

مقاله پژوهشی

تشخیص سه نوع بیماری برگ انگور بر پایه پردازش تصویر با استفاده از الگوریتم بهینه‌ساز پروانه و ماشین بردار پشتیبان

محسن نجف‌آبادی^۱، داود محمدزمانی^{۲*}، محمد غلامی پرشکوهی^۳

۱ و ۲- به ترتیب: دانشجوی دکتری؛ و دانشیار گروه مهندسی بیوسیستم، واحد تاکستان، دانشگاه آزاد اسلامی، تاکستان، ایران
۳- دانشیار گروه مهندسی مکانیک، واحد شهر قدس، دانشگاه آزاد اسلامی، تهران، ایران
تاریخ دریافت: ۱۴۰۲/۱۲/۲۵؛ تاریخ پذیرش: ۱۴۰۳/۴/۱۶

چکیده

امروزه تکنیک‌های هوش مصنوعی و فناوری‌های یادگیری ماشین توانسته است شناسایی و طبقه‌بندی بیماری‌های گیاهی را آسان کند. در این پژوهش، به منظور تشخیص و طبقه‌بندی برخی بیماری‌های برگ گیاه انگور با نام‌های پوسیدگی سیاه، اسکای (زوال) و لکه برگی، پس از حذف پس زمینه از تصویر برگ‌ها و استخراج ویژگی‌های بافت و رنگ و شکل از تصاویر، از ترکیبی از طبقه‌بند ماشین بردار پشتیبان و الگوریتم بهینه‌ساز پروانه برای انتخاب مهم‌ترین ویژگی‌ها در تشخیص بیماری برگ گیاه انگور استفاده شد. نتایج صحت طبقه‌بندی برای بیماری‌های پوسیدگی سیاه، اسکای (زوال) و لکه برگی و برگ سالم به ترتیب ۱۰۰، ۱۰۰، ۱۰۰ و ۹۵ درصد و دقت طبقه‌بندی برای تشخیص کل گروه‌های بیمار و سالم ۹۸/۷۵ درصد به دست آمد. نتایج طبقه‌بندی نشان داد که توان پردازش تصویر و یادگیری ماشین در تشخیص و طبقه‌بندی برخی بیماری‌های گیاهی برگ انگور عالی است. در این پژوهش همچنین ۱۵ ویژگی بافت، رنگ و شکل به کمک الگوریتم انتخاب ویژگی بهینه‌ساز پروانه به پژوهشگران بیماری شناسی گیاهی و علوم داده معرفی شده است.

واژه‌های کلیدی

استخراج ویژگی، انتخاب ویژگی، بیماری‌های انگور، تشخیص و طبقه‌بندی، هوش مصنوعی

مقدمه

۷۴۲۷۶۵۸۳ و ۳۲۱۷۵۰۰ تن گزارش شده است. تقریباً ۳۰ درصد از تولید انگور بر اثر آفات و بیماری‌ها از بین می‌رود و بنابراین لازم است رویکرد مناسبی برای مدیریت این میزان خسارت اتخاذ شود (Roostaei et al., 2015). بیماری‌های گیاهی از جمله عوامل کاهش شدید کیفیت و کمیت تولید هستند. ارزیابی بصری گیاهان توسط ناظران زمان‌بر، پرهزینه و مستعد خطاست. ارزیابی بیماری و نگهداری گیاهان نیازمند روش‌های جدید و نوآورانه برای مقابله با چالش‌های تولید کشاورزی

انگور یکی از مهم‌ترین محصولات اقتصادی باغی از مناطق معتدل تا گرمسیری است. مطابق مدارک موجود، این گیاه در مصر حدود ۵ تا ۶ هزار سال قبل کشت می‌شده است. همه انگورهای موجود در ایران به جنس ویتیس^۱ از خانواده ویتاسه^۲ تعلق دارند. در این خانواده حداقل ۱۱ جنس و حدود ۶۰۰ گونه شناخته شده است. سطح زیر کشت انگور در دنیا و در ایران به ترتیب ۶۹۳۱۳۵۴ و ۳۱۶۰۰۰ هکتار و میزان تولید آن در دنیا و در ایران به ترتیب

<https://doi.org/10.22092/amr.2024.365272.1482>

Email: dr.dmzamani@gmail.com

*نگارنده مسئول:

1- Vitis

2- Vitaceae

یکی از روش‌های مؤثر و سازنده در مسیر حل مسائل انتخاب ویژگی و موضوع‌های مرتبط با آن، استفاده از روش‌های بهینه‌سازی فراابتکاری و الگوریتم‌های تکاملی است (Barbedo, 2018). در این زمینه، مطالعات زیادی شده است. در مطالعه‌ای در مورد طبقه‌بندی بیماری‌های برگ درخت سیب، از جمله سفیدک پودری، موزاییک، و زنگ، ۳۸ ویژگی رنگ، بافت و شکل از هر تصویر رنگی استخراج شد. سپس از الگوریتم ژنتیک^۱ و انتخاب ویژگی مبتنی بر همبستگی^۲ برای کاهش ویژگی‌ها و انتخاب ویژگی‌های ضروری استفاده شد. دقت طبقه‌بندی در این روش ۹۰ درصد بود (Kumar et al., 2020). در پژوهشی دیگر، یک روش پردازش تصویر مؤثر برای شناسایی بیماری‌های گیاهی پیشنهاد شد. در این روش، پس از حذف نویز از تصویر اولیه، از خوشه‌بندی فازی^۳ برای جداسازی قسمت مورد نظر از تصویر استفاده شد. سپس، با استفاده از هیستوگرام گرادیان‌های جهت‌دار و آنتروپی، ویژگی‌های بافت ناحیه مورد نظر استخراج شد. برای طبقه‌بندی از ترکیب یادگیری عمیق و الگوریتم فاخته^۴ استفاده شد. نتایج طبقه‌بندی در این روش تشخیص بیماری دارای دقت ۸۷ درصد بود (Cristin et al., 2020). در یک مطالعه، الگوریتم جدیدی برای تشخیص چهار بیماری برگ سیب توسعه داده شد. با استفاده از تقسیم‌بندی خودکار ناحیه بیمار با استفاده از خوشه‌بندی خودکار K-means و طبقه‌بندی ماشین بردار پشتیبان^۵ دقت ۹۱ درصد به دست آمد (Javidan et al., 2022). در زمینه بیماری‌های موجود در محصول انگور نیز تحقیقاتی شده که در جدول ۱ به بعضی از آن‌ها

