لکه سیاه سیب، آلترناریا و آفت مینوز) از روی تصویر برگ آنها ارائه دادند. در این پژوهش برای آموزش شبکه از دو الگوریتم بهینه‌سازی ازدحام ذرات (PSO) و الگوریتم لونیبرگ مارکوارت (LM) استفاده شد. دقت این سامانه در تشخیص بیماری فوق‌الذکر ۹۹ درصد گزارش شده است.

در پژوهشی، چانلی و همکاران (Chuanlei et al., 2017) سه بیماری سفیدک پودری، زنگ و بیماری ویروس موزائیک، از بیمارگرهای برگ سیب را شناسایی و تشخیص دادند. در این تحقیق از الگوریتم‌های شبکه عصبی استفاده شد. در این پژوهش بیماری‌ها با دقت ۹۰ درصد به درستی تشخیص داده شدند.

عبودی (Oboudi, 2015) به کمک پردازش تصویر به تشخیص نشانه‌های ویروس آبله‌ای شدن برگ یا بیماری موزائیک خیار^۱ پرداخت. از این تصاویر ۳۱ ویژگی رنگی استخراج شد. به منظور دسته‌بندی گیاهان سالم از گیاهان دارای نشانه‌های موزائیکی، از شبکه عصبی مصنوعی استفاده شد که ورودی آن، ویژگی‌های استخراج شده از مرحله قبل بود. به منظور آموزش شبکه، از تابع آموزش Trainscg^۲ و از تابع آستانه‌گذاری سیگموئید^۲ برای لایه میانی و لایه خروجی استفاده شد. دقت گزارش شده در این پژوهش ۱۰۰ درصد بود.

حسینی و همکاران (Hosseini et al., 2018) در پژوهش خود به ارائه سامانه تشخیص بیماری قارچی سفیدک پودری و آنتراکنوز برگ خیار با تکنیک پردازش تصویر و شبکه عصبی مصنوعی

بیماری مهم لکه قهوه‌ای و بلاست برگ برنج پرداختند. آنها با پردازش تصویر برگ‌های گیاه برنج آلوده، لکه‌های ظاهری قسمت‌های آلوده از سطح برگ را جداسازی کردند. برای این کار ویژگی‌های شکلی مانند گردی، نسبت ظاهری، فشردگی و نسبت سطح قسمت‌های آلوده مربوط به بیماری لکه قهوه‌ای و بلاست برگ برنج از تصاویر سیاه و سفید برگ‌های آلوده استخراج، بررسی، و نشان داده شد که الگوریتم ارائه شده می‌تواند نقاط آلوده را با دقت ۹۷/۴ درصد تشخیص دهد.

اسلام و همکاران (Islam et al., 2017) با تکنیک جداسازی و همچنین دسته‌بند SVM در تحقیقی شدت بیماری برگ سیب‌زمینی را بررسی کردند. در این تحقیق، ابتدا با استفاده از برخی تکنیک‌های پردازش تصویر مانند جداسازی تصویر و اعمال کردن فیلترهایی برای بالا بردن دقت تشخیص و آنالیز فراوانی رنگی L^*a^*b ، ویژگی‌های تصاویر استخراج شد و پس از آن گیاهان به سه دسته کلی دسته‌بندی شدند: گیاهان با شدت بیماری زیاد، گیاهان با شدت بیماری کم، و گیاهان سالم. میانگین دقت تشخیص برای این سه دسته برابر با ۹۵ درصد به دست آمد.

روش پیشنهادی ژانگ و همکاران (Zhang et al., 2017) برای تشخیص هفت بیماری خیار شامل سه مرحله بود. در مرحله اول از روش خوشه‌بندی برای قطعه‌بندی برگ‌های گیاه بیمار استفاده شد، مرحله دوم شامل استخراج ویژگی‌های شکل و رنگ بود و در آخرین مرحله برگ‌ها به روش نمایش تنک دسته‌بندی شدند. آنها با این روش توانستند هفت بیماری خیار را با دقت میانگین ۸۵/۷ درصد پیش‌بینی کنند.

1- Cucumber Mosaic Virus

2- Sigmoid

پیشنهادی از لحاظ دقت و هزینه آموزش و با دقت ۹۹ درصد شناسایی شد.

دورماس و همکاران (Durmuş *et al.*, 2017) با الگوریتم‌های مبتنی بر یادگیری عمیق توانستند تعدادی از بیماری‌های گوجه‌فرنگی را تشخیص دهند و دسته‌بندی کنند. در این تحقیق از حدود ۱۸۰۰۰ عکس گوجه‌فرنگی و نیز از تکنیک‌های پردازش تصویر و معماری AlexNet و همچنین SqueezeNet تشخیص بیماری گوجه‌فرنگی و جداسازی محصولات سالم و ناسالم استفاده شد. این محققان ۹ کلاس مختلف از آفت و بیماری گوجه‌فرنگی شامل بیماری‌های لکه باکتریایی، لکه مویی، بیماری بادزدگی، کپک برگ، لکه سپتوریا، لکه هدف، کنه تار عنکبوتی، ویروس موزائیک و بیماری ویروسی برگ پیچیدگی زرد و یک کلاس هم به عنوان کلاس گوجه‌فرنگی سالم در نظر گرفتند که در نهایت با دقت ۹۷/۲ درصد موفق به دسته‌بندی شدند.

سوریواتی و همکاران (Suryawati *et al.*, 2018) در پژوهشی به بررسی بیماری‌های گوجه‌فرنگی پرداختند که در آن از معماری‌های AlexNet، VGGNet و GoogleNet استفاده کردند. این محققان سرانجام معماری VGGNet را به عنوان بهترین و دقیق‌ترین معماری‌ها برگزیدند. همچنین یک معماری ساده با دو لایه پیچشی نیز با دقت متوسط ارائه دادند. در این پژوهش نیز از مجموعه داده Plant Village استفاده شد. بهترین دقتی که در این پژوهش برای تشخیص بیماری گوجه‌فرنگی گزارش شده برابر با ۹۵/۲۴ درصد بود.

وانگ و همکاران (Wang *et al.*, 2017) در مقاله‌ای به بررسی شدت بیماری گوجه‌فرنگی پرداختند، این دسته‌بندی شامل برگ گوجه‌فرنگی سالم، کمی خراب، خراب، و کاملاً خراب بود. در این

پرداختند. مراحل پردازش تصویر شامل چهار قسمت بود: (۱) جمع‌آوری تصاویر، (۲) پیش‌پردازش، (۳) بررسی تصاویر تسهیل شده در دو فضای رنگی HSV و $L^* a^* b^*$ و انتخاب بهترین مولفه رنگی به منظور طبقه‌بندی و استخراج نواحی آسیب‌دیده برگ، (۴) استخراج خواص بافت نواحی آلوده سطح برگ با استفاده از ماتریس در هم ریختگی^۱. این محققان از شبکه عصبی مصنوعی با الگوریتم پس انتشار خطا و تابع آموزشی لونبرگ مارکورات LM استفاده و دسته‌بندی بیماری گیاهان را با توجه به دو فاکتور دقت و زمان روی آن ارزیابی کردند. مدل ارائه شده طی ۶ ثانیه با دقت ۹۹/۹۶ درصد این دو بیماری را تشخیص داد.

