

مقاله علمی-پژوهشی

امکان‌سنجی تشخیص برخط بیماری آتشک در گیاه لیلیوم به کمک سامانه ماشین بینایی و

خوشه‌بندی K-means

حدیث بی‌آبی^۱، سامان آبدانان مهدی‌زاده^{۲*}، محمدرضا صالحی سلمی^۳

تاریخ دریافت: ۱۳۹۷/۰۹/۲۱

تاریخ پذیرش: ۱۳۹۸/۰۳/۲۹

چکیده

تشخیص خودکار و به‌موقع بیماری‌های گیاهی، یک موضوع اساسی در نظارت و تولید محصولات سالم و باکیفیت است. لذا طراحی و توسعه روشی سریع، خودکار، ارزان و دقیق به‌منظور تشخیص بیماری گیاهان در مراحل اولیه از اهمیت به‌سزایی برخوردار است. در این پژوهش تصاویر از ۴۰ لیلیوم آلوده به بیماری آتشک و ۴۰ گیاه سالم توسط دوربین دیجیتال اخذ و پس از تقسیم‌بندی تصاویر تعداد ۹ ویژگی رنگی از سه کانال RGB، Lab و HSV از ساقه و برگ گیاه و همچنین یک ویژگی مورفولوژیکی (طول ساقه) از گیاه استخراج شد. با اعمال الگوریتم پرچین‌های زبانی طی ۱۰۰ هزار تکرار موثرترین این ویژگی‌ها (L برگ، L ساقه، a برگ، b برگ، H برگ، b ساقه، H ساقه، V برگ و طول ساقه) انتخاب و به‌وسیله خوشه‌بند K-means گروه‌بندی شدند. در نهایت نشان داده شد که دقت خوشه‌بند برای دو گونه بیمار، سالم و دقت کلی به‌ترتیب برابر با ۹۶/۴۲ و ۱۰۰ و ۹۷/۶۳ درصد به‌دست آمد.

واژه‌های کلیدی: الگوریتم پرچین‌های زبانی، پردازش تصویر، تشخیص بیماری گیاه، سلامت گیاه لیلیوم

مقدمه

قابل توجهی شود که میزان گسترش بیماری به شرایط فعلی محصول و حساسیت به عفونت بستگی دارد (Lucas et al., 1992). شناسایی علائم اولیه بیماری‌ها یکی از مهم‌ترین مسائل مورد بررسی محققین می‌باشد که روش‌های متعددی بدین منظور توسعه یافته است. از بین گونه‌های زینتی، گل لیلیوم یکی از زیباترین گل‌هایی است که امروزه طرفداران بی‌شماری را به خود اختصاص داده است و برای درمان بسیاری از بیماری‌ها و اختلالات از قبیل تنظیم ضربان قلب، درمان سوختگی، پاک‌کننده موثر خون و غیره شناخته شده است (Brosnan and Sun, 2003). این گیاه زینتی بسیار به بیماری حساس است و برخی از این بیماری‌ها سبب ایجاد اختلالات فیزیولوژیکی در آن می‌شود که بر تولید و کیفیت این گیاه در سراسر جهان تأثیر می‌گذارد. از جمله این بیماری‌ها می‌توان به بیماری آتشک اشاره کرد. این بیماری معمولاً روی گل‌ها ظاهر می‌شود به طوری که در ابتدا حالت آب سوخته پیدا می‌کنند و کمی بعد پژمرده و قهوه‌ای رنگ می‌شوند. سپس علائم بیماری در اطراف جام گل، روی برگ‌ها و نوک شاخه‌های جوان ظاهر می‌شود. با توسعه بیماری، شاخه‌های بیمار به سرعت پژمرده و به دلیل سوختگی و خمیدگی بیش از حد قسمت‌های انتهایی شاخه حالتی شبیه به عصا پیدا می‌کند. اما علت انتخاب بیماری فوق خسارت‌های هنگفت اقتصادی آن در سطح جهان و ایران است. سابقه بیماری آتشک در ایران به حدود ۱۴ سال می‌رسد. در حال حاضر ۱۲ استان مهم کشور به این بیماری آلوده است و سطح آلودگی‌های فعلی بالغ بر ۲۰۰۰۰ هکتار می‌باشد (Zeller, 2004).

امروزه هدف اصلی تحقیقات در زمینه کشاورزی، افزایش بهره‌وری و کیفیت همراه با کاهش هزینه‌ها است. یکی از اجزای حیاتی در طول روند رشد محصول، تشخیص دقیق بیماری‌های گیاهی و به‌کارگیری یک راه‌حل مناسب و به‌موقع در مواجهه با آن‌ها است. بیماری‌های گیاهی به‌تدریج به یک معضل بزرگ تبدیل شده‌اند، زیرا می‌توانند سبب کاهش معنی‌داری در کیفیت و کمیت محصولات کشاورزی شوند (Arivazhagan, 2013). به‌عبارت دیگر وجود بیماری، از عوامل محدودکننده رشد و باروری در گیاهان به‌شمار می‌رود. هنگامی که گیاهان بیمار می‌شوند، طیف وسیعی از علائم مانند نقاط یا رگه‌های رنگی در برگ‌ها، ساقه‌ها و دانه‌های گیاه را نشان می‌دهند. این علائم بصری هنگامی که بیماری پیشرفت می‌کند به‌طور مداوم رنگ، شکل و اندازه خود را تغییر می‌دهند؛ اگر شناسایی و کنترل در زمان مناسب صورت نپذیرد، می‌تواند منجر به زیان

۱- دانشجوی کارشناسی ارشد، گروه مکانیک بیوسیستم، دانشکده مهندسی زراعی و عمران روستایی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان

۲- استادیار، گروه مکانیک بیوسیستم، دانشکده مهندسی زراعی و عمران روستایی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان

۳- استادیار، گروه باغبانی، دانشکده کشاورزی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان

(Email: s.abdanan@asnrukh.ac.ir)

*- نویسنده مسئول:

DOI: 10.22067/jam.v11i2.77237

SVM نتایج بهتری را از شبکه عصبی برای طبقه‌بندی بیماری فراهم می‌کند. در پژوهشی دیگر پیمان و همکاران (۲۰۱۶) از تکنیک پردازش تصویر به منظور تشخیص دو بیماری مهم برنج (لکه قهوه‌ای و بلاست برگ برنج) استفاده کردند. در این مطالعه از پردازش رنگی به منظور جداسازی لکه‌های ظاهری قسمت‌های آلوده از سطح برگ استفاده شد. دقت الگوریتم پیشنهاد شده در تشخیص نقاط آلوده ۹۴/۴٪ به دست آمد. تشخیص بین دو نوع بیماری به دلیل شباهت‌های رنگی علائم بیماری‌ها تقریباً غیر ممکن بود. بنابراین به منظور بهبود آن، خصوصیات شکلی (ویژگی‌های بدون بعد مانند گردی، نسبت ظاهری، فشردگی و نسبت سطح قسمت‌های آلوده) از تصاویر سیاه و سفید برگ‌های آلوده استخراج شده و مورد بررسی قرار گرفتند. دقتی معادل با ۹۶/۶٪ برای الگوریتم به دست آمد که نشان‌دهنده توانایی در تشخیص دو بیماری لکه قهوه‌ای و بلاست برگ برنج بود (Payman et al., 2016).

