

## سامانه تشخیص بیماری قارچی سفیدک پودری و آنتراکنوز برگ خیار با تکنیک پردازش تصویر و شبکه عصبی مصنوعی

هادی حسینی<sup>۱\*</sup>، داود محمدزمانی<sup>۲</sup> و عباس ارباب<sup>۳</sup>

۱- \*نویسنده مسوول: مربی، موسسه آموزش عالی علمی کاربردی جهاد کشاورزی، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران (hosseini.hadi@yahoo.com)

۲- استادیار گروه مکانیک بیوسیستم، واحد تاکستان، دانشگاه آزاد اسلامی، تاکستان، ایران

۳- دانشیار گروه گیاهپزشکی، واحد تاکستان، دانشگاه آزاد اسلامی، تاکستان، ایران

تاریخ پذیرش: ۹۶/۰۴/۲۴

تاریخ دریافت: ۹۴/۱۲/۱۵

### چکیده

بیماری‌های گیاهی می‌توانند باعث کاهش کیفیت و کمیت محصولات کشاورزی شوند. در بعضی از کشورها کشاورزان زمان قابل توجهی را به منظور کنترل بیماری گیاهی صرف مشاوره با گیاه‌پزشکان می‌کنند در حالی که زمان عاملی مهم در کنترل بیماری می‌باشد، به همین دلیل ارائه روشی سریع، ارزان و دقیق برای تشخیص بیماری‌های گیاهی لازم به نظر می‌رسد. با توجه به این که بیماری‌های قارچی سفیدک پودری و آنتراکنوز بیشترین میزان خسارت را در گلخانه‌های خیار به وجود می‌آورند، در این پژوهش با استفاده از دانش پردازش تصویر و شبکه عصبی به تشخیص و طبقه‌بندی دو بیماری قارچی مذکور پرداخته شد. مراحل پردازش تصویر شامل چهار قسمت اصلی: (۱) جمع‌آوری تصاویر، (۲) پیش‌پردازش، (۳) بررسی تصاویر تصحیل شده در دو فضای رنگی HSV و  $L^*a^*b^*$  و انتخاب بهترین مؤلفه رنگی به منظور طبقه‌بندی و استخراج نواحی آسیب دیده برگ، (۴) استخراج خواص بافت نواحی آلوده سطح برگ با استفاده از ماتریس هم‌وقوعی بود. از آنجایی که دو فاکتور دقت و زمان در تشخیص و طبقه‌بندی بیماری‌های گیاهی حائز اهمیت است لذا شبکه عصبی مصنوعی (ANN) با الگوریتم پس انتشار خطا و تابع آموزشی لونیبرگ مارکورات (LM) به عنوان بهترین مدل انتخاب گردیدند که به طور موفقیت آمیزی قادر به تشخیص و طبقه‌بندی این دو بیماری در مدت زمان ۶ ثانیه و با دقت ۹۹/۹۶ درصد شدند.

**کلید واژه‌ها:** آنتراکنوز، استخراج ویژگی، سفیدک پودری، شبکه عصبی مصنوعی، ماتریس هم‌وقوعی

### مقدمه

روش‌های طیفی در مقایسه با روش‌های پردازش تصویر بسیار گران‌قیمت بوده و از لحاظ اقتصادی مقرون به صرفه نخواهد بود (Camargo and smith, 2009). با توجه به هزینه‌های بالا و اثرات زیست‌محیطی زیان‌آور سموم، استفاده از یک روش نظارتی، دقیق و مقرون به صرفه در زمان ضروری است (Bock et al, 2010). امروزه ابزارهای کامپیوتری مبتنی بر دانش پردازش تصویر در حوزه کشاورزی برای نظارت بر رشد محصول توسعه زیادی یافته و تشخیص بیماری‌های گیاهی می‌تواند برای افرادی که

بیماری‌های گیاهی یکی از عوامل اصلی زیان‌های اقتصادی در بخش تولیدات محصولات کشاورزی در سراسر جهان می‌باشد، لذا نظارت بر سلامت و تشخیص بیماری در گیاهان برای داشتن کشاورزی پایدار، امری حیاتی است (Sankaran et al, 2010). روش‌های زیادی برای تشخیص بیماری‌های گیاهی وجود دارد ولی اکثر این روش‌ها وقت‌گیر و پر هزینه هستند و یا جزو روش‌های مخرب محسوب می‌شوند. همچنین استفاده از

که بتدریج سطح آن را فرا می‌گیرد (شکل ۱- الف). بیماری آنتراکنوز خیار *Colletotrichum orbiculare* در گلخانه‌هایی با رطوبت بالا معمول است و جزء بیماری‌های مخرب خیار می‌باشد که به صورت لکه‌های قهوه‌ای رنگ مایل به حاشیه زرد رنگ ظاهر می‌شود و بتدریج کل سطح برگ را فرا می‌گیرد و باعث کاهش راندمان محصول می‌شود (شکل ۱- ب).

یکی از روش‌های معمول که توسط دانشمندان انجام می‌پذیرد، تخمین میزان آسیب ناشی از بیماری گیاهان (درجه بندی و تعیین درصد آلودگی) با استفاده از سامانه ماشین بینایی است. اگرچه برای محاسبه شدت بیماری استانداردهای کلی وجود دارد، ولی از آنجا که تعیین شدت بیماری با استفاده از چشم غیرمسلح انجام می‌شود، نمی‌توان به‌طور دقیق شدت بیماری را اندازه گرفت. از جمله مشکلات روش چشمی، متفاوت بودن دانش و درک افراد مختلف است که سبب می‌شود شدت بیماری در نمونه‌های مشابه توسط چند متخصص به صورت متفاوت تخمین زده شود. بنابراین اندازه‌گیری‌های انجام شده وابسته به شخص بوده و دقیق نمی‌باشد (Patil and kumar, 2011). در علم گیاه پزشکی اصول و روش تشخیص بیماری‌های گیاهی با استفاده از دو روش علائم بیماری<sup>۱</sup> که بیشتر از مشاهدات روی گیاه به دست می‌آید و نشانه‌های<sup>۲</sup> بیماری که مبتنی بر مشاهدات در آزمایشگاه است امکان پذیر است.

