

مقاله پژوهشی

طراحی و پیاده‌سازی سامانه هوشمند تحت وب برای تشخیص بیماری‌های برگ گیوی مبتنی بر یادگیری عمیق

امیرحسین حسینی خطبه‌سرا^۱ و مهدی صادق‌زاده^{۲*}

۱ و ۲- به ترتیب: دانش‌آموخته کارشناسی ارشد مهندسی کامپیوتر گرایش نرم‌افزار؛ و دانشیار گروه مهندسی کامپیوتر، دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران، تهران، ایران
تاریخ دریافت: ۱۴۰۴/۱۲/۷؛ تاریخ پذیرش: ۱۴۰۵/۴/۲

چکیده

در این پژوهش، یک سامانه هوشمند تحت وب برای تشخیص بیماری‌های برگ درخت گیوی از طریق تحلیل تصاویر آن ارائه شده است. سامانه پیشنهادی می‌تواند این چهار وضعیت برگ را شناسایی کند: سالم بودن برگ، آلوده بودن ریشه گیوی به نماتد، آلوده بودن برگ به آلترناریا و آلوده بودن برگ به فیتوفتورا. ارزیابی سامانه با استفاده از مجموعه داده مرجع AgriVision-Kiwi انجام شد که در مطالعات پیشین برای تشخیص بیماری‌های برگ گیوی استفاده شده است. در گام نخست، برای آشکارسازی ناحیه برگ‌ها از الگوریتم You Only Look Once نسخه ۱۱ (YOLOv11) استفاده شد. پس از آن، بیماری با بهره‌گیری از معماری یادگیری عمیق MobileNet-V3 تشخیص داده شد. سامانه با استفاده از زبان پایتون و چارچوب FastAPI توسعه یافته و مدیریت داده‌ها از طریق پایگاه داده MySQL صورت گرفته است. نتایج ارزیابی سامانه پیشنهادی روی مجموعه داده AgriVision-Kiwi با استفاده از اعتبارسنجی متقاطع ۱۰ بخشی نشان داد که مقدار صحت کلی برابر با ۹۹/۷۰۳ درصد، دقت میانگین ماکرو برابر با ۹۹/۷۱۲ درصد، حساسیت میانگین ماکرو برابر با ۹۹/۷۰۳ درصد و معیار F1 میانگین ماکرو برابر با ۹۹/۷۰۳ درصد است. این نتایج بیانگر توانایی سامانه در شناسایی چهار وضعیت برگ است: سالم بودن برگ، آلوده بودن ریشه گیوی به نماتد، آلوده بودن برگ آلترناریا و آلوده بودن برگ فیتوفتورا. یافته‌ها همچنین نشان می‌دهند که سامانه پیشنهادی ظرفیت مناسبی برای کاربرد در محیط‌های واقعی باغ گیوی دارد. علاوه بر این، ماهیت تحت وب سامانه موجب افزایش دسترس پذیری برای کاربران شده و امکان استفاده در شرایط واقعی باغ بدون نیاز به تجهیزات پیچیده را فراهم می‌کند.

واژه‌های کلیدی

بینایی ماشین، شبکه‌های عصبی کانولوشنی، طبقه‌بندی ریزدانه، فنوتیپ‌برداری

مقدمه

برای تولید محصول ایجاد کنند، هرچند حضور آن‌ها معمولاً در سیستم ریشه بهتر قابل تشخیص است. در مطالعه‌ای گزارش شده است که آلودگی‌های نماتدی در باغ‌های گیوی فرانسه و ایتالیا منجر به نابودی کامل برخی مزارع شده‌اند

در زمینه شناسایی نماتدها از طریق تصاویر برگ خلأ پژوهشی آشکاری وجود دارد. نماتدها تهدیدی جدی برای رشد طبیعی گیاه گیوی به شمار می‌روند و می‌توانند خسارت‌های شدیدی به درختان گیوی

مهم‌ترین مناطق تولید کیوی در ایران به شمار می‌روند. در این سال، سطح زیرکشت بارور کیوی در استان گیلان ۸/۱۹۴ هکتار و میزان تولید آن ۱۶۸/۰۳۲ تن گزارش شده است؛ سطح زیرکشت بارور این محصول در استان مازندران ۷/۷۴۴ هکتار و میزان تولید آن ۱۴۹/۸۶۶ تن بوده است (Anon, 2024). مقایسه این ارقام نشان می‌دهد که استان گیلان، هم از نظر سطح زیرکشت بارور و هم از نظر میزان تولید کیوی، جایگاه بالاتری نسبت به استان مازندران دارد به طوری که سطح زیرکشت بارور کیوی در گیلان ۴۵۰ هکتار و میزان تولید آن ۱۸/۱۶۶ تن بیشتر از مازندران بوده است. این نتایج، نقش برجسته دو استان گیلان و مازندران را در تولید کیوی کشور و برتری نسبی استان گیلان را نشان می‌دهد.

یائو و همکاران (Yao et al., 2022) یک روش دومرحله‌ای مبتنی بر یادگیری عمیق را برای تشخیص بیماری‌های برگ کیوی ارائه کردند. با جدا کردن برگ‌ها از پس‌زمینه طبیعی و استفاده از شبکه‌های UNet^۱ و DeepLabv3^۲، مدل مبتنی بر ResNet101^۳ به دقت ۹۶/۶ درصد دست یافت و نشان داد که روش پیشنهادی دقت و پایداری بالایی دارد و برای پایش هوشمند محصولات کشاورزی مناسب است.

با افزایش جمعیت جهانی، تقاضا برای تولید مواد غذایی نیز رو به افزایش است و این موضوع محصولات اساسی مانند ذرت را در معرض تهدید بیماری‌ها و آفات قرار می‌دهد. در این راستا، وو و همکاران (Wu et al., 2025) یک سامانه هوشمند را برای شناسایی بیماری‌ها و آفات برگ ذرت ارائه کردند که از روش‌های هوش مصنوعی و تحلیل

(El-Borai & Duncan, 2005). در چین کاهش عملکرد در حدود ۴۰ درصد در باغ‌های کیوی آلوده به نماتد گزارش شده است (Tao et al., 2017). در پژوهشی دیگر روی ۲۵ باغ کیوی در منطقه‌ای وسیع از ترکیه مشخص گردید که ۹۲ درصد باغ‌ها به نماتدها آلوده‌اند (Aydinli & Mennan, 2022). در یک باغ کیوی در پرتغال، نشان داد که ۳۵ گیاه از مجموع ۴۰ گیاه مورد مطالعه به نماتدها آلوده بوده‌اند (Gonçalves et al., 2025). همچنین یکی از مهم‌ترین چالش‌های این بیماری، دشواری تشخیص آن در مراحل اولیه است زیرا روش‌های رایج عمدتاً متکی بر تحلیل شیمیایی نمونه‌های خاک هستند که زمان‌بر و کم‌بازده محسوب می‌شوند. بنابراین، نماتد تهدیدی جدی برای باغ‌های کیوی در کشورهای مختلف جهان به شمار می‌روند و بینایی ماشین می‌تواند ابزار مؤثری برای تشخیص زودهنگام و کارآمد این آلودگی باشد.

