



مقاله پژوهشی

تشخیص و شمارش خودکار شب‌پره مینوز گوجه‌فرنگی، *Tuta absoluta* با استفاده از تکنیک یادگیری عمیقعلیرضا شعبانی‌نژاد^۱، عباسعلی زمانی^۲✉، مجید ایرانپور مبارکه^۳، سعید عباسی^۴، فرانک رنجبر^۵

۱، ۲، ۴- دانشجوی دکتری، دانشیار، دانشیار، گروه گیاه‌پزشکی، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران؛ ۳- استادیار، دانشکده مهندسی

کامپیوتر و فناوری اطلاعات، دانشگاه پیام نور، تهران ایران؛ ۵- استادیار، گروه خاک‌شناسی، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران

(تاریخ دریافت: خرداد ۱۴۰۲؛ تاریخ پذیرش: دی ۱۴۰۲)

چکیده

استفاده از فناوری‌های نوین برای تشخیص و اندازه‌گیری تراکم جمعیت آفات، می‌تواند گام مهمی برای تسهیل در اجرای برنامه‌های مدیریت تلفیقی آفات و کنترل دقیق‌تر و مؤثرتر آنها باشد. در این پژوهش، از تکنیک یادگیری عمیق و شبکه عصبی کانولوشنال با معماری AlexNet، جهت تشخیص و شمارش خودکار شب‌پره مینوز گوجه‌فرنگی (*Tuta absoluta* (Myrick) (Lepidoptera: Gelechiidae)، یکی از آفات کلیدی گیاه گوجه‌فرنگی در ایران، استفاده شد. برای جمع‌آوری تصاویر حشرات بالغ *T. absoluta*، تعداد ۱۵ تله دلتا در دو هکتار از مزارع گوجه‌فرنگی پردیس کشاورزی و منابع طبیعی دانشگاه رازی، نصب گردید. به‌منظور تهیه تصاویر، از دوربین عکاسی سونی مدل DSC-WX100 با دقت مؤثر حسگر ۱۸ مگاپیکسل، استفاده شد. برای ارزیابی عملکرد شبکه عصبی پیچشی با معماری AlexNet از پارامترهای دقت متوسط، دقت و یادآوری استفاده و برای ارزیابی عملکرد در شمارش، از منحنی رگرسیون خطی و ضریب تبیین استفاده شد. پارامترهای دقت متوسط (۰/۹۸)، دقت (۱۰۰) و یادآوری (۱۰۰) نشان از عملکرد بالای شبکه عصبی کانولوشنال در تشخیص شب‌پره مینوز گوجه‌فرنگی داشت و همچنین ضریب تبیین (۰/۹۸)، بیانگر دقت بالای شبکه در شمارش این آفت بود. به‌طور کلی، نتایج نشان داد که شبکه عصبی می‌تواند راه‌حلی کاربردی برای تشخیص و شمارش دقیق این آفت روی گوجه‌فرنگی با استفاده از تصاویر گرفته‌شده ارائه کند.

واژه‌های کلیدی: شب‌پره مینوز گوجه‌فرنگی، معماری AlexNet، یادگیری عمیق

Automatic detection and counting of *Tuta absoluta* (Myrick) using deep learning techniqueA. R. SHABANI NEZHAD¹, A. A. ZAMANI²✉, M. IRANPOUR MOBARAKEH³, S. ABBASI⁴, F. RANJBAR⁵

1, 2, 4. Ph.D. candidate, Associate Professor, Associate Professor, Department of Plant Protection, College of Agriculture, Razi University, Kermanshah, Iran; 3. Assistant Professor, Department of Computer Engineering and IT, Payam Noor University, Tehran, Iran; 5. Assistant Professor, Department of Soil Science, College of Agriculture, Razi University, Kermanshah, Iran

Abstract

The use of modern technologies for detecting and measuring pest population density can be an important step in facilitating the implementation of integrated pest management programs and achieving more precise and effective control. In this study, the deep learning technique and convolutional neural network with AlexNet architecture were used for the automatic detection and counting of the tomato leaf miner, *Tuta absoluta* (Myrick) (Lepidoptera: Gelechiidae), which is one of the key pests of tomato plants in Iran. To collect images of adult *T. absoluta* insects, 15 delta traps were installed in two hectares of tomato farms at the Campus of Agricultural and Natural Resources, Razi University. The Sony DSC-WX100 camera with an effective sensor resolution of 18 megapixels was used to capture the images. The performance of the convolutional neural network with the AlexNet architecture was evaluated using the parameters of average accuracy, accuracy, and recall. For counting performance, the linear regression curve and coefficient of determination were used. The average accuracy (98.0), accuracy (100), and recall (100) parameters indicate the high performance of the convolutional neural network in detecting the tomato leaf miner, and the coefficient of determination (0.98) indicates the network's high accuracy in counting this pest. Overall, the results demonstrate that the neural network can provide a practical solution for the accurate detection and counting of this pest on tomato plants using captured images.