لیو و همکاران (Liu *et al.*, 2018) برای تشخیص چهار بیماری از درخت سیب شامل لکه برگ آلترناریایی^۲، زنگ، موزائیک و لکه قهوه‌ای به پژوهش پرداختند و در آن از روش‌های یادگیری عمیق و شبکه AlexNet استفاده کردند و ایده کار بر کاهش پارامترهای مدل در این شبکه به منظور افزایش میزان همگرایی و دقت بیشتر بنا شده بود. شبکه طراحی شده در این مقاله توانست بیماری‌های سیب را با دقت ۹۷/۶۲ درصد پیش‌بینی کند.

کروز و همکاران (Cruz *et al.*, 2019) به تشخیص بیماری زردی انگور با استفاده از هوش مصنوعی پرداختند. در این پژوهش یک سیستم جدید با استفاده از شبکه‌های عصبی پیچشی برای تشخیص این بیماری در انگور با استفاده از تصاویر رنگی از برش‌های برگ ارائه شد. در این پژوهش ۶ معماری شبکه عصبی AlexNet، GoogleNet، InceptionV3، ResNet50، ResNet101 و SqueezeNet ارزیابی و مقایسه شدند که در بین آنها معماری ResNet50 بهترین نوع از معماری‌های

ویژگی‌های به دست آمده، تصاویر به روش SVM دسته‌بندی شدند.

ارزیابی: در انتها نتایج به دست آمده ارزیابی و با روش‌های دیگر مقایسه شدند.

در ادامه جزئیات هر مرحله ارائه شده است.

مرحله اول - آماده‌سازی تصاویر

وسایت Plant village متعلق به دانشگاه پنسیلوانیا است؛ این دانشگاه هر ساله از کارشناسان دعوت می‌کند تا با حضور خود در جلساتی درباره «دسته‌بندی بیماری‌ها» بحث کنند که خود به نوعی بیانگر اهمیت موضوع ترکیب کشاورزی و علوم کامپیوتری است. به همین منظور مجموعه داده‌ای با دسترسی آزاد^۱ و مناسب برای شناسایی بیماری گیاهان از روی تصاویر برگ‌ها تهیه کرده است. در این پژوهش نیز به منظور تمرکز بیشتر بر روش‌ها و مقایسه عادلانه نتایج با روش‌های دیگر در شرایط مشابه، از همین مجموعه داده استفاده شده است. این مجموعه داده بزرگ‌ترین و معتبرترین مجموعه داده در خصوص محصولات کشاورزی و بیماری‌های آنها است و بسیاری از مقالات معتبر از همین مجموعه استفاده کرده‌اند. شکل ۱ نمونه‌ای از برگ‌های مجموعه داده Plant Village را نشان می‌دهد.

در این مجموعه داده بیش از ۵۰۰۰۰ تصویر در ۳۸ دسته مختلف وجود دارد. از این مجموعه داده دو زیرمجموعه انتخاب شده است.

زیرمجموعه تصاویر اول به منظور مقایسه رویکرد پیشنهادی با نتایج مقاله وانگ و همکاران (Wang et al., 2017) و مشابه با آن مقاله انتخاب شد. این زیرمجموعه شامل تعدادی تصویر برگ سالم درخت سیب و تصاویر پوسیدگی سیاه برگ سیب ناشی از قارچ *Botryosphaeria obtusa* است.

پژوهش از معماری‌های VGG16، VGG19، Inception V3 و ResNet استفاده شد که به دقتی از ۸۰ تا ۹۰/۴ درصد رسیدند. بهترین عملکرد را معماری VGG16 با دقت ۹۰/۴ درصد ارائه داد.

پژوهش‌های فوق هر یک در زمینه تشخیص بیماری یک نوع گیاه بوده است. در این پژوهش ضمن ارائه روشی برای بیشتر کردن دقت تشخیص برای بیماری یک گیاه (درخت سیب)، امکان تشخیص شدت بیماری و همچنین تعیین نوع بیماری چندین گیاه (سیب، ذرت، توت‌فرنگی و گوجه‌فرنگی) به طور نیز هم‌زمان بررسی شده است.

مواد و روش‌ها

در این بخش روش پیشنهادی برای شناسایی به موقع بیماری‌های گیاهان با کمک تصاویر برگ‌های آنها شرح داده می‌شود. الگوریتم شامل چند مرحله است که این مراحل به اختصار شامل موارد زیر می‌شوند:

آماده‌سازی تصاویر: در ابتدا تصاویر لازم برای آموزش و آزمایش در شبکه‌های عصبی عمیق، آماده شدند.

پیش‌پردازش: هدف کلی در این مرحله حذف مولفه‌های غیرضروری (حذف نویز و تصویر زمینه) و بهبود کیفیت تصاویر بود که با استفاده از تکنیک‌های پردازش تصویر صورت گرفت.

استخراج ویژگی‌ها: این مرحله مربوط به استخراج ویژگی‌های سطح بالا از تصاویر ورودی است. برای این کار معماری‌های مختلف شبکه‌های یادگیری عمیق، طراحی و پارامترهای مناسب برای آنها تنظیم شد. پس از آن تصاویر به شبکه‌ها وارد و ویژگی‌های آنها از لایه‌های انتهایی استخراج شد.

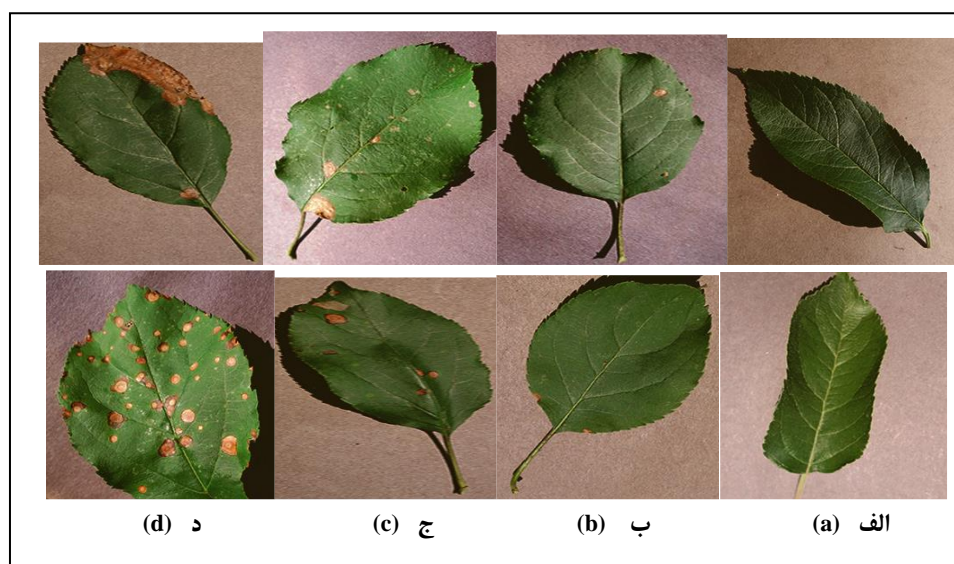
تشخیص/دسته‌بندی: در این مرحله با استفاده از

مانند وانگ و همکاران (Wang *et al.*, 2017)، تصاویر به صورت دستی با توجه به شدت بیماری به چهار مرحله تقسیم شدند: مرحله سالم، مرحله اولیه، مرحله میانی و مرحله نهایی. برگ‌های سالم عاری از لکه‌اند. برگ‌های مرحله اولیه دارای نقاط کوچک دایره‌ای به قطر کمتر از ۵ میلی‌متر، برگ‌های مرحله میانی دارای بیش از ۳ نقطه با حداقل یک نقطه قورباغه‌ای به شکل نامنظم‌اند و برگ‌های مرحله نهایی آنقدر آلوده‌اند که در شرف سقوط از درخت به نظر می‌رسند. دو نمونه از هر مرحله از این تصاویر در شکل ۲ قابل مشاهده است.