در تحقیقات فیلیپونه، و همکاران (Filippone et al., 2008) و گووندِر و سیواکو مار (Govender & Sivakumar, 2020) گفته شده است کیوی یکی از محصولات باغی باارزش اقتصادی و تغذیه‌ای بالا است که خاستگاه آن کشور چین است و از قرن بیستم تا کنون در بسیاری از مناطق جهان کشت و توسعه یافته است. این میوه به دلیل دارا بودن مقادیر قابل توجهی از ویتامین C، فیبر غذایی و ترکیبات آنتی‌اکسیدانی، نقش مهمی در سلامت انسان دارد و مصرف منظم آن با تقویت سیستم ایمنی و بهبود سلامت دستگاه گوارش، قلب و پوست همراه است.

بر اساس آمار رسمی وزارت جهاد کشاورزی در سال ۱۴۰۳، استان‌های گیلان و مازندران از

1- U-Shaped Convolutional Network

2- DeepLab Version 3 Plus

3- Residual Network with 101 Layers

به زوال تدریجی یا مرگ گیاه منجر شود. در تحقیقات بنی‌هاشمیان و همکاران (Banihashemian *et al.*, 2022) نماتدها از عوامل بیماری‌زای خاک‌زاد هستند که با ایجاد گال در ریشه‌ها، فرآیند جذب آب و مواد غذایی را مختل می‌کنند و موجب کاهش رشد، ضعف عمومی گیاه و افزایش حساسیت آن نسبت به دیگر بیماری‌ها می‌شوند. وجه مشترک این بیماری‌ها آن است که در مراحل اولیه، نشان‌های مشخصی روی برگ‌ها ظاهر می‌شود که می‌تواند به‌عنوان نشانه‌ای غیرتهاجمی برای تشخیص زودهنگام بیماری استفاده شوند.

طبق تحقیقات حسینی و همکاران (Hosny *et al.*, 2023) در سال‌های اخیر، برگ گیاهان به‌طور گسترده در الگوریتم‌های بینایی ماشین و سامانه‌های هوشمند کشاورزی برای تشخیص خودکار بیماری‌های گیاهی به کار گرفته شده‌اند. در تحقیقات یائو و همکاران (Yao *et al.*, 2022) تحلیل داده‌های بصری استخراج‌شده از تصاویر برگ‌ها این امکان را فراهم می‌سازد که نشانه‌های اولیه بیماری پیش از گسترش به میوه یا کل گیاه شناسایی شود. این امر ضمن کاهش خسارات عملکردی، زمینه مداخلات به موقع و مدیریت کم‌هزینه‌تر را فراهم می‌کند و وابستگی به بازدیدهای میدانی زمان‌بر و تشخیص‌های مبتنی بر تجربه فردی را کاهش می‌دهد. در تحقیقات لیو و وانگ (Liu & Wang, 2021) فناوری بینایی ماشین می‌تواند نقش مؤثری در بهبود مدیریت باغ و افزایش بهره‌وری تولید داشته باشد.

شاکیا (Shakya, 2020) نشان دادند که شبکه‌های عصبی کانولوشنی^۱ به عنوان یکی از

داده‌های گسترده بهره می‌برد. این سامانه به صورت یک نرم‌افزار تحت وب پیاده‌سازی می‌شود و قابلیت‌هایی مانند بارگذاری تصویر، شناسایی خودکار بیماری و آفت، ثبت‌نام و ورود کاربران، و ارائه گزارش‌های تفصیلی را فراهم می‌کند تا کاربران بتوانند به سهولت به اطلاعات موردنیاز برای مقابله به موقع با تهدیدات شناسایی شده دسترسی داشته باشند. نتایج آزمایش‌ها نشان داد که سامانه پیشنهادی دقت و پایداری بالایی در تشخیص بیماری‌ها و آفات برگ ذرت دارد. به طوری که دقت تشخیص به بیش از ۹۳ درصد رسید. این عملکرد مطلوب نشان‌دهنده قابلیت بالای سامانه در شناسایی دقیق و قابل اعتماد بیماری‌های برگ ذرت است. از این‌رو، این سامانه می‌تواند به عنوان ابزاری مؤثر و کاربردی در اختیار کشاورزان قرار گیرد و با پشتیبانی از تصمیم‌گیری آگاهانه، نقش مهمی در افزایش بهره‌وری تولید ذرت و توسعه کشاورزی پایدار داشته باشد.

در تحقیقات هوانگ و همکاران (Huang *et al.*, 2021) در خصوص کیوی گفته شده است آلترناریا^۱، نماتد^۲ و فیتوفتورا^۳ اهمیت ویژه‌ای دارند. در تحقیقات بی و همکاران (Bi *et al.*, 2019) نشان داده شده است در بیماری آلترناریا که بر اثر قارچ‌های جنس آلترناریا ایجاد می‌شود، با ایجاد لکه‌های تیره روی برگ‌ها موجب کاهش توان فتوسنتزی، تضعیف عمومی گیاه و در نهایت افت عملکرد در مراحل پیش و پس از برداشت می‌شود. بیماری فیتوفتورا که ناشی از عوامل شبه‌قارچی است، با آلوده‌سازی ریشه و طوقه درخت، سبب اختلال در جذب آب و عناصر غذایی می‌شود و در صورت عدم مدیریت مناسب، می‌تواند

1- Alternaria

2- Nematode

3- Phytophthora

معماری‌های حالتیکی مانند AlexNet و LeNet بهبود داده‌اند. در کنار توسعه مدل‌های تشخیص، تعدادی از مطالعات به طراحی ابزارها و سامانه‌های هوشمند مبتنی بر وب پرداخته‌اند که امکان استفاده عملی از مدل‌های یادگیری عمیق را برای پایش بیماری‌های گیاهی فراهم می‌سازد.

بانسال و همکاران (Bansal et al., 2023) یک رویکرد دومرحله‌ای را مبتنی بر یادگیری عمیق برای تشخیص بیماری سفیدک پودری کیوی ارائه کردند. در این روش، ابتدا یک شبکه عصبی کانولوشنی برای طبقه‌بندی دودویی میوه‌های کیوی به دو گروه سالم و آلوده به کار گرفته شد. نتایج گزارش شده نشان می‌دهد که دقت طبقه‌بندی دودویی به ۹۲/۱۴ درصد و دقت طبقه‌بندی چندحالتی به ۹۵/۹۱ درصد رسیده است. با این حال، این مطالعه بر تصاویر میوه کیوی متمرکز بوده است و شامل تحلیل برگ‌ها نمی‌شود. مجموعه داده مورد استفاده به صورت عمومی منتشر نشده و روش ارائه شده به سایر بیماری‌های کیوی تعمیم داده نشده است.