Keywords: AlexNet architecture, deep learning, tomato leaf miner

✉ azamani@razi.ac.ir

مقدمه

گوجه‌فرنگی با نام علمی (*Solanaceae Lycopersicon L.*)، به‌لحاظ اقتصادی یکی از مهم‌ترین محصولات زراعی در سراسر جهان است که به‌عنوان یکی از سبزیجات پر کشت نه‌تنها دارای عملکرد بالا و سازگاری گسترده، بلکه دارای ارزش غذایی بالایی است (Liu and Wang, 2020). این محصول در ایران، به‌طور گسترده در مناطق مختلف کشت می‌شود و مساحت زیر کشت این محصول حدود ۱۵۰ هزار هکتار در سراسر کشور است که به‌عنوان هفتمین کشور تولیدکننده گوجه‌فرنگی در دنیا شناخته می‌شود (Ashtari et al., 2020). کشت جهانی محصول گوجه‌فرنگی، منجر به ایجاد طیف گسترده‌ای از عوامل خسارت‌زا شده است. عوامل متعددی به‌ویژه آفات باعث کاهش عملکرد محصول گوجه‌فرنگی در مزرعه می‌شوند به‌طوری که کاهش محصول در اثر خسارت آفات، گاهی تا حدود ۱۰۰ درصد نیز گزارش شده است (Rezaei et al., 2015).

شب‌پره مینوز گوجه‌فرنگی، (*Lepidoptera: Gelechiidae*) *Tuta absoluta* (Myrick) یکی از آفات کلیدی این محصول در ایران و سایر نقاط دنیا به‌شمار می‌رود. شب‌پره مینوز گوجه‌فرنگی، آفتی چند نسلی با پتانسیل تولید مثلی بالا و دوره زندگی کوتاه است که عوامل مختلفی نظیر نبود اطلاعات دقیق در زمینه زیست‌شناسی آفت، عدم وجود دشمنان طبیعی کارآمد و در اختیار نداشتن ابزارهای مدیریتی توانمند به‌منظور مهار جمعیت آن، باعث ایجاد خسارت‌های قابل توجهی به‌تولید کنندگان محصول گوجه‌فرنگی در کشور شده است. در شرایط مناسب آب و هوایی و در صورت عدم اجرای برنامه‌های مدیریتی مناسب، خسارت این آفت می‌تواند منجر به نابودی ۹۰ درصد محصول در شرایط مزرعه و گلخانه شود (Potting et al., 2009). خسارت بالای *T. absoluta* در مناطق عمده کشت این محصول در کشور منجر به استفاده بی‌رویه کشاورزان از آفت‌کش‌های شیمیایی شده است که همین مسأله می‌تواند پیامدهایی نظیر ایجاد مقاومت، از بین

