

کاربرد پردازش تصویر و یادگیری عمیق در مطالعات گیاهان زراعی تحت تنش

مقاله مروری

عادل پشت‌دار*

دستیار پژوهشی گروه مهندسی تولید و ژنتیک گیاهی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان، ملاتانی، ایران.

*نویسنده مسئول: adelposhtdar@gmail.com

تاریخ پذیرش: ۱۴۰۱/۰۹/۰۱

تاریخ دریافت: ۱۴۰۱/۰۶/۰۲

چکیده

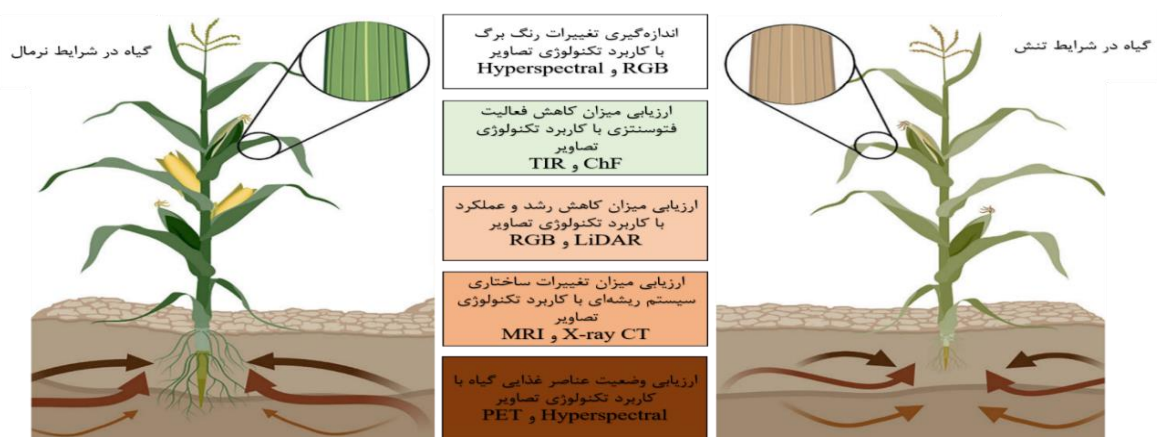
تنش‌های محیطی (زیستی و غیرزیستی) از یکی چالش‌های مهم تولیدکنندگان کشاورزی و امنیت غذایی بشر است. تولید پایدار با شناخت تنش‌های محیطی به کمک مطالعات فیزیولوژیک گیاهی امکان‌پذیر است. سالیان زیادی است که پژوهش‌های فیزیولوژیک و فنوتیپی گیاهان زراعی بر مبنای روش‌های فشرده آزمایشگاهی قدیمی، تخریبی و زمان‌بر در آزمایشگاه و مزرعه بوده است. حل این مسئله با استفاده از روش‌های سریعی مانند تکنولوژی بینایی ماشین، الگوریتم‌های یادگیری ماشین و یادگیری عمیق به دست می‌آید. این روش‌ها با پایش تغییرات فنوتیپی و فیزیولوژیک گیاهان زراعی در جهت پیش‌بینی یا تشخیص تنش‌ها، گام‌های موثری برداشته شود. در مقاله حاضر آخرین تکنولوژی‌های تصویر، شاخص‌های گیاهی و الگوریتم‌های متنوع مرتبط با گیاهان تحت تنش مرور شده است. همچنین، الگوریتم‌های بسیارپرکاربرد شبکه عصبی پیچشی در پردازش تصاویر گیاهان تحت تنش به طور خلاصه ذکر شده است. از طرف دیگر، چالش‌های کنونی استفاده از تکنیک‌های پردازش تصویر و هوش مصنوعی مرتبط با گیاهان تحت تنش مورد بحث قرار گرفته است.

کلمات کلیدی: کشاورزی هوشمند، محتوی کلروفیل، دمای سطح برگ و سنجش از دور.

مقدمه

امنیت غذایی جهانی یکی از مهم‌ترین چالش‌های مربوط به توسعه جوامع انسانی امروز است (Tilman *et al.*, 2011). به طوری که پیش‌بینی شده است که جمعیت جهان در سال ۲۰۵۰ به ۹ میلیارد نفر خواهد رسید. این بدین معنی است که برای تأمین نیاز انسان‌ها، در شرایط تغییرات سریع و شدید اقلیمی، از دست رفتن و تغییر کاربری اراضی زراعی و کاهش منابع آب در دسترس، تولیدات کشاورزی نیاز به افزایشی بیش از ۷۰ درصد مازاد بر سطح تولید کنونی دارد (Steenland and Thompson, 2020).

درک هوشمند و سریع اطلاعات فنوتیپی گیاهان زراعی به مدیریت صحیح مزرعه به‌عنوان مثال در انتخاب ارقام زراعی جدید با عملکرد کمی و کیفی بالاتر همراه با کاهش انرژی‌های ورودی به مزرعه، کمک قابل توجهی می‌کند. فنوتیپ گیاهان زراعی از طریق ویژگی‌های مورفولوژیک، فیزیولوژیک و بیوشیمیایی شامل رفتارهای حاصل از اثر متقابل ژن-محیط بر ساختار گیاهی، عناصر موجود در سلول‌ها، رشد و نمو قابل تشخیص است (Pan, 2015). این امر بدین معنی است که فنوتیپ گیاهان زراعی تنها تحت اثر ژن‌های آن‌ها نیست و بلکه انعکاس پیچیده‌ی رفتارهای فیزیولوژیک، بیوشیمیایی و میزان تحمل آن‌ها به تنش‌های محیطی است. فنوتیپ گیاهان از بخش‌های اساسی گیاهان از سطح سلول تا سطح اندام و حتی سایه‌انداز گیاهی ارزیابی می‌شود (Dhondt *et al.*, 2013) و می‌توان آن را به‌عنوان روشی کاربردی در ارزیابی رفتارهای خاص گیاهی تعریف کرد. پژوهش‌های فنوتیپی و فیزیولوژیک گیاهان تحت تنش‌های محیطی، بر مبنای طراحی و اجرای آزمایش‌های فشرده آزمایشگاهی و مزرعه‌ای بوده است. اما امروزه، تکنولوژی‌هایی که بر مبنای استفاده از سنسورها و تصویر هستند می‌توانند در مطالعات تغییرات فنوتیپی گیاهان با کمک نوسانات بازتابی، زیست‌توده و تشعشعات حرارتی قابل استفاده باشند. به‌عنوان مثال آثار و سازگاری به تنش غیر زنده می‌تواند با بررسی انواع داده‌های تصویر و سنسورها در پاسخ به تنش ویژه‌ای حاصل شود. به‌ویژه در شرایطی که گیاهان زراعی با انواع تنش‌های محیطی مواجه هستند. به‌عنوان مثال، در شرایط کمبود آب در دسترس یا تنش گرمایی، در اولین گام و در کم‌ترین زمان ممکن با تشخیص این تغییرات به کمک تکنولوژی تصویر و داده‌برداری مناسب به‌صورت غیر تخریبی می‌توان به سرعت مرحله و شدت تنش را پایش کرد. در این شرایط درک مکانیسم تنش مورد مطالعه و به دنبال آن پاسخ‌های گیاه زراعی جهت تشخیص اینکه کدام رفتار گیاه در مطالعه فنوتیپ آن دخالت دارد، بسیار ضروری است. مطالعات بی‌شماری در این زمینه در شرایط تنش‌های خشکی (Farooq *et al.*, 2009)، شوری (Negrão *et al.*, 2017)، غرقابی (Bailey-Serres and Brinton, 2012) و فلزات سنگین (Ghory *et al.*, 2019) گزارش شده است. تا سال‌های نه‌چندان دور، روش‌های کلاسیک (مرسوم) مطالعات فنوتیپی، مطالعات ژنومیکس و روش‌های ژنوتیپی در یک جایگاه و سطح نبودند.



شکل ۱: مختصری از رفتارهای فیزیولوژیکی عمده گیاهان زراعی در پاسخ به تنش‌های غیرزنده (غیرزیستی) و تکنولوژی‌های تصویر متفاوت مورد استفاده برای کمی‌سازی پاسخ فیزیولوژیک گیاه در شرایط تنش. تصویر سمت چپ گیاه در شرایط نرمال و گیاه سمت راست گیاه مواجه با تنش غیرزنده است. تکنولوژی‌های تصویر مورد استفاده بسته به نوع کاربرد آن در وسط ذکر شده‌اند. ^۱RGB (قرمز، سبز و آبی)، ^۲CHF (فلورسنس کلروفیل)، ^۳TIR (تصویر حرارتی مادون قرمز)، ^۴LiDAR (آشکارساز و سنجنده نوری)، ^۵MRI (تصویربرداری پرتوهای مغناطیسی)، ^۶CT (اسکن توموگرافی کامپیوتری)، ^۷PET (توموگرافی با نشر پوزیترون). (Al-Tamimi et al, 2022)

محدودیت‌های روش‌های کلاسیک مطالعات فنوتیپی محققان را بر آن داشت که از تکنولوژی‌های نوین در زمینه فنوتیپ و فیزیولوژی گیاهان در مسیر مهندسی کردن کشاورزی استفاده کنند. بنابراین، پیشرفت‌های بی‌شماری در مطالعات فنوتیپی گیاهان زراعی از طریق پژوهش‌های وسیع مزرعه‌ای همگام با علم رایانه، زیست‌شناسی، سنجش از دور، استاتستیک و ژنومیکس در جهت بررسی رفتارهای گیاهی پیچیده (ناشی از بیان ژن‌ها) روی داد که برای دستیابی به امنیت غذایی در آینده ضروریست. به طوری که امروزه پردازش تصویر به کمک تکنولوژی بینایی ماشین^۸ به شکل قابل توجهی در کشورهای توسعه یافته و در حال توسعه بر تولیدات کشاورزی و صنعتی تاثیر گذاشته است. این سیستم شامل سخت افزارهایی مانند دوربین‌ها، منابع نوری، کامپیوترها بخش عملگرای بینایی کامپیوتر (CV)^۹ و نرم افزارهای ساخت و راه‌اندازی الگوریتم‌های پردازش تصویر مانند پایتون^{۱۰}، متلب^{۱۱}، R^{۱۱} و ... که بخش هسته مرکزی بینایی کامپیوتر هستند، است (Wang et al., 2022). از طریق بینایی کامپیوتر روش‌هایی مانند روش فنوتیپی توان بالا^{۱۲} (HTP) که امکان مطالعه فنوتیپ گیاهان زراعی

¹ red, green and blue

² chlorophyll fluorescence

³ thermal infrared imaging

⁴ light detection and ranging

⁵ Magnetic resonance imaging

⁶ computed tomography

⁷ positron emission tomography

⁸ Machine vision Technology

⁹ Computer Vision

¹⁰ Python

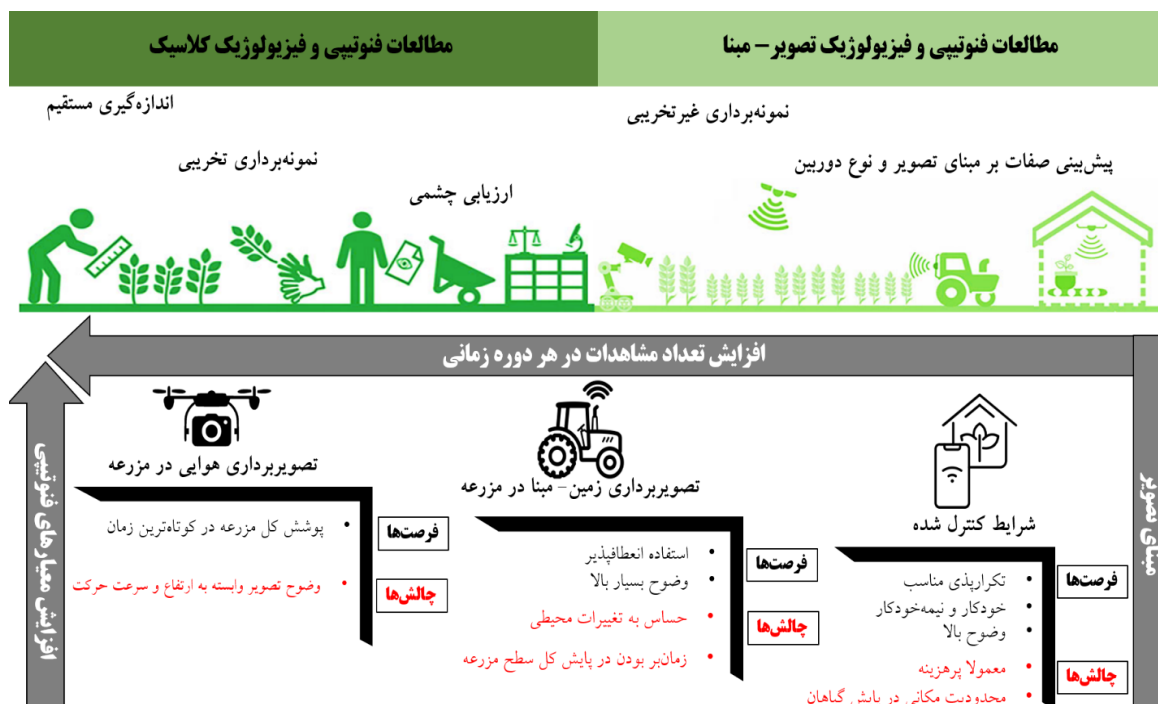
¹¹ Matlab

¹² High-throughput phenotyping

را به صورت غیر تخریبی برای دامنه‌های تیماری بی‌شماری از جمله تنش‌های غیر زنده مانند شوری، خشکی، غرقابی، کمبود عناصر غذایی و سایر عوامل تنش‌زای محیطی فراهم کرده است، میسر شده است (Li et al., 2014; Falgren, 2015; Hampling et al., 2015; Perez-Sanz et al., 2017; Das-Kohedri et al., 2019). تمام مطالعات ذکر شده در این مقاله، به فنوتیپ و فیزیولوژی گیاهان در پاسخ به تنش‌های محیطی به کمک تکنولوژی‌های تصویر- مبنای پرداخته است.