شکل ۱- نمونه تصاویر برگ‌های مجموعه داده PlantVillage

Figure 1- Sample images of PlantVillage dataset



شکل ۲- نمونه‌ای از تصاویر زیرمجموعه اول (برگ درخت سیب) با توجه به شدت بیماری پوسیدگی سیاه: الف) سالم، ب) در مرحله اولیه بیماری، ج) در مرحله میانی، د) در مرحله نهایی

Fig. 2 - An example of the images of the first subset (apple tree leaf) according to the severity of black rot disease: a) healthy, b) early stage, c) middle stage, d) final stage

تصاویری از دو بیماری پوسیدگی سیاه^۱ و لکه سیاه^۲ برای درخت سیب، دو بیماری سرکوسپورا^۳ و برگ بادبزی شمالی^۴ برای ذرت، بیماری سوختگی برگ اسکورچ برای توت‌فرنگی^۵ و بیماری سپتوریا^۶ برای گوجه‌فرنگی است.

نمونه‌ای از تصویر هر دسته از این زیرمجموعه پس از حذف تصویر زمینه در شکل ۳ مشاهده می‌شود.

زیرمجموعه تصاویر دوم باز هم از میان مجموعه تصاویر Plant Village به منظور نشان دادن قابلیت سیستم پیشنهادی برای تشخیص همزمان بیماری چندین گیاه مختلف انتخاب شد. این زیرمجموعه شامل تصاویر برگ‌هایی از درخت سیب، بوته ذرت، گوجه‌فرنگی و توت‌فرنگی است. در این زیرمجموعه دسته‌بندی به صورت ۱۰ دسته‌ای، شامل یک دسته سالم برای هر گیاه به همراه



شکل ۳- نمونه‌ای از برگ‌های دومین زیرمجموعه داده مورد استفاده برای این پژوهش

Fig. 3 - A sample of the sheets of the second data subset used for this research

حدود ۲۰ درصد از کل تصاویر برای آزمایش مشخصات آماری این دو زیرمجموعه در جدول ۱ استفاده شد که به صورت تصادفی انتخاب شدند. نشان داده شده است.

جدول ۱- تعداد تصاویر و دسته‌ها در زیرمجموعه‌های تصاویر مورد استفاده

Table 1- Number of images and categories in the image subsets

تعداد کل تصاویر No total images	تعداد تصاویر آزمایشی No test images	تعداد تصاویر آموزشی No train images	تعداد دسته‌ها No classes	تعداد گیاهان No plants	زیرمجموعه تصاویر Image subsets
2084	417	1667	4	1	زیرمجموعه تصاویر اول First image subset
4678	936	3742	10	4	زیرمجموعه تصاویر دوم Second image subset

فراهم بودن تعداد زیادی تصویر در مجموعه داده Plant village، ابتدا شبکه‌ها با استفاده از تصاویر این مجموعه داده آموزش داده شود و پس از آن برای آزمایش از تصاویر گرفته شده در مزارع و گلخانه‌های

گفتنی است که شبکه‌های عصبی پیشنهاد شده در این پژوهش را برای استفاده در گلخانه‌ها و مزارع مختلف می‌توان با هر مجموعه داده‌ای آموزش و مورد استفاده قرار داد. پیشنهاد می‌شود با توجه به

- 1- Apple-Blackrot
- 3- Corn-Cercospora
- 5- Strawberry-Scorch

- 2- Apple-Scab
- 4- Corn-Northern
- 6- Strawberry-Scorch

مختلف به کار رود.

افتادن الگوریتم حین آموزش، تصویر پس‌زمینه و سایه‌های برگ حذف و تصویر برگ جداسازی شد. این کار با قطعه‌بندی و ایجاد یک ماسک^۱ روی تصویر و استفاده از عملگرهای مورفولوژی^۲ صورت گرفت. در شکل ۴، نمونه‌ای از تصویر برگ یک گیاه قبل و بعد از جداسازی تصویر برگ از زمینه مشاهده می‌شود.

مرحله دوم - پیش‌پردازش

پیش‌پردازش تصاویر یکی از مراحل حساس و تاثیرگذار در فرآیند یادگیری و همچنین در نتیجه کار است. در گام اول از پیش‌پردازش تصویر، به منظور بالابردن دقت کار و جلوگیری از به اشتباه




شکل ۴ - تصویر برگ یک گیاه قبل و بعد از جداسازی تصویر برگ از زمینه

Fig. 4 - Leaf image of a plant before and after separating the leaf image from the background


در گام بعدی، تصاویر از فضای RGB که دارای سه کانال رنگی است، با ادغام کانال‌ها به فضای خاکستری با یک کانال تبدیل شدند. این پردازش در طول یادگیری به الگوریتم کمک می‌کند تا روی ویژگی‌های مهم‌تری از تصویر تمرکز کند و ویژگی‌های دقیق‌تری استخراج نماید. شکل ۶، نمونه‌ای از نتیجه این مرحله را نشان می‌دهد.

مجموعه داده مورد استفاده از تصاویری با ابعاد مختلف تشکیل شده بود. بنابراین در گام بعدی ابعاد تصاویر یکسان‌سازی شد. تمام تصاویر با سه کانال رنگی RGB به تصویری با ابعاد ۱۰۰ در ۱۰۰ پیکسل با همان سه کانال رنگی تبدیل شدند. در شکل ۵، یک نمونه از تغییر اندازه تصاویر ورودی مشاهده می‌شود.



شکل ۵ - نمونه تصویر قبل (سمت راست: ۲۵۶×۲۵۶) و بعد (چپ: ۱۰۰×۱۰۰) از پیش‌پردازش کاهش بعد

Figure 5 - Sample image before (right: 256 × 256) and after (left: 100 × 100) pre-processing dimension reduction



شکل ۶ - نمونه تصویر قبل (راست) و بعد (چپ) از تبدیل شدن به تصویر یک کاناله

Fig. 6 - Sample image before (right) and after (left) of converting to a single channel image

مرحله سوم - یادگیری عمیق و استخراج ویژگی

در مرحله سوم، پس از آنکه پیش پردازش کامل و تصاویر آماده شدند، لازم است ویژگی‌هایی از این تصاویر استخراج شود. یکی از بهترین روش‌های استخراج ویژگی از تصاویر آموزشی، استفاده از روش‌های یادگیری عمیق است که ویژگی‌هایی سطح بالا از تصاویر را استخراج می‌کند. به علت کاربردهای متنوع یادگیری عمیق و نتایج درخشان آن در حوزه‌های مختلف، تعداد زیادی معماری مبتنی بر یادگیری عمیق توسعه یافته است. یکی از مهم‌ترین آنها شبکه‌های عصبی پیچشی یا CNN است که بیشترین کاربرد آن در پردازش تصویر و دسته‌بندی است و در این مقاله نیز از همین شبکه استفاده شده است.

