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، ملاثانی، ایران.

*نویسنده مسئول: **adelposhtdar@gmail.com**

تاریخ دریافت:۱۴۰۱/۰۶/۰۲ **تاریخ پذیرش: ۱۴۰۱/۰۹/۰۱**

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 به‌دست 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 به‌طور 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.

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

مقدمه

امنیت غذایی جهانی یکی از مهم‌ترین چالش‌های مربوط به توسعه جوامع انسانی امروز است (Tilman *et al*., 2011). به‌طوری‌که 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 (Steensland 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 پاسخ های 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 نه چندان دور، روش‌های کلاسیک (مرسوم) مطالعات فنوتیپی، مطالعات ژنومیکس و روش‌های ژنوتیپی در یک جایگاه و سطح نبودند.

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

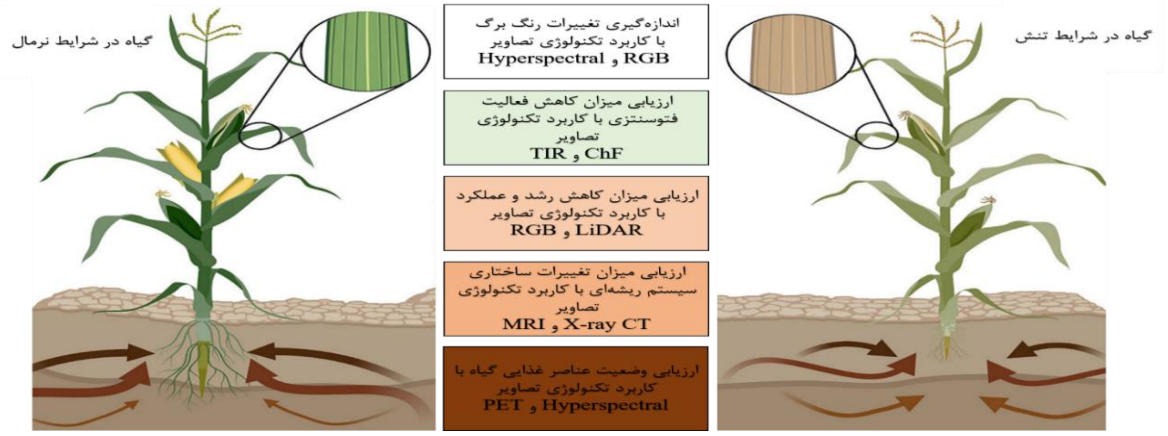

شکل ۱: مختصری از رفتارهای فیزیولوژیکی عمده گیاهان زراعی در پاسخ به تنش‌های غیرزنده (غیرزیستی) و تکنولوژی‌های تصویر متفاوت مورد استفاده برای کمی‌سازی پاسخ فیزیولوژیک گیاه در شرایط تنش. تصویر سمت چپ گیاه در شرایط نرمال و گیاه سمت راست گیاه مواجه با تنش غیرزنده است. تکنولوژی‌های تصویر مورد استفاده بسته به نوع کاربرد آن در وسط ذکر شده‌اند. RGB[1] (قرمز، سبز و آبی)، CHF[2] (فلورسنس کلروفیل)، TIR[3] (تصویر حرارتی مادون قرمز)، LiDAR[4] (آشکارساز و سنجنده نوری)، MRI[5] (تصویربرداری پرتوهای مغناطیسی)، CT[6] (اسکن توموگرامی کامپیوتری)، PET[7] (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، استاتیستیک و ژنومیکس در جهت بررسی رفتارهای گیاهی پیچیده (ناشی از بیان ژن‌ها) روی داد که برای دستیابی به امنیت غذایی در آینده ضروریست. به‌طوری‌که امروزه پردازش تصویر به کمک تکنولوژی بینایی ماشین[8] 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[9]) و نرم افزارهای ساخت و راه‌اندازی الگوریتم‌های پردازش تصویر مانند پایتون؛[10] متلب،[11] R و ...، که بخش هسته مرکزی بینایی کامپیوتر هستند، است (Wang *et al*., 2022). از طریق بینایی کامپیوتر روش‌هایی مانند روش فنوتیپی توان بالا[12] (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

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

را به‌صورت غیرتخریبی 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- مبنا 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 هرکدام مزایا و معایبی دارند. (شکل۲) 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 تصویربرداری هوایی (استفاده از ماهواره‌ها یا پهپادها) وضوح کم‌تر ولی سرعت حرکت و تصویربرداری بسیار بالاتر، سطح مزرعه بیش‌تری را پوشش می‌دهد. مزایا و معایب هر یک از روش‌ها در شکل ۲ ذکر شده است.

