

دوازدهمین کنگره ملی سراسری
فناوریهای نوین در حوزه توسعه پایدار ایران
12th National Congress of
the New Technologies in Sustainable Development of Iran

senacnf.ir

بررسی استفاده از تکنیک های یادگیری ماشین در تشخیص آفات و بیماری
محصولات کشاورزی

راضیه همت پور¹، سمیه هرانده²

¹دانشکده فنی و حرفه ای دختران سمنان ، سمنان rhemmatpour@tvu.ac.ir

²دانشکده فنی و حرفه ای دختران سمنان ، سمنان sharande @tvu.ac.ir

چکیده

حملات آفات و بیماری ها، تهدیدی دائمی برای کشاورزی بوده و خسارات سنگینی به اقتصاد کشور وارد می کند. بنابراین، تشخیص زودهنگام آن می تواند شدت بیماری ها را کاهش داده و از محصولات محافظت نماید. با این حال، شناسایی دستی بیماری و آفات محصولات زمان بر و مستعد خطا است و نیاز به دانش کامل از پاتوزن های گیاهی دارد. با توسعه چشمگیر تکنولوژی، با جایگزینی فناوری های نوین و به کارگیری آنها در جمع آوری و تحلیل داده، به افزایش دقت و سرعت تشخیص، کمک شایانی نموده است. در خلال سال های گذشته روش های شناخته شده پردازش تصویر، یادگیری ماشین و یادگیری عمیق در طبقه بندی و شناسایی بیماری و آفات کشاورزی استفاده شده اند. در این مقاله سعی داریم شما را با این روش ها آشنا کرده و آنها را با یکدیگر مقایسه کنیم.

واژه های کلیدی

یادگیری ماشین، یادگیری عمیق، تصویربرداری فراطیفی، تشخیص آفات و بیماری، کشاورزی

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

1- مقدمه

کشاورزی رکن اصلی بسیاری از کشورهاست. با توجه به رشد جمعیت، تقاضا برای مواد غذایی به طور پیوسته در حال افزایش است. برای رفع این نیاز مبرم، افزایش بهره وری کشاورزی و حفاظت از محصولات ضروری است. با این وجود، محصولات زراعی به دلیل وجود تعداد زیادی پاتوژن در محیط، مستعد ابتلا به بیماری های مختلف هستند. برخی از این پاتوژن های بیماری، ارگانسیم های ویروسی هستند، در حالی که برخی دیگر قارچی یا باکتریایی هستند [2]. بیماری های زراعی می توانند بهره وری را بین 10 تا 95 درصد کاهش دهند در نتیجه کاهش قابل توجهی در کمیت و کیفیت تولیدات کشاورزی ایجاد کنند [3]. بنابراین، شناسایی زودهنگام بیماری ها برای جلوگیری از خسارات هنگفت و کاهش استفاده بی رویه از آفت کش ها که می تواند به سلامت انسان و محیط زیست آسیب برساند، حیاتی است. در بیشتر موارد و به ویژه در کشورهای در حال توسعه و مزارع کوچک، کشاورزان بیماری های محصول را با چشم غیر مسلح بر اساس علائم بصری شناسایی می کنند. این کار خسته کننده است و نیاز به تخصص در آسیب شناسی گیاهی و زمان درمان طولانی دارد [4]. همچنین اگر مزرعه مورد حمله یک بیماری نادر قرار گیرد، کشاورزان برای به دست آوردن یک تشخیص دقیق و کارآمد به دنبال مشاوره تخصصی هستند بدیهی است هزینه های درمانی اضافی را به همراه دارد [5]. بنابراین، این روش مشاهده بصری برای مزارع بزرگ عملی و امکان پذیر نیست و حتی ممکن است به دلیل تصمیم گیری های مغرضانه، پیش بینی های اشتباهی را به همراه داشته باشد [6]. محدودیت های رویکرد سنتی، پژوهشگران را برانگیخته است تا پیشنهادات فناوری را برای شناسایی زودهنگام بیماری های محصول به روشی دقیق، سریع و قابل اعتماد و به منظور برآورده کردن نیازهای روزافزون مصرف کنندگان و کاهش اثرات زیست محیطی، نهادهای شیمیایی بر روی گیاهان، توسعه دهند. علاوه بر این، حملات آفات نیز از دیگر مشکلات کشاورزی محسوب می شود به خصوص در محیط گلخانه ای، شرایط برای رشد و تکثیر آفات فراهم است. در این مقاله به شناخت انواع آفات و بیماری های محصولات کشاورزی اشاره می شود سپس به مطالعه تطبیقی تکنیک های مختلف مورد استفاده و مقایسه عملکرد آنها و الگوریتم های مختلف، تکنیک های مورد استفاده برای طبقه بندی و تشخیص آفت و بیماری محصولات کشاورزی می پردازد. در ادامه چالش ها و راه حل های رفع چالش ها مورد بحث قرار می گیرد و در نهایت روش پیشنهادی بیان می شود.

2- انواع آفات گیاهی و شناسایی آنها

شناسایی دستی بیماری های محصول هم می تواند دقیق و هم نادرست باشد به این معنی که فقط در مزارع کوچک امکان پذیر است [6]. در مقابل، تشخیص خودکار بیماری به طور قابل توجهی دقیق تر است و زمان و کار کمتری را می طلبد [7]. در نتیجه، مطالعات متعدد انجام شده است [8-11]. در ادامه به تفصیل مورد بحث قرار می گیرد.

1-2- طبقه بندی بیماری های محصولات زراعی و علائم آنها

برگ های محصولات به شدت مستعد ابتلا به بیماری هایی هستند که یک پدیده طبیعی است [12]. با این حال، اگر اقدامات اصلاحی در زمان مناسب برای جلوگیری از شیوع بیماری انجام نشود، منجر به کاهش قابل توجهی در کیفیت و کمیت محصولات کشاورزی می شود [13]. محصولات زراعی تحت تأثیر عوامل بیماری زا مختلفی مانند ویروس ها، باکتری ها، قارچ ها قرار می گیرند [2]. بنابراین، پاتوژن های مسئول این بیماری به دو دسته طبقه بندی می شوند: اتوتروف ها، که در بافت زنده رشد می کنند، یا ساپروفیت ها، که در بافت های مرده ساکن هستند [14]. علائم بیماری بر رشد و نمو محصولات زراعی تأثیر منفی می گذارد و به راحتی قابل مشاهده است. تغییر رنگ برگ، اولین علامت بیماری در گیاهان است. علاوه بر این، شکل و بافت برگ ها در تشخیص بیماری های مختلف بسیار مفید است. بنابراین، بیماری های مختلف مانند کپک، زنگ و سفیدک پودری را می توان با پردازش تصویر برگ ها تشخیص داد [15، 16]. در زیر شرح مختصری از سه نوع بیماری گیاهی رایج به همراه تصاویر در شکل 1 ارائه می شود [17]. در جدول 1 بیماری و آفات رایج برخی محصولات شرح داده می شود.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir



بیماری ویروسی



بیماری قارچی



بیماری باکتریایی

شکل 1: انواع بیماری گیاه

- بیماری های ویروسی: در بین همه بیماری های گیاهی، تشخیص بیماری های ناشی از عفونت دشوار است. علاوه بر این، این علائم با نشانه های کمبود تغذیه یا آسیب اشتباه گرفته می شوند، زیرا هیچ شاخص از پیش تعیین شده ای وجود ندارد [2].
- بیماری های قارچی: بیماری های محلول پاشی توسط قارچ مانند سفیدک، آنتراکنوز و سفیدک پودری ایجاد می شود. در ابتدا روی برگهای پایینی پیر که دارای لکه های سبز مایل به خاکستری هستند یا در آب خیس می شوند ظاهر می شود. با بالغ شدن انگل، این لکه ها تیره می شوند و باعث رشد قارچ روی آنها می شوند [2].
- بیماری های باکتریایی: عوامل بیماری زا باعث ایجاد بیماری های جدی در سبزیجات می شوند. آنها مستقیماً وارد پوشش گیاهی نمی شوند، بلکه از طریق جراحات یا منافذ در محصول وارد می شوند مانند: صدمات ناشی از عوامل بیماری زا، حشرات و ادوات کشاورزی مختلف در حین انجام کارهایی مانند چیدن و هرس [2].

