

علمی پژوهشی

تشخیص آفات متدال مرکبات در شمال ایران با استفاده از شبکه عصبی حلقوی عمیق

مرتضی خان رمکی^۱، عزت الله عسکری اصلی ارده^{۲*} و احسان الله کوزه گر^۳،
ريحانه لونی^۴

۱- دانشجوی دکتری مهندسی مکانیک بیوسیستم دانشگاه محقق اردبیلی، اردبیل، ایران

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

۳- استادیار گروه مهندسی کامپیوتر دانشکده فنی و مهندسی شرق گیلان، دانشگاه گیلان، گیلان، ایران

۴- پژوهشگر پسادکتری، گروه مهندسی مکانیک بیوسیستم، دانشگاه تربیت مدرس، تهران، ایران

(تاریخ دریافت: ۹۹/۰۳/۰۴ تاریخ پذیرش: ۹۹/۰۶/۲۲)

چکیده

آفات و بیماری‌های گیاهی یک تهدید عمده برای امنیت غذایی بشر بشمار می‌آیند. در مزارع وسیع، تشخیص دقیق و به هنگام توسط انسان به دلیل زمان بر بودن و احتمال تشخیص اشتباه امکان پذیر نمی‌باشد. از این‌رو برای تشخیص فوری، اتوماتیک، مناسب و دقیق آفات کشاورزی، استفاده از پردازش تصویر و هوش مصنوعی از جمله یادگیری عمیق می‌تواند بسیار مفید باشد. در این تحقیق، مدل‌های شبکه عصبی حلقوی برای تشخیص و شناسایی سه نوع آفت مرکبات متدال در شمال ایران نظری پروانه مینوز، فوماژین (قارچ دوده مرکبات) و بالشتک با استفاده از تصاویر برگ‌های آلوده، از طریق روش‌های یادگیری عمیق توسعه داده شده است. برای این منظور معماری‌های رزنت و وی‌جی‌جی به عنوان شبکه عصبی حلقوی معروف که با استفاده از روش انتقال یادگیری بر روی ۱۷۷۴ تصویر برگ آلوده مرکبات در شرایط طبیعی و مزروعی فراهم گردید، آموزش داده شد. در مرحله آموزش، از روش افزونه‌سازی داده‌ها برای افزایش تعداد نمونه‌های آموزشی و بهبود تعیین‌پذیری طبقه‌بندها استفاده گردید. برای تجزیه و تحلیل تجربی از اعتبارسنجی ضربدری به منظور اندازه‌گیری دقت شبکه عصبی حلقوی استفاده شد. در این استراتژی همه تصاویر بدون هیچگونه همپوشانی مجموعه داده‌های آموزش و امتحان، آزمایش شدند. بر اساس نتایج به دست آمده دقت مدل‌های رزنت و وی‌جی‌جی به ترتیب ۹۶/۰۵ و ۸۹/۳۴ درصد ارزیابی گردید. از این‌رو مدل رزنت، می‌تواند روش فوق را به یک سیستم مشاوره یا هشداردهنده اولیه بسیار مناسب تبدیل کند.

کلید واژگان: آفات مرکبات، یادگیری عمیق، شبکه عصبی حلقوی، رزنت، وی‌جی‌جی

*مسئول مکاتبات: ezzataskari@uma.ac.ir

جمع آوری شده سه نوع بیماری را با استفاده از ویژگی‌های رنگ و بافت با دقت ۹۰/۷٪ تشخیص دهد^[۲]. گوهان و همکاران (۲۰۱۴) در تشخیص نواحی آلوده برگ مرکبات با استفاده از فنون پردازش تصویر، طی انجام مراحل ارتقاء کیفیت تصویر، خوش بندی، استخراج ویژگی بافت و طبقه بندی روی ۳۰۰ تصویر تهیه شده در شرایط آزمایشگاهی، نرخ صحیح طبقه بندی را ۹۶٪ اعلام کردند^[۳]. ژو و همکاران (۲۰۱۴) طی تحقیقی توانستند با روشی مبتنی بر تطابق کد جهت گیری^۲، ارائه یک هیستو گرام دوبعدی و بکارگیری ماشین بردار پشتیبان به نتایج مطلوبی در تشخیص قارچ چقدندر قند دست یابند^[۴]. سنتگار و همکاران (۲۰۱۸) یک روش آستانه‌گذاری قوی برای اندازه گیری پیشرفت کپک پودری در گیلاس پیشنهاد کردند^[۵]. در این تحقیق از داده‌های تارنامی دهکده گیاه^۳ استفاده شده است. علی و همکاران (۲۰۱۷) روش جدیدی را برای تشخیص و طبقه بندی بیماری‌های مرکبات با استفاده از الگوریتم تفاوت رنگ ΔE برای تشخیص قسمت‌های آلوده در تصویر ارائه دادند^[۶]. در این روش از رنگ، الگوریتم هیستو گرام شبیه‌های جهت دار^۴ و ویژگی‌های بافت برای طبقه بندی بیماری‌های مرکبات استفاده شد و بطور قابل توجهی، عملکرد بر حسب دقت و سطح زیر منحنی^۵ بهبود یافت. توسط شریف و همکاران (۲۰۱۸) روش ترکیبی شناسایی و تشخیص بیماری‌های مرکبات ارائه شد^[۷]. در این روش نقاط آسیب‌دیده مرکبات توسط تقسیم بندی بهینه با استفاده از رنگ، بافت، ویژگی‌های هندسی بخش‌بندی شد و انتخاب ویژگی با کاهش ابعاد، آنتروپی و چولگی مبتنی بر بردار کوواریانس انجام گرفت. در نهایت، نمونه‌ها با ماشین بردار پشتیبان طبقه بندی شدند. این روش بر روی مجموعه داده‌های گالری تصاویر مرکبات که از تارنامی دهکده گیاه و داده‌های محلی تهیه شد، آزمایش گردید و نتایج حاکی از این بود که این روش توانایی تشخیص آنتراتکنوز، لکه سیاه، شانکر، اسکب، سبز شدگی و ملانوز را دارد. رئوف و همکاران (۲۰۱۹) مجموعه‌ای از داده‌ها شامل تصاویر برگ‌های سالم و آلوده (۷۵۹ عدد) که از پتانسیل زیادی در تشخیص بیماری و آفت مرکبات دارند، تهیه کردند. هدف آنها، استفاده از تصاویر به منظور تشخیص و طبقه بندی بیماری و آفات مرکبات با بکارگیری از فنون یادگیری ماشین بود^[۸].

