مجله علوم و فنون باغبانی ایران جلد ۲۷ شماره ۱ صفحه‌های ۸۷ تا ۱۱۲ (۱۴۰۵)
مقاله پژوهشی

مروری ساختاریافته بر پایش و مدیریت پیش‌گیرانه سلامت گیاه در گلخانه: از بینایی ماشین و هشدار زودهنگام تا کنترل هوشمند

A Structured Review of Plant Health Monitoring and Preventive Management in Greenhouses: From Machine Vision and Early Warning to Intelligent Control

زهرا قوامی‌پور*[۱]، علیرضا بابائی[۱]، مصطفی شمسی[۲]

۱. گروه علوم باغبانی، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران، ایران
۲. گروه ریاضی کاربردی، دانشکده ریاضی و علوم کامپیوتر، دانشگاه امیرکبیر، تهران، ایران
*نویسنده مسئول، پست الکترونیک: (Zahra.Ghavami@modares.ac.ir)

تاریخ دریافت: ۱۴۰۵/۲/۱۸، تاریخ پذیرش: ۱۴۰۵/۳/۲۵

چکیده

انقلاب فناوری‌های بینایی ماشین و حسگرهای پیشرفته در کشاورزی کنترل‌شده، امکان تشخیص دقیق و حتی پیش‌نشانگانی تنش‌های زیستی و غیرزیستی را فراهم کرده است. با این حال، یک شکاف راهبردی، تبدیل این خروار داده‌های دقیق به تصمیم‌های کنترلی خودکار و پیش‌گیرانه را متوقف کرده است: سامانه‌های پایش سلامت گیاه اغلب در لایه «تشخیص وضعیت فعلی» متوقف می‌مانند و سامانه‌های کنترل هوشمند اقلیم و آبیاری نیز عمدتاً بر مبنای حفظ نقاط تنظیم محیطی (دما، رطوبت و CO_2) و بدون درنظرگرفتن سیگنال‌های مستقیم سلامت گیاه عمل می‌کنند. این مرور ساختاریافته با روش PRISMA-lite، به‌عنوان نسخه ساده‌شده چارچوب PRISMA برای گزارش مرورها، و تحلیل ۴۴ مطالعه نهایی از ۵۲۳ رکورد اولیه در پایگاه اسکوپوس، به‌طور کمّی به این سؤال پرداخته است که "چرا زنجیره عملیاتی تشخیص زودهنگام، پیش‌بینی ریسک و اقدام کنترلی، هنوز در گلخانه‌ها بسته نشده است؟" یافته‌ها نشان می‌دهند ۶۶ درصد مطالعات دارای پایش سلامت و ۳۶ درصد دارای مؤلفه کنترل هستند، اما تنها ۱۱ درصد (پنج مطالعه) موفق به اتصال خروجی سلامت گیاه (مانند شاخص تنش آبی یا فشار آفت) به یک حلقه کنترل خودکار شده‌اند. شکاف اصلی در یک گام حیاتی پنهان است: فقدان مدل‌های پیش‌بینی‌کننده‌ای که بتوانند خروجی تشخیصی را به یک «امتیاز ریسک کمّی» با افق زمانی مشخص (مثلاً احتمال پژمردگی در ۲۴ ساعت آینده) تبدیل کنند و آن را به‌عنوان یک متغیر حلت در اختیار کنترل‌کننده پیش‌بین قرار دهند. حلقه بیرونی سامانه‌های سلامت‌محور پیشنهادی ما، مسیر "پایش پیوسته، تبدیل داده‌ها به شاخص کمی ریسک، پیش‌بینی روند سلامت، و اقدام کنترلی پیش‌گیرانه" را ترسیم می‌کند. این مقاله استدلال می‌کند که نسل بعدی گلخانه‌های هوشمند باید از معماری‌های "محیط‌محور" به "گیاه‌محور" گذار کنند؛ چشم‌اندازی که با کاهش توأمان مصرف آب، سموم و انرژی، پایداری اقتصادی و زیست‌محیطی تولید در اقلیم‌های شکننده‌ای چون ایران را تضمین خواهد کرد.

واژه‌های کلیدی: سلامت گیاه، تنش آبی، تشخیص پیش‌ازعلائم، مدیریت هوشمند گلخانه، کنترل پیش‌گیرانه، بهینه‌سازی مصرف آب، کشت محافظت‌شده.

مقدمه

گلخانه‌های تجاری امروزی، به‌عنوان بستر اصلی تولید خارج از فصل محصولات باغبانی، نقشی راهبردی در تأمین امنیت غذایی و بهره‌وری منابع دارند. در این سامانه‌های کشت متراکم، توانایی تنظیم عوامل محیطی مانند دما، رطوبت، نور، غلظت دی‌اکسیدکربن و آبیاری، امکان دستیابی به عملکردهای بالا را فراهم کرده است. با این حال، همین محیط کنترل‌شده، در صورت مدیریت نادرست، می‌تواند شمشیری دو لبه باشد؛ زیرا تراکم بالای بوته، رطوبت نسبی زیاد و گردش محدود هوا، شرایط را برای شیوع سریع بیماری‌های قارچی، طغیان آفات و تشدید تنش‌های فیزیولوژیک مهیا می‌سازد. در نتیجه، سلامت گیاه در گلخانه همواره در معرض تهدید عواملی است که می‌توانند ظرف چند روز بخش قابل توجهی از محصول را از بین ببرند یا کیفیت آن را به‌شدت کاهش دهند.

در حال حاضر، پایش سلامت گیاه در بیشتر گلخانه‌های کشور و حتی بسیاری از واحدهای پیشرفته، عمدتاً بر بازدید چشمی، تجربه کارشناس و نمونه‌برداری دستی متکی است. این شیوه هرچند ارزشمند، با محدودیت‌های ذاتی از جمله زمان‌بری، وابستگی به نیروی انسانی متخصص، خطای انسانی و مهم‌تر از همه، ناتوانی در تشخیص مراحل آغازین بیماری یا تنش همراه است. در بسیاری از موارد، هنگامی که علائم ظاهری مانند کلروز، نکروز، پژمردگی یا پیدایش کپک آشکار می‌شود، گیاه بخش قابل توجهی از خسارت را متحمل شده و پنجره طلایی برای مداخله مؤثر از دست رفته است. این تأخیر در تشخیص، به معنای افزایش مصرف سموم، کاهش اثربخشی مدیریت تلفیقی آفات[۱]، و تحمیل هزینه‌های اضافی تولید است.

در سال‌های اخیر، فناوری‌های نوین بینایی ماشین و سنجش تصویری، افق‌های تازه‌ای را برای پایش خودکار و غیرمخرب سلامت گیاه گشوده‌اند. سنسورهای تصویری متنوعی از جمله تصویربرداری رنگی مرئی/قرمز-سبز-آبی[۲]، تصویربرداری حرارتی، تصویربرداری فراطیفی و چندطیفی، و تصویربرداری فلورسانس کلروفیل توسعه یافته‌اند که هر یک قادرند جنبه‌ای از وضعیت فیزیولوژیک گیاه را آشکار سازند. برای مثال، تصویربرداری فلورسانس کلروفیل در تشخیص سفیدک داخلی خیار پیش از ظهور علائم بصری موفق بوده است (Chen *et al.,* 2024). در حوزه آفات، سامانه‌های مبتنی بر هوش مصنوعی اشیا[۳] با تحلیل خودکار تصاویر تله‌های چسبنده، امکان شمارش آفات، تعیین سطح هشدار و تولید اطلاعات مدیریتی برای مدیریت تلفیقی آفات را فراهم کرده‌اند (Rustia *et al.,* 2022). در زمینه تنش‌های محیطی نیز پژوهش‌ها نشان داده‌اند که ترکیب تصویربرداری حرارتی و فراطیفی می‌تواند شاخص‌های حیاتی مانند شاخص تنش آبی گیاه[۴] و نرخ تعرق گیاه را با دقت بالایی برآورد کند (Mertens *et al.,* 2023). این دستاوردها نشان می‌دهد که ابزارهای فنی برای تشخیص دقیق و حتی پیش‌نشانگانی مسائل سلامت گیاه، اکنون در دسترس محققان و بهره‌برداران قرار دارد.

با وجود این پیشرفت‌های چشمگیر، یک پرسش اساسی برای مدیران گلخانه‌ها بی‌پاسخ مانده است: چگونه می‌توان این اطلاعات ارزشمند حاصل از بینایی ماشین را به اقدامات مدیریتی خودکار و پیش‌گیرانه تبدیل کرد؟ بخش بزرگی از ادبیات موجود، هنوز در سطح تشخیص وضعیت فعلی گیاه (سالم/بیمار، وجود/عدم وجود آفت، سطح تنش) متوقف شده است. خروجی این مدل‌ها اگرچه برای ارزیابی گذشته‌نگر مفید است، اما به این پرسش که «وضعیت گیاه در ساعات یا روزهای آینده چگونه تغییر خواهد کرد و چه اقدامی باید هم‌اکنون انجام شود» پاسخ نمی‌دهد. این خلأ اطلاعاتی در مدیریت گلخانه بسیار پرهزینه است، زیرا تصمیم‌هایی مانند تنظیم رطوبت، تهویه، آبیاری و تغذیه باید پیش از عبور گیاه از آستانه‌های بحرانی تنش اتخاذ شوند.

از سوی دیگر، سامانه‌های کنترل هوشمند و پیش‌بین اقلیم گلخانه که امروزه به‌صورت تجاری نیز در دسترس هستند، عمدتاً بر مبنای حفظ متغیرهای محیطی در محدوده‌های از پیش تعیین‌شده (نقاط تنظیم[۵]) عمل می‌کنند. این سامانه‌ها پارامترهایی مانند دما، رطوبت، CO_2 و شدت نور را با دقت بالایی کنترل می‌کنند، اما معمولاً وضعیت واقعی گیاه را به‌عنوان یک متغیر ورودی در نظر نمی‌گیرند (Achour *et al.,* 2020; Mahmood *et al.,* 2023). به بیان دیگر، کنترل رایج در گلخانه‌ها «محیط‌محور» است، نه «گیاه‌محور». این در حالی است که نیاز واقعی یک گیاه تحت تنش ممکن است با نقطه تنظیم

۱- Integrated Pest Management; IPM
۲- Red-Green-Blue; RGB
۳- Artificial Intelligence of Things; AIoT
۴- Crop Water Stress Index; CWSI
۵- setpoint

استاندارد تفاوت چشمگیری داشته باشد؛ برای نمونه، یک بوته گوجه‌فرنگی که در آستانه پژمردگی قرار دارد، نیازمند مداخله فوری در آبیاری یا کاهش دماست، حتی اگر پارامترهای کلی گلخانه همچنان در محدوده نرمال قرار داشته باشند.

بنابراین، آن‌چه در ادبیات علمی و کاربردی گلخانه‌های هوشمند کمتر به آن پرداخته شده، حلقه مفقوده میان پایش سلامت گیاه و کنترل محیط رشد است. سه جریان پژوهشی «تشخیص سلامت گیاه با بینایی ماشین»، «پیش‌بینی و هشدار زودهنگام» و «کنترل هوشمند اقلیم و منابع» عمدتاً به‌صورت موازی و مستقل از یکدیگر رشد کرده‌اند. در نتیجه، هنوز چارچوبی یکپارچه که در آن سیگنال سلامت گیاه به پیش‌بینی ریسک و سپس به تصمیم کنترلی پیش‌گیرانه تبدیل شود، به‌صورت بالغ در ادبیات وجود ندارد. این شکاف علمی-کاربردی، به‌ویژه در بستر اقلیم ایران که گلخانه‌ها با چالش‌های کم‌آبی، تنش گرمایی تابستان و نوسانات دمایی زمستان روبرو هستند، اهمیتی دوچندان دارد.

هدف این مقاله، واکاوی نظام‌مند همین شکاف از طریق یک مرور ساختاریافته است. این مطالعه تلاش می‌کند با تحلیل ۴۴ پژوهش کلیدی در بازه ۲۰۱۶-۲۰۲۶، تصویری روشن از وضعیت موجود، دستاوردها و خلأهای علمی در مسیر یکپارچه‌سازی سلامت گیاه و کنترل هوشمند گلخانه ارائه دهد. تمرکز ویژه مقاله بر گیاهان باغبانی در گلخانه و کشاورزی محیط‌های کنترل‌شده[1] سه گروه اصلی تهدیدکننده سلامت، یعنی بیماری‌ها، آفات و تنش‌های غیرزیستی (شامل تنش آبی، حرارتی، کمبود عناصر غذایی و شوری) خواهد بود. پرسش‌های اصلی که این مرور به دنبال پاسخ به آن‌هاست، عبارت‌اند از:

۱. چه فناوری‌های بینایی ماشین و سنسورهای تصویری برای پایش بیماری، آفت و تنش‌های غیرزیستی در گیاهان گلخانه‌ای به‌کار رفته‌اند و کدام‌یک قابلیت تشخیص در مراحل اولیه و پیش‌ازعلائم را دارند؟
۲. چه تعداد از پژوهش‌های موجود توانسته‌اند از تشخیص صرف وضعیت فعلی فراتر رفته و به پیش‌بینی روند، هشدار زودهنگام یا تحلیل ریسک سلامت گیاه نزدیک شوند؟
۳. سامانه‌های کنترل هوشمند اقلیم و آبیاری در گلخانه تا چه اندازه وضعیت فیزیولوژیک گیاه (رشد، فتوسنتز، تعرق یا سلامت) را در تابع هدف یا محدودیت‌های کنترلی خود لحاظ کرده‌اند؟
٤. موانع اصلی بر سر راه ایجاد زنجیره کامل «پایش سلامت ← پیش‌بینی خطر ← اقدام کنترلی خودکار» در گلخانه‌های مدرن کدامند؟

نوآوری این مرور در آن است که به‌جای بررسی مجزای فناوری‌های تشخیص یا روش‌های کنترل، کل زنجیره مدیریت سلامت گیاه در گلخانه را به‌صورت یکپارچه تحلیل می‌کند. برای این منظور، یک ماتریس شواهد از ۴۴ مطالعه یکتا تهیه شده و مطالعات از نظر نوع تهدید، نوع سنسور، خروجی سلامت، قابلیت تشخیص پیش‌نشانگانی، وجود پیش‌بینی، نوع کنترل، اهداف گیاه‌محور، محدودیت‌های سلامت‌محور و سطح پیاده‌سازی عملی مقایسه شده‌اند. این رویکرد امکان شناسایی کمّی شکاف‌ها را فراهم می‌کند و مشخص می‌نماید که با وجود پیشرفت‌های ارزشمند در هر دو حوزه پایش و کنترل، یکپارچه‌سازی این دو هنوز در مراحل آغازین خود قرار دارد و مسیری مهم برای پژوهش‌های آینده به شمار می‌رود.

