

مقاله پژوهشی

شناسایی آفات مرکبات با به‌کارگیری پهپاد و روش‌های هوش مصنوعی

رمضان هادی‌پور رکنی^۱، عزت‌اله عسکری اصلی ارده^۲ و سجاد سبزی^۳

چکیده

امروزه اجرای کشاورزی دقیق با هدف مدیریت و کنترل آفات می‌تواند در استفاده بهینه از سموم، کاهش اثرات نامطلوب زیست محیطی و تضمین سلامتی بشر مؤثر باشد. لیکن مدیریت تک‌تک درختان در سطح وسیع چالش بزرگی به‌شمار می‌آید. بنابراین، به‌کارگیری یک سامانه بینایی ماشین برای پایش و شناسایی آفات درختان در مرحله داشت ضروری به‌نظر می‌رسد. در این پژوهش، یک پهپاد مجهز به دوربین برای شناسایی آفات در نقاط مختلف باغ مرکبات مورد استفاده قرار گرفت. برای انتخاب بهینه سرعت خطی پهپاد، سه سرعت در محدوده ۱۰، ۲۰ و ۳۰ سانتی‌متر بر ثانیه در نظر گرفته شد. ویدئوهای ثبت شده پس از فریم‌بندی و تغییر ابعاد به سه مدل از پیش آموزش دیده شده یادگیری عمیق AlexNet، VGG-16 و GoogleNet ارائه شد. برای انتخاب الگوریتم مناسب، سه الگوریتم بهینه‌ساز متفاوت یعنی SGDm، RMSProp و Adam در فرآیند آموزش شبکه مورد استفاده قرار گرفت. نتایج ارزیابی نشان داد که مدل GoogleNet به‌کمک الگوریتم SGDm از نظر دقت تشخیص، بهترین عملکرد را داشته است. بیشترین دقت تشخیص آفت به‌مقدار ۹۶/۴۳٪ در سرعت ۱۰ سانتی‌متر بر ثانیه به‌دست آمد، به‌طوری که با افزایش محدوده سرعت به ۳۰ سانتی‌متر بر ثانیه، میزان دقت تشخیص به‌مقدار ۱۳٪ کاهش یافت. نتایج این تحقیق نشان می‌دهد که استفاده از ترکیب پهپاد و روش‌های هوش مصنوعی می‌تواند به متخصصان و کشاورزان در مدیریت و کنترل آفات باغ مرکبات کمک نماید.

واژه‌های کلیدی: بینایی ماشین، تشخیص آفات، مرکبات، یادگیری عمیق، یادگیری انتقالی.

ارجاع: هادی‌پور رکنی ر.، عسکری اصلی ارده ع. و سبزی س. ۱۴۰۱. شناسایی آفات مرکبات با به‌کارگیری پهپاد و روش‌های هوش مصنوعی. نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی. ۲۴: ۵۹-۶۸. <https://dx.doi.org/10.22034/JRMAM.2022.10139.558>

۱- دانشجوی دکتری گروه مهندسی بیوسیستم، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی.

۲- استاد گروه مهندسی بیوسیستم، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی.

۳- دانشجوی پسادکتری گروه مهندسی بیوسیستم، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی.

* نویسنده مسئول: ezzataaskari@uma.ac.ir

تاریخ دریافت: ۱۴۰۰/۱۰/۰۱ تاریخ پذیرش: ۱۴۰۰/۱۱/۱۵

مقدمه

کنترل آفات و بیماری های گیاهی یکی از مهم ترین عملیات در مرحله داشت مرکبات است. روش های مختلفی برای مبارزه با آفات وجود دارد که رایج ترین و مؤثرترین آن روش شیمیایی است. استفاده بی رویه از سموم شیمیایی دارای معایب مهمی از جمله اثرات نامطلوب زیست محیطی و افزایش هزینه برای باغدار است، بنابراین یک راه کار مناسب برای بهینه نمودن مصرف سموم، کنترل آفات به صورت خاص مکانی است. از آنجایی که مدیریت تک تک درختان بدون استفاده از فناوری های نوین امکان پذیر نیست، بنابراین باغداران در تلاش هستند تا عملیات باغی را با بهره گیری از فناوری های پهپادی¹ (UAV) و روش های هوش مصنوعی انجام دهند (Kobayashi et al., 2019; Velusamy et al., 2022). با پیشرفت های اخیر در فناوری هواپیمای بدون سرنشین و دوربین های تصویربرداری، امکان نظارت آفات در باغات و مزارع فراهم شده است، به طوری که در پژوهش هایی با موضوعاتی مانند نمونه برداری از باغ مرکبات (Kobayashi et al., 2019)، تشخیص بیماری های مرکبات ناشی از آفات پرندگان (Romero et al., 2022)، تشخیص بیماری درختان کاج در جنگل (Yu et al., 2021)، تشخیص بیماری در مزرعه سویا (Zhang et al., 2022)، تشخیص علف های هرز (Bah et al., 2018) و تشخیص آفات مهاجم در محصولات کشاورزی (Ulhaq & Khan 2020) از این فناوری استفاده شده است.

