

علمی پژوهشی

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

مرتضی خان رمکی<sup>۱</sup>، عزت اله عسکری اصلی ارده<sup>۲\*</sup> و احسان اله کوزه گر<sup>۳</sup>،  
ریحانه لونی<sup>۴</sup>

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 بیماری های گیاهی یک تهدید عمده برای امنیت غذایی بشر بشمار می آیند. در مزارع وسیع، تشخیص دقیق و به هنگام توسط انسان به دلیل زمان بر بودن و احتمال تشخیص اشتباه امکان پذیر نمی باشد. از اینرو برای تشخیص فوری، اتوماتیک، مناسب و دقیق آفات کشاورزی، استفاده از پردازش تصویر و هوش مصنوعی از جمله یادگیری عمیق می تواند بسیار مفید باشد. در این تحقیق، مدل های شبکه عصبی حلقوی برای تشخیص و شناسایی سه نوع آفت مرکبات متداول در شمال ایران نظیر پروانه مینوز، فوماژین (قارچ دوده مرکبات) و بالشتک با استفاده از تصاویر برگ های آلوده، از طریق روش های یادگیری عمیق توسعه داده شده است. برای این منظور معماری های رزنت و وی جی جی به عنوان شبکه عصبی حلقوی معروف که با استفاده از روش انتقال یادگیری بر روی ۱۷۷۴ تصویر برگ آلوده مرکبات در شرایط طبیعی و مزرعه ای فراهم گردید، آموزش داده شد. در مرحله آموزش، از روش افزونه سازی داده ها برای افزایش تعداد نمونه های آموزشی و بهبود تعمیم پذیری طبقه بندها استفاده گردید. برای تجزیه و تحلیل تجربی از اعتبارسنجی ضربدری به منظور اندازه گیری دقت شبکه عصبی حلقوی استفاده شد. در این استراتژی همه تصاویر بدون هیچگونه همپوشانی مجموعه داده های آموزش و امتحان، آزمایش شدند. بر اساس نتایج به دست آمده دقت مدل های رزنت و وی جی جی به ترتیب ۹۶/۰۵ و ۸۹/۳۴ درصد ارزیابی گردید. از اینرو مدل رزنت، می تواند روش فوق را به یک سیستم مشاوره یا هشداردهنده اولیه بسیار مناسب تبدیل کند.

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

\*مسول مکاتبات: ezzataskari@uma.ac.ir

## 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 منبع غنی از ترکیبات آنتی‌اکسیدان، ترکیبات فنلی، ویتامین C و کاروتنوئیدها (مانند بتاکاروتن، گزانتوفیل، گریپتو گزانتین و ویلوگزانتین) محسوب می‌شوند. همچنین میوه مرکبات غنی از ویتامین‌های A و B، کربوهیدرات (قند های ساده فروکتوز، گلوکز 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 بی‌رویه از سموم در مبارزه شیمیایی با آفات و بیماری‌ها باعث آلودگی های زیست محیطی نظیر 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 هزینه های تولید نیز می‌شود. انجام عملیات فوق نیاز به نظارت و پایش مستمر دارد و در صورت انجام توسط انسان، امکان خطا در تشخیص نوع آفت یا بیماری وجود دارد و همچنین مستلزم صرف هزینه و زمان است. در سال های اخیر، مطالعات مختلفی در توسعه فنون ماشین‌بینایی جهت تشخیص بیماری از تصاویر برگ در شرایط آزمایشگاهی صورت گرفته است. توسط ایقبال و همکاران (۲۰۱۸) مطالعه مروری به منظور شناسایی خودکار و طبقه بندی بیماری های مرکبات با استفاده از پردازش تصویر انجام و ضمن بررسی چالش ها در استفاده از انواع روشها در مراحل مختلف پردازش تصویر، K-means بعنوان یک تقسیم کننده و ماشین بردار پشتیبان<sup>۱</sup> بعنوان یک طبقه‌بند 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 لوبیا گلپسین مکس با الگوریتم بخش‌بندی مبتنی بر k-means ارائه کردند. این روش توانست از روی تصاویر

