

توسعه یک سامانه جدید به منظور تشخیص بیماری‌های برگ درخت سیب

زهرا قاسمی ورجانی^۱، سیدسعید محتسبی^{۲*}، هادی قاسمی^۳، الهام عمرانی^۴

۱. دانشجوی کارشناسی ارشد، دانشکده مهندسی و فناوری، پردیس کشاورزی و منابع طبیعی دانشگاه تهران

۲. استاد، دانشکده مهندسی و فناوری، پردیس کشاورزی و منابع طبیعی دانشگاه تهران

۳. دانش آموخته کارشناسی ارشد، دانشکده عمران محیط زیست دانشگاه امیرکبیر

۴. دانشجوی دکتری، دانشکده مهندسی و فناوری، پردیس کشاورزی و منابع طبیعی دانشگاه تهران

(تاریخ دریافت: ۱۳۹۶/۲/۱۲ - تاریخ بازنگری: ۱۳۹۶/۸/۱۵ - تاریخ تصویب: ۱۳۹۶/۸/۱۷)

چکیده

هر ساله بیماری‌های گیاهی موجب خسارت‌های قابل توجهی در بخش کشاورزی می‌شوند که می‌توان تأثیر آن‌را در چرخه اقتصادی کشورها و امنیت غذایی مردم احساس نمود. تشخیص زودهنگام بیماری‌های گیاهی راهکاری مفید برای کاهش این خسارت‌ها می‌باشد. در سال‌های اخیر محققان مختلف از روش‌هایی چون تصویربرداری برای تشخیص بیماری‌های گیاهی استفاده نموده‌اند. در این تحقیق یک سامانه جدید، متشکل از روش پردازش تصویر دیجیتال و مدل ترکیبی شبکه عصبی به منظور تشخیص سه بیماری برگ درخت سیب (بیماری‌های لکه سیاه سیب، آلترناریا و آفت مینوز) بکار گرفته شد. در واقع از فرایند روش پردازش تصویر دیجیتال برای تهیه، پردازش و استخراج ویژگی‌های هر یک از تصاویر نمونه‌ها و از مدل ترکیبی شبکه عصبی مصنوعی برای طبقه‌بندی بیماری‌ها استفاده گردید. در این مدل برای آموزش شبکه از دو الگوریتم بهینه‌سازی ازدحام ذرات (PSO) و الگوریتم لوبنبرگ مارکوارت (LM) استفاده شد. در ادامه عملکرد سامانه پیشنهادی در تشخیص بیماری‌های درخت سیب مورد ارزیابی قرار گرفته و مشاهده گردید که این سامانه در تشخیص بیماری فوق‌الذکر با دقت ۹۹ درصد و شاخص‌های $R^2 = 0/985$ و $RMSE = 0/099$ عملکرد مناسبی دارد و همچنین در مقایسه با سایر روش‌های انجام شده توسط دیگر محققان، در تشخیص بیماری‌های برگ درخت سیب توانایی بالاتری دارد.

واژه‌های کلیدی: بیماری‌های گیاهی، پردازش تصویر، شبکه عصبی مصنوعی، بهینه‌سازی ازدحام ذرات

مقدمه

است ۸۷/۴ هزار تن به ارزش ۱۲/۶ میلیون دلار سیب تولید کند که ۴/۳ درصد از این مبلغ صرف کنترل بیماری و ۲/۵ درصد آن به علت بیماری از بین رفته است (UGA, 2014). همانطور که ذکر گردید کشورهای مختلف در تلاش هستند تا به راهکارهایی برای تشخیص به هنگام بیماری‌های گیاهی دست یابند. یکی از متداول‌ترین راهکارها در گذشته، تشخیص بصری بیماری توسط کارشناسان مجرب بوده است که این روش مستلزم نظارت مستمر توسط آسیب شناسان گیاهی می‌باشد و در مزارع بزرگ معمولاً پر هزینه است. از طرفی، بسیاری از بیماری‌ها در مراحل اولیه بیماری علائم واضحی ندارند و شناسایی آن‌ها با چشم غیر مسلح به سختی صورت می‌پذیرد. به همین دلایل بررسی و ارائه یک ابزار سریع، خودکار، کم هزینه و دقیق برای تشخیص بیماری‌های گیاهی ضروری می‌باشد. در دهه‌های اخیر رشد فناوری سبب افزایش پیشرفت در شاخه‌های مختلف علوم، صنعت و کشاورزی شده است. از این رو محققین مختلف به دنبال استفاده از فناوری‌های نوین به-

بر اساس آمار فائو در سال ۲۰۱۳ ایران با تولید ۱/۷ میلیون تن سیب، نهمین کشور تولید کننده این محصول در جهان می‌باشد. در همین سال آمریکا با تولید ۴/۰۸ میلیون تن سیب علاوه بر رفع نیاز داخلی توانسته است با کسب ۱/۱ میلیارد دلار بزرگترین صادرکننده این محصول در جهان باشد (FAO, 2013). قیمت و بازار متعادل محصولات کشاورزی به شدت وابسته به کیفیت است و در این میان بیماری‌های گیاهی می‌تواند باعث کاهش قابل توجهی در کیفیت و کمیت محصولات شده و در نتیجه سبب نزول اقتصاد کشورهای متکی بر صادرات محصولات کشاورزی گردد. در برخی موارد این بیماری‌ها اگر در مراحل اولیه رشد شناسایی شوند، قابل پیشگیری و مدیریت می‌باشند. در این خصوص طبق آمار که کشور گرجستان (۲۰۱۴) منتشر کرده است این کشور در سال ۲۰۱۴ توانسته

* نویسنده مسئول: Mohtaseb@ut.ac.ir

(Pan et al., 2014)، و پوسیدگی میوه توت فرنگی (et al., 2016)، از جمله بیماری‌هایی است که به سختی توسط سامانه‌های ماشین بینایی تشخیص داده می‌شود اگرچه سامانه ماشین بویایی در شناسایی زود هنگام این بیماری‌ها بسیار موفق عمل کرده است.

با مطالعه تحقیقات اخیر صورت گرفته توسط محققان مختلف به منظور تشخیص بیماری‌های گیاهی، مشاهده می‌شود که علاوه بر استفاده از سامانه‌های پیشرفته پردازش تصویر، محققین به توسعه مدل‌های طبقه‌بندی دقیق‌تر نیز روی آورده‌اند. در این راستا در مطالعه‌ای به منظور تشخیص و طبقه‌بندی بیماری‌های (موزاییک، زنگ برگ، و لکه گرد) برگ درخت سیب و همچنین بیماری‌های (لکه قهوه‌ای، لکه خاکستری، لکه گرد و زنگ) ذرت از مدل طبقه‌بندی ترکیبی ماشین بردار پشتیبان-ژنتیک (SVM-GA) استفاده گردید که در واقع الگوریتم ژنتیک (GA¹) به منظور به دست آوردن مقادیر بهینه پارامترهای ماشین بردار پشتیبان (SVM²) به کار گرفته شد (Tian et al., 2015; Zhanga et al., 2012). همچنین در تحقیقی دیگر از مدل ترکیبی شبکه عصبی-ژنتیک (ANN-GA) برای طبقه‌بندی بیماری فیزیولوژیکی گوجه فرنگی استفاده شده است که در این مدل نیز از الگوریتم GA برای به دست آوردن وزن‌های شبکه عصبی مصنوعی (ANN³) استفاده شده است. نتایج این تحقیق نشان داد که مدل پیشنهادی دقت بالایی در طبقه‌بندی این بیماری داشته است (Fang et al., 2008).