کاربرد روش‌های کلاسیک و بینایی ماشین در مطالعات فنوتیپی و فیزیولوژیک گیاهی

امروزه استفاده از تکنولوژی‌های تصویر و هوش مصنوعی در کنار روش‌های رایج ارزیابی کلاسیک، مطالعات فنوتیپی و فیزیولوژیک گیاهان زراعی صورت می‌گیرد و هر کدام مزایا و معایبی دارند. (شکل ۲) تکنولوژی‌های مورد استفاده در دو حالت کلی می‌توانند مورد استفاده قرار گیرند: ۱. روش‌های زمینی ۲. روش‌های هوایی. روش‌های زمینی وضوح تصویر بالاتر و دقت بالاتری دارند چرا که در فاصله کم‌تر از گیاه زراعی تصویر برداری صورت می‌گیرد (Condorelli et al., 2018) اما در روش‌های تصویر برداری هوایی (استفاده از ماهواره‌ها یا پهپادها) وضوح کم‌تر ولی سرعت حرکت و تصویر برداری بسیار بالاتر، سطح مزرعه بیش‌تری را پوشش می‌دهد. مزایا و معایب هر یک از روش‌ها در شکل ۲ ذکر شده است.



شکل ۲: مروری بر روش‌های مطالعه فنوتیپی و سیستم‌های توان بالا در مقیاس‌های متفاوت (Al- et al, 2022)

(Tamimi)

روش‌های کلاسیک جهت ارزیابی پاسخ فیزیولوژیک گیاهان زراعی به تنش‌های محیطی بر مبنای آزمایش‌های تخریبی هستند. در روش‌های تخریبی گیاه به بخش‌های مختلفی شامل ریشه، ساقه، برگ، گل و یا بذر، پهنک برگ، مجموع ساقه و

ریشه، مجموع ساقه و برگ و ... تقسیم‌بندی می‌شود. این روش‌ها امکان ارزیابی ابعاد اندام‌های گیاهی مانند طول و یا قطر ساقه، طول ریشه، حجم ریشه، وزن تر و خشک آن‌ها را فراهم می‌کند (Negrão *et al.*, 2017). این آزمایش‌ها شامل فعالیت‌های فشرده آزمایشگاهی و مزرعه‌ای به‌ویژه در ارزیابی خصوصیات فیزیولوژیک و بیوشیمیایی همچون محتوی کلروفیل برگ، عناصر غذایی از جمله محتوی نیتروژن اندام‌های گیاه است. اندازه‌گیری پارامترهای گیاهی مانند عدد اسپد که مقدار کلروفیل و میزان خسارت برگ را در شرایط تنش نمایش می‌دهد نیز به کمک روش‌های کلاسیک و ابزارهای گران قیمت صورت می‌گیرد (Edeling *et al.*, 2007). سنجش مقدار تعرق گیاه و فتوسنتز برگ در دوره‌های زمانی مشابه در طول روز، انتخاب واحد یکسان و مشخص از اندام گیاهی یکسان از گیاه زراعی (جهت کاهش میزان خطای ناشی از تغییرات فضایی اطراف گیاه زراعی) همگی عواملی هستند که این روش‌ها را هزینه‌بر و زمان‌بر جلوه داده است. به‌ویژه در شرایطی که تشخیص سریع‌تر تنش و پاسخ رفتاری گیاهان اثر قابل‌توجهی در کاهش خسارت محصول و افت عملکرد دارد (Ahssan *et al.*, 2018). در مقابل نتایج نشان داده است که استفاده از روش‌های بینایی به‌دلیل مزایای زیاد آن‌ها از جمله قابل استفاده بودن برای جمعیت‌های زیاد نمونه‌های گیاهی در مزرعه یا آزمایشگاه تحت شرایط تنش، تکرارپذیر بودن و غیرتخریبی بودن اجرای آزمایش‌ها، رو به رشد است. اگرچه روش‌های بینایی، کمی نیستند و نیاز به پردازش دارند اما روش‌های کلاسیک مطالعات فیزیولوژیک و فنوتیپ گیاهان زراعی از طریق آزمایش‌های تخریبی، محدودیت‌های زیادی در مطالعه رفتار گیاهان زراعی (به‌ویژه در شرایطی که ژنوتیپ‌های زیادی جهت بررسی موجود باشد) ایجاد کرده‌اند. لذا این محدودیت‌ها را می‌توان به کمک مزایای تکنیک‌های پردازش تصویر که پتانسیل ارزیابی واکنش گیاه به شرایط تنش را دارد، به‌صورت مدل‌های کمی و سری‌های زمانی برطرف کرد.

استفاده از تصاویر در ارزیابی‌های فنوتیپی و فیزیولوژیک گیاه تحت تنش‌های محیطی

هدف محققان زراعت و اصلاح نباتات در سال‌های اخیر، دست یافتن به تکنولوژی‌ها و روش‌هایی برای رسیدن به پایداری عملکرد در شرایط تنش به‌ویژه در شرایط تغییر اقلیم است. امروزه، بسیاری از پژوهشگران امروزه در حال استفاده از تکنولوژی‌های تصویر- مبنا در جهت ارزیابی دقیق‌تر فنوتیپی و فیزیولوژیک گیاهان در مدت زمان کم‌تر هستند. داده‌های تصویر در کنار داده‌های دقیق اقلیمی می‌تواند اطلاعات مناسبی از ارتباط ژنوتیپ- محیط‌زیست که پیش از آن در دسترس نبودند را در اختیار قرار دهد (Negrão and Julkowska, 2020). مزیت اصلی تکنولوژی‌های تصویر- مبنا غیرتخریبی بودن آن‌ها است. امکان اینکه بر روی یک گیاه در سری‌های زمانی متوالی بدون تغییر در ساختار و اندام گیاه اندازه‌گیری‌های مخلف صورت گیرد، بسیار ارزشمند است. همچنین، خطای ناشی از حذف اندام‌های گیاه، که می‌تواند روند مسیرهای فیزیولوژیک گیاه را تغییر دهند و نتایج را به شکل دیگری رقم بزنند، دیگر وجود ندارد.

تکنولوژی‌های تصویر و کاربرد آن‌ها در ارزیابی فنوتیپی و فیزیولوژیک گیاهان

تاکنون انواع سنسورها و چندین روش تصویربرداری در مطالعات فیزیولوژیک گیاهان زراعی مورد استفاده قرار گرفته است. (جدول ۱ و شکل ۲) پیش از بررسی فیزیولوژیک و فنوتیپی هر آزمایش لازم است در خصوص اینکه آزمایش یک آزمایش فنوتیپی توان پایین است یا توان بالا، از دو بعد هزینه و تعداد گیاهان مورد بررسی، مشخص گردد. در شرایطی که هدف آزمایش یک مطالعه فیزیولوژیک باشد (به‌عنوان مثال بررسی خصوصیات انفرادی ارقام یا وقوع جهش)، تعداد بوته‌های مورد استفاده کاهش می‌یابد و حداکثر به ۱۲ بوته می‌رسد. از طرف دیگر، در شرایطی که هدف مطالعه ژنتیکی باشد و محقق با تنوع وسیعی از ارقام و لاین‌ها سروکار داشته باشد و بیش از ۱۰۰ تا ۱۰۰۰ بوته جهت مطالعه فنوتیپی داشته باشد بهتر است از آزمایش‌های فنوتیپی توان بالا استفاده شود. از نظر هزینه نیز چنانچه هزینه تجهیزات و اجرای به ۱۰۰ دلار و کم تر از آن باشد می‌توان از آزمایش‌های فنوتیپی توان پایین مثلاً با استفاده دوربین تلفن همراه استفاده کرد. در صورتی که در آزمایش‌های فنوتیپی توان بالا بودجه مورد نیاز به بیش از ۱۰۰۰ دلار افزایش می‌یابد و شامل استفاده از تجهیزات درون مزرعه‌ای، دوربین‌های چندطیفی و فراطیفی با استفاده از جایگاه‌های ویژه مستقر در مزرعه یا استفاده از پهپادها و کوادکوپترها است. در نتیجه بودجه مورد نیاز اجرای آزمایش تعیین‌کننده نوع مطالعه فنوتیپی خواهد بود. روش‌های فنوتیپی توان بالا (HTP) شامل استفاده از سنسورهای مختلفی است که می‌توان بر روی یک وسیله پرنده مانند کواد کوپتر یا پهپاد نصب گردد و یا به‌صورت ثابت روی یک جرثقیل یا اسکلت ثابت باشد. با استفاده از پهپاد می‌تواند سنسورهای RGB، حرارتی، چندطیفی و فراطیفی را نصب و استفاده کرد. امروزه نیز پرکاربردترین ابزار هدایت سنسورها در مزرعه پهپادها هستند که پارامترهای بی‌شماری را ثبت می‌کنند. پژوهش‌ها نشان داده است که بیش‌ترین مطالعات از طریق در دسترس‌ترین سنسورهای تصویر یعنی به کمک سنسورهای RGB که تصاویر را در محدوده طیف نور مرئی ثبت می‌کند صورت گرفته است. (شکل ۳)

تصاویر RGB

دوربین‌ها و سنسورهای RGB در دامنه وسیعی از جمله در مطالعات مربوط رفتارهای فیزیولوژیک و فنوتیپی گیاهان تحت تنش می‌توانند کاربرد داشته باشند. در تصاویر RGB، پیکسل‌ها دریافت شده و به کمک زیرواحدهای آن می‌تواند مساحت بخش‌های مختلف از جمله ساقه‌چه، حجم زیست‌توده، ارتفاع و عرض گیاه، تراکم سایه‌انداز، رنگ برگ و پیری را تخمین بزند. بنابراین می‌توان مراحل رشد تا زوال را به‌صورت سری‌های زمانی کمی کرد و این عمل را به‌عنوان مثال در دو شرایط تنش محیطی و نرمال طراحی و اجرا کرد (Al-Tamimi et al., 2016). دسترسی آسان به تصاویر این سنسورها به عنوان نمونه دوربین‌های تلفن‌های همراه ارتفاع‌یافته کنونی در کنار نرم افزارهایی همانند Image J (Abramoph et al.,)

2004) و یا PlantCV می‌تواند به محقق در مطالعه فنوتیپی توان پایین با هزینه بسیار پایین کمک کند. (Gehan, 2017) تصاویر RGB در شرایطی که حجم داده مورد نیاز زیاد باشد، می‌توانند بسیار هزینه‌بر باشند. اگرچه در این شرایط به کمک این حجم از داده‌های RGB می‌توان زیست‌توده، جوانه‌زنی و سلامت گیاه را پیش‌بینی کرد و یا مدل‌های سه بعدی از مورفولوژی رشد گیاه را ایجاد کنند (Fahlgeren, 2015; Hampeling *et al.*, 2015).

جدول ۱: خلاصه‌ای از کاربرد انواع تصویر و سنسور در مطالعات فیزیولوژیک گیاهی

نوع سنسور	صفات مورد ارزیابی	مزایای استفاده از این نوع تصویر	چالش‌های پیش رو در استفاده از تصویر
MRI	وضعیت رطوبتی بافت، تعرق، ساختارهای ریشه	ساختار سه بعدی دارد.	توان پایین و هزینه زیاد
Thermal	دمای سطح برگ و سایه‌اندازه	تغییرات دمایی شاخص مناسبی از تنش رطوبتی هستند	به شدت تحت تاثیر شرایط محیطی
LIDAR	ارتفاع بوته و ساختار سایه‌انداز	وضوح و دقت ارزیابی ارتفاع بوته، قابلیت استفاده در شب	حجم داده‌ها زیاد، تجزیه داده‌ها دشوار
Visible Image (RGB)	زیست‌توده ریشه و ساقه، مورفولوژی و رنگ	کم‌هزینه و در دسترس، پایش لحظه‌ای زیست‌توده، مورفولوژی و صفات مربوط به اجزاء عملکرد	عدم توانایی تشخیص محتوی رطوبت نسبی
Hyperspectral Image	صفات بسیاری بسته به دامنه طول‌موجی سنسور شامل غلظت رنگدانه‌ها، محتوی رطوبت نسبی و وضعیت عناصر غذایی گیاه؛ همچنین شاخص‌های سبزیگی (مانند NDVI و ...)	دامنه وسیع طول‌موجی، دریافت سگنال‌های تنش قبل از اینکه آثار تنش قابل مشاهده باشد.	حجم داده بسیار زیادی ایجاد می‌کند، نیاز به داده کاری و یادگیری عمیق برای بهبود تجزیه و تحلیل داده‌ها دارد.
Chlorophyll Fluorescence	فعالیت فتوسنتز ۲	تغییرات فلورسانس کلروفیل معمولاً زودتر از سایر علائم تنش اتفاق می‌افتد بنابراین به سرعت می‌توان به وقوع تنش پی‌برد	برای استفاده نیاز به شرایط تاریکی دارد.
X-ray CT	ساختار ریشه	وضوح بالای تصویر، ساختار سه بعدی	نیمه خودکار و جز تکنولوژی‌های تصویر توان پایین، هزینه بالا
PET	جابجایی و انتقال مجدد عناصر غذایی درون گیاه	حرکت عناصر درون گیاه را نشان می‌دهد و مسیر و مکان‌های ذخیره در گیاه قابل ردیابی است.	جز تکنولوژی‌های تصویر توان پایین محسوب می‌شود. هزینه بالایی دارد.