شبکه‌های عصبی پیچشی (کانولوشنال)

شبکه‌های عصبی پیچشی مانند انواع شبکه‌های عصبی متشکل از نورون‌هایی با وزن‌ها و بایاس‌های قابل یادگیری (تنظیم) هستند. هر نورون تعدادی ورودی دریافت و حاصل ضرب وزن‌ها در ورودی‌ها را محاسبه می‌کند و در انتها با استفاده از یک تابع تبدیل (فعال‌سازی) غیرخطی، نتیجه را ارائه می‌دهد. شبکه‌های عصبی پیچشی معمولاً برای ورودی‌های تصویر به کار می‌روند که در یک طرف

آن پیکسل‌های خام تصویر ورودی را می‌گیرد و در طرف دیگر آن امتیازات مربوط به هر دسته را ارائه می‌دهد. شکل ۷ ساختار یک شبکه عصبی پیچشی را نشان می‌دهد. شبکه عصبی پیچشی در حالت کلی، یک شبکه عصبی سلسله مراتبی است که لایه‌های پیچشی آن به صورت یک در میان با لایه‌های تجمیع‌کننده^۱ چیده شده است و بعد از آنها تعدادی لایه تماماً متصل^۲ برای دسته‌بندی وجود دارد (Shin *et al.*, 2016) بنابراین به طور کلی هر شبکه CNN از چند نوع لایه اصلی تشکیل می‌شود که هر یک وظیفه‌ای متفاوت برعهده دارد (O'Shea & Nash, 2015).

لایه‌های پیچشی: لایه پیچشی هسته اصلی

تشکیل‌دهنده شبکه عصبی پیچشی است که شامل مجموعه‌ای از فیلترهای قابل یادگیری است. فیلترها در عرض ورودی لغزیده می‌شوند و ضرب نقطه‌ای بین مقادیر فیلتر و مقادیر ورودی را محاسبه و نتیجه را به لایه بعد منتقل می‌کنند.

لایه‌های تجمیع‌کننده یا فشرده‌ساز: هدف

اصلی این لایه، کوچک کردن^۳ تصویر ورودی به منظور کاهش بار محاسباتی و حافظه است. انواع مختلف تجمیع‌کننده مانند میانگین و بیشینه وجود دارند. در تجمیع‌کننده بیشینه^۴ بیشترین مقدار و در

1- Pooling

3- Subsample

5- Average Pooling

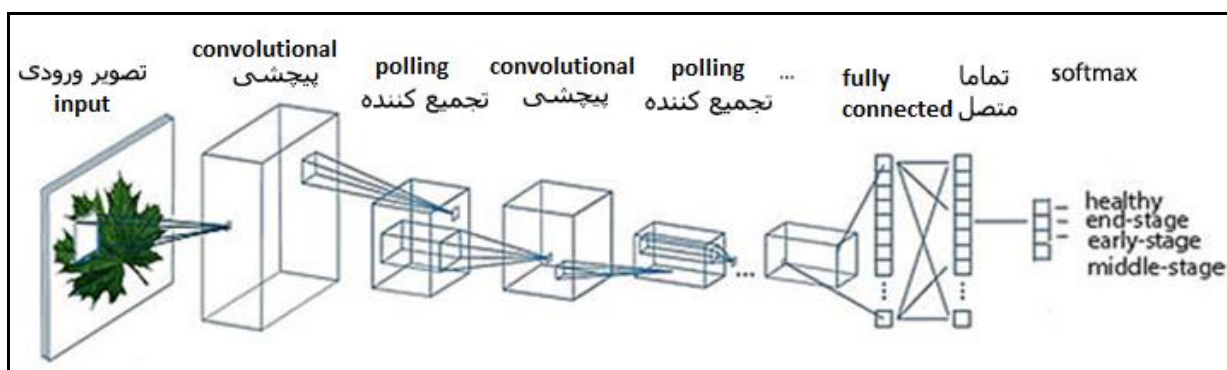
2- Fully Connected

4- Max Pooling

تجمیع‌کننده میانگین^۱، میانگین در هر محدوده نمونه‌گیری می‌شود. می‌کند.

لایه Softmax: این لایه وظیفه دسته‌بندی را به عهده دارد که با استفاده از خروجی لایه هموارساز و اعمال الگوریتم‌های مخصوص مانند وزن‌دهی و سیستم رای‌گیری^۳ دسته‌بندی انجام و خروجی ارائه می‌شود.

لایه هموارساز^۲: لایه هموارساز معمولاً قبل از اولین لایه تماماً متصل استفاده می‌شود و اطلاعات به دست آمده از لایه‌های قبل را به صورت یک بردار تبدیل



شکل ۷- ساختار یک شبکه عصبی پیچشی

Figure 7. Structure of a convolutional neural network

شبکه‌های مختلفی را مطرح کرده‌اند که هر یک از آنها عمق این معماری را تغییر می‌دهد. مشکل اصلی این معماری سرعت پایین و کند بودن است. اما شبکه‌های از قبل تعلیم‌دیده VGG به طور رایگان در اختیار عموم قرار دارند که می‌توان از آنها استفاده کرد. در این پژوهش از دو مدل مختلف از معماری VGG به نام‌های VGG16 و VGG19 استفاده شده است.

ب- معماری Inception

نام دیگر این معماری گوگل نت^۴ است، این معماری را شگدی و همکاران (Szegedy et al., 2015) معرفی کردند و محققان گوگل آن را توسعه دادند. گوگل نت با ارائه قوی‌ترین مدل، برنده رقابت «ImageNet» بود. در این معماری که علاوه بر عمق بیشتر دارای ۲۲ لایه است، (در مقایسه با VGG با

معماری‌های مورد استفاده از CNN

با توجه به نتایج خوب شبکه‌های CNN در حوزه پردازش تصویر، معماری‌های زیادی برای آن توسعه داده شده‌اند. در این پژوهش، از سه معماری شاخصی که نتایج بهتری داشته‌اند استفاده شده است که در ادامه این معماری‌ها بررسی شده‌اند (Liu et al., 2017).