در این مطالعه به منظور تشخیص سه بیماری برگ درخت سیب به نام‌های مینوز لکه گرد، لکه سیاه و آلترناریا که در ایران رایج می‌باشند از سامانه جدید متشکل از روش پردازش تصویر دیجیتال و شبکه عصبی ترکیبی استفاده گردیده است.

مواد و روش‌ها

در این مطالعه یک سامانه جدید متشکل از روش پردازش تصویر دیجیتال و مدل ترکیبی شبکه عصبی به منظور تشخیص بیماری‌های درخت سیب استفاده شده است. در این بخش به توضیح مختصری از نحوه عملکرد این سامانه در تشخیص بیماری پرداخته می‌شود.

روش پردازش تصاویر

در سال‌های اخیر استفاده از روش پردازش تصویر دیجیتال در

منظور تشخیص زودهنگام و به موقع بیماری‌های مختلف گیاهی شده‌اند. فناوری‌های به کار رفته، عمدتاً در دو بخش نوع سامانه پردازش نمونه و همچنین مدل‌های طبقه‌بندی می‌باشند. از سامانه‌های مختلف پردازش نمونه می‌توان به انواع سامانه‌های تصویربرداری، ماشین بویایی و ماشین چشایی و از مدل‌های مختلف طبقه‌بندی نیز می‌توان به انواع مختلف مدل‌های آماری، داده‌کاوی و هوش مصنوعی اشاره نمود. معمولاً سامانه‌های پردازش نمونه متناسب با نوع و علائم بیماری‌های گیاهی انتخاب می‌شوند.

سامانه تصویربرداری به خاطر داشتن مزایایی همچون غیرمخرب بودن، کاهش هزینه‌های نیروهای انسانی و دقت بالا در سال‌های اخیر مورد توجه بسیاری واقع شده است. محققان مختلف از این سامانه به منظور تشخیص بیماری غذایی برگ درخت نخل (Asraf et al., 2012)، طبقه‌بندی بیماری‌های (مینوز، لکه سیاه و آلترناریا) برگ درخت سیب (Omrani et al., 2014) و تشخیص بیماری برگ چای (Billah et al., 2015)، تشخیص و طبقه‌بندی بیماری‌های (سفیدک درونی، باکتریایی لکه زاویه‌ای، لکه حلقوی، لکه، پوسیدگی خاکستری، آنتراکنوز، سفیدک پودری) برگ خیار (Zhang et al., 2017) استفاده نموده‌اند. از آنجائیکه در مرحله آغاز و شیوع بیماری هیچ نشانه‌ای از آنها قابل رویت نمی‌باشد، به منظور استخراج ویژگی‌های بیماری باید از سامانه‌ای پیشرفته‌تر از تصویربرداری‌های معمول استفاده نمود. از این رو محققان سامانه تصویربرداری فراطیفی را مدنظر قرار دادند زیرا این سامانه علاوه بر ویژگی‌های فضایی مربوط به بیماری، ویژگی‌های طیفی را نیز استخراج می‌نماید که در تشخیص زودهنگام بیماری، بسیار مفید واقع می‌شود. در این راستا به منظور تشخیص بیماری برگ توت فرنگی در سه مرحله مختلف بیماری (سالم، شیوع، بیماری)، (Yeh et al., 2016)، تشخیص بیماری‌های (لکه برگی سرکوسپورایی، سفیدک پودری و زنگ) برگ چغندر (Mahlein et al., 2012)، بیماری قرنطینه‌ای میوه سبز مرکبات (Kumar et al., 2012)، از این سامانه استفاده شده است. از طرفی این سامانه بسیار گران قیمت، زمان‌بر و مستلزم استفاده از افراد آموزش دیده می‌باشد که شاید برای تمامی کشاورزان امکان استفاده از آن وجود نداشته باشد. ماشین بویایی نیز یک نوع دیگر از سامانه‌های پردازش نمونه می‌باشد که دارای مزایایی همچون غیرمخرب بودن، قابلیت اطمینان بالا، کاربری آسان و سریع بوده و در مواردی که هیچ علائم تغییر رنگی از بیماری در نمونه‌ها وجود ندارد بسیار کارآمد می‌باشد (Tian et al., 2013; Loutfi et al., 2015). تشخیص بیماری پوسیدگی نرم سیب زمینی (Massimo

1. Genetic Algorithm

2. Support Vector Machine

3. Artificial Neural Network

انتخاب از مقدار پاسخ بهینه دور باشد، فرایند آموزش شبکه برای دستیابی به پاسخ بهینه به تعداد تکرارهای زیادی نیازمند است و سرعت همگرایی الگوریتم برای دست یافتن به پاسخ بهینه کاهش می‌یابد و همچنین این امکان وجود دارد که الگوریتم در مسیر دستیابی به پاسخ بهینه در دام مینیمم‌های محلی قرار گیرد و هرگز به پاسخ بهینه دست پیدا نکند.

در این مطالعه برای حل این مشکل، قبل از آموزش شبکه عصبی توسط الگوریتم (LM^۳)، شبکه توسط الگوریتم PSO آموزش داده می‌شود و مقادیری برای وزن‌های شبکه حاصل می‌شود و چون این مقادیر توسط یک الگوریتم بهینه‌سازی به دست آمده است به پاسخ بهینه بسیار نزدیک است. سپس مقادیری که توسط الگوریتم PSO در مرحله قبل به دست آمدند به عنوان وزن‌های اولیه در نظر گرفته، شبکه توسط الگوریتم LM آموزش داده شده و وزن‌های نهایی حاصل می‌گردد.

سامانه جدید

همان‌طور که بیان گردید، در این مطالعه به منظور تشخیص بیماری‌های برگ درخت سیب، یک سامانه جدید متشکل از روش پردازش تصویر و مدل ترکیبی شبکه عصبی توسعه داده شد. نحوه عملکرد این سامانه ترکیبی در زیر ارائه شده است (شکل ۱).

مرحله اول: پیش پردازش داده‌ها

گام اول: جمع‌آوری نمونه‌های برگ

در این تحقیق سه نوع بیماری برگ درخت سیب، شامل بیماری لکه سیاه سیب، بیماری آلترناریا و آفت مینوز مورد بررسی قرار گرفت. تعداد ۳۲۰ نمونه‌ی مختلف برگ درخت سیب (۱۶۰ عدد از برگ‌ها آلوده به بیماری آلترناریا، ۹۲ عدد آلوده به بیماری لکه سیاه سیب و ۶۸ عدد آلوده به آفت مینوز) که دارای شدت‌های مختلف بیماری بودند، از مؤسسه اصلاح نهال و بذر کرج و همچنین باغ پردیس کشاورزی و منابع طبیعی دانشگاه تهران تهیه شد. در شکل (۲) نمونه‌ای از این برگ‌ها نشان داده شده است (Omran & Mohtasebi, 2013).