لیو و وانگ (Liu & Wang, 2021) یک معماری سفارشی شبکه عصبی کانولوشنی با نام Kiwi-ConvNet را ارائه کردند که با الهام از معماری‌های AlexNet و GoogleNet طراحی شده است. این مدل برای طبقه‌بندی سه بیماری برگ کیوی شامل لکه قهوه‌ای، موزاییک و آنترائونوز به کار گرفته شده است. نتایج مرحله اعتبارسنجی نشان داد که روش پیشنهادی به دقت ۹۸/۵۴ درصد دست یافته است.

با توجه به اهمیت تشخیص به موقع بیماری‌های کیوی و محدودیت روش‌های سنتی، هدف این پژوهش طراحی و پیاده‌سازی یک سامانه هوشمند

روش‌های مؤثر یادگیری عمیق^۲، در سال‌های اخیر نتایج چشمگیری در بخش‌بندی و طبقه‌بندی تصاویر در کاربردهای مختلف ارائه کرده‌اند.

جامعه بینایی ماشین، یادگیری عمیق را به طور گسترده پذیرفته است، زیرا این روش قادر است تصاویر را به صورت مستقیم پردازش کند. شبکه‌های CNN می‌توانند ویژگی‌های تصویر را به طور خودکار از مجموعه داده‌ها بیاموزند و با استفاده از یک معماری واحد، عملیات استخراج ویژگی و طبقه‌بندی را با سرعت بالاتر و کارایی بیشتر به انجام برسانند.

مریدها و همکاران (Mridha et al., 2021) می‌گویند در سال‌های اخیر، تشخیص خودکار بیماری‌های گیاهی به عنوان یکی از حوزه‌های فعال پژوهشی در کشاورزی هوشمند مورد توجه قرار گرفته است، زیرا ابتلای گیاهان به بیماری‌ها می‌تواند موجب کاهش کیفیت و کمیت تولید محصولات کشاورزی شود. بسیاری از پژوهش‌ها نشان داده‌اند که برگ گیاهان به دلیل دارا بودن ویژگی‌های بصری و بافتی متمایز، منبع مناسبی برای شناسایی نشانه‌های بیماری به شمار می‌آید. در این راستا، روش‌های مبتنی بر بینایی ماشین و یادگیری عمیق به طور گسترده برای استخراج ویژگی‌ها و تشخیص نوع بیماری از روی تصاویر برگ به کار گرفته شده‌اند. مطالعات پیشین عمدتاً از شبکه‌های عصبی عمیق^۳ و شبکه‌های عصبی کانولوشنی برای تشخیص بیماری‌های گیاهی استفاده کرده‌اند و نتایج نشان می‌دهد که این روش‌ها عملکرد بهتری نسبت به روش‌های سنتی مبتنی بر ویژگی‌های دستی دارند. برخی پژوهش‌ها با ارائه معماری‌های ترکیبی شبکه‌های عصبی عمیق، عملکرد مدل‌ها را نسبت به

1- Convolutional Neural Network (CNN)

2- Deep Learning

2- Deep Neural Networks (DNNs)

مبتنی بر یادگیری عمیق برای تشخیص بیماری‌های برگ کیوی از تصاویر دیجیتال است. در سامانه پیشنهادی، ابتدا ناحیه برگ‌ها با استفاده از الگوریتم YOLOv11^۱ شناسایی شد و پس از آن برگ‌های شناسایی شده در چهار حالت سالم و آلترناریا، فیتوفتورا و نماتد طبقه‌بندی می‌شوند. به منظور ارزیابی قابلیت کاربرد سامانه، امکان بارگذاری تصاویر و ارائه نتایج تشخیص در قالب یک محیط کاربری فراهم شده است.

مواد و روش‌ها

منطقه مورد مطالعه

باغ کیوی ۱۲ ساله با ۱۶ درخت، که در دو ردیف قرار داشتند، واقع در روستای خطبه‌سرا و شهرستان تالش بود. مختصات جغرافیایی این باغ به طول جغرافیایی ۴۸/۹۱۲۹۱ شرقی و عرض جغرافیایی ۳۸/۰۳۹۰۹ شمالی بود.

معرفی مجموعه داده

برای آموزش و ارزیابی مدل‌های تشخیص بیماری برگ کیوی، در این پژوهش از مجموعه داده AgriVision-Kiwi استفاده شد، که بر اساس تصاویر برگ‌های کیوی جمع‌آوری شده توسط کالامپوکاس و همکاران (Kalampokas et al., 2025) ساخته شده است. مجموعه داده شامل چهار وضعیت برگ سالم و بیماری‌های آلترناریا، نماتد و فیتوفتورا است و تعداد تصاویر اولیه برای هر حالت به ترتیب ۵۷، ۲۴، ۴۳ و ۲۸ تصویر بود. تصاویر ابتدا با استفاده از جعبه‌های محدودکننده^۲ برچسب‌گذاری شدند و سپس برای افزایش تنوع داده‌ها و کاهش بیش‌برازش، تحت مجموعه‌ای از عملیات افزایش داده شامل تبدیلات هندسی، تغییرات رنگ و تباین و اعمال محوشدگی

قرار گرفتند. این فرآیند باعث شد تا تعداد تصاویر برای مرحله آشکارسازی برگ‌ها به ۵۸۳۲ و برای طبقه‌بندی بیماری‌ها به ۶۴۴۷ تصویر افزایش یابد. مدل‌های یادگیری عمیق مانند YOLOv11 برای آشکارسازی برگ و MobileNet-V3^۳ برای طبقه‌بندی بیماری‌ها روی این داده‌های توسعه‌یافته آموزش داده شدند، تا سامانه پیشنهادی قابلیت عملکرد را در شرایط واقعی باغ‌های کیوی داشته باشد. کالامپوکاس و همکاران (Kalampokas et al., 2025) در پژوهش خود مجموعه داده تصویری اختصاصی را از برگ‌های درخت کیوی با هدف تشخیص بیماری‌های گیاهی تهیه کردند. تصاویر این مجموعه داده‌ها از باغ‌های کیوی واقع در منطقه کریسوپولی در استان کواوالا یونان جمع‌آوری شده و با استفاده از دوربین تلفن همراه با وضوح ۱۰۲۴×۱۹۲۰ پیکسل ثبت شده‌اند تا شرایط واقعی و در دسترس کشاورزان شبیه‌سازی شود. این مجموعه داده شامل چهار حالت مختلف، شامل سه بیماری آلترناریا، نماتد و فیتوفتورا به همراه حالت برگ سالم است. در مجموع، ۱۵۲ تصویر خام گردآوری شده که تنوع مناسبی از شرایط نوری، فاصله تصویربرداری و وضعیت سلامت برگ‌ها پوشش می‌دهد. تصاویر به صورت دستی و با استفاده از ابزار AnyLabeling در قالب جعبه‌های محدودکننده برچسب‌گذاری شده‌اند تا برای آموزش مدل‌های آشکارسازی برگ و تشخیص بیماری قابل استفاده باشند. به منظور افزایش تنوع داده‌ها و کاهش بیش‌برازش، مجموعه‌ای از روش‌های افزایش داده شامل تبدیلات هندسی، تغییرات رنگ و تباین و عملیات محوشدگی روی تصاویر اعمال شده است. این مجموعه داده‌ها با تمرکز بر کاربردهای عملی و

1- You Only Look Once

2- Bounding Box Regression


3- Mobile Network Version 3

پیکربندی و مورد استفاده قرار گرفت. این معماری، به عنوان نسخه‌ای بهبودیافته از چارچوب YOLO، امکان آموزش انتها به انتها و اجرای هم‌زمان رگرسیون جعبه‌های محدودکننده و طبقه‌بندی اشیاء را فراهم می‌کند (Khanam *et al.*, 2024). نمای کلی اجزای این معماری در شکل ۱ ارائه شده است.