اطلاعات کافی در زمینه کشت محصول ندارند مزایای زیادی داشته باشد (Camargo and smith, 2009). همچنین در حوزه کشاورزی این ابزارها دارای کاربردهایی نظیر تشخیص بیماری برگ، ساقه و میوه، بررسی سطح آسیب دیده به وسیله بیماری، تعیین رنگ منطقه آسیب دیده و غیره هستند (Jayamala and kumar, 2011). میزان سطح زیر کشت، تولید خیار گلخانه‌ای کشور طبق آمارنامه جهاد کشاورزی در سال ۱۳۹۴ به ترتیب برابر با ۵۴/۰۵۶/۲۲۸ متر مربع و ۱/۲۴۹/۱۷۰ تن می‌باشد (Ahmadi et al., 2015).

در بین محصولات گلخانه‌ای، قارچ‌ها بیشترین بیماری‌ها را در گلخانه‌های خیار به وجود می‌آورند. از جمله بیماری‌های مهم قارچی که به خیار و عمدتاً برگ آن حمله می‌کنند می‌توان به آنتراکنوز، سفیدک پودری و سفیدک داخلی اشاره کرد (Ahmadi et al., 2011). بیماری سفیدک پودری با نام علمی *Podosphaera xanthii* از مهم‌ترین بیماری گیاهی خانواده کدوئیان است که در نواحی معتدل نسبتاً خشک مشاهده می‌گردد. این بیماری از دیرباز در اکثر مناطق جالیز کاری از جمله سواحل دریای مازندران، اصفهان، تهران، کرج، قزوین و غیره وجود داشته است و هر ساله خسارت قابل توجهی به محصولات وارد می‌کند. نشانه‌های این بیماری به صورت لکه‌های سفید پودری شکل روی برگ و ساقه می‌باشد



A



B

شکل ۱- تصاویر بیماری‌های قارچی خیار گلخانه، الف: سفیدک پودری، ب: آنتراکنوز (اصلی)

Figure 1. The image of fungal disease of greenhouse cucumber, a: Powdery Mildew, b: Anthracnose (Original)

تأثیر را به منظور جداسازی علائم بیماری از یکدیگر دارند. از طرفی ویژگی خواص بافت نیز می‌تواند تأثیر بسزایی در تفکیک علائم بیماری داشته باشد. بنابراین بکارگیری ترکیب این ویژگی‌ها می‌تواند بسیار مناسب‌تر از استفاده هر کدام از آن‌ها به صورت مجزا باشد (Paliwal et al., 2003). از آنجایی که زمان عامل مهمی در کنترل بیماری است (Omran et al., 2014)، تشخیص سریع و دقیق بیماری‌های گیاهی در نظارت بر گلخانه‌های مکانیزه از اهمیت زیادی برخوردار است؛ به طوری که با داشتن اطلاعات اولیه سلامت محصول و تشخیص بیماری می‌تواند با اعمال استراتژی‌های مدیریتی مناسب نظیر آفت‌کش‌ها، قارچ‌کش‌ها و مواد شیمیایی خاص، این مهم را تسهیل نماید (Patil and kumar, 2011). لذا در این پژوهش از روش تکنیک پردازش تصویر و روش مدل‌سازی شبکه عصبی مصنوعی (ANN) با الگوریتم پس انتشار خطا به منظور تشخیص و طبقه‌بندی بیماری برگ خیار استفاده شده است.

## مواد و روش‌ها

### جمع‌آوری تصاویر

در این پژوهش تعداد ۱۵۰ نمونه که شامل برگ‌های سالم، آلوده به بیماری قارچی سفیدک پودری و آنتراکنوز (از هر کدام ۵۰ نمونه) از یک گلخانه خیار به مساحت ۹۶۰۰ متر مربع واقع در استان قزوین برای انجام تجزیه و تحلیل جمع‌آوری گردید و برای عکس‌برداری از دوربین Canon Power Shot مدل SX150 با بزرگنمایی ۱۴ پیکسل با مشخصات ابعادی ۱۵۰۰×۱۵۰۰ پیکسل استفاده شد. انتخاب نوع نور بستگی به کیفیت تصویر گرفته شده و تحت شرایط نورپردازی مشخص است که منابع متداول نورپردازی برای زمینه‌های مختلف تحقیقاتی از جمله کیفیت سنجی محصولات کشاورزی: لامپ فلورسنت یا مهتابی LED، لیزر و مادون قرمز می‌باشد (Brosnan and Sun, 2004). در این تحقیق به منظور بهبود شرایط نورپردازی و ارتقای کیفیت

در دهه گذشته محققان از تکنیک‌های پردازش تصویر به منظور بررسی بیماری در گیاهان استفاده کرده‌اند که در ادامه به آن اشاره خواهد شد. در سال ۲۰۰۹ روشی بر مبنای ماشین بردار پشتیبان، برای تشخیص بیماری برنج ارائه شد که در آن از ویژگی‌های رنگی علائم برای طبقه‌بندی بیماری‌ها استفاده شده بود (Yao et al., 2009). در سال ۲۰۰۶ با استفاده از تکنیک پردازش تصویر و آنالیزهای جداسازی چهار بیماری مربوط به درخت گریپ فروت شناسایی و با استفاده از ماتریس هم‌اتفاق این طبقه‌بندی انجام شد که خواص ساختاری رنگ مرکبات در کانال HSI استخراج، سپس با استفاده از آنالیزهای جداسازی با استفاده از نرم‌افزار SAS بیماری‌ها با دقت ۹۸/۷۵ درصد از هم جداسازی گردیدند (Pydipati et al., 2006).