است. در این راستا، حسگرها و تکنیک‌های تصویربرداری ظرفیت زیادی در ایجاد رویکردهای جدید برای تعاملات آسیب‌شناسی گیاهی و تشخیص بیماری‌های گیاهی نشان داده‌اند (Asefpour Vakilian & Massah, 2017). پیشرفت در فناوری کشاورزی فرصت‌هایی را برای تشخیص و طبقه‌بندی غیرمخرب بیماری‌های گیاهی ایجاد کرده است. پیشرفت‌های زیادی در بینایی ماشین وجود دارد که به شناسایی و طبقه‌بندی بیماری‌های گیاهی به طور خودکار کمک می‌کند (Mohammadzamani et al., 2020). یک طبقه‌بندی‌کننده، گیاه سالم یا ناسالم را با ویژگی‌های داده شده (رنگ، شکل و بافت) به عنوان ورودی تشخیص خودکار، تشخیص می‌دهد. دقت، پارامتر اصلی است که هر پژوهشگر برای محاسبه عملکرد مدل از آن استفاده می‌کند (Javidan et al., 2023; Mohammadzamani et al., 2023). طبقه‌بندی‌کننده در درجه اول به ویژگی‌هایی که استخراج می‌شوند بستگی دارد. بنابراین، استخراج ویژگی نقش کلیدی در شناسایی بیماری‌ها دارد. انتخاب مناسب ویژگی‌های صحیح منجر به دقت تشخیصی بالا می‌شود. انتخاب ویژگی را می‌توان به عنوان فرآیند شناسایی ویژگی‌های مرتبط و حذف ویژگی‌های غیرمرتبط و تکراری با هدف مشاهده زیرمجموعه‌ای از ویژگی‌ها تعریف کرد که مسئله را به خوبی و با حداقل کاهش درجه کارایی تشریح می‌کنند (Abdulridha et al., 2020). در فرآیند انتخاب ویژگی ابتدا باید تمام ویژگی‌های موجود مسئله استخراج و پس از آن ویژگی‌های مناسب انتخاب شود.

1- Genetic Algorithm

3- Fuzzy C-Means Clustering

5- Fuzzy C-Means Clustering

2- Correlation Based Feature Selection

4- Deep Neural Network Based Rider-Cuckoo

مجموعه داده‌های خود را ایجاد کنند. در این پژوهش، از مجموعه داده‌های جمع‌آوری شده از تاکستان‌های استان قزوین شامل یک کلاس برگ سالم و سه کلاس برگ بیمار شامل بیماری‌های پوسیدگی سیاه^۲، اسکای (زوال)^۳ و لکه برگی^۴، مجموعه‌ای از تصاویر تهیه گردید. تعداد تصاویر برای هر گروه ۱۰۰ عدد بود و در مجموع ۴۰۰ تصویر جمع‌آوری شد. پس از آن ترکیبی از الگوریتم بهینه‌ساز پروانه و ماشین بردار پشتیبان به منظور تشخیص و طبقه‌بندی بیماری‌های رایج برگ انگور توسعه داده شد. مؤثرترین ویژگی‌ها در شناسایی بیماری‌های گیاه انگور نیز معرفی شدند.

و محدودیت‌های موجود در آن‌ها اشاره شده است. نتایج بررسی‌ها نشان می‌دهد که ابزارها و داده‌های موجود و روش‌های تجزیه و تحلیل داده‌ها به منظور تشخیص بیماری‌های گیاهی از جمله انگور متفاوت است و بنابراین نتایج به دست آمده یکسان نخواهند بود. به منظور توسعه طبقه‌بندی‌کننده‌های تصویری دقیق برای تشخیص بیماری‌های گیاهی، به مجموعه داده‌های معتبر از تصاویر گیاه بیمار و سالم نیاز است. تا همین اواخر، مجموعه زیادی از داده‌های کشاورزی وجود نداشت و حتی مجموعه‌های داده کوچک‌تر به طور رایگان در دسترس نبودند. بنابراین، پژوهشگران مجبور بودند

جدول ۱- تحقیقاتی در زمینه تشخیص و طبقه‌بندی بیماری‌های موجود در انگور

Table 1- Research in the field of diagnosis and classification of diseases in grape crops

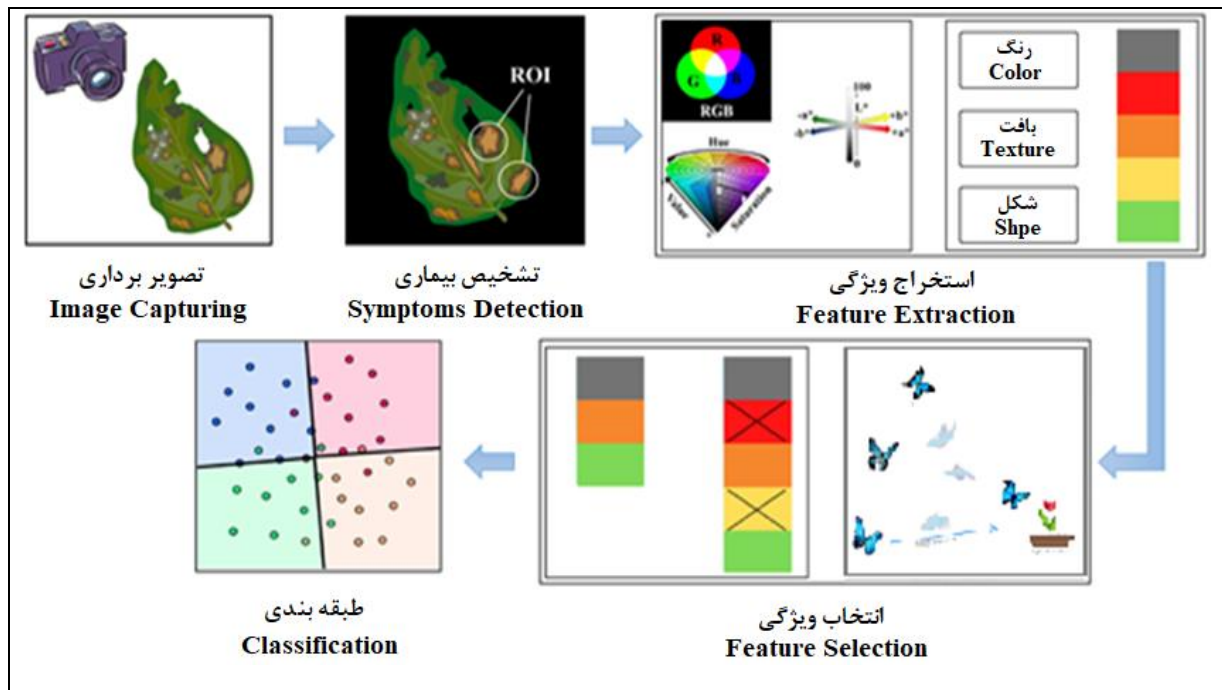
بیماری‌ها Diseases	تعداد تصاویر Number of images	روش تشخیص Detection Methods	دقت Accuracy	محدودیت‌ها Limitation	منبع References
Downy, Powdery	350	K-Means Clustering - SVM Classifier	88.89%	تعداد کم بیماری‌ها، دقت تشخیص کم، تمام ویژگی‌ها را از تصویر استخراج نمی‌کند، مؤثرترین ویژگی‌ها را انتخاب نمی‌کند، بیماری‌های رایج در برگ انگور مورد مطالعه قرار نگرفته است	Padol <i>et al.</i> (2016)
Black Rot, Black Measles, and Leaf Blight	600	SVM Classifier	93%	تمام ویژگی‌ها را از تصاویر استخراج نمی‌کند، مؤثرترین ویژگی‌ها را انتخاب نمی‌کند.	Jaisakthi <i>et al.</i> (2019)
Black Rot, Black Measles, and Isariopsis	600	AlexNet GoogLeNet ResNet-18	95.65% 92.29% 89.49%	استفاده از روش جعبه سیاه که زمان بر است، مؤثرترین ویژگی‌ها را انتخاب نمی‌کند.	Javidan <i>et al.</i> (2023)
Black rot, Esca measles, Leaf spot	380	GAN - CNN	98.70%	استفاده از روش جعبه سیاه که زمان بر است، مؤثرترین ویژگی‌ها را انتخاب نمی‌کند.	Liu <i>et al.</i> (2020)
Black Rot, Black Measles, Leaf Blight, and Mites	600	DR-IACNN	81.1%	دقت تشخیص پایین، از روش جعبه سیاه یادگیری عمیق استفاده می‌کند، که وقت‌گیر است، مؤثرترین ویژگی‌ها را انتخاب نمی‌کند.	Xie <i>et al.</i> (2020)

تشخیص نشانه‌های بیماری با استفاده از خوشه‌بندی (K -means، ۳) استخراج ویژگی‌های بافت، رنگ و شکل از تصویر، (۴) انتخاب ویژگی با استفاده از الگوریتم بهینه‌ساز پروانه و (۵) طبقه‌بندی بر اساس ماشین بردار پشتیبان. روش پیشنهادی در ادامه شرح داده شده است.