جدول 1: بیماری و آفات رایج برخی محصولات

برگ محصول	بیماری / نام علمی	علائم	دسته بندی پاتوزن
برنج	<i>Bipolaris oryzae</i> - لکه قهوه ای / <i>Pyricularia oryzae</i> Cavara - از بیم رفتن برگ /	- مرکز خاکستری مایل به سفید - قهوه ای تیره نامنظم	- قارچ
پنبه	<i>Stemphylium solani</i> - برگ فالیار / - کپک آرنولات/سروکوسپورا - لکه برگ/لکه آلترناریا	- لکه رنگ زرد روشن با تیره حاشیه های قهوه ای - لکه قهوه ای برنزه	- قارچ، باکتریایی، - ویروس - قارچ
	<i>Xanthomonas campestris</i> - بلایت باکتریایی /	- لکه های دایره ای برگ قهوه ای تیره تا سیاه - سبز مایل به زرد هاله	- قارچ - باکتریایی
مرکبات	- ملانوز/دیاپورته سیتری - لکه چرب / آمیکوسفارلا آفریکانا <i>Canker/Xanthomonas citri</i> subsp	- برگ در هنگام لمس خشن می شود - تاول قهوه ای مایل به زرد - شامل برگ صاف، متورم، ترک خورده، گرد تا فرورفته نامنظم است	- قارچ - قارچ - قارچ، باکتریایی
گوجه فرنگی	- بلایت زودرس / آلترناریا توماتوفیلا <i>Phytophthora infestans</i> - بلایت دیررس / <i>Leveillula taurica</i> - سفیدک پودری / - ویروس کلروز عفونی حلقه زرد/گوجه فرنگی	- نقطه حلقه تیره اطراف آن زرد است - لکه تاریک به سرعت در حال رشد است - برگ مجعد و مایل به زرد - خیس شده در آب حلقه شده توسط هاله زرد	- قارچ - قارچ - قارچ - ویروس
ذرت <i>carotovora</i>	<i>Erwinia</i> - پوسیدگی ساقه /	- زرد شدن برگهای سبز مات و قسمت های پایین ساقه	- قارچ
گندم	<i>Puccinia triticina</i> Erikss. - زنگ / <i>Blumeria graminis</i> - سفیدک پودری / - بلایت باکتریایی/سودوموناس سرنگه	- لکه های رنگ پریده برگ - در حالی که لکه خاکستری یا قهوه ای است - سبز مایل به زرد هاله	- قارچ - قارچ - باکتریایی
هندوانه	<i>Colletotrichum orbiculare</i> - آنتراکنوز / <i>Pseudoperonospora cubensis</i> - سفیدک کرکی /	- لکه های زرد نامنظم - لکه های زرد تا سفید	- قارچ

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senacnf.ir

علاوه بر بیماری ها، حملات آفت ها نیز یکی از مشکلات کشاورزان است. توسعه کشت های گلخانه ای چالش های زیادی را برای تولیدکنندگان و کشاورزان در پی داشته است. یکی از این چالش ها کنترل آفات در محیط های گلخانه ای است. کنترل شیمیایی آفات، به ویژه برای محصولات گلخانه ای مخاطرات بسیاری را در پی دارد. لذا استفاده از روش های کم خطرتر کاملاً ضروری است. آفات مهمی که در گلخانه های کشور روی سبزی های گلخانه ای خسارت ایجاد می کنند شامل بید گوجه فرنگی، تریپس ها، سفید بالک ها، شته ها، کنه ها و مگس های مینوز هستند. استفاده از نور در مدیریت این آفات بیشتر برای بید گوجه فرنگی، سفید بالک ها، تریپس ها و مگس های مینوز موفق بوده است. بید گوجه فرنگی یا شبیره مینوز یکی از آفات کلیدی گوجه فرنگی در دنیا است. خسارت این آفت به صورت کاهش رشد، کاهش کمی و کیفی میوه، از بین رفتن گیاه و کاهش بازپسندی (بین 50 تا 100 درصد) است. در شکل 2 تصاویر آفات رایج در ایران را مشاهده می کنید [1].



شته



تریپس



مگس مینوز



بید(شب پره) گوجه فرنگی



آبدزدک



مگس سفید (سفید بالک)



کنه



شیشک

شکل 2: انواع آفات رایج در گلخانه های ایران

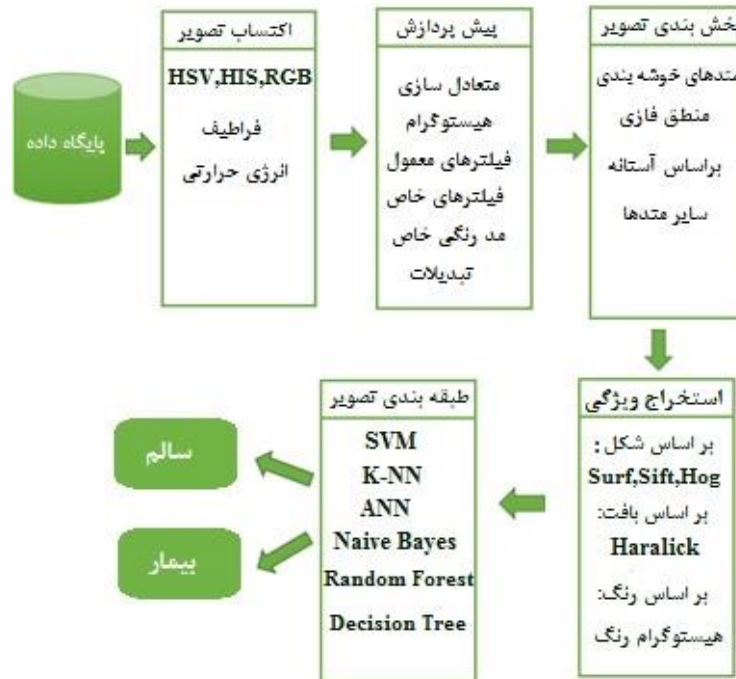
2-2 جمع آوری اطلاعات و روند شناسایی آفت یا بیماری گیاه

تصاویر برگ ها منبع با ارزشی از داده ها در مورد آسیب شناسی گیاه و رفتار مورفولوژیکی هستند. بنابراین، این داده ها باید به طور کامل استخراج و تجزیه و تحلیل شوند. پردازش تصویر [17] نقش مهمی در تشخیص و تجزیه و تحلیل بیماری های برگ ایفا می کند. روش مرسوم در فرآیند شناسایی بیماری برگ در شکل 3 نشان داده شده است، که بینشی از تکنیک های مختلف به کار گرفته شده توسط نویسندگان برای تشخیص بیماری با استفاده از پردازش تصویر و هوش مصنوعی را نشان می دهد.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir



شکل 3: فرایند شناسایی بیماری/آفت گیاه در پردازش تصویر

گام اول [18] در شناسایی بیماری ها، دریافت تصاویر است. در بیشتر موارد، تصاویر را می توان از یک دوربین دیجیتال یا یک سیستم تصویربرداری دریافت کرد. از آنجایی که تصاویر خام مستعد داشتن نویز هستند، حذف این ناخالصی ها ضروری است. مرحله دوم به عنوان پیش پردازش تصویر شناخته می شود و شامل حذف اعوجاج های ناخواسته، علاوه بر آن افزایش کنتراست برای شفاف سازی و روشن تر کردن ویژگی های تصویر است. به عنوان مثال، یک تابع گاوسی که تار می ملایم ایجاد می کند معمولاً برای کاهش نویز در تصویر استفاده می شود. پس از آن، بخش بندی تصویر [19] سومین مرحله ای است که در آن تصویر از پس زمینه آن قطعه بندی می شود، در حالی که ناحیه مورد نظر¹ برای تأکید بر ویژگی های برجسته تقسیم بندی می شود. مرحله چهارم استخراج ویژگی [20] است که اطلاعات و جزئیات یک تصویر را آشکار می کند. لازم به ذکر است ویژگی های برگ معمولاً شامل شکل، بافت و رنگ است که برای تشخیص محصول استفاده می شود. بنابراین، این ویژگی های انتخاب شده یک بردار ویژگی ورودی را تشکیل می دهند سپس به طبقه بندی کننده وارد می شوند. با استفاده از این بردار، می توان یک دسته از اشیاء را از دسته دیگر متمایز کرد. مرحله نهایی طبقه بندی [21] است. توجه داشته باشید که انتخاب یک طبقه بندی مناسب به مسئله بستگی دارد. هدف طبقه بندی کننده تشخیص تصاویر و مرتب سازی آنها در چندین کلاس از پیش تعریف شده بر اساس بردار ویژگی به دست آمده در مرحله چهارم است. برای این منظور، وظیفه طبقه بندی شامل دو مرحله، آموزش و آزمایش است. عملیات آموزشی، طبقه بندی کننده بر روی یک مجموعه داده آموزشی یاد می گیرد. بنابراین، هر چه تعداد مجموعه های آموزشی بیشتر باشد، دقت به دست آمده بهتر است. لازم به ذکر است که نتیجه باید در زمان مطلوبی حاصل شود.

¹ Region Of Interest (ROI)

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senacnf.ir

3- پیشینه تحقیق

در این بخش طبقه‌بندی بیماری‌های مختلف محصولات ارائه می‌شود و مفهوم تصویر برداری فراطیفی^۲، پردازش تصویر^۳، یادگیری ماشین^۴، یادگیری عمیق^۵ و یادگیری انتقالی^۶ را توضیح می‌دهد. در ادامه چندین پژوهش در زمینه تشخیص خودکار بیماری و آفت گیاهان بررسی می‌شود.

1-3- تصویربرداری فراطیفی برای تشخیص بیماری

چندین روش [22-25] برای خودکار کردن فرآیند تشخیص بیماری پیشنهاد شده است. این روش‌ها برای تشخیص خودکار بیماری‌های محصول به دو گروه روش‌های مستقیم و غیر مستقیم تقسیم می‌شوند [26]. روش‌های مستقیم شامل تکنیک‌های مولکولی [27] و سرولوژیکی [28,29] است که تشخیص دقیق و مستقیم عوامل بیماری‌زای محرک بیماری را فراهم می‌کند. این تکنیک‌ها به زمان قابل توجهی برای جمع‌آوری، پردازش و تجزیه و تحلیل نمونه‌های جمع‌آوری شده نیاز دارند. در مقابل، تکنیک‌های تصویربرداری نوری [31,30] از جمله روش‌های غیرمستقیم هستند که قادر به شناسایی بیماری‌ها و پیش‌بینی سلامت محصول از طریق پارامترهای مختلف مانند تغییرات مورفولوژیکی و میزان تعرق هستند.