Tavakoli et al. (2013) با استفاده از روشی مبتنی بر بررسی هیستوگرام لایه فام تصاویر و اعمال فیلترهای مورفولوژی و همچنین اثر هیستوگرام تصاویر در مدل رنگی HSV موفق به تشخیص بیماری سفیدک داخلی در گلخانه‌های خیار به کمک سامانه ماشین بینایی با دقت ۹۰ درصد شدند. در سال ۲۰۱۲ در پژوهشی با عنوان استفاده از ماشین بینایی به منظور تشخیص بیماری گیاه (بیماری سفیدک دروغین خیار) با استفاده از تبدیل فضای رنگی به HSV موفق به تشخیص تصاویر آلوده به بیماری با دقت ۹۰ درصد شدند (Nermeen et al., 2012). در سال ۲۰۱۳ روشی برای تشخیص خودکار بیماری‌های گیاه پنبه ارائه شد که از تبدیل موجک به منظور استخراج ویژگی و از شبکه ماشین بردار پشتیبان برای دسته‌بندی تصاویر استفاده گردید که در بهترین مدل دقت ۹۰ درصد گزارش شد (Bernardes et al., 2013).

استفاده از ویژگی‌های شکل، رنگ و بافت تصاویر محصولات کشاورزی به تنهایی نمی‌تواند عملکرد چندان مناسبی برای دسته‌بندی علائم بیماری داشته باشند. به عبارتی بعضی علائم بیماری یک محصول دارای ویژگی‌های خواص شکل و رنگ مشابه بوده که کمترین

با ضریب ۰/۵، ابعاد تصاویر از ۱۵۰۰×۱۰۰۰ به ۷۵۰×۵۰۰ پیکسل کاهش یافت که با این اقدام سرعت پردازش الگوریتم بر روی تصاویر تصحیل شده از برگ خیار افزایش یافت.

### جداسازی برگ از پس زمینه

بخش‌بندی تصویر از مهم‌ترین مراحل پردازش تصاویر است که تصویر را به ناحیه‌های سازنده آن تقسیم‌بندی می‌کند. روش‌های گوناگونی برای بخش‌بندی ناحیه مورد نظر وجود دارد که شامل تعیین حد آستانه، لبه‌یابی و ناحیه است. برای جداسازی برگ‌ها از پس‌زمینه، از روش حد آستانه استفاده شد که براساس رابطه ۱ عمل می‌کند:

رابطه (۱)

$$BW(x, y) = \begin{cases} 1 & \text{if } f(x, y) \geq T \\ 0 & \text{if } f(x, y) < T \end{cases}$$


طبق رابطه ۱ هر پیکسلی از تصویر که شدت نور بیشتر از  $T$  داشته باشد جزء ناحیه مورد نظر (ناحیه برگ) است و مقدار پیکسلی یک می‌گیرد و هر پیکسلی که شدت نور کمتر از  $T$  داشته باشد، جزء پس‌زمینه تصویر محسوب می‌شود و مقدار پیکسلی صفر می‌گیرد (Gonzalez et al., 2009) (شکل ۴).

تصاویر عکس برداری شده با دوربین، لامپ فلورسنت مورد استفاده قرار گرفت. به منظور کاهش اثر سایه و نویز از رنگ زمینه سیاه به عنوان پس‌زمینه<sup>۱</sup> استفاده شد (شکل ۲). فاصله عمودی لنز تا سطح نمونه در این پژوهش با استفاده از روش آزمون سعی و خطا به دست آمد که در نهایت فاصله ۳۰ سانتی‌متر به عنوان بهترین مقدار لحاظ شد.

در شکل ۳ بلوک دیاگرام مراحل تجزیه و تحلیل تصاویر تصحیل شده توسط رایانه‌ای با مشخصات پردازنده 8GB Ram, Core i7 و نرم‌افزار MATLAB نسخه 2014a آورده شده است.

### پیش‌پردازش

به دلیل این که تصاویر تصحیل شده دارای کیفیت بالایی بوده و نویز خاصی در آن‌ها وجود ندارد لذا هیچ نوع عملیات پیش‌پردازشی به منظور تغییر شدت روشنایی پیکسل‌های تصویر برای ارتقای کیفیت آن‌ها یا حذف نویز در تصاویر اعمال نگردید. با توجه به این که حجم تصاویر بالا بوده و این موضوع باعث افزایش مدت زمان پردازش تصویر توسط الگوریتم می‌شود، لازم بود تا حجم ابعادی تصاویر کاهش یافت، بنابراین با استفاده از دستور تغییر اندازه<sup>۲</sup> ماتریس‌ها (تصاویر) در نرم‌افزار MATLAB




شکل ۲- کلاس‌های مختلف برگ خیار، الف: برگ سالم، ب: برگ آلوده به بیماری سفیدک پودری، ج: برگ آلوده به بیماری آنتراکنوز (اصلی)


Figure 2. Different classes of cucumber leaf, A: healthy leaves, B: Powdery Mildew, C: Anthracnose (Original)

1- Background

2- Matlab code: (g = imresize (I, 0.5))



شکل ۳- بلوک دیاگرام مراحل پردازش تصویر  
Figure 3. The block diagram steps of image processing



شکل ۴- الف: فضای RGB، ب: فضای Gray scale، ج: هیستوگرام تصویر Gray scale، د: جداسازی برگ از پس زمینه (اصلی)

Figure 4. A: RGB space, B: Gray scale space, C: Histogram of the image gray scale, D: Leaf separating of background (Original)

رابطه (۲)

$$I(x, y) = 0.3R + 0.59G + 0.11B$$

### بخش بندی نواحی آسیب دیده

برای انجام عمل بخش بندی لازم است ابتدا تصاویر به فضای رنگی مستقل از دستگاه انتقال داده شوند تا بتوان به بررسی تصاویر تصحیل شده در دو فضای رنگی \*L\*a\*b\* و HSV پرداخت که این امر علاوه بر کاهش خطای تشخیص بیماری، باعث حذف اطلاعات اضافی تصویر می شود.

به منظور محاسبات ریاضی نیاز به استفاده از تصاویر در حالت دودویی یا باینری است به همین منظور تصاویر گرفته شده در فضای رنگی RGB می بایست به حالت دودویی تبدیل شوند به همین منظور در ابتدا می بایست میزان شدت روشنایی در فضای RGB منطبق با فضای خاکستری در محدوده فراوانی رنگی صفر تا ۲۵۵ قرار گیرد که این تبدیلات در رابطه ۲ آورده شده است (Mundada and Gohokar , 2013):

نوری مسبب آن هستند مؤثر باشد (شکل ۵).