مواد و روش‌ها

الگوریتم پیشنهادی

روش پیشنهادی اعمال شده به منظور تشخیص و طبقه‌بندی بیماری‌های برگ گیاه انگور و برگ سالم، در این مطالعه در شکل ۱ نشان داده شده است. این مراحل عبارتند از (۱) ایجاد پایگاه تصویر، (۲) حذف پس‌زمینه و تقسیم‌بندی تصویر برای



شکل ۱- مراحل مختلف تشخیص و طبقه‌بندی بیماری‌های برگ انگور به کار رفته در این پژوهش

Fig. 1- Different stages of diagnosis and classification of grape leaf diseases used in this research

ایجاد پایگاه تصاویر

در این مطالعه مجموعه مجموعه‌ای از داده از تصاویر برگ‌های انگور شامل: (بیماری‌های پوسیدگی سیاه، اسکای (زوال) و لکه برگی و برگ‌های سالم) توسط یک مدل متداول گوشی تلفن همراه سامسونگ (مدل A32) مجهز به دوربین ۶۴ مگاپیکسلی و از فاصله ۳۰ سانتی‌متری تهیه و آنالیز شده است (Arun Pandian & Gopal, 2019). مجموعه داده به دست آمده شامل ۴۰۰ برگ گیاه انگور است که به ۴ طبقه ۱۰۰ عددی برای هر گروه دسته‌بندی شدند. پایگاه داده تصاویر به دو پایگاه داده آموزشی و پایگاه داده آزمون تقسیم شد. پایگاه داده آموزشی شامل ۸۰ درصد از پایگاه داده تصاویر یعنی ۳۲۰ تصویر و پایگاه داده آزمون شامل ۲۰ درصد باقی‌مانده از پایگاه داده تصویر یعنی ۸۰ تصویر است. چارچوب پیشنهادی روی سیستم عامل ویندوز ۱۰ با پردازنده 2.20 @ Intel®Core™ i5-8130U

گیگاهرتز-۲/۲۱ گیگاهرتز با رم ۸ گیگابایت پیاده‌سازی شد. الگوریتم پیشنهادی به منظور تشخیص و طبقه‌بندی بیماری‌های انگور با استفاده از نرم‌افزار Matlab2018 پیاده‌سازی شده است.

تشخیص نشانه‌های بیماری

روش‌های مختلفی برای تقسیم تصاویر به مناطق مختلف وجود دارد. برخی از این روش‌ها مانند آستانه‌گذاری، ساده و برخی پیشرفته‌تر هستند مانند روش تقسیم‌بندی تصویر در حوزه فرکانس. از جمله روش‌های قابل اعتماد با رویکرد ساده برای آستانه‌گذاری، روش K-means و الگوریتم Otsu است. در این مطالعه، از روش خوشه‌بندی خودکار K-means برای تعیین ناحیه هدف بیماری استفاده شد (Chen et al., 2018). در این روش، برای جداسازی خودکار بیماری از آستانه‌گذاری رنگ به همان قسمت سالم برگ استفاده شد. بنابراین، خوشه‌ای که سبز است حذف شد. برای این منظور

طریق تکنیک‌های الگوریتم الگوی باینری محلی، فیلتر گابور و ماتریس هم‌رخداد تصاویر به دست آورد. ویژگی‌های رنگ اساساً ویژگی‌های بصری شیء را مشخص می‌کند. برای مثال، هیستوگرام رنگ و ماتریس همزمانی رنگ مدل رنگ را در میانگین، چولگی و انحراف معیار تعریف می‌کنند.

ویژگی‌های شکل تصویر را بر اساس کانتور جسم نشان می‌دهد. این‌ها را می‌توان با جهت‌گیری، مساحت، خروج از مرکز و... اندازه‌گیری کرد. ترکیبی از ویژگی‌های رنگ، بافت و شکل می‌تواند عملکرد سیستم طبقه‌بندی بیماری را افزایش دهد. گاهی یک نوع ویژگی ممکن است برای تعریف درست شیء کافی نباشد (Chen et al., 2018).

در این مطالعه، پس از تقسیم بندی ناحیه بیماری‌ها، به معنای استخراج قسمت آسیب‌دیده برگ از تصویر ورودی، ویژگی‌هایی مانند رنگ، شکل و بافت استخراج شد. ویژگی‌های رنگ (میانگین، بیشینه، انحراف معیار، میانه) و ویژگی‌های بافتی از GLCM (کنتراست، همبستگی، انرژی، همگنی، میانگین، انحراف معیار، آنتروپی، واریانس، صافی، کشیدگی و چولگی) در هر باند از سه فضای رنگی RGB، l^*a^*b و HSV، (۳۶ ویژگی رنگ و ۹۹ ویژگی بافت) و همچنین ۶ ویژگی شکل (شامل: مساحت، محیط، تعداد لکه‌ها، طول محور اصلی و فرعی نقاط و شاخص خروج از مرکز) از تصاویر استخراج شد.


در تصاویر برگ، پیکسل‌هایی که رنگ قرمز در آن‌ها کمتر از مقادیر آبی و سبز است پوشش داده شد. بنابراین، در بقیه تصویر فقط ناحیه بیمار برگ باقی می‌ماند. شکل‌های ۲ و ۳ مراحل مختلف حذف پس‌زمینه و سایه‌ها و تشخیص ناحیه بیماری از برگ اصلی در این تحقیق را نشان می‌دهد.

استخراج ویژگی از تصویرها

ویژگی تصویر بخشی از اطلاعات در مورد محتوا/شیء است که به شناسایی منحصر به فرد آن کمک می‌کند. برای این منظور به هر یک از اشیا یک برچسب به عنوان کلاس‌بندی آن اختصاص داده می‌شود. استخراج ویژگی‌های محتوایی تصویرها یکی از عملیات مهم در پردازش تصویر است که در مقایسه تصاویر بر اساس محتوا استفاده می‌شود.

عمدتاً از ویژگی‌هایی مانند شکل، بافت و رنگ تصویر برگ گیاه برای تشخیص بیماری‌های گیاهی استفاده می‌شود. بر اساس این ویژگی‌ها، الگوریتم مناسب برای استخراج ویژگی باید به درستی اعمال شود. در داده‌کاوی تعیین بهترین ویژگی در میان مجموعه‌ای از ویژگی‌ها و انتخاب تکنیک استخراج خوب، همواره چالش برانگیز است. بنابراین شناخت صحیح هر نوع از ویژگی‌های بافت، رنگ و شکل اهمیت ویژه‌ای دارد (Chen et al., 2018).