تصاویر RGB در تشخیص تغییرات رنگی برگ و شناسایی جزئیات اتفاق افتاده در سطح و ساختار برگ کمک می‌کند. به عنوان مثال، کمبود نیتروژن، تنش شوری و تنش آبی منجر به زوال و پیری برگ می‌شود و دوربین‌های RGB امکان کمی‌کردن اثر این تنش‌ها را با محاسبه تعداد پیکسل‌های زرد رنگ محیا می‌کند (Nilson *et al.*, 2015; Lazarević *et al.*, 2021). پیچیدگی یا لوله‌شدن برگ که در گیاهانی مانند ذرت به دلیل اینکه نوعی سازگاری به شرایط تنش خشکی هستند که منجر به کاهش سطح تعرقی گیاه می‌شود. با کمک تصاویر RGB می‌توان پس از ۴۵ روز از رشد گیاهان، میزان لوله شدن برگ را بصورت روزانه کمی کرد و با مقدار برگ‌های باز شدن در ادامه روز پس از رفع تنش خشکی، مقایسه نمود.

(Nilson *et al.*, 2015) (شکل‌های ۳ و ۴)

سنسورهای ChF

سنسورهای تصویر فلورسانس کلروفیل می‌توانند تصاویر وسیعی از کل برگ یا گیاه و نیز تخمین سلامت جامعه گیاهی در پاسخ به تنش‌های محیطی غیرزنده ثبت کنند (Aolia, 2016). به‌طور کلی نور جذبی توسط کلروفیل در گیاهان در سه مسیر استفاده می‌شود: ۱. واکنش‌های فتوشیمیایی، ۲. واکنش‌های غیرفتوشیمیایی (هدررفت گرمایی طی خنک کردن گیاه) و ۳. بازنشر از طریق فلورسانس. بنابراین اندازه‌گیری نور بازنشر شده، روشی جایگزین در ارزیابی میزان کارایی فتوشیمیایی گیاه فراهم می‌کند. پارامترهای کلیدی مانند عملکرد کوانتومی پتانسیل در سیستم فتوسنتزی F_v/F_m (که به شدت در شرایط تنش زنده و غیر زنده، تغییرپذیر است) به کمک تصاویر فلورسانس کلروفیل قابل ردیابی است (Munns *et al.*, 2010) و از این طریق ظرفیت فتوسنتزی گیاه تحت تنش شوری برآورد شده است. (Campbell *et al.*, 2015) (شکل‌های ۳ و ۴)

سنسورهای TIR

یکی دیگر از تکنولوژی‌های مورد استفاده در پردازش تصویر استفاده از سنتورهای مادون قرمز است که تصاویر حرارتی برای شناسایی و تشخیص تنش قبل از از این‌که توسط طیف نور قابل رویت قابل تشخیص باشد، استفاده می‌شود. تفکیک دمایی روشی جایگزین است که قادر به اندازه‌گیری هدایت روزنه‌ای (که نقشی حیاتی در پاسخ به تنش‌ها ایفا می‌کند) می‌باشد. تصاویر حرارتی مادون قرمز در ارزیابی دمای سایه‌انداز، اندازه‌گیری هدایت روزنه‌ای و تعرق گیاه در تنش شوری استفاده شده است (Pineda *et al.*, 2021). بخش حرارتی طیف الکترومغناطیس نور مستقیماً با محتوی آب بافت‌ها در ارتباط است و از این طریق می‌توان با کم‌ترین هزینه و در کوتاه‌ترین زمان، وقوع تنش آبی را تشخیص داد (Gerehard *et al.*, 2019) (شکل‌های ۳ و ۴).

تصاویر LiDAR

از جمله تکنولوژی‌های کاربردی در پردازش تصویر می‌تواند به سنسورهای ارزیابی و ساخت مدل‌های سه بعدی با تشخیص هدف و فاصله نور از آن اشاره کرد. این تصویر یکی از فناوری‌های سنجش از راه دور است که با تاباندن لیزر به هدف و تجزیه و تحلیل نور بازتاب‌شده، فاصله را اندازه می‌گیرد. لایدار مشابه رادار است که بعضی اوقات نیز رادار لیزری نامیده می‌شود. اختلاف اصلی لایدار و رادار، طول‌موج‌های تابشی مورد استفاده است. این تکنولوژی کاربردهای وسیعی از گیاهان کوچک تا درختان و جنگل‌های چندصد ساله دارد. یکی از ایرادات این روش، زمان‌بر بودن تصویربرداری و نیاز به ظرفیت زیاد باتری جهت تصویربرداری است. اما داده‌های سه بعدی LiDAR در ترکیب با تصاویر RGB، فلورسانس کلروفیل، انعکاس‌های فتوشیمیایی و تصاویر دمای سطح برگ را برآورد و می‌توانند پاسخ‌های رفتاری رنگدانه‌های گیاه، فتوسنتز جاری، تعرق، باز

شدن روزه‌ها، جهت‌گیری و زاویه برگ و ساقه را در شرایط تنش برآورد کنند (Jean, 2021) (شکل‌های ۳ و ۴).

تصاویر CT، PET و MRI

از دیگر روش‌های تصویر- مبنای سه بعدی می‌تواند به تکنولوژی کامپیوتری اشعه ایکس (X-ray)، توموگرافی انتشار پوزیترون (PET) و تصاویر رزونانس مغناطیسی (MRI) اشاره کرد. این تکنولوژی‌ها در سطح تک بوته استفاده می‌شوند و تشخیص‌های بسیار واضحی از ساختارهای گیاهی آسیب دیده در شرایط تنش را تهیه می‌کنند. از تصاویر اشعه ایکس بیش‌تر در مطالعات فنوتیپی ریشه گیاهان به‌دلیل هزینه اجرای کم‌تر و وضوح بالاتر، استفاده می‌شود (Atkinson *et al.*, 2019). به‌عنوان مثال برای پایش رشد و نمو غده‌های سبب‌زمینی در پاسخ به ترکیب تنش گرمایی و خشکی کاربرد داشته است (Van *et al.*, 2021). روش PET روش غیرتخریبی دیگری است که به کمک آن می‌توان مقادیر بسیار جزئی مواد رادیواکتیو کوتاه‌عمر تزریق شده به سلول‌ها و میکروارگانیزم‌ها را ردیابی کرد. ترکیب روش PET و CT می‌تواند اطلاعات بسیار دقیقی و کمی از ساختار خاک و رشد ریشه با وضوح بالا تهیه کند (Garbout *et al.*, 2012). MRI بر پایه امواج رادیویی است که امکان تصویربرداری از پروتون‌های آب (که در فرآیندهای فیزیولوژیکی درونی سلول اتفاق دخیل هستند) را در اختیار پژوهشگر قرار می‌دهد. به‌عنوان مثال در پژوهشی برای تشخیص تفاوت مسیر انتقال آب در گیاه جو کشت شده در شرایط مزرعه با جو متحمل به شرایط شور در تنش شوری، از این تکنولوژی استفاده شده است (Isayenkov *et al.*, 2020) (شکل‌های ۳ و ۴).

تصاویر^{۱۳} MSI و HSI

تصاویر چندطیفی (MSI) باندهای طول‌موجی بین ۳ تا ۱۰ از طیف نور و تصاویر فراطیفی (HSI) باندهای طول‌موجی بسیار نزدیک به هم را از محدوده طول‌موج‌های مرئی تا طیف طول‌موجی قرمز بسیار دورتر^{۱۵} (VNIR) و قرمز دور طول‌موج کوتاه^{۱۶} (SWIR) شامل می‌شوند و به کمک آن می‌توان خصوصیات بیولوژیکی، فیزیکی و شیمیایی نمونه‌ها را ارزیابی کرد (Jakman *et al.*, 2009; Jakman *et al.*, 2008; Valous *et al.*, 2009). پردازش تصاویر فراطیفی با شناسایی تغییرات نورانعکاسی ساطع شده از گیاه تحت تنش می‌تواند پیش‌تر از شاخص‌های ظاهری در طول‌موج قابل رویت، به تشخیص تنش کمک کند (Fahlegren, 2015; Sims *et al.*, 2002). در گزارش Mertens و همکاران (۲۰۲۱) ذکر شده است که با استفاده از تصاویر SWIR تمام بخش‌های گیاه شامل عناصر، آب و حتی متابولیت‌های ثانویه مانند فلاونوئیدها و ترپنوئیدها قابل اندازه‌گیری است. همچنین گزارش شده است که از داده‌های به‌دست آمده از این روش می‌توان به عنوان روشی جایگزین

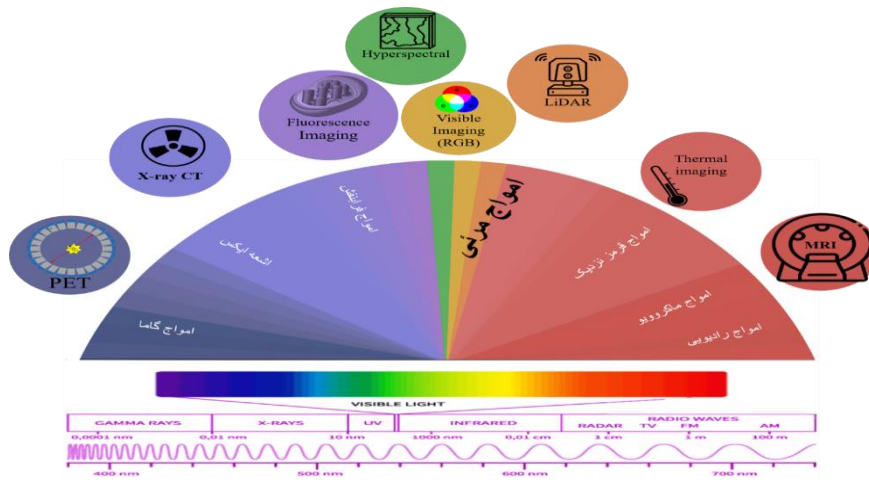
¹³ Multispectral Imaging

¹⁴ Hyperspectral imaging

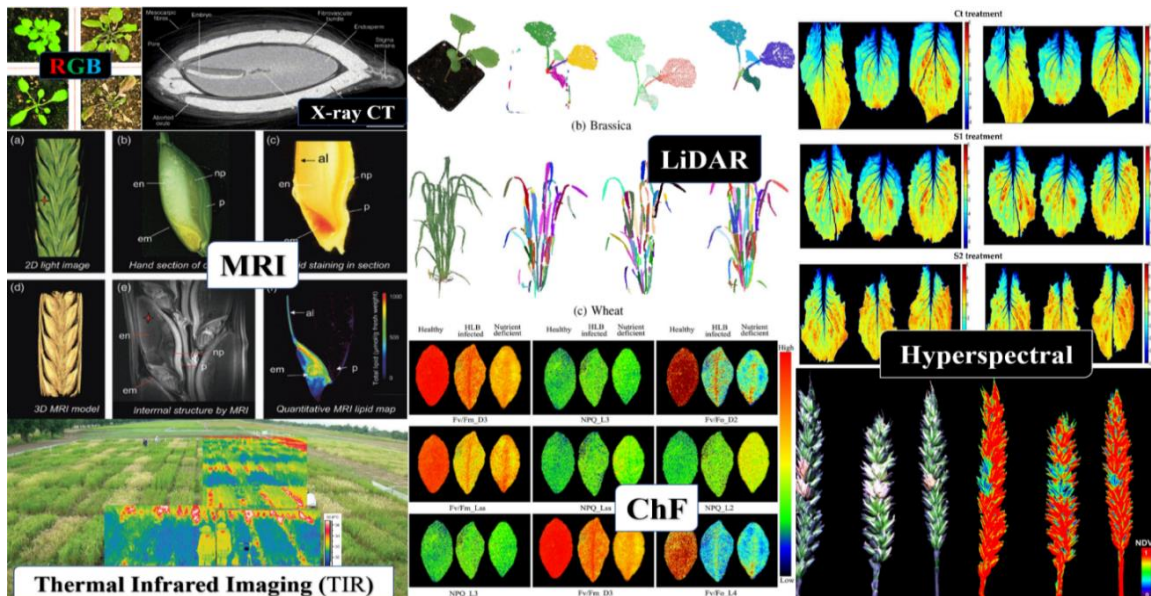
¹⁵ Visible and near infrared

¹⁶ Short-wave Infrared

روش تصاویر فراطیفی در ارزیابی گیاهان در دو شرایط تحت تنش و شرایط نرمال از سه روز پس از شروع آزمایش استفاده کرد (Mohad-Assari *et al.*, 2018). بنابراین می‌توان با هزینه بسیار کم و در مدت کوتاه‌تری حجم زیادی داده از آزمایش‌ها را برداشت و مورد ارزیابی قرارداد. در پژوهش‌های بسیاری از تصاویر فراطیفی به عنوان روش‌های جایگزین روش‌های تخریبی در ارزیابی خصوصیات فیزیولوژیک گیاهان زراعی استفاده شده است (جدول‌های ۴ و ۵). تصاویر فراطیفی نیازمند پردازش تصویر سنگین و پیشرفته به‌ویژه به کمک زبان یادگیری ماشین هستند. در این روش می‌توان با ارزیابی وضعیت پیکسل‌های تصویر به ارزیابی تنش پرداخت. البته هنوز هم دسترسی به تکنولوژی تصاویر فراطیفی نسبت به سایر تکنولوژی‌های تصویر ذکر شده، سخت‌تر است (شکل‌های ۳ و ۴).