بردن عوامل کنترل زیستی، باقی ماندن آفت‌کش روی محصول، بروز آلودگی‌های زیست محیطی و نیز افزایش هزینه‌های تولید را به‌دنبال داشته باشد (Fite and Tefera, 2022). بهترین و مناسب‌ترین راه برای جلوگیری از کاهش عملکرد محصول و به حداقل رساندن کاربرد آفت‌کش‌ها، شناسایی و تشخیص به‌موقع عوامل خسارت‌زای گیاهی است که از مباحث بسیار مهم و چالش برانگیز در حوزه کشاورزی است (Liu and Wang, 2020). اگرچه مشاهدات متخصصان، اصلی‌ترین رویکردی است که در عمل برای تشخیص و شناسایی آفات اتخاذ می‌شود، اما این امر نیاز به نظارت مداوم دارد که ممکن است در مزارع بزرگ بسیار پرهزینه و سخت باشد. بنابراین، کمک به کشاورزان در شناسایی و شمارش خودکار آفات با تجزیه و تحلیل تصاویر دیجیتال، ضروری است. امروزه ابزارهای کامپیوتری بر پایه‌ی پردازش تصویر در حوزه‌ی کشاورزی به‌منظور بهبود کیفیت و افزایش عملکرد محصول، توسعه‌ی زیادی داشته است. کاربرد تکنولوژی یادگیری عمیق، بازدهی صنعت کشاورزی را به‌وسیله‌ی کاهش هزینه‌های کارگری و به حداقل رساندن استفاده از آفت‌کش‌های شیمیایی و آلودگی زیست‌محیطی افزایش خواهد داد (Mokhtar et al., 2015; Zheng et al., 2019). روش‌های یادگیری عمیق یکی از جدیدترین فناوری‌های حال حاضر دنیا است که با ورود خود به‌تمامی علوم رخنه کرده است (Tran et al., 2019). در علوم کشاورزی، می‌توان از مدل‌های یادگیری عمیق برای پیش‌بینی و طبقه‌بندی انواع عوامل خسارت‌زای گیاهی، مدیریت محصولات، تشخیص علف‌های هرز، مدیریت زمین‌های کشاورزی و غیره استفاده کرد. شبکه‌های عصبی کانولوشن (CNN) (convolutional neural network) از رایج‌ترین روش‌های یادگیری عمیق در حل مسائل یادگیری ماشین هستند که به‌طور گسترده در پردازش تصویر و ویدئو به‌کار گرفته شده‌اند. شبکه‌های عصبی کانولوشن در کشاورزی، باعث گسترش تحقیقات در زمینه‌ی شناخت آفات گیاهی و به‌ویژه گیاه گوجه‌فرنگی شده است و

جدید در مزرعه به کار برد، تا با کاهش چشم‌گیر هزینه‌ها و نیز صرف زمان کمتر به تخمین‌های واقعی‌تری دست یافت. اگرچه با توسعه سریع فناوری یادگیری عمیق در سال‌های اخیر، بسیاری از محققان برای بهبود دقت در شناسایی و تشخیص بیماری‌ها و آفات گیاهان، تحقیقات متعددی در داخل و خارج از کشور انجام داده‌اند، اما تاکنون مطالعه‌ای به صورت جامع و مدون با استفاده از روش‌های یادگیری عمیق برای تشخیص و شمارش شب‌پره مینوز گوجه‌فرنگی در ایران، صورت نگرفته است، از اینرو ارائه رویکردی مبتنی بر تکنیک‌های یادگیری عمیق برای تشخیص و شمارش دقیق این آفت ضروری به نظر می‌رسد. بنابراین، هدف اصلی این پژوهش استفاده از یادگیری عمیق در تشخیص و شمارش خودکار *T. absoluta* است.

مواد و روش‌ها

جمع‌آوری نمونه‌ها

جهت جمع‌آوری حشرات بالغ شب‌پره مینوز گوجه‌فرنگی، از تله دلتا ساخت شرکت رها اندیش کاوان با ابعاد $20 \times 20 \times 30$ سانتی‌متر که در کف آن صفحه چسبنده به همراه فرومون جنسی (*T. absoluta*) ساخت شرکت *Xeroben* استفاده شد. این تله‌ها به تعداد ۱۵ عدد در دو هکتار از زمین‌های گوجه‌فرنگی واقع در پردیس کشاورزی و منابع طبیعی دانشگاه رازی کرمانشاه نصب شد. به منظور گرفتن تصاویر، از دوربین عکاسی سونی مدل DSC-WX100 با دقت مؤثر حسگر ۱۸ مگاپیکسل استفاده شد، که از فاصله‌های ۱۰، ۱۵ و ۲۰ سانتی‌متری از سطح صفحه چسبنده با فواصل زمانی ۴۸ ساعت یکبار تعداد ۱۸۰۰ تصاویر گرفته شد.