ویژگی‌های بافت نمایانگر ویژگی‌های سطح جسم مانند یکنواختی، آنتروپی، انرژی، کنتراست، همبستگی و غیره است. الگوهای بافت را می‌توان از



شکل ۲- حذف سایه بر اساس آستانه شامل: الف) تصویر با سایه، ب) استخراج نوار رنگ سبز از تصویر، پ) تشخیص لبه، ت) اتساع مورفولوژیکی برای اتصال لبه‌ها، ث) پر کردن جاهای خالی در تصویر لبه و ج) تصویر نهایی

Fig. 2- Shadow removal based on thresholding including: a) Image with shadow, b) extracting green color band from the image, c) edge detection, d) morphological dilation to connect edges, e) filling in the blanks in the edge image, and f) final image

تعداد تصاویر Number of images	نام و نشانه‌های بیماری‌ها Names and symptoms of diseases	ناحیه بیماری تشخیص داده شده Diagnosed disease area	بدون پس زمینه No background	تصویر اصلی Main image
100	پوسیدگی سیاه انگور: لکه‌های روی برگ‌ها به صورت ضایعات دایره ای کوچک قهوه‌ای مایل به قرمز مایل به قرمز ظاهر می‌شوند. Black rot of grapes: Spots on the leaves appear as small reddish-brown circular lesions.			
100	بیماری اسکای (زوال) انگور نشانه‌ها را می‌توان روی برگ‌ها شناسایی کرد زیرا الگوی نوار ببری به خود می‌گیرند. Esca disease (decline) of grapes The symptoms can be identified on the leaves as they take on a tiger stripe pattern.			
100	بیماری لکه برگی انگور ابتدا به صورت لکه‌های قرمز رنگ در سطح بالایی برگ ظاهر می‌شود. این لکه‌های دایره‌ای بزرگ می‌شوند و به رنگ قهوه‌ای مایل به قهوه‌ای روشن با حاشیه‌های مشخص و تیره تبدیل می‌شوند. Grape leaf spot disease First, it appears as red spots on the upper surface of the leaf. These circular spots enlarge and become light brown in color with distinct, dark borders.			
100	برگ سالم بدون نشانه healthy leaf without awakening			

شکل ۳- مراحل مختلف حذف پس زمینه و تشخیص ناحیه بیماری از برگ اصلی در این پژوهش

Fig. 3- Different stages of removing the background and detecting the diseased area from the main leaf in this research

انتخاب مهم‌ترین ویژگی‌های استخراج شده از تصویر

روش‌های انتخاب ویژگی دو مرحله اصلی دارند: راهبرد جستجو و ارزیابی کیفیت زیر مجموعه. در مرحله اول، راهبرد جستجو از روشی برای انتخاب زیرمجموعه‌های ویژگی‌ها استفاده می‌کند. آخرین مرحله شامل استفاده از یک طبقه‌بندی کننده برای ارزیابی کیفیت زیر مجموعه‌های به دست آمده توسط مازول راهبرد جستجو است. رویکردهای انتخاب ویژگی به دو دسته تقسیم می‌شوند: روش‌های مبتنی بر فیلتر و روش‌های مبتنی بر هم‌پوشانی. روش‌های مبتنی بر فیلتر از تکنیک‌های وابستگی داده‌های آماری برای یافتن زیرمجموعه‌های ویژگی‌ها استفاده می‌کنند. روش‌های مبتنی بر هم‌پوشانی از الگوریتم‌های یادگیری ماشین برای جستجوی راه‌حل تقریباً بهینه از مجموعه‌ای نمایی از راه‌حل‌های امکان پذیر استفاده می‌کنند. روش‌های مبتنی بر فیلتر مستقل از طبقه‌بندی کننده و نسبتاً سریع هستند، اما ارتباط ابعاد مختلف را هنگام تصمیم‌گیری در مورد زیرمجموعه‌ای از ویژگی‌ها منعکس نمی‌کنند. این تکنیک‌ها از روش‌هایی مانند کسب اطلاعات استفاده می‌کنند (Urbanowicz et al., 2018).

الگوریتم بهینه‌ساز پروانه^۱، الگوریتمی فراابتکاری است که از رفتار جستجوی غذای پروانه‌ها الهام گرفته شده است. این الگوریتم به دلیل ظرفیت خود به عنوان تکنیک بهینه‌سازی برای مسائل بهینه‌سازی جهانی و اعمال آن در برنامه‌های مختلف، توجه پژوهشگران مختلف را به خود جلب کرده است. الگوریتم بهینه‌ساز پروانه عملکرد بهتری را در مقایسه با برخی دیگر از الگوریتم‌های بهینه‌ساز

نشان می‌دهد. این فراابتکاری مبتنی بر جمعیت توانایی آن را دارد که تا حدی از رکود بهینه محلی جلوگیری کند، ضمن اینکه توانایی همگرایی خوبی به سمت بهینه‌ها دارد (Javidan et al., 2024).

الگوریتم بهینه‌ساز پروانه با در نظر گرفتن سه معیار به عنوان الگو توسعه داده شده است: ۱- از همه پروانه‌ها انتظار می‌رود رایحه‌ای منتشر کنند که باعث می‌شود پروانه‌ها یکدیگر را جذب کنند. ۲- هر پروانه به طور تصادفی یا به سمت بهترین پروانه‌ای که رایحه‌های بیشتری منتشر می‌کند حرکت می‌کند. ۳- شدت محرک یک پروانه تحت تأثیر مقدار تابع هدف آن است یا تعیین می‌شود. اهداف عبارت‌اند از: به حداکثر رساندن دقت طبقه‌بندی، به حداقل رساندن تعداد ویژگی‌های انتخاب شده، و حداکثر کردن میانگین اطلاعات متقابل بین ویژگی‌های انتخاب شده و برچسب کلاس راه‌حل (Irmak et al., 2022; Makhadmeh et al., 2022).

الگوریتم بهینه‌ساز پروانه از شبیه‌سازی یک پروانه برای تجزیه و تحلیل بوهای موجود در هوا برای یافتن منبع غذایی به دست می‌آید. هر پروانه عطر متفاوتی دارد. پروانه‌ها می‌توانند عطر سایر پروانه‌ها را در هوا استشمام و تجزیه و تحلیل کنند تا جهت حرکت به موقعیت بهینه غیرمحلی را تعیین کنند. بیان غلظت عطر در رابطه ۱ نشان داده شده است (Sadeghian et al., 2021).

$$f_i = cI^a \quad (1)$$

که در آن،

f_i = غلظت عطر؛ c = شکل ادراکی؛ I = شدت محرک؛ و a = شاخص قدرت شکل ادراک وابسته. هر پروانه

دارای یک بردار موقعیت است که می‌تواند در طول فرآیند بهینه‌سازی با استفاده از رابطه ۲ به روز شود.

$$x_i^{x+1} = x_i^x + F_i^{x+1} \quad (2)$$

که در آن،

$x_i^x =$ موقعیت پروانه نام در تکرار x ؛ $x_i^{x+1} =$ موقعیت پروانه به روز شده. دو مرحله کلیدی در الگوریتم بهینه‌ساز پروانه وجود دارد: مرحله جستجوی جهانی و مرحله جستجوی محلی. این فازها به صورت روابط ۲ و ۳ به دست می‌آیند.

$$F_i^{x+1} = (r^2 \times g^* - x_i^x) \times pf_i \quad (3)$$

$$F_i^{x+1} = (r^2 \times x_j^x - x_k^x) \times pf_i \quad (4)$$

که در آن،

x_j^x و $x_k^x =$ پروانه‌های j ام و k ام در فضا؛ $f_i =$ شدت عطری که از پروانه نام منتشر می‌شود؛ و g^* نشان می‌دهد که موقعیت پروانه، بهینه جهانی است. اگر x_j^x و x_k^x متعلق به یک جمعیت باشد و r یک عدد تصادفی یکنواخت در $[0, 1]$ باشد، رابطه ۳ به یک حرکت تصادفی محلی تبدیل می‌شود. یک احتمال سوئیچ p برای جابه‌جایی بین جستجوی رایج جهانی به جستجوی محلی استفاده می‌شود.