مواد و روش ها

این مطالعه به‌صورت یک مرور ساختاریافته با رویکرد PRISMA-lite انجام شد. هدف از این روش، شناسایی، غربالگری و سنتز مطالعات مرتبط با پایش سلامت گیاه در گلخانه، پیش‌بینی/هشدار زودهنگام و کنترل پیش‌بین بود. با توجه به ماهیت بین‌رشته‌ای موضوع، مرور حاضر صرفاً به مطالعات بینایی ماشین محدود نشد، بلکه مقالات مرتبط با کنترل پیش‌بین، مدیریت اقلیم، آبیاری، انرژی و یکپارچه‌سازی سلامت گیاه با کنترل نیز در دامنه جست‌وجو قرار گرفتند.

راهبرد جست‌وجو

جست‌وجوی اصلی به پایگاه Scopus محدود شد. دلیل انتخاب Scopus، پوشش گسترده آن از مجلات و مقالات کنفرانسی در حوزه‌های بین‌رشته‌ای کشاورزی، علوم گیاهی، مهندسی کنترل، سنجش تصویری و هوش مصنوعی، و نیز امکان دسترسی کامل و قابل‌تکرار نویسندگان به این پایگاه در زمان انجام مطالعه بود. در مقابل، به دلیل محدودیت دسترسی سازمانی به پایگاه‌هایی

۱- Controlled Environment Agriculture; CEA

مانند Web of Science و IEEE Xplore در زمان انجام مرور، این پایگاه‌ها به‌عنوان منابع اصلی جست‌وجو وارد فرایند مرور نشدند. بنابراین، دامنه مرور حاضر به رکوردهای نمایه‌شده در Scopus محدود است.

جست‌وجو تا تاریخ ۲۸ فوریه ۲۰۲۶ انجام شد. بازه زمانی مرور از سال ۲۰۱۶ تا ۲۰۲۶ در نظر گرفته شد و در عمل، شرط PUBYEAR > 2015 اعمال گردید. فقط رکوردهای انگلیسی از نوع مقاله پژوهشی و مقاله کنفرانسی وارد مرحله غربالگری شدند. برای پوشش کامل موضوع، راهبرد جست‌وجو در چند بلوک موضوعی طراحی شد: نخست، مطالعات مربوط به تشخیص بیماری گیاه با بینایی ماشین؛ دوم، مطالعات مربوط به تنش‌های غیرزیستی مانند تنش آبی، حرارتی، تغذیه‌ای و شوری؛ سوم، مطالعات کنترل پیش‌بین و بهینه‌سازی اقلیم، آب و انرژی در گلخانه؛ و چهارم، مطالعات بینابخشی مرتبط با اتصال پایش سلامت، هشدار زودهنگام و کنترل. رشته‌های جست‌وجوی بولی استفاده‌شده در Scopus به شرح زیر بودند:

Q1a: Disease-CV

TITLE-ABS-KEY(
(greenhouse OR "controlled environment" OR "controlled-environment" OR "protected cultivation" OR "protected agriculture" OR "CEA")
AND
("plant disease" OR pathogen* OR fungal OR bacteria* OR viral OR mildew OR blight OR "powdery mildew" OR "downy mildew")
AND
("early detection" OR "early diagnosis" OR presymptom* OR "pre-symptom*" OR monitoring OR "disease detection" OR "disease recognition")
AND
("machine learning" OR "deep learning" OR "computer vision" OR CNN OR "convolutional neural" OR transformer OR "vision transformer" OR ViT OR "anomaly detection" OR "few-shot" OR "self-supervised")
)
AND (PUBYEAR > 2015)
AND (LIMIT-TO(LANGUAGE, "English"))
AND (DOCTYPE(ar) OR DOCTYPE(cp))

Q1b: Abiotic stress-CV

TITLE-ABS-KEY(
(greenhouse OR "controlled environment" OR "controlled-environment" OR "protected cultivation" OR "protected agriculture" OR "CEA" OR glasshouse)
AND
("abiotic stress" OR "plant stress" OR "water stress" OR drought OR "heat stress" OR "temperature stress" OR salinity OR "salt stress" OR "nutrient stress" OR "nutrient deficiency" OR chlorosis OR "iron deficiency" OR "nitrogen deficiency" OR "physiological disorder")
AND
(monitoring OR detection OR diagnosis OR "stress detection" OR "stress recognition" OR "early warning" OR forecast* OR prediction OR presymptom* OR "pre-symptom*")
AND
("machine learning" OR "deep learning" OR "computer vision" OR CNN OR "convolutional neural" OR transformer OR "vision transformer" OR ViT OR "anomaly detection" OR "few-shot" OR "self-supervised")
)
AND (PUBYEAR > 2015)
AND (LIMIT-TO(LANGUAGE, "English"))
AND (DOCTYPE(ar) OR DOCTYPE(cp))

Q2: MPC/Optimization for irrigation, climate, and energy in greenhouses

TITLE-ABS-KEY(
(greenhouse OR glasshouse OR "protected cultivation" OR "controlled environment" OR "controlled-environment" OR CEA)
AND
("model predictive control" OR MPC OR "predictive control" OR "economic model predictive control" OR EMPC OR "receding horizon" OR "robust MPC" OR "stochastic MPC")
AND
(irrigation OR fertigation OR "irrigation scheduling" OR "climate control" OR microclimate OR HVAC OR ventilation OR heating OR cooling OR CO2 OR "energy management" OR "energy consumption" OR VPD)
)
AND (PUBYEAR > 2015)

AND (LIMIT-TO(LANGUAGE, "English"))
AND (DOCTYPE(ar) OR DOCTYPE(cp))

Q3: Health-aware MPC / bridge query

TITLE-ABS-KEY(
(greenhouse OR glasshouse OR "protected cultivation" OR "controlled environment" OR "controlled-environment" OR CEA)
AND
("model predictive control" OR MPC OR "predictive control" OR EMPC OR "receding horizon")
AND
("plant health" OR disease* OR stress OR "abiotic stress" OR "early warning" OR forecast* OR prediction OR anomaly OR "risk score" OR "risk-aware" OR "health-aware")
)
AND (PUBYEAR > 2015)
AND (LIMIT-TO(LANGUAGE, "English"))
AND (DOCTYPE(ar) OR DOCTYPE(cp))

چهار مجموعه جست‌وجو به‌ترتیب ۱۱۹، ۱۲۶، ۲۴۹ و ۱۲۵ رکورد اولیه بازگرداندند. رکوردها به نرم‌افزار Zotero منتقل شدند. پس از ادغام خروجی‌ها و حذف رکوردهای تکراری یا هم‌پوشان، مجموعه نهایی ۵۲۳ رکورد برای غربالگری عنوان و چکیده باقی ماندند. اگرچه یک رشته جست‌وجوی مستقل و جداگانه برای آفات تعریف نشده بود، رکوردهای مرتبط با پایش آفات در مرحله غربالگری عنوان و چکیده، از میان نتایج همین جست‌وجوهای گسترده‌تر شناسایی و با برچسب «آفت-بینایی ماشین» کدگذاری شدند. در مجموع، ۲۶ رکورد مرتبط با پایش آفات در مرحله غربالگری شناسایی شد.

معیارهای ورود و خروج

برای غربالگری اولیه، هر رکورد در یکی از چهار گروه "مطالعات وارد شده پس از غربالگری، مطالعات حذف شده پس از غربالگری، مطالعات نامطمئن یا مطالعات پشتیبان" طبقه‌بندی شد. رکوردهایی در گروه مطالعات وارد شده پس از غربالگری[۱] قرار گرفتند که به‌صورت مستقیم با گلخانه، کشت محافظت‌شده یا محیط کنترل‌شده مرتبط بودند و حداقل یکی از محورهای اصلی مرور را پوشش می‌دادند: پایش بیماری، آفت یا تنش غیرزیستی گیاه؛ تشخیص زودهنگام یا پیش‌نشانگانی؛ پیش‌بینی یا هشدار سلامت گیاه؛ یا کنترل پیش‌بین اقلیم، آبیاری، انرژی و منابع گلخانه. همچنین، مقاله باید روش، داده، مدل، متریک یا خروجی قابل استخراج برای تحلیل داشته باشد.

رکوردهایی در گروه مطالعات حذف شده پس از غربالگری[۲] قرار گرفتند که خارج از دامنه مرور بودند. مهم‌ترین دلایل خروج شامل نبود ارتباط با گلخانه یا محیط کنترل شده، استفاده از واژه «گلخانه» در معنای «گاز گلخانه‌ای» یا «اثر گلخانه‌ای»، نبود خروجی مرتبط با سلامت گیاه، نبود روش بینایی ماشین/سنسینگ در مطالعات سلامت گیاه، نبود کنترل پیش‌بین یا بهینه‌سازی مرتبط در مطالعات کنترل، و تمرکز صرف بر موضوعاتی مانند ژنتیک، اصلاح نباتات، عملکرد محصول یا مدیریت زراعی بدون ارتباط روشن با پایش یا کنترل هوشمند بود.

رکوردهایی که از روی عنوان و چکیده امکان تصمیم‌گیری قطعی درباره آن‌ها وجود نداشت، در گروه مطالعات نامطمئن[۳] قرار گرفتند. این موارد معمولاً شامل مطالعاتی بودند که گلخانه‌ای بودن، نوع سنسور، نوع خروجی سلامت یا ارتباط آن‌ها با کنترل در چکیده روشن نبود و برای تصمیم نهایی نیاز به بررسی متن کامل داشتند.

رکوردهای مطالعات پشتیبان[۴] شامل مطالعاتی بودند که برای زمینه‌سازی، تعریف مفاهیم، پشتیبانی از بحث یا تکمیل شکاف‌ها مفید بودند، اما وارد تحلیل اصلی ماتریس شواهد نشدند. این گروه می‌توانست شامل مقالات مروری، مقالات مجموعه‌داده / معیار ارزیابی[۵]، یا مطالعاتی با ارتباط غیرمستقیم با محور اصلی مرور باشد.

غربالگری و انتخاب مجموعه شواهد

پس از حذف رکوردهای تکراری و محدود کردن تحلیل به آیتم‌های اصلی، ۵۲۳ رکورد برای غربالگری عنوان و چکیده باقی ملند. از این میان، ۲۸۰ رکورد به‌عنوان مرتبط با دامنه مرور در گروه مطالعات وارد شده پس از غربالگری قرار گرفتند، ۲۱۳

۱- IN ۲- OUT ۳- MAYBE ۴- SUPPORT ۵- dataset/benchmark

رکورد حذف شـدند، ۲۵ رکورد به‌عنوان موارد مردد در گروه نامطمئن باقی ماندند، و پنج رکورد به‌عنوان مطالعات پشـتیبان یا زمینه‌ای در گروه مطالعات پشتیبان طبقه‌بندی شدند. هیچ رکوردی بدون تصمیم نهایی باقی نماند.

در مرحله بعد، از میان رکوردهای وارد شـده پس از غربالگری، مجموعه نهایی شـواهد برای تحلیل تفصـیلی انتخاب شـد. معیارهای انتخاب شامل ارتباط مستقیم با محور مرور، انجام مطالعه در گلخانه یا محیط کنترل‌شده، شفافیت روش و متریک‌ها، امکان استخراج داده برای ماتریس شواهد، دسترسی به متن کامل، اعتبار محل انتشار، تازگی روش، و پوشش متوازن خوشه‌های اصلی مرور بود. در نهایت، ۴۴ مطالعه یکتا به‌عنوان مجموعه نهایی شواهد انتخاب شد.

این ۴۴ مطالعه در شش خوشه تحلیلی سازمان‌دهی شدند: بیماری-بینایی ماشین (۱۲مطالعه)، آفت-بینایی ماشین (شش مطالعه)، تنش غیرزیسـتی-بینایی ماشـین (۱۰ مطالعه)، پیش‌بینی/هشـدار زودهنگام (شـش مطالعه)، کنترل پیش‌بین مدل‌مبنا/کنترل (۱۴ مطالعه) و یکپارچه‌سازی سلامت‌محور (پنج مطالعه). به‌دلیل ماهیت بین‌رشته‌ای موضوع، برخی مطالعات در بیش از یک خوشـه تحلیلی مورد اسـتفاده قرار گرفتند؛ برای مثال، یک مطالعه ممکن بود هم در بخش «تنش-بینایی ماشـین» و هم در بخش «پیش‌بینی/هشـدار زودهنگام» مرتبط باشـد. بنابراین، از ۴۴ مطالعه یکتا، در مجموع ۵۳ تخصـیص موضـوعی اسـتخراج شـد. در تحلیل‌های کمی، هر مطالعه یکتا فقط یک‌بار شـمارش شـد، اما در سـنتز موضـوعی، مطالعات بین‌بخشی در بخش‌های مرتبط نیز مورد بحث قرار گرفتند.