شبکه‌های عصبی کانولوشنال (پیچشی)

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

در عین حال یک استراتژی کاربردی برای توسعه روش‌های تشخیص بهتر ارائه داده است (Fuentes *et al.*, 2018). مطالعات متعدد در این زمینه حاکی از آن است که از بین انواع شبکه‌های عصبی، شبکه‌های عصبی کانولوشنال معمولاً دقت خوبی را در طبقه‌بندی تصاویر ارائه می‌کنند (Wang *et al.*, 2019). شبکه‌های عصبی کانولوشن می‌تواند برای آموزش نتایج پیش‌بینی مدل مورد استفاده قرار گیرد، که نه تنها می‌تواند در وقت و نیروی کار صرفه‌جویی کند، بلکه می‌تواند تشخیص و شمارش دقیق را انجام دهد. این روش خسارات زیاد ناشی از آفات را بسیار کاهش می‌دهد (Liu and Wang, 2020). در همین راستا، روش‌های مختلفی برای شناسایی و طبقه‌بندی آفات مبتنی بر تصویر در محصولات مختلف ارائه شده است. توانایی تکنیک پردازش تصویر در تشخیص بیماری‌های مهم برنج مورد بررسی قرار گرفته است و دقت ۹۶/۶ درصد الگوریتم به دست آمده نشان داد که تشخیص دو بیماری لکه قهوه‌ای و بلاست برگ برنج با تکنیک پردازش تصویر امکان‌پذیر بوده است (Pattnaik *et al.*, 2020). رویکردی مبتنی بر یادگیری عمیق برای شناسایی بیماری‌ها و آفات در گیاه گوجه‌فرنگی با استفاده از تصاویر گرفته شده در محل توسط دستگاه‌های دوربین با رزولوشن‌های مختلف ارائه شده است و نتایج آن نشان داده که سیستم پیشنهادی می‌تواند به طور مؤثری نه نوع مختلف بیماری‌ها و آفات را شناسایی کند (Fuentes *et al.*, 2017). برای ارزیابی شدت بیماری در گیاه گوجه‌فرنگی، سه مدل شناخته شده شبکه عصبی کانولوشنال (AlexNet, SqueezeNet, Inception V3) مورد استفاده قرار گرفته است و نتایج نشان داده که در مقایسه با دو شبکه دیگر، AlexNet بالاترین دقت را در هر دو روش به ترتیب ۸۹/۶۹ درصد و ۹۳/۴ درصد ارائه نموده است (Verma *et al.*, 2020).

به طور کلی، برای ارائه اطلاعات کارآمدتر و دقیق‌تر به منظور بررسی تراکم جمعیت آفت و در نتیجه آن کاربرد به موقع آفت‌کش‌ها، می‌توان روش‌های نوآورانه و تکنیک‌های

تابع خطا

تابع خطا الگوریتم AlexNet در طول آموزش ترکیبی از امتیاز شی بودن (Abjctness Score)، امتیاز احتمال کلاس (Class Probability Score) و امتیاز رگرسیون کادر محصور کننده (Bounding Box Regression Score) است (Redmon et al., 2016). امتیاز شی بودن احتمال وجود شی درون کادر محصورکننده، امتیاز احتمال کلاس احتمال برچسب درست زدن برای هر شی و امتیاز رگرسیون کادر محصور کننده میزان هم‌پوشانی کادر محصورکننده پیش‌بینی شده و کادر حقیقی را تعیین می‌کند. در AlexNet خطای امتیاز شی و احتمال کلاس از طریق آنتروپی متقاطع دودویی (Binary Cross-Entropy) همراه با تابع خطای منطقی (Logits Loss Function) و خطای کادر محصورکننده توسط اشتراک پیرامون اجتماع کلی (Generalized Intersection Over Union) به دست می‌آید (Rezatofighi et al., 2019).

ارزیابی

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

معیار دقت؛ نشان دهنده نسبت پیش‌بینی‌های صحیح به کل پیش‌بینی‌ها است، با استفاده از معادله (۱) به دست می‌آید:

$$\text{Accuracy} = \frac{tp + tn}{tp + tn + fp + fn} \quad (1) \quad \text{معادله (۱)}$$

که در آن؛

tp: تعداد تصاویری که وجود آفت در آن به درستی تشخیص داده شده،

tn: تعداد تصاویری که سلامت آن به درستی تشخیص داده شده،

fp: تعداد تصاویری که به اشتباه به عنوان آفت،

fn: تعداد تصاویری که به اشتباه به عنوان سالم تشخیص داده شده‌اند.