۱- مقدمه

از بین محصولات کشاورزی، میوه جات و سبزیجات حاوی مقادیر قابل توجهی از ترکیباتی هستند که می‌توانند برای سلامتی انسان بسیار مفید واقع شوند. مرکبات به عنوان یک منع غنی از ترکیبات آنتی اکسیدان، ترکیبات فنلی، ویتامین C و کاروتونوئیدها (مانند بتاکاروتون، گزان توفیل، گریپتو گزان‌تین و بیلو گزان‌تین) محسوب می‌شوند. همچنین میوه مرکبات غنی از ویتامین‌های A و B، کربوهیدرات (قند های ساده فروکتوز، کلوز و ساکارز) و مقادیری کلسیم، پتاسیم، نیاسین و اسید فولیک می‌باشد که میزان این ترکیبات با توجه به نوع مرکبات و همچنین شرایط رشد و ذخیره سازی آنها متفاوت است. بنابر اهمیت این میوه، برای کاهش ضایعات ناشی از آفات و بیماری‌ها، باید بصورت شیمیایی با آنها مبارزه نمود. اما امروزه استفاده بی رویه از سموم در مبارزه شیمیایی با آفات و بیماری‌ها باعث آلودگی های زیست محیطی نظری آلودگی منابع آب و خاک و همچنین نفوذ این مواد به داخل میوه می‌گردد و منجر به مسمومیت گیاهی و آبزیان و اثر سوء بر سلامت بشر می‌شود. تشخیص دقیق و به موقع بیماری مهمترین اقدام برای کنترل بیماری‌ها و آفات کشاورزی است. لذا شناسایی دقیق نقاط آلوده و به تبع آن مبارزه شیمیایی، علاوه بر کاهش آلودگی باعث کاهش هزینه‌های تولید نیز می‌شود. انجام عملیات فوق نیاز به نظارت و پایش مستمر دارد و در صورت انجام توسط انسان، امکان خطأ در تشخیص نوع آفت یا بیماری وجود دارد و همچنین مستلزم صرف هزینه و زمان است. در سال‌های اخیر، مطالعات مختلفی در توسعه فنون ماشین‌بینایی جهت تشخیص بیماری از تصاویر برگ در شرایط آزمایشگاهی صورت گفته است. توسط ایقبال و طبقه بندی بیماری‌های مروری به منظور شناسایی خودکار و طبقه بندی بیماری‌های مرکبات با استفاده از پردازش تصویر انجام و ضمن بررسی چالش‌ها در استفاده از انواع روش‌ها در مراحل مختلف پردازش تصویر، K-means^۶ یعنوان یک تقسیم کننده و ماشین بردار پشتیبان^۷، بعنوان یک طبقه بند مناسب معرفی شد و همچنین به استفاده از فنون یادگیری عمیق در شناسایی بیماری مرکبات تاکید شده است^[۱].

کوار و همکاران (۲۰۱۸) روشی را برای تشخیص بیماری در یک رقم لوییا گلیسین مکس با الگوریتم بخش‌بندی مبتنی بر k-means^۸ ارائه کردند. این روش توانست از روی تصاویر

2. Orientation Code Machine (OCM)

3. Plant Website Village

4. Histogram of Oriented Gradients

5. Area Under Curve

1. Support Vector Machine (SVM)

های مورد استفاده ۲۳۵۱ عدد بود که بوسیله موبایل هوشمند^۸ تهیه شده بود[۱۳].

هدف از این تحقیق، استفاده از دو معماری از شبکه عصبی حلقوی^۹ برای شناسایی خودکار سه نوع آفت مرکبات بود. از آنجایی که تنظیم کلیه وزن‌های این شبکه‌ها در حالت کلی نیاز به تعداد تصاویر بسیار زیادی داشت، برخلاف بسیاری از کارهای انجام شده، تمام تصاویر گردآوری شده در این تحقیق، در شرایط میدانی و واقعی، در بازه‌های زمانی مختلف، شرایط نوری و موقعیت‌های مکانی متفاوت، با استفاده از ابزارهای تصویربرداری مختلف تهیه شد تا امکان استفاده از نتایج این تحقیق در شناسایی و دفع آفات مرکبات بطور مکانیزه توسط ربات‌ها و تجهیزات دیگر مثل پهپاد‌ها فراهم شود. در واقع، در نمونه برداری سعی شده است اصل تنوع نمونه‌ها لحاظ گردد. بر اساس بررسی‌های انجام شده، تاکنون از شبکه‌های عصبی عمیق برای تشخیص آفات مرکبات در شرایط میدانی یا مزرعه‌ای استفاده نشده است.