طبق گزارش محققان ممکن است بعضی از تصاویر خروجی از پهپاد به دلیل وجود دو مشخصه تاری ناشی از حرکت² و مات شدن³ دارای کیفیت پایینی باشد و یا قسمتی از اندام آفت در تصویر وجود نداشته باشد (Peng & Jun, 2011; Ulhaq & Khan, 2020). بنابراین برای تجزیه و تحلیل تصاویر، استفاده از روش های یادگیری ماشین⁴ به ویژه روش یادگیری عمیق می تواند کارآیی بهتری داشته باشد، زیرا که روش یادگیری عمیق به دلیل قابلیت استخراج ویژگی و طبقه بندی تصاویر به طور خودکار نسبت به روش های سنتی برتری دارد

(Saleem et al., 2020; Kasinathan et al., 2021; Liu et al., 2020). یکی از معماری های مورد توجه در روش یادگیری عمیق، شبکه عصبی پیچشی⁵ (CNN) است که در تحلیل تصاویر دیجیتالی کاربرد فراوانی پیدا کرده است. این معماری از تعدادی لایه پیچشی، لایه فعال سازی، لایه ادغام⁶، لایه کاملاً متصل⁷ و لایه Softmax تشکیل شده است (Bollis et al., 2020; Alruwaili et al., 2019; Saleem et al., 2020). وظیفه لایه پیچشی، استخراج ویژگی ها از تصاویر است. این لایه به وسیله فیلترهای کانولوشنال دو بُعدی لغزنده با حرکت عمودی و افقی بر روی تصویر جابجا می شود و ویژگی های سطح پایین تصاویر مانند لبه ها و گوشه ها و ویژگی های سطح بالا مانند شکل و اشیا را به طور خودکار استخراج می کند (Turkoglu et al., 2019). تابع فعال ساز⁸ Relu، واحد خطی اصلاح شده است به طوری که روی خروجی هر لایه شبکه یک آستانه گیری انجام می دهد تا سرعت یادگیری شبکه را افزایش دهد. در لایه ادغام با انجام عملیات بیشینه گیری در ماتریس ها، پارامترها کاهش یافته و در نتیجه باعث افزایش سرعت محاسبات می شود. وظیفه لایه کاملاً متصل، ضرب و اضافه کردن وزن و بایاس به ورودی شبکه است. لایه Softmax با بهره گیری از احتمالات برای رفع پیچیدگی مربوط به طبقه بندی تصاویر مورد استفاده به کار می رود. در مطالعات اخیر، الگوریتم های بهینه ساز مختلفی مانند SGD⁹، RMSProp¹⁰ و Adam¹¹ در فرآیند آموزش شبکه CNN مورد استفاده قرار گرفته است. این الگوریتم ها می توانند با به روز رسانی پارامترهای وزن، خطا را کاهش و در نتیجه باعث بهبود نتایج مدل های CNN شوند (Turkoglu et al., 2019; Keskar & Socher 2017; Fooladi et al., 2019).

یکی از عوامل مؤثر در افزایش دقت مدل های CNN، در دسترس بودن مقادیر زیادی از داده های آموزشی (مانند تصاویر) است. به همین دلیل روش هایی مانند افزونه سازی¹² داده ها و استفاده از دانش مدل های از پیش

5- convolution neural networks

6- Max Pooling

7- Fully Connected

8- Rectified Linear Unit

9- Stochastic gradient descent

10- Root Mean Square

11- Adaptive Moment Estimation

12- Augmentation

1- Unmanned Aerial Vehicle

2- Motion blur

3- Defocus blur

4- Machine learning

سرعت ۳۰ فریم در ثانیه و عکاسی با وضوح ۱۲ مگاپیکسل را دارد. این سامانه با دارا بودن چهار موتور، قابلیت پرواز در جهت عمودی و افقی را دارد و می‌تواند با حمل دوربین در نقاط مختلف بین درختان فیلم‌برداری کند (شکل ۱).