برای حل مشکل انتخاب ویژگی، نسخه جدیدی از الگوریتم بهینه‌ساز پروانه ارائه شده است که از یک تابع سیگموئید (S شکل) استفاده می‌کند که پروانه‌ها را مجبور می‌کند در فضای جستجوی دودویی حرکت کنند. این تابع سیگموئید در رابطه ۵ نشان داده شده است (Mirjalili & Lewis, 2013; Sadeghian et al., 2021).

$$S(F_i^k(x)) = \frac{1}{1 + e^{-F_i^k(x)}} \quad (5)$$

که در آن، $F_i^k =$ عطر با ارزش پیوسته پروانه i در بعد k در تکرار x .

برای رسیدن به راه‌حل دودویی در مورد تابع سیگموئید یک آستانه تصادفی همان‌طور که در رابطه ۶ ذکر شده اعمال می‌شود. تابع S ، شکل ورودی بی‌نهایت را به آرامی به یک خروجی محدود نگاشت می‌کند.

$$X_i^k(x+1) = \begin{cases} 0, \rightarrow \text{rand} < S(F_i^k(x)) \\ 1, \rightarrow \text{otherwise} \end{cases} \quad (6)$$

که در آن،

$X_i^k =$ و $F_i^k =$ موقعیت و عطر پروانه نام در تکرار t در بعد k . بنابراین، هر راه‌حل در الگوریتم انتخاب ویژگی بهینه‌ساز پروانه به عنوان یک بردار تک بعدی مشخص می‌شود که در آن طول بردار به تعداد ویژگی‌ها بستگی دارد. هر سلول از بردار می‌تواند شامل یک یا صفر باشد. مقدار یک نشان می‌دهد که ویژگی مربوطه انتخاب شده است در حالی که مقدار صفر نشان می‌دهد که ویژگی انتخاب نشده است.

انتخاب ویژگی را می‌توان به عنوان مسئله بهینه‌سازی چند هدفه در نظر گرفت. در الگوریتم انتخاب ویژگی بهینه‌ساز پروانه بهترین راه‌حل شامل حداقل تعداد ویژگی با بالاترین دقت طبقه‌بندی است. بنابراین تابع تناسب λ این روش به صورت رابطه ۷ به دست خواهد آمد.

$$\text{Fitness} = \alpha \gamma_R(D) + \beta \frac{|R|}{|N|} \quad (7)$$

که در آن،

$\gamma_R(D) =$ میزان خطای طبقه‌بندی کننده؛ $|R| =$ اصلی بودن زیرمجموعه ویژگی انتخاب شده؛ $|N| =$ تعداد کل ویژگی‌ها در مجموعه داده اصلی؛ و α و $\beta =$ دو

اغتشاش برای نتیجه ایجاد شد. در نهایت بهترین الگوریتم از نظر کارایی و دقت برای تشخیص و طبقه‌بندی بیماری‌های انگور معرفی شد.

ارزیابی عملکرد روش پیشنهادی

ماتریس‌های اغتشاش برای ارزیابی موفقیت و کارایی سیستم‌های تشخیص بیماری استفاده شد. ماتریس اغتشاش خلاصه‌ای از نتایج پیش‌بینی در مورد مسئله طبقه‌بندی است. تعداد پیش‌بینی‌های درست و نادرست با مقادیر شمارش خلاصه شده و بر اساس هر کلاس تجزیه می‌شوند. در این تحقیق، از دقت برای ارزیابی عملکرد مدل طبقه‌بندی بیماری‌ها استفاده شده است. دقت روش طبقه‌بندی روی داده‌های آزمون، درصد مشاهدات مجموعه آزمون است که به درستی توسط مدل مورد استفاده طبقه‌بندی شده است. روابط ۸ و ۹ به ترتیب دقت و صحت طبقه‌بندی را نشان می‌دهد.

$$Accuracy = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (8)$$

$$Precision = \frac{TP}{TP+FP} \quad (9)$$

که در آنها،

TP = مجموعه رکوردهایی که توسط مدل به درستی، کلاس مثبت پیش‌بینی شد؛ TN = مجموعه رکوردهایی که توسط مدل به درستی، کلاس منفی پیش‌بینی شد؛ FP = مجموعه رکوردهایی که توسط مدل به اشتباه، کلاس مثبت پیش‌بینی شد؛ و FN = مجموعه رکوردهایی که توسط مدل به اشتباه، کلاس منفی پیش‌بینی شد.

پارامتر مربوط به اهمیت کیفیت طبقه‌بندی و طول زیرمجموعه. این تابع تناسب^۱ در همه الگوریتم‌های بهینه‌ساز برای ارزیابی راه‌حل‌ها با ایجاد تعادل بین دقت طبقه‌بندی و تعداد ویژگی‌های انتخابی استفاده می‌شود (Mirjalili, & Lewis, 2013; Sadeghian *et al.*, 2021).

طبقه‌بندی بیماری‌های برگ انگور توسط ماشین بردار پشتیبان

رویکردهای مختلف یادگیری ماشین، به عنوان مثال، روش‌های مبتنی بر نورون و مبتنی بر هسته، به پیش‌بینی و طبقه‌بندی تصاویر بیماری‌های مختلف گیاهان پرداخته است. ماشین بردار پشتیبان یک الگوریتم یادگیری ماشین با ناظر است که نمونه داده‌هایی را که به صورت نقاطی در فضا نشان داده شده است، با استفاده از یک خط یا ابر صفحه^۲، از هم جدا می‌کند. این جداسازی به گونه‌ای است که نقاط داده‌ای که در یک طرف خط هستند مشابه هم و در یک گروه قرار می‌گیرند. نمونه داده‌های جدید هم بعد از اضافه شدن به همان فضا در یکی از دسته‌های موجود قرار خواهند گرفت (Thaiyalnayaki & Josephet, 2021). طبقه‌بندی در ماشین بردار پشتیبان خطی برای آموزش بسیار سریع‌تر از طبقه‌بندی غیرخطی است، بنابراین، عملکرد می‌تواند تا حد زیادی بهبود یابد. اگر داده‌ها از قبل دارای ویژگی‌های زیادی باشند، یا به صورت خطی قابل تفکیک هستند، بیشتر اوقات دلیلی برای استفاده از توابع غیر خطی وجود ندارد (Javidan *et al.*, 2023). بنابراین، در این مطالعه از توابع خطی برای تشخیص و طبقه‌بندی برگ‌های بیمار و سالم استفاده و یک ماتریس