۲- مواد و روش‌ها

۱-۲ جمع‌آوری دادها

عملیات عکس‌برداری سه نوع آفت متداول گیاه مرکبات در شمال ایران نظری پروانه مینوز، فومارژین (قارچ دوده مرکبات) و بالشتک در زوایا و شرایط نوری متفاوت نظری هواي کاملاً آفتابی، نیمه ابری و کاملاً ابری در سه بازه زمانی صبح، ظهر و عصر توسط سه دوربین سونی مدل DSC-W170. دوربین Samsung-Galaxy J5 گوشی Samsung-Galaxy Grand Prime و Iphone X6 برای دستیابی به تصاویر متفاوت آفات، مستقل از پارامترهایی نظری زوایا، شدت تابش نور و نوع دوربین انجام گرفت. مجموع تصاویر جمع‌آوری شده حدود ۱۷۷۴ عدد برای سه کلاس فوق بود. جدول (۱) اطلاعات مربوط به سه کلاس را که شامل برخی از داده‌های آماری از قبیل نام علمی، عمومی آفات و تعداد تصاویر موجود در هر کلاس است، ارائه می‌دهد. شکل (۱) یک نمونه تصادفی از هر کلاس که در شرایط واقعی در سطح باغات مرکبات گرفته شده را نشان می‌دهد.

امروزه محققین بر روی شبکه‌های عصبی حلقوی^۱ به عنوان یکی از انواع شبکه عصبی که می‌تواند بازشناسی الگوهای چالش برانگیز را تسهیل کند، متمرکز شده‌اند. اگرچه هنوز موارد مبهم و ناشناخته زیادی برای یافتن در مورد سیستم بینایی انسان وجود دارد، اما ذکر این نکته حائز اهمیت است که فیلتر کردن تصویر در شبکه‌های عصبی حلقوی و سیستم بینایی انسان مشابه است. شبکه‌های عصبی مصنوعی هستند که هدف اصلی تکامل یافته شبکه‌های عصبی مصنوعی هستند که هدف اصلی آنها بکارگیری الگوهای تکراری در حوزه‌های مختلف مدل‌سازی به ویژه تشخیص تصویر می‌باشد[۹]. خصوصیت اصلی شبکه‌های فوق‌الذکر این است که با کمک روش مورد استفاده در لایه‌بندی آنها، تعداد اجزاء ساختاری مورد نیاز (تعداد نورون‌های مصنوعی) در مقایسه با شبکه‌های سنتی عصبی، به مقدار زیادی کاهش می‌یابد. در تحقیقات گذشته، شبکه عصبی حلقوی برای تشخیص بیماری‌ها و آفات دارای عالم مشابه به کار گرفته شد که زمان و هزینه تشخیص را به میزان قابل توجهی کاهش داد[۹ و ۳]. به عنوان مثال، کروز و همکاران (۲۰۱۷) برنامه‌ای را مبنی بر بینایی ماشین برای تشخیص عالم سندروم زوال سریع زیتون^{۱۰} روی برگ‌های زیتون اروپایی آلوهه به بیماری *Xylella fastidiosa* توسعه دادند[۱۰]. فرنتینوس (۲۰۱۸) از شبکه‌های آلکس نت^{۱۱} و وی جی^{۱۲} استفاده کرد تا طیف گسترده‌ای از بیماری‌های گیاهی شامل سبزیجات و میوه‌جات را شناسایی نماید. بیشتر تصاویر بکارگرفته شده در شرایط آزمایشگاهی تهیه شده اند[۱۱]. دنکار (۲۰۱۹) طی شرکت در یک رقابت با حداقل تشخیص قابل قبول ۶۰٪ در تشخیص چندین نوع احساسات عاطفی مردم از قبیل شادی، غمگین، عصابانی و غیره، با ترکیب عماری رز نت ۵۰٪ و وی جی ۱۶٪، به حداقل دقت ۹۲٪ دست یافتند. البته دقت تشخیص عماری اولی بیشتر از دومی بود [۱۲] نتایج تحقیقات برمانا و همکاران (۲۰۲۰) به منظور مقایسه عملکرد دو نوع عماری از شبکه‌های عصبی حلقوی یعنی مدل موبایل نت و مدل شبکه عصبی خود ساخته^۷ (SSCNN)، نشان داد که دقت آموزش و صحت اعتبار سنجی آنها بترتیب ۹۸٪ و ۹۲٪ و ۹۸٪ و ۹۹٪ می‌باشد. البته تعداد عکس

1. Convolutinal Neural Networks
2. Olive Quick Decline Syndrome
3. Alexnet
4. VGG
5. ResNet 50
6. VGG16
7. Self-Structured (SSCNN)

8. Smartmobiles

9. Convolutinal Neural Network

Table 1 Data set overview

Class	Pests common name	Pest scientific name	Images No.
1	Citrus leafminer	<i>Phyllocnistis citrella</i>	503
2	Sooty Mold	Black Sooty Mold on Citrus	732
3	Pulvinaria	<i>Pulvinaria aurantii</i>	539
Total			1774



Fig 1 Samples from the three examined classes: (a) Citrus Leafminer (b) Sooty Mold (c) Pulvinaria

بهبود می‌یابد. مژول باقیمانده می‌تواند یک سری عملیات را روی ورودی انجام دهد یا تمام این مراحل را رد کند. این مژول‌های باقیمانده به طور کلی روی هم سوار می‌شوند تا یک شبکه کامل ایجاد شود. معماری وی جی جی ۱۶ که توسط سیمونیان و زیسرمن (۲۰۱۴) در رقابت ILSVRC^۱ در سال ۲۰۱۴ با این دیدگاه که معماری عمیق‌تر باعث افزایش دقت می‌شود، ارائه گردید که به خطای $7/3$ درصدی دست یافت [۱۴]. شبکه وی جی جی شامل ۱۶ لایه حلقوی یا ۱۶ لایه پارامتری است. یکی از ویژگی‌های این شبکه این است که در آن لایه‌هایی که به تصویر نزدیکتر هستند، پهن‌تر و لایه‌های دورتر، عمیق‌تر هستند. وی جی جی شامل یک سری از لایه‌های محاسباتی است که پشت آن‌ها لایه‌های جمع‌کننده^۲ وجود دارند که لایه‌ها را کوچکتر می‌کنند. درنهایت، ویژگی‌ها تبدیل به یک بردار ویژگی می‌شوند تا در اختیار لایه‌های عصبی (نرونی) یا تمام اتصال^۳ قرار گیرند. نمودار کلی روش تشخیص آفات مرکبات در شکل ۲ نشان داده شده است. در روش پیشنهادی، مدل (معماری) بر اساس تکنیک انتقال یادگیری، آموختش داده شد. در این تحقیق از رویکرد یادگیری انتقالی استفاده شد.