با بررسی‌های به عمل آمده در هر سه مدل فضای رنگی مشخص گردید که هر یک از مؤلفه‌های رنگی در سه فضای رنگی مذکور به تنهایی نمی‌تواند برای بخش‌بندی نواحی آلوده سطح برگ مؤثر باشد و تمامی این مؤلفه‌ها می‌توانند در بالا بردن دقت استخراج نواحی آلوده سطح برگ نقش بسزایی داشته باشند. به همین دلیل از میانگین مؤلفه‌های رنگی در سه فضای رنگی RGB،  $L^*a^*b^*$  و HSV برای بخش‌بندی و استخراج نواحی آلوده سطح برگ استفاده گردید.

با توجه به این که عملکرد الگوریتم وابسته به ویژگی‌های استخراج شده از تصویر برگ خیار است بنابراین انتخاب ویژگی مرتبط و کارآمد از میان مجموعه ویژگی‌های رنگی استخراج شده، می‌تواند باعث افزایش عملکرد الگوریتم پیشنهاد شده برای طبقه‌بندی بیماری برگ خیار شود (Mery et al., 2013).

در مسائل مربوط به داده کاوی، تکنیک‌های گوناگونی برای انتخاب ویژگی‌های برتر وجود دارد که از آن جمله می‌توان به SFS، آنالیز فاکتور، CFS، الگوریتم ژنتیک و آنالیز حساسیت اشاره کرد (Mollazade et al., 2013). در این پژوهش از روش آنالیز حساسیت که جزو روش‌های پر کاربرد برای انتخاب ویژگی‌های برتر است و در تحقیقات زیادی کاربرد داشته است، استفاده شد (Donis-Gonzalez et al., 2013). که با استفاده از این آنالیز، هر ۹ مؤلفه رنگی انتخاب و مورد بررسی قرار گرفت (شکل ۶).

همان‌طور که مشاهده می‌شود مؤلفه‌های رنگی R، G، B، H، S، V،  $L^*$ ،  $a^*$  و  $b^*$  به‌طور تقریباً یکسان دارای مقادیر بالای حساسیت برای کلاس‌های برگ خیار هستند لذا با اعمال یک حد آستانه مناسب و تبدیل تصاویر خاکستری به باینری و محاسبه تفاضل نواحی آلوده از قسمت سالم برگ به بخش‌بندی و استخراج نواحی آلوده سطح برگ پرداخته شد (شکل ۷).

فضای رنگی  $L^*a^*b^*$  پیچیده‌ترین فضای رنگی تعریف شده توسط کمیته بین‌المللی روشنایی (CIE) می‌باشد. این فضا کلیه رنگ‌های قابل مشاهده توسط چشم انسان را توصیف می‌کند و تقریباً مشابه سیستم بینایی انسان طراحی شده است و به‌عنوان یک مدل مستقل کاربرد دارد لذا این مدل فضای رنگی برای بخش‌بندی تصاویر انتخاب گردید (Jafar Nejad Qomi, 2011).

در مدل رنگی HSV به توصیف کلیه رنگ‌های قابل مشاهده توسط چشم انسان پرداخته می‌شود که تقریباً مشابه سیستم بینایی بشر طراحی شده است. مدل رنگی HSV هر رنگ را با سه مؤلفه مشخص می‌نماید: رنگ<sup>۱</sup>، اشباع<sup>۲</sup> و ارزش<sup>۳</sup>.

به‌منظور بررسی تصاویر در فضای رنگی HSV نیاز به تبدیل فضای رنگی است که تبدیل فضای رنگی RGB به فضای رنگی HSV در رابطه ۳ نشان داده شده است (Albashish et al., 2011):

رابطه (۳-۱)

$$\text{Hue (h)} = \begin{cases} \theta & B \leq G \\ 360 - \theta & B > G \end{cases}$$

$$\theta = \arccos \left\{ \frac{(1/2)[(R - G) + (R - B)]}{[(R - G)^2(R - G)(G - B)]^{1/2}} \right\}$$

رابطه (۳-۲)

$$\text{Saturation (s)} = 1 - \frac{3}{R + G + B} [\min(R, G, B)]$$

رابطه (۳-۳)

$$\text{Value (v)} = \frac{R + G + B}{3}$$


در فضای رنگی HSV، می‌توان به این نتیجه رسید که تفاوت زیادی بین لکه‌های بیماری و پس‌زمینه در مؤلفه V تصویر وجود دارد. در حالی که مؤلفه V می‌تواند در کم کردن میزان نفوذ، که نویزهای قوی

1- Hue

2- Saturation


3- Value

H Component image    S Component image    V Component image




شکل ۵- مؤلفه تصویر در مدل HSV (اصلی)

Figure 5. The image component in HSV model (Original)



شکل ۶- آنالیز حساسیت مؤلفه‌های رنگی مختلف برگ خیار (اصلی)

Figure 6. Analysis of sensitivity of different color component of cucumber leaf (Original)



B

شکل ۷- بخش‌بندی نواحی آسیب دیده، الف: بیماری آنتراکنوز، ب: بیماری سفیدک پودری (اصلی)

Figure 7. Segmentation of leaf surface contamination, A: Anthracnose, B: Powdery Mildew disease (Original)

### تعیین درصد میزان خسارت

در این روش به منظور تعیین میزان خسارت مبادرت به تعریف تابعی برای شمارش تعداد پیکسل‌های سطح برگ و قسمت‌های آلوده آن شد که در رابطه ۴ درصد تعیین میزان خسارت سطح برگ ذکر شده است:

رابطه (۴)

$$\gamma = \frac{A}{A_t} \times 100$$

$\gamma$  میزان خسارت،  $A$  تعداد پیکسل‌های نواحی آلوده سطح برگ خیار و  $A_t$  تعداد پیکسل‌های کل برگ است.