شکل ۱- کوادکوپتر مدل DJI Phantom 4: ۱) دوربین، ۲) لرزش گیر، ۳) موتور الکتریکی، ۴) ملخ، ۵) گوشی هوشمند، ۶) کابل اتصال گوشی به کنترل ۷) دستی کنترل

عوامل مهمی از قبیل لرزش، وضوح پایین و سرعت جابجایی دوربین سبب می‌شود تا تصاویر به‌صورت تار و با کیفیت پایین ثبت شود. از طرفی دیگر تصاویر با کیفیت پایین، باعث کاهش دقت تشخیص الگوریتم‌ها می‌شود (Ali et al., 2020; Nguyen et al., 2020). دو مشخصه لرزش و وضوح دوربین عواملی هستند که توسط مهندسين طراح در حد امکان تنظيم شده است و قابل تغيير نيستند، بنا بر اين با تعيين سرعت پيشروي مناسب مي‌توان كيفيت تصاوير را در حد مطلوب نگه داشت. براي دستيابي به تصاوير با كيفيت، سرعت پيشروي پهپاد با سه سرعت خطي در محدوده ۱۰، ۲۰ و ۳۰ سانتی‌متر بر ثانیه مورد ارزیابی قرار گرفت. برای حذف تأثیر وزش باد ناشی از ملخ‌های پهپاد بر روی سوژه فیلم‌برداری، فاصله دوربین در حدود ۸۰ سانتی‌متری از درختان در نظر گرفته می‌شد (شکل ۲).

فیلم‌برداری در یک روز آفتابی (بعد از ظهر) با شدت نور محیط بین ۷۰۰۰ تا ۱۱۰۰۰ لوکس در باغی که فاصله بین سرشاخه‌های درختان (بین ردیف‌ها و روی ردیف‌ها) ۲ تا ۳ متر بود، انجام شد. شدت نور محیط به‌وسیله دستگاه لوکس‌متر مدل TEM8820 از شرکت لوترون اندازه‌گیری و ثبت شد. تعداد ۲۱ ویدئو در محدوده سه سرعت ۱۰، ۲۰ و ۳۰ سانتی‌متر بر ثانیه تهیه شد. پس از اتمام فیلم‌برداری، دسته‌بندی ویدئوها در گروه‌های مورد

آموزش دیده شده (روش یادگیری انتقالی^۱) برای رفع مشکل تعداد کم داده‌های آموزشی مورد استفاده قرار می‌گیرد (Ramalingam et al., 2020; Qi et al., 2021; Chen et al., 2021). تاکنون تحقیقات زیادی با استفاده از دانش مدل‌های از پیش آموزش دیده شده مانند VGG، GoogleNet، AlexNet و دیگر مدل‌ها انجام شده است (Saleem et al., 2020). به‌عنوان مثال، برای نمونه‌برداری آفات در مزرعه سویا از یک پهپاد مجهز به دوربین استفاده شد. در این تحقیق پنج مدل یادگیری عمیق VGG-19، VGG-16، ResNet-50، Inception-v3 و Xception مورد ارزیابی قرار گرفت. بیشترین دقت تشخیص با مدل ResNet-50 به مقدار ۹۳/۸۲٪ به‌دست آمد (Tetila et al., 2020). در پژوهشی از یک پهپاد برای تشخیص آفات و بیماری‌ها در مزارع برنج استفاده شد. برای طبقه‌بندی آفات و بیماری‌ها، ویدئوهای مختلف پس از استخراج فریم و دسته‌بندی به مدل‌های از پیش آموزش داده شده VGG16، ResNet-50، YOLOv3 و ResNet-101 ارائه شد. بیشترین مقدار دقت تشخیص با مدل VGG16 و YOLOv3 به میزان ۱۰۰٪ به‌دست آمد (Li et al., 2020). همچنین برای تخمین مرحله رشد گندم و جو (Rasti et al., 2021) و تشخیص بیماری بوته‌های سیب‌زمینی در مزرعه (Oishi et al., 2021) از فناوری پهپاد و روش یادگیری انتقالی استفاده شده است. مطالعه پژوهش‌های اخیر نشان می‌دهد استفاده از فناوری پهپاد و روش‌های هوش مصنوعی در حوزه کشاورزی رو به افزایش است. هدف از انجام این تحقیق، توسعه مدیریت و کنترل آفات باغ مرکبات با به‌کارگیری ترکیبی از فناوری پهپاد و روش‌های هوش مصنوعی است.

مواد و روش‌ها

برای تهیه پایگاه داده (ویدئو)، یک باغ مرکبات با مساحت ۵۰۰۰ مترمربع واقع در شهرستان قائمشهر - استان مازندران انتخاب شد. برای پایش و شناسایی آفات در نقاط مختلف درختان (از ساقه تا نوک تاج درخت) ویدئوهایی با استفاده از یک پهپاد Phantom 4 از شرکت DJI تهیه شد. این سامانه به‌وسیله نرم‌افزاری که در یک گوشی هوشمند نصب می‌شود، قابل راه‌اندازی و کنترل است و قابلیت فیلم‌برداری 4K با