روش تصویربرداری فراطیفی به طرز چشم‌گیری در دو دهه گذشته توسعه یافته است [32]، و برای شناسایی تنش‌های غیر زنده و زیستی در گیاهان کشت شده استفاده می‌شود [33]. تصویربرداری فراطیفی تکنیکی است که طیف سنجی و تصویر را با هم ترکیب می‌کند و امکان دستیابی همزمان اطلاعات فضایی و طیفی یک شی را فراهم می‌کند. عفونت بیماری باعث تغییراتی در خواص بیوشیمیایی و بیوفیزیکی گیاه مانند سرعت تعرق، ساختار بافت، آب و محتوای رنگدانه می‌شود. سپس این تغییرات می‌تواند خواص طیفی گیاه، فضای بین سلولی و محتوای آب را تغییر دهد [34]. با این حال، سیستم فراطیفی قادر به گرفتن این ویژگی‌های طیفی است. تصویربرداری طیفی نیاز به دوربین‌های تصویر برداری خاص دارد. فلورسانس و تصویربرداری فراطیفی [35] پرکاربردترین روش‌های غیرمستقیم برای شناسایی اولیه بیماری هستند. اگرچه تصاویر فراطیفی منبع ارزشمندی از داده‌ها و حاوی اطلاعات بیشتری نسبت به عکس‌های معمولی هستند [36]، اما دستگاه‌های فراطیفی بسیار گران، حجیم و برای کشاورزان کم درآمد به سختی به دست می‌آیند. از طرف دیگر، انواع دیگر دوربین‌های دیجیتال با قیمت‌های مناسب در فروشگاه‌های لوازم الکترونیکی موجود است. در نتیجه، بیشتر فرآیندهای شناسایی خودکار در نظر گرفته شده تاکنون بر روی تصاویر قابل مشاهده متمرکز شده‌اند که امکان استفاده از الگوریتم‌های بسیار دقیق و سریع را فراهم می‌کند. از این رو، این بررسی بر روی رویکردهای مختلف مبتنی بر تکنیک‌های پردازش تصویر و طیف سنجی برای تشخیص خودکار بیماری‌های محصول با استفاده از رویکردها و الگوریتم‌های متعدد با استفاده از یادگیری عمیق و ماشین، منطق فازی و یادگیری انتقال تمرکز می‌کند.

2-3- یادگیری ماشین و یادگیری عمیق

رایانه‌ها می‌توانند با استفاده از حجم عظیمی از داده، به طور خودکار الگوهای تکرارشونده را بدون دخالت انسان یاد بگیرند. یادگیری این الگوریتم‌ها به تقلید از شیوه یادگیری انسان انجام می‌شود و با بیشتر شدن تجربه رایانه، به تدریج دقت آن بالاتر می‌رود. یادگیری عمیق یکی از روش‌های یادگیری ماشین است. در این روش ماشین‌ها یاد می‌گیرند که بر اساس مدل‌هایی شبیه شبکه‌های عصبی مغز انسان مفاهیم سطح بالا و انتزاعی را یاد بگیرند. استفاده از یادگیری عمیق کمک می‌کند ماشین‌ها بتوانند تصمیم‌هایی شبیه تصمیم‌های انسانی بگیرند.

تفاوت بین یادگیری ماشین و یادگیری عمیق [37]، در این واقعیت نهفته است که الگوریتم‌های یادگیری ماشینی با داده‌های کمی و ساختاری سروکار دارند و اپراتور مسئول انتخاب الگوریتم مناسب برای استخراج ویژگی‌هایی است که بر پیش‌بینی تأثیر می‌

² hyperspectral imaging

³ Image processing

⁴ Machine Learning

⁵ Deep Learning

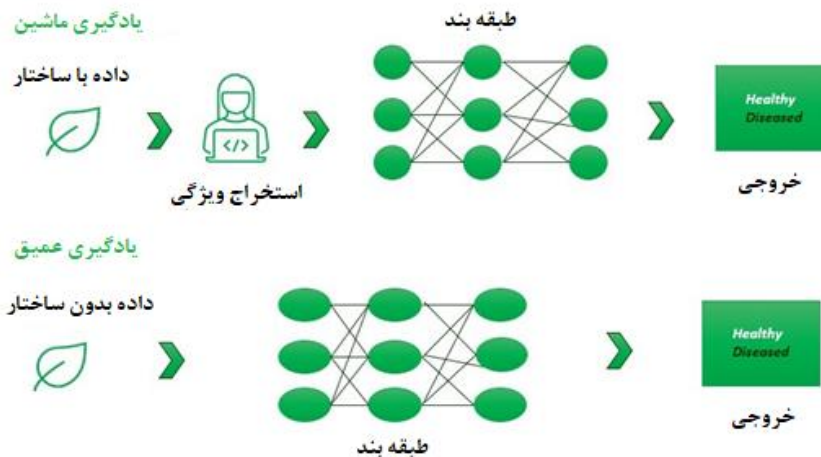
⁶ Transfer learning

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

گذارد. الگوریتم های یادگیری عمیق با داده های بدون ساختار سروکار دارند و برای استخراج عناصر تأثیرگذار در پیش بینی همانطور که در شکل 4 نشان داده شده است آموزش داده می شود. لازم به ذکر است الگوریتم های یادگیری عمیق در مقایسه با الگوریتم های یادگیری ماشین، حجم زیادی از داده ها و قدرت محاسباتی بالایی را طلب می کنند. در ادامه به بیان پژوهش هایی که در این زمینه صورت گرفته، پرداخته می شود.



شکل 4: مقایسه بین یادگیری ماشین و یادگیری عمیق

- R.Sujatha و همکاران (2021) از معماری Squeeze net (SN) و الگوریتم یادگیری (L-SVM) و جنگل تصادفی⁷ در تشخیص بیماری های برگ مرکبات استفاده کردند. دقت طبقه بندی الگوریتم های مختلف را به دست آوردند: RF 76 درصد ، SGD 86.5 درصد، ماشین بردار پشتیبان⁸ 87 درصد، VGG19 87.4 درصد، InceptionV3 89 درصد، VGG16 89.5 درصد. از نتایج به دست آمده RF کمترین و VGG16 بهترین دقت را ارائه دادند [38].
- Deepa و همکاران (2021) الگوریتم ماشین بردار پشتیبان چندکلاسه را برای تشخیص آفت برگ گیاه گوجه فرنگی پیشنهاد دادند. این روش از تکنیک های یادگیری ماشین برای تشخیص بیماری های برگ در گیاهان استفاده می کند و دقت بهتری را نشان می دهد [39].
- Waleej Haider و همکاران (2021) محصول گندم را برای شناسایی بیماری انتخاب کردند تشخیص بیماری توسط شبکه عصبی کانولوشن⁹، طبقه بندی بیماری مبتنی بر Symptom با استفاده از درخت تصمیم انجام می شود. در مقایسه با الگوریتم سنتی، الگوریتم پیشنهادی دارای دقت 98 درصد است [40].
- ChangjianZhouet و همکاران (2021) یک مدل بازسازی شبکه متراکم باقی مانده¹⁰ برای شناسایی بیماری برگ گوجه فرنگی پیشنهاد کردند. RRDN در مقایسه با مدل های دیگر مانند شبکه عصبی کانولوشن عمیق، ResNet50، DenseNet121 دقت بالاتری معادل 95 درصد ارائه می کند [41].
- Thenmozhi Kasinathan و همکاران (2021) مقاله ای با موضوع تشخیص آفات حشرات با الگوریتم های ANN, SVM, CNN, NB, KN را ارائه دادند. برای مجموعه داده های بزرگ حشرات، از تکنیک شناسایی آفات مدل شبکه عصبی

⁷ Random Forest(RF)

⁸Support vector machine (SVM)

⁹ Convolutional Neural Network (CNN)

¹⁰ restructured residual dense network(RRDN)