شکل ۳: طیف طول موجی در انواع سنسورها جهت ارزیابی ویژگی‌های فیزیولوژیک متناسب با ماهیت پردازنده و بازتاب دریافتی



شکل ۴: نمونه‌هایی از کاربرد انواع سنسورهای تصویر در مطالعات فیزیولوژیک و فنوتیپی گیاهان زراعی در شرایط تنش‌های محیطی.

پردازش تصویر و استخراج داده‌ها

روند عمومی پردازش تصویر برای دستیابی داده‌های تصویر دشوار است و بسته به نوع و ماهیت تصویر (RGB)، چند طیفی، فراطیفی و غیره) متفاوت باشد. مراحل پردازش تصویر شامل: ۱. بارگذاری تصویر، ۲. پیش‌پردازش تصویر (بهبود وضوح، حذف نویز) تا تصویر برای مراحل بعد قابل استفاده باشد، ۳. بخش‌بندی تصویر برای جداکردن اجزایی از تصویر که مورد نظر محقق هستند و پس زمینه حذف می‌شود، ۴. استخراج عوارض مورد نظر برای حصول داده‌های بر اساس هدف آزمایش به عنوان مثال: شیب، لبه، شکل، سایز، بافت، رنگ عوارض و غیره، ۵. کیفیت داده‌ها (پس از استخراج حجم زیادی از ردیف عوارض باید اصلاح شود)، ۶. فیلتر کردن صفات استخراج شده و تخمین زده شده، سپس به عوارض بیولوژیکی تبدیل شوند، ۷. داده‌کاوی و مدل‌سازی به عنوان مثال استفاده از مدل‌های مکانیکی برای توصیف پویایی رشد گیاه که حاوی اطلاعات توزیع فضایی و حرارتی گیاه است (Bailey-Serres and Brinton, 2012). اطلاعات حاصل از داده‌ها، روش‌های اجرا، شرایط محیطی و تشریح داده‌ها باید واضح و سهل‌الوصول باشد تا بتوان به خوبی مدل‌سازی و داده‌کاوی را انجام داد. طی فرآیند انتخاب داده‌ها و تخمین آن، تصویر گیاه از هر نمونه به یک داده عددی تبدیل خواهد شد که می‌تواند به صورت سری زمانی باشد. از این مرحله به بعد داده‌ها آماده آنالیزهای ریاضی برای تکمیل ارزیابی گیاه در شرایط تنش هستند. بنابراین انتخاب صفت مورد ارزیابی و تخمین آن با استفاده از داده‌های تصویر نیازمند خلاقیت و حساسیت روش آنالیز تصویر دارد تا بتواند به درستی رفتار فیزیولوژیک، ساختاری و حرارتی گیاه را اندازه‌گیری کند. صفات ساختاری به آسانی با استفاده از بخش‌بندی‌های رنگی قابل محاسبه و دسته‌بندی هستند. به عنوان مثال حجم ساقه به راحتی به کمک تصاویر RGB قابل تفکیک و برآورد است. در نهایت مجموع حجم کل ساقه‌ها به تخمین عملکرد زیست‌توده ساقه (به کمک مدل‌سازی و میزان همبستگی آن با سطح برگ، وزن تر ساقه و وزن خشک ساقه) منجر می‌شود (Golzarian *et al.*, 2011). جدول ۲ شامل پژوهش‌های صورت گرفته در مطالعات فیزیولوژیک و فنوتیپی گیاهان زراعی تحت تنش به کمک تکنیک‌های پردازش تصویر، در دو شرایط کنترل شده و مزرعه است (Al-Tamimi *et al.*, 2018).

شاخص‌های سبزی‌نگی (VI)^{۱۷}

برای توسعه مدل‌های ریاضی مرتبط با گیاهان زراعی، روش‌های زیادی برای استخراج اطلاعات مورد آزمون قرار گرفته است. در سال‌های اخیر مهمترین و محبوب‌ترین روش‌ها از تصاویر دیجیتال و شاخص‌های طیفی بدست آمده‌اند که می‌توانند صفات فیزیولوژیک بیشماری را پیش‌بینی کنند.

¹⁷ Vegetation Indices

جدول ۲: برخی از مطالعات صورت گرفته در زمینه واکنش گیاهان زراعی در شرایط مختلف تنش‌های محیطی با

تصاویر و سنسورهای مختلف

نوع تنش	مکان	گیاه	نوع تکنولوژی تصویر	صفات قابل اندازه‌گیری	نمونه برداری تجربی در صورت نیاز
سرما	کنترل شده	نخود	RGB-fluorescenc	وزن زیست‌توده، پارامترهای مرتبط با فلورسانس کلروفیل	-
سرما	مزرعه	ذرت	RGB- Multispectral	تشخیص، کمی‌سازی و دسته بندی تنش	-
خشکی	کنترل شده	جو	RGB	صفات و ماده خشک مرتبط با زیست‌توده و رشد	ماده خشک ساقه، تعداد پنجه و ارتفاع بوته
خشکی	کنترل شده	گندم	RGB	صفات مرتبط با زیست‌توده و رشد	-
خشکی	کنترل شده	برنج	RGB	صفات و ماده خشک مرتبط با زیست‌توده و رشد	ماده خشک ساقه، عملکرد و اجزاء عملکرد
خشکی	کنترل شده	جو سبز	RGB—fluorescence— near-infrared (NIR)	صفات مورفولوژیک، کارایی فتوسنتز، پارامترهای فتوسنتزی و محتوی آب سلول	-
خشکی	کنترل شده	جو	RGB	صفات و ماده خشک مرتبط با زیست‌توده و رشد	ماده خشک ساقه، تعداد پنجه و ارتفاع بوته
خشکی	کنترل شده	جو	RGB-fluorescenc	ارتفاع گیاه و پارامترهای فلورسانس کلروفیل	ماده خشک ساقه، محتوی رطوبت نسبی
خشکی	کنترل شده	برنج	RGB—near-infrared (NIR)—infrared— fluorescence	صفات و ماده خشک مرتبط با زیست‌توده و رشد، صفات ساختاری گیاه، کارایی فتوسنتز، پارامترهای فتوسنتزی و محتوی آب سلول	-
خشکی	کنترل شده	لئوس	RGB-fluorescenc	صفات و ماده خشک مرتبط با زیست‌توده و رشد، صفات مورفولوژیک، پارامترهای فلورسانس کلروفیل	-
خشکی	کنترل شده	ذرت	hyperspectra	زاویه برگ و مساحت سطح برگ	-
خشکی	کنترل شده	ذرت	hyperspectra	شاخص‌های سبزیگی	-
خشکی	کنترل شده	جو	RGB	صفات مرتبط با زیست‌توده و رشد	ماده خشک ساقه
خشکی و کمبود نیتروژن	کنترل شده	سورگوم	RGB—near-infrared (NIR)	صفات مرتبط با رشد و زیست‌توده، زوال (درصد)، طیف قرمز نزدیک، پارامترهای تشکیل دهنده محتوی رطوبت نسبی	ماده خشک ساقه، ارتفاع بوته، درصد ماده خشک، درصد رطوبت، محتوی کلروفیل
خشکی و کمبود نیتروژن	مزرعه	گندم	RGB	ماده خشک و صفات مرتبط با رشد و زیست‌توده	-
خشکی و کمبود نیتروژن	کنترل شده	ذرت، سویا و لوبیا	hyperspectral	NDVI، محتوی رطوبت نسبی برگ، غلظت عناصر ماکرو	زیست‌توده کل، غلظت عناصر ماکرو
گرما	کنترل شده	ماش	fluorescence	پارامترهای فلورسانس کلروفیل	-
شوری	کنترل شده	نخود	RGB	صفات مرتبط با رشد و زیست‌توده	ماده خشک ساقه، غلظت یون سدیم و پتاسیم برگ، ارتفاع بوته، زمان گلدهی، زمان نکروزه شدن برگ، عملکرد و اجزاء عملکرد
شوری	کنترل شده	برنج	RGB—fluorescence	زیست‌توده، زوال ساقه‌چه (درصد)	ماده خشک ساقه، غلظت یون سدیم و پتاسیم برگ
شوری	کنترل شده	برنج	RGB—fluorescence	زیست‌توده، پارامترهای فلورسانس کلروفیل	غلظت یون سدیم و پتاسیم برگ
شوری	کنترل شده	برنج	RGB	صفات مرتبط با رشد و زیست‌توده	ماده خشک ساقه
شوری	کنترل شده	جو	RGB	روابط ریاضی مرتبط با منحنی های رشد گیاه	-
شوری	کنترل شده	گندم	RGB	صفات مرتبط با رشد و زیست‌توده	غلظت یون سدیم و پتاسیم برگ
شوری	کنترل شده	برنج	RGB—fluorescence	صفات مرتبط با رشد و زیست‌توده	ماده خشک ساقه، پارامترهای گازی دخیل در فرآیندهای فتوسنتز، هدایت روزنه ای و تعرق، غلظت کلروفیل
شوری	کنترل شده	گندم	hyperspectral	NDVI و شاخص‌های سبزیگی	ماده خشک ساقه و ریشه
شوری	مزرعه	گوجه فرنگی	RGB	صفات مرتبط با رشد و زیست‌توده، پیش‌بینی عملکرد و اجزاء عملکرد	ماده خشک ساقه، عملکرد و اجزاء عملکرد
شوری	کنترل شده	لئوس	fluorescence	پارامترهای فلورسانس کلروفیل	ماده خشک ساقه
شوری	کنترل شده	بامیه	hyperspectral	قطعه بندی گیاه و برگ	زیست‌توده کل، عدد اسپد، غلظت یون سدیم، نرخ فتوسنتز و تعرق
شوری	کنترل شده	گندم	hyperspectral	تشخیص تنش، شاخص‌های سبزیگی، قطعه‌بندی برگ	ماده خشک ساقه و ریشه
کمبود نیتروژن	مزرعه	جو	RGB—multispectral— thermal	ماده خشک گیاه، شاخص زوال گیاه زراعی، شاخص انعکاس فتوشیمیایی، شاخص باندهای رطوبتی	عملکرد و اجزاء عملکرد
کمبود نیتروژن	کنترل شده	گندم	RGB—hyperspectral	صفات مورفولوژیک و آناتومیک، شاخص‌های سبزیگی مرتبط با مقدار کلروفیل	ماده خشک ساقه، عملکرد و اجزاء عملکرد، محتوی کلروفیل
کمبود نیتروژن	کنترل شده	سورگوم	RGB	ماده خشک و صفات مرتبط با رشد و زیست‌توده	-
کمبود نیتروژن	مزرعه	ذرت	hyperspectral	بازتاب های برگ	-
کمبود نیتروژن	مزرعه	پونجه	RGB—multispectral	NDVI، شاخص سطح برگ و پوشش سطح سبز	زیست‌توده، عملکرد و ارتفاع بوته
کمبود نیتروژن	مزرعه	ذرت	hyperspectral	NDVI	-

بیشترین شاخص‌ها، شاخص‌های سبزینگی (VI) یا همان شاخص‌های سبزینگی طیفی^{۱۸} (VIS) هستند (Abdel-). این شاخص‌ها در جهت تعیین میزان سلامت گیاهان، رطوبت نسبی و محتوی عناصر غذایی گیاهان توسعه یافته‌اند. شاخص‌های سبزینگی، نسبت‌های ساده شده‌ی ضروری حاصل از طول موج‌های خاصی هستند. این شاخص‌ها، بصورت کمی و حاصل از بازتاب نور انعکاسی در محدوده طول موج‌های مرئی و قرمز نزدیک از سطح گیاه حاصل شده است. بدین ترتیب امکان تمایز گیاه از خاک، مرحله سبزینگی، خصوصیات سبزینگی (زیست‌توده سایه‌انداز گیاهی، محتوی کلروفیل و ...) به راحتی قابل دستیابی است. پردازش داده‌های تصاویر فراطیفی به کمک تصویربرداری سنجش از دور، اطلاعات جامع تری نسبت به سایر تصاویر در دسترس قرار می‌دهند. شاخص‌های سبزینگی بی‌شماری (از طریق معادلات جبر خطی ساده) تا کنون مطرح شده و به طور وسیع در مطالعات فنوتیپی و فیزیولوژیک گیاهی مورد استفاده قرار گرفته است. (جدول ۳)