بنابراین صورت کسر به معنای جمع قطر اصلی در ماتریس درهم‌ریختگی است. مخرج کسر به معنای کلیه تصاویر (اعم از تصاویر درست تشخیص داده شده و تصاویر اشتباه دسته‌بندی

استفاده از یک تابع تبدیل فعال‌سازی غیرخطی، نتیجه را ارائه می‌دهد. شبکه‌های عصبی پیچشی معمولاً برای ورودی‌های تصاویر 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. شبکه عصبی پیچشی در حالت کلی یک شبکه عصبی سلسله مراتبی است که لایه‌های پیچشی آن به صورت یک در میان با لایه‌های تجمیع کننده چیده شده است و بعد از آن‌ها تعدادی لایه تماماً متصل 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 and Nash, 2015).

معماری مورد استفاده از CNN

در این پژوهش از شبکه AlexNet برای انتقال یادگیری استفاده شد (krizhevsky et al., 2012)، چرا که این شبکه برای طبقه‌بندی تصویر اشیاء آموزش دیده که مرتبط با کاربرد طبقه‌بندی آفات گوجه‌فرنگی می باشد. سه لایه آخر AlexNet یعنی آخرین لایه Fully connected، لایه‌های Softmax و Classification جایگزین شدند تا شبکه برای طبقه‌بندی با دو کلاس مناسب شود.

شناسایی و شمارش شی

شناسایی شی توسط این الگوریتم در سه مرحله انجام می‌گیرد در ابتدا ویژگی‌های با ارزش تصویر ورودی توسط شبکه پشتیبان شبکه استخراج می‌شوند. سپس در قسمت گردن شبکه این ویژگی‌ها با هم آمیخته شده و سه نقشه ویژگی به صورت $S \times S$ شبکه مشبک با گام‌های ۸، ۱۶ و ۳۲ جهت افزایش قابلیت شبکه در شناسایی اشیاء، کوچک متوسط و بزرگ شکل می‌دهد. در آخر، تشخیص شی در قسمت سر شبکه از طریق در نظر گرفتن سه کادر محصور کننده برای هر سلول شبکه مشبک و نسبت دادن بهترین کادر به شی انجام می‌گیرد. تعداد کادرهای تعیین شده در انتها تعداد اشیاء را مشخص می‌کنند و اندازه هر یک نمایان کننده اندازه شی مورد نظر است.

نتیجه و بحث

در ابتدا تصاویر به‌طور تصادفی به سه مجموعه داده آموزش (۷۰ درصد)، آزمون (۱۵ درصد) و اعتبارسنجی (۱۵ درصد) تقسیم شدند. پس از آموزش شبکه، برای بررسی دقت کار از داده‌ها از روش اعتبارسنجی تقاطعی استفاده شد. بر این اساس روند آموزش مدل پیشنهادی برای معماری AlexNet در شکل (۱) قابل مشاهده است.



شکل ۱- دقت اعتبارسنجی فرآیند آموزش معماری AlexNet خط آبی دقت مجموعه آموزشی را نشان می‌دهد، خط نارنجی دقت را در مجموعه اعتبارسنجی نشان می‌دهد.

Fig. 1. Accuracy of validation of the training process for AlexNet architecture. Blue line shows accuracy on training set, orange line shows accuracy on validation set

نمونه‌های تصادفی از خروجی مدل پیشنهادی مشاهده می‌شود که تصاویر ورودی را گرفته و پیش‌بینی درستی از تشخیص شب‌پره مینوز گوجه‌فرنگی روی سطح صفحه چسبیده داشته است (شکل ۲).

در جدول (۲) ماتریس درهم‌ریختگی برای معماری AlexNet آورده شده است. نتیجه ملموسی را که می‌توان از ماتریس‌های درهم‌ریختگی استخراج کرد، توانایی مناسب معماری Alexnet در شناسایی شب‌پره مینوز گوجه‌فرنگی و عدم وجود آن در تله‌ها است. بالا بودن مقدار ثبت شده نشان از عملکرد موفق این معماری دارد. مطابق جدول (۲) خطای شبکه در تشخیص وجود این آفت ۰/۱۹ درصد و برای تشخیص عدم وجود آن ۰/۴۸ محاسبه شد.