شبکه CNN

شبکه عصبی CNN یکی از معماری‌های یادگیری عمیق است که به دلیل دقت طبقه‌بندی بالا مورد توجه محققان قرار گرفته است. در این پژوهش برای تشخیص آفات مرکبات از شبکه CNN استفاده شد. برای دستیابی به دقت تشخیص بالا، داشتن تعداد زیادی از تصاویر برای آموزش شبکه CNN لازم است (Liu et al., 2020; Jahanbakhshi et al., 2020). از این رو برای جبران کمبود تصاویر آموزشی، از دو روش افزونه‌سازی تصاویر و روش یادگیری انتقالی استفاده شد. در این پژوهش تعداد ۱۵۰۰ تصویر با استفاده از روش‌های افزونه‌سازی، یعنی چرخش تصویر با زوایای ۴۵، ۹۰ و ۲۷۰ درجه و چرخش افقی و عمودی به ۹۰۰۰ تصویر افزایش داده شد. همچنین سه مدل از پیش آموزش دیده شده CNN یعنی AlexNet، VGG-16 و GoogleNet برای تشخیص آفات انتخاب شد. ابعاد تصاویر ورودی مطابق با قوانین مدل‌های VGG-16 و GoogleNet به ابعاد ۲۲۴×۲۲۴ و برای مدل AlexNet به ابعاد ۲۲۷×۲۲۷ کاهش داده شد. برای استفاده از مدل‌ها به روش یادگیری انتقالی، شبکه‌ها با اصلاح آخرین لایه به تعداد سه طبقه (بدون آفت، حلزون و شته)، مجدداً آموزش داده شد (شکل‌های ۵ تا ۷).

آموزش و آزمون شبکه

رایج‌ترین نسبت تقسیم مجموعه داده‌ها در برنامه‌های شبکه عصبی برای آموزش، اعتبارسنجی و آزمون به ترتیب ۷۰، ۲۰ و ۱۰ درصد است (Saleem et al., 2020; Tetila et al., 2020). بنابراین در هر مرحله ۷۰٪ از تصاویر برای آموزش شبکه، ۲۰٪ تصاویر برای اعتبارسنجی و ۱۰٪ تصاویر برای آزمون در نظر گرفته شد. برای دستیابی به بهترین نتیجه از الگوریتم‌های بهینه‌ساز SGDm، RMSProp و Adam در فرآیند آموزش شبکه‌ها استفاده گردید.

معیارهای ارزیابی

معیارهای آماری استاندارد مانند دقت تشخیص^۱، صحت^۲، فراخوانی^۳ و F1-Score برای ارزیابی عملکرد تشخیص

نظر (بدون آفت، حلزون و شته) انجام گرفت. برای استخراج فریم‌ها از نرم‌افزار MATLAB 2020 استفاده شد، به‌طوری که در هر ثانیه یک تصویر استخراج گردید. بطور کلی، پس از حذف تصاویر مابین درختان (بدون سوژه)، تعداد ۵۰۰ تصویر از هر طبقه یعنی بدون آفت، حلزون و شته انتخاب شد (شکل‌های ۳ و ۴).



شکل ۲- نحوه قرارگیری پهپاد نسبت به سوژه در باغ



شکل ۳- الف) نمونه تصویر آفت حلزون ثبت شده در محدوده سرعت ۱۰ سانتی‌متر بر ثانیه، ب) نمونه تصویر آفت حلزون ثبت شده در محدوده سرعت ۲۰ سانتی‌متر بر ثانیه و ج) نمونه تصویر آفت حلزون در محدوده سرعت ۳۰ سانتی‌متر بر ثانیه



شکل ۴- الف) درخت بدون شته، ب) درختان آلوده به شته در محدوده سرعت ۱۰ سانتی‌متر بر ثانیه، ج) درختان آلوده به شته در محدوده سرعت ۲۰ سانتی‌متر بر ثانیه و د) درختان آلوده به شته در محدوده سرعت ۳۰ سانتی‌متر بر ثانیه

1- Accuracy
2- Precision
3- Recall

$$F1 \text{ Score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (۴)$$


که در آن: TN تعداد تصاویر بدون آفتی که سیستم آنها را درست تشخیص داده؛ TP تعداد تصاویر آفت‌دار که سیستم آنها را درست تشخیص داده؛ FN تعداد تصاویر بدون آفتی که سیستم آنها را آفت‌دار تشخیص داده؛ FP تعداد تصاویر آفت‌دار که سیستم آنها را بدون آفت تشخیص داده است.