### استخراج ویژگی بافت

در سال‌های اخیر استفاده از خواص بافت در زمینه کیفیت سنجی محصولات کشاورزی توسعه یافته است و از این ویژگی برای طبقه‌بندی و آشکارسازی نواحی آسیب دیده محصولات مختلف کشاورزی استفاده می‌شود (Mery et al., 2013). در این پژوهش برای تحلیل بافت نمونه‌های برگ خیار از روش ماتریس هم‌وقوعی<sup>۱</sup> استفاده شده است (رابطه ۵)، (Mollazade et al., 2013):

رابطه (۵)

$$C_{\Delta x, \Delta y}(m, n) = \sum_{p=1}^i \sum_{q=1}^j \begin{cases} 1, & \text{if } (p, q) = n \text{ and } I(p + \Delta x, q + \Delta y) = m \\ 0 & \text{Otherwise} \end{cases}$$

در این رابطه،  $C$  ماتریس هم‌وقوعی،  $m$  و  $n$  مقادیر مربوط به شدت روشنایی در تصویر خاکستری،  $i$  و  $j$  اندازه تصویر،  $p$  و  $q$  مختصات فضایی<sup>۲</sup> و سرانجام  $\Delta x$  و  $\Delta y$  پارامترهای انحرافی<sup>۳</sup> می‌باشند، همچنین مقدار زاویه  $\theta$  برابر ۱ انتخاب شد (Mery et al., 2013). پس از اجرای این تکنیک بر روی تصاویر کلاس‌های مختلف بیماری برگ خیار، ویژگی‌ها با استفاده از ماتریس هم‌وقوعی استخراج شد (جدول ۱).

### طراحی مدل شبکه عصبی مصنوعی

هدف اصلی از کاربرد شبکه عصبی در این پژوهش

تشخیص و طبقه‌بندی بیماری برگ خیار به سه کلاس سالم، سفیدک پودری و آنتراکنوز خیار می‌باشد. لذا پس از استخراج ویژگی‌ها، مرحله بعد مربوط به طبقه‌بندی آن‌هاست. دو روش اصلی به منظور طبقه‌بندی وجود دارد که عبارتند از دسته‌بندی<sup>۴</sup> و خوشه‌بندی<sup>۵</sup>.

در روش دسته‌بندی که یک روش طبقه‌بندی داده به صورت نظارت شده است، تمامی داده‌ها بر چسب‌گذاری شده و کلاس یا طبقه مربوط به آن‌ها مشخص می‌شود.

فرآیند دسته‌بندی ابتدا با استفاده از ویژگی‌های مربوط به هر کلاس مشخص، آموزش می‌بیند که به آن فاز یادگیری می‌گویند. سپس با استفاده از تعداد مشخصی از نمونه‌ها، عملکرد مدل ساخته شده مورد ارزیابی قرار می‌گیرد. از روش‌های مختلف دسته‌بندی کننده می‌توان به درخت تصمیم<sup>۶</sup>، ماشین بردار پشتیبان<sup>۷</sup>، شبکه‌های عصبی مصنوعی<sup>۸</sup>، دسته‌بندی کننده بی‌زی<sup>۹</sup>، نزدیک‌ترین همسایه<sup>۱۰</sup> و تکنیک منطق فازی<sup>۱۱</sup> اشاره کرد که در بین روش‌های مذکور روش شبکه عصبی مصنوعی جزء تکنیک‌های پر کاربرد در زمینه‌های گوناگون می‌باشد (Teimouri et al., 2014).

یکی از مهم‌ترین ویژگی‌های شبکه عصبی مصنوعی توانایی و قابلیت آن‌ها در یادگیری است. آموزش و یادگیری به معنای تشخیص الگوهای معین و اختصاصی دادن پاسخ‌های صحیح به آن‌هاست. در حالت ایده‌آل شبکه باید بتواند در قبال دریافت ورودی‌هایی که حتی در فاز آموزش و یادگیری اعمال نگردیده‌اند پاسخ صحیح ایجاد نماید. آموزش دیدن شبکه‌های عصبی در واقع چیزی جز تنظیم وزن‌های ارتباطی نرون‌ها به ازای دریافت مثال‌های مختلف نیست تا خروجی شبکه به سمت خروجی مطلوب همگرا شود و مقدار خطا کاهش یابد (Jorabiyani et al., 2006).

4- Classification

5- Clustering

6- Decision tree

7- Support Vector Machine

8- Artificial Neural Network

9- Bayesian Network

10- KNN

11- Fuzzy technique

1- Co-Occurrence Matrix

2- Spatial position

3- Offset parameter



جدول ۱- ویژگی‌های بافت از ماتریس هم‌وقوعی

Table 1. Features extracted co-occurrence matrix

Equation	Co-occurrence matrix	Mathematical equation
6	Contrast	$\sum_{i,j}  i - j ^2 \cdot p(i, j)$
7	Energy	$\sum_{i,j} (p(i, j))^2$
8	Homogeneity	$\sum_{i,j} \frac{p(i, j)}{1 +  i - j }$
9	Entropy	$-\sum_i \sum_j P_d(i, j) \log P_d(i, j)$

استفاده گردید. مقادیر تخمین زده شده توسط شبکه با مقادیر واقعی مورد اندازه‌گیری و مقایسه قرار گرفت و پس از مشخص شدن مقدار خطا، آموزش شبکه تا جایی ادامه پیدا کرد تا میزان خطا کمتر از خطای مورد نظر برای آموزش شبکه شود. در آموزش شبکه از الگوریتم‌های `trainscg` و `traingdm`، `trainlm` و `traingd` استفاده شد و در ایجاد هر مدل، الگوریتم آموزشی ثابت در نظر گرفته شده است.