۲-۲-روش‌ها

معماری‌های اصلی شبکه عصبی حلقوی که در این تحقیق برای تشخیص آفات مرکبات از تصاویر برگ‌ها بکار گرفته شد، رزن特 ۵۰ و وی جی جی بود. ابتدا شاخصه‌های این معماری‌ها مرور و سپس نحوه بکارگیری آنها شرح داده می‌شود. در معماری رزن特 ۵۰ از ویژگی افزایش عمق شبکه (یعنی افزایش تعداد لایه‌های حلقوی) بدون افزایش تعداد پارامترهای آموزشی که منجر به استخراج معنی دار و متفاوت‌تر ویژگی‌ها می‌شود، استفاده گردید، تا دقت طبقه بنده را بهبود بخشد. رزن特 ۵۰ به عنوان بزرگترین معماری معروف شده توسط هی و همکاران (۲۰۱۶) توانست در بسیاری از مسابقات موفق شود [۱۴]. این معماری با عمق ۱۵۲ لایه تا آن سال به عنوان عمیق‌ترین معماری شناخته شد و هنوز هم یکی از عمیق‌ترین معماری‌ها است. یکی دیگر از ویژگی‌های این معماری شامل چندین مژول (واحد) باقیمانده که روی یکدیگر سوار شده‌اند، می‌باشد که در واقع ساختمان اصلی معماری رزن特 ۵۰ را تشکیل می‌دهند. در جدیدترین نسخه آن از اشاره‌گرهای خاص به نام اشاره‌گرهای جهشی استفاده می‌شود که به طور مستقیم لایه‌های حلقوی را به لایه‌های بالای آنها ارتباط می‌دهد و بدین ترتیب عمل بهینه‌سازی در آن انجام و در نتیجه وزن شبکه