از جمله روش‌های متداول در جلوگیری از بیماری‌های متداول در گیاهان سمپاشی در مواقع خاص و در مراحل مشخص از رشد گیاه می‌باشد. اما این روش سبب مصرف بی‌رویه سموم مختلف، اعمال هزینه‌های بالا به کشاورزان و تولیدکنندگان و همچنین سبب آلودگی محیط‌زیست نیز می‌شود (Rouzegar and Golzarian, 2015). همچنین عدم کنترل بیماری‌های گیاهی سبب بروز آسیب‌های جدی در گیاهان شده و نهایتاً منجر به مرگ و قحطی در مقیاس بزرگ مزارع خواهد شد. از این رو طراحی سامانه‌ای به منظور تشخیص زود هنگام بیماری‌ها و مقابله سریع و جلوگیری از گسترش آن به صورت هوشمند نه تنها سبب کاهش هزینه‌ها شده بلکه آلودگی‌های زیست‌محیطی را نیز کاهش می‌دهد. با توجه به پژوهش‌های پیشین و بررسی‌های صورت گرفته سامانه‌های موجود به صورت پیوسته بیماری را در گیاه تشخیص نمی‌دهند و همچنین تاکنون تحقیقی روی بیماری آتشک گیاه لیلیوم که به صورت گسترده باعث آسیب در بخش کشاورزی شده، صورت نگرفته است. بدین منظور هدف از این پژوهش طراحی و ساخت یک سامانه کنترل هوشمند نظر گرفته شد که به صورت خودکار سلامت گیاه لیلیوم را تشخیص داده و در راستای بهبود وضعیت گیاه اقدام نماید.

مواد و روش‌ها

جمع‌آوری نمونه‌ها

در این مطالعه تعداد ۴۰ گلدان چهار کیلویی برای گیاهان بیمار و همچنین ۴۰ گلدان چهار کیلویی برای گیاهان سالم به منظور بررسی آن‌ها در مرحله رویشی در نظر گرفته شد. پیازچه‌های این نمونه‌ها در گلدان‌هایی با شرایط خاک حاوی مخلوط ۱:۱ خاک بکر و کوکوپیت رشد داده شد. قطر گلدان‌ها ۲۰ سانتی‌متر و دارای ارتفاع ۳۰ سانتی‌متر بود. آزمایش در گلخانه‌ای با دمای ۱۵/۲۷ درجه سلسیوس

از جمله روش‌های متداول در تشخیص بیماری گیاهان استفاده از روش بصری است؛ اما این روش کار دشواری برای بررسی عملکرد تعدادی از پارامترها مانند اثر محیط، مواد مغذی، ارگانسم و غیره بوده و در عین حال دقت مناسبی در تکرارهای بسیار با توجه به خستگی فرد خیره ندارد. در صورتی که تشخیص بیماری‌های گیاهی از طریق برخی از روش‌های خودکار و هوشمند با توجه به حجم زیاد کار نظارت در مزارع بزرگ بسیار سود می‌باشد. از جمله روش‌های جایگزین در تشخیص بیماری‌ها می‌توان به روش‌های مبتنی بر تکنیک پردازش تصویر اشاره نمود؛ در این روش از علائمی که در برگ‌های گیاه ظاهر می‌شود در مراحل اولیه بیماری‌ها جهت تشخیص استفاده می‌گردد. لازم به ذکر است که این روش از دقت بالایی در تشخیص و همچنین شناسایی نوع بیماری برخوردار است (Arivazhagan et al., 2013). روش پردازش تصویر می‌تواند دسترسی به اطلاعات اولیه در مورد سلامت محصول و کنترل بیماری را از طریق استراتژی‌های مدیریتی مناسب مانند استفاده از آفت‌کش‌ها و قارچ‌کش‌ها تسهیل سازد.

با توجه به پیشرفت‌های اخیر در حوزه‌ی پردازش تصویر و شناخت ساختار تکنیک‌ها، می‌توان یک سیستم مستقل برای طبقه‌بندی بیماری محصولات ایجاد کرد. پژوهش‌های زیادی جهت تشخیص خودکار بیماری در محصولات مختلف انجام شده است (Barbedo et al., 2016; Gonzalez et al., 2006; Mansingh et al., 2007). در همین راستا آریواژگان و همکاران (۲۰۱۳) طرحی را به منظور کاربرد آنالیز بافت در تشخیص و طبقه‌بندی بیماری‌های برگ بر روی حدود ۵۰۰ برگ از ۳۰ گونه گیاهان مختلف بومی تامیل نادو^۱ مانند موز، لوبیا، لیمو، انبه، سیب‌زمینی، گوجه‌فرنگی و غیره ارائه دادند (Arivazhagan, 2013). در مرحله طبقه‌بندی از روش حداقل معیار فاصله و روش ماشین بردار پشتیبان (SVM) استفاده شد. دقت تشخیص با استفاده از روش حداقل معیار فاصله ۸۶/۷۷٪ و برای ماشین بردار پشتیبان ۹۴/۷۴٪ گزارش شد. در مطالعه دیگر عمرانی^۲ (۲۰۱۴)، برای شناسایی سه بیماری مختلف در برگ سبب (Alternaria)، لکه سیاه بر روی سبب و آفت miner بر روی برگ سبب) از تکنیک پردازش تصویر استفاده نمودند (Omriani, 2014). در این پژوهش سه روش محاسباتی طبقه‌بندی نرم^۳، شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) برای بیماری ارائه شدند. پس از نمونه‌برداری، برگ‌های آلوده به آزمایشگاه منتقل و سپس تصاویر برگ تحت شرایط کنترل شده اخذ شدند. در ادامه، خوشه‌بندی به وسیله k-means برای شناسایی مناطق آلوده انجام پذیرفت. نهایتاً با توجه به نتایج به دست آمده نشان داده شد که روش

1- Tamil Nadu

2- Omriani


3- Soft-computing

طراحی و ساخت سامانه تشخیص بیماری
در این پژوهش سامانه ماشین بینایی شامل یک دوربین دیجیتال (لاجیتک، مدل C930e)، دو عدد پروژکتور LED ۵۰ وات برای نورپردازی، یک سکوی متحرک عکس‌برداری به شعاع ۱۲۰ سانتی‌متر، استپر موتور ۱/۶۵ آمپر (مدل 42BYGH403، کشور چین)، درایور استپر موتور (مدل DRV8825، کشور چین)، موتور گیربکس ۱۲DC ولت ۱۰ RPM (ZHENG، مدل ZGX50R، چین)، پمپ آب (۱۲ ولت ۳/۶ وات، مدل TOL، چین)، سنسور تشخیص سطح محلول سم (YWROBOT، مدل V2) و شیر برقی مورد نظر (۱۲ ولت، مدل E247، چین)، مخزنی با ظرفیت ۱ لیتر و یک لپ‌تاپ بود. بر روی محور دوار ۸ نقطه توقف (محل قرارگیری گلدان‌ها) قرار داده شد که برای تشخیص این موقعیت‌ها از سنسور اثر هال (مدل UGN3144، چین) استفاده شد. قسمت‌های مختلف این سامانه هوشمند و نحوه ارتباط میان آن‌ها در شکل ۱ نشان داده شده است.

روزانه/شبانه و رطوبت نسبی ۷۰-۷۵ درصد انجام پذیرفت. نمونه‌های آزمایش ۴۰ گیاه شاهد (عاری از بیماری) و ۴۰ گیاه آلوده به بیماری آتشک بود. همچنین به منظور ایجاد تباین بالاتر پوشش دور سامانه محفظه عکس‌برداری سفید در نظر گرفته شد.

روش اعمال بیماری

پس از رسیدن گیاه به مرحله ۸ برگی، با بهره‌گیری از روش جمال زواره و همکاران (۲۰۰۴) تلقیح در آن‌ها صورت پذیرفت (Jamalizavareh et al., 2003). بدین ترتیب که از گیاهان لیلیوم آلوده به بیماری فوزاریوم، برگ‌هایی که به تازگی آلوده شده و حامل اسپورهای جوان قارچ بیمارگر بودند، جدا گردید. قطعاتی از این برگ‌ها درون آب مقطر حاوی توئین ۲۰ غوطه‌ور شدند و سپس با استفاده از لام گلوبول شمار تعداد اسپور در واحد حجم سوسپانسیون و روی $10^4 \times$ اسپور در میلی‌لیتر تنظیم شد. در مرحله آخر، با استفاده از یک افشانه دستی، سوسپانسیون در حدی که برگ‌ها کاملاً خیس شوند روی برگ‌های مورد نظر پاشیده شد. گیاهان تلقیح شده به مدت ۲۴ ساعت در شرایط تاریکی و رطوبت بالا نگهداری و سپس به شرایط عادی گلخانه برگردانده شدند.