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

- کانولوشن برای شناسایی آفات با برجسبهای کلاس استفاده شد. نتایج نشان داد که مدل شبکه عصبی کانولوشن برای کلاسهای 9 و 24 حشرات، دقت طبقه‌بندی خیلی خوب 91.5 و 90 درصد را نشان می‌دهد [42].
- Haoxu Yang و همکاران (2019) از یک مدل جدید یادگیری عمیق شبکه‌های باقی مانده وسیع¹¹ برای شناسایی خودکار بیماری در گوجه فرنگی، سیب زمینی، انگور، ذرت و سیب استفاده کردند. مجموعه داده‌ای شامل سی و شش هزار تصویر را جمع‌آوری و سپس با الگوریتم WRN و با استفاده از Tesla K80(GPU) در چارچوب TensorFlow تجزیه و تحلیل و ارزیابی کردند. نتایج نشان می‌دهد که مدل WRN دقت بیشتری نسبت به GoogLeNet inception V4 ارائه می‌کند [43].
 - Muammer و همکاران (2019) از الگوریتم‌های Inception, ResNet50, ResNet101, Inception V3, ResNetV2, VGG19, VGG16, Google Net, Squeeze Net, Alex Net, برای شناسایی بیماری در درختان زردآلو، گردو، هلو، گیلاس استفاده کردند. در نهایت ویژگی‌های ResNet50 با طبقه‌بندی کننده ماشین بردار پشتیبان دقت بهتری را نسبت به سایر الگوریتم‌ها نشان می‌دهد [44].
 - ShanwenZhangetal و همکاران (2019) از الگوریتم‌های Alexnet, GPDCNN, DCNN در تشخیص بیماری برگ خیار استفاده کردند. GPDCNN نتایج بهتری نسبت به DCNN, Alex Net نشان می‌دهد. این مدل باعث افزایش یادگیری و میزان تشخیص بالاتر می‌شود [45].
 - Artzai Picon و همکاران (2019) تصویر واقعی گرفته شده به وسیله موبایل با هدف شناسایی بیماری نباتات با مجموعه داده‌ای از هفده بیماری با 5 محصول دانه‌ای، گندم، ذرت، برنج، جو و غیره انتخاب کردند. شناسه محصول به شبکه عصبی کانولوشن فرستاده می‌شود که معماری شبکه عصبی کانولوشن با متاداده دسته‌بندی شده ترکیب می‌شود. راه حل پیشنهادی شامل متاداده‌های متنی یکپارچه با اطلاعات عکس‌های ضمیمه که در سیستم طبقه‌بندی با اطلاعات محصول ارسال می‌شود [46].
 - Chiranjeevi Muppala و همکاران (2020) مقاله‌ای برای شناسایی بید با استفاده از شبکه عصبی عمیق در شالیزار را مطرح کردند. روش پیشنهادی DNN-SAR، دقت 98.29 درصد را در مقایسه با ResNet50, Google Net, Alexnet به دست آورد [47].
 - Ching-ju chen و همکاران (2020) از مدل YOLOv3 برای طبقه‌بندی آفت و استخراج ویژگی‌های آنها در تشخیص آفت درخت میوه با دقت 90 درصد استفاده کردند [48].
 - Dimuthu Lakmal و همکاران (2019) از مدل‌های ماشین بردار پشتیبان و شبکه عصبی کانولوشن برای شناسایی حشره گیاه قهوه‌ای در شالیزار استفاده کردند. شبکه عصبی کانولوشن بازده کلی 96.20 درصد را تولید کرد [49].
 - Huiqun Hong و همکاران (2020) با پنج شبکه عصبی کانولوشن ResNet 50, Densenet_Xception, Xception, MobileNet، بر روی محصول گوجه فرنگی با 18 دسته‌بندی و 13112 تصویر توانسته‌اند با مدل Densenet_Xception به دقت 97.10 درصد برسند [50].
 - Liu Liu و همکاران (2019) از مدل‌های Inception, ResNet50, Local activated و شبکه پیشنهادی ناحیه¹² برای تشخیص 16 نوع آفت روی 88 هزار و ششصد تصویر استفاده کردند. مدل پیشنهادی RPN در تشخیص خودکار آفت موثرتر بود [51].

¹¹ wide residual networks

¹² Region Proposal Network(RPN)

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

- Quoc Bao Truong و همکاران در سال 2018 از مدل های DAG-CNN, HR, FPN و فرونشانی غیر حداکثری¹³ برای شناسایی هوشمند آفات گیاه گندم و برنج استفاده کردند. مدل پیشنهادی دقت 81.4 درصد را به دست آورد [52].
- Dhapitha Nesarajan و همکاران (2020) به این نتیجه دست یافتند که مدل های ماشین بردار پشتیبان و شبکه عصبی کانولوشنی برای شناسایی آفت گیاه نارگیل، بهترین روش طبقه بندی کننده است [53].
- Mohit Agarwal و همکاران (2020) از مدل های درخت تصمیم¹⁴، ماشین بردار پشتیبان، شبکه عصبی کانولوشن، Logistic Regression naive bayes جهت شناسایی آفت گیاه گوجه فرنگی استفاده کردند شبکه عصبی کانولوشن با 18160 تصویر دقت 98.4 درصد را نشان می دهد [54].
- Yong AI و همکاران (2020) برای شناسایی 28 بیماری 10 محصول کشاورزی از اینترنت اشیا و مدل Inception-ResNet-v2 استفاده کردند. این مدل دقت 86.1 درصد را نشان می دهد [55].
- Dhapitha Nesarajanet و همکاران (2020) از مدل های کانولوشن و ماشین بردار پشتیبان برای شناسایی آفت و بیماری درخت نارگیل استفاده کردند. ماشین بردار پشتیبان دقت 93.54 درصد و شبکه عصبی کانولوشن دقت 93.72 درصد را نشان می دهد [56].
- Xihai Zhang و همکاران (2018) برای شناسایی آفت گیاه ذرت از مدل های Google Net و Cifar10 استفاده کردند. دقت شناسایی به ترتیب 98.9 و 98.8 درصد بوده است [57].

3-2-1- یادگیری انتقالی

تحقیقات اخیر استفاده گسترده از شبکه عصبی کانولوشن های عمیق را نشان داده است که برای عملکرد مؤثر به مقدار زیادی داده نیاز دارد. چالش رایج مرتبط با استفاده از چنین مدل هایی مربوط به کمبود داده های آموزشی است. جمع آوری حجم زیادی از داده ها یک کار طاقت فرسا است و در حال حاضر هیچ راه حل برای جبران این مسئله در دسترس نیست. بنابراین، برای حل معضل اساسی داده های ناکافی، استفاده از مدل های یادگیری انتقالی توصیه می شود که در چنین مواردی بسیار مؤثر هستند [58]. به زبان ساده، یادگیری انتقالی فرآیندی است که در آن مدل آموزش دیده برای یک کار مشخص به عنوان نقطه شروع برای آموزش یک مدل جدید دوباره استفاده می شود. در این یادگیری سعی می شود، اطلاعات از دامنه اصلی به دامنه مقصد منتقل شود. این فرآیند یادگیری در شکل 5 نشان داده شده است.

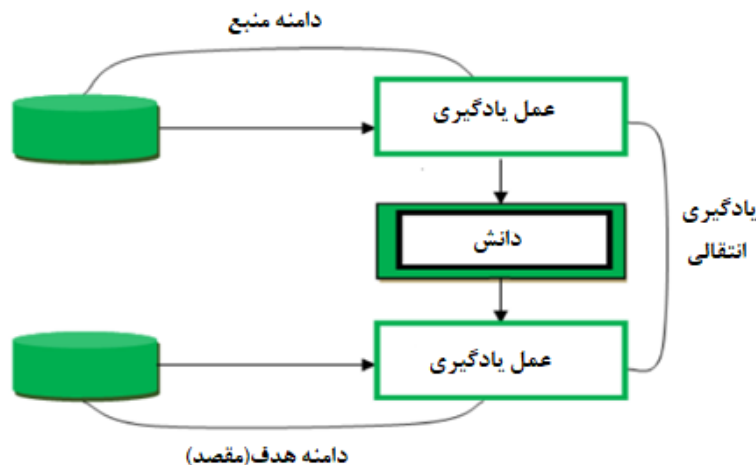
¹³ non-maximum suppression(NMS)

¹⁴ Decision Trees

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senacnf.ir



شکل 5: فرآیند یادگیری انتقالی

در طول دهه گذشته، کاربردهای یادگیری عمیق [59-61] و یادگیری انتقالی [8,62] در کشاورزی به موفقیت گسترده ای دست یافته اند و به دلیل توانایی آنها در یادگیری قابل اعتماد و تشخیص ویژگی های بصری، نتایج بسیار امیدوارکننده ای را به

همراه داشته اند. مطالعات جذاب متعددی [59,61,63-66] در مورد استفاده از این رویکردهای امیدوارکننده برای شناسایی بیماری ها منتشر شده است. به طور خاص، استفاده از یادگیری انتقالی روندی است که به طور فزاینده ای محبوب می شود و به طور گسترده توسط محققان استفاده می شود [67,68]. علاوه بر این، یادگیری انتقال تنها یک تکنیک نیست، بلکه مجموعه ای از تکنیک های تنظیم شده است که امکان توسعه مدل های بسیار دقیق را بر روی یک مجموعه داده تخصصی محدودتر، مانند مدل های مربوط به بیماری های گیاهی فراهم می کند. در ادامه به معرفی چند نمونه از این تحقیقات و داده های به کار رفته در آنها پرداخته می شود.

- Ferentinos و همکارانش با مدل های عمیق AlexNet, VGG16, Overfeat بر روی 25 نوع محصول با 58 دسته بندی و 87848 تصویر از مجموعه داده Open Dataset به دقت 99.53 درصد دست یافته اند [59].
- Kirti و همکاران (2021) از معماری ResNet 50 و الگوریتم شبکه عصبی عمیق¹⁵ جهت تشخیص آفت برگ درخت انگور استفاده کردند. سیستم پیشنهادی دارای مجموعه داده شامل 1807 تصویر (سالم و بیمار) است. معماری ResNet 50 شبکه عصبی عمیق در ترکیب با یادگیری انتقالی و Fine Tuning برای محاسبه نتایج استفاده شد. سیستم پیشنهادی دقت بیش از 97 درصد را ارائه می کند و نسبت به روش های موجود که مبتنی بر روش های استخراج ویژگی هستند، عملکرد بهتری دارد [60].
- در سال 2019 Geetharamani و همکارانش با مدل شبکه عصبی کانولوشن عمیق 9 لایه بر روی 14 نوع محصول در 39 دسته با 61486 تصویر از مجموعه داده Leaf disease به دقت 96.46 درصد دست یافتند [62].
- Singh و همکاران در سال 2020 با مدل های MobileNet, R-CNN و 13 نوع محصول در 27 دسته با 2598 تصویر از مجموعه داده PlantVillage به دقت 70.53 رسیده اند [64].