نتایج و بحث

نتایج انتخاب مهم‌ترین ویژگی‌های استخراج شده از تصویر

مهم‌ترین و تأثیرگذارترین ویژگی‌های انتخاب شده توسط الگوریتم بهینه‌ساز پروانه به صورت جداگانه برای ویژگی‌های رنگ، بافت و شکل در جدول ۲ نشان داده شده است. بر اساس نتایج به دست آمده در این جدول، با توجه به ویژگی‌های رنگ، چهار ویژگی از فضای رنگی l^*a^*b استخراج شد. برای ویژگی‌های بافت، چهار ویژگی استخراج شد. برای ویژگی‌های شکل، عوامل هندسی اصلی استخراج شده مانند محیط و مساحت ناحیه بیمار و درجه دایره‌ای بودن بیماری‌ها و تعداد لکه‌ها در انواع مختلف بیماری‌ها بیشترین تأثیر را در دقت طبقه

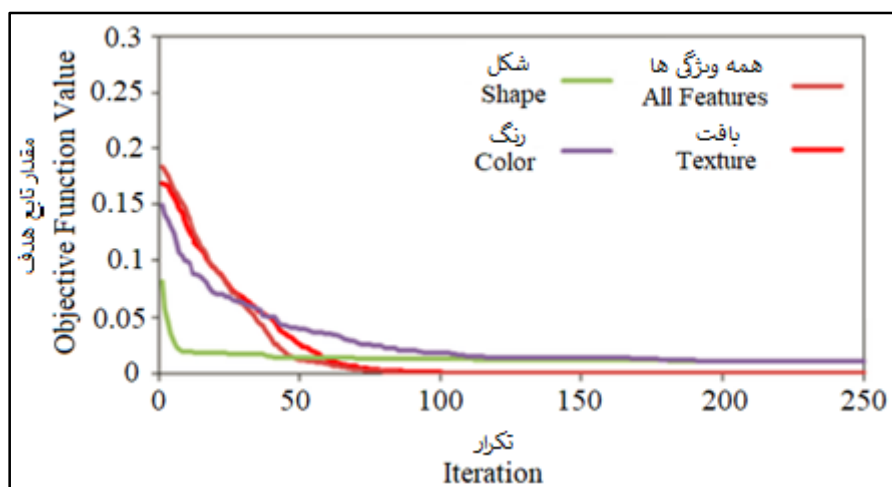
بندی داشتند. بنابراین، ۱۵ ویژگی مهم برای تشخیص گروه‌های بیماری برگ گیاه انگور در گروه‌های مختلف ویژگی‌های رنگ، بافت و شکل به صورت مجزا و نیز به صورت گروهی از ویژگی‌ها با

یکدیگر معرفی شد. جدول ۲ تفکیکی از رتبه‌بندی ویژگی‌های رنگ، بافت و شکل را برای هر گروه و نیز ترکیب ۱۵ ویژگی برتر را با میزان طبقه‌بندی ۹۵/۹۹ درصد نشان می‌دهد. همانطور که دیده می‌شود مشارکت ویژگی‌ها برای طبقه‌بندی نزدیک به یکدیگر است اما ویژگی بافت تأثیر بیشتری برای طبقه‌بندی دارد. نمودار همگرایی انتخاب ویژگی به روش الگوریتم بهینه‌ساز پروانه در شکل ۴ آورده شده است.

جدول ۲- مهم‌ترین/مؤثرترین ویژگی‌های رنگ، بافت و شکل

Table 2- The most important/effective features of color, texture and shape

دقت (درصد) Accuracy%	5	4	3	2	1	ردیف Row
70.45	mean (RGB) (B)	mean (RGB) (G)	Max (l^*a^*b) (b)	Median (RGB) (B)	Median (RGB) (G)	ویژگی رنگ Color feature
82.50	Standard Deviation (RGB) (B)	Mean (HSV) (H)	Median (l^*a^*b) (l)	Entropy (l^*a^*b) (b)	Energy (l^*a^*b) (l)	ویژگی بافت Texture feature
70	Number of objects	Minor axis length	Major axis length	Perimeter	Area	ویژگی شکل Shape feature
95.5	Mean (HSV) (H)	Energy (RGB) (R)	Median (RGB) (B)	Entropy (l^*a^*b) (b)	Energy (l^*a^*b) (l)	ویژگی برتر در مجموع ویژگی‌های رنگ، بافت و شکل The top 5 features in total are color, texture and shape



شکل ۴- نمودار همگرایی انتخاب ویژگی به روش الگوریتم بهینه‌ساز پروانه

Fig. 4- Convergence diagram of feature selection by the butterfly optimizer Algorithm

نتایج طبقه‌بندی بیماری‌ها

نتایج طبقه‌بندی به عنوان یک ماتریس اغتشاش برای داده‌های آزمون در جدول ۳ نشان داده شده است. اعداد برای پوسیدگی سیاه، اسکای (زوال) و لکه برگی، به ترتیب ۱، ۲، و ۳ بودند که در آن عدد ۴ به برگ‌های سالم اختصاص داده شد. بر اساس ماتریس اغتشاش، نرخ منفی کاذب (FN)، نرخ مثبت کاذب (FP)، نرخ مثبت واقعی (TP) و نرخ منفی واقعی (TN) در جدول ۴ نشان داده شده است. بر اساس نتایج ماتریس اغتشاش، سه بیماری پوسیدگی سیاه، اسکای (زوال) و بیماری لکه برگی با نشانه‌های تقریباً مشابه یکدیگر (لکه‌های قهوه‌ای و دایره‌ای) به خوبی تشخیص داده شده است. نتایج دقت تشخیص برای این سه گروه ۱۰۰ درصد است. در این بین، نتایج برای بیماری لکه برگی با نشانه‌های لکه‌های قرمز رنگ در روی برگ یک طبقه‌بندی نادرست با کلاس برگ سالم را نشان می‌دهد. نتایج برای دقت طبقه‌بندی کلاس برگ سالم ۹۵ درصد است. صحت طبقه‌بندی برای سه گروه بیماری و یک گروه برگ سالم ۹۸/۷۵ درصد به دست آمد. اگرچه نشانه‌های بیماری‌ها روی برگ‌ها بسیار شبیه به یکدیگر است،

اما طبقه‌بندی نتایج قابل قبولی را نسبت به تحقیقات دیگر محققان در جدول ۱ (در بخش مقدمه) نشان می‌دهد. آنچه در مقایسه با تحقیقات دیگر محققان به چشم می‌آید تفاوت در دقت طبقه‌بندی، تعداد ویژگی‌های استخراج شده، روش طبقه‌بندی و تعداد داده‌های موجود در تشخیص بیماری‌هاست که از مهم‌ترین مواردی است که طبقه‌بندی را متفاوت کرده است (Padol & Yadav, 2016). مهم‌ترین چالشی که در تحقیقات گذشته وجود دارد فقدان تصاویر زیاد به منظور استفاده در روش‌های مختلف یادگیری عمیق و شبکه‌های عصبی کانولوشنی است عملکرد طبقه‌بندی‌ها را تضعیف می‌کند (Liu et al., 2020; Xie et al., 2020). در زمینه روش‌های یادگیری عمیق نکته قابل تامل این است که این روش‌ها به روش‌های جعبه سیاه^۱ معروفاند.