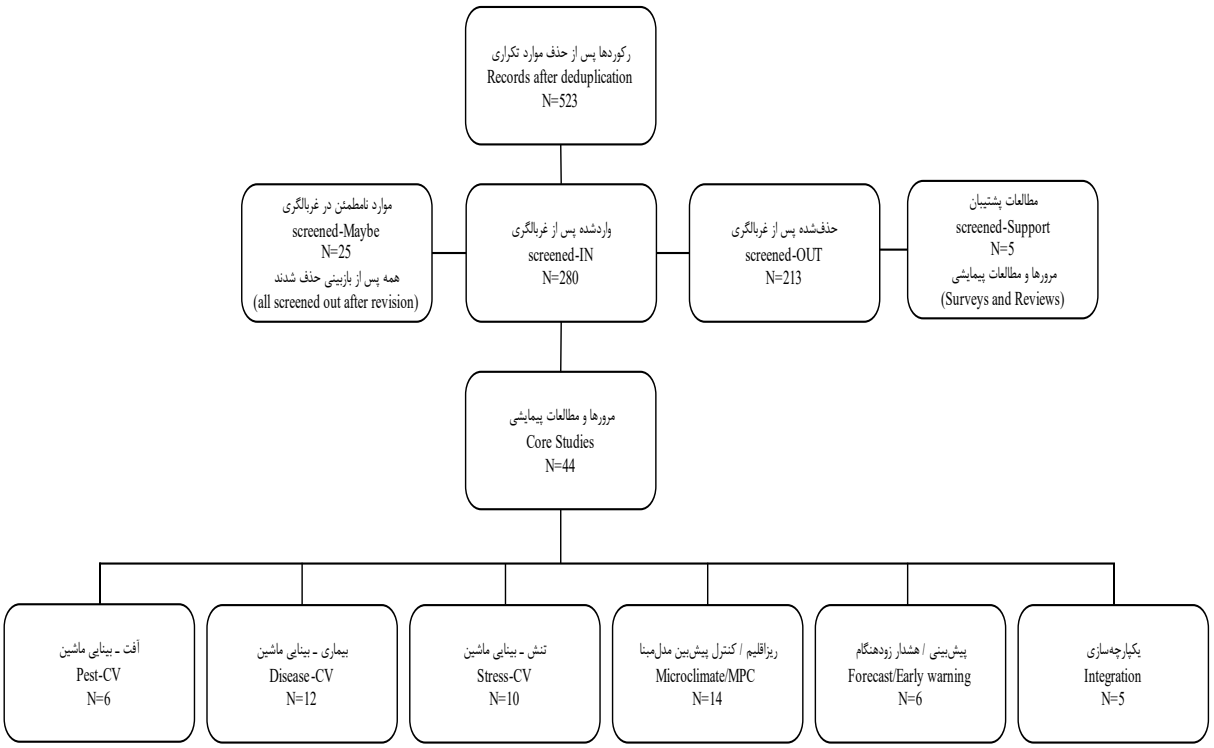

شکل ۱- نمودار جریان PRISMA-lite برای فرایند غربالگری مطالعات (بخش بالایی) و توزیع موضوعی مطالعات هسته در شش خوشه تحلیلی (بخش پایینی). بخش بالایی: مسیر گام‌به‌گام شناسایی، غربالگری و انتخاب را نشان می‌دهد. از ۵۲۳ رکورد اولیه، پس از اعمال معیارها، ۲۸۰ رکورد در گروه IN (مرتبط) ارزیابی شـدند که از میان آن‌ها ۴۴ مطالعه یکتا به‌عنوان مجموعه نهایی شـواهد برگزیده شـدند. بخش پایینی: نمودار دایره‌ای/میله‌ای، تخصـیص موضـوعی همین ۴۴ مطالعه منتخب را در شـش خوشـه تحلیلی اصـلی نمایش می‌دهد. نکته مهم: به دلیل ماهیت بین‌رشـته‌ای برخی مطالعات، یک مطالعه ممکن اسـت در بیش از یک خوشـه به‌کار رفته باشد؛ بنابراین مجموع تخصیص‌ها (۵۳ مورد) لزوماً برابر با تعداد کل مطالعات یکتا (۴۴ مورد) نیست.

Fig. 1. PRISMA-lite flow diagram of the screening process (upper panel) and thematic distribution of the core evidence set (n=44) across six analytical clusters (lower panel). The upper panel shows the step-by-step identification and eligibility check. The lower panel illustrates the thematic allocations of the final 44 studies. Note that due to the interdisciplinary nature, some studies were assigned to more than one cluster, resulting in a total of 53 thematic allocations.

استخراج داده و ماتریس شواهد

برای تحلیل منسجم مطالعات، یک ماتریس شواهد بر اساس ۴۴ مطالعه نهایی تهیه شد. هدف از این ماتریس، مقایسه مطالعات از نظر نوع تهدید، نوع سنسور، خروجی سلامت، سطح هوشمندی، نوع کنترل و میزان آمادگی عملیاتی بود.

برای هر مطالعه، اطلاعات زیر استخراج شد: خوشه اصلی و خوشه فرعی، نوع تهدید سلامت گیاه، نوع تنش در صورت وجود، نوع داده یا سنسور، خروجی سلامت، وجود تشخیص پیش‌نشانگانی یا زودهنگام، وجود پیش‌بینی یا هشدار، نوع کنترل، وجود هدف گیاه‌محور، وجود قید سلامت‌محور یا ریسک‌محور، پیامدهای مرتبط با مصرف آب یا انرژی، و سطح پیاده‌سازی.

در کدگذاری ماتریس شواهد، میان «تشخیص زودهنگام» و «پیش‌بینی» تمایز عملیاتی قائل شدیم. منظور از تشخیص زودهنگام یا پیش‌نشانگانی[۱]، شناسایی وضعیت غیرسالم، آلودگی، تنش یا تغییر فیزیولوژیک در همان زمان اندازه‌گیری، اما پیش از ظهور علائم شدید یا قابل مشاهده برای انسان بود. بنابراین، مطالعه‌ای که بتواند یک برگ آلوده بدون علامت ظاهری و یا با علائم اولیه بسیار خفیف، یک گیاه در مراحل آغازین تنش آبی، یا افزایش اولیه جمعیت آفت را در زمان حال شناسایی کند؛ در گروه تشخیص زودهنگام کدگذاری شد. در مقابل، منظور از پیش‌بینی[۲]، برآورد وضعیت آینده سلامت گیاه در یک افق زمانی مشخص یا ضمنی بود؛ برای مثال، تخمین احتمال عبور از آستانه تنش در ۲۴ یا ۴۸ ساعت آینده، پیش‌بینی روند افزایش شدت بیماری، یا تبدیل داده‌های پایش به سطح هشدار مبتنی بر روند زمانی. بر این اساس، تشخیص زودهنگام الزاماً پیش‌بینی محسوب نشد، مگر آنکه مطالعه خروجی زمانی، روندی، ریسک‌محور یا هشدار قابل اقدام برای آینده ارائه کرده باشد.

نوع تهدید در سه گروه اصلی بیماری، آفت و تنش غیرزیستی کدگذاری شد. تنش‌های غیرزیستی به دو گروه «آبی-حرارتی» و «تغذیه‌ای-یونی» تقسیم شدند. نوع سنسور یا داده شامل تصویربرداری رنگی مرئی، حرارتی، فراطیفی/چندطیفی، فلورسانس، چندسنسوری و مطالعات صرفاً کنترل[۳] بود. خروجی سلامت شامل طبقه‌بندی، شدت، شاخص سلامت، امتیاز ریسک یا متغیرهای فیزیولوژیک مانند تعرق، فتوسنتز، هدایت روزنه‌ای یا شاخص تنش آبی بود.

برای بخش کنترل، مطالعات از نظر وجود یا عدم وجود کنترل، نوع کنترل، اهداف گیاه‌محور[۴] و قیود سلامت‌محور[۵] بررسی شدند. منظور از گیاه‌محور اهداف مطالعاتی بود که رشد، فتوسنتز، عملکرد، وزن خشک یا وضعیت محصول را در مدل یا تابع هدف کنترل وارد کرده بودند. منظور از سلامت‌محور قیود مطالعاتی بود که ریسک، عدم‌قطعیت، قید سلامت، احتمال نقض آستانه یا ساختارهای نزدیک به کنترل سلامت‌محور را در چارچوب تصمیم‌گیری لحاظ کرده بودند.

سطح پیاده‌سازی نیز به‌صورت ترتیبی کدگذاری شد. سطح صفر به مطالعات شبیه‌سازی یا داده‌های غیرعملیاتی، سطح یک به آزمایش‌های آزمایشگاهی یا مبتنی بر مجموعه‌داده[۶]، سطح دو به آزمون در گلخانه یا نمونه اولیه گلخانه‌ای، و سطح سه به سامانه‌های عملیاتی یا نزدیک به کاربرد واقعی اختصاص یافت. این کدگذاری امکان بررسی شکاف میان دقت الگوریتمی و آمادگی عملیاتی را فراهم کرد.

ماتریس شواهد مبنای تحلیل‌های کمی و کیفی این مرور قرار گرفت. بر اساس این ماتریس، تعداد مطالعات دارای تشخیص پیش‌نشانگانی، پیش‌بینی، کنترل، اهداف گیاه‌محور، قیود سلامت‌محور و سطح پیاده‌سازی استخراج شد و برای شناسایی شکاف‌های اصلی ادبیات مورد استفاده قرار گرفت.

نمای کلی مجموعه شواهد

مجموعه نهایی شواهد این مرور شامل ۴۴ مطالعه یکتا بود که از میان ۲۸۰ رکورد مطالعات وارد شده پس از غربالگری انتخاب شدند. این مطالعات در شش خوشه تحلیلی سازمان‌دهی شدند: بیماری-بینایی ماشین، آفت-بینایی ماشین، تنش غیرزیستی-بینایی ماشین، پیش‌بینی/هشدار زودهنگام، کنترل پیش‌بین مدل‌مبنا/کنترل و یکپارچه‌سازی سلامت‌محور. به‌دلیل ماهیت بین‌رشته‌ای موضوع، برخی مطالعات در بیش از یک خوشه استفاده شدند؛ بنابراین، از ۴۴ مطالعه یکتا، در مجموع ۵۳ تخصیص موضوعی به‌دست آمد. این موضوع نشان می‌دهد که بخشی از ادبیات، به‌ویژه در مرز میان تنش غیرزیستی، پیش‌بینی و کنترل، ماهیت بین‌بخشی دارد.

۱- Early detection ۲- Prediction ۳- Control-only ۴- Plant-Aware Objective ۵- Health-Aware Constraint
۶- Dataset-based

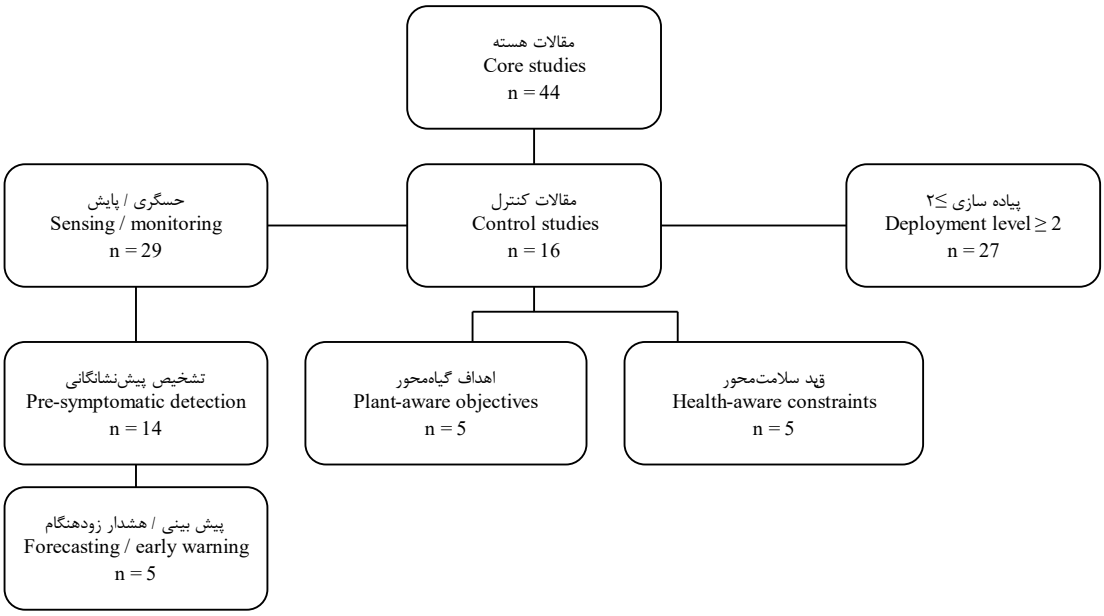

شکل ۲- طبقه‌بندی موضوعی مجموعه شاهد.

Fig. 2. Subject Classification of the evidence set.

از نظر توزیع موضوعی، بیشترین سهم تخصیص‌ها مربوط به کنترل پیش‌بین و مدیریت اقلیم/آب/انرژی بود. در سطح تخصیص موضوعی، ۱۲ رکورد به بیماری-بینایی ماشین، شش رکورد به آفت-بینایی ماشین، ۱۰ رکورد به تنش غیرزیستی-بینایی ماشین، شش رکورد به پیش‌بینی/هشدار زودهنگام، ۱۴ رکورد به کنترل پیش‌بین مدل‌مبنا/کنترل و پنج رکورد به یکپارچه‌سازی سلامت‌محور اختصاص یافت. این توزیع نشان می‌دهد که ادبیات موجود هم در سمت پایش سلامت گیاه و هم در سمت کنترل گلخانه رشد کرده است؛ اما تعداد مطالعاتی که این دو بخش را به‌صورت یکپارچه پوشش می‌دهند، همچنان محدود است.

از نظر نوع داده و سنسور، ۱۲ مطالعه صرفاً بر تصاویر تصویربرداری رنگی مرئی متکی بودند؛ نه مطالعه از داده‌های طیفی، فراطیفی، چندطیفی یا فلورسانس استفاده کردند؛ و هشت مطالعه رویکرد چندسنسوری داشتند. در مقابل، ۱۵ مطالعه در گروه صرفاً کنترلی قرار گرفتند و فاقد لایه مستقیم سنجش تصویری سلامت گیاه بودند. بنابراین، حدود دو سوم مطالعات نهایی دارای مؤلفه حسگری یا بینایی بودند، اما بخش قابل توجهی از مطالعات کنترل، بدون اتصال مستقیم به خروجی بینایی ماشین یا سنسور سلامت گیاه توسعه یافته‌اند. این الگو، یکی از شواهد اولیه برای وجود شکاف میان حسگری و کنترل در ادبیات گلخانه است.

از نظر سطح هوشمندی خروجی سلامت، ۱۴ مطالعه دارای مؤلفه تشخیص پیش‌نشانگانی یا زودهنگام بودند. این مطالعات عمدتاً از سنسورهایی مانند تصویربرداری فراطیفی[۱]، تصویربرداری چندطیفی[۲]، فلورسانس، تصویربرداری حرارتی یا داده‌های زمانی استفاده کردند و هدف آن‌ها تشخیص تغییرات بیماری یا تنش پیش از مرحله شدید یا قابل مشاهده بود. با این حال، فقط ۵ مطالعه به پیش‌بینی، هشدار زودهنگام، پایش سری زمانی[۳] یا خروجی ریسک‌محور نزدیک شدند. این اختلاف نشان می‌دهد که اگرچه تشخیص زودهنگام در ادبیات نسبتاً مورد توجه قرار گرفته، تبدیل آن به پیش‌بینی زمانی و هشدار قابل اقدام هنوز محدود است.