دقت شبکه بستگی زیادی به داده‌های انتخاب شده برای آموزش آن دارد که بایستی همگن و دارای توزیع نرمال باشد بنابراین پس از کامل شدن فرآیند آموزش، تمامی وزن‌های شبکه مشخص گشته و اتصال بین نرون‌ها ثابت شد. در این حالت مدل شبکه عصبی توانایی تخمین داده خروجی بر اساس اطلاعات ورودی به شبکه با دقت مناسب را داشت. تعیین تعداد لایه‌ها و این که در هر لایه چند نرون در شبکه عصبی قرار می‌گیرد مسئله‌ای پیچیده است که معمولاً با روش سعی و خطا و انجام آزمایش‌های مختلف طراحی می‌شود. شایان ذکر است به منظور یکسان نمودن ارزش داده‌ها، قبل از آموزش شبکه عصبی می‌بایست تمامی داده‌ها نرمال‌سازی شوند که از رابطه ۱۰ برای نرمالیزه کردن داده‌ها استفاده شد:

رابطه (۱۰)

$$X_{\text{norm}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}}$$

$X$  مقدار واقعی متغیر،  $X_{\text{min}}$  مقدار کمینه در

در این پژوهش برای تقویت عملکرد شبکه‌های عصبی، تمرکز بر روی افزایش تعداد داده‌های لازم برای آموزش شبکه‌های عصبی بود چرا که استفاده از داده‌های مختلف در هنگام آموزش شبکه باعث می‌شود شبکه محدوده وسیعی از داده‌ها را تجربه کرده و در نتیجه اتحاد در عملکرد شبکه افزایش یابد. به منظور تشخیص و طبقه‌بندی نواحی آلوده سطح برگ از ۹ ویژگی مؤلفه رنگی در سه مدل فضای `RGB`، `L*a*b*` و `HSV` و ۴ ویژگی خواص بافت (تضاد، انرژی، آنتروپی و همگنی) به عنوان ورودی شبکه استفاده شده است. خروجی شبکه شامل سه قسمت است (که شامل: ۱) برگ سالم، ۲) برگ آلوده به بیماری قارچی سفیدک پودری و ۳) آنتراکنوز می‌باشد.

در ساختار شبکه مذکور با تعیین تعداد داده‌های ورودی و استفاده از روش آزمون و خطا، شبکه عصبی پرسپترون با یک لایه مخفی عملکرد بسیار بالایی داشت. تابع انتقال لایه مخفی این شبکه از نوع سیگموئید و تابع لایه خروجی آن از نوع خطی می‌باشد. باید به این نکته توجه داشت تعداد نرون‌های بیشتر در لایه مخفی ممکن است شبکه را دچار بیش‌برازش<sup>۱</sup> کرده و شبکه قابلیت تعمیم خود را از دست دهد. به همین منظور پس از آموزش شبکه، میزان خطا بر روی مجموعه آموزشی باید به حداقل مقدار خود برسد. لذا از شاخص آماری خطای میانگین مربعات ( $MSE$ )<sup>۲</sup> برای انتخاب بهترین ساختار

1- Over fitting

2- Mean Squarer Error

به بررسی توزیع شدت سطوح خاکستری سه مؤلفه رنگی  $R$ ،  $G$  و  $B$  پرداخته شد که مشخص شد میزان شدت توزیع سطح خاکستری مؤلفه رنگی سبز ( $G$ ) دارای بهترین مؤلفه برای بخش‌بندی نواحی آلوده سطح برگ بود (شکل ۹).

ولی از آنجایی که محدوده رنگی نواحی آلوده سطح برگ و سالم در برخی قسمت‌ها با یکدیگر همپوشانی داشتند (یعنی در یک محدوده فراوانی رنگی می‌باشند)، باعث شد به اشتباه قسمت‌های سالم سطح برگ به عنوان بیماری شناسایی و طبقه‌بندی شود که این عامل می‌تواند در کم کردن میزان دقت طبقه‌بندی نواحی آلوده سطح برگ تأثیر بسزایی داشته باشد؛ به همین منظور برای استخراج ویژگی نواحی آلوده سطح بیمار برگ، لازم بود تا ابتدا مناسبترین فضای رنگی انتخاب گردد لذا تصاویر تصحیل شده علاوه بر فضای رنگی  $RGB$  در دو فضای رنگی  $L^*a^*b^*$  و  $HSV$  نیز مورد بررسی قرار گرفتند.

داده‌های ورودی، مقدار بیشینه در داده‌های ورودی و  $X_{norm}$  مقدار بیشینه نرمال می‌باشد.


## نتایج و بحث

### نتایج استخراج برگ از پس‌زمینه


با نمونه‌برداری از سطح برگ‌های خیار این نتیجه حاصل شد که هیستوگرام شدت سطوح خاکستری هر سه مؤلفه  $R$ ،  $G$  و  $B$  با توجه به یکنواخت بودن میزان سطح روشنایی محیط تقریباً در یک محدوده ۱۳۰ تا ۱۸۰ قرار داشت (شکل ۸)، لذا برای تعیین بهترین مؤلفه رنگی با توجه به ثابت بودن رنگ پس‌زمینه، استفاده از حد آستانه در مقایسه با سایر روش‌ها دارای نتایج مطلوب‌تری بود که برای تعیین این مهم از آزمون سعی و خطا استفاده شد.

### نتایج بخش‌بندی نواحی آلوده سطح برگ

در ابتدا به منظور بخش‌بندی نواحی آلوده سطح برگ



شکل ۸- هیستوگرام مربوط به مؤلفه‌های رنگی تصویر خاکستری: الف: مؤلفه  $R$ ، ب: مؤلفه  $G$ ، ج: مؤلفه  $B$   
Figure 8. Histogram of gray image color components: A: R component, B: G component, C: B component



شکل ۹- پروفیل شدت مقادیر سطوح خاکستری مربوط به آرایه‌های قرمز، سبز و آبی برگ خیار  
Figure 9. The profiles of intensity gray arrays of red, green and blue cucumber leaf

آموزش، اعتبار سنجی و ارزیابی مدل در نظر گرفته شدند. به منظور آموزش شبکه از میانگین مؤلفه‌های رنگی و خواص بافت به عنوان ورودی شبکه استفاده گردید، خروجی شبکه شامل عدد ۱ (برگ سالم)، عدد ۲ (سفیدک پودری) و عدد ۳ (آنتراکنوز) بود.


تابع آموزشی مورد استفاده لوبنرگ مارکوات (LM) بود که به عنوان مطلوبترین الگوریتم آموزشی انتخاب شد. برای انتخاب بهترین ساختار شبکه از شاخص آماری خطای میانگین مربعات (MSE) استفاده گردید که بر این اساس مقدار MSE برای شبکه‌ای با یک لایه مخفی و ۴ نرون در این لایه (توپولوژی ۳-۴-۱۳) به دست آمد که در بین سایر ساختارهای شبکه عصبی بهینه‌تر بود (شکل ۱۰).

