

Development of an Intelligent System for Diagnosis of the Botrytis Elliptica Disease in the Lilium Plant Using Image Processing

HADIS BIABI¹, SAMAN ABDANAN MEHDIZADEH^{2*}, MOHAMADREZA SALEHI SALMI³

1. Ms Student of Department of Mechanics of Biosystems Engineering, Faculty of Agricultural Engineering and Rural Development, Agricultural Sciences and Resources University of Khuzestan, Ahvaz, Iran
2. Assistant professor of Department of Mechanics of Biosystems Engineering, Faculty of Agricultural Engineering and Rural Development, Agricultural Sciences and Resources University of Khuzestan, Ahvaz, Iran,
3. Assistant professor of Horticultural Science Department, Faculty of Agriculture, Agricultural Sciences and Resources University of Khuzestan, Ahvaz, Iran

(Received: Nov. 4, 2018- Revised: Apr. 16, 2019- Accepted: Apr. 22, 2019)

ABSTRACT

The automatic detection of plant diseases in the early stages of growth can increase the quality of the final product and prevent the occurrence of permanent damage in large part of farms. Therefore, in this research an intelligent system was designed and developed based on image processing in order to detect and eliminate the disease in the lilium plant leaf, as well as the classification of healthy plants from the unhealthy ones. Accordingly, 20 healthy flowers and 20 unhealthy were evaluated by machine vision system. In order to classify plants, 19 color and morphology parameters of the plant were extracted and the most effective ones (leaf L, leaf a, leaf b, stem L, and stem length) were selected by fuzzy entropy method and these suitable features were grouped by the similarity classifier. As result, the efficiency of the proposed algorithm to diagnose and classify the disease using fuzzy entropy H1, H2 / H3 fuzzy entropy and without applying selection of features method were 96.15, 93.18 and 84.3, respectively.

Keywords: Plant leaf disease, image processing, fuzzy entropy, similarity classifier

توسعه سامانه هوشمند تشخیص بیماری آتشک در گیاه لیلیوم با استفاده از روش پردازش تصویر

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

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

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

۳. استادیار، گروه باغبانی، دانشکده کشاورزی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان، اهواز، ایران.

(تاریخ دریافت: ۱۳۹۷/۸/۱۳ - تاریخ بازنگری: ۱۳۹۸/۱/۲۷ - تاریخ تصویب: ۱۳۹۸/۲/۲)

چکیده

تشخیص خودکار بیماری‌های گیاهی در مراحل اولیه در مزارع بزرگ می‌تواند علاوه بر افزایش کیفیت محصول نهایی از بروز خسارات جبران ناپذیر نیز جلوگیری نماید. لذا در این پژوهش سامانه‌ای هوشمند بر مبنای پردازش تصاویر به منظور شناسایی و رفع بیماری آتشک در برگ گیاه لیلیوم و همچنین طبقه‌بندی گیاه سالم از بیمار طراحی و توسعه یافت. بر این اساس تعداد ۲۰ گل سالم و ۲۰ گل آلوده توسط سامانه بینایی ماشین ارزیابی شدند. به منظور طبقه‌بندی گیاهان تعداد ۱۹ ویژگی رنگی و موفولوژیکی از گیاه استخراج و موثرترین این ویژگی‌ها (L برگ، a برگ، b برگ، L ساقه و طول ساقه) با کمک روش آنتروپی فازی انتخاب و به وسیله طبقه‌بند مشابه گروه‌بندی گردیدند. راندمان الگوریتم پیشنهادی در تشخیص و طبقه‌بندی بیماری برای آنتروپی فازی H1، آنتروپی فازی H2/H3 و بدون انتخاب ویژگی به ترتیب ۹۶/۱۵، ۹۳/۱۸ و ۸۴/۳ بدست آمد.

واژه‌های کلیدی: بیماری برگ گیاه، پردازش تصویر، آنتروپی فازی و طبقه‌بند مشابه

مقدمه

رویکردهای پژوهشی در زمینه کشاورزی به سمت افزایش بهره‌وری و کیفیت غذا با کاهش هزینه و با افزایش سود است. بدین منظور مدیریت و تشخیص دقیق و به موقع شرایط مزرعه از اهمیت بسزایی برخوردار می‌باشد. در میان شرایط مختلف و بحران‌های موجود در مزارع و گلخانه‌ها، بیماری‌های گیاهی به یک معضل تبدیل شده‌اند که در صورت عدم مراقبت مناسب اثرات جدی بر روی گیاهان گذاشته و سبب کاهش معنی‌داری در کیفیت و کمیت محصولات کشاورزی داشته و حتی منجر به مرگ و قحطی در مقیاس بزرگ گردند (Arivazhagan, 2010). برای تسهیل دستیابی به پتانسیل تولید و جلوگیری از کاهش قابل توجه عملکرد، تشخیص بیماری‌ها به صورت دوره‌ای در طول عمر کل گیاه ضروری است (Perenzny et al., 2003; Elad et al., 2007). اما از طرف دیگر تشخیص زودهنگام بیماری در مراحل اولیه رشد آن نیز می‌تواند از گسترش بیماری‌ها جلوگیری نماید.

از روش‌های متداول شناسایی بیماری گیاهان‌ها می‌توان به روش بصری توسط خبره اشاره نمود؛ اما این روش دشوار و در

عین حال دقت آن وابسته به فرد بوده و تنها در مناطق محدودی قابلیت پیاده‌سازی را دارد؛ لذا تلاش برای توسعه روش‌های جایگزین که تشخیص بیماری‌های گیاهی را در مراحل اولیه به صورت خودکار و با دقت بالا انجام داده و کار طاقت‌فرسای نظارت در مزارع بزرگ محصولات زراعی و باغی را کاهش دهد حائز اهمیت می‌باشد (Naik and Sivappagari, 2016)

روش‌های متعددی برای شناسایی بیماری‌های گیاهی مانند سرولوژیک^۱، مولکولی^۲، بیومارکر^۳، و روش‌های مبتنی بر کیفیت گیاهی وجود دارد. از میان روش‌های فوق تشخیص بیماری مبتنی بر کیفیت گیاه شامل تصویربرداری و تکنیک‌های طیفی به صورت غیرمخرب و پیوسته هستند. تکنیک‌های طیف‌سنجی گران بوده و توسط پرسنل آموزش دیده صورت می‌گیرند؛ در حالیکه تکنیک‌های تصویربرداری کم هزینه و آسان برای پیاده سازی هستند. روش پردازش تصویر می‌تواند اطلاعات مفیدی در مراحل اولیه بیماری در مورد سلامت محصول در اختیار کشاورز قرار دهد. این مساله می‌تواند سبب تسهیل تشخیص بیماری و همچنین کنترل آن از طریق اعمال استراتژی‌های مدیریتی

* نویسنده مسئول: s.abdanan@asnrukh.ac.ir

1 . serological

2 . biomarker-based

باکتری‌ها و اختلالات فیزیولوژیکی در گیاه لیلیوم وجود دارد که بر تولید و کیفیت آن در سراسر جهان تأثیر می‌گذارد؛ هدف از این مطالعه طراحی و توسعه سامانه‌ای هوشمند به منظور تشخیص و رفع بیماری بر مبنای پردازش تصویر در نظر گرفته شد.