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، خوشه 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<sup>۲</sup>، ارائه یک هیستوگرام دوبعدی و بکارگیری ماشین بردار پشتیبان به نتایج مطلوبی در تشخیص قارچ چقندر قند دست یابند [۴]. سنگار و همکاران (۲۰۱۸) یک روش آستانه‌گذاری قوی برای اندازه‌گیری پیشرفت کپک پودری در گیلاس پیشنهاد کردند [۵]. در این تحقیق از داده‌های تارنمای دهکده گیاه<sup>۳</sup> استفاده شده است. علی و همکاران (۲۰۱۷) روش جدیدی را برای تشخیص و طبقه‌بندی بیماری‌های مرکبات با استفاده از الگوریتم تفاوت رنگ  $\Delta E$  برای تشخیص قسمت‌های آلوده در تصویر ارائه دادند [۶]. در این روش از رنگ، الگوریتم هیستوگرام شیب‌های جهت‌دار<sup>۴</sup> و ویژگی‌های بافت برای طبقه‌بندی بیماری‌های مرکبات استفاده شد و بطور قابل توجهی، عملکرد بر حسب دقت و سطح زیر منحنی<sup>۵</sup> 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 طبقه‌بندی شدند. این روش بر روی مجموعه داده‌های گالری تصاویر مرکبات که از تارنمای دهکده گیاه و داده‌های محلی تهیه شد، آزمایش گردید و نتایج حاکی از این بود که این روش توانایی تشخیص آنتراکنوز، لکه سیاه، شانکر، اسکب، سبزشدگی و ملانوز را دارد. رئوف و همکاران (۲۰۱۹) مجموعه ای 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].

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<sup>۸</sup> تهیه شده بود [۱۳].

هدف از این تحقیق، استفاده از دو معماری از شبکه عصبی حلقوی<sup>۹</sup> 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 پهبادها 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

### ۲-۱ جمع‌آوری داده‌ها

عملیات عکس‌برداری سه نوع آفت متداول گیاه مرکبات در شمال ایران نظیر پروانه مینوز، فوماژین (قارچ دوده مرکبات) و بالشتک در زوایا و شرایط نوری متفاوت نظیر هوای کاملاً آفتابی، نیمه ابری و کاملاً ابری در سه بازه زمانی صبح، ظهر و عصر توسط سه دوربین سونی مدل DSC-W170، دوربین گوشی Samsung-Galaxi J5، Samsung-Galaxi Grand Prime و iPhone X6 برای دستیابی به تصاویر متفاوت آفات، مستقل از پارامترهایی نظیر 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<sup>۱</sup> 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 حلقوی، شکل 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 علائم مشابه به کار گرفته شد که زمان و هزینه تشخیص را به میزان قابل توجهی کاهش داد [۳ و ۹]. به عنوان مثال، کروز و همکاران (۲۰۱۷) برنامه‌ای را مبتنی بر بینایی ماشین برای تشخیص علائم سندرم زوال سریع زیتون<sup>۲</sup> روی برگ‌های زیتون اروپایی آلوده به بیماری *Xylella fastidiosa* توسعه دادند [۱۰]. فرنتینوس (۲۰۱۸) از شبکه‌های آکس‌نت<sup>۳</sup> و وی‌جی‌جی<sup>۴</sup> استفاده کرد تا طیف گسترده‌ای از بیماری‌های گیاهی شامل سبزیجات و میوه‌جات را شناسایی نماید. بیشتر تصاویر بکارگرفته شده در شرایط آزمایشگاهی تهیه شده‌اند [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، عصبانی و غیره، با ترکیب معماری رزنت<sup>۵</sup> و وی‌جی‌جی<sup>۶</sup> ۱۶، به حداکثر دقت ۹۲/۴٪ دست یافتند. البته دقت تشخیص معماری اولی بیشتر از دومی بود [۱۲]. نتایج تحقیقات برمانا و همکاران (۲۰۲۰) به منظور مقایسه عملکرد دو نوع معماری از شبکه‌های عصبی حلقوی یعنی مدل موبایل‌نت و مدل شبکه عصبی خود ساخته<sup>۷</sup> (SSCNN)، نشان داد که دقت آموزش و صحت اعتبار سنجی آنها برترتیب ۹۸٪، ۹۲٪ و ۹۸٪، ۹۹٪ می‌باشد. البته تعداد عکس