گام دوم: تهیه تصاویر نمونه‌های برگ

برای تهیه‌ی تصاویر برگ‌ها از سامانه ماشین بینایی کارگاه طراحی و تحقیق گروه مهندسی مکانیک ماشین‌های کشاورزی پردیس کشاورزی و منابع طبیعی دانشگاه تهران استفاده شد (شکل ۳) (Omran & Mohtasebi, 2013).

علوم مختلف و صنعت روز به روز در حال گسترش است و هر روز کاربرد جدیدی برای آن یافت می‌شود. این روش به طور کلی متشکل از سه بخش اساسی استفاده از دوربین دیجیتال به منظور تهیه تصاویر نمونه‌ها، پردازش تصاویر و استخراج ویژگی‌ها می‌باشد. در این مطالعه از روش پردازش تصاویر به منظور استخراج ویژگی‌های مربوط به سه بیماری برگ درختان سیب (لکه سیاه، بیماری آلترناریا و آفت مینوز) استفاده گردید.

شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی ابزارهای محاسباتی انعطاف‌پذیری هستند که برای مدل‌سازی طیف گسترده‌ای از مسائل غیرخطی به کار می‌روند. این شبکه‌ها بدون دانش قبلی درباره مساله خاص، قادر به مدل‌سازی آن می‌باشند که این مدل‌سازی بر مبنای دانش موجود در الگوهای آموزشی ورودی به شبکه صورت می‌گیرد. شبکه‌های عصبی انواع مختلفی دارند که در این مطالعه از شبکه عصبی پرسپترون چند لایه (MLP^۱) استفاده شده است. MLP متشکل از لایه ورودی، لایه‌های پنهان و لایه خروجی می‌باشد. هر لایه شامل واحدهای پردازنده‌ی متعددی (نورون) هستند که به نورون‌های لایه مجاور متصل می‌شوند. عنصر ارتباطی بین نورون‌های لایه‌های مجاور، وزن‌ها هستند که باید برای رسیدن به پاسخ مطلوب تنظیم شوند.

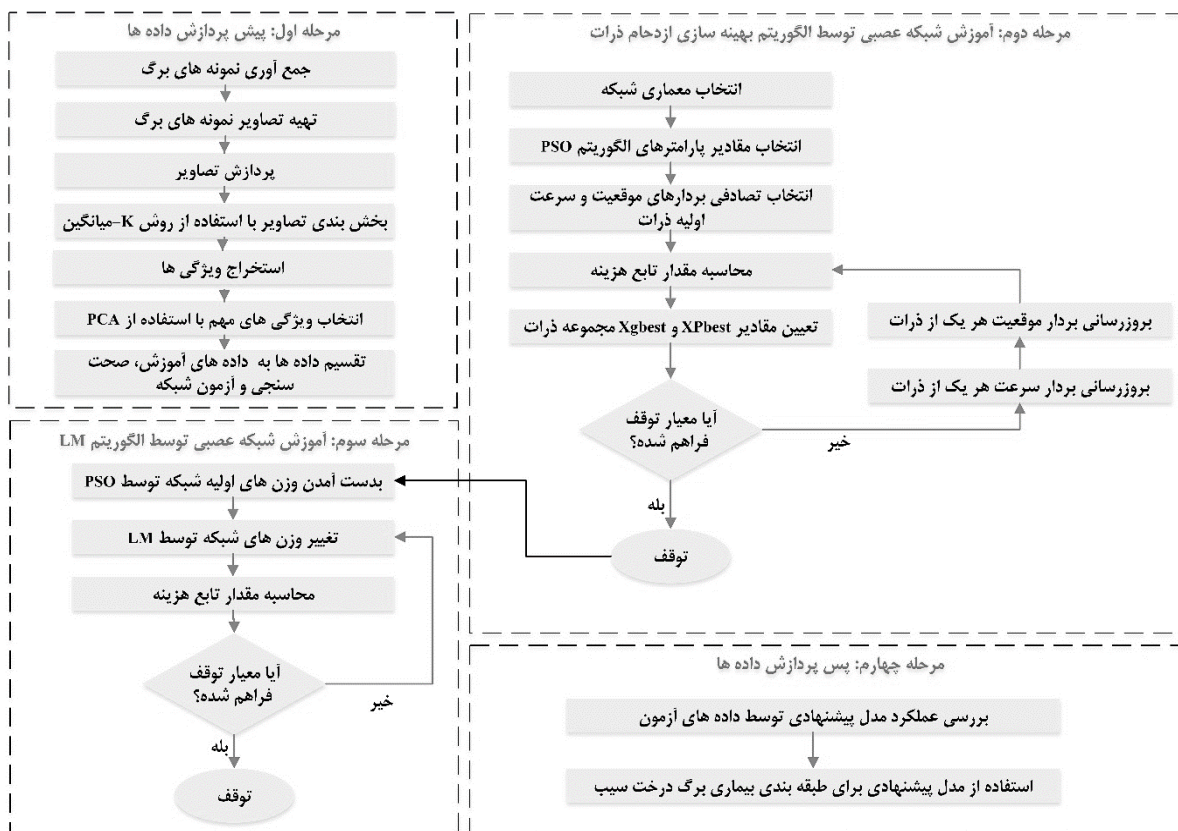
الگوریتم بهینه‌سازی ازدحام ذرات

الگوریتم بهینه‌سازی ازدحام ذرات (PSO^۲) اولین بار در سال ۱۹۹۵ توسط کندی و ابرهارت مطرح شد که در تدوین آن از پرواز گروهی پرندگان و شنای گروهی ماهی‌ها الهام گرفته شد (Eberhart & Kennedy, 1995). این روش برخلاف بسیاری از روش‌های سنتی، به مشتق‌گیری نیاز نداشته و می‌تواند برای توابع هدف با ماهیت تصادفی بکار برده شود. این الگوریتم نیز مانند سایر الگوریتم‌های جمعی، با جمعیت تصادفی شروع به کار می‌کند. در واقع هر کدام از اعضا یک ذره هستند که مجموعه را به وجود می‌آورند. این مجموعه با توجه به سرعت‌های هر ذره، در فضای تصمیم به سمت نقطه‌ای بهینه حرکت می‌کند. جزئیات دست‌یابی به پاسخ بهینه توسط الگوریتم PSO در بخش بعدی ارائه شده است.


مدل ترکیبی شبکه عصبی

یکی از نقاط ضعف در آموزش شبکه‌های عصبی، انتخاب تصادفی مقادیر ابتدایی وزن‌های شبکه می‌باشد که اگر این

1. Multi-Layer Perceptron
2. Particle Swarm Optimization



شکل ۱. نمودار مراحل مختلف همگرایی سامانه جدید



شکل ۲. سه دسته مختلف اختلال های سیب (الف) بیماری لکه سیاه سیب (ب) آفت مینوز (ج) بیماری آلترناریا.



شکل ۳. نمای از سامانه ساخته شده جهت تصویر برداری.