در ادامه ماتریس اغتشاش حاصل از مدل شبکه عصبی تک لایه آورده شده است که با ساختار ۳-۴-۱۳ در طی ۲۰ بار اجرای آن به دست آمده است (جدول ۲). پس از تشکیل ماتریس اغتشاش مقادیر دقت مربوط به هر یک از کلاس‌های بیماری برگ خیار محاسبه گردید، همان‌طور که مشاهده می‌شود کمترین عملکرد مربوط به بیماری قارچی سفیدک پودری بود.

لازم به ذکر است که هر کدام از این فضاها رنگی از نظر ویژگی رنگی متفاوت بوده و هر یک به طریقی بر روی بخش‌بندی نواحی آلوده سطح برگ مؤثر بودند به همین منظور با استفاده از آنالیز حساسیت مناسبترین ویژگی رنگی که شامل ۹ مؤلفه رنگی (S, H, b\*, a\*, L\*, B, G, R) و V بود، برای طبقه‌بندی نواحی آلوده سطح برگ انتخاب شد. همچنین علاوه بر بررسی مؤلفه‌های رنگی برای تشخیص و طبقه‌بندی نواحی آلوده سطح برگ از خصوصیات مربوط به خواص بافت (تضاد، انرژی، همگنی و آنتروپی) نیز استفاده شد که کمترین عملکرد مربوط به بیماری سفیدک پودری بود و مقدار دقت آن برابر با ۹۹/۹۵ درصد بود.

### نتایج انتخاب بهترین ساختار شبکه عصبی مصنوعی

در این پژوهش دو فاکتور دقت و زمان برای تشخیص و طبقه‌بندی نواحی آلوده سطح برگ حائز اهمیت بود، لذا شبکه عصبی پرسپترون چند لایه با الگوریتم پس انتشار خطا دارای نتایج بهتری در مقایسه با سایر مدل‌ها بود. برای طراحی مدل شبکه عصبی ۱۵۰ تصویر تصحیل شده به سه بخش داده‌های آموزشی، اعتبارسنجی و ارزیابی تقسیم‌بندی شدند که از کل داده‌ها ۷۰، ۲۰ و ۱۰ درصد به ترتیب برای



شکل ۱۰- نمای شبکه عصبی پرسپترون تک لایه

Figure 10. Single-Layer Perceptron Neural Network

جدول ۲- ماتریس اغتشاش حاصل از شبکه با ساختار ۳-۴-۱۳

Table 2. Confusion matrix of the network structure 3-4-13

Predict	Actual Class			Accuracy
	Healthy	Powdery mildew	Anthracnose	
Healthy	17	0	0	100
Powdery Mildew	1	16	0	99.95
Anthracnose	0	0	17	99.98

### نتیجه گیری

در این پژوهش اقدام به بررسی تصاویر تصحیل شده در سه فضای رنگی RGB، و  $L^*a^*b^*$  و HSV به منظور تعیین نواحی آلوده سطح برگ خیار شد. در مقایسه با یافته‌های محققان پیشین شبکه عصبی مصنوعی به روش پس انتشار خطا با تابع آموزشی لونیرگ مارکوات (LM) با توپولوژی ۳-۴-۱۳، توانست در مدت زمان ۶ ثانیه با دقت عملکرد ۹۹/۹۶ به تشخیص و طبقه‌بندی کلاس‌های مختلف بیماری قارچی خیار پردازد. از آنجایی که فرآیند طراحی و ساخت یک دستگاه به‌ویژه اگر دارای ساز و کارهای الکترومکانیکی (روبو تیکی) و حساس باشد، آنقدر زمان‌بر و هزینه‌بر است که ارضاء تمام پارامترهای مورد نظر محقق در طراحی را ناممکن می‌سازد، لذا در این پژوهش سعی شده تا حد امکان با بررسی مناسب‌ترین الگوریتم‌ها گامی در دستیابی به این

مهم برداشته شود. نظر به نتایج به‌دست آمده از این پژوهش و توجه به عامل سرعت تشخیص و کاهش هزینه‌های اقتصادی، الگوریتم‌های پیشنهادی می‌تواند برای توسعه و ساخت دستگاه تست و آنالیز برگ به‌عنوان تجهیزات گیاهپزشکی مؤثر واقع شود. همچنین با توجه به این که روش پیشنهادی عمومی می‌باشد لذا محدودیتی در مساحت وجود ندارد و می‌توان از الگوریتم پیشنهادی در واحدهای گلخانه در سطوح کوچک و بزرگ استفاده نمود.

### سیاس گزارى

بدین وسیله از حمایت و همکاری‌های معاونت محترم پژوهشی و فناوری دانشگاه آزاد اسلامی واحد تاکستان به‌منظور فراهم نمودن شرایط مناسب برای انجام این پژوهش سپاس‌گزارى می‌کنیم.

### REFERENCES

- Ahmadi, A., Qaderi, R., Sadeghi, R., and Ramezani, H.A. 2011. Diagnosis and management of pests and diseases, greenhouse production (cucumbers, tomatoes, peppers, strawberries, flowers & ornamental plants) with a color atlas. Training and Agricultural Extension Publication, Tehran, Iran. P. 67. (In Farsi).
- Ahmadi, K., Gholizadeh, H., Ebadzadeh, H.M., Hatami, F., Hossein pour, R., Kazemi fard, R., and Abadshah, H. 2015. Statistical Agricultural Jihad, Published by Agriculture Economic aspects Iran Ministry of Agriculture Statistics, In: Department of Planning and Economy, Center for information and Communication Technology, Ministry of Agriculture Jihad, Tehran, Iran. (In Farsi).
- Albashish, D., Braik, M., and Bani-Ahmad, S. 2011. Detection and classification of leaf diseases using k-means based segmentation and neural network-based classification. Journal of Information Technology, 10(2): 267-275
- Bernardes, A., Rogeri, J.R., Oliveira, N., Marranghello, A., Pereira, A., and Tavares, J.S. 2013. Identification of foliar diseases in cotton crop. Topics in Medical Image Processing and Computational Vision, 8: 67-85.
- Bock, C.H., Poole, G.H., Parker, P.E., and Gottwald, T.R. 2010. Plant disease severity estimated visually by digital photography and image analysis and hyperspectral imaging. Critical reviews in Plant Science, 29: 59-107.
- Brosnan, T., and Sun, D.W. 2004. Improving quality inspection of food products by computer vision - a review. Journal of Food Engineering, 61: 3-16.