طبقه‌بندی الگوریتم‌ها استفاده می‌شود (Khalifa et al., 2020; Jahanbakhshi et al., 2020). بنابراین مقادیر آن با استفاده از معادلات (۱) تا (۴) محاسبه شد. در این پژوهش، معیارهای ارزیابی با سه تکرار ثبت و در نهایت نتایج آنها گزارش شد.


$$\text{Accuracy} = \frac{TN + TP}{TN + FN + TP + FP} \quad (۱)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (۲)$$


$$\text{Recall} = \frac{TP}{TP + FN} \quad (۳)$$



شکل ۵- یادگیری انتقالی از مدل AlexNet



شکل ۶- یادگیری انتقالی از مدل GoogleNet




شکل ۷- یادگیری انتقالی با استفاده از مدل VGG-16

نتایج و بحث

تشخیص آفت حلزون

در مرحله اول سعی شد که فیلم‌برداری با کمترین سرعت خطی پهپاد انجام شود تا تصاویر ویدئویی با وضوح بهتری ثبت شوند، به‌طوری که سرعت میانگین در محدوده ۱۰ سانتی‌متر بر ثانیه به‌دست آمد. نتایج معیارهای ارزیابی مدل‌های مختلف CNN در جدول ۱ نشان داده شده است. نتایج نشان داد که در بین مدل‌های ارزیابی شده، مدل GoogleNet با الگوریتم SGDm با کسب دقت تشخیص ۹۶/۴۳٪ بهترین عملکرد را داشته است. تغییرات دقت آموزش و هزینه آموزش در شکل ۸ نشان می‌دهد که مدل GoogleNet با سپری نمودن حدود ۳۵ تکرار به دقت آموزش و همگرایی مطلوب رسیده است. طبق نتایج به‌دست آمده می‌توان گفت که همه مدل‌ها در صورت انتخاب صحیح الگوریتم‌های بهینه‌ساز برای تشخیص آفت کارایی خوبی دارند، اما حساسیت الگوریتم‌ها به تأثیر عوامل محیطی در تصاویر سبب شده است تا دقت تشخیص مدل‌ها با الگوریتم‌های مختلف، عملکردی متفاوت داشته باشد. در تحقیقی نسبتاً مشابه با تحقیق حاضر که از روش عکس‌برداری برای تهیه پایگاه داده و از مدل‌های از پیش آموزش دیده CNN

برای تحلیل تصاویر استفاده شد، دقت تشخیص آفت حلزون ۹۵/۴۷٪ به‌دست آمد (Zheng et al., 2019). برای تعیین سرعت بهینه پهپاد در پایش آفات مرکبات، فیلم‌برداری در محدوده دو سرعت خطی متفاوت یعنی ۲۰ و ۳۰ سانتی‌متر بر ثانیه انجام شد. از آنجایی که معیار دقت تشخیص به‌عنوان مهم‌ترین معیار در تحقیقات پژوهش‌گران گزارش شده است، بنابراین نتایج معیار دقت تشخیص به شرح جدول ۲ گزارش شد. نتایج نشان داد که مدل AlexNet با الگوریتم SGDm از نظر معیارهای ارزیابی شده نسبت به مدل‌های دیگر عملکرد بهتری داشته است. نتایج به‌دست آمده از سه سرعت خطی پهپاد نشان می‌دهد که دقت تشخیص آفت حلزون با افزایش سرعت از محدوده ۱۰ به ۳۰ سانتی‌متر بر ثانیه به مقدار ۱۳٪ کاهش یافته است (شکل ۱۰). مطابق گزارش محققان هر چه سرعت جابجایی دوربین از مقابل اشیاء بیشتر باشد مشخصه تاری و مات‌شدن پیکسل‌های تصویر افزایش می‌یابد، این دو مشخصه سبب کاهش کیفیت تصویر و در نتیجه کاهش دقت تشخیص الگوریتم می‌شود (Zhu et al., 2020; Peng & Jun, 2011).



شکل ۸- نمودار دقت آموزش و هزینه مربوط به مدل GoogleNet با الگوریتم بهینه‌ساز SGDm در سرعت ۱۰ متر بر ثانیه

جدول ۱- نتایج معیارهای ارزیابی در تشخیص آفت حلزون در محدوده سرعت ۱۰ سانتی‌متر بر ثانیه


مدل	الگوریتم	دقت تشخیص	صحت	فراخوانی	F ₁ Score
VGG-16	SGDm	۰/۹۵۵	۰/۹۵۷	۰/۹۵۵	۰/۹۵۶
	RMSProp	۰/۹۵۳	۰/۹۵۱	۰/۹۵۳	۰/۹۵۲
	Adam	۰/۹۶۲	۰/۹۶۳	۰/۹۶۲	۰/۹۶۲
Google Net	SGDm	۰/۹۶۴	۰/۹۶۴	۰/۹۶۴	۰/۹۶۴
	RMSProp	۰/۹۴۱	۰/۹۴۳	۰/۹۴۱	۰/۹۴۲
	Adam	۰/۹۵۵	۰/۹۶۵	۰/۹۶۵	۰/۹۶۵
AlexNet	SGDm	۰/۹۶۳	۰/۹۶۴	۰/۹۶۳	۰/۹۶۳
	RMSProp	۰/۹۵۶	۰/۹۵۲	۰/۹۵۶	۰/۹۵۲
	Adam	۰/۹۶۲	۰/۹۶۳	۰/۹۶۲	۰/۹۶۲