توسعه سامانه‌های مبتنی بر وب، بستر مناسبی برای آموزش و ارزیابی مدل‌های یادگیری عمیق در تشخیص بیماری برگ کیوی فراهم می‌کند.

معماری YOLOv11

به منظور آشکارسازی برگ‌ها، معماری YOLOv11 متناسب با نیازهای این پژوهش



شکل ۱- معماری تفصیلی YOLOv11 مبتنی بر هرم ویژگی و هدهای تشخیص چندمقیاسی برای طبقه‌بندی بیماری‌های برگ کیوی (Khanam & Hussain, 2024)

Fig. 1- Structural Overview of the YOLOv11 Feature Pyramid Architecture for Multi-Scale Kiwifruit Leaf Disease Detection (Khanam & Hussain, 2024)

خانام و حسین (Khanam & Hussain, 2024) چارچوب YOLO با معرفی یک معماری یکپارچه شبکه عصبی، تحول چشمگیری در حوزه آشکارسازی اشیاء ایجاد کردند؛ به گونه‌ای که به طور هم‌زمان وظایف رگرسیون جعبه‌های محدودکننده و طبقه‌بندی اشیاء را عمل می‌کند. این رویکرد یکپارچه، فاصله معناداری با روش‌های سنتی دو مرحله‌ای ایجاد کرد و امکان آموزش انتها به انتها^۱ را فراهم ساخت. در تحقیقات گفته شده است در هسته اصلی این معماری، سه مؤلفه بنیادین وجود دارد. نخست، بخش Backbone به عنوان استخراج‌کننده اصلی ویژگی عمل می‌کند و با استفاده از شبکه‌های عصبی کانولوشنی، داده‌های خام تصویر را به نقشه‌های ویژگی چندمقیاسی تبدیل می‌کند. دوم، بخش Neck به عنوان مرحله پردازش میانی عمل می‌کند و از لایه‌های تخصصی برای تجمیع و تقویت نمایش ویژگی‌ها در مقیاس‌های مختلف بهره می‌برد. سوم، بخش Head به عنوان سازوکار پیش‌بینی عمل می‌کند و بر اساس نقشه‌های ویژگی پالایش‌شده، خروجی نهایی شامل مکان‌یابی و طبقه‌بندی اشیاء را تولید می‌کند.

الگوریتم پیشنهادی

به منظور ارزیابی کیفیت راه‌حل‌های کاندیدا و تعیین جبهه پارتوی بهینه، تابع برازندگی چندهدفه^۲ مورد استفاده در الگوریتم MOPSO^۳ مطابق رابطه ۱ تعریف شد.

$$\mathbf{x} = [lr, wd, bs, is, aug]$$

$$F(\mathbf{x}) = \left[1 - \frac{N_{correct}}{N_{total}}, \frac{1}{M} \sum_{i=1}^M t_i, \frac{4N_{param}}{1024^2} \right] \quad (1)$$

$$\min_{\mathbf{x}} F(\mathbf{x})$$

که در آن، $\mathbf{x}$ = بردار تصمیم هر ذره در الگوریتم MOPSO که شامل سرعت یادگیری (lr)، ضریب کاهش وزن (wd)، اندازه دسته (bs)، اندازه تصویر ورودی (is) و نوع افزایش داده (aug) است. تابع هدف از سه مؤلفه تشکیل شده است. مؤلفه اول $\left(1 - \frac{N_{correct}}{N_{total}}\right)$ بیانگر خطای طبقه‌بندی مدل است که در آن $N_{correct}$ تعداد نمونه‌های صحیح طبقه‌بندی شده و N_{total} تعداد کل نمونه‌های ارزیابی است. مؤلفه دوم $\left(\frac{1}{M} \sum_{i=1}^M t_i\right)$ میانگین زمان استنتاج مدل را نشان می‌دهد که در آن t_i زمان استنتاج در تکرار i و M تعداد دفعات اندازه‌گیری است. مؤلفه سوم $\left(\frac{4N_{param}}{1024^2}\right)$ حجم مدل را بر حسب مگابایت محاسبه می‌کند که در آن N_{param} تعداد کل پارامترهای شبکه عصبی است. هدف الگوریتم، کمینه‌سازی همزمان خطای طبقه‌بندی، زمان استنتاج و حجم مدل به منظور دستیابی به یک مدل دقیق، سریع و سبک است. برای انتخاب راه‌حل‌های غیرغالب^۴ از مفهوم غلبه پارتو و آرشیو خارجی در الگوریتم MOPSO استفاده شد (Coello et al., 2004).

ابتدا تصاویر خام برگ‌های درخت کیوی که در مجموعه داده AgriVision-Kiwi موجود بودند، جمع‌آوری شدند. پس از آن، برگ‌ها در تصاویر با استفاده از جعبه‌های محدودکننده حاشیه‌نویسی شدند و این داده‌ها برای آموزش مدل YOLOv11 به منظور تشخیص ناحیه برگ استفاده گردیدند. پس از تشخیص برگ‌ها، نواحی استخراج شده بر اساس جعبه‌های محدودکننده برش داده شده و با حذف پس‌زمینه و یکدست‌سازی، به تصاویر برگ خالص تبدیل شدند. به منظور افزایش تنوع داده‌ها و کاهش

1- End-to-End Training

2- Multi-Objective Fitness Function

3- Multi-Objective Particle Swarm Optimization

4- Non-Dominated Solutions


بیش‌برازش، عملیات افزایش داده روی تصاویر اعمال شد و مجموعه داده نهایی AgriVision-Kiwi برای مرحله طبقه‌بندی ایجاد گردید. در مرحله بعد، به منظور دستیابی به بهترین پیکربندی مدل، از الگوریتم بهینه‌سازی ازدحام ذرات چندهدفه برای تنظیم پارامترهای MobileNet-V3 استفاده شد (Coello *et al.*, 2004). جدول ۱ مقادیر پارامترهای کنترلی مورد استفاده در فرآیند

بهینه‌سازی ابرپارامترهای مدل پیشنهادی را ارائه می‌دهد. پس از تعیین پارامترهای بهینه، مدل Large MobileNet-V3 با استفاده از اعتبارسنجی متقاطع Fold-9 آموزش داده شد تا ویژگی‌های عمیق تصاویر استخراج و نوع بیماری برگ به صورت خودکار شناسایی شود. روند کلی اجرای روش پیشنهادی در شکل ۲ نمایش داده شده است.