الف- معماری VGG

این معماری را سیمونیان و همکاران (Simonyan & Zisserman, 2014) معرفی کرده‌اند و شامل یک سری از لایه‌های پیچشی و لایه‌های تجمیع‌کننده است و بیشتر به خاطر شکل هرمی ماندش شناخته می‌شود که در آن لایه‌هایی که به تصویر نزدیک‌تر هستند پهن‌ترند و لایه‌های دورتر عمیق‌تر هستند. این گروه در تحقیقات خود

1- Average Pooling
3- Voting

2- Flatten
4- GoogleNet

داده‌های آموزشی. یکی از بهترین روش‌های دسته‌بندی، استفاده از ماشین بردار پشتیبان (SVM) (Suykens & Vandewalle, 1999) است. دسته‌بند SVM یک دسته‌بند مرزی است که با معیار قرار دادن بردارهای پشتیبان، بهترین دسته‌بندی و تفکیک بین داده‌ها را به دست می‌آورد. در SVM فقط داده‌های حاشیه‌ای که بردارهای پشتیبان نامیده می‌شوند مبنای یادگیری ماشین و ساخت مدل قرار می‌گیرند. بنابراین، الگوریتم SVM به نقاط داده پرت و نویز حساس نیست. هدف آن یافتن بهترین ابر صفحه^۲ از بین تعداد زیادی ابر صفحه ممکن در بین داده‌ها برای مرزبندی است به گونه‌ای که بیشترین فاصله را از تمام دسته‌ها (بردارهای پشتیبان آنها) داشته باشد.

در مرحله چهارم، به منظور تشخیص و دسته‌بندی برگ گیاهان در مدل پیشنهادی، از دسته‌بند SVM استفاده شد. به این معنی که لایه‌های تماماً متصل آخر در هر معماری شبکه یادگیر عمیق حذف و به جای آن یک دسته‌بند ماشین بردار پشتیبان قرار داده شد. ویژگی‌های استخراج شده از لایه ماقبل آخر، برای دسته‌بندی به این ماشین داده می‌شود.

دسته‌بند SVM معمولاً به صورت دو کلاسه کار می‌کند، اما در این پژوهش بیش از دو کلاس وجود دارد. بنابراین دسته‌بندی به صورت یکی در برابر همه^۴ اجرا شد. در این سبک دسته‌بندی، در گام اول اولین کلاس به عنوان کلاس مثبت و سایر کلاس‌ها به عنوان کلاس منفی در نظر گرفته می‌شوند و دسته‌بندی دو کلاسه اجرا می‌شود. پس از آن کلاس دوم به عنوان کلاس مثبت و سایر کلاس‌ها منفی تلقی می‌شوند و همین صورت

۱۹ لایه)، محققان یک رویکرد جدید نیز به نام ماژول آغازین^۱ ارائه دادند. این ماژول یک تغییر بزرگ نسبت به معماری‌های ترتیبی است. در یک لایه، چندین نوع استخراج‌کننده ویژگی^۲ (لایه‌هایی که مقادیر ورودی را دریافت و به نوعی داده برای محاسبات تبدیل می‌کنند) وجود دارند. در شبکه‌ای که خود در حال یادگیری است و باید از گزینه‌های مختلفی برای حل وظایف استفاده کند، این نوع لایه‌بندی به طور غیر مستقیم به عملکرد بهتر شبکه کمک می‌کند. این ماژول می‌تواند از ورودی‌ها مستقیماً در محاسبات خود استفاده کند، یا آنها را جمع‌بندی کند.

ج- معماری ResNet

معماری ResNet را که هی و همکاران (He et al., 2016) ارائه دادند، یکی از معماری‌های بزرگ است که نشان می‌دهد یک معماری یادگیری عمیق تا چه حد می‌تواند عمیق باشد. این معماری که کوتاه شده Residual Networks است شامل چندین ماژول رسوبی است که روی هم سوار شده‌اند و ساختمان اصلی معماری ResNet را تشکیل می‌دهند. به بیان ساده، ماژول رسوبی دو راه دارد، یا می‌تواند یک سری عملیات را روی ورودی انجام دهد، یا تمام این مراحل را رد کند. مزیت اصلی ResNet این است که هزاران هزار از این لایه‌های رسوبی می‌توانند کنار هم قرار بگیرند تا شبکه‌ای تشکیل دهند و پس از آن به یادگیری بپردازند. این مدل برخلاف شبکه‌های ترتیبی عادی مشکل کاهش عملکرد را در هنگام افزایش لایه‌ها ندارد.

مرحله چهارم - تشخیص و دسته‌بندی

دسته‌بندی عبارت است از فرآیند قرار دادن نمونه‌های جدید در دسته‌های مربوط بر اساس

1- Inception Module
3- Hyperplane

2- Feature Extractor
4- One vs Rest

تعداد کل داده‌هایی است که در واقع در آن کلاس هستند. معیار امتیاز F1 نیز به نوعی میانگین هارمونیک بین معیارهای صحت و بازخوانی است. این معیارها مطابق با روابط ۲ تا ۴ محاسبه می‌شوند.

$$Precision = \frac{tp}{tp + fp}, \quad (2)$$

$$Recall = \frac{tp}{tp + fn}, \quad (3)$$

$$F1 - score = 2 \frac{precision \times recall}{precision + recall} \quad (4)$$

ابزارها و محیط‌های پیاده‌سازی

روش پیشنهادی به زبان Python و روی بستر iPython و با استفاده از چارچوب‌های مطرح یادگیری ماشین به نام Keras و TensorFlow پیاده‌سازی شد. برای اجرای کد از سرویس ابری Google Colab استفاده شده است. در این شبیه‌ساز علاوه بر فراهم بودن بستری برای به اشتراک گذاری کد و استفاده از چارچوب‌های یادگیری عمیق، امکان ارائه GPU رایگان به کاربران نیز وجود دارد. در این سرویس به هر کاربر یک Nvidia Tesla T4 (سابقاً Tesla k80) ارائه می‌شود که کاربر می‌تواند از آن برای توسعه و اجرای برنامه‌های کاربردی یا تحقیقاتی در حوزه یادگیری عمیق بهره‌برداری کند.

پارامترها

نرخ یادگیری^۵ برای آموزش برابر با ۰/۱ و تعداد دوره‌های آموزش ۵۰ و تعداد تصاویر آموزشی در هر دور^۶ برابر با ۳۲ تنظیم شد. این پارامترها برای همه پیاده‌سازی‌ها یکسان و ثابت بودند. تعداد پارامترهای معماری‌های گوناگون مورد استفاده نیز در جدول ۲ آمده است.

دسته‌بندی به تعداد کلاس‌ها و تا آخرین کلاس دنبال می‌شود.

مرحله پنجم - ارزیابی

برای ارزیابی عملکرد الگوریتم از ماتریس در هم ریختگی استفاده شد که در ادامه پارامترهای ماتریس در هم ریختگی معرفی و بررسی می‌شود.

معیار دقت^۱ که نشان‌دهنده نسبت پیش‌بینی‌های صحیح به کل پیش‌بینی‌ها است، از رابطه ۱ به دست می‌آید:

$$Accuracy = \frac{tp + tn}{tp + tn + fp + fn} \quad (1)$$

که در آن،

tp = تعداد تصاویری که بیماری آن به‌درستی تشخیص داده شده؛ و tn = تعداد تصاویری که سلامت آن به درستی تشخیص داده شده؛ fp = تعداد تصاویری که به اشتباه به عنوان بیمار؛ و fn = تعداد تصاویری که به اشتباه به عنوان سالم تشخیص داده شده‌اند.

بنابراین، صورت کسر به معنای جمع قطر اصلی در ماتریس در هم ریختگی است. مخرج کسر به معنای کلیه تصاویر (اعم از تصاویر درست تشخیص داده شده و تصاویر اشتباه دسته‌بندی شده) است. به عبارت دیگر، دقت به معنی نسبت نمونه‌های درست تشخیص داده شده به کل نمونه‌ها است.