فلورسنت مونوکروم (مهبائی سفید) با توان ۲۰ وات که به همراه صفحات پخش کننده نور به عنوان بهترین حالت نورپردازی انتخاب گردید. عکس برداری از نمونه ها توسط دوربین انجام

این سامانه شامل یک دوربین CCD رنگی (Canon EOS)، یک رایانه شخصی برای ضبط تصاویر و صفحه نمایش همراه با یک سیستم نورپردازی مجهز به دو لامپ

منظور از بین بردن اثر درخشندگی می‌باشد (Omrani & Mohtasebi, 2013).

گام چهارم: بخش‌بندی تصاویر با استفاده از روش k -میانگین به منظور استخراج منطقه آلوده، بخش‌بندی براساس ناحیه صورت گرفت. دستوره‌های خوشه‌بندی تصاویر با استفاده از روش k -میانگین فقط به مولفه‌های a^* و b^* اعمال گردید و تصاویر به دو ناحیه سالم و آلوده‌ی برگ تقسیم شدند. پس از این مرحله، به دلیل اینکه لکه بیماری، سطح کمتری نسبت به سطح برگ داشت، این ناحیه انتخاب شد و بقیه عملیات پردازش تصاویر و استخراج ویژگی‌ها روی تصویر لکه بیماری اعمال گردید (شکل ۴). (Omrani & Mohtasebi, 2013).



شکل ۴. تصویر مربوط به مرحله‌ی خوشه‌بندی بیماری لکه سیاه سیب با استفاده از خوشه‌بند k -میانگین (الف) خوشه‌ی مربوط به برگ سالم (ب) خوشه‌ی بیابگر بیماری (ج) تصویر لکه‌ی بیماری پس از پردازش.

مولفه اصلی (PCA) در میان دیگر روش‌های داده‌کاوی برای کاهش ابعاد داده‌ها به‌صورت گسترده استفاده می‌شود. در این مطالعه نیز از PCA برای استخراج ویژگی‌های برتر و کاهش بردار ویژگی استفاده و تعداد ویژگی‌ها به ۳۳ مورد کاهش داده شد.

گام هفتم: تقسیم داده‌ها به داده‌های آموزش، صحت‌سنجی و آزمون شبکه

در این مطالعه تعداد ۳۲۰ نمونه برگ مورد مطالعه قرار گرفت. تعداد ۲۴۰ نمونه (۷۵ درصد کل داده‌ها) به عنوان داده‌های آموزش شبکه استفاده گردید که از میان این تعداد داده، ۶۰ نمونه به عنوان داده‌های صحت‌سنجی بکار گرفته شده است، همچنین تعداد ۸۰ نمونه (۲۵ درصد کل داده‌ها) برای آزمون شبکه در نظر گرفته شد.

مرحله دوم: آموزش شبکه عصبی توسط الگوریتم PSO
گام اول: انتخاب معماری شبکه

انتخاب یک معماری مناسب برای شبکه عصبی تأثیر زیادی بر عملکرد آن در طبقه‌بندی و تشخیص دارد. در این مطالعه از شبکه عصبی پرسپترون چند لایه (MLP) استفاده شده است که لایه اول دارای ۳۳ گره ورودی و لایه آخر شامل یک گره خروجی می‌باشد. اما انتخاب مناسب تعداد لایه‌های پنهان و همچنین تعداد نورون‌های این لایه‌ها از اهمیت ویژه‌ای برخوردار

گرفته و در فضای رنگی RGB بر روی کامپیوتر ذخیره شد. سپس به هر یک از بیماری‌ها یک عدد اختصاص داده شد که عدد ۱ نشان دهنده بیماری مینوز، ۲ بیماری لکه سیاه و ۳ بیماری آلترناریا می‌باشد.

گام سوم: پردازش تصاویر از جعبه‌ابزار برنامه متلب ۲۰۱۲ برای پردازش تصاویر استفاده گردید. مراحل پردازش تصاویر، عملیات مورد استفاده برای ارائه تصاویر قبل از استخراج ویژگی می‌باشد که در این مطالعه شامل از بین بردن پس زمینه، حذف دم برگ، نویزهای ناخواسته و تبدیل تصویر از فضای RGB به فضای $L^*a^*b^*$ به دلیل نزدیکی این فضا به سیستم بینایی انسان و حذف مؤلفه L^* تصاویر به

گام پنجم: استخراج ویژگی‌ها در این مرحله، مجموعه‌ای از ویژگی‌ها برای توصیف منطقه آلوده استخراج شد. به طور معمول از رنگ، شکل و ویژگی‌های مبتنی بر بافت برای توصیف منطقه استفاده می‌شوند. از آنجائیکه برای هر یک از بیماری‌های برگ سیب ویژگی‌های رنگ و بافت با یکدیگر متفاوت هستند از این رو تنها از این ویژگی‌ها برای طبقه‌بندی استفاده گردید. لازم به ذکر است که برای به دست آوردن ویژگی‌های بافت از آنالیز موجک و ماتریس هم‌وقوعی سطح خاکستری استفاده شد. در مجموع ۷۰ ویژگی شامل ۱۴ ویژگی رنگ (شدت، زاویه، ۴ ویژگی آماری متعلق به مولفه‌های a^* و b^* از فضای $L^*a^*b^*$ و R از فضای RGB)، ۲۴ ویژگی موجک (۲ ویژگی آماری برای ۴ ضریب در ۳ سطح موجک)، ۳۲ ویژگی ماتریس هم‌رویدادی (۸ ویژگی آماری در ۴ جهت (۰، ۴۵، ۹۰ و ۱۳۵درجه)) برای هر یک از انواع بیماری‌ها استخراج گردید.

گام ششم: انتخاب ویژگی‌های مهم با استفاده از PCA^1 همان‌طور که در مرحله قبل ذکر گردید تعداد ۷۰ ویژگی برای هر تصویر استخراج شد. به علت افزایش فضای ورودی برای مدل طبقه‌بندی می‌بایست بردار ویژگی‌ها را کاهش داد. روش آنالیز

1. Principal component analysis

$$Y_n = w_0 + \sum_{j=1}^L w_j \cdot f(w_{0j} + \sum_{i=1}^{33} w_{ij} x_i) \quad (\text{رابطه ۳})$$

که در رابطه فوق w وزن‌های لایه‌های مختلف شبکه، Y مقدار خروجی شبکه، x پارامترهای ورودی شبکه و f تابع انتقال لایه‌های پنهان شبکه می‌باشد.

پس از مشخص شدن مقدار خروجی شبکه برای هر ذره می‌بایست مقدار خطای بین خروجی شبکه و مقدار واقعی را محاسبه نمود که در واقع مقدار خطا همان مقدار هزینه برای هر ذره می‌باشد. در این مطالعه جذر میانگین مربع خطا (RMSE) به عنوان تابع هزینه هر ذره انتخاب شده است و به صورت زیر تعریف می‌گردد.

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (X_n - Y_n)^2} \quad (\text{رابطه ۴})$$

که در روابط فوق N تعداد الگوهای آموزش، Y مقادیر پیش‌بینی و X مقادیر واقعی است.

گام ششم: تعیین مقادیر x_{pbest} و x_{gbest} مجموعه ذرات.