1. ImageNet Large Scale Visual Recognition Challenge
2. Pooling
3. Fully Connected

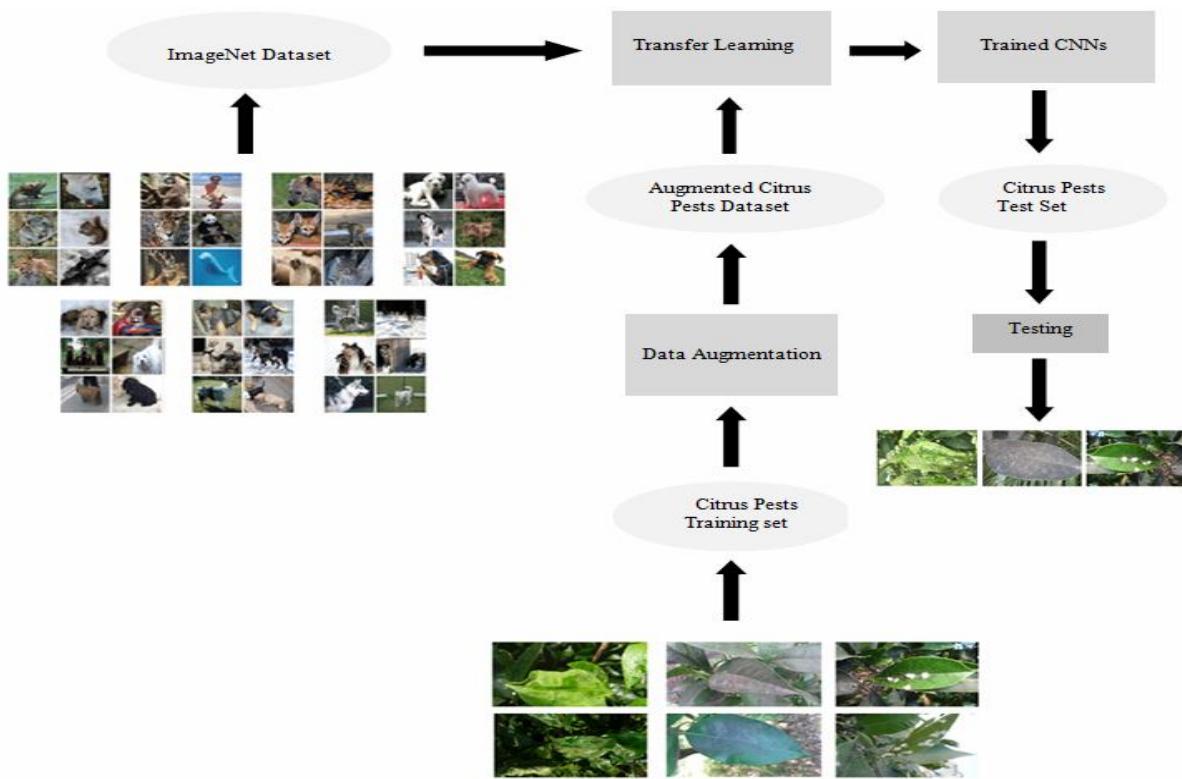


Fig 2 Block Diagram of the proposed method

آموزش داده می‌شوند، یک استراتژی مناسب است. به عنوان یکی دیگر از روش‌های پیشنهادی، برای کاهش خطر بیش‌برازش^۲ و بهبود دقت طبقه‌بندی، از افزونه‌سازی داده‌ها برای افزایش تعداد نمونه‌ها استفاده شد. از این‌رو افزایش تعداد نمونه‌ها و به تبع آن، پر کردن فضای ویژگی نمونه‌ها می‌تواند قابلیت تعمیم‌پذیری مدل پیشنهادی را ارتقاء دهد. افزونه‌سازی داده‌های انجام شده در این تحقیق شامل چرخش تصویر در چهار جهت (۴۵ درجه، ۹۰ درجه، ۱۳۵ درجه و ۱۸۰ درجه)، قرینه کردن و همچنین اضافه کردن نویز گوسی^۳ مصنوعی به تصویر بود. نمونه‌هایی از افزونه‌سازی داده بر روی سه نوع آفت مركبات مورد مطالعه در شکل‌های ۴،۳ و ۵ نشان داده شده است. در این پژوهش به منظور ارتقاء قابلیت اطمینان، این استراتژی ارزیابی، ده بار تکرار شد. در مدل‌های مورد استفاده، فرآیندهای آمده‌سازی و تست آنها در نرم افزار مطلب انجام شد. برای کاهش زمان آموزش، بروزرسانی وزن شبکه عصبی از جی پی یو^۴ (GPU) استفاده شد. سپس الگوریتم آماده سازی بر روی جی پی یو با کارت گرافیک مدل TI 1080 حافظه ۳۲ گیگ و CPUX 695 با استفاده از نرم افزار مطلب و در محیط ویندوز اجرا گردید.

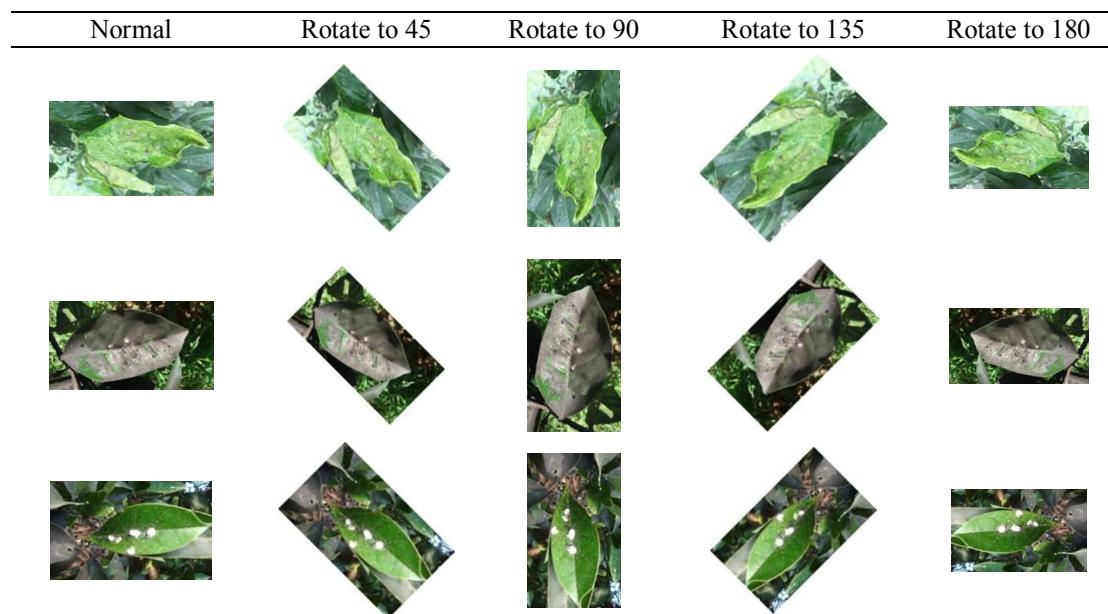
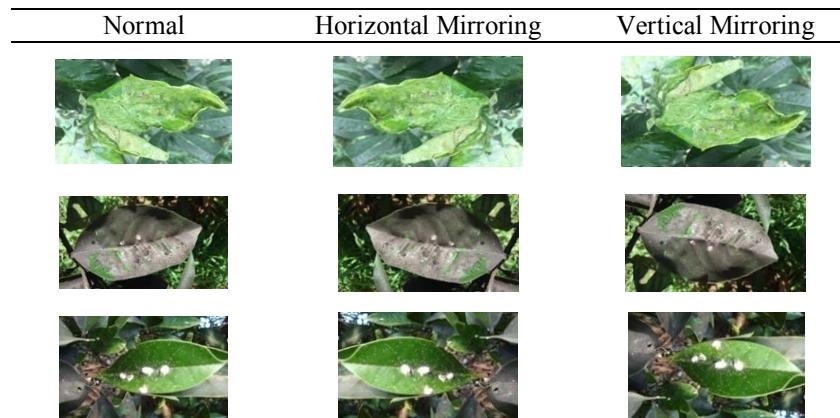
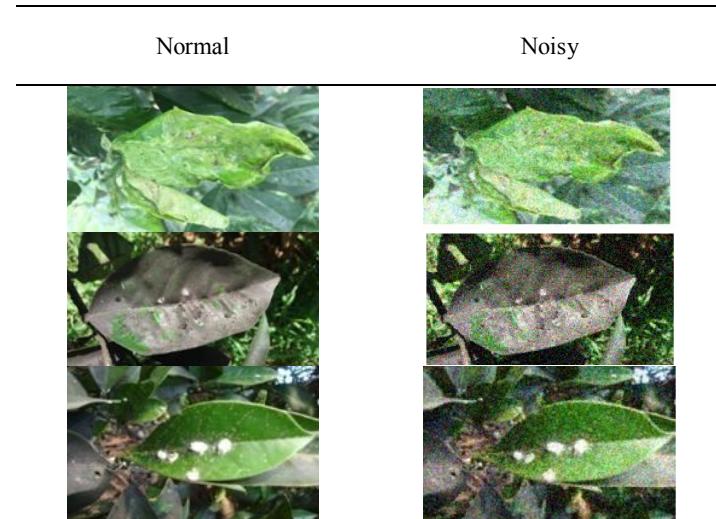
2. Overfitting