مواد و روش‌ها

در این مطالعه تعداد ۴۰ گل‌دان چهار کیلویی برای بررسی گیاهان در مرحله رویشی در نظر گرفته شد. آزمایش شامل ۲۰ نمونه گیاه سالم (شاهد و عاری از بیماری) و ۲۰ نمونه گیاه آلوده بود. پیازهای لیلیوم به صورت مستقیم در گل‌دان‌ها حاوی مخلوط ۱:۱ خاک بکر و کوکوپیت کاشته شد و در شرایط گلخانه‌ای پرورش داده شدند. شایان ذکر است که شرایط (دما بین ۲۸ تا ۲۲ درجه سلسیوس، گل‌دان‌هایی با قطر ۵/۱۳ سانتی‌متر و ارتفاع ۱۲ سانتی-متر و خاک با ظرفیت زراعی ۱۳/۲۴ درصد) یکسانی برای گیاهان در مدت یک ماه از آزمایش فراهم شد.

روش اعمال بیماری

پس از رسیدن به مرحله ۸ برگی، گیاهان تلقیح شدند. تلقیح به روش (Jamalizavareh *et al.*, 2004) انجام پذیرفت. بدین ترتیب که از گیاهان لیلیوم که در گلخانه پرورش یافته و آلوده به بیماری فوزاریوم بودند، 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 گردید و سپس با استفاده از لام گلبول شمار تعداد اسپور در واحد حجم سوسپانسیون و روی $10^4 \times 4$ اسپور در میلی‌لیتر تنظیم شد. بلافاصله با استفاده از یک افشانه دستی، سوسپانسیون روی برگ‌های مورد نظر در حدی که برگ‌ها کاملاً خیس شدند پاشیده شد. گیاهان تلقیح شده به مدت ۲۴ ساعت در شرایط تاریکی و رطوبت بالا نگهداری و سپس به شرایط عادی گلخانه برگردانده شدند.


طراحی و ساخت سامانه تشخیص بیماری

شکل ۱ شماتیک سامانه تصویر برداری و تشخیص بیماری در گیاه لیلیوم را نشان می‌دهد. همانطور که در شکل (۱) مشاهده می‌شود سامانه بینایی ماشین شامل یک دوربین دیجیتالی (لاجیتک، مدل C930e)، دو عدد پروژکتور ۵۰w LED جهت نورپردازی، یک سکوی متحرک عکس‌برداری به شعاع ۱۲۰ سانتی‌متر، موتور پله‌ای ۱،۶۵ آمپر (مدل 42BYGH403، کشور چین)، راه‌انداز موتور پله‌ای (مدل DRV8825، کشور چین)، موتورگیربکس ۱۲DC ولت RPM ۱۰ (ZHENG، مدل ZGX50R، چین)، پمپ آب (۱۲ ولت ۳/۶ وات، مدل TOL، چین)، سنسور تشخیص سطح

مناسب (مانند اعمال آفت‌کش‌ها و قارچ‌کش‌ها) گردد (Johannes 'Goodridge *et al.*, 2017؛ Tejonidhi *et al.*, 2016). (Camargo and Smith, 2009). (et al., 2017). علائم بصری از طریق تجزیه و تحلیل تصاویر رنگی به منظور تشخیص بیماری‌های مختلف در گیاهان (پنبه، ذرت، موز، بارهنگ، یونجه و سویا) توسعه دادند. در روش پیشنهادی تصاویر گیاه یا برگ بیمار از فضای RGB به فضای HSV و I1I2I3 منتقل و ویژگی‌های رنگی مناسب استخراج شدند. بر اساس نتایج مشخص گردید که الگوریتم توسعه یافته قادر به شناسایی منطقه بیمار، حتی در طیف وسیعی از شدت‌ها بود. در پژوهشی دیگر (Goodridge *et al.*, 2017) سامانه‌ای به منظور تشخیص هوشمند آلودگی‌های باکتریایی، قارچی (سیاه تاول)، اختلالات آفات و بیماری‌های برگ در محصولات مختلف را طراحی کردند. در این سامانه از روش تصمیم‌گیری چند معیاری استفاده شد. در حقیقت این پژوهش یک رویکرد مدل‌سازی برای بیماری بود که با استفاده از مجموعه‌ای از ویژگی‌ها هر بیماری از طریق دو پارامتر وزن نسبی و مقیاس وزن توصیف می‌شد. با توجه به نتایج به دست آمده از آزمایشات، دقت تشخیص بیماری و حساسیت آن به ترتیب برابر ۹۵/۵٪ و ۱۰۰٪ گزارش گردید. Naik *et al.*, 2016 در پژوهشی به تشخیص بیماری با استفاده از ویژگی‌های فضای رنگی HSV و طبقه‌بند SVM پرداختند. در این پژوهش از یک الگوریتم برای بخش‌بندی تصویر جهت تشخیص خودکار استفاده شد. همچنین به طبقه‌بندی بیماری‌های برگ گیاهان و بررسی تکنیک‌های مختلف طبقه‌بندی بیماری‌ها که توانایی تشخیص بیماری برگ را داشتند پرداخته شد. موز، لوبیا، زردچوبه، لیمو، انبه، سیب زمینی، گوجه فرنگی و سبزیجات، در الگوریتم پیشنهاد شده مورد آزمایش قرار گرفتند. در این پژوهش دقت تشخیص به دست آمده توسط طبقه‌بند SVM و NN^1 به ترتیب برابر با ۸۶/۷۷٪ و ۹۵/۷۴٪ بود که نشان از کارایی الگوریتم پیشنهادی در شناخت و طبقه‌بندی بیماری‌های برگ است.

در این میان یکی از راه‌های گسترش عوامل بیماری‌زا گیاهان زینتی هستند که به عنوان میزبان عمل نموده و به دلیل حساسیت بالا به بیماری در مراحل رشد، محبوبیت خود را به عنوان گیاهان باغبانی از دست داده‌اند (Sankaran *et al.*, 2010). از بین گونه‌های زینتی، گل لیلیوم یکی از زیباترین گل‌های است که امروزه طرفداران بیشماری را به خود اختصاص داده است و برای درمان بسیاری از بیماری‌ها و اختلالات از قبیل درمان سوختگی، تنظیم ضربان قلب، پاک‌کننده موثر خون و غیره شناخته شده است (Brosnan and Sun, 2003) با توجه به این موضوع که تعدادی از بیماری‌های ناشی از قارچ‌ها، ویروس‌ها،

یک روز در میان (۱۵ روز) گرفته شدند. با توجه به رشد بیماری در هر روز از آزمایش، نمونه‌های روز قبل با روز بعد متفاوت بودند و با در نظر داشتن دوره ۱۵ روزه عکس‌برداری، تعداد ۶۰۰ تصویر اخذ و مورد بررسی قرار گرفتند. تصویر اخذ شده در فضای رنگی RGB و با قدرت تفکیک ۸۴۰×۱۰۲۴ اخذ شد؛ به منظور جداسازی بهتر گیاه از پس‌زمینه از یک صفحه جدا کننده استفاده شد و در ادامه پس از انتقال تصاویر به رایانه، با استفاده از نرم-افزار MatLab 2016a پردازش تصویر به صورت برخط انجام می-پذیرد که شرح آن در بخش بعد خواهد آمد.