پس از مشخص شدن مقدار هزینه یک ذره در تکرار فعلی الگوریتم، این مقدار با مقدار هزینه‌های به دست آمده در تکرارهای قبلی الگوریتم مقایسه می‌شود و بردار موقعیتی که به ازای آن کمترین مقدار هزینه حاصل شده است به عنوان x_{pbest} آن ذره تعیین می‌گردد. از طرفی با مقایسه مقدار هزینه کلیه ذرات از اولین تکرار تا تکرار فعلی الگوریتم، بردار موقعیتی که به ازای آن کمترین مقدار هزینه حاصل می‌شود به عنوان x_{gbest} مجموعه ذرات تعیین می‌گردد.

گام هفتم: بررسی معیار توقف.

معیار توقف به دو صورت در نظر گرفته می‌شود. یکی اینکه تعداد تکرارهای مشخصی برای آموزش توسط الگوریتم در نظر گرفته شده و با رسیدن به آن تکرار، روند آموزش متوقف می‌شود و یا اینکه مقداری برای تابع هزینه مشخص شده و با رسیدن به آن مقدار، الگوریتم متوقف می‌شود. حال اگر معیار توقف برآورده نشد به گام ۳ بازگشته و روند فوق تا گام ۷ ادامه پیدا می‌کند و اگر معیار توقف برآورده شود مقدار x_{gbest} به عنوان پاسخ نهایی الگوریتم در نظر گرفته می‌شود.

مرحله سوم: آموزش شبکه عصبی با استفاده از الگوریتم LM

گام اول: تعیین وزن‌های اولیه شبکه

پاسخ نهایی که توسط الگوریتم PSO در مرحله قبل به دست آمد به عنوان وزن‌های اولیه شبکه در نظر گرفته می‌شود.

گام دوم: محاسبه تابع هزینه

است. که در این مطالعه از شبکه‌های مختلف با یک و دو لایه پنهان استفاده شده است و تعداد ۳ تا ۵ نورون نیز برای هر یک از این لایه‌ها در نظر گرفته شد. برای نورون‌های لایه‌های پنهان شبکه، تابع انتقال‌های تانژانت هایپربولیک و سیگموئید و برای لایه‌ی آخر، تابع انتقال خطی انتخاب گردید. در نتیجه برای دستیابی به بهترین مدل شبکه عصبی، ۲۴ معماری مختلف از شبکه عصبی مورد استفاده قرار گرفته شد.

گام دوم: انتخاب بردار موقعیت و سرعت اولیه ذرات به صورت تصادفی

در الگوریتم PSO هر ذره دارای دو بردار موقعیت و سرعت می‌باشد که در هر تکرار آموزش بروزرسانی می‌گردد. مولفه‌های بردار موقعیت هر ذره همان پاسخ بهینه مساله مورد نظر می‌باشد که در این مطالعه مولفه‌های بردار موقعیت هر ذره همان وزن‌های شبکه عصبی می‌باشد. در تکرار نخست الگوریتم PSO، مقادیر بردارهای سرعت و موقعیت هر ذره به صورت تصادفی انتخاب می‌گردد.

گام سوم: بروز رسانی بردار سرعت هر یک از ذرات

در هر تکرار الگوریتم PSO، بردار سرعت هر ذره با استفاده از رابطه ۱ بروز رسانی می‌گردد.

(رابطه ۱)

$$v_i^t = \omega v_i^{t-1} - r_1 c_1 (x_{pbesti} - x_i^{t-1}) + r_2 c_2 (x_{gbest} - x_i^{t-1})$$

که t شاخصه تکرار، ω پارامتر وزن اینرسی، v_i^{t-1} و x_i^{t-1} به

ترتیب بردار سرعت و بردار موقعیت ذره i ام در تکرار $t-1$ می‌باشند. r_1 و r_2 اعداد تصادفی بین $[0,1]$ هستند و c_1 و c_2 به ترتیب ضرایب شتاب و شناسایی می‌باشند. لازم به ذکر است که سرعت اولیه ذرات صفر در نظر گرفته شده است. x_{pbest} بهترین موقعیتی است که ذره تاکنون بدست آورده است و x_{gbest} بهترین موقعیتی است که کل ذرات تاکنون به دست آورده‌اند.

گام چهارم: بروزرسانی بردار موقعیت هر یک از ذرات.

از رابطه ۲ برای بروزرسانی بردار موقعیت ذرات استفاده می‌گردد.

$$x_i^t = x_i^{t-1} + v_i^t \quad (\text{رابطه ۲})$$

گام پنجم: محاسبه تابع هزینه هر یک از ذرات

در الگوریتم PSO هر ذره دارای یک بردار موقعیت و سرعت و مقدار هزینه می‌باشد. همان‌طور که بیان گردید مولفه‌های بردار موقعیت هر ذره همان وزن‌های شبکه می‌باشند. حال با مشخص بودن این بردار می‌توان به ازای هر الگوی آموزش ورودی به شبکه، خروجی شبکه را محاسبه نمود. در شبکه‌های عصبی MLP خروجی شبکه با استفاده از رابطه زیر محاسبه می‌گردد.

که در روابط فوق N تعداد داده‌ها، Y_i مقادیر پیش‌بینی و X_i مقادیر اندازه‌گیری شده است. \bar{X} و \bar{Y} به ترتیب میانگین داده‌های اندازه‌گیری شده و پیش‌بینی شده است.

گام دوم: ارائه مدلی مناسب و مطمئن پس از اطمینان از عملکرد سامانه پیشنهادی در طبقه‌بندی، می‌توان از آن به عنوان ابزاری مناسب برای تشخیص بیماری برگ درخت سیب استفاده نمود.

نتایج و بحث

اولین مرحله برای استفاده از سامانه پیشنهادی، آماده‌سازی داده‌های اندازه‌گیری شده می‌باشد که در بخش قبل به صورت کامل ارائه گردید. مرحله‌ی بعدی انتخاب معماری شبکه عصبی می‌باشد، برای دستیابی به بهترین مدل شبکه عصبی، ۲۴ معماری مختلف از شبکه عصبی مورد استفاده قرار گرفت. پس از انتخاب معماری شبکه عصبی می‌بایست شبکه مورد نظر با استفاده از الگوریتم PSO آموزش داده شود تا مقادیر اولیه وزن-های شبکه به دست آیند. در ابتدا می‌بایست پارامترهای الگوریتم PSO انتخاب شود که در این تحقیق این پارامترها مطابق با جدول ۱ انتخاب گردیدند.