3. Gaussian Noise

4. Graphic Process Unit

بطوریکه فقط لایه‌های کاملاً متصل انتهایی شبکه باز تنظیم شدند (و نه تمام وزن‌ها). همچنین، جهت افزایش تعداد نمونه‌های آموزش و به تبع آن افزایش قابلیت تعمیم طبقه‌بند از افزونه‌سازی داده‌ها از طریق چرخش، آینه‌سازی و اضافه کردن نویز گوسی استفاده گردید. در این رویکردها، آموزش کل وزن شبکه از ابتدا در لایه‌های مختلف ضرورت نداشت، زیرا از یک مدل از پیش‌آموزش داده شده بر روی مجموعه داده ایمیج‌نت^۱ استفاده شد، با این تفاوت که وزن تمامی لایه‌ها به غیر از دو لایه آخر، ثابت در نظر گرفته شد که طی آن، تنها وزن‌های مربوط به دو لایه آخر تنظیم شدند. توجه به این نکته حائز اهمیت است که تعداد نرون‌های لایه آخر در معماری‌های از پیش آموزش دیده برابر تعداد کلاس‌ها است. از این‌رو، در دو رویکرد پیشنهادی، تعداد نرون‌های لایه آخر برابر سه در نظر گرفته شد. در تکنیک انتقال یادگیری، ویژگی‌های اساسی استخراج شده از فیلترهای اولیه، برای انواع مختلف تصاویر یکسان هستند. بنابراین لازم نبود که وزن فیلترهای اولیه مجدداً از لایه اول تنظیم شوند. این استراتژی باعث تسريع در فرایند آموزش با ثابت نگهداشتن لایه‌های حلقوی اولیه در شبکه‌های عصبی عمیق می‌شود. همچنین، انتقال یادگیری هنگامی که شبکه‌های عصبی حلقوی روی یک مجموعه داده کوچک

1. ImageNet

**Fig 3** Data augmentation by image rotation with different angles**Fig 4** Data augmentation by image mirroring**Fig 5** Data augmentation by adding Gaussian noise

داده‌ها در ابتدا به دو مجموعه آموزش و امتحان تقسیم شدند.

سپس ۱۷۷۴ تصویر جمع‌آوری شده به روش تصادفی در دو

۳- نتایج و بحث

بار تکرار شد و نتیجه آن (جدول ۲) نشان داد که انحراف معیار مدل‌ها از مقادیر کمی برخوردار است. پارامترهای این مدل یادگیری عمیق در جدول ۳ ارائه شده است.

مجموعه فوق قرار گرفتند، به طوری که ۷۰ درصد از آنها مجموعه آموزش و ۳۰ درصد مجموعه تست را تشکیل می‌دادند. بنابراین، برای آموزش مدل‌های شبکه عصبی حلقوی، از ۱۲۴۱ تصویر تصادفی استفاده شد. این استراتژی ارزیابی ده

Table 2 The mean accuracy and standard deviation of models when 70% of samples randomly selected for training and the others for testing

CNN Model	Mean Accuracy (%)	Standard Deviation (%)	Min. Accuracy (%)	Max. Accuracy (%)
Resnet 50	95.838	0.8658	94.9722	96.7038
VGG16	88.789	0.7556	88.0334	89.5446

Table 3 Hyper-parameters of the used CNN models

Optimizer	Bach size	Number of epochs	Learning rate	Weight decay
Stochastic Gradient Decent (SGD)	64	10	0.001	0.00001

ماتریس‌ها و سپس تقسیم بر تعداد کل تصاویر، دقت محاسبه گردید. همانطور که مشاهده می‌شود، عملکرد مدل‌های شبکه عصبی حلقوی در جدول ۲ و جدول ۴ تقریباً مشابه است. با این وجود، مرحله آموزش مدل‌های شبکه عصبی حلقوی به طور کلی زمانبر است، اما مسئله پیچیده‌ای در انجام طبقه‌بندی وجود ندارد. زیرا طبقه‌بندها بصورت غیر بر خط آموزش می‌بینند. به هر حال واضح است که آموزش سریع بدون تاثیر منفی بر روی دقت برای طبقه‌بندها یک مزیت بسیار می‌آید. در شکل ۶ زمان آموزش و دقت مدل‌های مورد بررسی نشان داده شده است.