شکل ۱- شماتیک سامانه بینایی ماشین

Fig.1. Schematic of the machine vision system

از نمونه اخذ می‌شد و در صورتی که نمونه نیاز به سمپاشی یا قارچ‌کشی داشت به محل نازل منتقل و با توجه به محل بیماری نازل توسط استپر موتور در موقعیت مناسب قرار می‌گرفت و سمپاشی صورت می‌پذیرفت. به علاوه تعداد ۲ عدد کلید محدودکننده حرکت نیز در سامانه تعبیه شد تا حرکت نازل در پایین‌ترین و بالاترین موقعیت محدود گردد. در صورتی که مخزن سم نیز به ۱۰٪ مقدار خود

نحوه عملکرد سامانه به این صورت می‌باشد که به دلیل حساس بودن سنسور اثر هال به میدان مغناطیسی به محض قرارگیری مقابل آهنربا فعال می‌شود. برای این منظور از یک آهنربا به عنوان شاخص بر روی صفحه دیوار استفاده شد که به محض چرخش صفحه و عبور آهنربا از روی سنسور، خروجی آن فعال و برد کنترلر موقعیت صفحه را نمایش می‌دهد. بعد از قرار گرفتن گلدان در موقعیت مناسب تصویر

پیش‌پردازش از قبیل: یکنواخت‌سازی هیستوگرام تصویر و حذف نویزهای موجود در تصویر با استفاده از فیلتر میانه بدون آسیب زدن به جزئیات لبه‌ها روی هر یک از کانال‌های رنگی (R، G و B) صورت پذیرفت. سپس با آستانه‌گذاری اتسو ساقه گیاه از پس‌زمینه جدا شد. به دلیل تشابه رنگی بین ساقه و برگ‌ها، قسمت‌هایی از برگ‌ها در تصویر باقی ماندند که برای حل این مشکل از عملگر فرسایش استفاده شد. پس از جداسازی برگ‌ها از ساقه با فیلترگذاری روی مساحت (۳۲۰ پیکسل مربع) برگ‌ها از تصویر حذف شدند. بعد از حذف برگ‌ها، تصویر محدب ساقه محاسبه و اسکلت تصویر استخراج شد. علاوه بر این قسمت‌هایی از اسکلت ساقه به اشتباه حذف شدند که می‌بایست این نواحی در تصویر بازسازی شوند. به این منظور از عملگر اتساع برای بازسازی این نواحی استفاده شد. در نهایت با ضرب نمودن اسکلت در تصویر اصلی، تصویر ۳ کاناله آن استخراج و همچنین با کم کردن ساقه از تصویر اصلی برگ‌ها نیز از ساقه جدا شدند. شکل ۲ فلورچارت جداسازی ساقه و برگ از پس‌زمینه را نشان می‌دهد. شایان ذکر می‌باشد که برای به‌کارگیری عملگر اتساع و فرسایش از ماتریس همسایگی ۳×۳ استفاده شد.

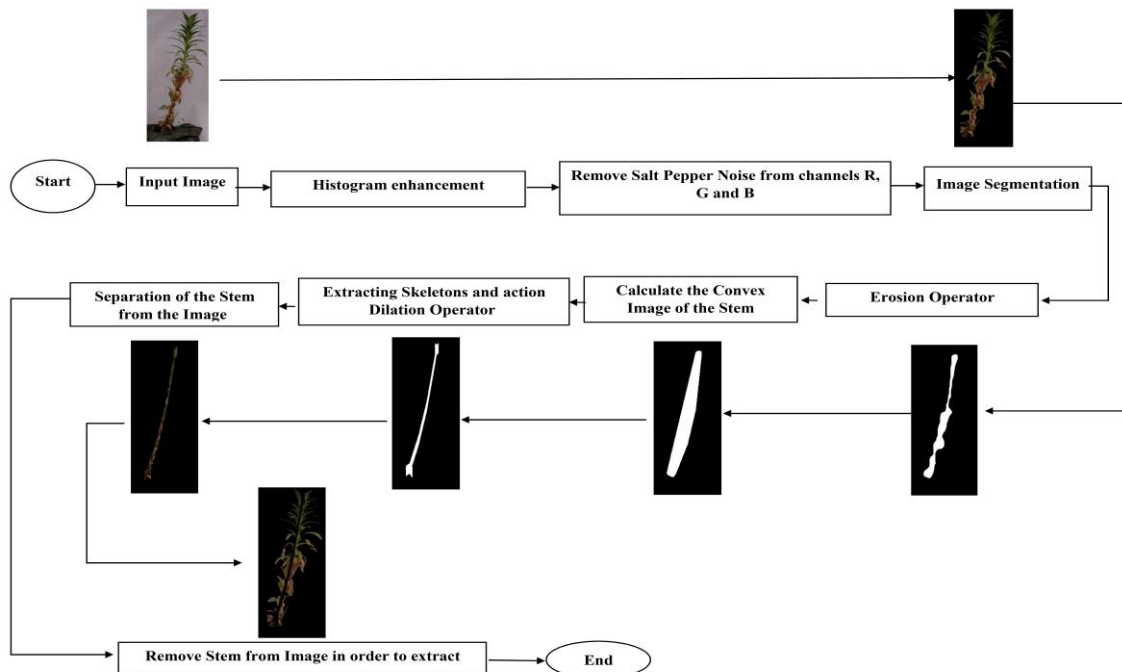
می‌رسید یک پیام بر روی صفحه نمایش برای هشدار به کاربر ارسال می‌شد و در حالتی که مخزن خالی بود سامانه عمل نمی‌کرد تا مخزن مجدد پر شود.

سامانه اخذ و تحلیل تصاویر

در این پژوهش دوربین در فاصله ثابت ۵۰ سانتی‌متری از گل در ارتفاع ۶۰ سانتی‌متری از سطح زمین به گونه‌ای قرار داشت که گیاه به‌طور کامل برای ارزیابی ساقه و برگ‌های متصل به آن در مقابل دید دوربین قرار داشت. تصاویر تحت شرایط نور ثابت در فضای گلخانه در ساعتی مشخصی از روز (۱۰ تا ۱۲) طی مدت آزمایش‌ها پس از ۱۰ روز از گذشت تلقیح بیماری به‌صورت یک روز در میان در مدت یک ماه گرفته شدند. تصاویر اخذ شده در فضای رنگی RGB و با قدرت تفکیک ۱۰۲۴×۸۴۰ اخذ شدند و در ادامه پس از انتقال تصاویر به رایانه، با استفاده از نرم‌افزار MatLab 2016a پردازش تصویر انجام گرفت که شرح آن در ذیل آمده است.

پیش‌پردازش و پردازش تصویر

هدف کلی این مرحله ارتقای تصویر و حذف مولفه‌های غیر ضروری از تصویر است. بدین منظور ابتدا بر روی تصاویر عملیات



شکل ۲- فلورچارت جداسازی ساقه و برگ از پس‌زمینه

Fig.2. Flowchart of stem and leaf segmentation from the background

برگ گیاهان مورد استفاده قرار گرفت. لازم به ذکر است که ویژگی‌های به‌دست آمده این بخش از مطالعه به‌منظور آموزش خوشه‌بند مورد استفاده قرار گرفتند.

فضاهای رنگی مورد آزمایش

در این پژوهش پس از جداسازی تصویر گیاه به بررسی ۹ کانال رنگی (R، G، B، L، a، b، H، S و V) از سه فضای رنگی (RGB، Lab و HSV) و طول ساقه به‌منظور تشخیص بیماری آتشک در

۵. برای هر یک از مقادیر i ($i=1, \dots, k$) ویژگی z ام در حالتی یافته شد که بیشترین مقدار p به ازای مقادیر کلاس i ام حاصل شد؛ در این صورت ویژگی z ام جزء مجموعه ویژگی‌های منحصر به فرد قرار می‌گرفت.