شکل ۱- شماتیک از نماهای مختلف سامانه تصویر برداری و تشخیص بیماری در گیاه لیلیوم

نحوه جداسازی بخش بیمار و سالم گیاه

در این پژوهش به منظور محاسبه درصد بیماری و همچنین استخراج پارامترهای رنگی بخش بیمار در گیاهان ابتدا با انجام عملیات آستانه‌گذاری چند مرحله‌ای اتسو، طول کل ساقه گیاه استخراج گردید (شکل ۲-الف). سپس با استفاده از آستانه‌گذاری مجدد ناحیه سالم گیاه جدا گردید (شکل ۲-ب) و در نهایت با استفاده از درصد بیماری در گیاه محاسبه (شکل ۲-ج) و ویژگی-های رنگی از بخش‌های سالم و بیمار گیاه استخراج گردید.



(الف)

(ب)

(ج)

شکل ۲- نحوه جداسازی گیاه از پس‌زمینه (الف) طول کل ساقه؛ (ب) طول ساقه سالم و (ج) طول ساقه بیمار

محلول سم (YWROBOT، مدل V2) و شیر برقی مورد نظر (۱۲ ولت، مدل E247، چین)، مخزنی با ظرفیت ۱ لیتر و یک لپ‌تاپ بود. ۸ نقطه توقف بر روی صفحه دوار (محل قرارگیری گلدان‌ها) قرار داده شد که برای تشخیص این موقعیت‌ها از سنسور اثر هال (مدل UGN3144، چین) استفاده گردید. نحوه قرارگیری دوربین به این صورت بود که دوربین در فاصله ثابت ۵۰ سانتی‌متر کنار گیاهان جهت ارزیابی ساقه و برگ‌های متصل به آن قرار داشت. بدین ترتیب تصاویر تحت شرایط نور ثابت در فضای گلخانه در ساعتی مشخصی (۱۰ تا ۱۲) از روز طی مدت آزمایشات به صورت

همانطور که اشاره شد در این سامانه از ۸ سنسور اثر هال

استفاده گردید. این سنسورها به میدان مغناطیسی حساس می-باشند و خروجی آن به محض قرارگیری در مقابل آهنربا فعال می‌گردد. یک عدد آهنربا به عنوان شاخص بر روی صفحه دوار نصب بود که با چرخش صفحه و عبور آهنربا از روی سنسور خروجی آن فعال می‌شد و برد کنترلر موقعیت صفحه را نمایش می‌داد. نحوه عملکرد سامانه بدین صورت است که بعد از قرار گرفتن گلدان در موقعیت مناسب تصویر از نمونه اخذ می‌شد و در صورتی که نمونه نیاز به سمپاشی یا قارچ کشی داشت به محل نازل منتقل و با توجه به محل بیماری، نازل توسط موتور پله‌ای در موقعیت مناسب قرار می‌گرفت و سم‌پاشی صورت می‌پذیرفت. بعلاوه تعداد ۲ عدد کلید محدود کننده حرکت نیز در سامانه تعبیه شده است تا حرکت نازل در پایین‌ترین و بالاترین موقعیت محدود گردد. در صورتی که مخزن سم نیز به ۱۰٪ مقدار خود برسد یک پیام بر روی صفحه نمایش برای هشدار به کاربر ارسال می‌گردد و در حالتی که مخزن خالی گردد سامانه عمل نمی‌کند تا مخزن مجدد پرگردد. در ضمن سامانه طراحی شده توانایی عملکرد به دو صورت زمان‌بندی شده و تشخیص بر اساس ویژگی-های استخراج شده از تصاویر را داراست.



(رابطه ۳)

$$H_2(A; W) = \sum_{j=1}^n w_j \left(\cos \frac{\pi \mu_A(x_j)}{2} + \cos \frac{\pi (1 - \mu_A(x_j))}{2} - 1 \right)$$

تابع هدف در این پژوهش دقت طبقه بند مشابه در نظر گرفته شد. اصل اساسی در طبقه‌بندی مشابه این است که ابتدا می‌بایست بردارهای ایده آل ایجاد گردند (رابطه ۴).

$$v_i = (-v_i(f_1), \dots, v_i(f_t)) \quad (\text{رابطه ۴})$$

که i نشان دهنده شماره گروه و متعلق به کلاس C_i است. پس از استخراج بردارهای ایده‌آل، شباهت $s(x, v)$ بین نمونه x که می‌بایست طبقه‌بندی شوند و بردارهای ایده‌آل v محاسبه می‌گردند. اگر نمونه به گروه i تعلق داشته باشد، مقدار شباهت بین بردار ایده‌آل و نمونه $s(x, v) = 1$ می‌باشد و در غیر این صورت این مقدار صفر می‌شود. حال با ترکیب آنتروپی فازی و طبقه‌بند مشابه و جمع نمودن مقادیر آنتروپی این ویژگی برای تمام نمونه‌ها در مجموعه آموزشی، مقادیر آنتروپی برای ویژگی‌ها بدست آمد. اگر شباهت‌ها بالا (و یا کم) باشد مقدار آنتروپی پایین (و یا بالا) بدست می‌آید. این بخش به تفصیل در بخش بعد مورد بررسی قرار می‌گیرد.



شکل ۳- روند جداسازی برگ از ساقه و برگ به منظور محاسبه ویژگی‌های رنگی

ویژگی‌های استخراج شده

ویژگی‌های رنگی، مورفولوژی و بافت، در پژوهش‌های متعددی به منظور تشخیص و شناسایی بیماری در محصولات کشاورزی مورد استفاده قرار گرفته‌اند (Revathi and Barbedo et al., 2016؛ Hemalatha, 2012؛ Tejonidhi et al., 2016). در این پژوهش به بررسی ۹ ویژگی رنگی (R, G, B, L, a, b, H, S و V) مربوط به ساقه و برگ‌ها از ۳ فضای رنگی RGB، Lab و HSV و طول ساقه به منظور تشخیص بیماری آتشک در برگ گیاهان پرداخته شد. به منظور استخراج طول ساقه از روش رشد ناحیه استفاده گردید به این صورت که ابتدا بخشی از تصویر که در مرکز گل قرار داشت به عنوان هسته شروع جست‌جو انتخاب شد (شکل ۳ ب). سپس پیکسل‌هایی که از نظر ویژگی‌های شدت (میانگین، واریانس، چولگی و کشیدگی) مشابه هم بودند به عنوان معیارهایی برای رشد ناحیه در نظر گرفته شد و تا زمان بدست آمدن طول ساقه رشد ناحیه ادامه یافت (شکل ۳ پ، ت و ث). سپس اسکلت تصویر بدست آمد (شکل ۳ ج) و ساقه جدا گردید و با ضرب نمودن آن در تصویر اصلی، تصویر ۳ کاناله آن استخراج شد (شکل ۳ چ). شایان ذکر می‌باشد که برای رشد ناحیه از ماتریس همسایگی ۳×۳ استفاده گردید. همچنین به منظور بدست آوردن معیار مناسب نیز برگ‌ها از تصویر اصلی جدا گردیدند (شکل ۳ ح). لازم به ذکر است که ویژگی‌های بدست آمده این بخش از مطالعه به دو بخش مربوط به برگ و ساقه تقسیم شدند و به منظور آموزش طبقه‌بند مورد استفاده قرار گرفتند.