برخی از مهم‌ترین شاخص‌های سبزینگی که در جدول ۳ ذکر شده‌اند، عبارتند از: ۱. NDVI و ۲. SR یا همان^{۱۹} RVI، که بیشترین استفاده را دارند. مقدار SR در واقع نسبت بین نور انعکاسی در محدوده طول موجی قرمز نزدیک و طول موج قرمز است. بنابراین، یک روش بسیار سریع در تفکیک برگ‌های سبز در از سایر عوارض در تصویر و تخمین درست زیست‌توده است. اگر هر دو عدد بازتابی طول موج‌های قرمز نزدیک و قرمز برابر باشند، مقدار SR برابر با ۱ و یا نزدیک ۱ خواهد بود. مقدار SR برای خاک معمولاً نزدیک یک است. با افزایش مقدار سبزینگی، مقدار شاخص SR نیز افزایش می‌یابد و به این سادگی می‌تواند میزان رشد را تخمین زد. شاخص NDVI نیز از نسبت رابطه طول موج بازتابی در بخش نور قرمز و قرمز نزدیک طیف نوری بدست می‌آید و دامنه آن بین -۱ و ۱ متغیر است. مقدار مثبت‌تر نشان دهنده مقدار سبزینگی بیشتر و محدوده منفی نشان‌دهنده بخش‌های غیرسبزینه هستند (Al-Tamimi et al., 2022). یک محدوده گیاهی سالم باید حداقل مقدار NDVI برابر یا بیشتر از ۰/۵ داشته باشد. در حالی که این مقدار برای گیاهان تحت تنش کمتر از این عدد خواهد بود (Zarco-Tejada et al., 2012; Al-Henoy et al., 2019; Liang et al., 2018).^{۲۰} GNDVI که از نسبت باندهای طول موجی سبز و قرمز نزدیک بدست می‌آیند، شاخص مناسبی است که دامنه آن از ۰ تا ۱ است (Al-Tamimi et al., 2022). این شاخص بیشتر در ارتباط با بخش‌های جذب امواج در سیستم‌های فتوسنتزی است و ارتباط خطی مستقیمی با شاخص سطح برگ و زیست‌توده گیاهان زراعی دارد (Karneili et al., 2010). ذکر این نکته لازم است که بسیاری از این شاخص‌ها باید برای گیاهان و شرایط اقلیمی مختلف مورد آزمون و ارزیابی قرار گیرند. اگرچه نتایج پژوهش‌ها

¹⁸ Vegetation Indices spectrum

¹⁹ Ratio vegetation index

²⁰ Green Normalized Vegetation Index

نشان داده است که اغلب آن‌ها قابل اجرا برای گیاهان دیگر نیز هستند. به طور کلی شاخص‌هایی مانند شاخص‌های سبزی‌نگی مستخرج شده از تصاویر و سایر شاخص‌های تنش ذکر شده تاکنون و پردازش تصاویر مورد بحث، نیازمند داده‌های حجیم و اغلب پیچیده‌ای دارد که با روش‌های مرسوم قابل دستیابی نیستند. این داده‌های حجیم به کمک روش‌های کامپیوتری نوین مورد علاقه محققان تحت عنوان "یادگیری ماشین" صورت می‌گیرد.

کاربرد هوش مصنوعی در پردازش تصاویر گیاهان و مدل‌سازی فیزیولوژیک آن‌ها

یادگیری ماشین (ML) و الگوریتم‌های مورد استفاده در پردازش تصویر

با افزایش حجم داده برای پردازش و مدل‌سازی رفتار گیاهان به‌ویژه رشدیافته در شرایط تنش‌زای محیطی، پژوهشگران نیازمند استفاده از راه‌کارهایی برای مدیریت داده‌ها و ذخیره‌سازی آن‌ها هستند. ارزش داده‌های حاصل شده از تصاویر به‌دست آمده از سنسورها نیز به روش‌های تخصصی پردازشی وابسته است. برای غلبه بر چالش ناشی از حجم داده‌ها، یادگیری ماشین (ML) و زیرشاخه‌های آن، با چهار رویه ICQP (شناسایی،^{۲۲} دسته‌بندی،^{۲۳} کمی‌سازی^{۲۴} و پیش‌بینی^{۲۵}) به عنوان روش‌هایی در یکپارچه‌سازی داده‌ها و تشخیص فنوتیپی گیاهان تحت تنش کاربرد دارند (Osama et al., 2015; Sing et al., 2016). خلاصه‌ای کاربرد یادگیری ماشین در جدول ۴ ذکر شده است (Rico-Chávez et al., 2022). یادگیری ماشین را می‌توان تعریفی از توانایی برنامه‌های کامپیوتری بر مبنای یادگیری انسانی شناخت (Coza et al., 1996). روند این یادگیری به ۲ دسته تقسیم می‌شود: ۱. تحت نظارت و ۲. یادگیری بدون نظارت. یادگیری با نظارت داده‌های برجسب‌دار را در مسیر یادگیری و آزمون یک مدل انتخابی استفاده می‌کند (مثلاً در مقایسه بین تنش و بدون تنش). الگوریتم‌های یادگیری ماشین با ناظر برای یادگیری از روی نمونه‌ها طراحی شده‌اند. نام یادگیری با ناظر هم از این ایده سرچشمه می‌گیرد که آموزش این نوع الگوریتم‌ها مانند این است که یک معلم بر کل روند آموزش نظارت دارد. یادگیری با ناظر را می‌توان به دو زیرمجموعه کلی: الف: طبقه‌بندی و ب: رگرسیون تقسیم کرد (Mitchell, 1997; Ma, 2014). در مقابل، یادگیری بدون نظارت که نیازی به داده‌های برجسب‌دار ندارد و در عوض از تکنیک‌های کلاستر کردن داده‌ها در تفکیک عوارض استفاده می‌کند. در این روش، کاربر نیازی به نظارت بر مدل ندارد، در عوض خود مدل به‌تنهایی برای کشف الگوها و اطلاعاتی که در داده وجود دارد کار می‌کند. معمولاً، از مدل‌های یادگیری بدون ناظر برای سه هدف اصلی خوشه‌بندی، اتحاد و کاهش ابعاد استفاده می‌شود (Bhatt, 2018; Parded, 2018).

²¹ Machine Learning

²² identification

²³ classification

²⁴ quantification

²⁵ prediction

جدول ۳: مهم‌ترین و پرکاربردترین شاخص‌های گیاهی مورد استفاده در پردازش تصویر مطالعات فیزیولوژیک گیاهان

تحت تنش

ردیف	شاخص گیاهی	معادله	مخفف
۱.	شاخص سبزیگی تفاضلی	NIR - Red	DVI ^{۲۶}
۲.	شاخص ساده پوشش گیاهی	$\rho\text{NIR}/\rho\text{RED}$	SR ^{۲۷}
۳.	شاخص ساده پوشش گیاهی اصلاحی	$(\rho 800 - \rho 445) / (\rho 680 - \rho 445)$	MSR ^{۲۸}
۴.	شاخص ساده پوشش گیاهی اصلاحی مرز قرمز	$(\rho 750 - \rho 445) / (\rho 705 \text{ nm} - \rho 445)$	MRESR ^{۲۹}
۵.	شاخص سبزیگی تفاضلی نرمالیزه	$(\rho\text{NIR} - \rho\text{RED}) / (\rho\text{NIR} + \rho\text{RED})$	NDVI ^{۳۰}
۶.	شاخص سبزیگی تفاضلی نرمالیزه سبز	$(\rho\text{NIR} - \rho\text{GREEN}) / (\rho\text{NIR} + \rho\text{GREEN})$	GNDVI ^{۳۱}
۷.	شاخص مرز قرمز تفاضلی نرمالیزه	$(\rho\text{NIR} - \rho\text{RED EDGE}) / (\rho\text{NIR} + \rho\text{RED EDGE})$	RENDVI ^{۳۲}
۸.	شاخص سبزیگی اصلاحی خاک تنظیم‌شده قرمز	$1.16 (\rho\text{NIR} - \rho\text{RED}) / (\rho\text{NIR} + \rho\text{RED} + 0.16)$	OSAVI ^{۳۳}
۹.	شاخص سبزیگی اصلاحی خاک تنظیم شده سبز	$(\rho\text{NIR} - \rho\text{GREEN}) / (\rho\text{NIR} + \rho\text{GREEN} + 0.16)$	GOSAVI ^{۳۴}
۱۰.	شاخص سبزیگی نسبی سبز	$\rho\text{NIR} / \rho\text{GREEN}$	GRVI ^{۳۵}
۱۱.	شاخص نسبی سبز و قرمز	$\rho\text{RED} / \rho\text{GREEN}$	RGRI ^{۳۶}
۱۲.	شاخص غیرخطی	$(\rho\text{NIR}2 - \rho\text{RED}) / (\rho\text{NIR}2 + \rho\text{RED})$	NLI ^{۳۷}
۱۳.	شاخص محتوی آبی برگ	$\text{Log}(1 - (\rho\text{NIR} - \rho\text{MIDIR})) / -\text{log}(1 - (\rho\text{NIR} - \rho\text{MIDIR}))$	LWCI ^{۳۸}
۱۴.	شاخص سبزیگی بهبودیافته	$2.5[(\rho\text{NIR} - \rho\text{RED}) / (\rho\text{NIR} + 6 * \rho\text{RED} - 7.5 * \rho\text{BLUE} + 1)]$	EVI ^{۳۹}
۱۵.	شاخص بازتاب فتوشیمیایی	$(\rho 531 - \rho 570) / (\rho 531 + \rho 570)$	PRI ^{۴۰}
۱۶.	شاخص رنگدانه ساختار متراکم	$(\rho 800 - \rho 445) / (\rho 800 + \rho 680)$	SIPI ^{۴۱}
۱۷.	شاخص سبزیگی تفاضلی اصلاحی مرز قرمز	$\rho 750 - \rho 705) / (\rho 750 + \rho 705 - 2 * \rho 445)$	mRENDVI ^{۴۲}
۱۸.	شاخص آبی تفاضلی نرمالیزه	$(\rho\text{NIR} - \rho\text{SWIR}) / (\rho\text{NIR} + \rho\text{SWIR})$	NDWI ^{۴۳}
۱۹.	شاخص تنش رطوبتی	$(\rho 1599) / (\rho 819)$	MSI ^{۴۴}
۲۰.	شاخص مادون قرمز تفاضلی نرمالیزه	$(\rho 819 - \rho 1649) / (\rho 819 + \rho 1649)$	NDII ^{۴۵}
۲۱.	شاخص بازتابی زوال گیاه	$(\rho 680 - \rho 500) / \rho 750$	PSRI ^{۴۶}
۲۲.	شاخص سبزیگی تفاضلی نرمالیزه اصلاح شده	$\sqrt{(\rho\text{NIR} - \rho\text{RED}) / (\rho\text{NIR} + \rho\text{RED})} + 0.5$	TDVI ^{۴۷}
۲۳.	شاخص سبز-قرمز تفاضلی نرمالیزه	$(\rho\text{GREEN} - \rho\text{RED}) / (\rho\text{GREEN} + \rho\text{RED})$	NGRDI ^{۴۸}
۲۴.	شاخص سبزیگی کلروفیل	$(\rho\text{NIR} / \rho\text{GREEN}) - 1$	CIgreen ^{۴۹}
۲۵.	شاخص مرز قرمز کلروفیل	$(\rho\text{NIR} / \rho\text{RED EDGE}) - 1$	CIrededge ^{۵۰}
۲۶.	شاخص محتوی کلروفیل سایه‌انداز	$\text{RENDVI} - \text{RENDVI min} / \text{RENDVI max} - \text{RENDVI min}$	CCCI ^{۵۱}
۲۷.	شاخص سبزیگی کلروفیل	$\rho\text{NIR} \times (\rho\text{RED} / \rho\text{GREEN}^2)$	CVI ^{۵۲}
۲۸.	شاخص سبزیگی اصلاح شده خاک	$(\rho\text{NIR} - \rho\text{RED}) (1+L) / (\rho\text{NIR} + \rho\text{RED}) + L$	SAVI ^{۵۳}

ρ نشان‌دهنده بازتاب از باند مورد نظر است.

- ۲۶ Difference Vegetation Index
 ۲۷ Simple Ratio
 ۲۸ Modified Simple Ratio
 ۲۹ Modified Red-Edge Simple Ratio Index
 ۳۰ Normalized Difference Vegetation Index
 ۳۱ Green Ndvi
 ۳۲ Red-Edge Normalized Difference Vegetation Index
 ۳۳ Optimized Soil-Adjusted Vegetation Index
 ۳۴ Green Optimized Soil Adjusted Vegetation Index
 ۳۵ Green Ratio Vegetation Index
 ۳۶ Red, Green Ratio Index
 ۳۷ Nonlinear Index
 ۳۸ Leaf Water Content Index
 ۳۹ Enhanced Vegetation Index
 ۴۰ Photochemical Reflectance Index
 ۴۱ Structure Insensitive Pigment Index
 ۴۲ Modified Red Edge Ndvi
 ۴۳ Normalised Difference Water Index
 ۴۴ Moisture Stress Index
 ۴۵ Normalized Difference Infrared Index
 ۴۶ Plant Senescence Reflectance Index
 ۴۷ Transformed Normalized Difference Vegetation Index
 ۴۸ Normalized Green-Red Difference Index
 ۴۹ Green Chlorophyll Index
 ۵۰ Red-Edge Chlorophyll Index
 ۵۱ Canopy Chlorophyll Content Index
 ۵۲ Chlorophyll Vegetation Index
 ۵۳ Soil Adjusted Vegetation Index

امروزه، تکنیک‌های برجسته‌ی یادگیری عمیق که استفاده می‌شوند، اغلب به یادگیری با ناظر متکی هستند. با وجود این، کاملاً واضح مشهود است که انسان‌ها اشیاء، الگوها و مفاهیم را بدون نظارت خاصی یاد می‌گیرند. به تعبیری، یادگیری ما کاملاً بدون نظارت است. اما هنوز یادگیری بدون ناظر به اندازه‌ی یادگیری با ناظر محل توجه نبوده است. شاید دلیل آن به دشوار بودن حل مسائل به این روش و نتایج نامطلوب آن بازگردد (Al-Tamimi et al., 2022).