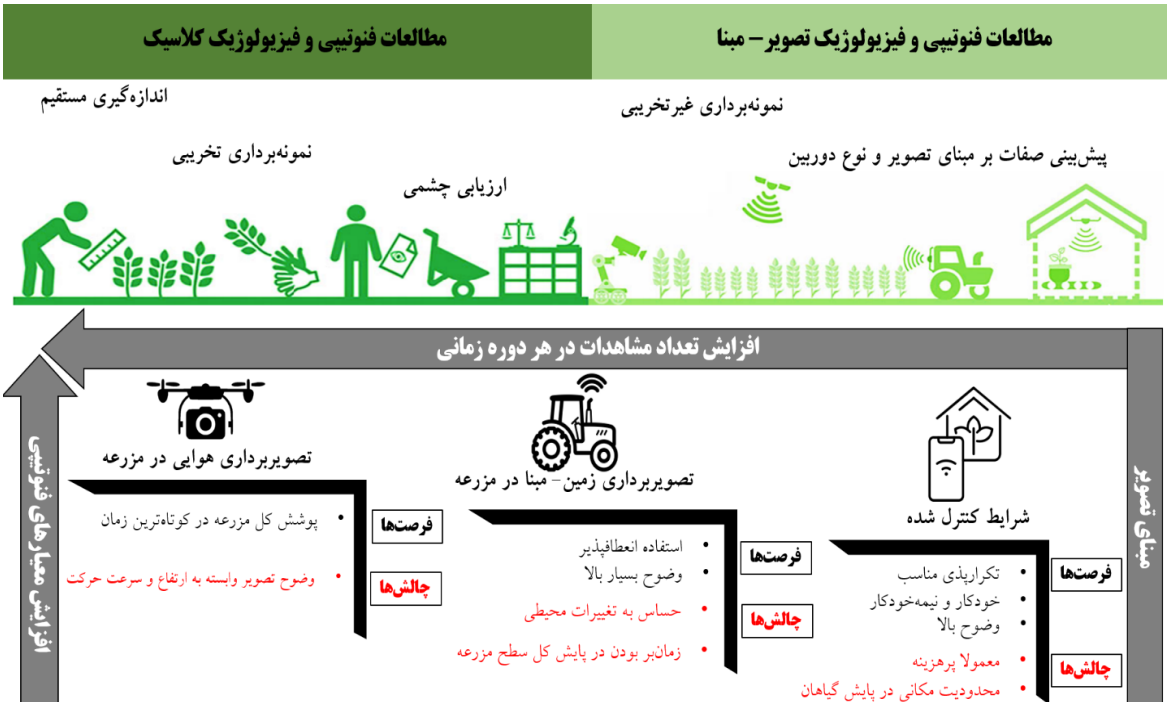

شکل ۲: مروری بر روش‌های مطالعه فنوتیپی و سیستم‌های توان بالا در مقیاس‌های متفاوت (Al- *et al*, 2022 (Tamimi

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

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

ریشه، مجموع ساقه و برگ و ... تقسیم‌بندی می‌شود. این روش‌ها امکان ارزابی 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 فیزیوژیک و بیوشمیایی 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 زمان بر 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 دقیق تر 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.

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

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 لاین ها سرو کار 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 مثلا 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 پهبادها هستند که پارامترهای بی‌شماری را ثبت می‌کنند. پژوهش‌ها نشان ادده 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 به عنوان 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 ارتقاع‌یافته کنونی در کنار نرم افزارهایی همانند Image J (Abramoph *et al*.,

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

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).