اندازه‌گیری‌های آنتروپی فازی و انتخاب ویژگی

در بسیاری از موارد، می‌توان با استفاده از محاسبات فازی معیار مناسبی از خطا را بدست آورد. با توجه به این مفهوم De Luca and Termini (1971) and Shannon (1948) مطابق داشت را جهت اندازه‌گیری آنتروپی فازی با در نظر گرفتن آنتروپی احتمالاتی شانون به صورت رابطه ۱ پیشنهاد نمودند (Bandemer & Nather, 1992):

(رابطه ۱)

$$H_1(A) = - \sum_{j=1}^n (\mu_A(x_j) \log \mu_A(x_j) + (1 - \mu_A(x_j)) \log [(1 - \mu_A(x_j))])$$

که در این رابطه $\mu_A(x_j)$ مقادیر فازی است. شایان ذکر است که در پژوهش‌های مختلف توابع آنتروپی فازی متفاوتی پیشنهاد شده است. Parkash et al., (2008) آنتروپی‌های فازی با توابع ۲ و ۳ را با موفقیت در فرآیند انتخاب ویژگی و طبقه‌بندی پیاده‌سازی نمودند:

(رابطه ۲)


$$H_2(A; W) = \sum_{j=1}^n w_j \left(\sin \frac{\pi \mu_A(x_j)}{2} + \sin \frac{\pi (1 - \mu_A(x_j))}{2} - 1 \right)$$

طبقه‌بندی مشابه^۱

به عبارت دیگر، برداری که بالاترین تشابه با برداری ایده‌آل v_i را دارد به گروه i ام تعلق دارد.

نتایج و بحث

در این پژوهش ابتدا تصاویر اخذ شده از وضعیت گیاه سالم و بیمار در طول مدت آزمایش مورد پردازش قرار گرفته و پس از آستانه‌گذاری ویژگی‌های یاد شده استخراج و تصاویر تجزیه و تحلیل شدند. شکل ۴ تصاویری از کانال‌های ۳ فضای رنگی گیاه بیمار را نمایش می‌دهد. در این پژوهش، به منظور تعیین مناسب‌ترین فضاهای رنگی، در هر فضا اطلاعات حاصل از هر کانال رنگ نسبت به دیگر کانال‌ها مورد مقایسه قرار گرفت.



شکل ۴- تصویر گیاه بیمار در فضاهای مختلف رنگی

نتایج آنالیز آماری انجام شده میان پارامترهای اندازه‌گیری شده آزمایش

آنالیز واریانس ویژگی‌های رنگی برگ، ساقه و ویژگی موفولوژی مربوط به ساقه به ترتیب در جداول (۱)، (۲) و (۳) آمده است.

مشکل اساسی در طبقه‌بندی، تقسیم‌بندی فضای ویژگی‌ها به نواحی مختلف برای هر دسته می‌باشد. در حالت ایده‌آل این تقسیم‌بندی باید به گونه‌ای صورت پذیرد که هیچ یک از تصمیمات نادرست نباشد (Abdanan Mehdizadeh and Soltani, Kazemi., 2016). حال در نظر بگیرید یک مجموعه X از اشیا را به N گروه مختلف c_1, \dots, c_n با ویژگی‌های خود می‌بایست طبقه‌بندی شوند. فرض شود که t تعداد عناصر مختلف (f_1, \dots, f_t) است که می‌توان از اشیا اندازه‌گیری نمود. شایان ذکر است که این مقادیر برای هر یک از ویژگی‌ها پیش از طبقه‌بندی نرمال شده‌اند به طوری که می‌توانند به عنوان یک مقدار بین $[0, 1]$ ارائه گردند. در نتیجه، اشیایی که می‌خواهند طبقه‌بندی شوند، بردارهایی هستند که متعلق به $[0, 1]^t$ هستند. در این روش، همانطور که پیش‌تر اشاره شد، ابتدا باید برای هر گروه بردار ایده‌آلی $v_i = (v_i(f_1), \dots, v_i(f_t))$ تعیین شود که نشان دهنده کلاس i باشد. این بردار از مجموعه نمونه x_i استخراج می‌گردد. به عنوان مثال بردارها $x = (x(f_1), \dots, x(f_t))$ متعلق به کلاس C_i است.

بعد از تعیین بردارهای ایده‌آل می‌بایست طبقه‌بندی داده‌های ناشناخته صورت پذیرد. در این پژوهش به منظور تعیین شباهت داده‌های ناشناخته با بردارهای ایده‌آل از شباهت در ساختار عمومی پیشنهاد شده توسط (Luukka et al., 2001) استفاده گردید (رابطه ۵):

(رابطه ۵)

$$s(x, v) = \left(\frac{1}{t} \sum_{r=1}^t w_r (1 - |x(f_r)^p - v(f_r)^p|)^{m/p} \right)^{1/m}$$

که در این رابطه m میانگین بردار ویژگی (عدد ثابت) برای $x, v \in [0, 1]^t$ در اینجا p یک پارامتر از ساختار (Lukasiewicz تعمیم یافته است و در این مطالعه یک در نظر گرفته شد (Luukka et al., 2001). w_r پارامتر وزن است به طوری که وزن‌های مختلف را می‌توان برای ویژگی‌های مختلف برای تأکید بر اهمیت آنها اعمال نمود. در این پژوهش با توجه به اینکه شناختی از اهمیت و الویت ویژگی‌ها در دست نبود و به منظور جلوگیری از ایجاد تعصب نسبت به ویژگی خاصی، وزن یک انتخاب شد (Formato et al., 1999). نهایتاً به منظور تعیین گروه مورد نظر برای بردار ویژگی ناشناخته از رابطه ۶ استفاده گردید (Luukka & Leppalampi, 2006)

$$s(x, v_i) = \max S(x, v_i) \quad i = 1, \dots, N \quad (\text{رابطه ۶})$$

گردید. همان‌طور که مشخص است اثر ساده روز و بیماری در سطح احتمال ۱٪ بر ویژگی طول ساقه معنی‌دار شده در حالی‌که اثر متقابل روز در بیماری معنی‌دار نشده است ($p > 0.05$).