این بدان معناست که ویژگی‌های استخراج شده درون شبکه‌ای قابل تحلیل نیستند و در اکثر موارد افرادی که میزان زیادی اطلاعات از چگونگی رفتار در طبقه‌بندی ندارند نمی‌توانند آن‌ها را تحلیل و بررسی کنند (Javidan et al., 2023). در چنین

1- Black Box

مواردی، استفاده از یادگیری ماشین و استخراج درست و مؤثر ویژگی‌های اصلی مانند بافت، رنگ و شکل از تصاویر برگ‌های بیمار می‌تواند رویکردی مؤثرتر باشد (Jaisakthi *et al.*, 2019). ضعف در وجود داده‌های کمتر را می‌توان با استفاده از طبقه‌بندی در یادگیری ماشین برطرف کرد اما شرط دقت طبقه‌بندی بالا استخراج ویژگی‌هایی است که دقت طبقه‌بندی را نیز افزایش می‌دهد (Padol & Yadav, 2016). نتایج مقایسه با تحقیقاتی که از یادگیری ماشین استفاده کرده‌اند نشان می‌دهد که استفاده از گروه‌های مختلف ویژگی تأثیر زیادی در دقت طبقه‌بندی دارد (Padol & Yadav, 2016; Javidan *et al.*, 2023). در تحقیق حاضر، با پردازش تصویرهای رنگی محل بیماری روی برگ مشخص و مهم‌ترین و تاثیرگذارترین ویژگی‌های تصویر به منظور تشخیص و طبقه‌بندی بیماری‌های برگ انگور به محققان معرفی شد. نتایج به‌دست آمده به‌وسیله یک الگوریتم بهینه‌ساز پروانه به‌عنوان انتخاب‌کننده ویژگی‌ها نشان داد که گروه‌های مختلف رنگی، و شکل اهمیت تقریباً یکسانی در طبقه‌بندی دارند بنابراین حذف یا نادیده گرفتن هر یک از گروه‌های ویژگی، عملکرد الگوریتم طبقه‌بندی بیماری را کاهش خواهد داد.

جدول ۳- نتایج ماتریس اغتشاش برای طبقه‌بندی بیماری‌های برگ گیاه انگور

Table 2- The results of the confusion matrix for the classification of grape plant leaf diseases

برگ سالم Healthy	لکه برگی Leaf blight	اسکای (زوال) Black rot	پوسیدگی سیاه Black measles	گروه برگ‌ها Leaf group
0	0	0	20	پوسیدگی سیاه Black measles
0	0	20	0	اسکای (زوال) Black rot
1	19	0	0	لکه برگی Leaf blight
20	0	0	0	برگ سالم Healthy

کلاس واقعی
Actual class

کلاس پیش‌بینی شده
Predicted class

جدول ۴- نتایج پارامترهای ماتریس اغتشاش

Table 3- Results of confusion matrix parameters

سالم Healthy	لکه برگی Leaf blight	اسکای (زوال) Black rot	پوسیدگی سیاه Black measles	کلاس Class
20	19	20	20	TN نرخ منفی واقعی
1	0	0	0	FP نرخ مثبت کاذب
0	1	0	0	FN نرخ منفی کاذب
59	60	60	60	TN نرخ منفی واقعی
0.9523	1	1	1	Precision دقت
0.9875	0.9875	0.9875	0.9875	Accuracy صحت

نتیجه‌گیری

بیماری‌های پوسیدگی سیاه، اسکای (زوال) و لکه‌برگی و برگ سالم به ترتیب ۱۰۰، ۱۰۰، ۱۰۰ و ۹۵ درصد و دقت طبقه‌بندی برای تشخیص کل گروه‌های بیمار و سالم ۹۸/۷۵ درصد به دست آمد. نتایج به‌دست آمده نشان داد که طبقه‌بندی بیماری توسط الگوریتم پیشنهادی دقت بالایی دارد و به عنوان یک تکنیک کمکی برای آسیب‌شناسان گیاهی قابل استفاده است. نتایج این تحقیق برای محققان بخش مدیریت آفات گیاهی و نیز کاربران تخصصی بخش باغبانی کاربرد دارد اما به منظور بررسی تغییر شرایط محیطی در حین تصویربرداری، بررسی رهیافت پیشنهادی در تشخیص دیگر بیماری‌های شایع انگور، تغییر رقم انگور، تعیین خودکار درصد آلودگی، تجویز نحوه مدیریت و مبارزه با بیماری به صورت برخط و امکان کاربردی کردن نتایج برای همگان با توسعه برنامه‌های کاربردی تشخیص و تجویزی، پیشنهاد می‌شود مطالعات جامع‌تری ادامه یابد.

در این مطالعه، الگوریتم جدیدی بر اساس انتخاب مهم‌ترین و مؤثرترین ویژگی‌ها برای شناسایی و طبقه‌بندی بیماری‌های گیاه انگور پیشنهاد شد. برای این منظور ترکیبی از روش انتخاب ویژگی الگوریتم بهینه‌ساز پروانه و طبقه‌بندی‌کننده ماشین بردار پشتیبان برای تشخیص بیماری‌های برگ گیاه انگور با نشانه‌های مشابه ارائه شد. برای این منظور ۳۶ ویژگی رنگی، ۹۹ ویژگی بافت در سه فضای رنگی RGB، HSV و l^*a^*b و نیز شش ویژگی شکل از تصاویر سه گروه بیماری برگ گیاه انگور به نام‌های پوسیدگی سیاه، اسکای (زوال) و لکه‌برگی و همچنین گروه برگ سالم استخراج شد. پس از استخراج ویژگی، توسط الگوریتم بهینه‌ساز پروانه بهترین و مؤثرترین ویژگی برای هر سه گروه ویژگی: رنگ، بافت و شکل انتخاب شد. سپس طبقه‌بندی به کمک ماشین بردار پشتیبان صورت گرفت. نتایج صحت طبقه‌بندی برای

تعارض منافع

نویسندگان در خصوص مقاله ارائه شده به طور کامل از سوء اخلاق نشر، از جمله سرقت ادبی، سوء رفتار، جعل داده‌ها و یا ارسال و انتشار دوگانه، پرهیز نموده‌اند و منافی تجاری در این راستا وجود ندارد.

مراجع

- Abdulridha, J., Ampatzidis, Y., Kakarla, S. C., & Roberts, P. (2020). Detection of target spot and bacterial spot diseases in tomato using UAV-based and benchtop-based hyperspectral imaging techniques. *Precision Agriculture*, 21(7), 955-978. <https://doi.org/10.1007/s11119-019-09703-4>.
- Arun Pandian, J., & Gopal, G. (2019). Identification of plant leaf diseases using a nine-layer deep convolutional neural network. *Computers and Electrical Engineering*, 76, 323-338. <https://doi.org/10.1016/j.compeleceng.2019.04.011>.
- Asefpour Vakilian, K., & Massah, J. (2017). A farmer-assistant robot for nitrogen fertilizing management of greenhouse crops. *Computers and Electronics in Agriculture*, 139(9), 153-163. <https://doi.org/10.1016/j.compag.2017.05.012>.