جدول۱: 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 سبزینگی (مانند NDVI و ...)	دامنه وسیع طول‌موجی، دریافت سگنال های تنش قبل از اینکه آثار تنش قابل مشاهده باشد.	حجم داده بسیارزیادی ایجاد می‌کند، نیاز به داده کاری و یادگیری عمیق برای بهبود تجزیه و تحلیل داده‌ها دارد.
Chlorophyll Fluorescence	فعالیت فتوسیستم ۲	تغییرات فلورسانس کلروفیل معمولا زودتر از سایر علائم تنش اتفاق می‌افتد بنابراین به سرعت می‌توان به وقوع تنش پی‌برد	برای استفاده نیازبه 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 ذخیر 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 اتفاق‌افتاده 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 دوربین های 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) (شکل_های ۳ و ۴)

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

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). به‌طورکلی نور جذبی توسط کلروفیل در گیاهان در سه مسیر استفاده می‌شود: ۱. واکنش های فتوشیمیایی، ۲. واکنش های غیرفتوشیمایی (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 ۲ (Fv/Fm) (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 روئیت 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 مستقیما 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 پرادزش 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، فلورسناس کلروفیل، انعکاس‌های فتوشیمایی و تصاویر دمای سطح برگ را برآورد و می‌توانند پاسخ‌های رفتاری رنگدانه‌های گیاه، فتوسنتز جاری، تعرق، باز

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

شدن روزنه‌ها، 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 سیب‌زمینی 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 کوتاه-عمر تزریق شده به سلول‌ها و میکروارگانیسم‌ها 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

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

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).

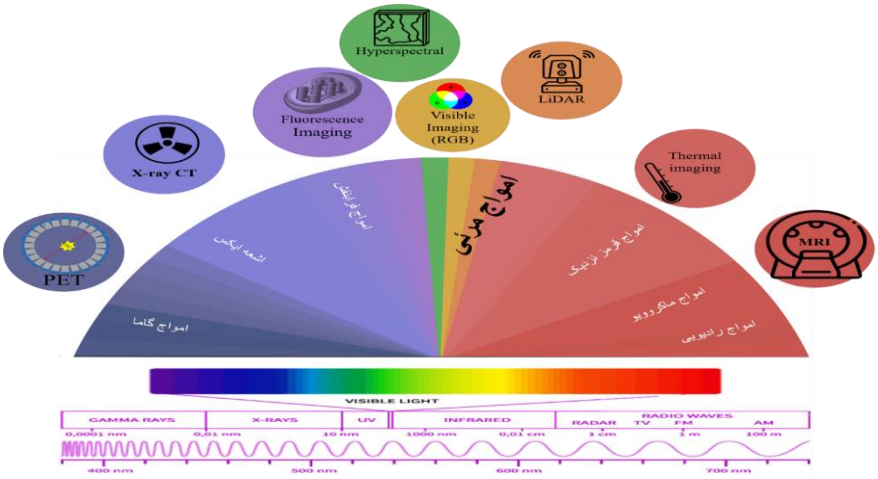

شکل ۳: طیف طول‌موجی در انواع سنسورها جهت ارزیابی ویژگی‌های فیزیولوژیک متناسب با ماهیت پردازنده و بازتاب دریافتی