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

8. Smartmobiles
9. Convolutional Neural Network

Table 1 Data set overview

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



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

بهبود می‌یابد. ماژول باقیمانده می‌تواند یک سری عملیات را روی ورودی انجام دهد یا تمام این مراحل را رد کند. این ماژول‌های 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<sup>1</sup> 2014 با این دیدگاه که معماری عمیق‌تر باعث افزایش دقت می‌شود، ارائه گردید که به خطای ۷/۳ 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<sup>۲</sup> وجود دارند که لایه‌ها را کوچکتر می‌کنند. در نهایت، ویژگی‌ها تبدیل به یک بردار ویژگی می‌شوند تا در اختیار لایه‌های عصبی (نرونی) یا تمام اتصال<sup>۳</sup> 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، آموزش 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، رزنت ۵۰ و وی جی جی بود. ابتدا شاخصه‌های این معماری‌ها مرور و سپس نحوه بکارگیری آنها شرح داده می‌شود. در معماری رزنت ۵۰ از ویژگی افزایش عمق شبکه (یعنی افزایش تعداد لایه‌های حلقوی) بدون افزایش تعداد پارامترهای آموزشی که منجر به استخراج معنی دار و متفاوت تر ویژگی‌ها می‌شود، استفاده گردید، تا دقت طبقه بندی را بهبود بخشد. رزنت ۵۰ به‌عنوان بزرگترین معماری معرفی 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 ماژول (واحد) باقیمانده که روی یکدیگر سوار شده‌اند، می‌باشد که در واقع ساختمان اصلی معماری رزنت 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

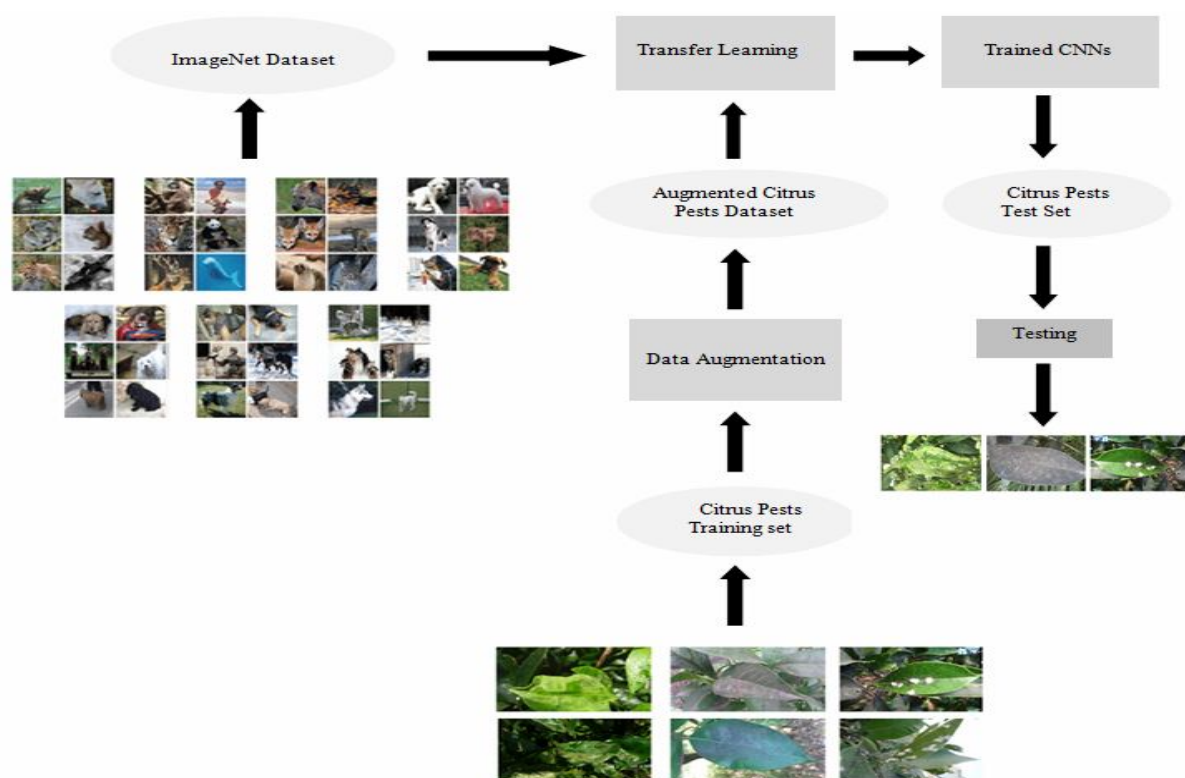


Fig 2 Block Diagram of the proposed method

آموزش داده می‌شوند، یک استراتژی مناسب است. به عنوان یکی دیگر از روش‌های پیشنهادی، برای کاهش خطر بیش‌برازش<sup>۲</sup> 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<sup>۳</sup> مصنوعی به تصویر بود. نمونه‌هایی از افزونه‌سازی داده بر روی سه نوع آفت مرکبات 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 آماده‌سازی و تست آنها در نرم افزار مطلب انجام شد. برای کاهش زمان آموزش، برورسانی وزن شبکه عصبی از جی پی یو<sup>۴</sup> (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.