۶. ویژگی‌های L و K که دارای بزرگترین مقدار p هستند به‌عنوان ویژگی‌های رایج تمیزدهنده انتخاب شدند.

۷. با توجه به ویژگی‌های تمییز دهنده انتخاب شده (L)، مجموعه آموزشی جدید (X_{new}) تشکیل و آزمون خوشه‌بند از طریق ویژگی‌های انتخاب شده‌ی حاصل از داده‌های اصلی صورت گرفت.

لازم به ذکر است که در هر بخش از انتخاب ویژگی خوشه‌بند K -means با استفاده از پرچین‌های زبانی به‌کار برده می‌شود. به همین دلیل، وضعیت‌های مختلفی نظیر محدودیت‌هایی مربوط به پرچین‌های زبانی، تعداد قوانین و مقادیر اولیه برای طراحی این نوع از الگوریتم خوشه‌بند وجود دارد که شرح آن در ذیل آمده است.

به‌منظور ارزیابی خوشه‌بند از چهار شاخص آماری حساسیت (TPR)، تشخیص (SPC)، صحت (PPV) و دقت (ACC) استفاده شد (رابطه ۲، ۳، ۴ و ۵).

$$PPV(\%) = \frac{TP}{TP + FP} \times 100 \quad (2)$$

$$TPR(\%) = \frac{TP}{TP + FN} \times 100 \quad (3)$$

$$SPC(\%) = \frac{TN}{TN + FP} \times 100 \quad (4)$$

$$ACC(\%) = \frac{TP + TN}{TP + FP + FN + TN} \times 100 \quad (5)$$

خوشه‌بندی با استفاده از روش K-means

روش K-means روشی بر مبنای یادگیری بی‌نظارت می‌باشد به این صورت که ابتدا تعدادی نقطه به دلخواه به‌عنوان مرکز خوشه در نظر گرفته می‌شود. سپس با بررسی داده‌ها، داده‌هایی که به مرکز خوشه نزدیک‌ترین هستند به آن نسبت داده می‌شوند. در آخر با گرفتن میانگین در هر خوشه می‌توان مراکز خوشه و به دنبال آن خوشه‌های جدید ایجاد شود. بنابراین در این پژوهش پس از بهبود تصویر و استخراج ویژگی از خوشه‌بندی K-means (Cao et al., 2012) در تقسیم‌بندی N مشاهده از k خوشه‌بندی مشخص شده توسط کاربر استفاده شد. در این روش، هر ویژگی به یک خوشه که به بردار میانگین نزدیک‌تر است اختصاص داده می‌شود. این روش تا زمانی که تغییر قابل توجهی در محل بردار میانگین بین تکرارهای پی در پی از الگوریتم وجود نداشته باشد، ادامه می‌یابد (Kanungo et al., 2002). در این مطالعه، دو خوشه تعریف شد، یکی برای گیاه بیمار و دیگری برای گیاه سالم. الگوریتم خوشه‌بندی در رابطه (۶) تعریف شده است:

الگوریتم انتخاب ویژگی با استفاده از پرچین‌های زبانی^۱

به‌منظور انتخاب بهترین ویژگی از روش پیشنهاد شده توسط سیتسلی (۲۰۱۰) استفاده شد (Cetisli, 2010). در ابتدای این الگوریتم، تنها یک قاعده طبقه‌بندی فازی برای هر گروه وجود دارد. هنگامی که تعداد قاعده‌ها از تعداد گروه‌ها بیشتر باشد، مقادیر پرچین‌های زبانی برای انتخاب ویژگی‌ها کافی نخواهد بود. به‌علاوه، این مقادیر (مقادیر پرچین‌ها) به مقادیر باینری ساده‌سازی می‌شوند.

در این الگوریتم دو روند متفاوت وجود دارد: ۱) انتخاب ویژگی و ۲) حذف ویژگی. به منظور حذف ویژگی، باید مقادیر پرچین‌های زبانی هر ویژگی در هر گروه کوچکتر از 0.5 باشد و همچنین باید نزدیک به صفر مقداردهی شوند. برای انتخاب ویژگی نیز دو شاخص مورد نظر است: الف) در هر یک از گروه‌ها ویژگی‌هایی انتخاب می‌شوند که بیشترین مقدار پرچین را دارند، ب) ویژگی‌های انتخاب شده دارای بزرگترین مقدار پرچین متعلق به یک گروه خاص هستند، زیرا هر ویژگی نمی‌تواند برای همه گروه‌ها انتخاب شود. به همین دلیل، یک تابع انتخابی برای مقادیر پرچین هر ویژگی در نظر گرفته شد (رابطه ۱):

$$p_j = \prod_{i=1}^k p_{ij} \quad (1)$$

در این رابطه، p_j مقدار انتخابی ویژگی z ام را مشخص می‌کند و K تعداد گروه‌ها است.

برای ساده‌سازی مقادیر پرچین زبانی به مقادیر باینری، مقادیر اولیه پرچین‌ها 0.5 در نظر گرفته شدند (Cetisli, 2010). پس از تعیین مقادیر پرچین‌ها، اگر مقدار پرچین هر ویژگی به اندازه ۱ افزایش یابد، این ویژگی از ویژگی‌های انتخابی متعلق به گروه مورد بررسی است و در صورتی که مقدار پرچین هر ویژگی به صفر کاهش یابد، این ویژگی جزو ویژگی‌های پرت گروه محسوب می‌شود. شرح الگوریتم انتخاب ویژگی و طبقه‌بندی با جزئیات بیشتر در ذیل آمده است.

مراحل انتخاب ویژگی

۱. با استفاده از توزیع گاوسی^۲ یک قاعده طبقه‌بندی برای هر گروه توصیف شد.
۲. p_{ij} ، به‌ازای $i=1, 2, \dots, k$ (تعداد گروه‌ها است) و $j=1, 2, \dots, D$ (تعداد ویژگی‌ها است) برابر مقدار 0.5 شد.
۳. تعداد ویژگی‌های انتخاب شده (L) تعیین شد.
۴. خوشه‌بند K-means توسط پرچین‌های زبانی آموزش داده شده و در فرآیند آموزش، محدوده P_{ij} بین ۰ و ۱ قرار داده شد ($0 \leq P_{ij} \leq 1$).

1- linguistic hedges

2- Gaussian

مرکز ثقل برای هر یک از خوشه‌ها با استفاده از رابطه (۸) به دست می‌آید:

$$m_k = \frac{\sum_{k=1}^m 1\{C_{k=j}\} x_k}{\sum_{k=1}^m 1\{C_{k=j}\}} \quad (8)$$


نتایج و بحث

در این پژوهش ابتدا تصاویر اخذ شده از وضعیت گیاه در دو حالت بیمار و سالم، در طول مدت یک ماه از آزمایش مورد پردازش قرار گرفت. سپس تصاویر به دست آمده به منظور بررسی و انتخاب فضاهای رنگی مناسب مورد ارزیابی قرار گرفتند. شکل ۳ علائم ظاهری بیماری آتشک در طول عکس برداری را نشان می‌دهد.