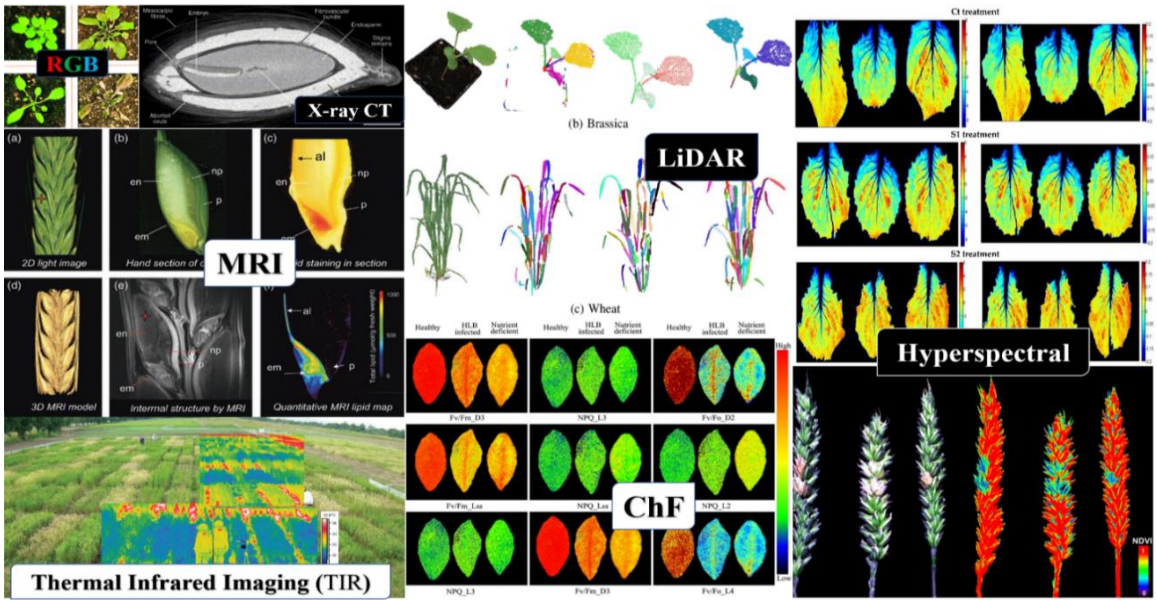

شکل ۴: نمونه هایی از کاربرد انواع سنسورهای تصویر در مطالعات فیزیولوژیک و فنوتیپی گیاهان زراعی در شرایط تنش‌های محیطی.

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

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 سهل والوصول 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[17] (VI)

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

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

. 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 تخریبی در صورت نیاز
سرما	کنترل‌شده	نخود	RGB-fluorescenc	وزن زیست‌توده، پارامترهای مرتبط با فلورسانس کلروفیل	-
سرما	مزرعه	ذرت	RGB- Multispectral	تشخیص، کمی‌سازی و دسته بندی تنش	-
خشکی	کنترل‌شده	جو	RGB	صفات و ماده خشک مرتبط با زیست‌توده و رشد	ماده خشک ساقه، تعداد پنجه و ارتفاع بوته
خشکی	کنترل‌شده	گندم	RGB	صفات مرتبط با زیست‌توده و رشد	-
خشکی	کنترل‌شده	برنج	RGB	صفات و ماده خشک مرتبط با زیست‌توده و رشد	ماده خشک ساقه، عملکرد و اجزاء عملکرد
خشکی	کنترل‌شده	جو سبز	RGB—fluorescence— near-infrared (NIR)	صفات مورفولوژیک، کارایی فتوسنتز، پارامترهای فتوسنتزی و محتوی آب سلول	-
خشکی	کنترل‌شده	جو	RGB	صفات و ماده خشک مرتبط با زیست‌توده و رشد	ماده خشک ساقه، تعداد پنجه و ارتفاع بوته
خشکی	کنترل‌شده	جو	RGB-fluorescenc	ارتفاع گیاه و پارامترهای فلورسانس کلروفیل	ماده خشک ساقه، محتوی رطوبت نسبی
خشکی	کنترل‌شده	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	کنترل‌شده	لتوس	RGB-fluorescenc	صفات و ماده خشک مرتبط با زیست‌توده و رشد، صفات مورفولوژیک ، پارامترهای فلورسانس کلروفیل	-
خشکی	کنترل‌شده	ذرت	hyperspectra	زاویه برگ و مساحت سطح برگ	-
خشکی	کنترل‌شده	ذرت	hyperspectra	شاخص‌های سبزینگی	-
خشکی	کنترل‌شده	جو	RGB	صفات مرتبط با زیست‌توده و رشد	ماده خشک ساقه
خشکی و کمبود نیتروژن	کنترل‌شده	سورگوم	RGB—near-infrared (NIR)	صفات مرتبط با رشد و زیست‌توده، زوال (درصد)، طیف قرمز نزدیک، پارامترهای تشکیل‌دهنده محتوی رطوبت نسبی	ماده خشک ساقه، سطح برگ، 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	کنترل‌شده	ذرت، سویا و لوبیا	hyperspectral	NDVI، محتوی رطوبت نسبی برگ، غلظت عناصر ماکرو	زیست‌توده کل، غلظت عناصر ماکرو
گرما	کنترل‌شده	ماش	fluorescence	پارامترهای فلورسانس کلروفیل	-
شوری	کنترل‌شده	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	کنترل‌شده	برنج	RGB—fluorescence	زیست‌توده، زوال ساقه‌چه (درصد)	ماده خشک ساقه، غلظت یون سدیم و پتاسیم برگ
شوری	کنترل‌شده	برنج	RGB—fluorescence	زیست‌توده، پارامترهای فلورسانس کلروفیل	غلظت یون سدیم و پتاسیم برگ
شوری	کنترل‌شده	برنج	RGB	صفات مرتبط با رشد و زیست‌توده	ماده خشک ساقه
شوری	کنترل‌شده	جو	RGB	روابط ریاضی مرتبط با منحنی های رشد گیاه	-
شوری	کنترل‌شده	گندم	RGB	صفات مرتبط با رشد و زیست‌توده	غلظت یون سدیم و پتاسیم برگ
شوری	کنترل‌شده	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	کنترل‌شده	گندم	hyperspectral	NDVI و شاخص‌های سبزینگی	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	کنترل‌شده	لتوس	fluorescence	پارامترهای فلورسانس کلروفیل	ماده خشک ساقه
شوری	کنترل‌شده	بامیه	hyperspectral	قطعه بندی گیاه و برگ	زیست‌توده کل، عدد اسپد، غلظت یون سدیم، نرخ فتوسنتز و تعرق
شوری	کنترل‌شده	گندم	hyperspectral	تشخیص تنش، شاخص‌های سبزینگی، 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	کنترل‌شده	گندم	RGB—hyperspectral	ماده خشک و صفات مرتبط با رشد و زیست‌توده، صفات مورفولوژیک و اناتومیک، شاخص‌های سبزینگی مرتبط با مقادیر کلروفیل	ماده خشک ساقه، عملکرد و اجزاء عملکرد، محتوی کلروفیل
کمبود نیتروژن	کنترل‌شده	سورگوم	RGB	ماده خشک و صفات مرتبط با رشد و زیست‌توده	-
کمبود نیتروژن	مزرعه	ذرت	hyperspectral	بازتاب های برگ	-
کمبود نیتروژن	مزرعه	یونجه	RGB—multispectral	NDVI، شاخص سطح برگ و پوشش سطح سبز	زیست‌توده، عملکرد و ارتفاع بوته
کمبود نیتروژن	مزرعه	ذرت	hyperspectral	NDVI	-