همان‌طور که در جدول (۱) و (۲) مشاهده می‌گردد اثر روز بر روی تمامی ویژگی‌ها به جز ویژگی B و V و اثر بیماری هم بر روی تمامی ویژگی‌ها به جز G و S معنی‌دار شد. همچنین اثر متقابل روز در بیماری نیز برای ویژگی‌های S, b, a, L, B, R, V معنی‌دار

جدول ۱- نتایج تجزیه واریانس ویژگی‌های رنگی برگ گل لیلیوم سفید

| میانگین مربعات | | | | | | درجه آزادی | منابع تغییر |
|----------------|-------------|------------|-----------------------|----------------------|----------|------------|--------------|
| b | a | L | B | G | R | | |
| ۱۷۱/۵۴** | ۴۷/۴۴* | ۱۶/۶۲** | ۱۲۷/۷۹ ^{n.s} | ۵۹۱/۸۳** | ۴۹۶/۳۲** | ۱۴ | روز |
| ۶۰۰۷۴۷/۱** | ۶۵۵۲۲۸/۰۵** | ۲۰۴۸۰/۰۸** | ۱۵۸۵/۱۶** | ۹۹/۴۱ ^{n.s} | ۲۶۸۶/۶** | ۱ | بیماری |
| ۷۷/۸۴** | ۴۶/۴۲* | ۲۹/۵۷** | ۳۱۶/۱۹** | ۱۷۳/۸ ^{n.s} | ۳۶۲/۴۶* | ۱۴ | روز × بیماری |

جدول ۲- نتایج تجزیه واریانس ویژگی‌های رنگی برگ و مورفولوژی گل لیلیوم سفید

| میانگین مربعات | | | | درجه آزادی | منابع تغییر |
|----------------------|----------------------|---------------------|---------------------|------------|--------------|
| ویژگی مورفولوژی | ویژگی‌های رنگی برگ | | | | |
| طول ساقه | V | S | H | | |
| ۵۲۳۹/۲۵** | ۰/۰۰۵ ^{n.s} | ۰/۰۳** | ۰/۳۱** | ۱۴ | روز |
| ۳۵۲۵/۶۳** | ۰/۰۱* | ۰/۰۱ ^{n.s} | ۰/۱۷* | ۱ | بیماری |
| ۷۶/۳۸ ^{n.s} | ۰/۰۰۴* | ۰/۰۵** | ۰/۰۳ ^{n.s} | ۱۴ | روز × بیماری |

فضای رنگی HSV هر سه کانال معنی‌دار نگردیدند ($p > 0.05$). به طور کلی از بین سه فضای رنگی که مورد بررسی در تشخیص بیماری آتشک، بهترین فضای رنگی Lab به دلیل تعداد کانال‌های رنگی معنی‌دار بیشتر نسبت به دیگر فضاهای رنگی بود.

با توجه به جدول (۳)، آنالیز آماری ویژگی‌های رنگی استخراج شده از ساقه نشان داد که از فضای رنگی RGB اثر متقابل روز در بیماری تنها برای کانال G در سطح ۱٪ معنی‌دار می‌باشد و برای فضای رنگی Lab پارامتر L در سطح احتمال ۱٪ و پارامتر a در سطح احتمال ۵٪ معنی‌دار شدند؛ در حالی که در

جدول ۳- نتایج تجزیه واریانس ویژگی‌های رنگی ساقه گل لیلیوم سفید

| میانگین مربعات | | | | | | درجه آزادی | منابع تغییر | | | |
|----------------------|---------------------|---------------------|----------------------|---------------------|-----------|----------------------|-------------|-----------------------|----|--------------|
| V | S | H | b | a | L | | | | | |
| ۰/۰۰۸** | ۰/۰۲** | ۰/۰۳ ^{n.s} | ۲۲/۴۷ ^{n.s} | ۴۷/۴۷* | ۲۹/۰۴** | ۳۵۵/۰۶** | ۷۸۲/۰۶** | ۶۷۹/۷۸** | ۱۴ | روز |
| ۰/۰۰۷* | ۰/۳۱** | ۰/۰۱ ^{n.s} | ۳۷۰۱/۴۴** | ۰/۱۶ ^{n.s} | ۲۴۳۹۴/۷** | ۳۷/۰۴ ^{n.s} | ۳۵۹/۴۶* | ۳۴۰/۱۷ ^{n.s} | ۱ | بیماری |
| ۰/۰۰۱ ^{n.s} | ۰/۰۱ ^{n.s} | ۰/۰۱ ^{n.s} | ۲۲/۳۶ ^{n.s} | ۴۶/۹۱* | ۲۸/۶۴** | ۶۳/۸۶ ^{n.s} | ۱۹۸/۸۳** | ۱۲۱/۹۶ ^{n.s} | ۱۴ | روز × بیماری |

*, **, و ^{n.s} به ترتیب تفاوت معنی‌دار در سطح ۵ درصد، ۱ درصد و عدم تفاوت معنی‌داری را نشان می‌دهد.


دلیل تولید کلروفیل بیشتر به منظور جبران افت عملکرد دیگر برگ‌های از دست رفته است. برای کانال H یک روند نزولی مشاهده گردید که بیشترین مقدار آن مربوط به روز اول و کمترین مقدار مربوط به روز پانزدهم بوده است ولی بین ۶ روز آخر اختلاف معنی‌داری مشاهده نمی‌شود ($p > 0.05$). طول ساقه گیاه همین‌جور که بدیهی است از روز اول تا روز دهم یک روند افزایشی داشته ولی با توجه به اینکه اثر بیماری در اثر ساده نمایان نمی‌شود در نتیجه نمی‌توان به کاهش طول ایجاد شده در اثر بیماری استناد نمود. در ویژگی‌های رنگی ساقه کانال‌های S, b, B, R, V

به منظور بررسی دقیق‌تر اثر ساده بر پارامترهای معنی‌دار شده آنالیز دانکن در سطح احتمال ۵٪ بر روی پارامترها برای تیمار روز مورد بررسی قرار گرفت (جدول ۴). مطابق جدول (۴) از میان ویژگی‌هایی رنگی استخراج شده از برگ، کانال G در روز دوم کمترین مقدار را به خود اختصاص داده و در روز پانزدهم بیشترین مقدار را داشته است که در طول آزمایش این اختلاف دارای یک روند افزایش معنی‌داری بود. با توجه به این تغییرات هر چه میزان بیماری افزایش می‌یابد میزان تمایل برگ‌های باقی‌مانده در گیاه به سمت سبز شدن افزایش می‌یابد که احتمالاً به

۷ روند صعودی داشته‌اند به طوری که مقدار این پارامترها از ۴۴/۵، ۶/۴۹، ۰/۴۴ و ۰/۲۷ در روز یازدهم افزایش یافته است. ۵۲/۶۳، ۴۰/۰۷، ۵/۴۵، ۰/۳۸ و ۰/۲۳ در روز اول به ۶۸/۳۲