۱- Hyperspectral Imaging; HSI ۲- Multispectral Imaging; MSI ۳- Time-series monitoring

در بخش کنترل، ۱۶ مطالعه دارای مؤلفه کنترل بودند. این مطالعات شـــامل واژه‌هایی مانند کنترل پیش‌بین مدل‌مبنا[۱]، کنترل پیش‌بین مدل‌مبنای مقاوم[۲]، کنترل پیش‌بین مدل‌مبنای تصـــادفی[۳]، کنترل پیش‌بین مدل‌مبنای اقتصـــادی[۴]، کنترل آبیاری، کنترل اقلیم، مدیریت انرژی و بهینه‌ســـازی نقاط تنظیم اقلیم/انرژی بودند. با این حال، فقط پنج مطالعه دارای اهداف گیاه‌محور بودند؛ یعنی رشد، فتوسنتز، عملکرد یا وضعیت محصول را به‌صورت صریح وارد مدل یا تابع هدف کنترل کردند.

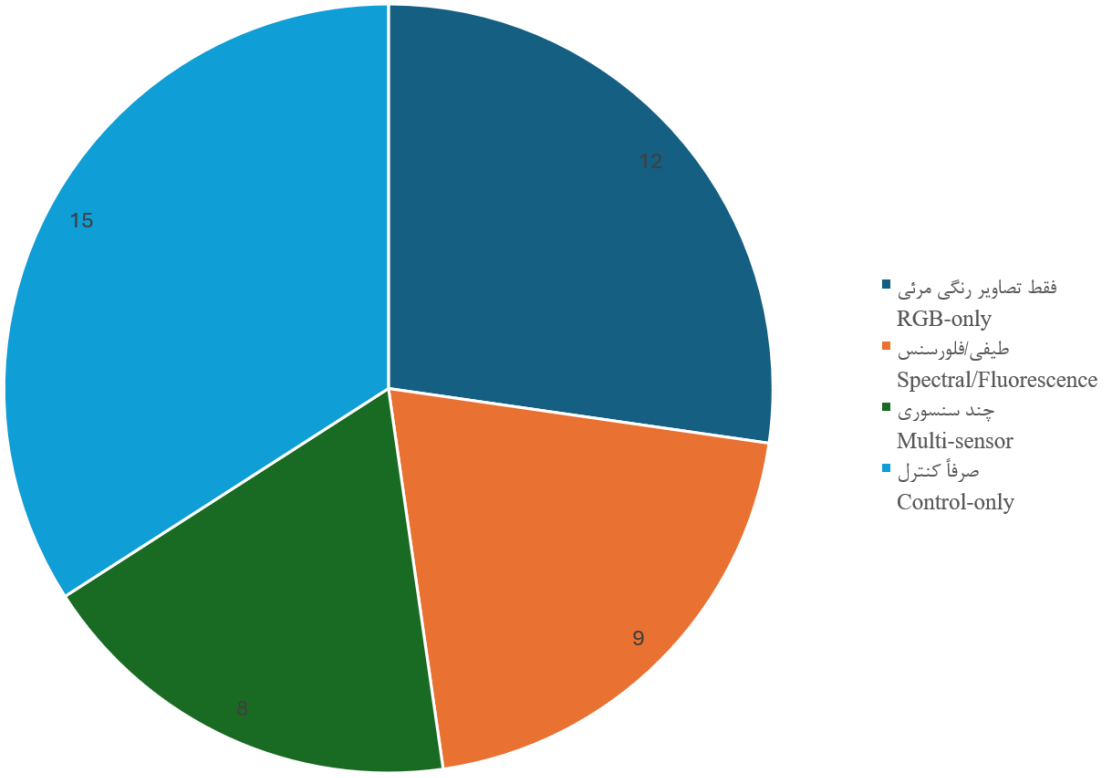

شکل ۳- توزیع مطالعات نهایی بر اساس نوع داده یا سنسور (وجه‌های پایش سلامت گیاه). نمودار دایره‌ای، سهم هر یک از چهار گروه اصلی را نشان میدهد: «صرفا تصویربرداری رنگی مرئی» (۱۲ مطالعه)، «تصویربرداری طیفی، فراطیفی، چندطیفی و فلورسانس» (نه مطالعه)، «چندسنسوری» (هشت مطالعه)، و «صرفاً کنترل (بدون سنجش تصویری)» (۱۵ مطالعه).

Fig. 3. Distribution of the final studies by data/sensor type (plant health monitoring modalities). The pie chart shows the share of four main categories: "RGB-only" (12 studies), "HSI/MSI/Fluorescence" (9 studies), "Multi-sensor" (8 studies), and "Control-only (without imaging sensing)" (15 studies).

همچنین، فقط پنج مطالعه دارای ساختاری نزدیک به قیود سلامت‌محور یا ریسک‌محور بودند. این یافته نشان می‌دهد که کنترل پیش‌بین در گلخانه از نظر روش‌های کنترل و مدیریت منابع پیشـــرفت کرده، اما هنوز عمدتاً بر متغیرهای محیطی متمرکز است و کمتر از شاخص‌های مستقیم سلامت گیاه استفاده می‌کند.

از نظر آمادگی عملیاتی، ۲۷ مطالعه در ســـطح پیاده‌ســـازی دو یا بالاتر قرار گرفتند؛ یعنی داده یا آزمون آن‌ها در گلخانه، نمونه اولیه گلخانه‌ای یا سامانه نزدیک به کاربرد واقعی انجام شده بود. این عدد نشان می‌دهد که بخش قابل توجهی از مطالعات از ســـطح آزمایش کاملاً آزمایشـــگاهی فراتر رفته‌اند. با این حال، ســـطح پیاده‌ســـازی بالا الزاماً به معنی یکپارچگی کامل نیســـت. بسیاری از مطالعات در گلخانه ارزیابی شده‌اند، اما هنوز چرخه کامل پایش، هشدار، تصمیم‌گیری و کنترل را پوشش نمی‌دهند.

بر اســاس ماتریس شــواهد، ســه الگوی کلی در ادبیات قابل مشــاهده اســت. نخســت، مطالعات بینایی ماشــین در تشــخیص بیماری، آفت و تنش رشد قابل توجهی داشته‌اند، اما بیشتر آن‌ها در سطح تشخیص، طبقه‌بندی (سالم/دارای عارضه) یا تخمین

۱- Model Predictive Control; MPC
۲- Robust Model Predictive Control; RMPC
۳- Stochastic Model Predictive Control; SMPC
۴- Economic Model Predictive Control; EMPC

و برآورد شـــدت باقی مانده‌اند. دوم، مطالعات کنترل پیش‌بین توانســـته‌اند مســـائل اقلیم، انرژی، CO_2، آبیاری و عدم‌قطعیت را مدل‌سـازی کنند؛ اما اغلب خروجی‌های سـلامت گیاه را به‌صـورت مسـتقیم وارد تصـمیم کنترل نکرده‌اند. سـوم، مطالعات واقعاً بین‌بخشی که پایش سلامت، پیش‌بینی و کنترل را به هم متصل کنند، هنوز تعداد کمی دارند.

بنابراین، نمای کلی مجموعه شواهد نشان می‌دهد که ادبیات موجود از نظر اجزای منفرد، یعنی حسگری و کنترل، نسبتاً غنی اسـت؛ اما از نظر اتصـال این اجزا به یک سـامانه سـلامت‌محور، هنوز پراکنده و ناکامل اسـت. این نتیجه، مبنای تحلیل‌های بعدی مقاله اسـت: نخسـت بررسـی جزئی روش‌های بینایی ماشـین برای بیماری، آفت و تنش؛ سـپس تحلیل لایه‌های مشـترک مانند تشـخیص پیش‌نشـانگانی، یادگیری عمیق مبتنی بر تصـاویر رنگی مرئی، پیاده‌سـازی در شـرایط واقعی، و در نهایت بررسـی شکاف میان پیش‌بینی سلامت و کنترل پیش‌بین گلخانه.

جدول ۱- خلاصه کمی مجموعه نهایی شواهد.

Table 1. Quantitative summary of the final evidence core.

شاخص Indicator	تعداد Frequency	درصد از کل Percentage of total
کل مقالات هسته Total core studies	44	100
مطالعات دارای حسگری/پایش Studies involving sensing/monitoring	29	65.9
مطالعات پیش‌نشانگانی Pre-symptomatic studies	14	31.8
پیش‌بینی/هشدار زودهنگام Forecasting / early-warning studies	5	11.4
مطالعات دارای شاخص کنترلی Studies involving control	16	36.4
اهداف گیاه‌محور Plant-aware objectives	5	11.4
قیود سلامت‌محور Health-aware constraints	5	11.4
مطالعات با سطح پیاده‌سازی ≥ 2 Studies with deployment level ≥ 2	27	61.4
صرفاً تصویربرداری رنگی مرئی RGB-only imaging	12	27.3
تصویربرداری طیفی/فلورسانس Spectral/fluorescence imaging	9	20.5
تصویربرداری چند سنسوری Multi-sensor imaging	8	18.2
مطالعات صرفاً کنترلی Control-only studies	15	34.1

نتایج

پایش سلامت گیاه با بینایی ماشین

پایش بیماری گیاه در گلخانه با بینایی ماشین

بیماری‌های گیاهی در کشت‌های متراکم گلخانه‌ای به دلیل رطوبت نسبی بالا، دمای مطلوب رشد عامل بیماری‌زا و تراکم بالای میزبان حساس، می‌توانند ظرف چند روز تا ۱۰۰ درصد محصول را نابود کنند. در چنین شرایطی، تشخیص زودهنگام بیماری، پیش از آنکه علائم بصری آشکاری مانند لکه برگی، کپک یا پژمردگی ظاهر شود، کلید موفقیت در مدیریت بیماری و کاهش مصرف سموم است. در گلخانه‌های سنتی، این کار هنوز متکی به بازدید چشمی کارشناس است که علاوه بر زمان‌بر بودن، در مراحل آغازین آلودگی به‌ویژه زمانی که کانون‌های اولیه بیماری در نقاطی از گلخانه پنهان‌اند، اغلب ناتوان است. فناوری‌های

بینایی ماشین برای پر کردن این خلأ در دو مسیر اصلی توسعه یافته‌اند: تشخیص پیش‌نشانگانی با سنسورهای طیفی و فلورسانس، و تشخیص علائم ظاهری با تصاویر رنگی مرئی و یادگیری عمیق.

نخستین مسیر، شناسایی تغییرات فیزیولوژیک گیاه پیش از بروز علائم قابل مشاهده است. بیماری‌ها پیش از ایجاد لکه یا کپک، متابولیسم گیاه، محتوای کلروفیل و بازتاب طیفی برگ را تغییر می‌دهند. برای نمونه، Rivera-Romero و همکاران (۲۰۲۵) با استفاده از بازتاب طیفی و شاخص‌های گیاهی، چهار سطح خسارت سفیدک پودری را در کدوییان تشخیص دادند و توانستند با دقت ۹۸ درصد و ضریب کاپای ۰/۹۶ مراحل اولیه بیماری را از یکدیگر تفکیک کنند. چنین خروجی‌هایی به‌مراتب ارزشمندتر از یک برچسب ساده «سالم/بیمار» است، زیرا به مدیر گلخانه امکان می‌دهد شدت و مرحله پیشرفت بیماری را ارزیابی کرده و برای مداخله هدفمند برنامه‌ریزی کند. در مطالعه‌ای دیگر، Chen و همکاران (۲۰۲۴) با استفاده از تصویربرداری فلورسانس کلروفیل توانستند برگ‌های خیار آلوده به سفیدک داخلی را حدود سه روز پیش از ظهور علائم ظاهری با دقت ۹۶/۷۴ درصد از برگ‌های سالم تشخیص دهند. این پنجره زمانی سه‌روزه فرصتی طلایی برای اقدامات پیش‌گیرانه مانند کاهش رطوبت، افزایش تهویه یا حذف موضعی برگ‌های آلوده فراهم می‌کند (Chen *et al.,* 2024; Rivera-Romero *et al.,* 2025).

مسیر دوم، تشخیص بیماری و تخمین شدت آن با دوربین‌های رنگی ساده و مدل‌های یادگیری عمیق است که از نظر هزینه و سهولت نصب در گلخانه‌های تجاری مزیت دارد، هرچند معمولاً به ظهور علائم بصری وابسته است. Wspanialy و Moussa (۲۰۲۰) سامانه‌ای را برای تشخیص هم‌زمان چند بیماری گوجه‌فرنگی گلخانه‌ای و تخمین شدت بیماری در سطح برگ توسعه دادند. مدل آن‌ها با نسخه اصلاح‌شده U-Net، نسبت سطح آلوده برگ را برآورد کرد؛ شاخصی که برای پایش روند بیماری و سنجش اثربخشی اقدامات کنترلی بسیار کاربردی‌تر از تشخیص دودویی سالم/بیمار است. همچنین، مدل‌های سبک و بلادرنگ مانند SE-YOLOv5 ارائه‌شده توسط Qi و همکاران (۲۰۲۲) برای شناسایی بیماری ویروسی گوجه‌فرنگی در پس‌زمینه پیچیده گلخانه با دقت ۹۱ درصد، و مدل PYSS معرفی‌شده توسط Xu و همکاران (۲۰۲۲) برای تشخیص بیماری برگ خربزه با حجم پردازشی تنها ۱/۱ مگابایت و قابل اجرا روی سخت‌افزار کم‌هزینه Jetson Nano، همگی گام‌هایی عملی به سوی استقرار این فناوری‌ها در گلخانه‌های واقعی هستند (Wspanialy & Moussa, 2020; Qi *et al.,* 2022; Xu *et al.,* 2022).

با وجود این دستاوردها، هنوز شکافی میان خروجی مدل‌های تشخیص بیماری و اقدام مدیریتی عملی وجود دارد. بیشتر این مدل‌ها برگ را به‌عنوان «سالم» یا «بیمار» طبقه‌بندی می‌کنند، اما به‌ندرت می‌گویند که نرخ گسترش بیماری چقدر است، چند روز تا آلودگی کامل باقی مانده، یا کدام اقدام محیطی (مثلاً کاهش رطوبت نسبی از ۸۵ درصد به ۷۵ درصد) بیشترین تأثیر را در توقف روند بیماری خواهد داشت. با این حال، خروجی‌های طیفی و تصویری کنونی به‌خوبی ظرفیت آن را دارند که به‌عنوان ورودی یک سامانه هشدار زودهنگام عمل کنند و به گلخانه‌دار فرصت دهند پیش از همه‌گیر شدن بیماری، رطوبت، دما و تهویه را اصلاح کند.