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

بیش‌ترین شاخص‌ها، شاخص‌های سبزینگی (**VI**) یا همان شاخص‌های سبزینگی طیفی[18](VIS) هستند (Abdel-Rahman *et al*., 2013; GO *et al*., 2020; Haan *et al*., 2019; Hassani-Jalilian *et al*., 2020). 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 طول‌موج های خاصی هستند. این شاخص‌ها، بصورت کمی و حاصل از بازتاب نور انعکاسی در محدوده طول‌موج های 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 شده اند، عبارتند از: ۱. NDVI و ۲. SR یا همان[19]RVI، که بیش‌ترین استفاده را دارند. مقدار SR در واقع نسبت بین نور انعکاسی در محدوده طول‌موجی قرمز نزدیک و طول‌موج 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 طول‌موج‌های قرمز نزدیک و قرمز برابر باشند، مقدار SR برابر با ۱ و یا نزدیک ۱ خواهد بود. مقدار SR برای خاک معمولا 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 طول‌موج 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). ۳.GNDVI[20] که از نسبت باندهای طول‌موجی 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 بخش های 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

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

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 داده‌کاوی 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[21] (ML[22]) 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[22]،دسته‌بندی[23]،کمی‌سازی[24] و پیش‌بینی[25]) 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 برچسب‌دار را در مسیر یادگیری و آزمون یک مدل انتخابی استفاده می‌کند (مثلا 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 برچسب‌دار ندارد و در عوض از تکنیک‌های کلاسترکردن داده‌ها در تفکیک عوارض استفاده می‌کند. در این روش، کاربر نیازی به نظارت بر مدل ندارد، درعوض خود مدل به‌تنهایی برای کشف الگوها و اطلاعاتی که در داده وجود دارد کار می‌کند. معمولا، 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

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

جدول۳: مهم‌ترین و پرکاربردترین شاخص‌های گیاهی مورد استفاده در پردازش تصویر مطالعات فیزیولوژیک گیاهان تحت تنش