در علوم مرتبط با فنوتیپ و فیزیولوژی گیاهان زراعی، الگوریتم‌های یادگیری ماشین بسیار مهم هستند و تنها بر اساس داده‌های عددی کار می‌کنند. داده‌هایی که از بینایی کامپیوتر برای پردازش تصویر حاصل از انواع سنسور ذکر شده بدست آمده‌اند. هرچه اطلاعات تصویر بیشتر باشد حجم داده‌های پردازش شده توسط یادگیری ماشین بیشتر و دقت الگوریتم‌ها بالاتر خواهد بود. به عبارت دیگر، سنسورهای چندطیفی و فراطیفی بر تصاویر RGB و سایر سنسورها، برتری و یادگیری ماشین قدرت بیش‌تری در پردازش‌های تصاویر چندطیفی و فراطیفی به‌ویژه در شرایط تنش‌های محیطی (به عنوان مثال با برآورد شاخص NDVI) دارد. اگرچه استفاده از یادگیری ماشین برای داده‌های طیفی و آنالیز آنها نیازمند پیش‌پردازش‌های داده‌ها دارد که این امر به کمک الگوریتم‌های با کارایی بسیار بالایی میسر است. لازم به ذکر است که داده‌های حاصل از برداشت‌های زمینی مانند زیست‌توده، داده‌های هواشناسی و محیطی و پارامترهای گیاهی مانند محتوی کلروفیل برای ارزیابی مدل بسیار ضروری هستند (Al-Tamimi et al., 2022). بسته به نوع آزمایش و کاربرد نوع خاصی از سنسورهای تصویر، الگوریتم‌های یادگیری ماشین متفاوتی ارائه شده است. به عنوان مثال، اگر پژوهشگر نیازمند دسته‌بندی تصاویر برای مقایسه تیمار تنش با شاهد باشد، می‌تواند از الگوریتم‌های متفاوتی مانند ماشین بردار پشتیبان یا همان SVM⁵⁴ و الگوریتم شبکه عصبی پس انتشار (BPNN)⁵⁵ انتشار رو به عقب خطاها که به اختصار "پس انتشار" نامیده می‌شود و الگوریتمی برای یادگیری نظارتی شبکه عصبی با استفاده از گرادینان کاهش است) که از الگوریتم‌های قدیمی بینایی ماشین هستند (Patrício et al., 2018) استفاده کرد. در پژوهشی، این الگوی استفاده در پردازش تصاویر فراطیفی تغییرات زیست‌توده جو را در تنش خشکی برآورد کردند (Schmitter et al., 2017).

اگر پژوهشگر تمایل به پیش‌بینی رفتار گیاه تحت تنش داشته باشد، از الگوریتم‌هایی مانند شبکه عصبی مصنوعی می‌تواند استفاده کند.

یادگیری عمیق (DL)⁵⁶ و الگوریتم‌های پرکاربرد در پردازش تصویر

اگرچه زبان یادگیری ماشین بسیار قدرتمند است اما کارایی الگوریتم‌های آن زمانی که داده‌ها از پیچیدگی بالایی برخوردار

⁵⁴ Support Vector Machin

⁵⁵ back-propagation neural network

⁵⁶ Deep Learning

باشند، کاهش می‌یابد. در مطالعات فنوتیپی توان بالا زمانی که از سنسورهای فراطیفی برای تصویر برداری استفاده می‌شود، حجم قابل توجهی از داده‌ها به‌ویژه در سری‌های زمانی تصویر برداری منجر به ایجاد بانک داده عظیمی می‌شود. در این شرایط پیشنهاد شده است که از تکنیک یادگیری عمیق استفاده شود (Wang and sou, 2022).

جدول ۴: کاربرد یادگیری ماشین و زیرشاخه‌های آن تحت ۴ عملکرد اصلی ICQP در تنش‌های محیطی زنده و غیر

زنده				
تکنیک	الگوریتم	نوع کاربرد	گیاه	نوع تنش مورد استفاده
یادگیری عمیق (تصویر)	(CNN), AlexNet, GoogLeNet, and Inception V3	شناسایی	ذرت	تنش آبی
یادگیری ماشین بدون نظارت	Least squares discriminant analysis (PLS-DA) and least-squares support vector machine (LS-SVM)	شناسایی	تنباکو	تنش فلزات سنگین و جیوه
یادگیری عمیق (تصویر)	CNN	شناسایی	برنج	تنش زیستی
یادگیری ماشین بدون نظارت (ویدئو)	Hidden Markov models (HMMs)	شناسایی و دسته‌بندی	لوبیا	تنش خشکی، عناصر غذایی و شیمیایی
یادگیری عمیق (تصویر)	CNN	شناسایی و کمی‌سازی	قهوه	تنش زیستی پوسیدگی و لکه قهوه‌ای برگ
یادگیری ماشین با نظارت، مولفه‌های اصلی	K-nearest neighbors (KNN)	شناسایی و دسته‌بندی	برنج	تنش شوری
یادگیری ماشین با نظارت	ReliefF, support vector machine (SVM), recursive feature elimination (RFE), and random forest (RF)	شناسایی و دسته‌بندی	گندم	تنش شوری
یادگیری عمیق	RF, SVM, multilayer perceptron (MLP)	شناسایی و دسته‌بندی	علف هرز بروموس	تنش خشکی
یادگیری ماشین با نظارت	SVM	شناسایی و دسته‌بندی	برگ بادمجان	تنش زیستی
یادگیری ماشین با نظارت	RF, SVM, KNN	دسته‌بندی و پیش‌بینی	ریحان، قهوه، نخود و ذرت	تنش بیماری فوزاریوم و لکه قهوه‌ای، کمبود پتاسیم و خسارت علف کش
یادگیری ماشین با نظارت	RF, artificial neural networks	دسته‌بندی	ذرت	تنش آبی
یادگیری ماشین با نظارت	(ANN), and Confident multiple-choice learning	دسته‌بندی و پیش‌بینی	<i>Arabidopsis thaliana</i>	تنش آبی
یادگیری عمیق (تصویر)	CNN	دسته‌بندی	سورگوم	تنش گرما، سرما، شوری و خشکی
یادگیری ماشین با نظارت	Decision tree (DT), SVM, and Naïve Bayes (NB)	دسته‌بندی	<i>Arabidopsis thaliana</i>	تنش متابولیک
یادگیری ماشین با نظارت	Hierarchical models	دسته‌بندی	سویا	تنش کمبود آهن
یادگیری ماشین با نظارت	ANN, CNN, optimum-path forest, KNN, and SVM	دسته‌بندی	سویا	تنش سرما و اسمزی در شرایط کمبود نور
یادگیری ماشین با نظارت	RF	دسته‌بندی	گندم	تنش آبی
یادگیری عمیق (تصویر)	CNN, SVM	دسته‌بندی	سویا	تنش‌های زیستی (بیماری‌های قارچی و باکتریایی) و غیرزیستی (کمبود عناصر غذایی و خسارت شیمیایی)
یادگیری ماشین نظارت شده	MLP and probabilistic neural network (PNN)	دسته‌بندی	ذرت و گندم	تنش خشکی
یادگیری ماشین نظارت شده	Decision tree (DT), SVM, and NB	پیش‌بینی	آرابیدوپسیس	تنش‌های خشکی، شوری، سرما و گرما
یادگیری ماشین نظارت شده	Ridge regression, LASSO, elastic net, RF, reproducing kernel Hilbert space, Bayes A and Bayes B	پیش‌بینی	ذرت	تنش خشکی
یادگیری ماشین با نظارت	SVM	دسته‌بندی	چغندر قند	تنش خشکی و کمبود نیتروژن در شرایط هجوم علف‌هرز
یادگیری عمیق	CNN	پیش‌بینی	ذرت و گندم	تنش‌های محیطی
یادگیری ماشین نظارت شده	Genomic random regression	پیش‌بینی	گندم	تنش‌های محیطی

در واقع یادگیری عمیق شاخه‌ای از الگوریتم‌های زبان یادگیری ماشین است که دارای لایه‌های چندگانه است که می‌تواند برای استخراج عوارض (صفات) بیشماری از بانک داده‌ها استفاده شود. این الگوریتم به خوبی می‌تواند از سه طریق: ۱. دسته

بندی (Ghosh *et al.*,)، ۲. قطعه بندی (Bauer *et al.*, 2019; Barbedo *et al.*, 2019; Ferentinos *et al.*, 2018)، ۳. تشخیص اشیاء (Baht *et al.*, 2019) در بررسی رفتار گیاهان تحت تنش و مطالعه فیزیولوژیک آن‌ها مورد استفاده قرار گیرد (جدول ۵ مهم‌ترین الگوریتم‌های یادگیری عمیق در هر یک از ۳ زمینه کاربردی ذکر شده) (Wang and Sou, 2022). یادگیری عمیق کاربردهای بسیار موفقی در مطالعات فنوتیپی گیاهان در زمینه‌های پیش‌بینی عملکرد اقتصادی، کنترل علف‌هرز و شناسایی تنش‌های محیطی داشته است. در زمینه تشخیص تنش‌های محیطی در گیاهان زراعی نیز به کمک تکنیک‌های متعددی از جمله پردازش تصویر، معمولاً از الگوریتم‌های دسته بندی، قطعه بندی و تشخیص اشیاء استفاده می‌شود (جدول ۵). به عنوان مثال، Fang و همکاران (۲۰۲۲) از یادگیری عمیق برای بهبود قطعه‌بندی تصاویر فراطیفی و پیش‌بینی رشد بامیه در شرایط تنش شوری استفاده کردند.

یکی از محبوب‌ترین و پرکاربردترین زیر شاخه‌های یادگیری عمیق برای دسته‌بندی، استفاده از انواع الگوریتم‌های شبکه عصبی است (Wang and Sou, 2022). تحقیقات زیادی در زمینه استفاده از الگوریتم شبکه‌های عصبی در تخمین پارامترهای فیزیولوژیک و فنوتیپی به عنوان مثال محتوی نیتروژن و کلروفیل برگ از طریق پردازش رنگ و سائز پیکسل‌ها صورت گرفته است (Noah *et al.*, 2006; Lio *et al.*, 2017). Pattanayak و Gupta (۲۰۱۷) با استفاده از شبکه عصبی مصنوعی با استفاده از مقدار عدد اسپد و باندهای قرمز، سبز و آبی با کمک پردازش تصویر، موفق به برآورد بسیار مناسبی از محتوی کلروفیل برگ سیب زمینی شدند. در سال‌های اخیر، استفاده از الگوریتم شبکه عصبی پیچشی (CNN) نسبت به الگوریتم‌های قدیمی مانند الگوریتم SVM در زبان یادگیری ماشین، در علوم کشاورزی مورد توجه ویژه قرار گرفته است. برای چهار گیاه پر مصرف در جهان (گندم، ذرت، برنج و سویا) از بینایی ماشین با مدل‌سازی به کمک الگوریتم CNN، اقدام به تشخیص و ارزیابی اندام‌های گیاه، تداخل علف‌های هرز، بیماری‌های گیاهی، تنش‌های غیرزیستی و شناسایی ارقام دانه‌ای نموده و بسیار مورد توجه متخصصین اصلاح نباتات (به دلیل تاثیر قابل توجه این تکنیک بر تولید گیاهان دانه‌ای)، قرار گرفته است (Wang and Sou, 2022). پیشرفت‌های حاصل شده در بینایی کامپیوتری (CV)، با ظهور یادگیری عمیق (DL) در طول زمان ایجاد شده و در درجه اول بر مبنای الگوریتم خاصی شبکه عصبی پیچشی (CNN) بوده‌اند. CNN الگوریتمی است که تصویر ورودی را دریافت و به هر یک از اجزا تصویر میزان اهمیت (وزن‌های قابل‌یادگیری) اختصاص داده و قادر به تفکیک آن‌ها است. در این الگوریتم نسبت به الگوریتم‌های دیگر حجم پیش‌پردازش‌ها کاهش یافته است. در حالی‌که مشخصات تصویر در روش‌های اولیه به صورت دستی، مهندسی شده‌اند؛ الگوریتم‌های CNN با آموزش دیدن بسیار، فراگیری بیش‌تر این مشخصات را به‌دست آورده است (Al-Sobeidi *et al.*, 2021).