پایش آفات با بینایی ماشین

آفات در گلخانه، برخلاف بیماری‌ها که عمدتاً علائم خود را روی بافت گیاه آشکار می‌سازند، اغلب موجوداتی متحرک و ریز هستند که پایش جمعیت آن‌ها نیازمند رویکردی متفاوت است. حشرات مکنده‌ای مانند سفیدبالک و تریپس، علاوه بر تغذیه مستقیم از شیره گیاه و کاهش بنیه بوته، ناقلان اصلی ویروس‌های مخربی چون ویروس پیچیدگی برگ زرد گوجه‌فرنگی[۱] و ویروس پژمردگی لکه‌ای گوجه‌فرنگی[۲] به شمار می‌روند. در یک گلخانه تجاری، چند روز تأخیر در تشخیص طغیان این آفات می‌تواند به خسارت جبران‌ناپذیر و قرنطینه محصول منجر شود. بنابراین، پایش پیوسته و دقیق جمعیت آفات برای تعیین دقیق زمان مداخله در چارچوب مدیریت تلفیقی آفات یک ضرورت عملی است. در حال حاضر، روش رایج، نصب تله‌های چسبنده زرد و شمارش دستی حشرات به‌دام‌افتاده است که کاری زمان‌بر، وابسته به نیروی متخصص و مستعد خطا است.

پیشرفت‌های بینایی ماشین این فرآیند را متحول کرده است. محور اصلی پژوهش‌ها، تشخیص و شمارش خودکار آفات ریز روی تصاویر تله‌های چسبنده است. Li و همکاران (۲۰۲۱) مدل TPest-RCNN را بر پایه Faster R-CNN برای تشخیص سفیدبالک و تریپس در تصاویر تله‌های چسبنده گلخانه توسعه دادند. از آنجا که اندازه این آفات در تصاویر با تفکیک

۱- Tomato Yellow Leaf Curl Virus; TYLCV

۲- Tomato Spotted Wilt Virus; TSWV

۱۹۲۰×۲۵۶۰ گاهی تنها ۱۵×۱۰ پیکسل بود، تصاویر به کاشی‌های کوچک‌تر تقسیم و طراحی جعبه‌های مرجع[۱] متناسب با اشیای ریز بهینه‌سازی شد. مدل نهایی با میانگین دقت ۰/۹۲۵ و همبستگی بالای ۹۷ درصد با شمارش دستی، نشان داد که شمارش خودکار می‌تواند جایگزینی قابل‌اعتماد برای روش سنتی باشد. گام بعدی، حرکت از تشخیص لحظه‌ای به پایش روند جمعیت در طول زمان بود. در پژوهشی، Zhang و همکاران (۲۰۲۳) با استقرار یک سامانه خودکار ثبت تصویر از تله‌های چسبنده زرد در دو گلخانه گوجه‌فرنگی گیلاسی و توت‌فرنگی، جمعیت شش گروه آفت را به‌مدت ۴۰ روز پایش کردند. مدل بهبودیافته YOLOv5 با دقت ۹۶ درصد، نه‌تنها آفات را شمارش کرد، بلکه سری زمانی جمعیت آن‌ها را نیز ثبت نمود و نشان داد که تراکم آفت در گلخانه گوجه‌فرنگی حدود ۱/۷ برابر گلخانه توت‌فرنگی است. چنین تحلیل‌هایی برای برنامه‌ریزی مدیریت تلفیقی آفات و تعیین نقاط کانونی آلودگی[۲] ارزشمند است (Li *et al.,* 2021; Zhang *et al.,* 2023).

مطالعات جدیدتر حتی به تشخیص در سطح گونه نیز ورود کرده‌اند که در مدیریت تلفیقی آفات اهمیت حیاتی دارد؛ زیرا گونه‌های مختلف یک جنس ممکن است مقاومت به سموم، توان انتقال ویروس و زیست‌شناسی کاملاً متفاوتی داشته باشند. Laekeman و همکاران (۲۰۲۵) با استفاده از مدل‌های YOLO11 و YOLO-NAS روی تصاویر غیرمیکروسکوپی تله‌های زرد، موفق به تفکیک دو گونه تریپس و دو گونه سفیدبالک با میانگین دقت ۷۹ تا ۸۹ درصد شدند. نکته برجسته این مطالعه، اثبات امکان تشخیص گونه‌ای با دوربین‌های معمولی و وضوح حداقل ۸۰ میکرومتر بود که راه را برای استفاده از گوشی‌های هوشمند یا ماژول‌های دوربین ارزان‌قیمت باز می‌کند. در کنار دقت مدل‌ها، چالش اصلی همچنان داده است؛ زیرا بسیاری از مدل‌ها روی تصاویر با پس‌زمینه ساده آموزش دیده‌اند و در شرایط نوری متغیر و تراکم بالای حشرات در گلخانه واقعی افت عملکرد می‌دهند. مجموعه‌داده‌هایی مانند WMC-Leafset معرفی‌شده توسط Prasad و Pushpa (۲۰۲۵) که ۳۲۰۰ تصویر با پس‌زمینه پیچیده و برگ‌های هم‌پوشان را شامل می‌شود، تلاشی برای پر کردن این شکاف داده‌ای است (Laekeman *et al.,* 2025; Prasad & Pushpa, 2025).

با این حال، مشابه حوزه بیماری‌ها، شکاف اصلی در تبدیل داده‌های پایش آفت به تصمیم مدیریتی است. در حالی که شمارش آفت به‌تنهایی یک خروجی مفید است، ارزش واقعی آن زمانی آشکار می‌شود که این شمارش با آستانه زیان اقتصادی[۳] تلفیق شده و به توصیه‌ای عملی مانند «اکنون زمان رهاسازی دشمن طبیعی است» یا «دریچه‌های سقف را برای کاهش ورود آفات ببندید» تبدیل شود. نمونهٔ شاخص در این زمینه، سامانه مبتنی بر هوش مصنوعی اشیاء ارائه‌شده توسط Rustia و همکاران (۲۰۲۲) است که با تحلیل روند افزایش روزانه جمعیت آفت، سطح هشدار و توصیه مدیریتی متناظر با آن را صادر می‌کند. این همان جهتی است که پژوهش‌های آینده باید به سوی آن حرکت کنند: از تشخیص صرف به سمت پیش‌بینی ریسک طغیان و مدیریت تلفیقی خودکار (Rustia *et al.,* 2022).

پایش تنش‌های غیرزیستی با بینایی ماشین

برخلاف بیماری‌ها و آفات که عوامل زیستی مشخصی دارند، تنش‌های غیرزیستی حاصل برهم‌کنش گیاه با شرایط محیطی مانند وضعیت آب، دما، تغذیه و شوری هستند. این تنش‌ها نه‌تنها عملکرد کمی و کیفی محصول را کاهش می‌دهند (مانند پوسیدگی گلگاه گوجه‌فرنگی بر اثر نوسان آبیاری و کمبود انتقال کلسیم، یا بدشکلی میوه خیار بر اثر تنش دمایی)، بلکه مستقیماً به تصمیم‌های مدیریتی روزانه گلخانه‌دار در مورد آبیاری، تهویه و کودآبیاری مرتبط‌اند. از این رو، پایش تنش‌های غیرزیستی با بینایی ماشین نسبت به پایش بیماری و آفت، به‌طور بالقوه پیوند نزدیک‌تری با مدیریت خودکار منابع دارد. پژوهش‌های این حوزه را می‌توان در دو گروه تنش‌های «آب ـ حرارت» و تنش‌های «تغذیه‌ای ـ یونی» بررسی کرد.

پایش تنش آب – حرارت. بخش عمده مطالعات بر تنش آبی و خشکی متمرکز است، زیرا کم‌آبی به‌سرعت بر بسته شدن روزنه‌ها، دمای برگ، تعرق و محتوای آب بافت اثر می‌گذارد. در میان سنسورها، تصویربرداری حرارتی یکی از مستقیم‌ترین پیوندها را با وضعیت آبی گیاه دارد؛ افزایش دمای تاج‌پوش معمولاً نشانه‌ای زودهنگام از کاهش تعرق پیش از پژمردگی آشکار است. Mertens و همکاران (۲۰۲۳) در یک پلتفرم فنوتایپینگ خودکار، از ترکیب تصویربرداری حرارتی و فراطیفی برای برآورد شاخص‌های فیزیولوژیک مانند شاخص تنش آبی گیاه و نرخ تعرق استفاده کردند. نتایج آن‌ها نشان داد که این شاخص‌ها

۱- Anchor Boxes ۲- Hotspot ۳- Economic Threshold

می‌توانند وضـــعیت آبی گیاه را بســـیار دقیق‌تر از اندازه‌گیری ســـاده دمای برگ منعکس کنند و تخمین تعرق را برای ورود به مدل‌های تصـــمیم‌گیری آبیاری ممکن ســـازند. در همین راســـتا، Xia و همکاران (۲۰۲۱) با اســـتفاده از طیف مرئی ـ نزدیک‌به‌فروسـرخ و الگوریتم‌های یادگیری ماشـین در بسـتر رایانش ابری، توانسـتند سـطوح مختلف تنش آبی را در گوجه‌فرنگی گلخانه‌ای با دقت بالا طبقه‌بندی کنند و نشـــان دهند که چنین روش‌هایی در مقیاس داده بزرگ می‌توانند به ســـامانه‌های تصمیم‌یار آبیاری متصل شوند (Mertens *et al.,* 2023; Xia *et al.,* 2021).

در کنار سـنسـورهای پیشـرفته، پژوهش‌هایی نیز به دنبال راهکارهای سـاده‌تر با دوربین‌های رنگی متداول بوده‌اند. Chen و همکاران (۲۰۲۵) با توســعه مدل YOLOv8-ECS توانســتند برگ‌های پژمرده خیار را در شــرایط واقعی گلخانه با چالش‌هایی مانند پس‌زمینه سبز، هم‌پوشانی برگ‌ها و نور متغیر با دقت ۴/۹۷ درصد تشخیص دهند. اگرچه پژمردگی یک نشانه نسبتاً دیرتر از تغییرات روزنه‌ای است، اما سرعت، هزینه پایین و امکان اجرای بلادرنگ این روش آن را به گزینه‌ای عملی برای هشدار سریع در گلخانه‌های تجاری تبدیل می‌کند. در سـطح فنوتایپینگ پیشـرفته نیز، Li و همکاران (۲۰۲۶) با اسـتفاده از تصـویربرداری فراطیفی و مدل‌های مبتنی بر ترنسفورمر، شاخص جامع تحمل خشکی را در ژرم‌پلاسم چای پیش‌بینی کردند و نشان دادند که نسـل جدید معماری‌های یادگیری عمیق می‌تواند از طبقه‌بندی سـاده تنش فراتر رفته و ارزیابی کمّی از تحمل به خشـکی ارائه دهد. همچنین، Das Choudhury و همکاران (۲۰۲۴) رویکردی مبتنی بر توالی‌های تصـویری اتوفلورسـانس را برای پایش تنش خشـــکی در طول زمان به‌کار بردند و شـــاخص‌های پویایی مانند «میانگین متحرک درصـــد بافت تحت تنش» را تعریف کردند. چنین شـــاخص‌های زمانی، نســـبت به یک تصـــویر منفرد، برای طراحی هشـــدارهای زودهنگام و پیش‌بینی روند تنش بســـیار مناسب‌تر هستند (Chen *et al.,* 2025; Li *et al.,* 2026; Das Choudhury *et al.,* 2024).

تمامی این پژوهش‌ها نشان می‌دهند که پایش تنش آبی با بینایی ماشین دیگر در سطح تشخیص «تنش هست/نیست» متوقف نمانده، بلکه به سمت برآورد کمیت‌های فیزیولوژیک مانند تعرق، هدایت روزنه‌ای و شاخص تنش آبی حرکت کرده است. این خروجی‌ها می‌توانند با اتصال به سیستم‌های آبیاری هوشمند، امکان تنظیم پویای دور و حجم آبیاری را بر اساس نیاز واقعی گیاه فراهم آورند.

پایش تنش تغذیه‌ای – یونی. در ســـامانه‌های کشـــت بدون خاک و کودآبیاری که بخش قابل توجهی از گلخانه‌های مدرن را تشـکیل می‌دهند، کمبود عناصـر غذایی، مسـمومیت و شـوری می‌تواند بسـیار سـریع‌تر از آنچه تصـور می‌شـود به اختلال رشـد و کاهش کیفیت منجر شود. کمبود نیتروژن، آهن، منگنز یا کلسیم هر یک الگوی کلروز و نکروز متفاوتی روی برگ ایجاد می‌کنند که تشخیص سریع آن برای اصلاح محلول غذایی ضروری است. Elvanidi و همکاران (۲۰۱۸) با استفاده از طیف‌سنجی بازتابی در گوجه‌فرنگی بدون خاک، شاخص جدیدی به نام BANI برای برآورد غلظت نیتروژن برگ توسعه دادند و به همبسـتگی ۰/۹۶ با مقادیر اندازه‌گیری‌شـده دسـت یافتند. چنین شـاخصـی می‌تواند جایگزین آزمون‌های مخرب برگ شـده و مبنایی برای تنظیم خودکار غلظت نیتروژن در محلول غذایی باشد (Elvanidi *et al.,* 2018).

Navarro و همکاران (۲۰۲۲) با بررسـی گیاه شـاهی وحشـی، نشـان دادند که تصـویربرداری فراطیفی قادر اسـت تنش‌های زیسـتی (فوزاریوم[1] و ریزوکتونیا[2]) و غیرزیسـتی (کم‌آبی و شـوری) را که نشانه‌های ظاهری مشابهی دارند، از یکدیگر تفکیک کند و باندهای مؤثر در این تفکیک را شـــناســـایی نماید. این قابلیت برای مدیریت دقیق گلخانه اهمیت زیادی دارد، زیرا علت واقعی کاهش شادابی گیاه ممکن است بیماری ریشه باشد یا شوری بستر، و انتخاب اقدام اصلاحی کاملاً به تشخیص درست بستگی دارد. حتی در مسـیرهای غیرتصـویری، مطالعاتی مانند کار Tran و همکاران (۲۰۲۴) با اسـتفاده از پتانسـیل الکتریکی سـاقه گوجه‌فرنگی، توانسته‌اند کمبود عناصر منگنز، آهن، نیتروژن و کلسیم را با دقت‌هایی بین ۷۸ تا ۸۹ درصد و پیش از ظهور علائم بصـری تشـخیص دهند، که نشـان‌دهنده آن اسـت سـامانه‌های چندحسـگری فیزیولوژیک نیز می‌توانند مکمل قدرتمندی برای بینایی ماشین در پایش سلامت تغذیه‌ای باشند (Navarro *et al.,* 2022; Tran *et al.,* 2024).