Camargo, A., and Smith, J. 2009. An image processing based algorithm to automatically identify plant disease visual symptoms. *Journal of Bio-System Engineering*, 102(1): 9-21.

Donis-González, I.R., Guyer, D.E., Leiva-Valenzuela, G.A., and Burns, J. 2013. Assessment of chestnut slice quality using color images. *Journal of Food Engineering*, 115: 407-414.

Gonzalez, R. C., Woods, R.E., and Eddins, S.L. 2009. *Digital image processing using matlab*, 3<sup>rd</sup> Ed. Prentice Hall Publication, New Jersey, USA.

Jayamala K.P., and Kumar, R. 2011. Advances in image processing for detection of plant diseases. *Journal of Advanced Bio Informatics Application and Research*, 2: 135-141.

Jorabiyani, M., Zare, T., and Ostovar, O. 2006. *Neural networks*. Shahid Chamran university of Ahvaz Publication, Ahvaz. (In Farsi).

Mery, D., Pedreschi, F., and Soto, A. 2013. Automated design of a computer vision system for visual food quality evaluation. *Journal of Food and Bioprocess Technology*, 6(8): 2093-2108.

Mollazade, K., Omid, M., Akhlaghian, F., Rezaei Kalaj, Y., Mohtasebi, S.S., and Zude, M. 2013. Analysis of texture-based features for predicting mechanical properties of horticultural products by laser light backscattering imaging. *Journal of Computers and Electronics in Agriculture*, 98: 34-45. (In Farsi with English abstract).

Mundada, R.G., and Gohokar, V.V. 2013. Detection and classification of pests in greenhouse using image processing. *Journal of Electronics and Communication Engineering*, 5(6): 57-63.

Jafar Nejad Qomi, E. 2011. *Digital image processing*. Computer Science Publication, Tehran. (In Farsi).

Nermeen, A., Shahd, E., Rami, A., and Tamimi, H. 2012. Using computer vision for plant disease detection. *Palestine Polytechnic University, Hebron and Palestine*.

Omrani, E., Mohtasebi, S.S., Rafiei, Sh., Hosseinpour, S., and Aghili Nategh, N. 2014. Apple leaf diseases detection using image analysis techniques. *Proceeding of the 8<sup>th</sup> National Congress on Agriculture Machinery Engineering, Mashhad, Iran*. (In Farsi with English abstract).

Paliwal, J., Visen, N.S., Jayas, D.S., and White, N.D.G. 2003. Comparison of a neural network and a non-parametric classifier for grain kernel identification. *Journal of Bio-Systems Engineering*, 85(4): 405-413.

Patil, J., and Kumar, R. 2011. Advances in image processing for detection of plant disease. *Journal of Advanced Bioinformatics Applications and Research*, 2(2): 135-141.

Pydipati, R., Burks, T.F., and Lee, W.S. 2006. Identification of citrus disease using color texture features and discriminant analysis. *Journal of Computers and Electronics in Agriculture*, 52(1-2): 49-59.

Sankaran, S., Mishra, A., Ehsani, R., and Davis, C. 2010. A review of advanced techniques for detecting plant diseases. *Journal of Computer and Electronics in Agriculture*, (72): 1-13.

Tavakoli, N., Hemmat, A., and Nazari, B. 2013. Preventing spread of downy mildew in greenhouse cucumber with machine vision system. Proceeding of National Conference of Passive Defense in Agriculture, Qeshm, Iran. (In Farsi with English abstract).

Teimouri, N., Omid, M., Mollazade, K., and Rajabipour, A. 2014. A novel artificial neural networks assisted segmentation algorithm for discriminating almond nut and shell from background and shadow. Journal of Computers and Electronics in Agriculture, 105: 34-43.

Yao, Q., Guan, Z., Zhou, Y., Tang, J., Hu, Y., and Yang, Y. 2009. Application of support vector machine for detecting rice disease using shape and color texture features. International Conference on Engineering Computation, Washington DC, USA. pp: 79-83.

## **A recognition system to detect powdery mildew and anthracnose fungal disease of cucumber leaf using image processing and artificial neural networks technique**

H. Hosseini<sup>1\*</sup>, D. Mohammad Zamani<sup>2</sup> and A. Arbab<sup>3</sup>

1. **\*Corresponding Author:** Instructor, Institute of Technical and Vocational Higher Education, Agriculture Jihad-Agriculture Research, Education and Extension Organization (AREEO), Tehran, Iran. (hosseini.hadii@yahoo.com)
2. Assistant Professor, Department of Bio System Engineering, Takestan Branch, Islamic Azad University, Takestan, Iran
3. Associate Professors, Department of Plant Protection, Takestan Branch, Islamic Azad University, Takestan, Iran

Received: 5 March 2016

Accepted: 15 July 2017

---

### **Abstract**

Plant disease can cause quality and quantity reduction of agriculture crops. In some countries, farmers spend considerable time to consult with plant pathologists, as time is an important factor to control disease; so it seems necessary to offer a fast, cheap and accurate method to detect plant diseases. Since the fungal diseases named 'Powdery Mildew' and 'Anthracnose' cause the greatest amount of damage in cucumber produced in greenhouses, thus in this research the two mentioned fungal diseases detection and classification were studied using image processing and neural networks techniques. Image processing include four main steps: 1) Image acquisition 2) preprocessing 3) extraction of the best color parameters of HSV and L\* a\* b\* color spaces in order to classify and extract defected areas of the leaf and 4) extraction of textural properties of defected areas of cucumber leaf using co-occurrence matrix. Since, two factors of accuracy and time are important in detection and classification of plant disease, thus artificial neural networks (ANN) with back propagation algorithm (BP) and Levenberg-Marquardt (LM) training function were selected as the best model that was able to successfully detect and classify the mentioned plant diseases in 6 seconds with 99.96% accuracy.

**Keywords:** *Powdery mildew, Anthracnose, Feature extraction, Artificial neural network, Co-occurrence matrix*