ردیف	شاخص گیاهی	مخفف	معادله
۱.	شاخص سبزینگی تفاضلی	DVI[۲۶]	NIR – Red
۲.	شاخص ساده پوشش گیاهی	SR[۲۷]	ρNIR/ρRED
۳.	شاخص ساده پوشش گیاهی اصلاحی	MSR[۲۸]	(ρ800 − ρ445) / (ρ680−ρ445)
۴.	شاخص ساده پوشش گیاهی اصلاحی مرز قرمز	MRESR[۲۹]	(ρ750 – ρ445) / (ρ705 nm – ρ445)
۵.	شاخص سبزینگی تفاضلی نرمالیزه	NDVI[۳۰]	(ρNIR – ρRED) / (ρNIR + ρRED)
۶.	شاخص سبزینگی تفاضلی نرمالیزه سبز	GNDVI[۳۱]	(ρNIR−ρGREEN) / (ρNIR+ρGREEN)
۷.	شاخص مرز قرمز تفاضلی نرمالیزه	RENDVI[۳۲]	(ρNIR−ρRED EDGE) / (ρNIR+ρRED EDGE)
۸.	شاخص سبزینگی اصلاحی خاک تنظیم‌شده قرمز	OSAVI[۳۳]	1.16 (ρNIR−ρRED) / (ρNIR+ρRED+0.16)
۹.	شاخص سبزینگی اصلاحی خاک تنظیم شده سبز	GOSAVI[۳۴]	(ρNIR − ρGREEN) / (ρNIR + ρGREEN + 0.16)
۱۰.	شاخص سبزینگی نسبی سبز	GRVI[۳۵]	ρNIR / ρGREEN
۱۱.	شاخص نسبی سبز و قرمز	RGRI[۳۶]	ρRED / ρGREEN
۱۲.	شاخص غیرخطی	NLI[۳۷]	(ρNIR2 − ρRED) / (ρNIR2 + ρRED)
۱۳.	شاخص محتوی آبی برگ	LWCI[۳۸]	Log (1 − (ρNIR − ρMIDIR)) / −log (1 − (ρNIR − ρMIDIR))
۱۴.	شاخص سبزینگی بهبودیافته	EVI[۳۹]	2.5[(ρNIR – ρRED) / (ρNIR + 6 * ρRED – 7.5 * ρBLUE + 1)]
۱۵.	شاخص بازتاب فتوشیمیایی	PRI[۴۰]	(ρ531 − ρ570) / (ρ531 + ρ570)
۱۶.	شاخص رنگدانه ساختار متراکم	SIPI[۴۱]	(ρ800 − ρ445) / (ρ800 + ρ680)
۱۷.	شاخص سبزینگی تفاضلی اصلاحی مرز قرمز	mRENDV[۴۲]	ρ750 − ρ705) / (ρ750 + ρ705 −2 * ρ445)
۱۸.	شاخص آبی تفاضلی نرمالیزه	NDWI[۴۳]	(ρNIR − ρSWIR) / (ρNIR + ρSWIR)
۱۹.	شاخص تنش رطوبتی	MSI[۴۴]	(ρ1599) / (ρ819)
۲۰.	شاخص مادون قرمز تفاضلی نرمالیزه	NDII[۴۵]	(ρ819 − ρ1649) / (ρ819 + ρ1649)
۲۱.	شاخص بازتابی زوال گیاه	PSRI[۴۶]	(ρ680 − ρ500) / ρ750
۲۲.	شاخص سبزینگی تفاضلی نرمالیزه اصلاح شده	TDVI[۴۷]	$\sqrt{(q\ NIR - \rho RED)\ /(\rho\ NIR + \rho RED)\ +\ 0.5}$
۲۳.	شاخص سبز- قرمز تفاضلی نرمالیزه	NGRDI[۴۸]	(ρ GREEN− ρ RED) / (ρ GREEN+ ρ RED)
۲۴.	شاخص سبزینگی کلروفیل	CIgreen[۴۹]	(ρ NIR / ρ GREEN) − 1
۲۵.	ساخص مرز قرمز کلروفیل	CIrededge[۵۰]	(ρ NIR / ρ RED EDGE) − 1
۲۶.	شاخص محتوی کلروفیل سایه‌انداز	CCCI[۵۱]	RENDVI − RENDVI min / RENDVI max− RENDVI min
۲۷.	شاخص سبزینگی کلروفیل	CVI[۵۲]	$\rho\ NIR \times (\rho\ RED / \rho\ GREEN^2)$
۲۸.	شاخص سبزینگی اصلاح شده خاک	SAVI[۵۳]	(ρ NIR− ρ RED) (1+L) / (ρ NIR+ ρ RED) + L

ρ نشان‌دهنده بازتاب از باند مورد نظر است.