در مجموع، پژوهش‌های حوزه تنش‌های غیرزیستی با بینایی ماشین نشان می‌دهند که این حوزه از تشخیص صرف «گیاه تحت تنش» فراتر رفته و در حال تولید شاخص‌های کمّی فیزیولوژیک است که ذاتاً با مدیریت آب، تغذیه و اقلیم گره خورده‌اند.

۱- *Fusarium* ۲- *Rhizoctonia*

با این حال، هنوز این خروجی‌ها به‌طور نظام‌مند به آستانه‌های تصمیم‌گیری برای اصلاح دور آبیاری، فرمول محلول غذایی یا تنظیم رطوبت متصل نشده‌اند. پر کردن این فاصله، گام بعدی و ضروری برای تحقق گلخانه‌های واقعاً هوشمند و سلامت‌محور خواهد بود.

پیش‌بینی خطر و هشدار زودهنگام: گامی فراتر از تشخیص

تشخیص اینکه یک برگ در لحظه آلوده است یا یک بوته در حال حاضر تحت تنش آبی قرار دارد، برای مدیریت روزمره گلخانه ارزشمند اما ناکافی است. در عمل، پرسش اصلی یک گلخانه‌دار یا مدیر تولید این است: «با توجه به وضعیت فعلی گیاهان و روند تغییرات، چند ساعت یا چند روز دیگر به نقطه بحران می‌رسم و اکنون چه اقدامی باید انجام دهم تا از خسارت جلوگیری شود؟» پاسخ به این پرسش مستلزم وجود یک لایه پیش‌بینی‌کننده و هشداردهنده است که وضعیت سلامت گیاه را نه فقط در زمان حال، بلکه در افق زمانی مشخصی پیش‌بینی کرده و آن را به یک سطح خطر قابل اقدام ترجمه کند.

با این حال، مرور نظام‌مند ما نشان می‌دهد که بخش عمده ادبیات موجود در پایش سلامت گیاه با بینایی ماشین، هنوز در گام نخست یعنی «تشخیص وضعیت فعلی» متوقف مانده است. از میان ۴۴ مطالعه تحلیل‌شده در این مقاله، تنها ۵ مطالعه به‌طور مشخص به مفهوم پیش‌بینی زمانی، هشدار زودهنگام یا تحلیل ریسک آینده نزدیک شده‌اند. این اختلاف فاحش، بیانگر یک شکاف مهم در ادبیات است: دانش فنی برای تشخیص لحظه‌ای نسبتاً بالغ شده، اما تبدیل این تشخیص به یک ابزار تصمیم‌یار که بگوید «تا ۴۸ ساعت آینده احتمال پژمردگی بالای ۸۰ درصد است»، هنوز در مراحل آغازین قرار دارد.

نزدیک‌ترین نمونه‌های موجود به هشدار زودهنگام، پژوهش‌هایی هستند که موفق به تشخیص بیماری یا تنش پیش از بروز علائم قابل مشاهده شده‌اند. برای مثال، Chen و همکاران (۲۰۲۴) نشان دادند که تصویربرداری فلورسانس کلروفیل می‌تواند برگ‌های خیار آلوده به سفیدک داخلی را حدود سه روز پیش از ظهور علائم ظاهری با دقت نزدیک به ۹۵ درصد شناسایی کند. این «پنجره پیش‌آگاهی» سه‌روزه، در یک گلخانه تجاری فرصتی طلایی برای اعمال مداخلات پیش‌گیرانه مانند کاهش نقطه تنظیم رطوبت، افزایش تهویه، یا حذف موضعی کانون‌های آلودگی پیش از گسترش بیماری فراهم می‌کند. با این وجود، باید توجه داشت که این دستاورد هنوز یک «تشخیص زودهنگام» است، نه یک «پیش‌بینی» کامل؛ زیرا مدل، وضعیت پنهان فعلی را آشکار می‌کند، اما مسیر آینده بیماری یا نرخ گسترش آن را تخمین نمی‌زند. برای تبدیل چنین خروجی‌هایی به هشدار عملیاتی، لازم است احتمال آلودگی، روزهای پس از تلقیح، شدت بالقوه و عوامل محیطی مساعدکننده (مانند مدت ترشدگی برگ و دما) در یک مدل خطر دینامیک ادغام شوند (Chen *et al.*, 2024).

در حوزه بیماری‌ها، تخمین شدت نیز می‌تواند پلی به سوی هشدار باشد. در پژوهشی، Wspanialy و Moussa (۲۰۲۰) نشان دادند که مدل‌های یادگیری عمیق می‌توانند سطح آلوده برگ به بیماری را برآورد کنند. این شاخص نسبت به برچسب دودویی سالم/بیمار اطلاعات بیشتری برای ردیابی روند بیماری در طول زمان به دست می‌دهد. اگر شدت بیماری هر ۲۴ ساعت یک‌بار پایش شود و روند افزایشی آن از یک آستانه مشخص فراتر رود، می‌توان یک هشدار برای مداخله صادر کرد. اما تا زمانی که این شدت‌سنجی به‌صورت سری زمانی تحلیل نشود، همچنان در حد یک ارزیابی مقطعی باقی می‌ماند (Wspanialy & Moussa, 2020).

در پایش تنش‌های غیرزیستی، پژوهش‌هایی که مستقیماً متغیرهای فیزیولوژیک مانند تعرق، شاخص تنش آبی گیاه یا دمای تاج‌پوش را برآورد می‌کنند، ذاتاً برای هشدار زودهنگام مناسب‌تر هستند، زیرا این متغیرها ساعت‌ها تا روزها پیش از پژمردگی آشکار تغییر می‌کنند. مطالعه Mertens و همکاران (۲۰۲۳) با استفاده از ترکیب دوربین‌های حرارتی و فراطیفی در یک پلتفرم فنوتایپینگ خودکار، توانست نرخ تعرق و شاخص‌های تنش آبی را به‌طور پیوسته پایش کند. چنین داده‌هایی اگر به‌صورت زنده به یک مدل تصمیم‌گیری متصل شوند، می‌توانند اعلام کنند که «گیاه در ۲۴ ساعت گذشته به‌طور مداوم تعرقی پایین‌تر از حد بهینه داشته و روند کاهشی است؛ ضروری است آبیاری و رطوبت نسبی بازبینی شود». Sun و همکاران (۲۰۲۳) نیز نشان دادند که ترکیب تصاویر مرئی و حرارتی می‌تواند صفاتی مانند نرخ فتوسنتز و هدایت روزنه‌ای را تخمین بزند؛ صفاتی که برای ساخت یک شاخص ریسک فیزیولوژیک پیوسته ایده‌آل هستند (Mertens *et al.*, 2023; Sun *et al.*, 2023).

نوآوری مهمی که در مطالعات اخیر دیده می‌شود، حرکت از تحلیل یک تصویر منفرد به تحلیل توالی‌های تصویری در طول زمان است. Das Choudhury و همکاران (۲۰۲۴) به‌جای اتکا به یک عکس، از سری‌های زمانی تصاویر اتوفلورسانس برای

فنوتایپینگ تنش خشکی استفاده کردند و شاخص‌های پویایی مانند «درصد بافت تحت تنش» و میانگین متحرک آن را تعریف نمودند. این رویکرد تغییر تدریجی و پیش‌رونده سلامت گیاه را به تصویر می‌کشد و پایه بسیار محکم‌تری برای پیش‌بینی آینده نسبت به طبقه‌بندی تک‌زمانه فراهم می‌آورد (Das Choudhury *et al.*, 2024).

در حوزه آفات، مفهوم هشدار زودهنگام ماهیتاً با روند جمعیت، آستانه اقتصادی و شناسایی نقاط کانونی گره خورده است. نمونه برجسته در این زمینه، کار Rustia و همکاران (۲۰۲۲) است که با راه‌اندازی یک سامانه مبتنی بر هوش مصنوعی اشیا، تصاویر تله‌های چسبنده، شمارش آفات و داده‌های محیطی را در چندین گلخانه و در برخی موارد تا ۱۳۶۸ روز پایش کردند. نکته کلیدی این مطالعه آن بود که خروجی سامانه به شمارش آفت محدود نماند، بلکه روند افزایش روزانه جمعیت تحلیل و به سطوح هشدار (مانند «آبی: عادی»، «زرد: افزایش توجه»، «قرمز: مداخله ضروری») تبدیل شد. این سطح از بلوغ دقیقاً همان چیزی است که مدیریت تلفیقی آفات در گلخانه‌های تجاری به آن نیاز دارد: هشداری که نه فقط بگوید چند حشره وجود دارد، بلکه بر اساس آستانه اقتصادی مشخص کند «اکنون باید دشمن طبیعی رهاسازی شود» یا «دریچه‌های سقف برای جلوگیری از ورود بیشتر بسته شوند» (Rustia *et al.*, 2022).

بر اساس شواهد بررسی‌شده، می‌توان چهار سطح بلوغ را برای گذار از تشخیص ساده به هشدار زودهنگام تصمیم‌پذیر تعریف کرد:

۱. تشخیص زودهنگام: مدل قادر است وضعیت غیرسالم (بیماری، آفت یا تنش) را زودتر از چشم انسان و در مراحل اولیه تشخیص دهد (مانند شناسایی سفیدک پیش از ظهور کپک).
۲. خروجی کمّی سلامت: مدل به‌جای برچسب سالم/بیمار، یک مقدار عددی پیوسته تولید می‌کند (مانند درصد شدت بیماری، شاخص تنش آبی، شماره جمعیت آفت).
۳. پایش زمانی و روندیابی: خروجی مدل در فواصل منظم اندازه‌گیری و روند تغییرات آن تحلیل می‌شود تا مشخص شود وضعیت رو به بهبود است یا وخامت.
٤. هشدار تصمیم‌پذیر: مدل با تلفیق روند سلامت گیاه، آستانه‌های بحرانی از پیش‌تعریف‌شده و عوامل محیطی، سطح خطر را تعیین کرده و یک اقدام مدیریتی مشخص را پیشنهاد می‌دهد (مثلاً «دور آبیاری را ۲۰ درصد کاهش دهید»).

در حال حاضر، اکثر مطالعات حوزه بیماری و تنش در سطح یک و دو قرار دارند. مطالعات انگشت‌شماری مانند کار Rustia و همکاران (۲۰۲۲) در حوزه آفات، و تا حدی Das Choudhury و همکاران (۲۰۲۴) در تنش خشکی، توانسته‌اند به سطح سه و چهار نزدیک شوند. برای پر کردن این شکاف، ضروری است که پژوهش‌های آینده، خروجی‌های بینایی ماشین را به‌جای برچسب‌های دودویی، در قالب شاخص‌های پیوسته خطر (Risk Score)، احتمال وقوع خسارت یا زمان تخمینی باقی‌مانده تا عبور از آستانه بحرانی ارائه دهند. چنین شاخص‌هایی نه‌تنها برای تصمیم‌گیری آگاهانه‌تر توسط مدیر گلخانه مفیدند، بلکه پیش‌نیاز اساسی برای ورود اطلاعات سلامت گیاه به حلقه‌های کنترل خودکار و پیش‌گیرانه به شمار می‌روند.

مدیریت هوشمند و کنترل پیش‌گیرانه گلخانه: از اقلیم و آب تا سلامت گیاه

در یک گلخانه تجاری، تصمیم‌های مدیریتی روزانه مانند تنظیم دما، رطوبت، تهویه، آبیاری و تغذیه، همگی بر سلامت و عملکرد گیاه اثر مستقیم دارند. اگر این تصمیم‌ها صرفاً بر اساس تقویم زمانی ثابت یا حفظ نقطه تنظیم از پیش‌تعیین‌شده اتخاذ شوند، بدون آنکه وضعیت واقعی گیاه در نظر گرفته شود، دو پیامد نامطلوب محتمل است: یا منابع (آب، انرژی، کود) بیش از نیاز مصرف می‌شوند، یا گیاه به‌طور خاموش وارد مرحله تنش شده و پیش از آشکارشدن علائم، خسارت می‌بیند. بنابراین، هدف ایده‌آل در گلخانه هوشمند، حرکت از کنترل صرف محیط به سمت «مدیریت پیش‌گیرانه» است؛ مدیریتی که با پیش‌بینی وضعیت آینده گیاه و گلخانه، اقدامات کنترلی را پیش از وقوع بحران اعمال می‌کند.

در دهه اخیر، دسته‌ای از روش‌های کنترل هوشمند موسوم به کنترل پیش‌بین در گلخانه توسعه یافته‌اند. این روش‌ها برخلاف کنترل‌کننده‌های ساده روشن/خاموش، قادرند رفتار آینده گلخانه را در یک افق زمانی پیش‌بینی کرده و با درنظرگرفتن محدودیت‌های عملی (مانند ظرفیت سیستم گرمایش یا حداکثر دبی آبیاری)، بهترین مسیر کنترلی را برگزینند. مرور ما نشان می‌دهد که ادبیات این حوزه از نظر روش‌های کنترل، مدیریت انرژی و برخورد با عدم‌قطعیت‌ها پیشرفت قابل توجهی داشته، اما

همچنان عمدتاً بر متغیرهای محیطی متمرکز است. در ادامه، این پژوهش‌ها را بر اساس خروجی باغبانی‌شان در سه محور مدیریت اقلیم، مدیریت آب و تغذیه، و کنترل سلامت‌محور تحلیل می‌کنیم.

کنترل هوشمند اقلیم برای کاهش تنش‌های محیطی

بخش عمده‌ای از مطالعات کنترل هوشمند در گلخانه، با هدف نگه‌داشتن دما، رطوبت و CO_2 در محدوده مطلوب و کاهش مصرف انرژی انجام شده‌اند. این کنترل اقلیم اگرچه در نگاه اول صرفاً محیط‌محور به نظر می‌رسد، اما مستقیماً با سلامت گیاه پیوند دارد: دمای بالاتر از آستانه تحمل، تنش گرمایی و کاهش فتوسنتز را به دنبال دارد؛ رطوبت نسبی بیش از حد، پنجره مساعد برای شیوع بیماری‌های قارچی را می‌گشاید؛ و کمبود CO_2 رشد را محدود می‌کند. بنابراین، یک کنترل اقلیم دقیق، خود نوعی مدیریت پیش‌گیرانه سلامت است.