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، بازخوانی و امتیاز F1 است. معیار صحت نشان دهنده 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 تعداد کل داده‌های است که در آن کلاس هستند. معیار امتیاز F1 نیز به نوعی میانگین هارمونیک بین معیارهای صحت و بازخوانی است. این معیارها در معادله ۲ تا ۴ نشان داده شده‌اند (Dyrmann et al., 2016).

$$\text{precision} = \frac{tp}{tp + fp} \quad \text{معادله (۲)}$$

$$\text{Recall} = \frac{tp}{tp + fn} \quad \text{معادله (۳)}$$

$$f1 - \text{score} = 2 \frac{\text{precision} \times \text{Recall}}{\text{precision} + \text{Recall}} \quad \text{معادله (۴)}$$

روش پیشنهادی به زبان ابزارها و محیط‌های پیاده‌سازی

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 اشتراک‌گذاری 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 ارائه می‌شود که کاربر می‌تواند از آن برای توسعه و اجرای برنامه‌های کاربردی یا تحقیقاتی در حوزه یادگیری عمیق بهره‌برداری کند.

برای آموزش شبکه از الگوریتم (SGDM) و تعداد ۹۰ تکرار استفاده شد. همچنین نرخ یادگیری اولیه ۰/۰۰۰۱ و اندازه ۳۰ Minibatch و تعداد سایر پارامترها در جدول (۱) در نظر گرفته شد.

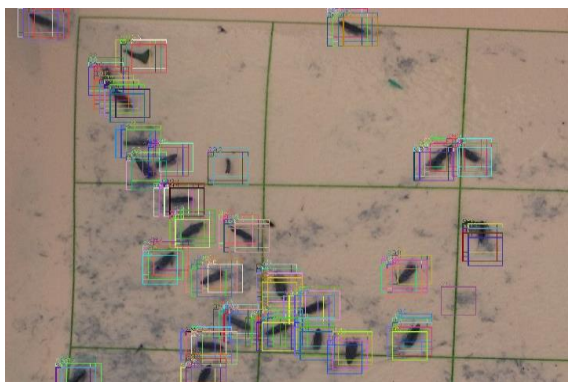
جدول ۱- تعداد پارامترهای مورد نیاز برای این روش

Table 1. Number of parameters required for the used models

Type of architecture	Parameters	Trainable parameters	
AlexNet	24555044	24555044	0

بیماری‌های گوجه‌فرنگی استفاده کرده بودند مطابقت دارد چرا که دقت گزارشی آن‌ها به ترتیب ۹۷/۲ و ۹۵/۲۴ بود.


به‌منظور ارزیابی دقیق‌تر عملکرد الگوریتم در شمارش، بین تعداد واقعی هر نمونه و تعداد پیش‌بینی شده توسط شبکه، از منحنی رگرسیون خطی استفاده شد (شکل ۳). این نتایج بیانگر قدرت تعمیم‌پذیری بالای شبکه AlexNet ($R^2=0.99$) در تخمین تعداد شب‌پره مینوز گوجه‌فرنگی است. که این نتایج با مطالعات Verma *et al.*, (2020) و Fuentes *et al.*, (2017) که رویکردی مبتنی بر یادگیری عمیق برای شناسایی آفات در گوجه‌فرنگی با استفاده از تصاویر گرفته‌شده توسط دستگاه‌های دوربین با رزولوشن‌های مختلف ارائه کردند، همسو است.



جدول ۲- ماتریس اغتشاش شبکه AlexNet
Table 2. Implementation confusion matrix

Prediction / truth	With <i>Tuta absoluta</i>	Healthy
With <i>Tuta absoluta</i>	99/81	0.19
Healthy	99.52	0.48

بر اساس پارامترهای مذکور در جدول (۱)، نتایج معیارهای مختلف برای ارزیابی دسته‌بندی شامل دقت، بازخوانی، صحت و امتیاز F1 به تفکیک در جدول (۳) نشان داده شده است. طبق نتایج دقت این روش ۹۹/۸۱ به دست آمد. که این نتایج با مطالعات صورت گرفته توسط Durmus *et al.*, (2017) و Suryawati *et al.*, (2018) که از تکنیک یادگیری عمیق با معماری AlexNet برای شناسایی و تشخیص آفات و



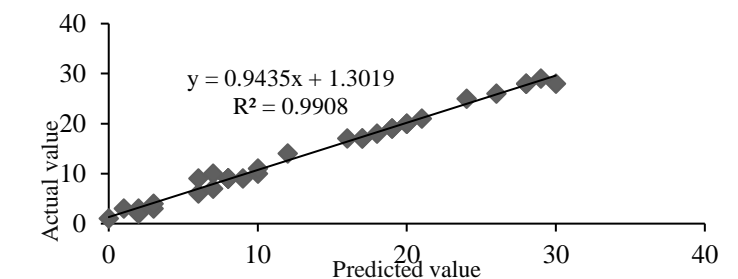
شکل ۲- نمونه تصادفی از شمارش و پیش‌بینی *Tuta absoluta* توسط شبکه