جدول ۱- تنظیمات پارامترهای الگوریتم بهینه‌سازی ازدحام ذرات چندهدفه

Table 1. Parameter Settings of the multi-objective particle swarm optimization (MOPSO) algorithm

مقدار Value	پارامتر Parameter	توضیح Description	
6	NP	Particle number	تعداد ذرات
3	Itermax	Maximum iterations	حداکثر تعداد تکرار
5	Repository	Archive size	اندازه آرشیو
0.9	w	Weight factor	وزن اینرسی
1.49445	c1	Cognitive learning coefficient	ضریب یادگیری شناختی
1.49445	c2	Social learning coefficient	ضریب یادگیری اجتماعی



شکل ۲- روند شناسایی بیماری برگ کیوی با استفاده از مدل‌های YOLOv11 و MobileNet-V3

Fig. 2- Workflow for Kiwifruit Leaf Disease Detection Using YOLOv11 and MobileNet-V3

مقایسه نتایج به صورت منصفانه و یکنواخت دنبال شود. برای بهینه‌سازی پارامترهای مدل از الگوریتم Adam^۱ استفاده شد. این الگوریتم روش بهینه‌سازی است مبتنی بر گرادیان که با تنظیم تطبیقی سرعت یادگیری برای هر پارامتر، همگرایی پایدار و کارآمدی را فراهم می‌کند. فرآیند آموزش در قالب چندین دوره تکرار دنبال شد و داده‌ها در هر مرحله به صورت دسته‌ای به مدل ارائه شدند.

تابع زیان مورد استفاده برای کمینه‌سازی، آنتروپی متقاطع^۲ بود که به صورت رابطه ۲ تعریف می‌شود:

تنظیمات فرآیند آموزش و معیارهای ارزیابی عملکرد در تحقیقات کالامپوکاس و همکاران (Kalampokas *et al.*, 2025) فرآیند آموزش مدل‌ها با استفاده از روش اعتبارسنجی متقاطع طی شد. در هر تکرار، بخشی از داده‌ها برای آموزش و بخش مجزایی برای ارزیابی عملکرد مدل استفاده شد تا پایداری و قابلیت تعمیم مدل بررسی شود. این فرآیند به صورت تکرارشونده اجرا شد به گونه‌ای که تمامی داده‌ها در مراحل مختلف در نقش داده آموزشی و اعتبارسنجی قرار گرفتند. تنظیمات آموزشی در تمامی تکرارها ثابت نگه داشته شد تا

1- Adaptive Moment Estimation

2- Cross-Entropy Loss

$$L = -y \cdot \log(\hat{y}) \quad (۲)$$

که در آن،

y = نمایانگر برچسب واقعی^۱ نمونه که می‌تواند مقدار صفر یا ۱ برای مسائل دوحالته یا یک بردار one-hot برای مسائل چندحالتی باشد. از طرفی، y نمایانگر پیش‌بینی مدل است که احتمال تعلق نمونه به هر حالت را نشان می‌دهد و مقداری بین صفر و ۱ است. تابع لگاریتم $\log(\hat{y})$ باعث می‌شود که اگر مدل پیش‌بینی اشتباه با احتمال بالا داشته باشد (یعنی $y = 1$ و $\hat{y}$ نزدیک به صفر باشد)، مقدار زیان به شدت افزایش یابد، در حالی که اگر مدل پیش‌بینی صحیح با احتمال بالا داشته باشد (یعنی $\hat{y}$ نزدیک به ۱ باشد)، مقدار زیان کاهش می‌یابد. این ویژگی باعث می‌شود مدل بیشتر روی پیش‌بینی‌های اشتباه با احتمال بالا متمرکز شود و تلاش کند تا آن‌ها را کاهش دهد.

هدف اصلی در آموزش مدل‌های یادگیری ماشین، کمینه کردن مقدار زیان است. به عبارت دیگر، مدل سعی می‌کند پیش‌بینی‌های خود را طوری تنظیم کند که مقدار آنتروپی متقاطع پایین بیاید و خطاهای مدل کاهش یابد. تابع آنتروپی متقاطع برای مسائل طبقه‌بندی چندحالتی هم قابل استفاده است و به همین دلیل یکی از توابع زیان استاندارد در یادگیری عمیق و سایر الگوریتم‌های یادگیری ماشین محسوب می‌شود.

دقت مثبت^۲ میزان صحت پیش‌بینی‌های مثبت مدل را اندازه‌گیری می‌کند. در رابطه^۳، TP به تعداد نمونه‌های مثبت واقعی اشاره دارد که مدل آن‌ها را به درستی پیش‌بینی کرده است و FP به تعداد

نمونه‌های منفی اشاره دارد که اشتباهاً به عنوان مثبت پیش‌بینی شده‌اند. هرچه دقت مثبت بالاتر باشد، مدل بهتر می‌تواند نمونه‌های مثبت را به درستی شناسایی کند و خطای مثبت کمتری داشته باشد (Kalampokas et al., 2025).

$$\text{Precision} = \frac{\text{True Positives (TP)}}{\text{True Positives (TP)} + \text{False Positives (FP)}} \quad (۳)$$

ریکال یا حساسیت^۳ میزان توانایی مدل در شناسایی نمونه‌های مثبت واقعی را نشان می‌دهد. در رابطه^۴، TP = تعداد نمونه‌های مثبت واقعی که مدل آن‌ها را به درستی شناسایی کرده است و FN = تعداد نمونه‌های مثبت واقعی که مدل نتوانسته آن‌ها را شناسایی کند. ریکال یا حساسیت در مواقعی که هدف تشخیص همه نمونه‌های مثبت است، اهمیت ویژه‌ای دارد و یک مدل با ریکال یا حساسیت بالا می‌تواند به‌طور مؤثر نمونه‌های مثبت را شناسایی کند (Kalampokas et al., 2025).

$$\text{Recall} = \frac{\text{True Positives (TP)}}{\text{True Positives (TP)} + \text{False Negatives (FN)}} \quad (۴)$$

دقت کلی^۴، نسبت نمونه‌های درست پیش‌بینی‌شده به کل نمونه‌ها را نشان می‌دهد. در رابطه^۵، TP = تعداد نمونه‌های مثبت درست پیش‌بینی‌شده؛ TN = تعداد نمونه‌های منفی درست پیش‌بینی‌شده؛ FP = تعداد نمونه‌های منفی اشتباه پیش‌بینی‌شده و FN = تعداد نمونه‌های مثبت اشتباه پیش‌بینی‌شده. دقت به طور کلی عملکرد مدل را