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، آیین‌سازی 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<sup>۱</sup> 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 تسریع 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

2. Overfitting  
3. Gaussian Noise  
4. Graphic Process Unit

1. ImageNet






Fig 3 Data augmentation by image rotation with different angles

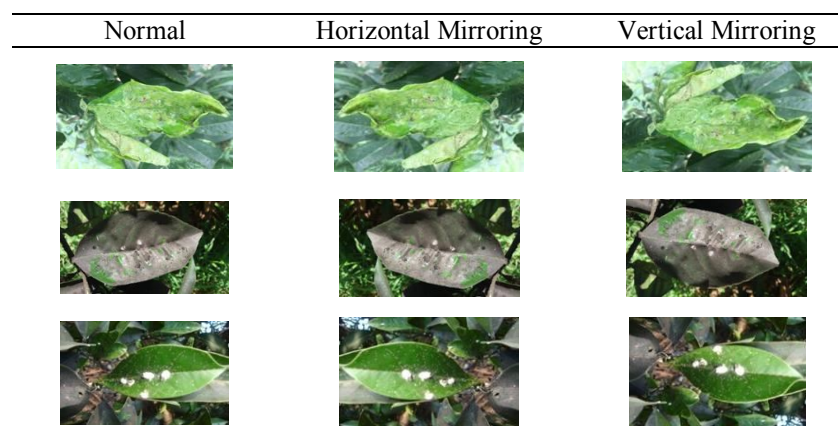


Fig 4 Data augmentation by image mirroring




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 فوق‌تر 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 بشمار می‌آید. در شکل ۶ زمان آموزش و دقت مدل‌های مورد بررسی نشان داده شده است.

در این تحقیق از روش استاندارد دیگری موسوم به اعتبارسنجی متقاطع ده‌تایی<sup>۱</sup> 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 طبقه‌بند روی نه قسمت باقیمانده آموزش دید و سپس روی قسمت کنار گذاشته شده، آزمایش و دقت آن اندازه‌گیری 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 خطاها 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 متقاطع ده‌تایی در جدول ۴ نشان ارائه شده است.



**Fig 6** Training time and accuracy of the proposed CNN architectures

**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 متقاطع ده‌تایی ارائه شده است. با استفاده از این ماتریس می‌توان دریافت که چند نمونه در کلاس‌های دیگر طبقه‌بندی نشده‌اند. علاوه بر این، با جمع عناصر قطر اصلی این

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

همان طور که در بخش قبلی ذکر شد، افزونه سازی داده برای افزایش تعداد داده ها، یکی از مزایای روش پیشنهادی محسوب می شود. بطوریکه با انجام آن دقت مدل های رزنت 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

**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 متداول 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 رزنت 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 تعمیم 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 سمپاش در چنین مزارعی مورد استفاده قرار گیرد.

دلیل اصلی برتر بودن مدل رزنت در مقایسه با مدل دیگر، سادگی و معماری عمیق تر آن است. مدل رزنت 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 این رو، رزنت 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 مدلهایی با پارامترهای آموزش دیده زیاد مانند وی جی جی به دقت مدل رزنت، قدری نزدیک شده است. بطورکلی مقادیر دقت تشخیص ۹۶/۰۵ برای مدل رزنت ۵۰ و ۸۹/۳۴ برای مدل وی جی جی ۱۶ در شرایط مزرعه ای در مقایسه با بسیاری از تحقیقات انجام شده که در شرایط آزمایشگاهی انجام شدند، میتواند از کارایی بهتری برخوردار باشند.

## 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.

## ۴- نتیجه گیری

در این تحقیق، یک رویکرد محاسباتی برای تشخیص آفات متداول مرکبات در شمال ایران از طریق یادگیری عمیق ارائه شد. برای این منظور، عملکرد دو معماری معروف شبکه عصبی حلقوی به نام های رزنت و وی جی 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 Debellis, 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., Debellis, 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*

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

Khanramaki, M.<sup>1</sup>, Askari Asli Ardeh, E.<sup>2\*</sup>, Kozegar, E.<sup>3</sup>, Loni, R.<sup>4</sup>

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