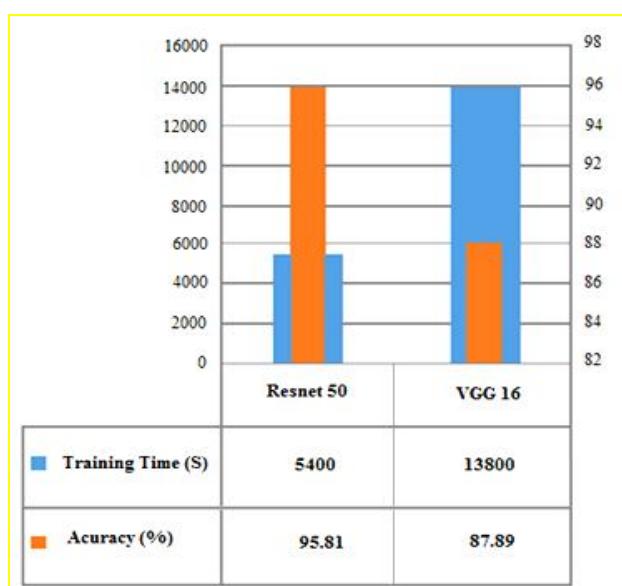


Fig 6 Training time and accuracy of the proposed CNN architectures

در این تحقیق از روش استاندارد دیگری موسوم به اعتبارسنجی متقطع دهتایی^۱ نیز جهت ارزیابی کارایی شبکه‌های عصبی حلقوی پیشنهادی استفاده شد که طی آن کل مجموعه داده به صورت تصادفی به ده قسمت مساوی تقسیم شدند. در هر تکرار، یک قسمت جهت تست کنار گذاشته شد و طبقه بند روی نه قسمت باقیمانده آموزش دید و سپس روی قسمت کنار گذاشته شده، آزمایش و دقت آن اندازه گیری شد. در تکرار بعدی، قسمت دوم جهت تست کنار گذاشته شد و این روند به همین ترتیب ادامه پیدا کرد تا جایی که تمامی قسمت‌ها مورد آزمایش قرار گیرند. نهایتاً، با توجه به مجموع خطاهای روی تمام قسمت‌ها، خطای کلی سیستم تعیین شد. مهمترین مزیت این استراتژی آزمایش، این است که عملکرد مدل‌های استفاده شده نه تنها بر روی بخشی از مجموعه داده‌ها بلکه بر روی تمامی آنها مورد ارزیابی قرار گرفت. نتیجه حاصل از ارزیابی اعتبارسنجی متقطع دهتایی در جدول ۴ نشان ارائه شده است.

Table 4 Accuracy of the CNN models based on 10-fold cross validation

CNN Model	Accuracy
ResNet50	95.81
VGG16	87.89

در جدول ۵ ماتریس‌های ترکیبی ناشی از استراتژی اعتبارسنجی متقطع دهتایی ارائه شده است. با استفاده از این ماتریس می‌توان دریافت که چند نمونه در کلاس‌های دیگر طبقه بندی نشده‌اند. علاوه بر این، با جمع عناصر قطر اصلی این

1. 10-Fold Cross Validation

Table 5 Confusion matrices of the proposed CNN architectures

	ResNet50	Predicted Class			VGG16	Predicted Class		
		Citrus leafminer	Sooty Mold	Pulvinaria		Citrus leafminer	Sooty Mold	Pulvinaria
Actual Class	Citrus leafminer	484	6	13	Citrus leafminer	437	29	27
	Sooty Mold	10	708	14	Sooty Mold	34	648	50
	Pulvinaria	12	20	507	Pulvinaria	26	49	474

سنگین مانند وی جی را بهبود ببخشد. بطوریکه تفاوت دقت مدل وی جی با افزونه سازی و بدون افزونه سازی داده ها ۱/۴۶ درصد است. اما این تفاوت در مدل رزن特 ۰/۲۸ درصد می باشد. لذا، مطلب فوق نشان می دهد که برای مجموعه داده های کم، دقت مدل رزننت به دلیل داشتن پارامترهای آموزشی کمتر و عمق بیشتر نسبت به وی جی بیشتر است.

Table 6 the impact of data augmentation on the accuracy of CNN models

CNN Model	Accuracy (with augmentation)	Accuracy (without augmentation)
ResNet50	96.05	95.77
VGG16	89.34	87.88

تصویر برگ مرکبات در تشخیص سه نوع آفت متدالوی مرکبات یعنی پروانه مینوز برگ ، فوماژین (قارچ دوده مرکبات) و بالشتک، ارزیابی شد. برای تهیه مجموعه داده های متنوع، از دوربین های مختلف در شرایط مختلف نوری و بازه های زمانی متفاوت استفاده شد. بر اساس آزمایشات انجام شده و استفاده از روش افزونه سازی داده ها، دقت تشخیص مدل رزننت به بالاترین دقت به مقدار ۹۶/۰۵ درصد رسید. با چنین مجموعه ای از داده ها و دقت نسبتاً بالای بدست آمده، روش پیشنهادی در شرایط میدانی دارای اعتبار و تعیین پذیری مطلوب می باشد و می تواند در تشخیص خودکار آفات در مزارع وسیع به خوبی عمل نماید و حتی به عنوان ورودی ربات ها و پهپاد های سه پا مش در چنین مزارعی مورد استفاده قرار گیرد.

۵- قدردانی

از گروه فناوری و مدیریت تولید پژوهشکده مرکبات و میوه های نیمه گرمسیری کشور مستقر در شهرستان رامسر، استان مازندران بخصوص آقای دکتر اسماعیل غلامیان به دلیل همکاری در آماده سازی پایگاه داده این تحقیق قدردانی می شود.

همان طور که در بخش قبلی ذکر شد، افزونه سازی داده برای افزایش تعداد داده ها، یکی از مزایای روش پیشنهادی محاسبه می شود. بطوریکه با انجام آن دقت مدل های رزننت ۵۰ و وی جی جی بتر تیب از مقادیر ۹۵/۷۷٪ به ۹۶/۰۵٪ و ۸۷/۸۸٪ به ۸۹/۳۴٪ ارتقاء یافت (جدول ۶). همچنین میتوان دریافت افزونه سازی داده می تواند دقت کلیه مدل ها به ویژه مدل های

دلیل اصلی برتر بودن مدل رزننت در مقایسه با مدل دیگر، سادگی و معماری عمیق تر آن است. مدل رزننت نسبت به مدل های دیگر به دلیل کم بودن پارامترهای آموزش دهنده آن ساده تر و به دلیل تأثیر مثبت اشاره گرهای جهشی در معماری آن، عمیق تر است. از اینرو، رزننت برای مجموعه داده های کم، گزینه خوبی است. البته، با مقایسه ستون های ۲ و ۳ در جدول ۶ می توان دریافت با افزایش تعداد تصاویر در مجموعه داده، دقت مدل هایی با پارامترهای آموزش دیده زیاد مانند وی جی به دقت مدل رزننت، قدری نزدیک شده است. بطور کلی مقادیر دقت تشخیص ۹۶/۰۵ برای مدل رزننت و ۸۹/۳۴ برای مدل وی جی ۱۶ در شرایط مزرعه ای در مقایسه با بسیاری از تحقیقات انجام شده که در شرایط آزمایشگاهی انجام شدند، میتواند از کارآیی بهتری برخوردار باشد.