¹⁵ Deep neural network

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senacnf.ir

- Al-bayati و همکاران با شبکه عصبی DNN و توصیف گر SURF, GOA بر روی محصول سیب با 6 دسته و 2539 تصویر از مجموعه داده PlantVillage به دقت 98.28 دست یافته اند [65].
- Arsenovic و همکاران با مدل شبکه عصبی کانولوشن چند کاناله بر روی 12 نوع محصول در 42 دسته با 79265 تصویر از مجموعه داده PlantVillage به دقت 93.67 دست پیدا کرده اند [66].
- Costa و همکارانش با مدل InceptionV3 و شبکه عصبی کانولوشن روش سلسله مراتبی برای طبقه بندی محصولات سیب، هلو و گوجه فرنگی در 16 دسته با 24000 تصویر از مجموعه داده PlantVillage توانسته اند به دقت 97.74 درصد برسند [68].
- De Luna و همکاران با مدل Faster R-CNN, شبکه عصبی کانولوشن بر روی محصول گوجه فرنگی با 4 دسته بندی و 4923 تصویر که خود تهیه کرده بودند توانسته اند به دقت 91.67 درصد برسند [69].

3-2-2- مقایسه بین مدل های یادگیری عمیق

در این راستا مطالعه ای توسط Ngugi و همکاران انجام شد [70]. نتایج به دست آمده مقایسه عملکرد 10 مدل یادگیری عمیق یعنی AlexNet, ResNet-101, GoogleNet, DenseNet201, Vgg16, Inceptionv3, InceptionResNetv2, SqueezeNet, MobileNets و ShuffleNet بر روی مجموعه داده PlantVillage در جدول 2 ارائه شده است.

جدول 2: مقایسه مدل های مختلف یادگیری عمیق بر روی مجموعه داده PlantVillage

ویژگی	صحت	دقت	F1-score	Recall	معماری
0.9997	0.9897	0.9871	0.9856	0.9843	AlexNet
0.9999	0.9948	0.9926	0.9916	0.9906	InceptionV3
0.9997	0.9899	0.9891	0.9881	0.9874	GoogleNet
0.9996	0.9837	0.9785	0.9787	0.9791	SqueezeNet
0.9999	0.9973	0.9958	0.9961	0.9965	DenseNet201
0.9999	0.9951	0.9928	0.9930	0.9932	VGG16
0.9999	0.9851	0.9924	0.9929	0.9936	ResNet101
0.9998	0.9929	0.9895	0.9897	0.9901	ShuffleNet
0.9997	0.9905	0.9895	0.9862	0.987	MobileNetv2
0.9998	0.9930	0.9901	0.9893	0.9887	InceptionResNetv2

طبق جدول 2 مدل DenseNet201 مناسب ترین مدل است زیرا به ذخیره سازی کمتری نیاز دارد و دارای بهترین معیارهای عملکردی است (صحت = 0.9973، دقت = 0.9958، فراخوان = 0.9965، ویژگی = 0.9999، امتیاز = $F1 = 0.9961$). در مقایسه با مدل های InceptionV3 و ResNet-101 به زمان یادگیری طولانی تری (82 ساعت) نیاز دارد. با این حال، دقت آنها کمی کمتر از DenseNet201 است. بنابراین هنگام انتخاب بین این سه معماری باید دقت ویژه ای داشت، زیرا هر مدل دارای مزایا و محدودیت های خاصی است. در مقایسه، معماری های کوچک MobileNet, SqueezeNet و ShuffleNet در برنامه های کاربردی جاسازی شده و موبایلی که منابع محاسباتی محدود هستند، به دلیل زمان یادگیری کوتاه و نیاز ذخیره سازی کم، مطلوب هستند، زیرا با این محدودیت ها این مدل ها همچنان به دقت بالایی دست می یابند.

3-3- کاربرد اینترنت اشیا در زمینه تشخیص بیماری برگ

اینترنت اشیا قابلیت های کشاورزی را بهبود بخشیده است. برنامه های کاربردی اینترنت اشیا می توانند در هر زمانی در طول فعالیت های کشاورزی به کشاورزان کمک کنند و آنها را با آخرین اطلاعات محصول و آب و هوا برای نظارت از راه دور مزارع به روز نگه دارند. با

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

استفاده از برنامه های اینترنت اشیا [71-73]، کشاورزان می توانند برای برداشت فصل آینده برنامه ریزی کنند. علاوه بر این، آنها می توانند بیماری های محصول را در مراحل اولیه شناسایی کنند تا از گسترش بیماری جلوگیری کنند و عملکرد خود را ذخیره کنند. برنامه های اینترنت اشیا¹⁶ کشاورزی به وضوح نقش مهمی در افزایش تولیدات کشاورزی و کاهش تلفات محصول به دلیل بیماری ها ایفا می کنند. در این زمینه، تحقیقات زیادی برای شناسایی بیماری ها، انجام شده است که به طور خلاصه بیان می شود.

- Devi و همکاران سیستمی مبتنی بر اینترنت اشیا با استفاده از روش های خوشه بندی GLCM، RFC و k-means ایجاد کرده اند. این سیستم به دقت کلی تقریبی 99.99٪ در تشخیص و طبقه بندی بیماری بر اساس روش های RFC GLCM رسیدند [64].

- Truong و همکاران نیز سیستم اینترنت اشیا با استفاده از طبقه بندی ماشین بردار پشتیبان که قادر به تحلیل زمان واقعی و برخط است ارائه کرده اند [68]

- Chen و همکاران پلتفرم RiceTalk را ارائه کرده اند که با استفاده از مدل هوش مصنوعی و دستگاه های اینترنت اشیا به صحت پیش بینی خالص 89.4 درصد می رسد [71].

- Krishna و همکاران سیستم اینترنت اشیا با استفاده از خوشه بندی ماشین بردار پشتیبان و k-means ایجاد کرده اند به طوری که به محض شناسایی بیماری با ارسال پیامک فوری هشدار، کشاورز را مطلع می کند [72]

- M. Mishra و همکاران یک سیستم نظارت و تشخیص خودکار بیماری های گیاهی مبتنی بر اینترنت اشیا، با استفاده از فیلتر میانی طراحی کرده که به یک بهینه ساز اصلاح شده به نام شبکه عصبی چرخشی یا RideNN مبتنی بر SCA متصل است و توانستند به دقت 91.56 درصد دست یابند [73].

- Win و همکاران، سیستم مبتنی بر اینترنت اشیا برای نظارت بر برنج از راه دور با استفاده از یادگیری عمیق و یادگیری انتقالی را پیاده سازی کرده اند. این سیستم به صورت برخط، ناظر بر پارامترهای محیطی می باشد [74].

- Sourav Kumar Bhoi و همکاران (2021) از فناوری های اینترنت اشیا (IOT) و وسایل نقلیه هوایی بدون سرنشین 17 برای شناسایی آفت برنج استفاده کردند. این مدل بر مکانیزم هوش مصنوعی برای انجام فرایند تشخیص آفت در مزرعه برنج تمرکز دارد و آفت را می توان با گرفتن برچسب با بالاترین ارزش اطمینان شناسایی کرد و مقدار آستانه آن را 75 درصد در نظر گرفت [75].

- Sanjeevi Pandiyan و همکاران (2020) روش جدید مبتنی بر اینترنت اشیا استخراج ابعاد تقسیم شده پیشرفته ۱۸، تشخیص ناهمگن اینترنت اشیا 19، شناسایی و جداسازی امن ۲۰ را برای افزایش دقت در شناسایی بیماری برگ گیاه سیب پیشنهاد کردند آزمایش دقت 98.55 درصد را نشان می دهد [76].

4- چالش ها

دربخش پیشینه تحقیق تعدادی از تحقیقات امیدوارکننده انجام شده در چند سال گذشته در زمینه شناسایی و تشخیص بیماری برگ گیاهان ارائه شد، اما همچنان تا به امروز، چالش های حل نشده متعددی وجود دارد که باید برطرف شوند تا سیستم های تشخیص بیماری های زراعی مناسبی ساخته شوند به طوری که توانایی شناسایی با دقت بالا و در شرایط مختلف مزارع را داشته باشند. مهم ترین این چالش های عبارتند از:

¹⁶ Internet of thing(IOT)

¹⁷ Unmanned Aerial Vehicle(UAV)

¹⁸ Advanced segmented dimension extraction (ASDE)

¹⁹ Heterogeneous IoT Detection

²⁰ Secure Identification and Isolation(SII)