جدول ۵: استفاده از الگوریتم CNN در مطالعات فیزیولوژیک گیاهی در تنش زیستی

دقت و صحت مدل (درصد)	الگوریتم و مدل استفاده شده	نوع تصویر	نوع صفت مورد بررسی	گیاه مورد بررسی	نوع فعالیت یادگیری عمیق
۹۴	CNN	RGB	دسته‌بندی بیماری بلاست برگ	برنج	دسته‌بندی تصویر
۹۵.۶۷	InceptionResNetV2	RGB	بیماری لکه برگ برنج	برنج	
۸۹.۹	N-CNN	RGB	برگ سالم و برگ ناسالم	گندم	
۹۹.۰۲	CNN with BiLSTM	RGB	دسته‌بندی برگ سالم از ناسالم	ذرت	
۹۶.۲۵	DeepForest (gcForest)	RGB	دسته‌بندی برگ سالم از ناسالم	ذرت	
۹۸.۱۴	SoyNet	RGB	دسته‌بندی برگ سالم از ناسالم	سویا	
۹۸.۰۹ برای بلاست	Faster R-CNN with RPN	RGB	تشخیص نوع بیماری	برنج	تشخیص اشیاء
۹۶.۷ برای بلاست	Faster R-CNN with FCM-KM	RGB	تشخیص بیماری	برنج	
۹۶.۴ برای ویروس و ۶۵.۶۳ برای لکه باکتریایی	Multi-feature fusion Faster R-CNN	RGB	تشخیص بیماری	سویا	قطع‌بندی تصویر
۹۸	SimpleNet	RGB	قطع‌بندی نقاط زنگ زرد گندم	گندم	
۷۷.۷ برای بیماری در سنبله و ۹۸.۸ برای قطع‌بندی سطح بیماری	Mask-RCNN	RGB	بررسی فیزیولوژیک مقاومت به فوزاریوم	گندم	
۹۵.۳۳	CNN	RGB	قطع‌بندی بخش‌های خاکستری برگ ذرت	ذرت	دسته‌بندی تصویر
۵۷۹۰	ResNet-50+SVM	RGB	پیش‌بینی کمبود نیتروژن	برنج	
۱۵۰۰	Densenet-121	RGB	دسته‌بندی کمبود عناصر غذایی و کمبود نیتروژن	برنج	
۱۱۵۶	ResNet-50	RGB	کمبود عناصر غذایی	برنج	
۱۸۰۴۰	CNN+SVM	RGB	ارزیابی تنش آبی و تشخیص آن	ذرت	
۱۱۲۸۰	InceptionV3	RGB	شناسایی تعداد برگ آلوده با لارو	ذرت	
۱۰۰۰۰	ResNet-50	RGB	دسته‌بندی و شمارش تعداد آفات	سویا	دسته‌بندی تصویر
۳۰۶۳	NemaNet	RGB	شناسایی نماتدها	سویا	
۵۱۹,۷۵۲	ResNet-50 with RPN	RGB	مکان یابی آفات	گندم	تشخیص اشیاء
۱۵۰۰۰	Faster R-CNN with RPN	RGB	شناسایی آفات	ذرت	
۳۷۱۰	YOLO V3, V4 and V5	RGB	شناسایی آفات	سویا	
۷۲.۵	YoLoV3-tiny	RGB	شناسایی گونه علف‌های هرز	گندم	
۹۹.۴۴	CNN-LVQ	RGB	شناسایی گونه علف‌های هرز	سویا	دسته‌بندی تصویر
۹۷.۲۵	DRCNN	RGB	دسته‌بندی علف‌های هرز	سویا	
۸۸.۵۴	ResNet-18	RGB	تشخیص ردیف‌های کشت نشاء برنج	برنج	تشخیص اشیاء
۸۹.۸	Faster R-CNN	RGB	مکان یابی نشاء	برنج	
۹۷.۷۱	Faster R-CNN (VGC19)	RGB	تشخیص گیاهچه	ذرت	
۹۹.۸	Faster R-CNN	RGB	تشخیص گیاه زراعی و علف هرز	ذرت	
۹۶.۴۸	MTS-CNN	RGB	قطع‌بندی بین علف هرز و نشاء برنج	برنج	
۹۴.۷	Mask R-CNN (ResNet50/101-FPN)	RGB	تمایز گیاهچه ذرت از سایر گیاهان	ذرت	
۹۵.۴۹ و ۹۵.۶۸	DenseNet, MobileNet	RGB	شناسایی ارقام	گندم	دسته‌بندی
۹۲.۰۷	ResNet-50,SE-ResNet,SE-ResNeXt	RGB	شناسایی ارقام	گندم	
۹۹.۷	P-ResNet	RGB	دسته‌بندی بذور ذرت	ذرت	تشخیص اشیاء
۹۹.۴	Faster R-CNN with RPN	RGB	شمارش تعداد دانه در خوشه	برنج	
۹۸.۶	RetinaNet with FPN	RGB	تشخیص سنبله	گندم	
۹۴.۵	YOLOv4 with dual SPP	RGB	تشخیص سنبله	گندم	
۸۸.۹۷	(TasselNet, ResNet34)	RGB	شمارش گل‌آذین نر (تاسل)	ذرت	
MAE=13.21, MSE=17.6	TCNN	RGB	شمارش بذر	سویا	
MAE=0.6	VGG-Two	RGB	شمارش بذر	سویا	قطع‌بندی تصویر
MSE=0.6	VGG-16	RGB	دسته‌بندی ارقام	ذرت	
۹۸.۱	TasseINetv2	RGB	شمارش تعداد سنبله	گندم	
۹۱.۰۱	VGG	RGB	کمی‌سازی تعداد سنبله	گندم	
۹۰.۴۸	VGG-16	RGB	شمارش تعداد دانه ذرت	ذرت	
۱۰۰ برای طول، ۹۹ برای قطر	Mask R-CNN	RGB	ارزیابی هندسی بلال	ذرت	
۹۵.۶۹۲, ۵۶.۴۷	CK-CNN, ResNet50, Mask R-CNN,	RGB	قطع‌بندی بذور ارقام	ذرت	قطع‌بندی تصویر
MAP=95.7	ResNet-101 with FPN	RGB	ارزیابی فنوتیپی	سویا	

این الگوریتم شبیه با الگوی ارسال و دریافت پیام نورون‌ها در مغز انسان است و از ساختار قشر بصری مغز انسان الگوبرداری شده است (Lio *et al.*, 2021). از سال ۲۰۱۲، الگوریتم‌های CNN برای حل مسائل مرتبط با بینایی کامپیوتر با کارایی بسیار بالاتر از الگوریتم‌های قدیمی زبان یادگیری ماشین طراحی و اجرا شدند (Diba *et al.*, 2017). الگوریتم CNN می‌تواند در تشخیص و کمی‌سازی استرس‌های برگ گیاهان تحت تنش در سری‌های زمانی مختلف به درستی و با کارایی بالا کاربرد داشته باشد. مجموعه‌ای از پرکاربردترین الگوریتم‌های CNN در جدول ۵ ذکر شده است و استفاده از آن‌ها توسط فیزیولوژیست‌های گیاهی و محققان اصلاح نباتات جهت مطالعات فنوتیپی و فیزیولوژیک گیاهان زراعی (برای افزایش کارایی تولید و عملکرد به‌ویژه در شرایط تنش و تامین امنیت غذایی بشر) در حال افزایش است (Wang and Sou, 2022). در نهایت ذکر این نکته لازم است که کارهای بسیاری انجام شده است تا عملکرد گیاهان زراعی استراتژیک مانند برنج، گندم، ذرت و ... از طریق مطالعات فنوتیپی و فیزیولوژیک بهبود یابد. توانایی به‌دست آوردن و جمع‌آوری داده از منابع تصویر مختلف (از جمله تصاویر چندطیفی، فراطیفی و RGB و سایر سنسورها) به کمک تکنیک‌های هوش مصنوعی در جوامع گیاهی تحت تنش‌های محیطی، این امکان را همواره فراهم کرده است که به صورت لحظه‌ای و به سرعت با بررسی‌های فیزیولوژیک و فنوتیپی به تشخیص تنش پی‌برد. اگرچه با پیشرفت توسعه و تولید سنسورهای پیشرفته در کنار تکنولوژی‌ها تصویر موجود، هنوز هم نیازمند پژوهش بیشتر و ساخت و کاربرد الگوریتم‌های پرکاربرد همچون CNN در کنار بینایی ماشین بوده تا کارایی آن‌ها افزایش یابد.

نتیجه‌گیری

یادگیری عمیق با وجود چالش‌های زیادی که در مسیر آن وجود دارد، تا کنون به خوبی در شناسایی تنش‌های گیاهی (زیستی و غیرزیستی) موفق بوده است. اغلب مقالاتی که تا کنون در زمینه کاربرد یادگیری عمیق و پردازش تصویر مرتبط با گیاهان بوده است، از تصاویر دو بعدی (به عنوان مثال تصاویر خاکستری و تصاویر دیجیتال) استفاده کرده‌اند. چراکه بسیاری از الگوریتم‌ها قادر به آموزش تصاویر سه بعدی مانند تصاویر فراطیفی نیستند. بنابراین در آینده نزدیک باید از شبکه‌های عصبی که قادر به استفاده از این تصاویر سه بعدی هستند، در شناسایی سریع تغییرات فیزیولوژیک ناشی از تنش‌ها، بویژه تنش‌های بدون بازگشت، بیشتر مورد استفاده قرار گیرند. در حال حاضر با وجود توسعه تکنولوژی‌های جدید تصویر، اغلب از الگوریتم‌های نظارت شده استفاده می‌شود. از این‌رو، محققان در تلاش هستند که با وجود دشواری ساخت الگوریتم‌های بدون نظارت (به دلیل اهمیت آن‌ها و مزایای بیش‌تر آن‌ها)، شبکه‌های دقیق‌تر و کاربردی‌تر در اندازه‌گیری پارامترهای فیزیولوژیک و فنوتیپی گیاهان زراعی ارائه دهند. در مجموع، یادگیری عمیق در کنار پردازش تصویر می‌تواند با

ارائه نتایج درستی از شناسایی و پیش‌بینی تنش‌های زیستی و غیرزیستی، به پایداری عملکرد در گیاهان و هوشمندسازی کشاورزی منجر شود.

منابع

Abdel-Rahman, E.M., Ahmed, F.B., Ismail, R. 2013. Random Forest regression and spectral band selection for estimating sugarcane leaf nitrogen concentration using EO-1 Hyperion hyperspectral data. *Int. J. Remote Sens*, 34, 712–728.

Abràmoff, MD., Magalhães, PJ., Ram, SJ. 2004. Image processing with ImageJ. *Biophotonics Int.* 11, 36–42.

Ahsan, M, Eshkabilov, S., Cemek, B., Küçüktopcu, E., Lee, C.W., Simsek, H. 2021. Deep Learning Models to Determine Nutrient Concentration in Hydroponically Grown Lettuce Cultivars (*Lactuca sativa* L.). *Sustainability*, 14, 416.

Al-Tamimi, N., Brien, C., Oakey, H., Berger, B., Saade, S., Ho. YS., Schmockel, SM., Tester, M., Negrao, S. 2016. Salinity tolerance loci revealed in rice using highthroughput non-invasive phenotyping. *Nat. Commun.* 7, 13342.

Al-Tamimi, N., Langan, P., Bernád, V., Walsh, J., Mangina, E., Negrão, S. 2022. Capturing crop adaptation to abiotic stress using image-based technologies. *Open Biol.* 12: 210353.

Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaria, J., Fadhel, M. A., Al-Amidie, M., Farhan, L. 2021. Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *J. Big Data*, 8- 53.

Atkinson, JA., Pound, MP., Bennett, MJ., Wells, DM. 2019. Uncovering the hidden half of plants using new advances in root phenotyping. *Curr. Opin. Biotechnol.* 55, 1–8.

Awlia, M. 2016. High-throughput nondestructive phenotyping of traits that contribute to salinity tolerance in *Arabidopsis thaliana*. *Front. Plant Sci.* 7, 1414.

Bah, M. D. et al. 2018. Deep learning with unsupervised data labeling for weed detection in line crops in UAV images. *Remote Sens.* 10, 1690 38.

Bailey-Serres, J., Lee. SC., Brinton, E. 2012. Waterproofing crops: effective flooding survival strategies. *Plant Physiol.* 160, 1698–1709.

Barbedo., J. G. A. 2019. Plant disease identification from individual lesions and spots using deep learning. *Biosyst. Eng.*, 180, 96–107.

Bauer, A., Bostrom, A.G., Ball, J., Applegate, C., Cheng, T., Laycock, S., Zhou, J. 2019. Combining computer vision and deep learning to enable ultra-scale aerial phenotyping and precision agriculture: A case study of lettuce production. *Hortic. Res.* 2019, 6, 1–12.

Bhatt, P., Sarangi, S., Pappula, S. 2019. Detection of diseases and pests on images captured in uncontrolled conditions from tea plantations. In *Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping IV*, Thomasson, J.A., McKee, M., Moorhead, R.J., Eds., SPIE: Bellingham, WA, USA, p. 33.

Campbell, MT., Knecht, AC., Berger, B., Brien, CJ., Wang, D., Walia, H. 2015. Integrating image-based phenomics and association analysis to dissect the genetic architecture of temporal salinity responses in rice. *Plant Physiol.* 168, 1476–1489.