۶- نتیجه گیری

در این تحقیق، یک رویکرد محاسباتی برای تشخیص آفات متدالوی مرکبات در شمال ایران از طریق یادگیری عمیق ارائه شد. برای این منظور، عملکرد دو معماری معروف شبکه عصبی حلقوی به نام های رزننت و وی جی بر روی ۱۷۷۴

in Agriculture, 150, 220–234.

- [8] Rauf, H.T., Saleem, B. A., Ullah Lali, M. I., Khan, M. A., Sharif, M. and Chan Bukhari, S. A. 2019. A citrus fruits and leaves dataset for detection and classification of citrus diseases through machine learning. *Data in brief*, 26, 1-7.
- [9] Luvisi, A., Ampatzidis, Y. and Debelleis, L. 2016. Plant pathology and information technology: Opportunity for management of disease outbreak and applications in regulation frameworks. *Sustainability*, 8(8), 831.
- [10] Cruz, A.C., Luvisi, A., Debelleis, L. and Ampatzidis, Y. 2017. X-FIDO: An effective application for detecting olive quick decline syndrome with deep learning and data fusion. *Frontiers in Plant Science*, 8, 1–12.
- [11] Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318.
- [12] Dhankhar, P. 2019. ResNet-50 and VGG-16 for recognizing Facial Emotions. *International Journal of Innovations in Engineering and Technology*. 13(4): 126-130.
- [13] Barmana, U. , Choudhuryb, R.D, Sahuc, D. and Barmanc, G. G. 2020. Comparison of convolution neural networks for smartphone image based real time classification of citrus leaf disease. *Computers and Electronics in Agriculture*. 177, 1-9.
- [14] He, K., Zhang, X., Ren, S. and Sun, J. 2016. Deep residual learning for image recognition. *Institute of Electrical and Electronics Engineering (IEEE) Conference on Computer Vision and Pattern Recognition*, pp. 770–778. Las Vegas, USA.

۶- منابع

- [1] Iqbal, Z., Khan, M. A., Sharif, M., Shah, J.H., Rehman, M. H. and Javed, K. 2018. An automated detection and classification of citrus plant diseases using image processing techniques. A review: *Computers and Electronics in Agriculture*. 153, 12-32.
- [2] Kaur, S., Pandey, S. and Goel, S. 2018. A semi-automatic leaf disease detection and classification system for soybean culture. *IET Image Processing*, 12 (6): 1038-1048.
- [3] Gavhale, K. R., Gawande, U. and Hajari, K. 2014. Unhealthy Region of Citrus Leaf Detection Using Image Processing Techniques. *Proceeding of International Conference for Convergence for Technology*, 6-8 April 2014.
- [4] Zhou, R., Kaneko, S., Tanaka, F., Kayamori, M. and Shimizu, M. 2014. Disease detection of cercospora leaf Spot in sugar beet by robust template matching. *Computers and Electronics in Agriculture*, 108, 58–70.
- [5] Sengar, N., Dutta, M.K. and Travieso, C.M. 2018. Computer vision based technique for identification and quantification of powdery mildew disease in cherry leaves. *Computing*, 100(11): 1–13.
- [6] Ali, H., Lali, M. I., Nawaz, M. Z., Sharif, M. and Saleem, B. A. 2017. Symptom based automated detection of citrus diseases using color histogram and textural descriptors. *Computers and Electronics in Agriculture*, 138, 92–104.
- [7] Sharif, M., Khana, M.A., Iqbala, Z., Azama, M.F., Lalib, M.I.U. and Javedc, M.Y. 2018. Detection and classification of citrus diseases in agriculture based on optimized weighted segmentation and feature selection. *Computers and Electronics in Agriculture*

Detection of common citrus pests in northern Iran using a Deep Convolutional Neural Network

Khanramaki, M.¹, Askari Asli Ardeh, E. ^{2*}, Kozegar, E.³, Loni, R.⁴

1. Phd Student, Department of Biosystems Engineering, University of Mohaghegh Ardabili, Ardabil, Iran
2. Associate professor, Department of Biosystems Engineering, University of Mohaghegh Ardabili, Ardabil, Iran
3. Assistant professor, Department of Computer Engineering and Engineering Sciences, Faculty of Technology and Engineering, University of Guilan, Guilan, Iran
4. Postdoc Researcher, Department of Biosystems Engineering, Tarbiat Modares University, Tehran, Iran

(Received: 2020/05/24 Accepted: 2020/09/02)

Plant pests and diseases are a major threat to human food security. In large farms, accurate and timely human diagnosis is not possible due to time consuming and possible misdiagnosis. Therefore, for immediate, automatic, appropriate and accurate detection of agricultural pests, the use of image processing and artificial intelligence, including deep learning can be very useful. In this study, convolutional neural network models have been developed to identify three common citrus pests in northern Iran such as citrus leafminer, sooty mold and pulvinaria using images of infected leaves, through deep learning methods. For this purpose, Resnet50 and VGG16 architectures are trained as well-known convolutional neural networks, applying the transfer learning method on 1774 images of infected citrus leaves, accumulated from natural and field conditions. In the training phase, data augmentation is used to increase the number of training samples, and to improve the generalizability of the classifiers. For experimental analysis, cross validation strategy is used to evaluate the accuracy of the convolutional neural network. In this strategy, all images are tested without any overlap between training and test sets. Based on the results, the accuracies of Resnet 50 and VGG 16 models are evaluated as 96.05 and 89.34%, respectively. Hence, the Resnet 50 model can convert the above method into a very suitable early consulting or warning system.

Key words: Citrus pests, Deep Learning, Convolutional Neural Networks, ResNet50, VGG16

* Corresponding Author Email Address: ezzataskari@uma.ac.ir