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

- 1- داده های مورد استفاده در زمان آموزش: مشکل اصلی در استفاده از مدل های یادگیری عمیق برای تشخیص بیماری های گیاهی، ناکافی بودن مجموعه داده ها از نظر تنوع و اندازه [77] است زیرا این مدل ها نیازمند داده های بسیار زیادی هستند. در اکثر موارد، شناسایی بیماری های گیاهی در شرایط ایده آل و کنترل شده [78] مانند وجود یک بیماری منفرد با زمینه همگن انجام شده است. علاوه بر این، شرایط محیطی در نظر گرفته نمی شود. از این رو، میزان دقت به دست آمده بالاتر از میزان دقت به دست آمده در یک کاربرد عملی خواهد بود. علاوه بر این، برچسب زدن تصویر یک کار بسیار پر زحمت و خسته کننده است. با توجه به این عوامل، تولید یک مجموعه داده قابل اعتماد، کارآمد و جامع بسیار چالش برانگیز است. همچنین وجود داده نامتعادل (اختلاف زیاد بین داده های هر کلاس) باعث عملکرد پیش بینی ضعیف به طور خاص در کلاس های با تعداد داده اقلیت می شود و مستعد طبقه بندی اشتباه خواهد شد. از دیگر معایب داده کم و وجود داده نامناسب در زمان آموزش بروز مشکل بیش برآزش و کم برآزش می باشد. در حال حاضر، شش راه برای مقابله با کمبود مجموعه داده وجود دارد: تکنیک های افزایش داده، اشتراک گذاری داده ها، دانش شهروندی، یادگیری انتقالی، داده های مصنوعی.
- 2- دریافت تصویر: شرایط ثبت تصویر (نور، موقعیت مکانی، باد و دوربین): در حالت ایده آل، تصاویر باید در شرایط مشابه گرفته شوند. با این حال، در عمل، این کار فقط در آزمایشگاه امکان پذیر می باشد زیرا نظارت بر شرایط ضبط بسیار دشوار است. بنابراین تصاویر ممکن است ویژگی های غیرقابل پیش بینی را ارائه دهند و شناسایی بیماری را به یک عمل پر چالش تبدیل کنند. با این وجود تلاش های متعددی برای توسعه روش های روشنایی ثابت برای رفع این مسئله انجام شده است [79]. مثلاً مسئله روشنایی محصولات زراعی در محیط های طبیعی که نوسانات زیادی دارند رشد می کنند. بنابراین، تصاویر تحت تأثیر عوامل متعددی مانند باد، روشنایی و سایر شرایط آب و هوایی قرار می گیرند. در نتیجه، مسائل نور اجتناب ناپذیر است و حذف کامل تغییرات تقریباً غیرممکن است. برای حل این مشکل می توان با تغییر زاویه ای که عکس در آن گرفته می شود یا موقعیت برگ، حضور نورهای خاص را کاهش داد [80]. دومین چالش در این زمینه دوربین است. وضوح تصویر یکی از عوامل مهمی است که تأثیر مستقیمی بر ویژگی های تصویر دارد. وضوح بالاتر امکان تشخیص ضایعات و هاگ های کوچک را فراهم می کند. علاوه بر این، دستگاهی که برای گرفتن تصویر استفاده می شود نیز بر این ویژگی ها تأثیر می گذارد.
- 3- پیش پردازش تصویر: در طول عملیات پیش پردازش و ذخیره سازی تصاویر برگ، با افزایش نسبت فشرده سازی، اطلاعات بیشتری از دست می رود. این عمل ممکن است تأثیر چشمگیری بر تجزیه و تحلیل ضایعات بزرگ نداشته باشد، اما ممکن است علائم کوچک را به شدت مخدوش کند. بنابراین، فشرده سازی باید به حداقل برسد یا حتی از آن اجتناب شود، به خصوص اگر علائم کوچک باشند.
- 4- تقسیم بندی تصویر و تشخیص علائم: به طور کلی، علائم مریضی یا آفات مرزهای مشخصی ندارند. آنها به تدریج در بافت طبیعی ناپدید می شوند و تمایز بین مناطق سالم و بیمار را بسیار مبهم می کند. این مسئله به وضوح بر دقت آستانه و ویژگی های استخراج شده تأثیر می گذارد. ممکن است یک برگ با برگ دیگر یا قسمت های دیگر گیاه همپوشانی داشته باشد و حتی ممکن است کج شده یا با شبنم یا غبار پوشانده شود. راه حل های کمی برای این مشکل پیشنهاد شده است زیرا ناسازگاری در این فرآیند ذاتی هست.
- 5- انتخاب و استخراج ویژگی: اگرچه برخی از گونه های گیاهی را می توان بر اساس شکل برگ شناسایی کرد، گونه های دیگر دارای شکل برگ مشابهی هستند. علاوه بر این، علائم لزوماً در مناطقی که به راحتی قابل دسترسی هستند بروز نمی کنند. در عمل غالباً می توانند زیر برگ ها باشند یا توسط موانع دیگری پوشیده شوند یا بیماری ها روی ساقه ها، میوه ها یا حتی گل ها ظاهر شوند. اما متأسفانه به این مشکل توجه کافی نشده است و تنها فوئنتس و همکاران [61] استفاده از شبکه سریعتر شبکه عصبی کانولوشن را برای تشخیص تعدادی از بیماری های گیاهی گوجه فرنگی در چندین مکان پیشنهاد کرده است. در این خصوص مشکلات دیگری مانند: تفاوت در علائم بیماری باشد. با توجه به مرحله توسعه بیماری، یک بیماری خاص می تواند ویژگی های بسیار متمایزی در

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

شکل، رنگ و اندازه علائم داشته باشد و باعث مشکلات شناسایی جدی شود. لازم به ذکر است که بسیاری از بیماریهای مختلف می توانند به طور همزمان رخ دهند و تمایز بین ترکیبی از علائم و علائم فردی را بسیار پیچیده می کند. همچنین بیماری ها می توانند همزمان با بسیاری از اختلالات مانند کمبودهای تغذیه ای، آفات و بیماری ها رخ دهند. در نهایت شباهت علائم بین انواع مختلف اختلال مانند: بیماریها، وجود انگلها و کمبودهای تغذیه ای، تعیین منبع یک علامت با قطعیت بسیار دشوار است، به خصوص اگر فقط از طیف مرئی در فرآیند شناسایی استفاده شود.

6- چالش های دیگر: برخی دیگر از چالش های پیش روی تکنیک های شناسایی خودکار بیماری ها و آفات گیاهی را نمی توان در موارد بالا طبقه بندی کرد. این چالش ها شامل کاهش پیچیدگی، علاوه بر نیازهای محاسباتی و حافظه است [81]، زیرا رایانه ها و دوربین های کم هزینه منابع محاسباتی بسیار محدودی دارند. در عین حال، با افزایش وضوح تصویر، منابع محاسباتی نیز در حال رشد هستند. نگرانی عمده دیگر فقدان مجموعه داده های دارای برچسب مناسب [64] و به اندازه کافی بزرگ با تنوع بالا است. این مهم ترین مانع در هنگام آموزش مدل های شبکه عصبی پرتکرار (RNN) برای تشخیص بیماری های گیاهی است، زیرا جمع آوری تصاویر در میدان نه تنها یک کار پرمحمت است، بلکه به راهنمایی کارشناسان کشاورزی برای حاشیه نویسی دقیق نیز نیاز دارد. با این وجود، دو مجموعه داده رایگان وجود دارد: PlantVillage[82] و پایگاه داده تصویری از مجموعه داده علائم بیماری گیاهی PDDB

5- پیشنهادات

در بخش قبل، مشکلات موجود برای جهت دهی به تحقیقات آینده در این زمینه بیان شد. بنابراین، کار آینده باید ابتدا به دنبال دستیابی به مجموعه داده های متنوع و با اندازه بزرگ باشد تا تحقیقات در این راستا را بیشتر ترویج کند. علاوه بر این، توسعه مدل های مبتنی بر شبکه عصبی کانولوشنال فشرده که می تواند به دقت بالاتری دست یابد و استفاده از این فناوری ها در پلتفرم های تعبیه شده مطلوب است. ثانیاً، در تحقیقات آتی باید بر توسعه روش ها و تکنیک های قابل اعتماد برای حذف پس زمینه ها و ترکیب اشکال دیگر داده ها، مانند روندهای هواشناسی، تاریخچه وقوع بیماری و موقعیت مکانی، تأکید بیشتری شود تا دقت و قابلیت اطمینان شناسایی بیماری افزایش یابد. علاوه بر این، تشخیص بیماری در اجزای مختلف گیاهان و درختان، مانند ساقه ها، شکوفه ها و میوه ها، به دلیل اهمیت فوق العاده ای که دارد، باید بیشتر مورد توجه محققان قرار گیرد.

با توجه به شرایط اقلیمی کشورمان ایران و کمبود منابع آبی و کم آبی های اخیر به خصوص در استان های گرم خشک، انتظار می رود رغبت کشاورزان به سمت کاشت محصولات با آب کم و یا استفاده از روش هایی برای کاهش مصرف آب رود. علاوه بر روش های گفته شده می توان از روش های نوین برای شناسایی آفات و بیماری گیاهان در کشاورزی استفاده کرد. در این مطالعه سعی بر آن بوده است که تحقیقات صورت گرفته در روش های نوین کشاورزی بررسی شود. در انتها پیشنهاد می شود با توجه به شرایط اقلیمی کشور، باید به سمت کشت با آب کمتر و بازدهی بیشتر پیش رود، تا در کنار مصرف کمتر منابع، سود بیشتری حاصل شود. برای بازدهی بیشتر می توان از یادگیری انتقالی و یادگیری عمیق با مجموعه ای کوچکتر از تصاویر گیاهان و محصولات صیفی مرسوم در ایران و آفات و بیماری رایج بومی استفاده کرد و مدل آموزش دیده ای را متناسب با محصولات و چالش های کشاورزی گلخانه ای کشورمان ساخت. همچنین می توان با استفاده از حسگرها و اینترنت اشیا مصرف آب، برق و یا سوخت برای کنترل دما و رطوبت در گلخانه ها و همچنین میزان مصرف سموم و آفت کش ها را کنترل و مدیریت کرد.

6- نتیجه گیری

در این مطالعه، به بررسی آفات و بیماری های گیاهان و محصولات کشاورزی پرداخته و با بررسی پژوهش های انجام شده در زمینه تشخیص خودکار آفات و بیماری ها و با توجه به مقایساتی که بین روش های مختلف یادگیری ماشین مانند درخت تصمیم، ماشین بردار پشتیبان و یادگیری عمیق انجام شده است می توان نتیجه گرفت یادگیری عمیق دقت و سرعت بالاتری داشته و می توان با تکنیک هایی

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

مانند یادگیری انتقالی و Fine Tuning بر چالش کم بودن تصاویر آموزشی غلبه کرد. تشخیص به موقع و دقیق سبب کاهش نیاز به نیروی متخصص انسانی، صرف انرژی کمتر و کاهش تلفات و بهبود کیفیت محصولات می شود.