برای نمونه، Mahmood و همکاران (۲۰۲۳) یک چارچوب کنترل پیش‌بین مقاوم داده‌محور را برای تنظیم دمای گلخانه توسعه دادند که با وجود عدم‌قطعیت‌های جوی، توانست علاوه بر حفظ پایداری دما، مصرف انرژی را ۹.۶۷ درصد در زمستان و ۲۳.۶۱ درصد در تابستان کاهش دهد. این کاهش مصرف انرژی در گلخانه‌های مناطق خشک و نیمه‌خشک، که هزینه گرمایش و سرمایش بخش بزرگی از هزینه تولید است، اهمیت اقتصادی بالایی دارد. همچنین، Chen و You (۲۰۲۱) نشان دادند که در شرایط اقلیمی سخت (مانند تابستان‌های داغ یا زمستان‌های سرد)، استفاده از مدل‌های داده‌محور مقاوم می‌تواند از نوسانات شدید دمایی جلوگیری کرده و گیاه را حتی در بدترین شرایط آب‌وهوایی از تنش گرمایی یا سرمازدگی حفظ کند (Mahmood *et al.*, 2023; Chen & You, 2021).

در سطحی کلان‌تر، مدیریت هم‌زمان منابع نیز مورد توجه قرار گرفته است. Lin و همکاران (۲۰۲۶) با ارائه یک چارچوب کنترل سلسله‌مراتبی، مدیریت انرژی، آب، کربن و غذا را در یک گلخانه مجهز به پنل‌های فتوولتائیک و باتری یکپارچه کردند. آن‌ها نشان دادند که راهبرد «حداقل‌سازی هزینه کل» با درنظرگرفتن هم‌زمان مصرف انرژی، تأمین CO_2 و انتشار کربن، می‌تواند هزینه‌ها را تا ۸۱ درصد نسبت به راهبرد حداقل‌سازی صرف انرژی کاهش دهد. چنین رویکردهایی به‌ویژه برای گلخانه‌های مدرنی که به دنبال پایداری اقتصادی و زیست‌محیطی هستند، الگویی ارزشمند است (Lin *et al.*, 2026).

مدیریت بهینه آب و تغذیه با کنترل پیش‌گیرانه

پس از اقلیم، آبیاری و تغذیه دو عامل تعیین‌کننده دیگر در سلامت و عملکرد گیاهان گلخانه‌ای هستند. کنترل هوشمند در این حوزه به‌دنبال آن است که به‌جای تقویم ثابت آبیاری یا فرمول از پیش‌تعیین‌شده کود، نیاز واقعی گیاه را مبنای تصمیم‌گیری قرار دهد. Abioye و همکاران (۲۰۲۱) یک کنترل‌کننده پیش‌بین برای آبیاری دقیق گلخانه توسعه دادند که روی سخت‌افزار کم‌هزینه Raspberry Pi اجرا می‌شد. آزمایش‌های آن‌ها روی کشت طالبی نشان داد که این سامانه طی ۲۱ روز توانست حدود ۳۰ درصد در مصرف آب صرفه‌جویی کند، بدون آنکه گیاه دچار تنش آبی شود. این نتیجه از منظر باغبانی و در شرایط بحران آب، نشان‌دهنده آن است که اتصال یک مدل پیش‌بین به سامانه آبیاری می‌تواند مصرف آب را به‌طور محسوسی کاهش دهد. در مطالعه‌ای دیگر، Abioye و همکاران (۲۰۲۳) همین رویکرد را برای آبیاری قطره‌ای صرفه‌جویانه پیاده‌سازی کردند و نتایج را با روش‌های رایج مبتنی بر تبخیر-تعرق مرجع مقایسه کردند (Abioye *et al.*, 2021; Abioye *et al.*, 2023).

به سوی کنترل یکپارچه سلامت‌محور

پیشرفت‌هایی که در دو بخش قبل مرور شد، عمدتاً از نوع «گیاه‌آگاه»[1] هستند؛ یعنی بهره‌وری گیاه (رشد، فتوسنتز یا عملکرد) را در تابع هدف کنترل لحاظ کرده‌اند. اما «سلامت‌محور»[2] بودن کنترل، گامی فراتر است: در این حالت، شاخص‌های مستقیم سلامت مانند شدت بیماری، احتمال تنش آبی، فشار آفت یا ریسک پژمردگی نیز به‌عنوان ورودی یا قید به کنترل‌کننده داده می‌شود. ماتریس شواهد این مرور نشان می‌دهد که از ۱۶ مطالعه دارای مؤلفه کنترلی، تنها پنج مطالعه واجد چنین رویکردی بوده‌اند؛ به این معنا که کنترل سلامت‌محور همچنان در مراحل آغازین خود قرار دارد.

نخستین سطح یکپارچگی سلامت محور، وارد کردن رشد یا فتوسنتز در مسئله کنترل است. Achour و همکاران (۲۰۲۰) با طراحی یک کنترل‌کننده نظارتی برای مدیریت محیط داخلی گلخانه در چارچوب پیوند غذا-انرژی-آب، تابع هدفی را تعریف

۱- Plant-Aware
۲- Health-Aware

کردند که هم‌زمان نرخ فتوسنتز را بیشینه کرده و مصرف آب و انرژی را کمینه کند. در این رویکرد، گیاه دیگر صرفاً دریافت‌کننده منفعل شرایط محیطی نیست، بلکه وضعیت فیزیولوژیک آن به‌طور فعال در تصمیم‌گیری وارد می‌شود. همچنین، Wadinger و همکاران (۲۰۲۵) یک چارچوب کنترل پیش‌بین اقتصادی برای گلخانه کاهو ارائه کردند که با ترکیب مدل رشد گیاه و مدل اقلیم، عملکرد محصول، هزینه انرژی و هزینه اجتماعی CO_2 را به‌طور هم‌زمان بهینه می‌کرد. این مطالعات اگرچه از شاخص‌های مستقیم سلامت (مانند شدت بیماری یا شاخص تنش آبی) استفاده نمی‌کنند، اما در مقایسه با کنترل‌کننده‌های صرفاً محیط‌محور، گامی مهم به سوی گیاه‌محوری هستند (Achour *et al.,* 2020; Wadinger *et al.,* 2025).

گام بعدی، کنترل مبتنی بر به‌روزرسانی مداوم پارامترهای گیاه است. Valábek و همکاران (۲۰۲۵) نشان دادند که با استفاده از تحلیل حساسیت و اندازه‌گیری‌های محدود فیزیولوژیک می‌توان پارامترهای مدل رشد کاهو را به‌صورت برخط تصحیح کرد و کنترل‌کننده را با وضعیت واقعی گیاه هماهنگ ساخت. این ایده برای کنترل سلامت‌محور اهمیت زیادی دارد، زیرا سلامت گیاه در طول فصل پویا است و کنترل‌کننده باید خود را با تغییرات واقعی (نه فقط مدل‌های تئوریک) تطبیق دهد.

در سطح معماری سامانه، Hu و You (۲۰۲۳) چارچوبی مبتنی بر شبکه‌های عصبی آگاه از فیزیک و کنترل پیش‌بین مقاوم ارائه کردند که اقلیم داخلی، وضعیت محصول و ورودی‌های کنترلی (گرمایش، تهویه، CO_2، آبیاری و کوددهی) را در یک مدل دیجیتال یکپارچه می‌ساخت. نتایج آن‌ها نشان داد که این مدل دقیق‌تر می‌تواند نقض محدودیت‌ها را کاهش داده و نسبت انرژی به عملکرد را بهبود بخشد. هرچند در این مطالعه نیز خروجی مستقیم بینایی ماشین (مانند تصویر یک برگ بیمار) به کنترل وارد نشده، اما معماری آن به‌گونه‌ای است که می‌توان در آینده شاخص‌های سلامت گیاه را به‌عنوان متغیر حالت جدید به آن افزود (Valábek *et al.,* 2025; Hu & You, 2023).

آخرین سطح یکپارچگی، در نظر گرفتن عدم‌قطعیت و ریسک سلامت در قالب محدودیت‌های احتمالاتی است. سلامت گیاه ذاتاً با عدم‌قطعیت همراه است: خطای مدل‌های تشخیص، نوسانات محیطی غیرقابل پیش‌بینی، و تفاوت میان رقم‌های گیاهی همگی بر احتمال وقوع تنش اثر می‌گذارند. Svensen و همکاران (۲۰۲۴) با توسعه یک روش کنترل پیش‌بین تصادفی با قیود احتمالاتی، نشان دادند که می‌توان این عدم‌قطعیت‌ها را به‌صورت ریاضی فرموله کرد تا کنترل‌کننده با احتمال بالایی (مثلاً ۹۵ درصد) تضمین کند که گیاه از آستانه‌های بحرانی عبور نخواهد کرد. هرچند در این پژوهش از شاخص سلامت بصری استفاده نشده، اما بستر ریاضی آن برای کنترل سلامت‌محور ایده‌آل است، زیرا می‌تواند قیودی مانند «احتمال وقوع پژمردگی در ۲۴ ساعت آینده کمتر از پنج درصد باشد» را در تصمیم‌های آبیاری و اقلیم بگنجاند (Svensen *et al.,* 2024).

شکاف اصلی: از کنترل موازی تا کنترل متصل

مرور این بخش نشان می‌دهد که دو مسیر «پایش سلامت با بینایی ماشین» و «کنترل هوشمند گلخانه» تا حد زیادی به‌صورت مستقل از یکدیگر رشد کرده‌اند. همان‌طور که در بخش‌های پیشین نشان داده شد، بینایی ماشین اکنون می‌تواند بیماری، آفت و تنش را با دقت بالا تشخیص داده و حتی به تشخیص پیش‌نشانگانی نزدیک شود. از سوی دیگر، کنترل‌کننده‌های پیش‌بین قادرند دما، رطوبت، CO_2، انرژی و آبیاری را با لحاظ‌کردن محدودیت‌ها و عدم‌قطعیت‌ها مدیریت کنند. با این حال، در اکثر قریب به اتفاق موارد، خروجی سامانه‌های بینایی ماشین (مانند شاخص تنش آبی، شدت بیماری یا شماره آفت) به‌عنوان ورودی وارد کنترل‌کننده نمی‌شود. به بیان دیگر، حلقه «سیگنال سلامت گیاه ← پیش‌بینی ریسک ← اقدام کنترلی» هنوز بسته نشده است.

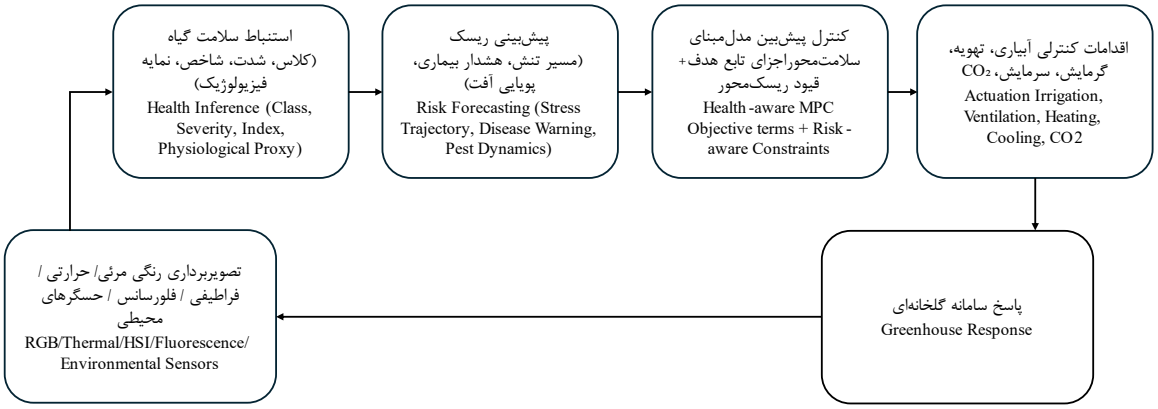

شکل ۴- چرخه مفهومی مدیریت پیش‌گیرانه و سلامت‌محور در گلخانه هوشمند. این نمودار، شکاف اصلی شناسایی‌شده در مرور (فقدان اتصال میان پایش سلامت و کنترل) و مسیر پیشنهادی برای پر کردن آن را نشان می‌دهد. حلقه بیرونی، مؤلفه‌های یک سامانه یکپارچه سلامت‌محور را شامل می‌شود: (۱) پایش پیوسته سلامت گیاه با استفاده از حسگرهای بینایی ماشین (RGB، حرارتی، فراطیفی، فلورسانس و چندسنسوری)، (۲) تبدیل داده‌های خام به شاخص‌های کمّی سلامت (مانند شاخص تنش آبی، شدت بیماری، فشار آفت و امتیاز ریسک)، (۳) پیش‌بینی روند سلامت و تولید هشدار زودهنگام بر اساس مدل‌های پیش‌بینی‌کننده، و (۴) اعمال اقدامات کنترلی پیش‌گیرانه (تنظیم دما، رطوبت، تهویه، آبیاری و تغذیه) توسط کنترل‌کننده پیش‌بین. حلقه داخلی، چرخه پیوسته «پایش ← پیش‌بینی ← اقدام ← بازخورد» را نشان می‌دهد که گیاه را به‌عنوان متغیر مرکزی در تصمیم‌گیری‌های مدیریتی گلخانه قرار می‌دهد

Fig. 4. conceptual framework for preventive and health-aware management in smart greenhouses. This diagram illustrates the principal gap identified in this review (the disconnect between plant health monitoring and control) and the proposed pathway to bridge it. The outer loop depicts the components of an integrated health-aware system: (1) continuous plant health monitoring using computer vision sensors (RGB, thermal, hyperspectral, fluorescence, and multi-sensor fusion), (2) transformation of raw data into quantitative health indicators (e.g., CWSI, disease severity, pest pressure, and risk scores), (3) forecasting of health trajectories and generation of early warnings based on predictive models, and (4) execution of preventive control actions (adjustment of temperature, humidity, ventilation, irrigation, and nutrition) by a model predictive controller. The inner loop represents the continuous "monitor → predict → act → feedback" cycle, placing the plant as the central decision-making variable in greenhouse management.