$$W(c) = \sum_{k=1}^k N_k \sum_{c(i)=k} |x_i - m_k|^2 \quad (6)$$

که در آن، m_k بردار میانگین خوشه k ام است. N_k تعداد مشاهدات در مشاهده k ام، بردار x_i به یک و تنها یک خوشه اختصاص داده می‌شود. عدم تشابه بر اساس فاصله اقلیدسی اندازه‌گیری شد. مراحل مختلف روش خوشه‌بندی شامل: (۱) ابتدا k نقطه به عنوان نقاط مراکز خوشه‌ها انتخاب می‌شوند، (۲) هر نمونه داده به خوشه‌ای که مرکز دارای کمترین فاصله تا آن داده را داراست، نسبت داده می‌شود، (۳) پس تعلق تمام داده‌ها به یکی از خوشه‌ها و برای هر خوشه یک نقطه جدید به عنوان مرکز محاسبه می‌شود (میانگین نقاط متعلق به هر خوشه)، (۴) تکرار تا زمانی که برچسب‌های مجموعه تغییر نکند ادامه می‌یابد و در نهایت (۵) خوشه‌بندی با استفاده از رابطه (۷) حاصل شد:

$$C_i = \operatorname{argmin} \left\{ |x_i - m_k|^2 \right\} \quad (7)$$



شکل ۳- علائم ظاهری بیماری آتشک در طول عکس برداری
Fig.3. Signs of Botrytis Elliptica disease during shooting image


به برگ) و طول ساقه نسبت به سایر ویژگی‌ها از بیشترین تعداد وقوع برخوردار بودند. افزایش پارامتر L به سبب افزایش میزان روشنایی برگ‌ها و رنگ پریدگی آن‌ها در طول آزمایش قابل توجه است. در کانال رنگی b با افزایش بیماری میزان تمایل برگ از رنگ آبی به زرد تغییر یافته (یعنی زردتر شدن برگ) است. همچنین پارامتر a با گذشت زمان در طول آزمایش روند نزولی داشته که نشان‌دهنده تمایل گیاه به سمت سبزیگی است اما برای تیمارهای بیمار با کاهش سبزیگی

نتایج انتخاب ویژگی

به منظور انتخاب ویژگی در این پژوهش از روش انتخاب ویژگی پرچین زبانی استفاده شد (شکل ۴). مطابق شکل ۴ پس از پیاده‌سازی الگوریتم پرچین‌های زبانی طی ۱۰۰ هزار تکرار ویژگی‌های L_L (مربوط به برگ)، L ساقه، a_L (مربوط به برگ)، b_L (مربوط به برگ)، H_L (مربوط به برگ)، b ساقه، H ساقه، V_L (مربوط

و بیمار اختلاف معنی‌دار مشاهده شد. همچنین مطابق آنالیز آماری صورت گرفته اثر متقابل روز در بیماری برای تمامی ویژگی‌های انتخاب شده نیز معنی‌دار بود که می‌توان نتیجه گرفت که انتخاب ویژگی به‌درستی صورت گرفته است (جداول ۱ و ۲). پس از انتخاب مناسب‌ترین ویژگی‌ها عمل خوشه‌بندی صورت پذیرفت. نتایج خوشه‌بندی داده‌ها در ماتریس درهم ریختگی آورده شده است (جدول ۴).

انتخاب ویژگی



شکل ۴- نمودار تعداد وقوع ویژگی‌ها با به‌کارگیری الگوریتم پرچین‌های زبانی

Fig.4. Occurrence results obtained from the application of the linguistic hedges algorithm

HSV و Lab معنی‌دار بود. همان‌طور که مشاهده می‌شود اثر روز بر ویژگی مورفولوژی طول ساقه در سطح احتمال ۱٪ و اثر متقابل روز در بیماری در سطح ۵٪ معنی‌دار بود در حالی‌که اثر بیماری معنی‌دار نبود.

نتایج حاصل از بررسی‌ها آنالیز آماری

با توجه به جدول ۱، آنالیز آماری ویژگی‌های رنگی استخراج شده از برگ نشان داد که اثر روز بر تمامی ویژگی‌های رنگی به‌جز L و b اثر بیماری نیز بر تمامی کانال‌های به‌جز R و V معنی‌دار است. همچنین اثر متقابل روز در بیماری برای هر سه فضای رنگی RGB،

جدول ۱- نتایج تجزیه واریانس ویژگی‌های رنگی برگ و مورفولوژی گل لیلیوم

Table 1- Results of variance analysis of leaf color and morphological characteristics

منابع تغییر S. O. V	درجه آزادی df	میانگین مربعات (MS)				
		ویژگی‌های رنگی برگ (Leaf color features)				
		R	G	B	L	A
روز (Day)	14	281.85*	685.33**	199.25**	6.37 ^{ns}	65.27**
بیماری (Disease)	1	544.29 ^{ns}	822.54**	1859.03**	22778.36**	485074.82**
روز×بیماری (Disease×Day)	14	294.49*	159.19*	153.63*	20.97*	131.07**
ویژگی مورفولوژی (Morphological features)						
		b	H	S	V	طول ساقه (Stem length)
روز (Day)	14	20.25 ^{ns}	0.06**	0.03**	0.007**	6934.43**
بیماری (Disease)	1	827960.84**	11.54**	0.02*	0.00005 ^{ns}	35.26 ^{ns}
روز×بیماری (Disease×Day)	14	166.99**	0.04**	0.01*	0.003*	226.78*

*, **, ns به ترتیب تفاوت معنی‌دار در سطح ۵ درصد، ۱ درصد و عدم تفاوت معنی‌داری را نشان می‌دهد.

*, **, and ns respectively, there is a significant difference in the level of 5%, 1% and no significant difference.

مطابق جدول ۲، نتایج آماری ویژگی‌های رنگی ساقه نشان داد که اثر روز بر تمامی فضاها رنگی ذکر شده معنی‌دار شد و همچنین بیماری اثر معنی‌داری برای تمامی کانال‌ها به جز B، R و V داشت. همچنین اثر متقابل برای تمامی کانال‌ها به جز B معنی‌دار شد. به‌طور کلی از بین سه فضای رنگی مورد بررسی، بهترین فضای رنگی Lab، فضای دوم HSV و فضای سوم RGB بود.

جدول ۲- نتایج تجزیه واریانس ویژگی‌های رنگی ساقه گل لیلیوم

Table 2- Results of analysis of variance of color characteristics of Lilium flower stem

منابع تغییر S. O. V	درجه آزادی df	میانگین مربعات (MS)				
		R	G	B	L	A
روز (Day)	14	1494.85**	2095.13**	947.41**	78.39**	56.45**
بیماری (Disease)	1	371.25 ^{ns}	3003.95**	176.42 ^{ns}	30420.48**	2017.01**
روز×بیماری (Disease×Day)	14	320.96**	263.86**	68.72 ^{ns}	78.77**	54.83**
			b	H	S	V
روز (Day)	14	22.32*	0.006**	0.03**	0.02**	
بیماری (Disease)	1	19002.09**	0.00009 ^{ns}	0.0003 ^{ns}	0.01**	
روز×بیماری (Disease×Day)	14	24.01*	0.002*	0.02**	0.005**	

*, ** و ns به ترتیب تفاوت معنی‌دار در سطح ۵ درصد، ۱ درصد و عدم تفاوت معنی‌داری را نشان می‌دهد.

*, ** and ns respectively, there is a significant difference in the level of 5%, 1% and no significant difference.

با توجه به آنالیز دانکن انجام شده بر روی تیمار روز در سطح احتمال ۵٪ (جدول ۳) کانال B در روز سوم کمترین مقدار را به خود اختصاص داده و در روز پانزدهم بیشترین مقدار را داشته است که در طول آزمایش اختلاف معنی‌داری میان روزهای آزمایش مشاهده شد. با توجه به این تغییرات هر چه میزان بیماری افزایش می‌یابد میزان تمایل گیاه به سمت آبی شدن نیز افزایش می‌یابد.


جدول ۳- نتایج بررسی اثر روز بر ویژگی‌های رنگی ساقه گل لیلیوم

Table 3- Results of the effect of day on color characteristics of Lilium flower stem

روز (Day)	ویژگی‌های رنگی ساقه (Stem color features) B
روز ۱	29.78 ^{de}
روز ۲	22.64 ^e
روز ۳	21.97 ^e
روز ۴	22.06 ^e
روز ۵	23.66 ^e
روز ۶	23.25 ^e
روز ۷	27.03 ^e
روز ۸	26.98 ^e
روز ۹	26.64 ^e
روز ۱۰	37.19 ^{cd}
روز ۱۱	38.89 ^{bc}
روز ۱۲	40.22 ^{bc}
روز ۱۳	46.72 ^{ab}
روز ۱۴	44.13 ^{abc}
روز ۱۵	49.44 ^a

حروف متفاوت با هم در سطح احتمال ۵ درصد اختلاف معنی‌داری دارند.