منابع

- [1] مجله ترویجی سبزیجات گلخانه ای، جلد چهارم، شماره 1، بهار، 1400 صفحات: 11-15
- [2] Lucas G.B, Campbell C.L, Lucas L.T. Causes of plant diseases. 1992. In Introduction to Plant Diseases, Springer Berlin/Heidelberg, Germany, pp. 9–14.
- [3] Shirahatti, J, Patil, R, Akulwar P. 2018. A survey paper on plant disease identification using machine learning approach, In Proceedings of the 2018 3rd International Conference on Communication and Electronics Systems (ICCES), Coimbatore, India, pp 1171–1174.
- [4] Liu, L, Dong Y, Huang W, Du X, Ren B, Huang L, Zheng Q, Ma H. 2020. A disease index for efficiently detecting wheat fusarium head blight using sentinel-2 multispectral imagery. IEEE, 52181–52191.
- [5] Prasad R., Ranjan K.R., Sinha A.2006. AMRAPALIKA: An expert system for the diagnosis of pests, diseases, and disorders in Indian mango. Knowl.-Based Syst, Sciencedirect, Elsevier, 9–21.
- [6] Singh, V, Misra A.K.2017. Detection of plant leaf diseases using image segmentation and soft computing techniques, 41–49.
- [7] Neupane K, Baysal-Gurel, F.2021. Automatic identification and monitoring of plant diseases using unmanned aerial vehicles: A review. Mdpi, 3841.
- [8] Abbas, A., Jain, S., Gour, M., Vankudothu, S.2021. Tomato plant disease detection using transfer learning with C-GAN synthetic images. Comput. Electron. Agric., 187, 106279.
- [9] Hamdani, H., Septiarini, A., Sunyoto, A., Suyanto, S., Utamingrum, F. 2021. Detection of oil palm leaf disease based on color histogram and supervised classifier. Optik, 245, 167753.
- [10] Sun, H., Xu, H., Liu, B., He, D., He, J., Zhang, H., Geng, N. MEAN-SSD.2021. A novel real-time detector for apple leaf diseases using improved light-weight convolutional neural networks. Comput. Electron, Agric, 189, 106379.
- [11] Pothan, M.E., Pai, M.L.2020. Detection of rice leaf diseases using image processing. In Proceedings of the 2020 Fourth International Conference on Computing Methodologies and Communication (ICCMC), Erode, India, pp. 424 430.
- [12] Kelman, A., Pelczar Michael, J., Shurtleff Malcolm, C., Pelczar Rita, M. 2021. Plant Disease Available online <https://www.britannica.com/science/plant-disease>.
- [13] Cerda, R., Avelino, J., Gary, C., Tixier, P., Lechevallier, E., Allinne, C. 2017. Primary and secondary yield losses caused by pests and diseases: Assessment and modeling in coffee. PLoS ONE, 12, e0169133.
- [14] Kaur, M., Bhatia, R. 2019. Leaf disease detection and classification: A comprehensive survey. In Proceedings of the International Conference on IoT Inclusive Life, Chandigarh, India, pp. 291–304.
- [15] Singh, V., Misra, A. 2015. Detection of unhealthy region of plant leaves using image processing and genetic algorithm. In Proceedings of the 2015 International Conference on Advances in Computer Engineering and Applications, Ghaziabad, India, pp. 1028–1032.
- [16] Karthika, J., Santhos, M., Sharan, T. 2021. Disease detection in cotton leaf spot using image processing. J. Phys. Conf. Ser. 1916, 012224.
- [17] Devaraj, A., Rathan, K., Jaahnavi, S., Indira, K. 2019. Identification of plant disease using image processing technique. In Proceedings of the 2019 International Conference on Communication and Signal Processing (ICCSP), Chennai, India, pp. 0749–07534–6.
- [18] Mojjada, R.K., Kumar, K.K., Yadav, A., Prasad, B.S.V. 2020 Detection of plant leaf disease using digital image processing.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

- [19] Iqbal, M.A., Talukder, K.H. Detection of potato disease using image segmentation and machine learning. In Proceedings of the 2020 International Conference on Wireless Communications Signal Processing and Networking (WiSPNET), Chennai, India, pp. 43–47.
- [20] Srivastava, A.R., Venkatesan, M. 2020. Tea leaf disease prediction using texture-based image processing. In Emerging Research in Data Engineering Systems and Computer Communications, Springer: Berlin/Heidelberg, Germany, pp.17–25.
- [21] Whitmire, C.D., Vance, J.M., Rasheed, H.K., Missaoui, A., Rasheed, K.M., Maier, F.W. 2021. Using machine learning and feature selection for alfalfa yield prediction. *AI*, 2, 6.
- [22] Afifi, A., Alhumam, A., Abdelwahab, A. 2021. Convolutional neural network for automatic identification of plant diseases with limited data. *Plants*, 10, 28.
- [23] Mugithe, P.K., Mudunuri, R.V., Rajasekar, B., Karthikeyan, S. 2020. Image processing technique for automatic detection of plant diseases and alerting system in agricultural farms. In Proceedings of the 2020 International Conference on Communication and Signal Processing (ICCSP), Chennai, India,, pp. 1603–1607.
- [24] Parikshith, H., Rajath, S.N., Kumar, S.P. 2019. Leaf disease detection using image processing and artificial intelligence-A survey. In Proceedings of the International Conference On Computational Vision and Bio Inspired Computing, Coimbatore, India, pp. 304–311.
- [25] Sethy, P.K., Barpanda, N.K., Rath, A.K., Behera, S.K. 2020. Deep feature based rice leaf disease identification using support vector machine. *Comput. Electron. Agric*, 175, 105527.
- [26] Mitra, D. 2021. Emerging plant diseases: Research status and challenges, *Emerg. Trends Plant Pathol*, 1-17.
- [27] Ichiki, T.U., Shiba, T., Matsukura, K., Ueno, T., Hirae, M., Sasaya, T. 2013. Detection and diagnosis of rice-infecting viruses. *Front. Microbiol*, 4, 289.
- [28] Lacomme, C., Holmes, R., Evans, F. 2015. Molecular and serological methods for the diagnosis of viruses in potato tubers. In *Plant Pathology*, Springer: Berlin/Heidelberg, Germany, pp. 161–176.
- [29] Balodi, R., Bisht, S., Ghatak, A., Rao, K. 2017. Plant disease diagnosis: Technological advancements and challenges. *Indian Phytopathol*, 70, 275–281.
- [30] Bachika, N.A., Hashima, N., Wayayoka, A., Mana, H.C., Alia, M.M. 2021. Optical imaging techniques for rice diseases detection: A review. *J. Agric. Food Eng.*, 2.
- [31] Galletti, P.A., Carvalho, M.E., Hirai, W.Y., Brancaglioni, V.A., Arthur, V., da Silva, C.B. 2020. Integrating optical imaging tools for rapid and non-invasive characterization of seed quality: Tomato (*Solanum lycopersicum* L.) and carrot (*Daucus carota* L.) as study cases. *Front. Plant Sci*, 11, 577851,
- [32] Bioucas-Dias, J.M., Plaza, A., Camps-Valls, G., Scheunders, P., Nasrabadi, N., Chanussot, J. 2013. Hyperspectral remote sensing data analysis and future challenges. *IEEE Geosci. Remote Sens. Mag*, 1, 6–36.
- [33] Mananze, S., Pôças, I., Cunha, M. 2018. Retrieval of maize leaf area index using hyperspectral and multispectral data. *Remote Sens*, 10, 1942.
- [34] Rumpf, T, Mahlein A.-K, Steiner U, Oerke, E.-C., Dehne, H.-W., Plümer, L. 2010. Early, detection and classification of plant diseases with support vector machines based on hyperspectral reflectance, *Comput. Electron. Agric*, 74, 91–99.
- [35] Bauriegel, E., Herppich, W.B. 2014. Hyperspectral and chlorophyll fluorescence imaging for early detection of plant diseases, with special reference to *Fusarium spec.* infections on wheat. *Agriculture* 2014, 4, 32–57.
- [36] Mishra, P., Polder, G., Vilfan, N. 2020. Close range spectral imaging for disease detection in plants using autonomous platforms: A review on recent studies. *Curr. Robot. Rep*, 1, 43–48.
- [37] Janiesch, C., Zschech, P., Heinrich, K. 2021. Machine learning and deep learning. *Electron. Mark*, 1–11.