از معیارهای مهم دیگر در ارزیابی دسته‌بندها، معیارهای صحت^۲، بازخوانی^۳ و امتیاز F1^۴ است. معیار صحت نشان‌دهنده نسبت تعداد پیش‌بینی‌های صحیح در یک کلاس، به تعداد کل پیش‌بینی‌ها برای همان کلاس است. معیار بازخوانی، بیان‌کننده نسبت تعداد داده‌های درست دسته‌بندی شده (پیش‌بینی‌های صحیح) در یک کلاس خاص، به

1- Accuracy

3- Recall

5- Learning Rate

2- Precision

4- F1-Score

6- Batch Size

جدول ۲- تعداد پارامترهای مورد نیاز برای مدل های استفاده شده

Table 2 - Number of parameters required for the used models

نوع معماری Type of architecture	تعداد کل پارامترها #parameters	تعداد پارامترهای آموزش پذیر #trainable parameters	تعداد پارامترهای آموزش ناپذیر #non-trainable parameters
VGG16	50,391,428	50,391,428	0
VGG19	55,701,124	55,701,124	0
ResNet	23,599,044	23,599,044	53,120
InceptionV3	21,776,836	21,776,836	34,432

نتایج و بحث

داده‌های اعتبارسنجی در قالب معیارهای دقت اعتبارسنجی در شکل ۸ قابل مشاهده است. برای ارزیابی‌ها، روش اعتبارسنجی تقاطعی ۵-برابری^۲ به کار گرفته شد.

لایه آخر هر معماری با دسته‌بند SVM جایگزین شد و مدل‌ها دوباره آموزش داده شدند و مجدداً دقت آن اندازه گرفته شد. دقت نهایی برای معماری‌های مختلف در حالت اولیه (بدون SVM) و حالت اصلاح شده (با SVM) در جدول ۳ قابل مشاهده است. یادآوری می‌شود برای ثبت نتایج عادلانه و حصول اطمینان از دقت محاسبه شده برای هر معماری، هر پیاده‌سازی پنج بار تکرار شد و مقادیر ثبت شده میانگین دقت‌های محاسبه شده است.

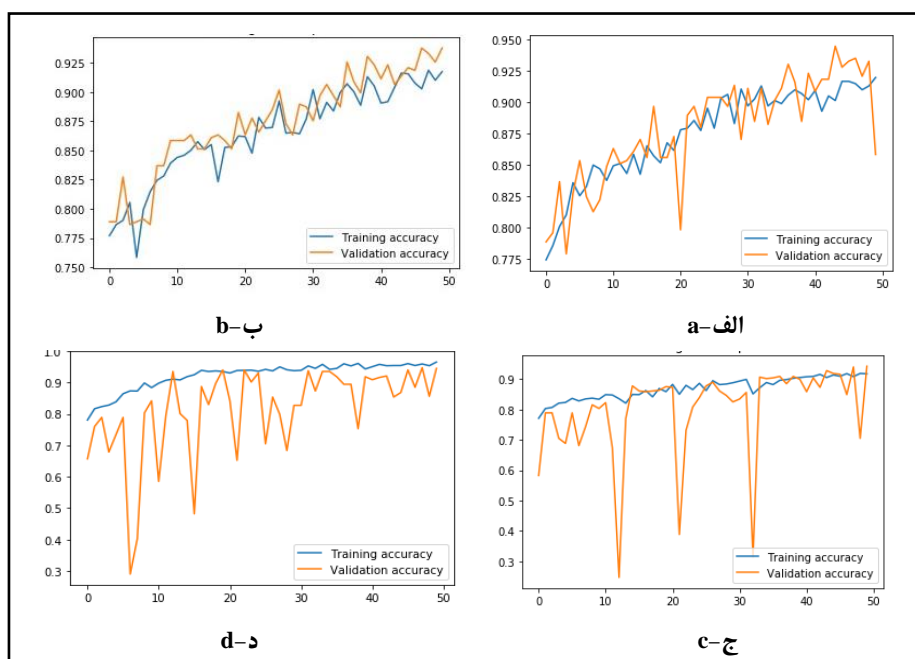
گفتنی است که دقت‌های به دست آمده برای معماری اولیه (بدون SVM) همان دقت‌هایی است که در مرجع (Wang et al., 2017) روی همین مجموعه داده ثبت شده است که در پیاده‌سازی انجام شده از این معماری‌ها در این پژوهش نیز دقیقاً همین نتایج به دست آمد که نشان‌دهنده درست بودن شبکه‌های طراحی شده است.

پیشتر گفته شد که برای اجرای این پژوهش و مقایسه نتایج، دو زیر مجموعه جداگانه تهیه شده است. بر این اساس دو پیاده‌سازی مختلف اجرا شد که در ادامه نتایج آنها ارائه شده است.

نتایج زیرمجموعه تصاویر اول - بیماری‌های درخت سیب

در اولین مرحله پیاده‌سازی، معماری‌های VGG16، VGG19، ResNet50 و InceptionV3 روی مجموعه تصاویر استفاده شده توسط وانگ و همکاران (Wang et al., 2017) برای تشخیص بیماری درخت سیب پیاده‌سازی و ارزیابی شدند. پس از آن همانطور که در بخش روش‌ها (مرحله چهارم) ذکر شد، این معماری‌ها با ماشین بردار پشتیبان ترکیب و مجدداً ارزیابی شدند. نتایج این جایگزینی در ادامه بررسی شده است.

پس از جدا کردن داده‌های آزمایشی، بخشی از داده‌های آموزشی برای اعتبارسنجی^۱ کنار گذاشته شد و با بقیه داده‌های آموزشی مدل‌ها آموزش داده شدند، سپس دقت کار با داده‌های اعتبارسنجی ارزیابی شد. بر این اساس، روند آموزش مدل‌های پیشنهادی برای معماری‌های مختلف با کمک



شکل ۸- دقت اعتبارسنجی روند آموزش برای معماری الف) VGG16، ب) VGG19، ج) Inception V3، د) ResNet

خط آبی دقت روی مجموعه آموزش، خط نارنجی دقت روی مجموعه اعتبارسنجی را نشان می‌دهد.

Fig. 8- Accuracy of validation of the training process for architecture a) VGG16, b) VGG19, c) Inception V3, d) ResNet

Blue line shows accuracy on training set, orange line shows accuracy on validation set

جدول ۳- نتایج به دست آمده برای دقت معماری‌های مختلف در تشخیص بیماری‌های درخت سیب برحسب درصد

Table 3- Results for the accuracy of different architectures in diagnosing apple tree diseases in percentage

میزان افزایش دقت Increase accuracy	دقت معماری پیشنهادی (+SVM) Proposed architecture accuracy (+ SVM)	دقت معماری اولیه (-SVM) Primary Architectural Accuracy (-SVM)	نوع معماری Type of architecture
4.56	94.96	90.40	VGG16
5.56	92.59	87.03	VGG19
13.29	94.4	81.11	Inception V3
14.47	93.75	79.28	ResNet50

درصد صورت گرفت که دقت آن از ۹۰/۴۰ به ۹۴/۹۶ درصد افزایش یافت. همان‌طور که مشاهده می‌شود، رویکرد پیشنهاد شده تاثیر بسیار خوبی روی کارایی معماری‌های شاخص شبکه‌های عصبی پیچشی برای تشخیص بیماری گیاهان از روی تصاویر برگ آنها داشته است. جدول ۴ ماتریس در هم ریختگی برای این معماری را نشان می‌دهد.