Different letters indicate significant difference at the 5% probability level.



شکل ۵- نمودار اثر متقابل روز در بیماری ویژگی H استخراج شده از تصویر برگ لیلیوم
حروف متفاوت با هم در سطح احتمال ۵ درصد اختلاف معنی‌داری دارند.

Fig.5. The interaction effect of day and disease in H attribute extracted from the leaf
Different letters indicate significant difference at the 5% probability level.

بیماری و همچنین کاهش میزان سبزیگی برگ‌ها و متمایل شدن آن‌ها به قرمزی قابل توجه می‌باشد. در چهار روز اول آزمایش اختلاف معنی‌داری بین شاهد و تیمار بیمار مشاهده نشد ($p > 0.05$) اما از روز پنجم تا روز پانزدهم اثر بیماری به صورت معنی‌داری بین شاهد با تیمار بیمار مشهود بود ($p < 0.05$). بنابراین می‌توان نتیجه گرفت که این معیار پس از گذشت چهار روز بیماری در گیاه را تشخیص می‌دهد. در همین راستا چادھاری و همکارانش (۲۰۱۲) روش مبتنی بر تبدیل رنگ به منظور تشخیص بیماری در برگ گیاهان (زردآلو، برنج، سویا و عنبیه) پرداختند (Chaudhary et al., 2012). در این تحقیق یک الگوریتم برای تقسیم نقطه به نقطه بیماری با استفاده از تکنیک‌های پردازش تصویر در برگ گیاه مورد بررسی قرار گرفت. نتایج نشان داد که استفاده از آستانه مولفه "a" فضای رنگی CIELab در تمام موارد، نقاط بیماری را به صورت دقیق‌تری تشخیص می‌دهد.


نتایج خوشه‌بندی

جدول ۴ خروجی حاصل از خوشه‌بند K-means را در تشخیص ۴۰ گیاه بیمار و ۴۰ گیاه سالم را نشان می‌دهد. مطابق با نتایج به دست آمده چهار شاخص حساسیت، تشخیص، صحت و دقت که به ترتیب ۱۰۰، ۹۴/۱۱، ۹۶/۴۲ و ۹۷/۶۳ به دست آمدند که نشان‌دهنده دقت بالا و توانایی تشخیص دو گروه گیاه سالم و بیمار توسط سامانه ماشین بینایی است. لازم به ذکر است که زمان مصرفی این سامانه در تشخیص، شناسایی موقعیت و سمپاشی به صورت میانگین ۲۶/۳۵

با توجه به شکل ۵ مقدار پارامتر H با گذشت زمان در طول آزمایش برای تیمار بیمار کاهش یافته است اما برای تیمار سالم صرف‌نظر از تغییراتی که در طول آزمایش مشاهده می‌شود تقریباً روند ثابتی داشته است. بین تیمار بیمار با تیمار سالم از روز اول آزمایش اختلاف معنی‌داری رویت شد ($p < 0.05$) اما بین تیمار بیمار در طول آزمایش اختلاف معنی‌داری مشاهده نشده است ($p > 0.05$). بنابراین می‌توان نتیجه گرفت که این معیار از روز اول آزمایش توانایی تشخیص بیماری در گیاه را با توجه به تفاوت معنی‌دار در این ویژگی بین تیمار شاهد و بیمار را دارد. در همین راستا نیاک و همکاران (۲۰۱۶) به منظور تشخیص خودکار بیماری برگ گیاه از ویژگی‌های HSV و طبقه‌بندی SVM استفاده کردند (Naik et al., 2016). در این پژوهش از الگوریتم ژنتیک به منظور تقسیم‌بندی تصویر برای تشخیص خودکار بیماری و همچنین طبقه‌بندی بیماری‌های برگ گیاهان (موز، لوبیا، زردچوبه، لیمو، انبه، سیب‌زمینی، گوجه‌فرنگی و ساپاتو) استفاده شد. بر اساس نتایج الگوریتم پیشنهادی توانایی تشخیص و طبقه‌بندی بیماری‌های برگ در مرحله اولیه را دارا بود. همچنین ویژگی‌ها^۱ و همکارانش (۲۰۰۸) نیز پژوهشی به منظور تشخیص بیماری‌های گیاهی در فضای رنگی HSI انجام دادند (Weizheng et al., 2008). نتایج نشان داد که مؤلفه رنگی H به خوبی می‌تواند بیماری در گیاه را تشخیص دهد.

طبق شکل ۶ مقادیر پارامتر a با گذشت زمان برای تیمار بیمار از ۰/۴۷ به ۰/۱۹ کاهش یافته است این مسأله با توجه به افزایش

ثانیه به دست آمد که نشان از عملکرد مناسب سامانه در تشخیص و رفع عیب دارد.



شکل ۶- نمودار اثر متقابل روز در بیماری ویژگی a استخراج شده از تصویر ساقه لیلیوم حروف متفاوت با هم در سطح احتمال ۵ درصد اختلاف معنی‌داری دارند.

Fig.6. Interaction effect of the day and disease in a feature extracted from the Lilium stem image Different letters indicate significant difference at the 5% probability level.

جدول ۴- دقت تشخیص خوشه‌بند k-means

Table 4- k-means clustering accuracy

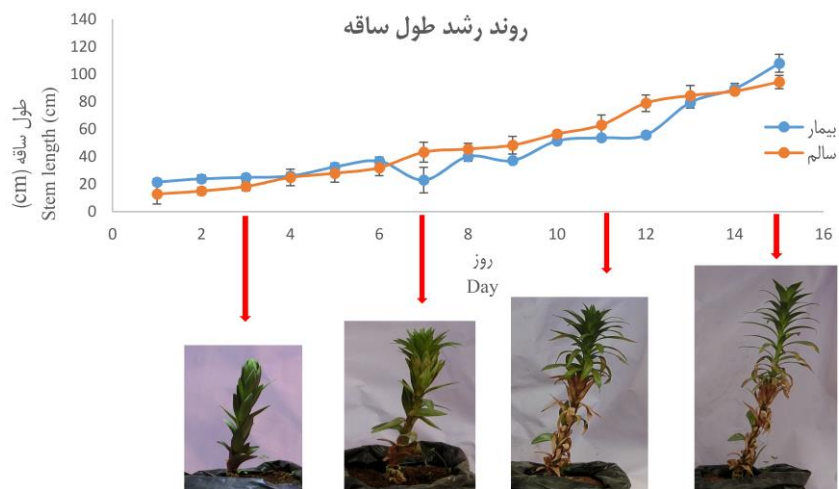
FC	بیمار (Diseased)	سالم (Healthy)	دقت خوشه‌بند (%) (Clustering accuracy)
بیمار (Diseased)	27	1	96.42
سالم (Healthy)	0	16	100
دقت خوشه‌بند (%) (Clustering accuracy)	100	94.11	97.63

ترتیب بود: ابتدا تصاویر به فضای HSI منتقل و سپس ویژگی‌های حاصل از ماتریس هم رویدادی مورد نظر استخراج شده و سپس عمل دسته‌بندی با استفاده از شبکه عصبی انجام می‌پذیرفت. در این پژوهش نتایج با دقت ۸۴ تا ۹۳ درصد بر حسب نوع بیماری حاصل شد. در پژوهشی دیگر ژانگ و همکاران (۲۰۱۷) با استفاده از طبقه‌بندی نمایندگی نزولی (SR^۲) و خوشه‌بندی K-means به شناسایی بیماری خیار مبتنی بر تصویر برگ پرداختند (Zhuang et al., 2017). در روش پیشنهادی نشان داده شد که در شناسایی هفت بیماری مهم خیار با نرخ تشخیص کلی ۸۵/۷٪، بیشتر از سایر روش‌های شناخته شده است.