جدول ۲- نتایج معیار دقت تشخیص حلزون در محدوده دو سرعت فیلم‌برداری

مدل	الگوریتم	سرعت خطی ۲۰ سانتی‌متر بر ثانیه	سرعت خطی ۳۰ سانتی‌متر بر ثانیه
VGG-16	SGDm	۰/۹۱۷	۰/۸۲۷
	RMSProp	۰/۹۰۵	۰/۸۰۱
	Adam	۰/۹۲۴	۰/۸۳۳
Google Net	SGDm	۰/۹۲۲	۰/۸۴۲
	RMSProp	۰/۹۱۸	۰/۸۰۰
	Adam	۰/۹۱۵	۰/۸۳۷
AlexNet	SGDm	۰/۹۲۳	۰/۸۴۵
	RMSProp	۰/۹۱۸	۰/۸۲۱
	Adam	۰/۹۱۷	۰/۸۴۲

اما در تحقیقی نسبتاً مشابه با این تحقیق که از روش عکس‌برداری برای تهیه تصاویر و از مدل‌های از پیش آموزش دیده شده CNN برای تحلیل تصاویر استفاده شد، بیشترین دقت تشخیص آفت شته به مقدار ۹۶/۰۵٪ به‌دست آمد (Khanramaki & Askari Asli Ardeh, 2021)


نتایج به‌دست آمده از سه سرعت پهپاد در تشخیص آفت شته نشان می‌دهد که با افزایش سرعت پهپاد از محدوده ۱۰ به ۳۰ سانتی‌متر بر ثانیه، دقت تشخیص به مقدار ۱۳٪ کاهش یافته است (شکل ۱۱). دلیل این امر ایجاد دو مشخصه تار ناشی از حرکت و مات شدن تصاویر در هنگام جابجایی دوربین است که باعث کاهش کیفیت و وضوح تصویر می‌شود، این دو مشخصه در تحقیق (Peng & Jun, 2011) گزارش شده است و با نتایج دیگر محققان (Ulhaq & Khan, 2020; Zhu et al., 2020) مطابقت دارد.



شکل ۱۱- مقایسه بین دقت تشخیص آفت شته در محدوده سه سرعت فیلم‌برداری پهپاد



شکل ۹- نمونه‌ای از تصاویر طبقه‌بندی شده (خروجی برنامه) مدل GoogleNet و الگوریتم SGDm - کلاس (۰): تصاویر بدون آفت و کلاس (۱): آفت حلزون



شکل ۱۰- مقایسه بین دقت تشخیص آفت حلزون در محدوده سه سرعت فیلم‌برداری پهپاد

تشخیص آفت شته


در این مرحله ویدئوهای خروجی از پهپاد در محدوده سه سرعت ۱۰، ۲۰ و ۳۰ سانتی‌متر بر ثانیه مورد بررسی قرار گرفت که نتایج معیار دقت تشخیص به شرح جدول ۳ قرائت شد. بیشترین دقت تشخیص به مقدار ۹۵/۵۵٪ با مدل AlexNet و به‌کمک الگوریتم SGDm در محدوده سرعت ۱۰ سانتی‌متر بر ثانیه به‌دست آمد. هر چند که روش تصویربرداری، نوع دوربین و روش مورد استفاده در یادگیری ماشین می‌تواند در نتایج تحقیقات موثر باشد،

جدول ۳- نتایج معیار دقت تشخیص شته در سه سرعت فیلم‌برداری

مدل	الگوریتم	سرعت خطی ۱۰ سانتی‌متر بر ثانیه	سرعت خطی ۲۰ سانتی‌متر بر ثانیه	سرعت خطی ۳۰ سانتی‌متر بر ثانیه
VGG-16	SGDm	۰/۹۲۸	۰/۸۷۸	۰/۷۸۶
	RMSProp	۰/۸۷۳	۰/۸۶۲	۰/۷۵۱
	Adam	۰/۹۳۴	۰/۸۸۵	۰/۸۰۶
Google Net	SGDm	۰/۹۵۳	۰/۸۹۳	۰/۸۱۵
	RMSProp	۰/۸۹۶	۰/۸۷۱	۰/۷۷۸
	Adam	۰/۹۴۸	۰/۸۹۶	۰/۸۱۷
AlexNet	SGDm	۰/۹۵۵	۰/۸۹۸	۰/۸۲۴
	RMSProp	۰/۹۰۶	۰/۸۶۷	۰/۷۸۶
	Adam	۰/۹۴۷	۰/۸۷۱	۰/۸۲۰