جدول ۴- نتایج بررسی اثرات ساده (دانکن) روز بر ویژگی‌های رنگی و مورفولوژی گل لیلیوم سفید

| فاکتور ویژگی | ویژگی‌های رنگی برگ | | ویژگی مورفولوژی گل | | | ویژگی‌های رنگی ساقه | | |
|--------------|-----------------------|--------------------|----------------------|----------------------|----------------------|---------------------|----------------------|----------------------|
| | G | H | طول ساقه | R | B | b | S | V |
| روز ۱ | ۴۹/۰۸ ^{ef} | ۰/۶۱ ^a | ۲۱/۳۶ ^g | ۵۲/۶۳ ^e | ۴۰/۰۷ ^c | ۵/۴۵ ^{ab} | ۰/۳۸ ^{abcd} | ۰/۲۳ ^{def} |
| روز ۲ | ۴۸/۶۹ ^f | ۰/۴۶ ^{ab} | ۳۱/۶۶ ^{gf} | ۵۶/۵۸ ^{de} | ۴۰/۱۸ ^c | ۶/۳۱ ^{ab} | ۰/۴۲ ^{ab} | ۰/۲۳ ^{cdef} |
| روز ۳ | ۵۰/۰۵ ^{ef} | ۰/۵۳ ^a | ۳۳/۵۴ ^{gf} | ۵۶/۶۵ ^{de} | ۴۱/۰۷ ^c | ۴/۸۴ ^{ab} | ۰/۳۹ ^{abcd} | ۰/۲۳ ^{cef} |
| روز ۴ | ۵۳/۹۸ ^{ef} | ۰/۶۲ ^a | ۳۶/۰۵ ^{ef} | ۵۶/۹۹ ^{de} | ۴۱/۳۶ ^c | ۲/۳۱ ^b | ۰/۴۱ ^{abc} | ۰/۲۲ ^f |
| روز ۵ | ۵۳/۸۷ ^{ef} | ۰/۵۴ ^a | ۳۸/۵۶ ^{ef} | ۵۷/۸۴ ^{de} | ۴۴/۶۴ ^{bc} | ۴/۰۲ ^{ab} | ۰/۳ ^d | ۰/۲۳ ^{cef} |
| روز ۶ | ۶۴/۳۶ ^{abcd} | ۰/۳۳ ^{bc} | ۴۲/۲۲ ^{def} | ۶۷/۷۷ ^{bc} | ۴۵/۹۸ ^{bc} | ۳/۸۸ ^{ab} | ۰/۴۱ ^{abc} | ۰/۲۶ ^{bcd} |
| روز ۷ | ۶۴/۷۱ ^{abcd} | ۰/۳۳ ^{bc} | ۴۳/۶ ^{def} | ۷۰/۱۳ ^{abc} | ۴۳/۰۲ ^c | ۴/۱۸ ^{ab} | ۰/۴۵ ^{ab} | ۰/۲۷ ^{bc} |
| روز ۸ | ۵۵/۳۲ ^{def} | ۰/۳ ^{bc} | ۴۹/۱۸ ^{de} | ۲۷/۷۹ ^{cd} | ۳۸/۹۵ ^c | ۴/۹۷ ^{ab} | ۰/۴۵ ^{ab} | ۰/۲۵ ^{cdef} |
| روز ۹ | ۵۶/۹۶ ^{def} | ۰/۲۹ ^{bc} | ۵۵/۰۵ ^d | ۶۳/۷ ^{cd} | ۳۷/۶۸ ^c | ۶/۹۱ ^{ab} | ۰/۴۷ ^a | ۰/۲۵ ^{cdef} |
| روز ۱۰ | ۵۹/۵۶ ^{bcd} | ۰/۱۵ ^c | ۷۰/۶۹ ^c | ۶۸/۳۵ ^{bc} | ۴۲/۴۶ ^c | ۷/۰۲ ^{ab} | ۰/۴۴ ^{ab} | ۰/۲۷ ^{bcd} |
| روز ۱۱ | ۶۵/۳۷ ^{abcd} | ۰/۳ ^c | ۷۳/۸ ^{bc} | ۶۸/۳۲ ^{bc} | ۴۴/۵ ^{bc} | ۶/۴۹ ^{ab} | ۰/۴۴ ^{ab} | ۰/۲۷ ^{bc} |
| روز ۱۲ | ۶۷/۷۹ ^{ab} | ۰/۱۵ ^c | ۷۶/۵۵ ^{bc} | ۷۲/۷۸ ^{abc} | ۴۷/۰۰۵ ^{bc} | ۶/۵۱ ^{ab} | ۰/۴۳ ^{ab} | ۰/۲۹ ^{ab} |
| روز ۱۳ | ۶۵/۵۸ ^{abcd} | ۰/۱۷ ^c | ۸۱/۴۴ ^{abc} | ۷۴/۲۷ ^{ab} | ۴۸/۷۱ ^{bc} | ۸/۱ ^a | ۰/۴ ^{abc} | ۰/۳ ^{ab} |
| روز ۱۴ | ۶۷/۴۸ ^{abc} | ۰/۱۶ ^c | ۸۶/۸۶ ^{ab} | ۷۵/۸۶ ^{ab} | ۵۳/۹۷ ^{ab} | ۶/۰۱ ^{ab} | ۰/۳۵ ^{bcd} | ۰/۳ ^{ab} |
| روز ۱۵ | ۷۲/۶۹ ^a | ۰/۱۵ ^c | ۹۳/۲۹ ^a | ۷۹/۸۶ ^a | ۵۹/۹۳ ^a | ۵/۲۷ ^{ab} | ۰/۳۱ ^{cd} | ۰/۳۱ ^a |



شکل ۵- نمودار اثر متقابل روز در بیماری ویژگی b استخراج شده از تصویر برگ لیلیوم سفید


احتمال ۵٪ مشاهده گردید. بنابراین می‌توان نتیجه گرفت که این معیار از روز اول اعمال بیماری به خوبی می‌تواند بیماری را در گیاه تشخیص دهد. روند این پارامتر در خلال آزمایشات برای تیمار شاهد صعودی بود به طوری که در روز پانزدهم به ۱۷/۸۵ رسید که نشان از تمایل گیاه از رنگ آبی به زرد می‌باشد.

پارامتر b مولفه زرد-آبی را مشخص می‌کند، زرد برای مقادیر مثبت و آبی برای مقادیر منفی است (Guzmán et al., 2015). مطابق شکل ۱ (۵) مشاهده می‌شود کانال b در بخش منفی قرار دارد و نشان دهنده آبی رنگ بودن گیاه است. از روز اول تا روز پانزدهم بین شاهد با تیمار بیمار اختلاف معنی‌داری در سطح

کمبود نیترژن و پتاسیم در گیاهان گوجه پیشنهاد کردند. در این مطالعه الگوریتم به استخراج تعدادی از ویژگی‌های رنگی از تصویر بر پایه اجزای b از فضای رنگی Lab و ویژگی‌های بافت از سه روش مختلف: عملگرهای اختلاف^۱، تبدیل فوریه^۲ و تجزیه بسته‌ی موجک^۳ پرداختند؛ به منظور انتخاب ترکیب مناسب ویژگی‌ها از الگوریتم ژنتیک استفاده نمودند. در نهایت، ترکیبی از ویژگی‌های بهینه شده به عنوان ورودی طبقه‌بندی نزدیک به همسایگی فازی K استفاده و دقت ۹۸/۲٪ بدست آمد.