1- True Label
3- Recall

2- Precision
4- Accuracy

نتایج و بحث

نتایج ارزیابی مدل MobileNetV3 Large در تکرار نهم از

اعتبارسنجی متقاطع ده‌تایی

مدل MobileNetV3 Large در فرآیند

۱۰-Fold Cross-Validation عملکرد بسیار خوبی

در شناسایی بیماری برگ کیوی از خود نشان داده

است. این مدل توانسته است عملکردی پایدار و

دقیق در تمامی تکرارها داشته باشد و توانایی بالایی

در شناسایی نمونه‌های مثبت از خود به نمایش

بگذارد. مدل تعادل مناسبی بین دقت و حساسیت

در شناسایی حالت‌ها یعنی سالم بودن برگ، آلودگی

ریشه کیوی به نماتد و آلودگی برگ به آلترناریا و

فیتوفتورا داشته و زمان استنتاج آن برای هر تصویر

مناسب و سریع است. علاوه بر این، اندازه مدل

به گونه‌ای است که برای استفاده در دستگاه‌های

لبه‌ای^۱ و کاربردهای بلادرنگ بسیار مناسب است.

این نتایج در جدول ۲ آورده شده است.

نشان می‌دهد، اما در مواقعی که داده‌ها نامتوازن

هستند (مثلاً تعداد نمونه‌های مثبت بسیار کمتر از

نمونه‌های منفی است)، ممکن است معیار مناسبی

نباشد (Kalampokas et al., 2025).

Accuracy

$$= \frac{\text{True Positives (TP)} + \text{True Negatives (TN)}}{\text{True Instances (TP + TN + FP + FN)}} \quad (5)$$

F1-Score میانگین هارمونیک دقت و ریکال (حساسیت)

است. در رابطه ۶، این معیار زمانی که داده‌ها

نامتوازن باشند، بسیار مهم است، زیرا هم دقت و هم

حساسیت را به طور همزمان در نظر می‌گیرد

(Kalampokas et al., 2025).

$$F1 - score = \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (6)$$

جدول ۲- نتایج ارزیابی مدل MobileNetV3 Large در تکرار نهم

Table 2- Evaluation Results of MobileNetV3 Large for Fold 9

توضیحات Description	انحراف معیار Standard Deviation	میانگین مقدار Mean Value	شاخص عملکرد Performance Metric
میانگین عملکرد در ۱۰ بخش Average performance across 10 folds	± 0. 004065	99. 703%	صحت کلی Accuracy
میانگین دقت در تمام حالت‌ها Macro-average precision across all classes	± 0. 003839	99. 7119%	دقت (میانگین ماکرو) Precision (Macro)
توانایی شناسایی صحیح هر حالت Ability to correctly identify each class	± 0. 004068	99. 703%	حساسیت (میانگین ماکرو) Recall (Macro)
تعادل بین دقت و حساسیت Balance between Precision and Recall	± 0. 004068	99. 703%	F1 (میانگین ماکرو) F1(Macro)
مناسب برای کاربردهای بلادرنگ Suitable for real-time applications	—	≈ 10. 40 ms	زمان استنتاج (تصویر تکی) Inference Time (Single Image)
سبک و مناسب برای استقرار در لبه شبکه Lightweight for edge deployment	—	16. 05 MB	حجم مدل Model Size
تعداد نمونه‌های اعتبارسنجی در این بخش Number of validation samples in this fold	—	640	تعداد نمونه اعتبارسنجی Validation Count

مقایسه عملکرد مدل پیشنهادی با مدل پایه

فرآیند بهینه‌سازی ابرپارامترها موجب بهبود عملکرد مدل در تمامی معیارهای اصلی شده است. مدل پیشنهادی ضمن دستیابی به دقت بالاتر، از زمان استنتاج بسیار کمتری دارد که آن را برای کاربردهای عملی و استقرار در سامانه‌های مبتنی بر وب و لبه شبکه مناسب می‌سازد. جزئیات این مقایسه در جدول ۳ ارائه شده است.

به منظور ارزیابی اثربخشی روش پیشنهادی، عملکرد مدل بهینه شده با نتایج گزارش شده برای مدل پایه در پژوهش کالامپوکاس و همکاران (Kalampokas et al., 2025) مقایسه شد. در این مقایسه، شاخص‌های دقت، دقت مثبت، حساسیت، امتیاز F1، زمان استنتاج و حجم مدل بررسی شدند. نتایج نشان می‌دهند که استفاده از

جدول ۳- مقایسه عملکرد مدل پیشنهادی با مدل پایه


Table 2. Comparison of Proposed and Baseline Model

بهبود Improvement	پیشنهادی مدل Proposed Model	پایه مدل Baseline Model	معیار Metric	
+1. 103%	99. 703%	98. 6%	Accuracy	دقت
+1. 112%	99. 712%	98. 6%	Precision	دقت مثبت
+1. 203%	99. 703%	98. 5%	Recall	حساسیت
-	99. 000%	-	F1-score	امتیاز اف ۱
≈50× Faster	10. 40 ms	496 ms	Inference Time	زمان استنتاج
-	16. 05 MB	-	Model Size	حجم مدل

معرفی کلی سامانه

توسعه می‌یابد و مدیریت اطلاعات کاربران و نتایج از طریق پایگاه داده MySQL صورت می‌گیرد. هدف از طراحی این سامانه، فراهم کردن بستری تحت وب برای استفاده آسان از مدل تشخیص بیماری برگ کیوی در محیط‌های واقعی است. کاربران می‌توانند تنها با بارگذاری یک تصویر از برگ کیوی، نتیجه تشخیص را در قالب حالت بیماری یا برگ سالم دریافت کنند. معماری سامانه به گونه‌ای طراحی شده است که امکان استفاده از تصاویر ثبت شده با تلفن همراه و دسترسی از طریق مرورگرهای وب را فراهم می‌کند. شکل ۳ نمایی از صفحه اصلی سامانه را نشان می‌دهد.

سامانه kiwifruitscanai.com یک پلتفرم هوشمند تحت وب برای تشخیص بیماری‌های برگ درخت کیوی از طریق تحلیل تصاویر است. در این سامانه، تصاویر بارگذاری شده ابتدا توسط مدل YOLOv11 پردازش خواهد شد و ناحیه برگ از تصویر استخراج می‌شود. پس از آن تصویر برگ استخراج شده به مدل MobileNet-V3 Large که پیش‌تر روی مجموعه داده AgriVision-Kiwi آموزش دیده است، ارسال می‌شود تا وضعیت سلامت برگ یا نوع بیماری تعیین گردد. سامانه با استفاده از زبان برنامه‌نویسی پایتون و چارچوب FastAPI



شکل ۳- صفحه اصلی سامانه تحت وب KiwiAI برای تشخیص خودکار بیماری‌های برگ کیوی با استفاده از مدل‌های یادگیری عمیق
Fig. 3- Home page of the web-based KiwiAI system for automatic kiwifruit leaf disease recognition using deep learning models


مستقل از برگ کیوی دارای نشانه‌های این بیماری که توسط دکتر نگین میرقاسمی، متخصص نماتدشناسی، تأیید شده بود (fasl5.co, 2023) توسط سامانه پردازش شد. نتایج تشخیص سامانه با برچسب اعلام شده توسط متخصص مطابقت کامل داشت. شکل ۵ نمونه‌ای از خروجی سامانه در تشخیص بیماری ناشی از آلودگی ریشه به نماتد از این تصویر مستقل را نمایش می‌دهد.