منابع

- Ali, M. M., Hashim, N., & Hamid, A. S. A. (2020). Combination of laser-light backscattering imaging and computer vision for rapid determination of oil palm fresh fruit bunches maturity. *Computers and Electronics in Agriculture*, 169: 105235.
- Alruwaili, M., Alanazi, S., El-Ghany, S. A., & Shehab, A. (2019). An efficient deep learning model for olive diseases detection. *International Journal of Advanced Computer Science and Applications*, 10(8): 486-492.
- Bah, M. D., Hafiane, A., & Canals, R. (2018). Deep learning with unsupervised data labeling for weed detection in line crops in UAV images. *Remote sensing*, 10(11): 1690.
- Bollis, E., Pedrini, H., & Avila, S. (2020). Weakly Supervised Learning Guided by Activation Mapping Applied to a Novel Citrus Pest Benchmark. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, 70-71.
- Chen, J. W., Lin, W. J., Cheng, H. J., Hung, C. L., Lin, C. Y., & Chen, S. P. (2021). A Smartphone-based application for scale pest detection using multiple-object detection methods. *Electronics*, 10(4): 372.
- Fooladi, S., Farsi, H., & Mohamadzadeh, S. (2019). Detection and classification of skin cancer using deep learning. *Birj and Univ Med Sci*, 26(1): 44-53.
- Jahanbakhshi, A., Momeny, M., Mahmoudi, M., & Zhang, Y. D. (2020). Classification of sour lemons based on apparent defects using stochastic pooling mechanism in deep convolutional neural networks. *Scientia Horticulturae*, 263: 109133.
- Kasinathan, T., Singaraju, D., & Uyyala, S. R. (2021). Insect classification and detection in field crops using modern machine learning techniques. *Information Processing in Agriculture*, 8(3): 446-457.
- Keskar, N. S., & Socher, R. (2017). Improving generalization performance by switching from adam to SGD. *arXiv preprint arXiv:1712.07628*.
- Khalifa, N. E. M., Loey, M. O. H. A. M. E. D., & Taha, M. H. N. (2020). Insect pests' recognition based on deep transfer learning models. *Journal of Theoretical and Applied Information Technology*, 98(1): 60-68.
- Khanramaki, M., Askari Asli Ardeh, E., Kozegar, E., Loni, R. (2021). Detection of common citrus pests in northern Iran using a Deep Convolutional Neural Network.



شکل ۱۲ - نمونه‌ای از تصاویر طبقه‌بندی شده (خروجی برنامه) مدل AlexNet و الگوریتم SGDm کلاس (۰): بدون آفت و کلاس (۲): تصاویر با آفت شته

نتیجه‌گیری

در این پژوهش برای شناسایی آفات در باغ مرکبات از فناوری پهپاد و روش‌های هوش مصنوعی استفاده شد. برای ارزیابی میزان تأثیر سرعت خطی پهپاد بر دقت تشخیص آفات، فیلم‌برداری در محدوده سه سرعت خطی ۱۰، ۲۰ و ۳۰ سانتی‌متر بر ثانیه انجام شد. ویدئوهای جمع‌آوری شده بعد از استخراج فریم و تغییر ابعاد به مدل‌های از پیش آموزش داده شده AlexNet، VGG-16 و GoogleNet ارائه شد. برای انتخاب الگوریتم مناسب و دستیابی به دقت تشخیص مطلوب از سه الگوریتم بهینه‌ساز SGDm، RMSProp و Adam در فرآیند آموزش مدل‌ها استفاده شد. نتایج نشان داد که مدل‌های مورد استفاده در صورت انتخاب الگوریتم بهینه‌ساز مناسب در فرآیند آموزش از دقت خوبی برخوردار هستند. بیشترین دقت تشخیص آفت حلزون با مدل GoogleNet و بیشترین دقت تشخیص شته با مدل AlexNet به ترتیب با ۹۶/۴۳٪ و ۹۵/۵۵٪ در محدوده سرعت خطی ۱۰ سانتی‌متر بر ثانیه به‌دست آمد. نتایج نشان داد که الگوریتم بهینه‌ساز SGDm نسبت به دیگر الگوریتم‌ها عملکرد بهتری در فرآیند آموزش شبکه داشت. نتایج دقت تشخیص آفات از ویدئوهای خروجی در سه سرعت خطی پهپاد نشان داد که این معیار با سرعت خطی پهپاد نسبت عکس دارد به‌طوری که با افزایش سرعت خطی از محدوده ۱۰ به ۳۰ سانتی‌متر بر ثانیه، دقت تشخیص به میزان ۱۳٪ کاهش یافت. این مقدار می‌تواند متناسب با نوع دوربین نصب شده در دیگر مدل‌های پهپاد متغیر باشد. نتایج حاصل از این پژوهش نشان می‌دهد که به‌کارگیری پهپاد و روش‌های هوش مصنوعی می‌تواند برای شناسایی آفات در سطح وسیعی از باغات مورد استفاده قرار گیرد.