همان‌طور که در جدول ۳ مشخص است، بهترین نتایج مربوط به معماری VGG16 است. اما میزان افزایش و بهبود دقت بسته به نوع معماری متفاوت است. در پژوهش حاضر بیشترین میزان افزایش دقت روی معماری ResNet و در حدود ۱۴/۵ درصد بود. طوری که دقت آن را از ۷۹/۲۸ به ۹۳/۷۵ درصد رساند. کمترین افزایش دقت نیز روی معماری VGG16 و به میزان ۴/۵۶

جدول ۴- ماتریس در هم ریختگی پیاده‌سازی VGG16
Table 4 - VGG16 implementation confusion matrix


همه All	سالم Healthy	مرحله شدید بیماری Severe stage	مرحله میانی بیماری Intermediate stage	مرحله اولیه بیماری Early stage	پیش بینی / واقعیت Prediction / truth
27	1	0	1	25	مرحله اولیه بیماری Early stage
36	0	5	30	1	مرحله میانی بیماری Intermediate stage
25	0	13	10	2	مرحله شدید بیماری Severe stage
329	328	0	0	1	سالم Healthy
417	329	18	41	29	همه All

مطابق با جدول ۴، معیارهای مختلف برای امتیاز F1 به تفکیک نوع دسته محاسبه و در جدول ارزیابی دسته‌بند شامل دقت، بازخوانی، صحت و ۵ ارائه شده‌اند.

جدول ۵- نتایج ارزیابی دسته‌های مختلف بیماری درخت سیب با معیارهای مختلف برای معماری VGG16 برحسب درصد
Table 5 - Evaluation Results of different categories of apple tree disease with different criteria for VGG16 architecture in percentage

امتیاز F1-score	بازخوانی Recall	صحت Precision	دقت Accuracy	تعداد دسته‌بندی شده Predicted Number	تعداد واقعی Truth Number	دسته Class
89	86	93	98.56	27	29	مرحله اولیه بیماری Early stage
78	73	83	95.92	36	41	مرحله میانی بیماری Intermediate stage
65	72	52	95.92	25	18	مرحله شدید بیماری Severe stage
100	100	100	99.52	329	329	سالم Healthy

در شکل ۹ دو نمونه تصادفی از خروجی مدل گرفته و پیش‌بینی درستی از نوع گیاه و نوع بیماری پیشنهادی مشاهده می‌شود که تصویر ورودی را آن ارائه داده است.



شکل ۹- دو نمونه تصادفی از پیش‌بینی بیماری برگ بر اساس روش پیشنهادی (راست: پوسیدگی سیاه سیب، چپ: توت فرنگی اسکورچ)

Fig. 9- Two random samples of leaf disease prediction based on the proposed method
Right: Black apple rot, Left: Scorch strawberry

نتایج زیرمجموعه تصاویر دوم- بیماری‌های چهار گیاه مختلف به طور همزمان

پیاده‌سازی قبلی به منظور مقایسه نتایج با روش‌های دیگر تنها روی بیماری‌های مختلف درخت سیب صورت گرفت. در پیاده‌سازی دوم که برای نشان دادن قابلیت تعمیم سیستم طراحی شده است، از مجموعه تصاویری استفاده شده که علاوه بر تصاویری از برگ درخت سیب، تصاویری از برگ گیاهان ذرت، گوجه‌فرنگی و توت‌فرنگی را نیز شامل می‌شدند. این پیاده‌سازی نشان داد که سیستم

پیشنهادی می‌تواند به راحتی و تنها با تغییر مجموعه تصاویر، بدون نیاز به تنظیمات دیگر، برای گیاهان مورد نظر در یک مزرعه یا گلخانه نیز به کار گرفته شود.

پیاده‌سازی مزبور برای ترکیبی از معماری VGG16 و ماشین بردار پشتیبان اجرا شد. در این حالت دقت تشخیص نوع و بیماری گیاه به ۹۶/۸ درصد رسید. نتایج معیارهای مختلف در تشخیص بیماری هر گیاه به طور مجزا در جدول ۶ ارائه شده است.

جدول ۶- نتایج حاصل از ارزیابی روش پیشنهادی برای زیرمجموعه تصاویر دوم با ۱۰ دسته برحسب درصد

Table 6- Evaluation results of proposed method for second image subset with 10 categories in percentage

امتیاز F1	بازخوانی	صحت	دقت	تعداد دسته‌بندی شده	تعداد واقعی	دسته
F1-score	Recall	Precision	Accuracy	classified	Truth Number	Class
100	100	100	100	83	83	پوسیدگی سیاه سیب Apple Blackrot
96	97	96	99.47	70	69	سیب سالم Apple Healthy
96	96	96	99.15	89	89	لکه سیاه سیب Apple Scab
87	85	88	97.33	93	96	سرکوسپورا ذرت Corn Cercospora
100	100	100	100	88	88	ذرت سالم Corn Healthy
89	90	87	97.55	103	100	بادبذنی شمالی ذرت Corn Northern
100	100	100	100	91	91	توت فرنگی سالم Strawberry Healthy
98	98	98	99.57	104	104	توت فرنگی اسکورچ Strawberry Scorch
98	99	97	99.57	103	101	گوجه فرنگی سالم Tomato Healthy
97	96	98	99.25	113	116	سپتوریا گوجه فرنگی Tomato Septoria

نتیجه‌گیری

در این مقاله سیستمی برای تشخیص بیماری گیاهان از روی تصویر برگ آنها پیشنهاد و پیاده‌سازی شد. برای این کار از روش‌های پردازش تصویر مبتنی بر یادگیری عمیق استفاده شد.

الگوریتم‌های یادگیری عمیق با استفاده از شبکه‌های عصبی با تعداد زیادی لایه پنهان به صورت سلسله مراتبی ویژگی‌هایی را از تصاویر استخراج می‌کنند که بامعنا تر و سطح بالاتر از ویژگی‌های معمولی مانند لبه و هیستوگرام عمل می‌کنند. در این

آزمایشی اندازه‌گیری شد. نتایج حاصل نشان‌دهنده دقت بالا و افزایش چشمگیر دقت نسبت به حالتی است که از دسته‌بند SVM استفاده نشود. در آینده با توسعه رویکرد ارائه شده در این پژوهش می‌توان از آن به عنوان بخش اصلی در یک سیستم کاملاً خودکار در کشاورزی هوشمند استفاده کرد. پیشنهاد می‌شود در چنین سیستمی با تعبیه یک یا چند دوربین در سقف هر گلخانه به صورت دوره‌ای تصاویری از گیاهان گرفته شود و با افزودن بخش‌هایی برای جداسازی تصاویر برگ از سایر تصاویر و استخراج تصاویر هر برگ پس از رفع مشکلاتی نظیر روی هم افتادگی آنها، تعدادی از این تصاویر به صورت تصادفی به عنوان ورودی به برنامه ارائه شده در این مقاله داده شود. چنانچه خروجی این برنامه بیماری خاصی را در گیاهان گلخانه تشخیص دهد، برنامه می‌تواند اخطار لازم را صادر کند.