Fig. 2. Random samples of the *Tuta absoluta* prediction based on the proposed method

جدول ۳- ارزیابی نتایج دسته وجود و عدم وجود شب‌پره مینوز گوجه‌فرنگی در معماری AlexNet بر حسب درصد

Table 3. Evaluation results of different categories of *Tuta absoluta* with Alexnet architecture in percentage

F1-score	Recall	Precision	Accuracy	Class
100	100	100	99.81	With <i>Tuta absoluta</i>
100	100	100	99.52	Healthy



شکل ۳- رابطه خطی رگرسیونی و ضریب تبیین بین مقادیر واقعی داده‌ها و مقادیر پیش‌بینی شده توسط مدل

Fig 3. Linear regression relationship and coefficient of determination between actual value and predicted value by model

یادگیری عمیق نسبت به روش‌های پیشین در این است که بدون هیچ پیش پردازشی می‌تواند از روی تصویر خام، نوع آفت را تشخیص دهد. طبیعی است با افزایش حجم داده‌های آموزشی، قدرت تشخیص این مدل‌ها نیز افزایش می‌یابد. از طرف دیگر با توسعه رویکرد ارائه شده در این پژوهش، می‌توان از آن به‌عنوان بخش اصلی در یک سیستم کاملاً خودکار در کشاورزی هوشمند استفاده کرد.

سپاسگزاری

این مقاله بخشی از رساله دکتری نگارنده اول است که توسط دانشگاه رازی حمایت مالی شده است.

برای کشت مناسب و موفقیت‌آمیز محصولات کشاورزی، تشخیص و شمارش دقیق آفات ضروری است. تشخیص و شمارش سریع‌تر آفات در گیاهان می‌تواند به توسعه روش‌های کنترلی به‌موقع کمک کند و در عین حال خسارات اقتصادی را به‌میزان قابل توجهی کاهش دهد. پیشرفت‌های اخیر در یادگیری عمیق به محققان اجازه داد تا دقت سیستم‌های تشخیص را به‌شدت بهبود بخشند. از یافته‌های این مطالعه می‌توان نتیجه گرفت که مدل‌های یادگیری عمیق، توانایی بالایی در تشخیص و شمارش دقیق آفت کلیدی گوجه‌فرنگی *T. absoluta* با استفاده از تصاویر گرفته شده را دارند و روش‌های شناسایی و شمارش آفات بر اساس سیستم هوشمند نسبت به روش‌های رایج کارآمدتر است. مزیت اصلی

References

- ASHTARI, S., SABAH, Q. AND TALEBI JAHROMI, K. H. 2020. Survey of parasitismic effect of two species of *Trichogramma* on eggs of *Tuta absoluta* under effect of pesticides. *Journal of Vegetables Sciences* 4(7): 1-11 (In Farsi). DOI:10.22034/IUVS.2020.125738.1094
- DYRMANN, M., KARSTOFT, H., AND MIDTIBY, H. S. 2016. Plant species classification using deep convolutional neural network. *Bio systems engineering*, 151: 72-80. Doi.org/10.1016/j.biosystemseng.2016.08.024
- DURMUŞ, H., GÜNEŞ, E. O., AND KIRCI, M. 2017. 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. DOI:10.1109/Agro-Geoinformatics.2017.8047016
- FITE, T., TEFERA, T. 2022. Genetic variation and population structure of the old world bollworm *helicoverpa armigera* (lepidoptera: noctuidae) in Ethiopia. *Environmental Entomology* 51(4): 859-869. <https://doi.org/10.1093/ee/nvac039>
- FUENTES, A. F., YOON, S., LEE, J. AND PARK, D. S. 2018. High-performance deep neural network-based tomato plant diseases and pests diagnosis system with refinement filter bank. *Front Plant Sciences*, 9: 1162. Doi: 10.3389/fpls.2018.01162
- FUENTES, A., YOON, S., KIM, S. C. AND PARK, D. S. 2017. A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors (Basel)*, 17. DOI: 10.3390/s17092022
- KRIZHEVSKY, A., SUTSKEVER, I., AND HINTON, G. E. 2012. Image net classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25: 1097-1105. <https://doi.org/10.1145/3065386>
- LIU, J. AND WANG, X. 2020. Tomato diseases and pests detection based on improved yolo v3 convolutional neural network. *Front Plant Sciences*, 11: 898. <https://doi.org/10.3389/fpls.2020.00898>
- MOKHTAR, U., ALI, M. A., HASSENIAN, A. E. and HEFNY, H. 2015. Tomato leaves diseases detection approach based on support vector machines, 11th