در همین راستا Sannakki *et al.*, (2013) نیز روشی مبتنی بر پردازش تصویر به منظور تشخیص خودکار گسترش درجه بیماری در برگ‌های گیاه انار را با استفاده از منطق فازی پیشنهاد کردند. در این پژوهش تصاویر برگ‌های انار جهت تعیین نشانه‌های بیماری به فضای رنگ Lab منتقل و از طریق K-means خوشه بندی شدند. نتایج مشاهده شده از طریق آزمایشات در مقایسه با درجه‌بندی کاربر دقیق و رضایت بخش گزارش گردید. در پژوهشی دیگر Xu *et al.*, (2007) یک روش به منظور شناسایی

برگ a



شکل ۶- نمودار اثر متقابل روز در بیماری ویژگی a استخراج شده از تصویر برگ لیلیوم سفید

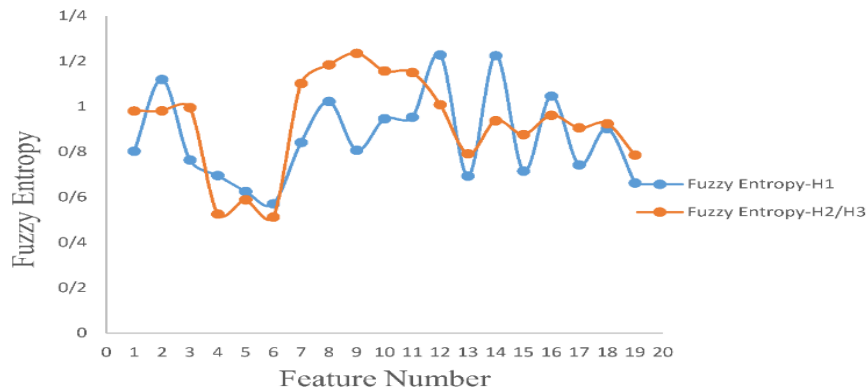
فازی) در آستانه‌گذاری بدست آمد. تلفیق این تکنیک‌های آستانه اتوماتیک و طراحی استراتژی طبقه‌بندی، میزان آسیب‌های محصول را با دقت ۹۸٪ نشان داد. در پژوهشی دیگر Hosseini *et al.*, (2018) سامانه تشخیص بیماری قارچی سفیدک پودری و آنتراکنوز برگ خیار به کمک تکنیک پردازش تصویر و شبکه عصبی مصنوعی توسعه دادند. در این پژوهش به بررسی تصاویر اخذ شده در سه فضای رنگی RGB، و L^*a^*b و HSV به منظور تعیین نواحی آلوده سطح برگ خیار پرداخته شد. نتایج نشان داد که شبکه عصبی مصنوعی (ANN) با الگوریتم پس انتشار خطا به عنوان بهترین مدل قادر به تشخیص و طبقه‌بندی بیماری با دقت ۹۹/۹۶ درصد است.

نتایج انتخاب ویژگی

انتخاب ویژگی نقش مهمی در طبقه‌بندی دارد و می‌تواند با حذف

با توجه به شکل (۶) مقادیر پارامتر a برای تیمار بیمار با گذشت زمان در طول آزمایش کاهش یافته‌اند که نشان‌دهنده تمایل گیاه به سمت سبزی است اما نسبت به تیمار شاهد از میزان سبزی کمتری برخوردار بودند. از این‌رو، اختلاف معنی‌داری از روز اول تا روز پانزدهم بین شاهد با تیمار بیمار مشاهده گردید ($p < 0.05$). بنابراین می‌توان نتیجه گرفت که این معیار از روز اول اعمال بیماری به خوبی توانایی تشخیص بیماری در گیاه را دارد. در پژوهشی Macedo-Cruz *et al.*, (2011) به بررسی تصویر دیجیتال با هدف کاهش خسارت ناشی از یخ‌زدگی محصولات یونجه در مرحله گلدهی پرداختند. فضای رنگی مورد استفاده در این پژوهش Lab بود که هیستوگرام هر کانال به صورت آستانه-گذاری به طور متوالی به مناطق مختلف تقسیم گردید. بهترین آستانه اعمال شده به صورت خودکار به عنوان ترکیبی از سه استراتژی ((1) روش Otsu؛ (2) الگوریتم Isodata؛ و (3) آستانه

(2001). مطابق شکل (۷) برای آنتروپی فازی H1 (رابطه ۱) ویژگی‌های ۴، ۵، ۶، ۱۳ و ۱۹ که به ترتیب برابر با L برگ، a برگ، b برگ، L ساقه و طول ساقه و برای آنتروپی فازی H2/H3 (رابطه ۲) ویژگی‌های ۴، ۵ و ۶ که به ترتیب برابر با L برگ، a برگ و b برگ انتخاب شدند.



شکل ۷- نتایج آنتروپی فازی

جدول ۵- دقت طبقه‌بند مشابه، مشابه با آنتروپی فازی H1 و مشابه با


| آنتروپی فازی H2/H3 | |
|--------------------|--------------------------|
| روش | میانگین دقت طبقه‌بند (%) |
| Sim | ۸۴/۳ |
| Sim +H1 | ۹۶/۱۵ |
| Sim +H2/H3 | ۹۳/۱۸ |

در پژوهشی (Bernardes *et al.*, 2013) به منظور تشخیص خودکار بیماری‌های گیاه پنبه از روش پردازش تصویر استفاده کردند. در این پژوهش از تبدیل موجک برای استخراج ویژگی و از شبکه عصبی ماشین بردار پشتیبان برای دسته‌بندی تصاویر استفاده شد. نتایج آزمایش نشان داد که روش پیشنهادی در بهترین مدل دقتی برابر با ۹۱٪ را داشت. در همین راستا (Bashish *et al.*, 2011) از شبکه عصبی پس انتشار به منظور دسته‌بندی بیماری‌های گیاهی استفاده کردند. در این پژوهش شش نوع بیماری با شبکه‌ای با ده لایه مخفی تفکیک و دقت ۹۳٪ گزارش شد. در پژوهشی دیگر (Tavakoli *et al.*, 2013) با استفاده از روشی مبتنی بر بررسی هیستوگرام لایه فام تصاویر و اعمال فیلترهای مرفولوژی 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. که در مقایسه با نتایج حاصل از این پژوهش می‌توان نتیجه گرفت که روش پیشنهادی در این پژوهش از دقت بالاتری جهت تشخیص بیماری برخوردار است. از طرف دیگر سامانه پیشنهادی توانایی سمپاشی و رفع بیماری در محصول مورد بررسی را دارد.

ویژگی‌های اضافی از مجموعه داده‌ها، مدل را ساده‌تر و حتی در مواردی دقیق‌تر نماید. در این پژوهش روش‌های آنتروپی فازی در فرایند انتخاب ویژگی مورد استفاده قرار گرفت. ویژگی‌هایی که مقدار آنتروپی فازی زیر ۰/۷ داشتند به عنوان ویژگی مناسب برای طبقه‌بند انتخاب شده و وارد طبقه‌بند گردیدند (Luukka *et al.*,

نتایج طبقه‌بندی

شکل (۸) مرحله آموزش طبقه‌بند را نشان می‌دهد. همان‌طور که در نمودار مشاهده می‌شود دقت طبقه‌بند آموزش دیده با آنتروپی فازی H1 و H2/H3 به صورت یکنواخت و بدون نوسان صورت می‌پذیرد و هم تشخیص گیاه سالم و ناسالم به درستی صورت پذیرفته است و زمانی که نرخ مثبت صحیح بالای ۹۱٪ است مثبت کاذب ۱۳٪ می‌باشد که این نشان دهنده این است که طبقه‌بند با دقت مناسب و خطای کمی عمل گروه‌بندی را انجام داده است.