در مطالعه‌ای کوی و همکاران (۲۰۰۹) به منظور تشخیص سریع و دقیق طبقه‌بندی بیماری زنگ سویا^۱ استفاده از سنسور تصویر چند بعدی را پیشنهاد دادند (Cui et al., 2009). آن‌ها از روش اتسو و K-means استفاده کردند. نتایج نشان داد که هر دو مرحله رشد برگ و عفونت شدید، سبب طیف وسیعی از تغییرات در سطح برگ شدند. به‌طور کلی، برگ‌های قدیمی با عفونت شدید زنگ‌زدگی باعث کمترین بازتاب می‌شدند. نتایج اولیه حاصل از این مطالعه در مقیاس آزمایشگاهی نشان داد که این روش تصویربرداری چند طیفی می‌تواند مقادیر اندک زنگ سویا را نیز تشخیص دهد. در همین راستا ال هیاری و همکاران (۲۰۱۱) از روش خوشه‌بندی k-means و شبکه عصبی مصنوعی برای دسته‌بندی پنج نوع بیماری گیاهی استفاده کردند (Al-Hiary et al., 2011). در این مطالعه روش کار به این

2- Sparse representation

1- Soybean rust



شکل ۷- روند رشد طول ساقه در گیاه
 Fig.7. Growth pattern of stem length in plant

تولید شده می‌شود. همان‌گونه که پیش‌تر نیز گفته شد در صورتی که مراقبت مناسب در گیاه صورت نگیرد، می‌تواند اثرات جدی بر روی آن بگذارد و به همین دلیل کیفیت، مقدار یا بهره‌وری محصول مربوطه تحت تاثیر قرار می‌گیرد.


شکل ۷ روند بیماری در گیاه را در طی یک ماه آزمایش نشان می‌دهد. همانطور که مشاهده می‌گردد در صورتی که بیماری در مراحل اولیه رشد به‌موقع تشخیص داده نشود سبب گسترش آن در کل گیاه و نهایتاً باعث کاهش معنی‌داری در کیفیت و کمیت گیاه



شکل ۸- تصویر گل بیمار در فضاهاى مختلف رنگى
 Fig.8. Disease flower image in different color spaces

معنی‌داری در سطح معنی‌دار ۵٪ وجود دارد (جدول ۵). این مساله نشان می‌دهد که هنگامی که بیماری در گیاه پیشرفت می‌کند به‌طور موثر بر روی ویژگی‌های رنگ، شکل و اندازه گل نیز تاثیر می‌گذارد که می‌تواند بازار پسندی محصول را نیز تحت تاثیر قرار دهد.

شکل ۸ و ۹ نمونه‌ای از گل‌های گیاه بیمار و سالم را نشان می‌دهد. مطابق با شکل ۸ زمانی که گیاه بیمار است از بین ویژگی‌های رنگی استخراج شده گل پارامترهای L ، a ، b و B و نسبت به گیاه سالم (شکل ۹) کاهش یافته‌اند. مطابق با آنالیز آماری صورت گرفته میان ویژگی‌های رنگی، بین پارامترهای B ، b ، H و V اختلاف



شکل ۹- تصویر گل سالم در فضاهای مختلف رنگی

Fig.9. Healthy flower image in different color spaces

جدول ۵- نتایج آزمون تی ویژگی‌های رنگی گل لیلیوم

Table 5- T-test results of Liliium flower color characteristics

ویژگی Feature	Levene's Test for Equality of Variances		t-test for Equality of Means		
	F	Sig.	t	Sig. (2-tailed)	Mean Difference
B	13.072	0.004	2.06	0.079	26.609
L	0.03	0.866	-16.949	0.000	-1.497
a	0.644	0.438	-17.438	0.000	-3.782
b	11.347	0.006	3.089	0.017	13.744
H	9.614	0.009	2.088	0.082	0.002
S	1.815	0.203	-2.764	0.017	-0.052
V	8.61	0.013	4.509	0.001	0.083

شناسایی می‌نماید. در این پژوهش به‌منظور تشخیص بیماری تصاویر ساقه و برگ گیاه لیلیوم در فضاهای رنگی مختلف (RGB، Lab و HSV) مورد بررسی قرار گرفتند. با توجه به نتایج آنالیز آماری دانکن و همچنین بررسی داده‌ها در هر فضای رنگی مختلف، مناسب‌ترین ویژگی‌ها (L برگ، L ساقه، a برگ، b برگ، H برگ، H ساقه، H برگ، H ساقه، V برگ و طول ساقه) برای استفاده در خوشه‌بندی K-means

نتیجه‌گیری

امروزه دستیابی به پتانسیل تولید و جلوگیری از کاهش قابل توجه عملکرد، تشخیص بیماری‌های دوره‌ای و تکراری و نظارت در طول عمر گیاه، امری ضروری است. در این مطالعه یک روش مبتنی بر پردازش تصویر را توصیف می‌کند که علائم بصری بیماری‌های گیاهی را از طریق تجزیه و تحلیل تصاویر رنگی و ویژگی مورفولوژی

تعیین شد. نتایج حاصل از خوشه‌بند برای گیاهان بیمار و سالم به ترتیب برابر با ۹۶/۴۲ و ۱۰۰ درصد و در نهایت دقت کلی خوشه‌بند بینایی ماشین در تشخیص بیماری آتشک می‌باشد.