[26] Difference Vegetation Index
[27] Simple Ratio
[28] Modified Simple Ratio
[29] Modified Red-Edge Simple Ratio Index
[30] Normalized Difference Vegetation Index
[31] Green Ndvi
[32] Red-Edge Normalized Difference Vegetation Index
[33] Optimized Soil-Adjusted Vegetation Index
[34] Green Optimized Soil Adjusted Vegetation Index
[35] Green Ratio Vegetation Index
[36] Red, Green Ratio Index
[37] Nonlinear Index
[38] Leaf Water Content Index
[39] Enhanced Vegetation Index
[40] Photochemical Reflectance Index
[41] Structure Insensitive Pigment Index
[42] Modified Red Edge Ndvi
[43] Normalised Difference Water Index
[44] Moisture Stress Index
[45] Normalized Difference Infrared Index
[46] Plant Senescence Reflectance Index
[47] Transformed Normalized Difference Vegetation Index
[48] Normalized Green–Red Difference Index
[49] Green Chlorophyll Index
[50] Red-Edge Chlorophyll Index
[51] Canopy Chlorophyll Content Index
[52] Chlorophyll Vegetation Index
[53] Soil Adjusted Vegetation Index

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

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. به‌تعبیری، یادگیری ما کاملاً بدون نظارت است. اما هنوز یادگیری بدون ناظر به‌اندازه‌ی یادگیری باناظر 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 پردازش های 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 پیش‌پردازهای 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، الگورتیم‌های 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 SVM[54] 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 گرادیان کاهشی 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[56](DL) 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

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

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	*Arabidopsis thaliana*	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	*Arabidopsis thaliana*	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 (بیماری های 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 الگورتیم به خوبی می‌تواند از سه طریق: ۱. دسته

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

بندی (Bauer *et al*., 2019; Barbedo *et al*., 2019; Ferentinos *et al*., 2018)، ۲. قطعه بندی (Ghosh *et al*., 2016) و ۳. تشخیص اشیاء (Bahtt *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، معمولا 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 سایز پیکسل‌ها صورت گرفته است (Noah *et al*., 2006; Lio *et al*., 2017). Gupta و Pattanayak (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[57]) 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 مختصصین 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 برمبنای 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).