جدول ۱. پارامترهای مختلف الگوریتم بهینه‌سازی ازدحام ذرات

مقدار	پارامتر
۳۰۰	تعداد تکرار
۱۰۰	تعداد ذرات
۲	ضریب شتاب (C_1)
۲	ضریب شناسایی (C_2)
۰/۹۹	وزن اینرسی نهایی (ω_{max})
۰/۲	وزن اینرسی اولیه (ω_{min})

همان‌طور که در جدول فوق مشاهده می‌شود تعداد ۱۰۰ ذره برای الگوریتم PSO در نظر گرفته شده است، که هر ذره دارای یک بردار موقعیت و سرعت می‌باشد. بردار موقعیت هر ذره، وزن‌های شبکه عصبی می‌باشد که به طور مثال برای شبکه با معماری ۱-۳-۳-۳، بردار موقعیت هر ذره دارای ۱۱۸ بعد می‌باشد که این مقادیر در ابتدا (نقطه شروع) به صورت تصادفی انتخاب می‌گردند. داده‌های ورودی از طریق لایه اول وارد شبکه شده و پس از عبور از لایه‌های مختلف شبکه، خروجی شبکه حاصل می‌شود. حال با داشتن خروجی شبکه و همچنین مقدار خروجی اندازه‌گیری شده، مقدار خطا (RMSE) محاسبه می‌شود. پس از محاسبه خطا، x_{pbest} و x_{gbest} ذرات به دست می‌آید

به منظور محاسبه خطای شبکه از میانگین مربع خطا (MSE) استفاده شد که به صورت زیر تعریف می‌گردد.

$$E = \frac{1}{N} \sum_{n=1}^N (Y_n - X_n)^2 \quad (\text{رابطه ۵})$$

که در رابطه فوق E مقدار خطا یا همان تابع هزینه شبکه می‌باشد و X و Y به ترتیب مقدار خروجی شبکه و مقدار واقعی می‌باشند.

گام سوم: بروزرسانی وزن‌های شبکه با استفاده از الگوریتم LM در واقع آموزش شبکه عصبی همان تنظیم وزن‌های شبکه می‌باشد که برای این منظور می‌بایست وزن‌ها به گونه‌ای تنظیم گردند که مقدار خطای رابطه ۵ حداقل شود. تنظیم وزن‌های شبکه با استفاده از رابطه زیر صورت می‌گیرد.

$$\Delta w = -\eta \frac{\partial E}{\partial w} \quad (\text{رابطه ۶})$$

در رابطه فوق η پارامتر نرخ یادگیری و $\partial E / \partial w$ مشتق جزئی تابع E برحسب وزن w است.

یکی از الگوریتم‌های دقیق و پرکاربرد که به صورت گسترده به منظور تنظیم وزن‌های شبکه مورد استفاده قرار می‌گیرد الگوریتم LM می‌باشد. در این مطالعه نیز از این الگوریتم جهت آموزش شبکه عصبی استفاده گردیده است.

گام چهارم: بررسی معیار توقف

اگر معیار توقف برآورده شد وزن‌های به دست آمده در گام ۳ به عنوان پاسخ نهایی الگوریتم در نظر گرفته می‌شود و اگر معیار توقف برآورده نشود به گام ۲ بازگشته و روند فوق تا گام ۴ ادامه پیدا می‌کند.

مرحله چهارم: پس پردازش داده‌ها

گام اول: بررسی عملکرد شبکه با داده‌های آزمون پس از به دست آمدن پاسخ نهایی شبکه، عملکرد آن در طبقه‌بندی توسط داده‌های آزمون مورد ارزیابی قرار داده می‌شود. در این تحقیق جهت ارزیابی دقت مدل پیشنهادی از دو شاخص آماری، ضریب همبستگی CC^2 و RMSE استفاده شده است.

$$CC = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2 (Y_i - \bar{Y})^2}} \quad (\text{رابطه ۷})$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (X_n - Y_n)^2} \quad (\text{رابطه ۸})$$

1. Mean Square Error
2. Correlation Coefficient

شده است ارائه شده است. ستون دوم مربوط به معماری شبکه عصبی می‌باشد که برای مثال معماری ۱-۵-۳-۳ مربوط به شبکه‌ای با ۳۳ ورودی و ۱ خروجی می‌باشد و همچنین دارای دو لایه پنهان است که لایه پنهان اول دارای ۳ نورون و لایه پنهان دوم دارای ۵ نورون می‌باشد. ستون سوم جدول مربوط به تابع انتقال نورون‌های لایه‌های مختلف شبکه است به عنوان مثال عبارت $tansig-tansig-purelin$ به این معنی است که نورون‌های لایه پنهان اول و دوم دارای تابع انتقال تانژانت سیگموئید می‌باشند و همچنین تابع انتقال نورون لایه آخر از نوع خطی است. ستون چهارم جدول، مربوط به تعداد تکرارهای الگوریتم LM برای آموزش شبکه عصبی می‌باشد و ستون‌های پنجم و ششم ضریب همبستگی و جذر میانگین مربعات خطای مربوط به داده‌های آموزش را نشان می‌دهد. ستون‌های هفتم و هشتم مربوط به ضریب همبستگی و جذر میانگین مربعات خطای داده‌های آزمون است.


که با مشخص شدن این مقادیر و با استفاده از روابط (۱) و (۲) مقادیر بردار سرعت و بردار مکان هر ذره بروزرسانی می‌شود و این روند ادامه پیدا می‌کند تا معیار توقف حاصل گردد. پس از طی مراحل فوق وزن‌های شبکه که همان بردار موقعیت (x_{gbest}) بهترین ذره می‌باشد حاصل می‌گردد. در مرحله بعدی می‌بایست شبکه عصبی را با استفاده از الگوریتم LM آموزش داد و چون وزن‌های اولیه توسط الگوریتم PSO به دست آمده و نزدیک به جواب بهینه است شبکه طی تکرارهای کمی به جواب بهینه سراسری رسیده و مقادیر وزن‌های نهایی حاصل می‌شود. حال در مرحله پایانی پس از اینکه آموزش شبکه عصبی توسط داده‌های آموزش به اتمام رسید عملکرد آن در طبقه‌بندی بیماری برگ درخت سیب توسط داده‌های آزمون مورد ارزیابی قرار می‌گیرد.

در جدول ۲، ۱۰ معماری برتر از ۲۴ معماری مختلف شبکه عصبی که توسط الگوریتم ترکیبی PSO-LM آموزش داده

جدول ۲. شاخص‌های آماری شبکه‌های مختلف.

ردیف	معماری شبکه	تابع انتقال لایه‌ها	تکرار	داده‌های آموزش		داده‌های آزمون	
				RMSE	CC	RMSE	CC
۱	۳۳-۳-۳-۱	tansig-tansig-purelin	۱۴۰	۰/۹۹۳	۰/۹۹۲	۰/۹۹۲	
۲	۳۳-۴-۵-۱	sig-sig-purelin	۱۸۰	۰/۹۹۵	۰/۰۸۲	۰/۹۹۵	
۳	۳۳-۳-۱	sig-purelin	۲۰۰	۰/۹۸۵	۰/۱۳۵	۰/۹۸۴	
۴	۳۳-۴-۱	sig-purelin	۱۳۰	۰/۹۸۲	۰/۱۴۹	۰/۹۸۲	
۵	۳۳-۳-۱	tansig-purelin	۱۰۰	۰/۹۸۵	۰/۱۳۸	۰/۹۸۲	
۶	۳۳-۴-۱	tansig-purelin	۶۰	۰/۹۸۴	۰/۱۴۳	۰/۹۸۲	
۷	۳۳-۵-۱	sig-purelin	۳۳۰	۰/۹۹۵	۰/۰۷۸	۰/۹۹۵	
۸	۳۳-۳-۴-۱	sig-purelin	۲۰۰	۰/۹۸۳	۰/۱۴۳	۰/۹۸۱	
۹	۳۳-۴-۳-۱	tansig-tansig-purelin	۸۰	۰/۹۹۹	۰/۱۱۲	۰/۹۷۹	
۱۰	۳۳-۵-۱	tansig-purelin	۲۰۰	۰/۹۹۵	۰/۰۸۳	۰/۹۷۷	

که در جدول ۲ مشاهده می‌شود، تعداد ۱۴۰ تکرار برای الگوریتم LM در به دست آوردن وزن‌های بهترین شبکه در نظر گرفته شد که در شکل ۵ مقادیر خطای (RMSE) در طی تکرارهای مختلف ارائه شده است.