- comparative evaluation of convolutional neural networks and deep learning optimizers. *Plants*, 9(10): 1319.
- Tetila, E. C., Machado, B. B., Astolfi, G., de Souza Belete, N. A., Amorim, W. P., Roel, A. R., & Pistori, H. (2020). Detection and classification of soybean pests using deep learning with UAV images. *Computers and Electronics in Agriculture*, 179, 105836.
- Turkoglu, M., Hanbay, D., & Sengur, A. (2019). Multi-model LSTM-based convolutional neural networks for detection of apple diseases and pests. *Journal of Ambient Intelligence and Humanized Computing*, 1-11.
- Ulhaq, A., & Khan, A. (2020). Pest Animal's Detection and Habitat Identification in Low-resolution Airborne Thermal Imagery. *Preprints*, 1-12.
- Velusamy, P., Rajendran, S., Mahendran, R. K., Naseer, S., Shafiq, M., & Choi, J. G. (2022). Unmanned Aerial Vehicles (UAV) in Precision Agriculture: Applications and Challenges. *Energies*, 15(1): 217.
- Yu, R., Luo, Y., Zhou, Q., Zhang, X., Wu, D., & Ren, L. (2021). Early detection of pine wilt disease using deep learning algorithms and UAV-based multispectral imagery. *Forest Ecology and Management*, 497: 119493.
- Zhang, Z., Khanal, S., Raudenbush, A., Tilmon, K., & Stewart, C. (2022). Assessing the efficacy of machine learning techniques to characterize soybean defoliation from unmanned aerial vehicles. *Computers and Electronics in Agriculture*, 193: 106682.
- Zheng, Y. Y., Kong, J. L., Jin, X. B., Wang, X. Y., Su, T. L., & Zuo, M. (2019). CropDeep: The crop vision dataset for deep-learning-based classification and detection in precision agriculture. *Sensors*, 19(5): 1058.
- Zhu, H., Wei, H., Li, B., Yuan, X., & Kehtarnavaz, N. (2020). A Review of Video Object Detection: Datasets, Metrics and Methods. *Applied Sciences*, 10(21): 7834.
- Iranian Journal of Food Science and Technology*. JFST, 17(109) (in Persian).
- Kobayashi, F. K., Mattos, A. B., Gemignani, B. H., & Macedo, M. M. (2019). Experimental analysis of citrus tree classification from UAV images. *IEEE International Symposium on Multimedia (ISM)*, 32-327.
- Li, D., Wang, R., Xie, C., Liu, L., Zhang, J., Li, R., & Liu, W. (2020). A recognition method for rice plant diseases and pests video detection based on deep convolutional neural network. *Sensors*, 20(3): 578.
- Liu, B., Ding, Z., Tian, L., He, D., Li, S., & Wang, H. (2020). Grape leaf disease identification using improved deep convolutional neural networks. *Frontiers in Plant Science*, 11: 1082.
- Nguyen, H. D. D., Pan, V., Pham, C., Valdez, R., Doan, K., & Nansen, C. (2020). Night-based hyperspectral imaging to study association of horticultural crop leaf reflectance and nutrient status. *Computers and Electronics in Agriculture*, 173: 105458.
- Oishi, Y., Habaragamuwa, H., Zhang, Y., Sugiura, R., Asano, K., Akai, K., & Fujimoto, T. (2021). Automated abnormal potato plant detection system using deep learning models and portable video cameras. *International Journal of Applied Earth Observation and Geoinformation*, 104: 102509.
- Peng, Z., & Jun, C. (2011). Weed recognition using image blur information. *Biosystems engineering*, 110(2): 198-205.
- Qi, H., Liang, Y., Ding, Q., & Zou, J. (2021). Automatic Identification of Peanut-Leaf Diseases Based on Stack Ensemble. *Applied Sciences*, 11(4): 1950.
- Ramalingam, B., Mohan, R. E., Pookkuttath, S., Gómez, B. F., Sairam Borusu, C. S. C., Wee Teng, T., & Tamilselvam, Y. K. (2020). Remote insects trap monitoring system using deep learning framework and IoT. *Sensors*, 20(18): 5280.
- Rasti, S., Bleakley, C. J., Silvestre, G. C., Holden, N. M., Langton, D., & O'Hare, G. M. (2021). Crop growth stage estimation prior to canopy closure using deep learning algorithms. *Neural Computing and Applications*, 33(5): 1733-1743.
- Romero, A., Sánchez-DelaCruz, E., & Ochoa, A. (2022). Implementation of an intelligent model based on Convolutional Neural Network for the detection of diseases in citrus crops caused by bird pests using an intelligent drone. In *Technological and Industrial Applications Associated With Industry 4.0*, Springer, Cham., pp. 3-22.
- Saleem, M. H., Potgieter, J., & Arif, K. M. (2020). Plant disease classification: A