- International Computer Engineering Conference (ICENCO). IEEE, pp. 246-250.
DOI: 10.1109/ICENCO.2015.7416356
- O'SHEA, K., AND NASH, R. 2015. An introduction to convolutional neural networks. arXiv Preprint arXiv:1511.08458.
<https://doi.org/10.48550/arXiv.1511.08458>
- PATTNAIK, G., SHRIVASTAVA, V. K. AND PARVATHI, K. 2020. Transfer learning-based framework for classification of pest in tomato plants. Applied Artificial Intelligence, 34: 981-993
<https://doi.org/10.1080/08839514.2020.1792034>.
- POTTING, R., JAN VAN DER GAAG, D., LOOMANS, A., VAN DER STRATEN, M., ANDERSON, H., MACLEOD, A., CASTRILLÓN J. M. G. AND CAMBRA, G. V. 2009. *Tuta absoluta*, Tomato leaf miner moth or South American tomato moth. Ministry of Agriculture, Nature and Food Quality (LVN) Plant Protection Service of the Netherlands. Accessed on 10/21/10 from:
http://www.minlnv.nl/cdlpub/servlet/CDLServlet?p_file_id=42402
- REDMON, J., S. DIVVALA, GIRSHICK, R. and A. FARHADI. A. 2016. You only look once: Unified, real-time object detection. Pages 779-788. Proceedings of the IEEE conference on computer vision and pattern recognition.
<https://doi.org/10.48550/arXiv.1506.02640>
- REZAEI, M., ASADI, G. AND HOSSEINI, M. 2015. The marginal effects of *Datura stramonium* L. on the density of key pests of tomato *Lycopersicon esculentum* Mill. Journal of Weed Ecology, 3: 81-90.
- REZATOFI, H., N. TSOI, J. GWAK, A. SADEGHIAN, I. REID AND SAVARESE. S. 2019. Generalized intersection over union: A metric and a loss for bounding box regression. Pages 658-666. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.
<https://doi.org/10.48550/arXiv.1902.09630>
- SHIN, H. C., ROTH, H. R., GAO, M., LU, L., XU, Z., NOGUES, I., YAO, J., MOLLURA, D., and 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: 1285-1298. DOI: 10.1109/TMI.2016.2528162
- SURYAWATI, E., SUSTIKA, R., YUWANA, R.S., SUBEKTI, A. AND PARDEDE, H.F. 2018. Deep structured convolutional neural network for tomato diseases detection. In 2018 international conference on advanced computer science and information systems (ICACSIS) (pp. 385-390). IEEE.
DOI:10.1109/ICACSIS.2018.8618169
- TRAN, T. T., CHOI, J. W., LE, T. T. AND KIM, J. W. 2019. A comparative study of deep cnn in forecasting and classifying the macronutrient deficiencies on development of tomato plant. Applied Sciences, 9: 1601. <https://doi.org/10.3390/app9081601>
- VERMA, S., CHUG, A. AND SINGH, A. P. 2020. Application of convolutional neural networks for evaluation of disease severity in tomato plant. Journal of Discrete Mathematical Sciences and Cryptography, 23:273282.
<https://doi.org/10.1080/09720529.2020.1721890>
- WANG, Q., QI, F., SUN, M., QU, J. AND XUE, J. 2019. Identification of tomato disease types and detection of infected areas based on deep convolutional neural networks and object detection techniques. Comput Intell Neurosci, 91:42-53.
<https://doi.org/10.1155/2019/9142753>
- ZHENG, Y. Y., KONG, J. L., JIN, X. B., WANG, X. Y., SU, T. L. AND ZUO, M. 2019. CropDeep: The crop vision dataset for deep-learning-based classification and detection in precision agriculture. Sensors, 19: 1058.
<https://doi.org/10.3390/s19051058>