شکل ۸- روند آموزش طبقه‌بند مشابه با روش انتخاب ویژگی آنتروپی فازی

مطابق با جدول (۵) میانگین دقت طبقه‌بند برای ۱۹ ویژگی وارد شده ۸۴/۳ درصد و برای ۵ ویژگی L برگ، a برگ، b برگ، L ساقه و طول ساقه در آنتروپی فازی H1 برابر با ۹۶/۱۵ درصد و همچنین برای ۳ ویژگی (L برگ، a برگ و b برگ) وارد شده در آنتروپی فازی H2/H3 برابر با ۹۳/۱۸ درصد شد.

نتیجه‌گیری

برای طبقه‌بندی گیاه آلوده از سالم استفاده گردید. بر اساس نتایج ویژگی‌های ۵ ویژگی‌L برگ، a برگ، b برگ، L ساقه و طول ساقه برای آنتروپی فازی H1 و ۳ ویژگی‌L برگ، a برگ و b برگ برای آنتروپی فازی H2/H3 انتخاب شدند. نتایج طبقه‌بند با انتخاب ویژگی آنتروپی فازی H1، آنتروپی فازی H2/H3 و بدون انتخاب ویژگی به ترتیب برابر با ۹۶/۱۵، ۹۳/۱۸ و ۸۴/۳ بود که نشان دهنده دقت خوب و خطای کم طبقه‌بند است.

سپاسگزاری

بدینوسیله نویسندگان از حمایت مالی دانشگاه علوم کشاورزی و منابع طبیعی خوزستان قدردانی می‌نمایند.

REFERENCES

- Abdanan Mehdizadeh, S., & Soltani Kazemi, M. (2016). Manufacturing and testing of a system to detect bee colony density inside the hive using machine vision. *Iranian Journal of Biosystem Engineering*, 47(1), 21-29 (In Farsi with English abstract)
- Arivazhagan, S., Shebiah, R.N., Nidhyandhan, S.S. & Ganesan, L. (2010). July. Classification of citrus and non-citrus fruits using texture features. *In Computing Communication and Networking Technologies (ICCCNT), 2010 International Conference on* (pp. 1-4). IEEE
- Bandemer, H. & Nather, W. (1992). Fuzzy data analysis. *Kluwer Academic Publisher*
- Barbedo, J.G.A., Koenigkan, L.V. & Santos, T.T. (2016). Identifying multiple plant diseases using digital image processing. *Biosystems Engineering*, 147, 104-116
- Bashish, D. A., Braik M. & Bani-Ahmad, S. (2011). Detection and Classification of Leaf Diseases using Kmeans-based Segmentation and Neural-networks-based Classification. *Information technology journal*, 10(2), 257-266
- Bernardes, A., Rogeri, J.R., Oliveira, N., Marranghello, A., Pereira, A. & Tavares, J.S. (2013). Identification of foliar diseases in cotton crop. *Topics in Medical Image Processing and Computational Vision*, 8, 67-85
- Brosnan, T. & 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
- Camargo, A. & Smith, J.S. (2009). An image-processing based algorithm to automatically identify plant disease visual symptoms. *Biosystems engineering*, 102(1), 9-21
- De Luca, A. & Termini, S. (1971). A definition of non-probabilistic entropy in setting of fuzzy set theory. *Information Control*, 20, 301-312
- Elad, Y., Messika, Y., Brand, M., Rav David, D. & Szejnberg, A. (2007). Effect of microclimate on *Leveillula taurica* powdery mildew of sweet pepper. *Phytopathology*, 97(7), 813-824
- Formato, F., Gerla, G. & Scarpati, L. (1999). Fuzzy subgroups and similarities. *Soft Computing*, 3, 1-6
- Goodridge, W., Bernard, M., Jordan, R. & Rampersad, R. (2017). Intelligent diagnosis of diseases in plants using a hybrid Multi-Criteria decision making technique. *Computers and Electronics in Agriculture*, 133, 80-87
- Guzman, M.G. & Harris, E. (2015). Dengue. *The Lancet*, 385(9966), 453-465
- Hosseini, H., Mohammad Zamani, D. & Arbab, A. (2018). A recognition system to detect powdery mildew and anthracnose fungal disease of cucumber leaf using image processing and artificial neural networks technique. *Scientific Journal of Agriculture*, 40(4), 15-28 (In Farsi with English abstract)
- Jamalizavareh, A., Sharifi tehrani, A., Hejarood, GH., Zad, J., Mohammadi, M. & Talebi, KH. (2004). 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 with English abstract)
- Johannes, A., Picon, A., Alvarez-Gila, A., Echazarra, J., Rodriguez-Vaamonde, S., Navajas, A.D. & Ortiz-Barredo, A. (2017). Automatic plant disease diagnosis using mobile capture devices, applied on a wheat use case. *Computers and Electronics in Agriculture*, 138, 200-209
- Luukka, P. & Leppalampi, T. (2006). Similarity classifier with generalized mean applied to medical data. *Computers in Biology and Medicine*, 36, 1026-1040
- Luukka, P., Saastamoinen, K. & Kononen, V. (2001). A classifier based on the maximal fuzzy similarity in the generalized Łukasiewicz-structure. *In Proceedings of the FUZZ-IEEE 2001 conference, Melbourne, Australia.*
- Macedo-Cruz, A., Pajares, G., Santos, M. & Villegas-Romero, I. (2011). Digital image sensor-based assessment of the status of oat (*Avena sativa* L.) crops after frost damage. *Sensors*, 11(6), 6015-

6036

- Naik, M. R. & Sivappagari, C. M. R. (2016). Plant Leaf and Disease Detection by Using HSV Features and SVM Classifier. *International Journal of Engineering Science*, 3794
- Parkash, O. M., Sharma, P. K. & Mahajan, R. (2008). New measures of weighted fuzzy entropy and their applications for the study of maximum weighted fuzzy entropy principle. *Information Sciences*, 178(11), 2389–2395
- Revathi, P. & Hemalatha, M. (2012). Classification of cotton leaf spot diseases using image processing edge detection techniques. In *Emerging Trends in Science, Engineering and Technology (INCOSET)*, 169-173
- Sankaran, S., Mishra, A., Ehsani, R. & Davis, C. (2010). A review of advanced techniques for detecting plant diseases. *Computers and Electronics in Agriculture*, 72(1), 1-13
- Sannakki, S.S., Rajpurohit, V.S., Nargund, V.B. & Arunkumar, R. (2013). Disease identification and grading of pomegranate leaves using image processing and fuzzy logic. *International journal of food engineering*, 9(4), 467-479
- Shannon, C. E. (1948). A mathematical theory of communication. *Bell System Technical Journal*, 379–423, 623–659
- Tavakoli, N., Hemmat, A. & 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)
- Tejonidhi, M. R., Nanjesh, B. R., Math, J. G. & D'sa, A.G. (2016). March. Plant disease analysis using histogram matching based on Bhattacharyya's distance calculation. In *Electrical, Electronics, and Optimization Techniques (ICEEOT)*, 1546-1549
- Xu, H. R., Ying, Y. B., Fu, X. P. & Zhu, S. P. (2007). Near-infrared spectroscopy in detecting leaf miner damage on tomato leaf. *Biosystems Engineering* 96 (4), 447–454