دوازدهمین کنگره ملی سراسری
فناوریهای نوین در حوزه توسعه پایدار ایران
12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

- [38] R.Sujatha, Jyotir Moy Chatterjee, NZ Jhanjhi, Sarfraz Nawaz Brohi, 2021. Performance of deep learning vs machine learning in plant leaf disease detection, *Microprocessors and Microsystems*, 103615, ISSN 0141-9331.
- [39] Deepa, R. N and C. Shetty, 2021. A Machine Learning Technique for Identification of Plant Diseases in Leaves, 6th International Conference on Inventive Computation Technologies (ICICT), pp.481-484.
- [40] W. Haider, A. -U. Rehman, N. M. Durrani and S. U. Rehman. 2021. A Generic Approach for Wheat Disease Classification and Verification Using Expert Opinion for Knowledge-Based Decisions, *IEEE*, pp.31104-31129.
- [41] C. Zhou, S. Zhou, J. Xing and J. Song. 2021. Tomato Leaf Disease Identification by Restructured Deep Residual Dense Network, *IEEE*, pp. 28822-28831.
- [42] Thenmozhi Kasinathan, Dakshayani Singaraju, Srinivasulu Reddy Uyyala. 2020. Insect classification and detection in field crops using modern machine learning technique, *ELSEVIER*.
- [43] Yang, H., Gao, L., Tang, N. et al. 2019. Experimental analysis and evaluation of wide residual networks based agricultural disease identification in smart agriculture system, *J Wireless Com Network*, 292.
- [44] Muammertürkoğlu, Dvuthanbay. 2019. plant disease and pest detection using deep learning based features, *Turkish Journal of Electrical Engineering & Computer Sciences*, Page Number 1636 – 16511.
- [45] Shanwen Zhang, Subing Zhang, Chuanlei Zhang, Xianfeng Wang, Yun Shi. 2019. Cucumber leaf disease identification with global pooling dilated convolutional neural network, *Elsevier, Computers and Electronics in Agriculture*.
- [46] ArtzaiPicon, Maximilian Seitz, Aitor Alvarez-Gila, Patrick Mohnke, Amaia OrtizBarredo. 2019. Crop conditional Convolutional Neural Networks for massive multi-crop plant disease classification over cell phone acquired images taken on real field conditions, *Elsevier, Computers and Electronics in Agriculture*.
- [47] C. Muppala and V. Guruviah. 2020. Detection of leaf folder and yellow stemborer moths in the paddy field Using deep Neural network with search and rescue optimization, *Information Processing in Agriculture*.
- [48] C. -J. Chen, Y. -Y. Huang, Y. -S. Li, C. -Y. Chang and Y. -M. Huang. 2020. An AIoT Based Smart Agricultural System for Pests Detection, *IEEE*, pp. 180750-180761.
- [49] D. Lakmal, K. Kugathasan, V. Nanayakkara, S. Jayasena, A. S. Perera and L. Fernando. 2019. Brown Plant hopper Damage Detection using Remote Sensing and Machine Learning, 18th IEEE International Conference On Machine Learning And Applications (ICMLA), pp. 97-104.
- [50] H. Hong, J. Lin and F. Huang. 2020. Tomato Disease Detection and Classification by Deep Learning, *International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE)*, pp. 25-29.
- [51] L. Liu et al. 2019. Deep Learning based Automatic Approach using Hybrid Global and Local Activated Features towards Large-scale Multi-class Pest Monitoring, 2019 IEEE 17th International Conference on Industrial Informatics (INDIN), pp. 1507-1510.
- [52] Q. B. Truong, T. K. N. Thanh, M. T. Nguyen, Q. D. Truong and H. X. Huynh. 2018. Shallow and Deep Learning Architecture for Pests Identification on Pomelo Leaf. 2018 10th International Conference on Knowledge and Systems Engineering (KSE), , pp335-340.
- [53] D.Nesarajan, L. Kunalan, M. Logeswaran, S. Kasthuriarachchi and, D. Lungalage, 2020. Coconut Disease Prediction System Using Image Processing and Deep Learning Techniques, 2020 IEEE 4th International Conference on Image Processing, Applications and Systems (IPAS), , pp. 212-217.
- [54] Mohit Agarwal, Suneet Kr. Gupta, K.K. 2020. Biswas Development of Efficient CNN model for Tomato crop disease identification Sustainable Computing: Informatics.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

- [55] Y. Ai, C. Sun, J. Tie and X. Cai. 2020. Research on Recognition Model of Crop Diseases and Insect Pests Based on Deep Learning in Harsh Environments, IEEE, pp. 171686-171693.
- [56] D. Nesarajan, L. Kunalan, M. Logeswaran, S. Kasthuriarachchi and D. Lungalage, 2020. Coconut Disease Prediction System Using Image Processing and Deep Learning Techniques, IEEE 4th International Conference on Image Processing, Applications.
- [57] X. Zhang, Y. Qiao, F. Meng, C. Fan and M. Zhang. 2018. Identification of Maize Leaf Diseases Using Improved Deep Convolutional Neural Networks IEEE, pp.30370-30377.
- [58] Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., He, Q. 2020. A comprehensive survey on transfer learning. Proc. IEEE, 109, 43–76.
- [59] Ferentinos, K.P. 2018. Deep learning models for plant disease detection and diagnosis. Comput. Electron. Agric. 145, 311–318.
- [60] K. Kirti, N. Rajpal and J. Yadav, Black Measles. 2021. Disease Identification in Grape Plant (*Vitis vinifera*) Using Deep Learning, 2021 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS), , pp. 97-101. 9397205.
- [61] Fuentes, A, Yoon, S., Kim, S.C., Park, D.S. 2022. A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. Sensors 2017. 17.
- [62] Geetharamani, G., Pandian, A. 2019. Identification of plant leaf diseases using a nine-layer deep convolutional neural network. Comput. Electr. Eng. 76, 323–338.
- [63] Chen, J., Chen, J., Zhang, D., Sun, Y., Nanekaran, Y.A. 2020. Using deep transfer learning for image-based plant disease identification. Comput. Electron. Agric. 173, 105393.
- [64] Singh, D., Jain, N., Jain, P., Kayal, P., Kumawat, S., Batra, N. 2020. PlantDoc: A dataset for visual plant disease detection. In Proceedings of the 7th ACM IKDD CoDS and 25th COMAD, Hyderabad, India., pp. 249–253.
- [65] Al-bayati, J.S.H., Üstündağ, B.B. 2020. Evolutionary feature optimization for plant leaf disease detection by deep neural networks. Int. J. Comput. Intell. Syst., 13, 12–23.
- [66] Arsenovic, M., Karanovic, M., Sladojevic, S., Anderla, A., Stefanovic, D. 2019. Solving current limitations of deep learning based approaches for plant disease detection. Symmetry, 11, 939.
- [67] Too, E.C., Yujian, L., Njuki, S., Yingchun, L. 2019. A comparative study of fine-tuning deep learning models for plant disease identification. Comput. Electron. Agric., 161, 272–279.
- [68] Costa, J., Silva, C., Ribeiro, B. 2019. Hierarchical deep learning approach for plant disease detection. In Proceedings of the Iberian Conference on Pattern Recognition and Image Analysis, Madrid, Spain, pp.383–393.
- [69] De Luna, R.G., Dadios, E.P., Bandala, A.A. 2018. Automated image capturing system for deep learning-based tomato plant leaf disease detection and recognition. Proceedings of TENCON 2018-IEEE Region 10 Conference, Jeju Island, Korea. pp. 1414–1419.
- [70] Ngugi, L.C., Abelwahab, M., Abo-Zahhad, M. 2021. Recent advances in image processing techniques for automated leaf pest and disease recognition-A review. Inf. Process. Agric. 8, 27–51.
- [71] Chen, W.-L., Lin, Y.-B., Ng, F.-L., Liu, C.-Y., Lin, Y.-W. 2019. RiceTalk: Rice blast detection using internet of things and artificial intelligence technologies. IEEE Internet Things J. 7, 1001–1010.
- [72] Krishna, M., Sulthana, S.F., Sireesha, V., Prasanna, Y., Sucharitha, V. 2019. Plant disease detection and pesticide spraying using dip and IoT. J. Emerg. Technol. Innov. Res. 6, 54–58.
- [73] Mishra, M., Choudhury, P., Pati, B. 2021. Modified ride-NN optimizer for the IoT based plant disease detection. J. Ambient Intell. Humaniz. Comput. 12, 691–703.
- [74] Ramcharan, A., Baranowski, K., McCloskey, P., Ahmed, B., Legg, J., Hughes, D.P. 2017. Deep learning for image-based cassava disease detection. Front. Plant Sci., 8, 1852.
- [75] Sourav Kumar Bhoi, Kalyan Kumar Jena, Sanjaya Kumar Panda, Hoang Viet Long, Raghvendra Kumar, P. Subbulakshmi, Haifa Bin Jebreen, 2021. An Internet of Things assisted Unmanned Aerial Vehicle based artificial intelligence model for rice pest detection, Microprocessors and Microsystems, sciencedirect.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

- [76] Sanjeevi Pandiyan, Ashwin M., Manikandan R., Karthick Raghunath K.M., Anantha Raman G.R. 2020. Heterogeneous Internet of things organization Predictive Analysis Platform for Apple Leaf Diseases Recognition, sciencedirect. Pages 99-110.
- [77] Barbedo, J.G. 2018. Factors influencing the use of deep learning for plant disease recognition. Biosyst. Eng. 172, 84–91.
- [78] Mohanty, S.P., Hughes, D.P., Salathé, M. 2016. Using deep learning for image-based plant disease detection. Front. Plant Sci., 7, 1419.
- [79] Guo, W, Rage, U.K., Ninomiya, S. 2013. Illumination invariant segmentation of vegetation for time series wheat images based on decision tree model, Comput. Electron. Sciencedirect, 96, 58–66,.
- [80] Pourreza, A., Lee, W.S., Raveh, E., Ehsani, R., Etxeberria, E. 2014. Citrus Huanglongbing detection using narrow-band imaging and polarized illumination Trans . ASABE, 57, 259–272.
- [81] Liu, J., Wang, X. 2021. Plant diseases and pests detection based on deep learning: A review. Plant Methods, .17, 1 18.
- [82] Hughes, D.,Salathé, M. 2015 . An open access repository of images on plant health to enable the development of mobile disease diagnostics. 1511.