جریان کار سامانه

جریان کاری سامانه به صورت گام‌به‌گام پیش می‌رود. ابتدا تصویر برگ توسط کاربر بارگذاری می‌شود. تصویر ورودی پس از پیش‌پردازش اولیه، وارد مرحله آشکارسازی برگ می‌شود. پس از شناسایی ناحیه برگ، تصویر به مدل طبقه‌بندی بیماری ارسال و بیماری مرتبط تشخیص داده می‌شود. در پایان، نتیجه تشخیص به همراه نام بیماری از طریق رابط وب به کاربر ارائه می‌شود.


هدف اصلی سامانه پیشنهادی، فراهم کردن ابزاری ساده، در دسترس و کم‌هزینه برای کمک به کشاورزان در تشخیص زودهنگام بیماری‌های برگ درختان کیوی است. در این راستا، از معماری YOLOv11 برای آشکارسازی برگ‌ها و از مدل MobileNet-V3 برای طبقه‌بندی بیماری‌ها استفاده شد. پس از آموزش و ارزیابی مدل‌ها، سامانه به گونه‌ای پیاده‌سازی شد که کاربران بتوانند تصاویر برگ‌های کیوی را بارگذاری و نتیجه تشخیص را دریافت کنند. نمونه‌ای از خروجی‌های سامانه در تشخیص بیماری‌های برگ درختان کیوی در شکل ۴ نمایش داده شده است.

با توجه به اینکه بیماری ناشی از حمله نماتد به ریشه یکی از دشوارترین بیماری‌های برگ کیوی برای تشخیص از طریق تصاویر است و پژوهش‌های پیشین نیز به چالش‌برانگیز بودن شناسایی آن اشاره کرده‌اند (Kalampokas et al., 2025)، یک تصویر



شکل ۴- نمونه‌ای از عملکرد سامانه پیشنهادی در تشخیص بیماری برگ کیوی با استفاده از مجموعه داده مرجع

Fig. 4. An example of the performance of the proposed system in kiwifruit leaf disease detection using a reference dataset



شکل ۵- نمونه‌ای از خروجی سامانه در تشخیص بیماری نماتد از یک تصویر مستقل منتشرشده توسط متخصص نماتدشناسی،

دکتر نگین میر قاسمی (fasl5. co, 2023)

Figure 5. Example output of the system for detecting Nematodes disease from an independent kiwifruit leaf image, validated by plant pathology expert Dr. Negin Mir Ghasemi (fasl5. co, 2023)

نتیجه‌گیری

مسیرهای توسعه سامانه پیشنهادی، گسترش دامنه بیماری‌های قابل تشخیص از طریق افزودن بیماری‌های اقتصادی مهم در باغ‌های کیوی است. از جمله می‌توان به بیماری لکه قهوه‌ای کیوی^۱ ناشی از قارچ *Corynespora cassiicola* اشاره کرد. ژو و همکاران (Zhu et al., 2025) گزارش کردند که این بیماری با ایجاد ریزش زودهنگام برگ‌ها، موجب کاهش میانگین عملکرد محصول به میزان ۲۲/۶۵ درصد و تنزل یک درجه‌ای کیفیت میوه کیوی می‌شود و در نهایت خسارتی اقتصادی در حدود ۷۳/۵۹۱ یوان در هر هکتار به همراه دارد. از این‌رو، توسعه سامانه پیشنهادی و افزودن قابلیت تشخیص این بیماری می‌تواند در شناسایی زودهنگام آلودگی، کاهش خسارت‌های اقتصادی و بهبود مدیریت باغ‌های کیوی نقش مؤثری داشته باشد.

سامانه پیشنهادی با دریافت تصویر برگ کیوی از کاربر، تصویر را از طریق مدل YOLOv11 پردازش کرده و ناحیه برگ را استخراج می‌کند. تصویر برگ استخراج شده توسط مدل MobileNet-V3 Large تحلیل شده و نتیجه تشخیص در قالب حالت بیماری یا سلامت برگ از طریق رابط وب نمایش داده می‌شود. ارزیابی مدل مورد استفاده در سامانه بر روی مجموعه داده AgriVision-Kiwi نشان داد که مدل به صحت کلی ۹۹/۷۰۳ درصد، دقت ۹۹/۷۱۱۹ درصد، حساسیت ۹۹/۷۰۳ درصد و امتیاز F1 برابر با ۹۹/۷۰۳ درصد دست یافته است. طراحی سامانه به گونه‌ای است که کاربران می‌توانند تنها با بارگذاری یک تصویر از برگ کیوی، نتیجه تشخیص را دریافت کنند. وب‌محور بودن سامانه امکان استفاده از آن را از طریق رایانه و تلفن همراه فراهم می‌سازد. یکی از

تعارض منافع

نویسندگان در خصوص انتشار 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 منافعی تجاری در این راستا وجود ندارد.

مراجع

- Anon. (2024). Report on area, production, and yield of kiwi fruit by province (Table 50-1-3). Ministry of Agriculture Jihad, Iran. (in Persian)
- Aydınlı, G., & Mennan, S. (2022). Prevalence of root-knot nematodes and their effects on fruit yield in kiwifruit orchards in Samsun Province (Türkiye). *Turkish Journal of Entomology*, 46(2), 187-197. <https://doi.org/10.16970/entoted.1092654>.
- Banihashemian, S. N., Jamali, S., Golmohammadi, M., & Ghasemnezhad, M. (2022). Isolation and identification of endophytic bacteria associated with kiwifruit and their biocontrol potential against *Meloidogyne incognita*. *Egyptian Journal of Biological Pest Control*, 32(1), 111. <https://doi.org/10.1186/s41938-022-00601-y>.
- Bansal, A., Sharma, R., Sharma, V., Jain, A. K., & Kukreja, V. (2023). An automated approach for accurate detection and classification of kiwi powdery mildew disease. *Proceedings of the 2023 IEEE 8th International Conference for Convergence in Technology (I2CT)*. April. 7. Lonavla, India. <http://doi:10.1109/I2CT57861.2023.10126126>.