References

1. Agrios, G. N. 2006. Plant Pathology, fifth ed. Academic Press, p. 952. ISBN: 9780120445653.
2. Al-Hiary, H., S. Bani-Ahmad, M. Reyalat, M. Braik and Z. ALRahamneh. 2011. Fast and Accurate Detection and Classification of Plant Diseases. International Journal of Computer Applications 17 (1): 31-38.
3. Arivazhagan, S., R. N. Shebiah, S. Ananthi, and S. V. Varthini. 2013. Detection of unhealthy region of plant leaves and classification of plant leaf diseases using texture features, Agricultural Engineering International: CIGR Journal 15 (1): 211-217.
4. Barbedo, J. G. A., L. V. Koenigkan, and T. T. Santos. 2016. Identifying multiple plant diseases using digital image processing, Biosystems Engineering 147: 104-116.
5. Brosnan, T., and Sun, D. W. 2003. Influence of Modulated Vacuum Cooling on the Cooling Rate, Mass Loss and Vase Life of Cut Lily Flowers, Biosystems Engineering 86 (1): 45-49.
6. Cao, X., B. Ning, P. Yan, and X. Li. 2012. Selecting key poses on manifold for pair-wise action recognition, Industrial Informatics, IEEE Transactions 8 (1): 168-177.
7. Cetisli, B. 2010. The effect of linguistic hedges on feature selection: Part 2. Expert Systems with Applications 37 (8): 6102-6108.
8. Chaudhary, P., A. K. Chaudhari, A. N. Cheeran, and S. Godara. 2012. Color transform based approach for disease spot detection on plant leaf, International Journal of Computer Science and Telecommunications 3 (6): 65-70.
9. Cui, D., Q. Zhang, M. Li, Y. Zhao, and G. L. Hartman. 2009. Detection of soybean rust using a multispectral image sensor, Sensing and Instrumentation for Food Quality and Safety 3 (1): 49-56.
10. Gonzalez-Andujar, J. L., C. Fernandez-Quintanilla, J. Izquierdo, and J. M. Urbano. 2006. SIMCE: an expert system for seedling weed identification in cereals, Computers and Electronics in Agriculture 54 (2): 115-123.
11. Jamalizavareh, A. H., A. Sharifi Tehrani, Gh. A. Hejarood, S. J. Zad, M. Mohammadi, and Kh. Talebi Jahromi. 2003. An Investigation of the Effectiveness of Acibenzolar-S-Methyl for the Control of Cucumber Powdery Mildew. Iranian Journal of Agriculture Science 35 (2): 285-292. (In Farsi).
12. Johannes, A., A. Picon, A. Alvarez-Gila, J. Echazarra, S. Rodriguez-Vaamonde, A. D. Navajas, and A. Ortiz-Barredo. 2017. Automatic plant disease diagnosis using mobile capture devices, applied on a wheat use case. Computers and Electronics in Agriculture 138: 200-209.
13. Kanungo, T., D. M. Mount, N. S. Netanyahu, C. D. Piatko, R. Silverman, and A. Y. Wu. 2002. An efficient k-means clustering algorithm: Analysis and implementation, Pattern Analysis and Machine Intelligence, IEEE Transactions 24 (7): 881-892.
14. Lucas, B. G., C. L. Campbell, and L. T. Lucas. 1992. Introduction to Plant Diseases, Identification and Management. Van Nostrand Reinhold, U.S.
15. Mansingh, G., H. Reichgelt, and K. M. O. Bryson. 2007. CPEST: an expert system for the management of pests and diseases, in the Jamaican coffee industry. Expert System Application 32 (1): 184-192.
16. Naik, M. R., and C. M. R. Sivappagari. 2016. Plant Leaf and Disease Detection by Using HSV Features and SVM Classifier, International Journal of Engineering Science 3794.
17. Oerke, E. C., U. Steiner, H. W. Dehne, and M. Lindenthal. 2006. Thermal imaging of cucumber leaves affected by downy mildew and environmental conditions, Journal of Experimental Botany 57 (9): 2121-2132.
18. Omrani, E., B. Khoshnevisan, S. Shamshirband, H. Saboohi, N. B. Anuar, and M. H. N. M. Nasir. 2014. Potential of radial basis function-based support vector regression for apple disease detection. Measurement 55: 512-519.
19. Payman, S. H., A. Bakhshipour Ziaratgahi, and A. Jafari. 2016. Exploring the possibility of using digital image processing technique to detect diseases of rice leaf. Journal of Agricultural Machinery 6 (1): 69-79. (In Farsi).
20. Rouzegar, M. R., and M. R. Golzarian. 2015. The application of image processing to detect and classify diseases of plants and fruits, 2nd National conference of Modern Topic in Agriculture, Tehran, Iran, 9-17. (In Farsi).
21. Sankaran, S., A. Mishra, R. Ehsani, and C. Davis. 2010. A review of advanced techniques for detecting plant diseases, Computers and Electronics in Agriculture 72 (1): 1-13.
22. Tang, J., D. Wang, Z. Zhang, L. He, J. Xin, and Y. Xu. 2017. Weed identification based on K-means feature learning combined with convolutional neural network, Computers and Electronics in Agriculture 135: 63-70.
23. Weizheng, S., W. Yachun, C. Zhanliang, and W. Hongda. 2008. December. Grading method of leaf spot disease based on image processing, in 2008 international conference on computer science and software engineering, 491-494. IEEE.
24. Zeller, W. 2004. Studies on induced resistance against Fire Blight (*E. amylovora*) with different bioagents. Abstract book of 10th int. Workshop on Fire Blight. Biolognaltaly. P. 56.
25. Zhuang, S., P. Wang, B. Jiang, M. Li, and Z. Gong. 2017. Early detection of water stress in maize based on digital images, Computers and Electronics in Agriculture 140: 461-468.

Feasibility of Online Diagnosis of Botrytis elliptica Disease in the Lilium Plant using the Machine Vision System and K-means

H. Biabi¹, S. Abdanan Mehdizadeh^{2*}, M. Salehi Salmi³

Received: 12-12-2018

Accepted: 19-06-2019

Introduction

The automatic detection of plant diseases in early stages in large farms, in addition to increasing the quality of the final product, could prevent the occurrence of irreparable damage. To this end, accurate and timely diagnosis of farm conditions is of great importance. In order to facilitate production potential and prevent a significant decline in yield, disease diagnosis is necessary periodically throughout the whole life of the. On the other hand, early detection of the disease in its early stages of growth can also prevent the spread of diseases. One of the most common methods for diagnosing plant diseases is the use of visual methods, but this method is difficult to evaluate the performance of a number of parameters such as the effects of the environment, nutrients, and organisms and so on. Furthermore, the accuracy of repetitions is very much related to individual fatigue of inspector. Research on activities that have the ability to identify diseases at an early stage and prevent the spread of contagious diseases are of great importance. Therefore, the use of new applications and new detection technologies to protect can significantly reduce the risk of product loss. Therefore, the purpose of this research is to design and construct an intelligent control system that automatically detects the health of the lilium plant and to improve the plant's condition.

Materials and Methods

Sample collection

In this study, 80 pots of four kilograms (including healthy and disease plants) were considered for plant growth in vegetative stage. The spring onions were grown in pots with 20 cm diameter and 30 cm height. Experiments were carried out in a greenhouse with a temperature of 27.15°C day/night and a relative humidity of 70-75%.

Image processing

In this research, the camera was placed at a constant distance of 50 cm from the flower to evaluate the stem and the leaves attached to it. The images were captured under the constant light conditions in the greenhouse during a specific hour of the day (10 to 12) every other day. The image was taken in RGB color space with a resolution of 1024 × 840 pixels, and after image transfer to the computer, image processing was performed using Matlab 2016a. After examining the plant image, 9 color channels (R, G, B, L, a, b, H, S, and V) were examined from three color spaces (RGB, Lab and HSV) and stem length to diagnosis of Botrytis elliptica disease.

Feature selection and classification

In this research, after improving the image and extracting the feature, the linguistic hedges method was used to select the features and the K-means clustering was applied in the N-division of the k-clustering specified by the user. In this method, each attribute was assigned to a cluster closer to the mean vector. This method continues until there was no significant change in the mean vectors between successive repetitions of the algorithm.

Results and Discussion

According to the results of feature selection L leaf, L stem, a leaf, b leaf, H leaf, b stem, H stem, V leaf and stem length, were the best features. Moreover, the accuracy of diagnosis for the diseased and healthy plants were 96.42 and 100 percent, respectively, and the overall classification accuracy was 97.63 percent. Therefore, in general, it can be said that the proposed image processing method is desirable and acceptable in order to diagnose the disease. According to this, Zhuang *et al.* (2017) used sparse representation (SR) classification and K-means clustering to identify leaf-based cucumber disease. In the proposed method, it has been shown that system could detect cucumber diseases with accuracy rate of 85.7%. Therefore, the proposed image processing technique seems to be able to diagnose the disease quickly and easily.

1- MSc Student, Department of Mechanics of Biosystems Engineering, Faculty of Agricultural and Rural Development, Agricultural Sciences and Resources University of Khuzestan, Ahvaz, Khuzestan, Iran

2- Assistant Professor, Department of Mechanics of Biosystems Engineering, Faculty of Agricultural and Rural Development, Agricultural Sciences and Resources University of Khuzestan, Ahvaz, Khuzestan, Iran

3- Assistant Professor, Horticultural Science Department, Faculty of Agriculture, Agricultural Sciences and Resources University of Khuzestan, Ahvaz, Khuzestan, Iran

(*- Corresponding Author Email: s.abdanan@asnrkh.ac.ir)

Conclusions

Today, in the modern agricultural systems, numerous computational methods have been designed to help farmers to control the proper growth of their products. However, there are still major problems with the rapid, accurate and classification of diseases in the early days of the disease. Therefore, the purpose of this study was to design, construct and evaluate a smart system based on image processing in order to identify and classify the leaf disease of the leaves of the liliium plant and remove it by spraying the contaminated parts. For this purpose, the linguistic hedges method was used to select the characteristics and k-means method to classify the infected plant from healthy. The results of the classification for the diseased and healthy plants were 96.42 and 100 percent, respectively, and the overall classification accuracy was 97.63 percent, which indicates the acceptable accuracy of the machine vision system in detecting the disease.

Keywords: Diagnosis of plant disease, Image processing, Linguistic hedges algorithm, K-means