- Barbedo, J. G. A. (2018). Factors influencing the use of deep learning for plant disease recognition. *Biosystems Engineering*, 172(6), 84-91. <https://doi.org/10.1016/j.biosystemseng.2018.05.013>.
- Chen, J., Zheng, H., Lin, X., Wu, Y., & Su, M. (2018). A novel image segmentation method based on fast density clustering algorithm. *In Engineering Applications of Artificial Intelligence*, 73(10), 92-110. <https://doi.org/10.1016/j.engappai.2018.04.023>.
- Cristin, R., Kumar, B. S., Priya, C., & Karthick, K. (2020). Deep neural network based Rider-Cuckoo Search Algorithm for plant disease detection. *Artificial intelligence review*, 53(8), 4993-5018. <https://link.springer.com/article/10.1007/s10462-020-09813-w>.
- Irmak, B., Karakoyun, M., & Gülcü, Ş. (2022). An improved butterfly optimization algorithm for training the feed-forward artificial neural networks. *Soft Computing*, 27(7), 3887-3905. <https://link.springer.com/article/10.1007/s00500-022-07592-w>.
- Jaisakthi, S. M., Mirunalini P., & Thenmozhi, D. (2019). *Grape leaf disease identification using machine learning techniques. In Proceedings of the 2019 International Conference on Computational Intelligence in Data Science (ICCIDIS)*. Feb. 23-25, Chennai, India.
- Javidan, S. M., Banakar, A., Vakilian, K. A., & Ampatzidis, Y. (2022). A feature selection method using slime mould optimization algorithm in order to diagnose plant leaf diseases. *In Proceedings of the 8th Iranian Conference on Signal Processing and Intelligent Systems (ICSPIS)*. Dec. 28-29. Kashan, Iran. (in Persian)
- Javidan, S. M., Banakar, A., Vakilian, K. A., & Ampatzidis, Y. (2023). Diagnosis of grape leaf diseases using automatic K-means clustering and machine learning. *Smart Agricultural Technology*, 3(3), 100081-100110. <https://doi.org/10.1016/j.atech.2022.100081>.
- Javidan, S. M., Banakar, A., Vakilian, K. A., Ampatzidis, Y., & Rahnama, K. (2024). Diagnosing the spores of tomato fungal diseases using microscopic image processing and machine learning. *Multimedia Tools and Applications*, 83(5), 20-43. <https://doi.org/10.1007/s11042-024-18214-y>.
- Kumar, S., Sharma, B., Sharma, V. K., Sharma, H., & Bansal, J. C. (2020). Plant leaf disease identification using exponential spider monkey optimization. *Sustainable Computing: Informatics and Systems*, 28(3), 100283-100294. <https://doi.org/10.1016/j.suscom.2018.10.004>.
- Liu B., Tan C., Li S., He J., & Wang H. (2020). A data augmentation method based on generative adversarial networks for grape leaf disease identification. *IEEE*, <https://doi.org/10.1109/ACCESS.2020.2998839>.
- Makhadmeh, S. N., Al-Betar, M. A., Abasi, A. K., Awadallah, M. A., Doush, I. A., Alyasseri, Z. A. A., & Alomari, O. A. (2022). Recent advances in butterfly optimization algorithm, its versions and applications. *Archives of Computational Methods in Engineering*, 30(2), 1399-1420. <https://link.springer.com/article/10.1007/s11831-022-09843-3>.
- Mirjalili, S., & Lewis, A. (2013). S-shaped versus V-shaped transfer functions for binary Particle Swarm Optimization. *Swarm and Evolutionary Computation*, 9(3), 1-14. <https://doi.org/10.1016/j.swevo.2012.09.002>.
- Mohammadzamani, D., Sajadian, S., & Javidan, S. M. (2020). Detection of *Callosobruchus maculatus* F. with image processing and artificial neural network. *Applied Entomology and Phytopathology*, 88(1), 103-112. <https://doi.org/10.22092/jaep.2020.341684.1324>. (in Persian)

- Mohammadzamani, D., Javidan, S. M., Zand, M., & Rasouli, M. (2023). Detection of Cucumber Fruit on Plant Image Using Artificial Neural Network. *Journal of Agricultural Machinery*, 13(1), 18-29. <https://doi.org/10.22067/jam.2022.73827.1077>.
- Padol, P. B., & Yadav, A. A. (2016). SVM classifier based grape leaf disease detection. In *Proceedings of the 2016 Conference on Advances in Signal Processing (CASP)*, April 12-15. Lisbon, Portugal.
- Roostaei, P., Rasouli, M., & Babaei, A. (2015). Study of compatibility and the effect of pollen of some grape cultivars on fruit set and quantitative and qualitative characters of fruit, cv. Rish Baba Sefid. *Plant Production Technology*, 7(1), 193-210. (in Persian)
- Sadeghian, Z., Akbari, E., & Nematzadeh, H. (2021). A hybrid feature selection method based on information theory and binary butterfly optimization algorithm. *Engineering Applications of Artificial Intelligence*, 97(5), 104079-104084. <https://doi.org/10.1016/j.engappai.2020.104079>.
- Thaiyalnayaki, K., & Joseph, C. (2021). Classification of plant disease using SVM and deep learning. *Materials Today: Proceedings*, 47(6), 468-470. <https://doi.org/10.1016/j.matpr.2021.05.029>.
- Urbanowicz, R. J., Meeker, M., La Cava, W., Olson, R. S., & Moore, J. H. (2018). Relief-based feature selection: Introduction and review. *Journal of Biomedical Informatics*, 85(3), 189-203. <https://arxiv.org/abs/1711.08421>.
- Xie, X., Ma, Y., Liu, B., He, J., Li, S., & Wang, H. (2020). A deep-learning-based real-time detector for grape leaf diseases using improved convolutional neural networks. *Frontiers in Plant Science*, 11(2), 751-766. <https://doi.org/10.3389/fpls.2020.00751>.

Research Paper

Diagnosis of Three Types of Grape Leaf Diseases Based on Image Processing using Butterfly Optimization Algorithm and Support Vector Machine

M. Najafabadiha, D. Mohammad Zamani* and M. Gholami Parashkoochi

*Corresponding Author: Associate Professor, Department of Biosystems Engineering, Takestan branch, Islamic Azad University, Takestan, Iran. Email: dr.dmzamani@gmail.com

Received: 15 March 2024, Accepted: 19 July 2024

<https://doi.org/10.22092/amsr.2024.365272.1482>

Abstract

Today, artificial intelligence techniques and machine learning technologies have made it easy to identify and classify plant diseases. In this research, in order to diagnose and classify some diseases of grapevine leaves with the names of black measles, black rot, and leaf blight, after removing the background from the image of the leaves and extracting the characteristics of texture and color and from the images, a combination of support vector machine classification and butterfly optimization algorithm was used to select the most important features in the diagnosis of grape plant leaf disease. The results of classification accuracy for black measles, black rot, leaf blight, and healthy leaf diseases are 100, 100, 100 and 95% respectively, and the classification accuracy for the diagnosis of all diseased and healthy groups is 98.75%. It was achieved. The classification results showed that image processing and machine learning are excellent in diagnosing and classifying some plant diseases of grape leaves. In this research, 15 features of texture, color and shape have been introduced to the researchers of plant pathology and data science with the help of the butterfly optimization feature selection algorithm.

Keywords: Artificial Intelligence, Diagnosis and Classification, Feature Extraction, Feature Selection, Grape Diseases



© 2023 Agricultural Mechanization and Systems Research, Karaj, Iran. This is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0 license)