شکل ۵. مقادیر خطای شبکه (RMSE) طی تکرارهای مختلف الگوریتم PSO-LM

پس از آموزش شبکه‌های مختلف توسط الگوریتم ترکیبی و مقایسه نتایج آنها، مشاهده شد که شبکه عصبی با معماری ۱-۳-۳-۳ با تابع انتقال تانژانت سیگموئید در لایه‌های پنهان و تابع انتقال خطی در لایه خروجی، نسبت به دیگر شبکه‌ها عملکرد مناسب‌تری دارد.

همانطور که قبلاً ذکر گردید انتظار می‌رود با پیش‌آموزش شبکه عصبی توسط الگوریتم PSO، آموزش شبکه توسط الگوریتم LM با تکرارهای کمی صورت گیرد. مطابق آنچه که در جدول ۱ مشاهده می‌شود تعداد ۳۰۰ تکرار برای الگوریتم PSO، در به دست آوردن وزن‌های شبکه‌های عصبی در نظر گرفته شد که شکل ۵ نشان‌دهنده مقادیر خطای (RMSE) در طی تکرارهای مختلف برای بهترین شبکه عصبی می‌باشد. همچنین همان‌طور

طور که در مطالب پیشین بیان شد تعداد نمونه‌های برگ‌گی مورد بررسی ۳۲۰ عدد بود که ۱۶۰ عدد از این برگ‌ها آلوده به بیماری آلترناریا، ۹۲ عدد آلوده به بیماری لکه سیاه سب و ۶۸ عدد آلوده به آفت مینوز بودند. اعدادی که در جدول ۳ مشاهده می‌شود مربوط به همین ارقام می‌باشد و بیان می‌کند که هر مدل توانسته است چه تعداد از نمونه‌های بیماری را به درستی تشخیص دهد. به عنوان نمونه مدل شبکه عصبی ترکیبی توانسته است از ۱۶۰ نمونه مربوط به بیماری آلترناریا تعداد ۱۵۹ نمونه را به درستی تشخیص دهد و ۱ نمونه را به اشتباه به عنوان بیماری لکه سیاه تشخیص دهد.

در جدول ۳ میزان توانایی شبکه عصبی آموزش یافته توسط الگوریتم ترکیبی PSO-LM در تشخیص بیماری‌های درخت سیب مورد ارزیابی قرار گرفته است. همچنین در این جدول عملکرد این مدل در مقایسه با مدل‌های رگرسیون بردار پشتیبان^(۱) (SVR) با تابع کرنل پایه شعاعی^(۲) (RBF) و تابع کرنل چندجمله‌ای^(۳) و مدل ANN که توسط همین داده‌ها در مطالعه‌ای جداگانه برای تشخیص بیماری درخت سیب بکار برده شده‌اند مورد ارزیابی قرار گرفت (Omrani et al., 2014). همان

1. Support Vector Regression
2. Radial basis function
3. polynomial

جدول ۳. ماتریس اغتشاش حاصل از مدل‌های مختلف

ANN (PSO-LM)							
واقعی	۰	۱	۲	۳	۴	مجموع	درصد صحیح
۱	۰	۱۵۹	۱	۰	۰	۱۶۰	۹۹
۲	۰	۱	۹۱	۰	۰	۹۲	۹۹
۳	۰	۰	۱	۶۷	۰	۶۸	۹۹
مجموع	۰	۱۶۰	۹۳	۶۷	۰	۳۲۰	-
SVR(RBF)							
واقعی	۰	۱	۲	۳	۴	مجموع	درصد صحیح
۱	۰	۱۵۹	۱	۰	۰	۱۶۰	۹۹
۲	۰	۰	۹۲	۰	۰	۹۲	۱۰۰
۳	۰	۰	۰	۶۸	۰	۶۸	۱۰۰
مجموع	۰	۱۵۹	۹۳	۶۸	۰	۳۲۰	-
SVR(poly)							
واقعی	۰	۱	۲	۳	۴	مجموع	درصد صحیح
۱	۲	۱۴۹	۹	۰	۰	۱۶۰	۹۳
۲	۰	۴۲	۵۰	۰	۰	۹۲	۵۴
۳	۲	۰	۲۳	۶۸	۰	۶۸	۶۶
مجموع	۲	۱۹۱	۸۲	۶۸	۰	۳۲۰	-
ANN							
واقعی	۰	۱	۲	۳	۴	مجموع	درصد صحیح
۱	۴۴	۸۳	۳۳	۰	۰	۱۶۰	۵۲
۲	۰	۲۲	۵۰	۲۰	۰	۹۲	۵۴
۳	۰	۰	۱۱	۴۴	۱۳	۶۸	۶۵
مجموع	۴۴	۱۰۵	۹۴	۶۴	۱۳	۳۲۰	-

همچنین در جدول ۴ شاخص‌های ضریب تشخیص (R^{2f}) و RMSE مربوط به مدل پیشنهادی و مدل‌های SVR-RBF،

همان‌طور که در جدول فوق مشاهده می‌شود مدل پیشنهادی در مقایسه با دو مدل SVR-poly و ANN دارای عملکرد بهتری است و در مقایسه با مدل SVR-RBF عملکرد تقریباً مشابهی دارد.

SVR-poly و ANN مورد مقایسه قرار گرفته است.

جدول ۴. شاخص‌های آماری مدل‌های مختلف

مدل	داده‌های آموزش		داده‌های آزمون	
	R ²	RMSE	R ²	RMSE
ANN (PSO-LM)	۰/۹۸۷	۰/۰۹۲	۰/۹۸۵	۰/۰۹۹
SVR-RBF	۰/۹۸۷	۰/۱۳	۰/۹۶۳	۰/۲
SVR-Poly	۰/۸۸۹	۰/۳۹	۰/۸۵۴	۰/۴۲
ANN	۰/۸۲۸	۰/۵۶	۰/۸۲۳	۰/۵۳

در جدول فوق مشاهده می‌شود شاخص R² مدل پیشنهادی برای داده‌های آزمون برابر ۰/۹۸۵ می‌باشد که این مقدار از مقادیر R² بدست آمده از مدل‌های دیگر بیشتر می‌باشد. همچنین شاخص RMSE مدل پیشنهادی برای داده‌های آزمون برابر ۰/۰۹۹ است که این مقدار در مقایسه با مقادیر سایر مدل‌ها کمتر می‌باشد. در نتیجه می‌توان گفت که مدل پیشنهادی عملکرد مناسب‌تری نسبت به سایر مدل‌ها در تشخیص نوع بیماری برگ درخت سیب دارد.