[57] Convolutional Neural Networks

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

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

نوع فعالیت یادگیری عمیق	گیاه مورد بررسی	نوع صفت مورد بررسی	نوع تصویر	الگوریتم و مدل استفاده شده	دقت و صحت مدل (درصد)
دسته‌بندی تصویر	برنج	دسته‌بندی بیماری بلاست برگی	RGB	CNN	۹۴
	برنج	بیماری لکه برگی برنج	RGB	InseptionResNetV2	۹۵،۶۷
	گندم	برگ سالم و برگ ناسالم	RGB	N-CNN	۸۹،۹
	ذرت	دسته‌بندی برگ سالم از ناسالم	RGB	CNN with BiLSTM	۹۹،۰۲
	ذرت	دسته‌بندی برگ سالم از ناسالم	RGB	DeepForest (gcForest)	۹۶،۲۵
	سویا	دسته‌بندی برگ سالم از ناسالم	RGB	SoyNet	۹۸،۱۴
تشخیص اشیاء	برنج	تشخیص نوع بیماری	RGB	Faster R-CNN with RPN	۹۸،۰۹ برای بلاست
	برنج	تشخیص بیماری	RGB	Faster R-CNN with FCM-KM	۹۶،۷ برای بلاست
	سویا	تشخیص بیماری	RGB	Multi-feature fusion Faster R-CNN	۹۶،۴ برای ویروس و ۶۵،۶۳ برای لکه باکتریایی
قطعه بندی تصویر	گندم	قطعه‌بندی نقاط زنگ زرد گندم	RGB	SimpleNet	۹۸
	گندم	بررسی فیزیولوژیک مقاومت به فوزاریوم	RGB	Mask-RCNN	۷۷،۷ برای بیماری در سنبله و ۹۸،۸ برای قطعه‌بندی سطح بیماری
	ذرت	قطعه بندی بخش‌های خاکستری برگ ذرت	RGB	CNN	۹۵،۳۳
دسته‌بندی تصویر	برنج	پیش‌بینی کمبود نیتروژن	RGB	ResNet-50+SVM	۵۷۹۰
	برنج	دسته‌بندی کمبود عناصر غذایی و کمبود نیتروژن	RGB	Densenet-121	۱۵۰۰
	برنج	کمبود عناصر غذایی	RGB	ResNet-50	۱۱۵۶
دسته‌بندی تصویر	ذرت	ارزیابی تنش آبی و تشخیص آن	RGB	CNN+SVM	۱۸۰۴۰
	ذرت	شناسایی تعداد برگ آلوده با لارو	RGB	InceptionV3	۱۱۲۸۰
	سویا	دسته‌بندی و شمارش تعداد آفات	RGB	ResNet-50	۱۰۰۰۰
	سویا	شناسایی نماتدها	RGB	NemaNet	۳۰۶۳
تشخیص اشیاء	گندم	مکان یابی آفات	RGB	ResNet-50 with RPN	۵۱۹،۷۵۲
	ذرت	شناسایی آفات	RGB	Faster R-CNN with RPN	۱۵۰۰۰
	سویا	شناسایی آفات	RGB	YOLO V3, V4 and V5	۳۷۱۰
دسته‌بندی تصویر	گندم	شناسایی گونه علف‌های هرز	RGB	YoLoV3-tiny	۷۲،۵
	سویا	شناسایی گونه علف‌های هرز	RGB	CNN-LVQ	۹۹،۴۴
	سویا	دسته‌بندی علف‌های هرز	RGB	DRCNN	۹۷،۲۵
تشخیص اشیاء	برنج	تشخیص ردیف‌های کشت نشاء برنج	RGB	ResNet-18	۸۸،۵۴
	برنج	مکان یابی نشاء	RGB	Faster R-CNN	۸۹،۸
	ذرت	تشخیص گیاهچه	RGB	Faster R-CNN (VGC19)	۹۷،۷۱
	ذرت	تشخیص گیاه زراعی و علف هرز	RGB	Faster R-CNN	۹۹،۸
قطعه‌بندی تصویر	برنج	قطعه‌بندی بین علف هرز و نشاء برنج	RGB	MTS-CNN	۹۶،۴۸
	ذرت	تمایز گیاهچه ذرت از سایر گیاهان	RGB	Mask R-CNN (ResNet50/101-FPN)	۹۴،۷
دسته‌بندی	گندم	شناسایی ارقام	RGB	DenseNet, MobileNet	۹۵،۶۸و ۹۵،۴۹
	گندم	شناسایی ارقام	RGB	ResNet-50,SE-ResNet,SE-ResNeXt	۹۲،۰۷
	ذرت	دسته‌بندی بذور ذرت	RGB	P-ResNet	۹۹،۷
تشخیص اشیاء	برنج	شمارش تعداد دانه در خوشه	RGB	Faster R-CNN with RPN	۹۹،۴
	گندم	تشخیص سنبله	RGB	RetinaNet with FPN	۹۸،۶
	گندم	تشخیص سنبله	RGB	YOLOv4 with dual SPP	۹۴،۵
	ذرت	شمارش گلاذین نر (تاسل)	RGB	(TasselNet, ResNet34)	۸۸،۹۷
	سویا	شمارش بذر	RGB	TCNN	MAE=13.21,MSE=17.62
	سویا	شمارش بذر	RGB	VGG-Two	MAE=0.6 MSE=0.6
	ذرت	دسته‌بندی ارقام	RGB	VGG-16	۹۸،۱
قطعه‌بندی تصویر	گندم	شمارش تعداد سنبله	RGB	TasseINetv2	۹۱،۰۱
	گندم	کمی‌سازی تعداد سنبله	RGB	VGG	۹۸
	ذرت	شمارش تعداد دانه ذرت	RGB	VGG-16	۹۰،۴۸
	ذرت	ارزیابی هندسی بلال	RGB	Mask R-CNN	۱۰۰ برای طول، ۹۹ برای قطر
	ذرت	قطعه‌بندی بذور ارقام	RGB	CK-CNN،ResNet50 ،Mask R-CNN,	۹۵،۶،۹۲،۵،۶۴،۷
	سویا	ارزیابی فنوتیپی	RGB	ResNet-101 with FPN	MAP=95.7

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

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، الگورتیم‌های 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، هنوزهم نیازمند پژوهش بیشتر و ساخت و کاربرد الگوریتم‌های پرکاربردی 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 سه‌بعدی 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 (به‌دلیل 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

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

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.

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

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., Pirsiavash, 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, LJ., 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.

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

Hassani-jalilian, O., Igathinathane, C., Doetkott, C., Bajwa, S., Nowatzki, J., Esmaeili, 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.

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

Munns, R., James, RA., Sirault, XR., Furbank, RT., Jones, HG. 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, EH., Edwards, AM., Blomstedt, CK., Berger, B., Moller, BL., Gleadow, RM. 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, PJ., 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., Léon, 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, DA., 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, AK., 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.

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]

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 Harsselaar, 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.

[Downloaded from cpj.ahvaz.iau.ir on 2026-09-13]