- Bi, X., Hieno, A., Otsubo, K., Kageyama, K., Liu, G., & Li, M. A. (2019). Multiplex PCR assay for three pathogenic phytophthora species related to kiwifruit diseases in China. *Journal of General Plant Pathology*, 85, 12-22. <https://doi.org/10.1007/s10327-018-0822-3>.
- Coello Coello, C. A., Pulido, G. T., & Lechuga, M. S. (2004). Handling multiple objectives with particle swarm optimization. *IEEE Transactions on Evolutionary Computation*, 8(3), 256-279. <https://doi.org/10.1109/TEVC.2004.826067>.
- El-Borai, F. E., & Duncan, L. W. (2005). *Nematode parasites of subtropical and tropical fruit tree crops*. In M. Luc, M., Sikora, R. A., and Bridge, J. (Eds) Plant parasitic nematodes in subtropical and tropical agriculture, CABI Pub. Wallingford, UK. <https://doi.org/10.1079/9780851997278.0467>.
- Filippone, M., Camastra, F., Masulli, F., & Rovetta, S. A. (2008). Survey of kernel and spectral methods for clustering. *Pattern Recognit*, 41, 176-190. doi:<https://doi.org/10.1016/j.patcog.2007.05.018>.
- Govender, P., & Sivakumar, V. (2020). Application of k-means and hierarchical clustering techniques for analysis of air pollution: A review (1980-2019). *Atmospheric Pollution Research (APR)*, 11, 40-56. <https://doi.org/10.1016/j.apr.2019.09.009>.
- Gonçalves, A. R., Conceição, I. L., Carvalho, R. P., & Costa, S. R. (2025). Meloidogyne hapla dominates plant-parasitic nematode communities associated with kiwifruit orchards in Portugal. *Plant Pathology*, 74(1), 171-179. <https://doi.org/10.1111/ppa.14005>.
- Hosny, K. M., El-Hady, W. M., Samy, F. M., Vrochidou, E., & Papakostas, G. A. (2023). Multi-class classification of plant leaf diseases using feature fusion of deep convolutional neural network and local binary pattern. *IEEE Access*, 11, 62307-62317. <https://doi.org/10.1109/ACCESS.2023.3286730>.
- Huang, K., Tang, J., Zou, Y., Sun, X., Lan, J., Wang, W., Xu, P., Wu, X., Ma, R., Wang, Q., Wang, Z., & Liu, J. (2021). Whole genome sequence of alternaria alternata, the causal agent of black spot of kiwifruit. *Frontiers in Microbiology*, 12, 713462. <https://doi.org/10.3389/fmicb.2021.713462>.
- Kalampokas, T., Vrochidou, E., Mavridou, E., Iliadis, L., Voglitsis, D., Michalopoulou, M., Broufas, G., & Papakostas, G. A. (2025). Empowering kiwifruit cultivation with AI: Leaf disease recognition using agrivision-kiwi open dataset. *Electronics*, 14(9), 1705. <https://doi.org/10.3390/electronics14091705>.
- Khanam, R., & Hussain, M. (2024). YOLOv11: An overview of the key architectural enhancements. arXiv. <https://arxiv.org/abs/2410.17725>.
- Liu, J., & Wang, X. (2021). Diseases and pests detection based on deep learning: A Review. *Plant Methods*, 17, 22. <https://doi.org/10.1186/s13007-021-00722-9>.
- Mridha, K., Ranpariya, A., Kumbhani, S., Ghosh, A., & Shaw, R. N. (2021). Plant disease detection using web application by neural network. *Proceedings of the 2021 IEEE 6th International Conference on Computing, Communication and Automation (ICCCA)*. Dec. 17-19, Arad, Romania. <https://doi.org/10.1109/ICCCA52192.2021.9666354>.
- Shakya, S. (2020). Analysis of artificial intelligence based image classification techniques. *Journal of Innovative Image Processing (JIIP)*, 2(01), 44-54. <https://doi.org/10.36548/jiip.2020.1.005>.
- Tao, Y., Xu, C., Yuan, C., Wang, H., Lin, B., Zhuo, K., & Liao, J. (2017). Meloidogyne aberrans sp. nov.(Nematoda: Meloidogynidae), a new root-knot nematode parasitizing kiwifruit in China. *PLoS one*, 12(8), e0182627. <https://doi.org/10.1371/journal.pone.0182627>.
- Wu, Z., Li, X., Chung, K. L., & Chen, J. (2025). AI-powered identification of corn leaf diseases and pests: A flask-based web application for enhanced agricultural decision-making. In *2025 8th World Conference*

- on Computing and Communication Technologies (WCCCT). April, 11-13, Shenzhen, China. <https://doi.org/10.1109/WCCCT65447.2025.11027989>.
- Yao, J., Wang, Y., Xiang, Y., Yang, J., Zhu, Y., Li, X., Li, S., Zhang, J., & Gong, G. (2022). Two-stage detection algorithm for kiwifruit leaf diseases based on deep learning. *Plants*, 11(6), 768. <https://doi.org/10.3390/plants11060768>.
- Zhu, Y., Xu, J., Wang, J., Yang, R., Chen, W., Yao, K., Ma, M., Chen, Q., Fan, Z., Wu, C., Hu, R., & Gong, G. (2025). Different disease levels reveal kiwifruit brown spot impacts on fruit yield and quality. *Journal of Fungi*, 11(8), 593. <https://doi.org/10.3390/jof11080593>.

Original Paper

Design and Implementation of a Web-Based Intelligent System for Kiwifruit Leaf Disease Detection Using Deep Learning

A. Hosseini Khotbeh-Sara and M. Sadeghzadeh*

*Corresponding Author: Associate Professor, Department of Computer Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran. Gmail: sadeghzadeh1999@gmail.com

<https://orcid.org/0000-0002-0489-7551>

Received: 26 February 2026, Accepted: 23 June 2026

<http://doi.org/10.22092/amsr.2026.372416.1534>

Abstract

In this study, an intelligent web-based system is presented for diagnosing kiwifruit leaf diseases through image analysis. The proposed system is capable of identifying four conditions: healthy leaves, kiwifruit root infection caused by nematodes, Alternaria leaf infection, and Phytophthora leaf infection. The system was evaluated using the AgriVision-Kiwi benchmark dataset, which has been employed in previous studies on kiwifruit leaf disease diagnosis. In the first stage, the You Only Look Once version 11 (YOLOv11) algorithm was used to detect and localize leaf regions. Subsequently, the detected leaves were classified using the MobileNet-V3 deep learning architecture. The system was developed in Python using the FastAPI framework, while data management was implemented through a MySQL database. The evaluation results obtained on the AgriVision-Kiwi dataset using 10-fold cross-validation demonstrated an overall accuracy of 99.703%, a macro-averaged precision of 99.7119%, a macro-averaged recall of 99.703%, and a macro-averaged F1-score of 99.703%. These results demonstrate the system's effectiveness in distinguishing among the four target conditions: healthy leaves, kiwifruit root infection caused by nematodes, Alternaria leaf infection, and Phytophthora leaf infection. The findings further indicate that the proposed system has considerable potential for application under real-world conditions in kiwifruit orchards. Moreover, the web-based nature of the system enhances its accessibility and enables users to employ it directly in orchard environments without requiring complex or specialized equipment.

Keywords: Computer Vision, Convolutional Neural Network, Fine-Grained Classification, Phenotyping



© 2024 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)