نتیجه‌گیری کلی

از آنجائیکه در سال‌های اخیر همواره ایران یکی از بزرگ‌ترین کشورهای تولید کننده سیب در جهان می‌باشد، تشخیص و جلوگیری از تشدید بیماری‌های درخت سیب از اهمیت بالایی برخوردار است. در این راستا، در تحقیق حاضر یک سامانه جدید متشکل از روش پردازش تصویر و مدل ترکیبی شبکه عصبی برای تشخیص بیماری‌های شایع برگ درخت سیب به نام‌های لکه سیاه سیب، آلترناریا و آفت مینوز توسعه داده شد. به

منظور استفاده از یک مدل دقیق طبقه‌بندی، در این سامانه از مدل ترکیبی شبکه عصبی استفاده گردید که در این مدل برای آموزش شبکه عصبی از الگوریتم ترکیبی PSO-LM استفاده شد. از آنجائیکه در اولین مرحله آموزش ANN، وزن‌های اولیه شبکه به صورت تصادفی انتخاب می‌شوند این امکان وجود دارد که اگر این وزن‌ها از پاسخ بهینه دور باشند، شبکه با سرعت کمتری به همگرایی برسد یا اینکه در مسیر آموزش در دام حداقل‌های محلی قرار گیرد، که در این مطالعه به منظور رفع این مشکل از الگوریتم PSO برای پیش‌آموزش ANN و به دست آوردن وزن‌های اولیه شبکه استفاده گردید.

نتایج نشان داد که استفاده از الگوریتم ترکیبی PSO-LM در آموزش شبکه بسیار مفید است زیرا سبب می‌شود تا شبکه با تعداد تکرار کمی به پاسخ بهینه سراسری دست یابد. همچنین مقایسه نتایج این مدل ترکیبی با سایر مدل‌های هوش مصنوعی در تشخیص بیماری نشان داد که مدل ترکیبی شبکه عصبی براساس شاخص‌های R² = ۰/۹۸۵ و RMSE = ۰/۰۹۹ بدست آمده برای داده‌های آزمون نسبت به دیگر مدل‌های طبقه‌بندی از دقت بالاتری برخوردار است.

در نهایت براساس نتایج به دست آمده از این تحقیق می‌توان بیان کرد که سامانه پیشنهادی را می‌توان به عنوان یک ابزار دقیق، کارآمد، قابل دسترس و با کاربری آسان‌تر را به منظور تشخیص به‌هنگام بیماری‌های برگ درخت سیب در باغ‌های کشور استفاده کرد تا نه تنها جایگاه ایران در تولیدات سیب در جهان حفظ شود بلکه با کاهش خسارات ناشی از بیماری، این جایگاه را حتی ارتقا بخشید.

REFERENCES

- Asraf, H. M., Nooritawati, M. T., Shah Rizam, M. S. B. (2012). A Comparative Study in Kernel-Based Support Vector Machine of Oil Palm Leaves Nutrient Disease, *Journal of Procedia Engineering*, 41, 1353–1359.
- Billah, M., Miah, M. B. A., Hanifa, A. and Ruhul Amin, M. d. (2015). Adaptive Neuro Fuzzy Inference System based Tea Leaf Disease Recognition using Color Wavelet Features, *Journal of Communications on Applied Electronics*, 3(5), 1–4.
- Eberhart, R. and Kennedy, J. (1995). A new optimizer using particle swarm theory, *Journal of IEEE Service Center*, 39–43.
- Fang, J., Zhang, C., Wang, S. (2008). Application of genetic algorithm (GA) trained artificial neural to identify tomatoes with physiological, *Journal of Computer and Computing Technologies in Agriculture*, 259, 1103-1111.
- Food and Agriculture Organization. (2013). *Statistics: Crops (Production) in FAO*. Retrieved January 12, 2013, From <http://www.fao.org/faostat/en/#data/QC>
- Kumar, A., Lee, W. S., Ehsani, R. J., Albrigo, G., Yang, C., Mangan, R. L. (2012). Citrus greening disease detection using aerial hyperspectral and multispectral imaging techniques, *Journal of Applied Remote Sensing*, 6, 1–22.
- Loutfi, A., Coradeschi, S., Mani, G.K., Shankar, P. Rayappan, J.B. (2015). Electronic noses for food quality: a review. *Journal of Food Engineering*, 144, 103–111.
- Mahlein, A. K., Steiner, U., Hillnhütter, C., Dehne, H. W., Oerke, E. C. (2012). Hyperspectral imaging for small-scale analysis of symptoms caused by different sugar beet diseases, *Journal of Plant Methods*, 1–13.
- Massimo, F. R, Daciana, I., Clarkson, J. P., Covington,

- J. A. (2016). Early identification of potato storage disease using an array of metal-oxide based gas sensors, *Journal of Postharvest Biology and Technology*, 116, 50–58.
- Omrani, E. (2013). Plant Diseases Detection Using Image Processing Technique. M. Sc. Thesis, University of Tehran, College of Agriculture and Natural Resources. (In Farsi)
- Omrani, E., Khoshnevisan, B., Shamshirband, S., Saboohi, H., Anuar, N. B., Nasir, M. H. N. M. (2014). Potential of radial basis function-based support vector regression for apple disease detection, *Journal of Measurement*, 55, 512–519.
- Pan, L., Zhang, W., Zhu, N., Mao, Sh., Wangd, J., Tu, K. (2014). Early detection and classification of pathogenic fungal disease in post-harvest strawberry fruit by electronic nose and gas chromatography–mass spectrometry, *Journal of Food Research International*, 62, 162–168.
- Tian, J., Qiuxia, H., Xiaoyi, M. A., Mingyu, H. A. N. (2012). An Improved KPCA/GA-SVM Classification Model for Plant Leaf Disease Recognition, *Journal of Computational Information Systems*, 33, 7737–7745.
- Tian, X., Wang, J. & Cui, S. (2013). Analysis of pork adulteration in minced mutton using electronic nose of metal oxide sensors. *Journal of Food Engineering*, 119(4), 744–749.
- UGA Extension. (2014). *Georgia Plant Disease Loss Estimates 2014*. AP 102-7, From <http://extension.uga.edu/publications/detail.cfm?number=AP102-7>
- Yeh, Y. H., Chung W. C., Liao, J.Y., Chung, C. L., Kuo, Y. F. and Te, L. T. (2016). Strawberry foliar anthracnose assessment by hyperspectral imaging, *Journal of Computers and Electronics in Agriculture*, 122, 1–9.
- Zhanga, Z., Hea, X., Sunb, X., Guoc, L., Wangd, J., Wangd, F. (2015). Image Recognition of Maize Leaf Disease Based on GA-SVM, *Journal of Chemical Engineering Transactions*, 46, 199–204.
- Zhang, Sh., Wu, X., You, Zh., Zhang, L. (2017). Leaf image based cucumber disease recognition using sparse representation classification, *Journal of Computers and Electronics in Agriculture*, 134, 135–141.