پژوهش از معماری‌های مطرح یادگیری عمیق شبکه‌های عصبی پیچشی شامل VGG16، VGG19، Inception-v3، ResNet50 استفاده شد. ویژگی‌های استخراج شده از این لایه‌ها به دسته‌بندی مبتنی بر الگوریتم SVM اعمال شد تا بر اساس داده‌های آموزشی به پیش‌بینی بیماری یا سلامت گیاهان از طریق تصاویر آنها پردازد. طرح پیشنهادی برخلاف اکثر کارهای مشابه که تنها برای یک نوع گیاه قابل استفاده است، برای گیاهان متنوع و بیماری‌های مختلف قابل تعمیم است. این مدل بر اساس دو مجموعه تصویر از بین مجموعه تصاویر Plant Village پیاده‌سازی شد. در پیاده‌سازی اول از تصاویر برگ درخت سیب استفاده شد که در آن علاوه بر سلامت یا بیماری گیاه، شدت بیماری نیز تشخیص داده شد. در پیاده‌سازی دوم بر اساس تصاویری از گیاهان سیب، ذرت، گوجه‌فرنگی و توت‌فرنگی آموزش و سپس دقت آن روی تصاویر

مراجع

- Chuanlei, Z., Shanwen, Z., Jucheng, Y., Yancui, S., & Jia, C. (2017). Apple leaf disease identification using genetic algorithm and correlation based feature selection method. *International Journal of Agricultural and Biological Engineering*, 10(2), 74-83.
- Cruz, A., Ampatzidis, Y., Pierro, R., Materazzi, A., Panattoni, A., De Bellis, L., & Luvisi, A. (2019). Detection of grapevine yellows symptoms in *Vitis vinifera* L. with artificial intelligence. *Computers and Electronics in Agriculture*, 157, 63-76.
- Durmuş, H., Güneş, E. O., & Kırıcı, M. (2017). Disease detection on the leaves of the tomato plants by using deep learning. *Disease detection on the leaves of the tomato plants by using deep learning. Proceedings of the 6th International Conference on Agro-Geoinformatics*. Aug. 7-10. Virginia, USA.
- Ghasemi Varjani, Z., Mohtesabi, S. S., Ghasemi, H., & Omrani, I. (2018). Development of a new hybrid system to detect apple tree leaf diseases. *Iranian Biosystems Engineering*, 49(2), 215-225. (in Persian)
- 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*. June 26 July 1. Las Vegas, NV, USA.

- Hosseini, H., Mohammad Zamani, D., & Master, A. (2018). Detection System for Sefidak Poudri Fungal Disease and Anthracnose Cucumber Leaf by Image Processing Technique and Artificial Neural Network. *Plant Protection (Scientific Journal of Agriculture)*, 40(4), 15-28. (in Persian)
- Islam, M., Dinh, A., Wahid, K., & Bhowmik, P. (2017). *Detection of potato diseases using image segmentation and multiclass support vector machine. Proceedings of the 30th Canadian Conference on Electrical and Computer Engineering (CCECE)*. April 30-May 3. Windsor, Canada.
- Liu, B., Zhang, Y., He, D., & Li, Y. (2018). Identification of apple leaf diseases based on deep convolutional neural networks. *Symmetry*, 10(1), 11. <https://doi.org/10.3390/sym10010011>.
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., & Alsaadi, F. E. (2017). A survey of deep neural network architectures and their applications. *Neurocomputing*, 234, 11-26.
- Ng, P. C., & Henikoff, S. (2003). SIFT: Predicting amino acid changes that affect protein function. *Nucleic Acids Research*, 31(13), 3812-3814.
- O'Shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. *arXiv Preprint arXiv:1511.08458*.
- Oboudi, M. (2015). *Diagnosis of cucumber mosaic virus symptoms by image processing*. (M. Sc. Thesis), Isfahan University of Technology, Faculty of Agriculture, Isfahan, Iran. (in Persian)
- Peyman, S. H., BakhshiPour, A., & Jaafari, A. A. (2016). Feasibility of applying digital image processing method to detect rice leaf surface diseases. *Agricultural Machinery*, 6(1), 69-79. (in Persian)
- Shin, H. C., Roth, H. R., Gao, M., Lu, L., Xu, Z., Nogues, I., Yao, J., Mollura, D., & Summers, R. M. (2016). Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning. *IEEE Transactions on Medical Imaging*, 35(5), 1285-1298.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv Preprint arXiv:1409.1556*.
- Suryawati, E., Sustika, R., Yuwana, R. S., Subekti, A., & Pardede, H. F. (2018). *Deep Structured Convolutional Neural Network for Tomato Diseases Detection. Proceedings of the International Conference on Advanced Computer Science and Information Systems (ICACSIS)*. Oct. 27-28. Yogyakarta, Indonesia.
- Suykens, J. A., & Vandewalle, J. (1999). Least squares support vector machine classifiers. *Neural Processing Letters*, 9(3), 293-300.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). *Going deeper with convolutions*. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. June 7-June 12. Boston, USA.
- Wang, G., Sun, Y., & Wang, J. (2017). Automatic image-based plant disease severity estimation using deep learning. *Computational Intelligence and Neuroscience*. <https://doi.org/10.1155/2017/2917536>.

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.

Research Paper**Plants Disease Detection by Image Processing of Their Leaves
Based on Deep-Learning****R. Rad*, M. Mousavi and F. Vardi**

* Corresponding Author: Assistant Professor, Computer Engineering and IT Group, Department of Technical Engineering, Islamic Azad University, Parand Branch. Tehran, Iran. Email: raad@ce.sharif.edu, roia_rad@yahoo.com
Received: 20 January 2020, Accepted: 22 June 2020

Abstract

Rapid diagnosis of plant diseases has always been an important challenge for the agricultural industry. One of the approaches that has been welcomed in this field is the use of image processing methods. The advantage of these methods is that they are automatic, fast, low cost, non-destructive and accurate. In this article efforts were focused on distinguishing automatically healthy plants from unhealthy ones and also diagnosing the types and severity of their disease, by processing the images of the leaves of plants and agricultural products. To do this, deep learning-based methods including several different architectures of convolutional neural networks were used along with a support vector machine classifier. The proposed method in this study can be generalized to different plants and products as well as several plants simultaneously. The designed networks were evaluated using two different subsets of Plant Village data sets. In the first subset, which was related to the diagnosis of apple tree disease in four different classes, the accuracy was 95%, and in the second subset, which was related to four different plants in ten classes, the accuracy was 96.8%. Evaluation results showed that combining the support vector machine classifier with deep learning networks improved plant disease detection accuracy.

Keywords: Convolutional Neural Networks, Deep Learning, Image Classification, Mechanized Agricultural Systems, Plant Disease Diagnose

[© 2020 Agricultural Mechanization and Systems Research, Karaj, Iran.](#)



[This is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International \(CC BY 4.0 license\)](#)