Condorelli, GE., Maccaferri, M., Newcomb, M., AndradeSanchez, P., White, JW., French, AN., Sciara, G., Ward, R., Tuberosa, R. 2018. Comparative aerial and ground based high throughput phenotyping for the genetic dissection of NDVI as a proxy for drought adaptive traits in durum wheat. *Front. Plant Sci.* 9, 893.

Das Choudhury, S., Samal, A., Awada, T. 2019. Leveraging image analysis for high-throughput plant phenotyping. *Front. Plant Sci.* 10, 508.

Dhondt, S., Wuyts, N., Inze, D. 2013. Cell to wholeplant phenotyping: the best is yet to come. *Trends Plant Sci* 18, 428–439.

Diba, A., Sharma, V., Pazandeh, A., Pirsivash, H., van Gool, L. 2017. Weakly supervised cascaded convolutional networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition 2017, Honolulu, HI, USA, 21–26 July 2017*, pp. 914–922.

El-Hendawy, S.E., Al-Suhaibani, N.A., Elsayed, S., Hassan, W.M., Dewir, Y.H., Refay, Y., Abdella, K.A. 2019. Potential of the existing and novel spectral reflectance indices for estimating the leaf water status and grain yield of spring wheat exposed to different irrigation rates. *Agric. Water Manag.*, 217, 356–373. [CrossRef

Fahlgren, N. 2015. A versatile phenotyping system and analytics platform reveals diverse temporal responses to water availability in *Setaria*. *Mol. Plant* 8, 1520–1535.

Fahlgren, N., Gehan, MA., Baxter, I. 2015. Lights, camera, action: high-throughput plant phenotyping is ready for a close-up. *Curr. Opin. Plant Biol.* 24, 93–99.

Farooq, M., Wahid, A., Kobayashi, N., Fujita, D., Basra, S. 2009. Plant drought stress: effects, mechanisms and management. In *Sustainable agriculture* (eds E Lichtfouse, M Navarrete, P Debaeke, V Souchere, C Alberola), pp. 153–188. Berlin, Germany: Springer.

Feng, X., et al. 2020. Hyperspectral imaging combined with machine learning as a tool to obtain highthroughput plant salt-stress phenotyping. *Plant J.* 101, 1448–1461.

Ferentinos, K.P. 2018. Deep learning models for plant disease detection and diagnosis. *Comput. Electron. Agric.*, 145, 311–318.

Garbout, A., Munkholm, L.J., Hansen, SB., Petersen, BM., Munk, OL., Pajor, R. 2012. The use of PET/CT scanning technique for 3D visualization and quantification of real-time soil/plant interactions. *Plant Soil* 352, 113–127.

Gehan, MA. 2017. PlantCV v2: image analysis software for high-throughput plant phenotyping. *PeerJ* 5, e4088.

Gerhards, M., Schlerf, M., Mallick, K., Udelhoven, T. 2019. Challenges and future perspectives of multi-/Hyperspectral thermal infrared remote sensing for crop water-stress detection: A review. *Remote Sens.* 11, 1240.

Ghori, N-H., Ghori, T., Hayat, M., Imadi, S., Gul, A., Altay, V., Ozturk, M. 2019. Heavy metal stress and responses in plants. *Int. J. Environ. Sci. Technol.* 16, 1807–1828.

Ghosh, P., Mitchell, M., Tanyi, J.A., Hung, A.Y. 2016. Incorporating priors for medical image segmentation using a genetic algorithm. *Neurocomputing* 2016, 195, 181–194.

Golzarian, MR., Frick, RA., Rajendran, K., Berger, B., Roy, S., Tester, M., Lun, DS. 2011. Accurate inference of shoot biomass from high-throughput images of cereal plants. *Plant Methods* 7, 2.

Guo, Y., Yin, G., Sun, H., Wang, H., Chen, S., Senthilnath, J., Wang, J., Fu, Y. 2020. Scaling effects on chlorophyll content estimations with RGB camera mounted on a UAV platform using machine-learning methods. *Sensors*, 20, 5130.

Gupta, S. D., Pattanayak, A. K. 2017. Intelligent Image Analysis (iia) Using Artificial Neural Network (ann) for Non-invasive Estimation of Chlorophyll Content in Micropropagated Plants of Potato. *In Vitro Cell.r Develop. Bio. Plant.*, 14, 1–7.

Han, L., Yang, G., Dai, H., Xu, B., Yang, H., Feng, H., Li, Z., Yang, X. 2019. Modeling maize above-ground biomass based on machine learning approaches using UAV remote-sensing data. *Plant Methods*, 15, 10.

- Hassani-jalilian, O., Igathinathane, C., Doetkott, C., Bajwa, S., Nowatzki, J., Esmaili, S.A.H. 2020.** Chlorophyll estimation in soybean leaves infield with smartphone digital imaging and machine learning. *Comput. Electron. Agric.*, 174, 105433.
- Humplík, JF., Lazár, D., Husičková, A., Spíchal, L. 2015.** Automated phenotyping of plant shoots using imaging methods for analysis of plant stress responses—a review. *Plant Methods* 11, 29.
- Isayenkov, S., Hilo, A., Rizzo, P., Tandron Moya, YA., Rolletschek, H., Borisjuk, L., Radchuk, V. 2020.** Adaptation strategies of halophytic barley *Hordeum marinum* ssp. *Marinum* to high salinity and osmotic stress. *Int. J. Mol. Sci.* 21, 9019.
- Jackman, P., Sun, D-W., Du, C-J., Allen, P. 2009.** Prediction of beef eating qualities from colour, marbling and wavelet surface texture features using homogenous carcass treatment. *Pattern Recognition* 42: 751–763. 30.
- Jackman, P., Sun, D-W., Du, CJ., Allen, P., Downey, G. 2008.** Prediction of beef eating quality from colour, marbling and wavelet texture features. *Meat Science* 80: 1273–1281. 29.
- Jin, S. 2021.** Lidar sheds new light on plant phenomics for plant breeding and management: Recent advances and future prospects. *ISPRS J. Photogramm. Remote Sens.* 171, 202–223.
- Karnieli, A., Agam, N., Pinker, RT., Anderson, M., Imhoff, ML., Gutman, GG., Panov, N., Goldberg, A. 2010.** Use of NDVI and land surface temperature for drought assessment: merits and limitations. *J. Clim.* 23, 618–633.
- Koza, J.R., Bennett, F.H., Andre, D., Keane, M.A. 1996.** Automated design of both the topology and sizing of analog electrical circuits using genetic programming. In *Artificial Intelligence in Design'96*, Springer: Dordrecht, The Netherlands, , pp. 151–170.
- Lazarević, B., Šatović, Z., Nimac, A., Vidak, M., Gunjača, J., Politeo, O., Carović-Stanko, K. 2021.** Application of phenotyping methods in detection of drought and salinity stress in basil (*Ocimum basilicum* L.). *Front. Plant Sci.* 12, 174.
- Li, L., Zhang, Q., Huang, D. 2014.** A review of imaging techniques for plant phenotyping. *Sensors* 14, 20 078–20 111.
- Liang, L., Di, L., Huang, T., Wang, J., Lin, L., Wang, L., Yang, M. 2018.** Estimation of leaf nitrogen content in wheat using new hyperspectral indices and a random forest regression algorithm. *Remote Sens.*, 10, 1940.
- Liu, J., Wang, X. 2021.** Plant diseases and pests detection based on deep learning: A review. *Plant Methods*, 17, 22.
- Liu, P., Shi, R., Zhang, C., Zeng, Y., Wang, J., Tao, Z., Gao, W. 2017.** Integrating Multiple Vegetation Indices via an Artificial Neural Network Model for Estimating the Leaf Chlorophyll Content of *Spartina Alterniflora* under Interspecies Competition. *Environ. Monitor. Assess.*, 189, 596.
- Ma, C. 2014.** Machine learning for big data analytics in plants. *Trends Plant Sci.* 19, 798–808.
- Mertens, S. 2021.** Proximal hyperspectral imaging detects diurnal and drought-induced changes in maize physiology. *Front. Plant Sci.* 12, 240.
- Mitchell, T.M. 1997.** *Machine Learning*, McGraw-Hill Higher Education 33.
- Mohd Asaari, MS., Mishra, P., Mertens, S., Dhondt, S., Inzé, D., Wuyts, N., Scheunders, P. 2018.** Close-range hyperspectral image analysis for the early detection of stress responses in individual plants in a high-throughput phenotyping platform. *ISPRS J. Photogramm. Remote Sens.* 138, 121–138.

Munns, R., James, R.A., Sirault, X.R., Furbank, R.T., Jones, H.G. 2010. New phenotyping methods for screening wheat and barley for beneficial responses to water deficit. *J. Exp. Bot.* 61, 3499–3507.

Negrão, S. and Julkowska, M. M. 2020. Plant Phenotyping. *eLS*, 1–14. Available at: <http://dx.doi.org/10.1002/9780470015902.a0028894>.

Negrão, S., Schmöckel, S., Tester, M. 2017. Evaluating physiological responses of plants to salinity stress. *Ann. Bot.* 119, 1–11.

Neilson, E.H., Edwards, A.M., Blomstedt, C.K., Berger, B., Moller, B.L., Gleadow, R.M. 2015. Utilization of a highthroughput shoot imaging system to examine the dynamic phenotypic responses of a C4 cereal crop plant to nitrogen and water deficiency over time. *J. Exp. Bot.* 66, 1817–1832.

Noh, H., Zhang, Q., Shin, B., Han, S., Feng, L. 2006. A Neural Network Model of Maize Crop Nitrogen Stress Assessment for A Multi-spectral Imaging Sensor. *Biosyst. Eng.*, 94, 477–485.

Osama, K., Mishra, B.N., Somvanshi, P. 2015. Machine Learning Techniques in Plant Biology. In *PlantOmics: The Omics of Plant Science*, Springer: Berlin/Heidelberg, Germany, pp. 731–754

Pan, Y.H. 2015. Analysis of concepts and categories of plant phenome and phenomics. *Acta Agron. Sin.*, 41, 175–186.

Pardede, H. F. et al. 2018. Unsupervised convolutional autoencoder-based feature learning for automatic detection of plant diseases. In *2018 International Conference on Computer, Control, Informatics and its Applications (IC3INA)*, pp. 158–162, IEEE.

Patrício, D.I., Rieder, R. 2018. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. *Comput. Electron. Agric.* 153, 69–81.

Perez-Sanz, F., Navarro, P.J., Egea-Cortines, M. 2017. Plant phenomics: an overview of image acquisition technologies and image data analysis algorithms. *Gigascience* 6, gix092.

Pineda, M., Barón, M., Pérez-Bueno, M-L. 2021. Thermal imaging for plant stress detection and phenotyping. *Remote Sensing* 13, 68.

Rico-Chávez, A.K.; Franco, J.A.; Fernandez-Jaramillo, A.A.; Contreras-Medina, L.M.; Guevara-González, R.G.; Hernandez-Escobedo, Q. 2022. Machine Learning for Plant Stress Modeling: A Perspective towards Hormesis Management. *Plants*, 11, 970.

Schmidt, J., Claussen, J., Wörlein, N., Eggert, A., Fleury, D., Garnett, T., Gerth, S. 2020. Drought and heat stress tolerance screening in wheat using computed tomography. *Plant Methods* 16, 15.

Schmitter, P., Steinrücken, J., Römer, C., Ballvora, A., León, J., Rascher, U., Plümer, L. 2017. Unsupervised domain adaptation for early detection of drought stress in hyperspectral images. *ISPRS J. Photogramm. Remote Sens.* 131, 65–76.

Sims, D.A., Gamon, J. A. 2002. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sens. Environ.* 81, 337–354.

Singh, A., Ganapathysubramanian, B., Singh, A.K., Sarkar, S. 2016. Machine learning for high-throughput stress phenotyping in plants. *Trends Plant Sci* 21, 110–124.

Steensland, A., Thompson, T. L. 2020. Global Agricultural Productivity Report: Productivity in a Time of Pandemics. *Global Agricultural Productivity Report: Productivity in a Time of Pandemics*, College of Agriculture and Life Sciences: Blacksburg, VA, USA, 2020.

Tilman, D., Balzer, C., Hill, J., Befort, B.L. 2011. Global food demand and the sustainable intensification of agriculture. *Proc. Natl. Acad. Sci. USA*, 108, 20260–20264.

Uddling, J., Gelang-Alfredsson, J., Piikki, K., Pleijel, H. 2007. Evaluating the relationship between leaf chlorophyll concentration and SPAD-502 chlorophyll meter readings. *Photosynth. Res.* 91, 37–46.

Valous, NA., Mendoza, F., Sun, D-W., Allen, P. 2009. Colour calibration of a laboratory computer vision system for quality evaluation of pre-sliced hams. *Meat Science* 81: 132–141.

Van Harselaar, JK., Claußen, J., Lübeck, J., Wörlein, N., Uhlmann, N., Sonnewald, U., Gerth, S. 2021. X-ray CT phenotyping reveals bi-phasic growth phases of potato tubers exposed to combined abiotic stress. *Front. Plant Sci.* 12, 613108.

Wang, Y.-H., Su, W.-H. 2022. Convolutional Neural Networks in Computer Vision for Grain Crop Phenotyping: A Review. *Agronomy*, 12, 2659.

Zarco-Tejada, P.J., González-Dugo, V., Berni, J.A. 2012. Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. *Remote Sens. Environ.*, 117, 322–337.