برای بستن این حلقه، پژوهش‌های آینده باید چند مانع عملی را پشت سر بگذارند. نخست، مقیاس‌های زمانی حسگری و کنترل باید هماهنگ شوند: تصویربرداری ممکن است ساعتی یا روزانه باشد، در حالی که کنترل اقلیم در بازه‌های چند دقیقه‌ای عمل می‌کند. دوم، خروجی‌های بینایی ماشین اغلب طبقه‌بندی‌های کیفی (سالم/بیمار) هستند و باید به شاخص‌های کمّی پیوسته (مانند امتیاز ریسک یا کمبود تعرق) تبدیل شوند تا برای یک کنترل‌کننده عددی قابل استفاده باشند. سوم، مدل‌های هزینه-فایده باید توجیه اقتصادی نصب سنسورهای پیشرفته (مانند فراطیفی) را در گلخانه‌های تجاری نشان دهند. و چهارم، هنوز مجموعه‌داده‌های طولی و چندفصلی که تغییرات سلامت گیاه را همراه با داده‌های اقلیمی و اقدامات کنترلی ثبت کرده باشند، بسیار اندک است.

در مجموع، شواهد این مرور نشان می‌دهد که ادبیات کنونی از نظر ابزارهای منفرد (تشخیص و کنترل) غنی، اما از نظر اتصال این ابزارها به یک زنجیره منسجم سلامت‌محور، پراکنده است. مسیر رو به جلو، نه صرفاً افزایش دقت مدل‌های تشخیص یا پیچیده‌تر کردن کنترل‌کننده‌ها، بلکه طراحی یکپارچه سامانه‌هایی است که سلامت واقعی گیاه را به‌عنوان متغیر اصلی وارد چرخه تصمیم‌گیری و کنترل کنند. چنین سامانه‌هایی می‌توانند با پیش‌گیری به‌موقع از تنش‌ها و بیماری‌ها، مصرف آب، سموم و انرژی را کاهش داده و پایداری تولید در گلخانه‌های آینده را تضمین کنند.

نتیجه‌گیری و بحث

این مرور ساختاریافته با تحلیل ۴۴ مطالعه یکتا و ۵۳ تخصیص موضوعی در شش خوشه تحلیلی، تصویری روشن از وضعیت کنونی و خلأهای موجود در مسیر هوشمندسازی مدیریت سلامت گیاه در گلخانه‌ها ارائه داد. یافته‌ها نشان می‌دهد که ادبیات علمی در دو حوزه «پایش سلامت با بینایی ماشین» و «کنترل هوشمند اقلیم و منابع» به‌طور مستقل پیشرفت‌های چشمگیری داشته، اما زنجیره یکپارچه‌ای که این دو را به هم پیوند دهد، هنوز به بلوغ نرسیده است. در ادامه، سه شکاف بنیادین شناسایی‌شده به‌تفصیل بحث می‌شود.

شکاف نخست: از تشخیص به پیش‌بینی. بخش بزرگی از مطالعات بینایی ماشین، چه در حوزه بیماری، آفت و چه تنش‌های غیرزیستی، بر تشخیص وضعیت فعلی گیاه متمرکزند. در بیماری-بینایی ماشین، مدل‌ها معمولاً برگ را به‌عنوان «سالم» یا «بیمار» طبقه‌بندی می‌کنند؛ در آفت-بینایی ماشین، شمارش یا شناسایی آفت روی تله‌های چسبنده انجام می‌شود؛ و در تنش-بینایی ماشین، شاخصی مانند شاخص تنش آبی گیاه یا شدت پژمردگی تخمین زده می‌شود. این خروجی‌ها برای ارزیابی گذشته‌نگر و پایش مقطعی مفیدند، اما به پرسش اصلی مدیر گلخانه که «وضعیت تا فردا یا چند روز آینده چگونه خواهد شد؟» پاسخ نمی‌دهند. از میان ۴۴ مطالعه، تنها پنج مطالعه به پیش‌بینی زمانی، هشدار سطح خطر یا تحلیل روند آینده نزدیک شده‌اند. برای مثال، Chen و همکاران (۲۰۲۴) نشان دادند که می‌توان بیماری سفیدک داخلی را سه روز پیش از ظهور علائم تشخیص داد، و Rustia و همکاران (۲۰۲۲) ثابت کردند که تبدیل شمارش آفت به سطح هشدار و کانون آلودگی، ارزش عملیاتی سامانه را به‌شدت افزایش می‌دهد. با این حال، در بیشتر مطالعات، افق زمانی پیش‌بینی، آستانه مداخله، و زمان تخمینی باقی‌مانده تا خسارت تعریف نشده است. این خلأ باعث می‌شود خروجی سامانه‌های بینایی ماشین در حد «یک گزارش وضعیت» باقی بماند و نتواند مستقیماً جرقه یک اقدام مدیریتی را بزند.

شکاف دوم: غلبه کنترل محیط‌محور بر کنترل سلامت‌محور. در سوی دیگر، پژوهش‌های کنترل هوشمند گلخانه عمدتاً با محوریت تنظیم دما، رطوبت، CO_2، نور و مصرف انرژی توسعه یافته‌اند. این رویکرد منطقی و ضروری است، اما تحلیل ما نشان داد که از ۱۶ مطالعه دارای مؤلفه کنترلی، تنها پنج مطالعه واقعاً اهداف گیاه‌محور (مانند حداکثرسازی فتوسنتز یا رشد) را در تابع هدف خود گنجانده‌اند (Achour *et al.,* 2020; Wadinger *et al.,* 2025) و فقط پنج مطالعه قیود سلامت‌محور یا ریسک‌محور (مانند احتمال عبور از آستانه تنش) داشته‌اند (Svensen *et al.,* 2024). به بیان دیگر، بیشتر کنترل‌کننده‌های موجود، محیط رشد را برای یک «گیاه متوسط فرضی» تنظیم می‌کنند، نه برای گیاه واقعی که ممکن است در آن لحظه در آستانه پژمردگی، حمله آفت یا کمبود تغذیه باشد. این در حالی است که همانطور که در بخش‌های پیشین نشان داده شد، فناوری‌های بینایی ماشین اکنون قادرند وضعیت واقعی گیاه را با دقت بالایی منعکس کنند. بنابراین، شکاف اصلی در نبود کنترلر نیست، بلکه در استفاده نکردن از خروجی‌های سلامت گیاه به‌عنوان ورودی این کنترلرهاست.

شکاف سوم: فقدان یکپارچگی سیستماتیک میان پایش و کنترل. این شکاف که مهم‌ترین یافته مرور است، از رشد جزیره‌ای دو حوزه پایش و کنترل ناشی شده است. مطالعات بیماری-بینایی ماشین و تنش-بینایی ماشین شاخص‌های ارزشمندی مانند شدت بیماری، شاخص تنش آبی گیاه، تعرق، یا احتمال آلودگی تولید می‌کنند. از سوی دیگر، مطالعات کنترل پیش‌بین ابزارهای قدرتمندی برای مدیریت قیود و عدم‌قطعیت‌ها فراهم آورده‌اند. اما این دو مجموعه ابزار به‌ندرت در یک سامانه واحد ترکیب شده‌اند. برای مثال، Mertens و همکاران (۲۰۲۳) خروجی‌های نزدیک به شاخص سلامت و روند تنش را تولید می‌کنند، اما آن‌ها را وارد یک حلقه کنترل نمی‌کنند. در مقابل، Svensen و همکاران (۲۰۲۴) بستر ریاضی لازم برای کنترل ریسک را فراهم کرده‌اند، اما ورودی این بستر هنوز پارامترهای اقلیمی است، نه ریسک سلامت حاصل از پردازش تصویر. این جدایی به این معناست که حلقه «سیگنال سلامت - پیش‌بینی ریسک - اقدام کنترلی» که جوهره یک گلخانه واقعاً هوشمند و سلامت‌محور است، در هیچ‌یک از سامانه‌های بررسی‌شده به‌طور کامل پیاده‌سازی نشده است.

فراتر از این سه شکاف اصلی، یک شکاف عملیاتی نیز قابل مشاهده است. ۲۷ مطالعه از ۴۴ مطالعه در سطح پیاده‌سازی گلخانه‌ای یا بالاتر قرار داشتند که نشان می‌دهد ادبیات از فاز کاملاً آزمایشگاهی فاصله گرفته است. اما آمادگی برای استقرار تجاری همچنان محدود است. بسیاری از این مطالعات، یک مدل تشخیص یا کنترل را روی داده‌های گلخانه‌ای آزمون کرده‌اند،

اما یک سامانه کامل شامل تصویربرداری پیوسته، پردازش در لبه[1]، واسط کاربری ساده، هشدار با قابلیت اقدام، تصمیم‌یاری و بازخورد کنترلی خودکار ارائه نمی‌دهند. نمونه‌هایی مانند سامانه مبتنی بر هوش مصنوعی اشیا معرفی‌شده توسط Rustia و همکاران (۲۰۲۲) که پایش آفت را به هشدار و توصیه مدیریت تلفیقی آفات متصل کرده، از این نظر استثنا هستند و نشان می‌دهند که چنین یکپارچگی‌ای عملی است، اما هنوز به بیماری‌ها و تنش‌های غیرزیستی تعمیم نیافته است.

در مجموع، یافته‌های این مرور تأکید می‌کند که ادبیات هوشمندسازی گلخانه به جای کمبود الگوریتم‌های تشخیص یا نبود کنترل‌کننده‌های پیشرفته، از ضعف در اتصال این دو رنج می‌برد. مسیر آینده باید از توسعه جداگانه «بهترین مدل تشخیص» یا «پیچیده‌ترین کنترلر» به سمت طراحی چارچوب‌های یکپارچه‌ای تغییر جهت دهد که سلامت گیاه را به‌عنوان متغیر حالت وارد حلقه کنترل می‌کنند. جدول زیر این شکاف‌ها و مسیرهای پیشنهادی برای عبور از آن‌ها را به‌طور خلاصه ارائه می‌دهد.

جدول ۲- شکاف‌های پژوهشی کلیدی و مسیرهای پیشنهادی به سوی کنترل سلامت‌محور در گلخانه.

Table 2. Key research gaps and proposed pathways toward health-aware control in greenhouses.

شکاف پژوهشی کلیدی Key research gap	چالش اصلی Main challenge	وضعیت موجود Current state of knowledge	راهکار پیشنهادی Proposed approach	مطالعات پیشرو/نمونه‌های نزدیک به راهکار پیشنهادی Pioneering studies / studies closely aligned with the proposed approach
از تشخیص به پیش‌بینی From detection to prediction	عدم وجود افق زمانی در خروجی مدل‌های سلامت گیاه Lack of a temporal horizon in the outputs of plant-health models	۱۴ مطالعه تشخیص زودهنگام دارند، اما تنها پنج مطالعه خروجی پیش‌بینی‌کننده، هشدار روندی یا سطح خطر قابل اقدام ارائه می‌دهند. Fourteen studies provide early detection, but only five studies generate predictive outputs, trend-based warnings, or actionable risk levels.	توسعه مدل‌های پیش‌بینی ریسک برای تخمین احتمال، شدت و زمان وقوع تنش، بیماری یا طغیان آفت در افق‌های زمانی مشخص. Develop risk-prediction models to estimate the probability, severity, and timing of stress, disease, or pest outbreaks within defined temporal horizons.	Chen *et al.* (2024) و Rivera-Romero *et al.* (2025) در تشخیص پیش‌نشانگانی بیماری؛ Wspanialy and Moussa (2020) در تخمین شدت بیماری؛ Das Choudhury *et al.* (2024) در تحلیل توالی‌های تصویری و شاخص‌های پویای تنش؛ Rustia *et al.* (2022) در تبدیل روند جمعیت آفت به سطح هشدار مدیریتی. Chen *et al*. (2024) and Rivera-Romero *et al*. (2025) on pre-symptomatic disease detection; Wspanialy & Moussa (2020) on disease-severity estimation; Das Choudhury *et al*. (2024) on image-sequence analysis and dynamic stress indicators; Rustia *et al.* (2022) on translating pest-population trends into management-oriented warning levels.

۱- Edge computing

غلبه کنترل محیط‌محور Dominance of environment-oriented control	نادیده‌گرفتن سیگنال سلامت گیاه به‌عنوان ورودی کنترل Neglect of plant-health signals as control inputs	از ۱۶ مطالعه دارای مؤلفه کنترلی، فقط پنج مطالعه دارای اهداف گیاه‌محور یا قیود سلامت‌محور/ریسک‌محور هستند. Among the 16 studies with a control component, only five incorporated plant-aware objectives or health-/risk-aware constraints.	طراحی کنترل پیش‌بین مدل‌مبنا سلامت‌محور بر پایه شاخص سلامت، امتیاز ریسک، مسیر شدت بیماری، فشار آفت یا کمبود تعرق به‌عنوان متغیر حالت یا قید نرم/احتمالی. Design health-aware model predictive control frameworks in which health indices, risk scores, disease-severity trajectories, pest pressure, or transpiration deficits are used as state variables or as soft/probabilistic constraints.	Achour *et al.* (2020) در وارد کردن فتوسنتز به تابع هدف کنترل؛ Wadinger *et al.* (2025) در ترکیب مدل رشد گیاه با کنترل پیش‌بین اقتصادی؛ Valábek *et al.* (2025) در به‌روزرسانی تطبیقی پارامترهای رشد گیاه؛ Svensen *et al.* (2024) در استفاده از قیود احتمالاتی برای مدیریت عدم‌قطعیت در کنترل گلخانه. Achour *et al*. (2020) on incorporating photosynthesis into the control objective function; Wadinger *et al.* (2025) on integrating plant-growth models with economic model predictive control; Valábek *et al.* (2025) on adaptive updating of plant-growth parameters; Svensen *et al.* (2024) on using probabilistic constraints to manage uncertainty in greenhouse control.
فقدان یکپارچگی سیستماتیک Lack of systematic integration	رشد جزیره‌ای حوزه‌های پایش سلامت و کنترل پیش‌بین Fragmented development of health-monitoring and predictive-control domains	زنجیره «سیگنال سلامت گیاه ← پیش‌بینی ریسک ← اقدام کنترلی» در هیچ سامانه عملیاتی به‌طور کامل بسته نشده است. The chain “plant-health signal → risk prediction → control action” has not yet been fully closed in any operational system.	ایجاد چارچوب‌های یکپارچه عملیاتی با پروتکل‌های تبادل داده برای هماهنگ‌سازی مقیاس‌های زمانی حسگری، پیش‌بینی، تصمیم‌گیری و کنترل. Establish integrated operational frameworks with data-exchange protocols to	Rustia *et al.* (2022) به‌عنوان نمونه نزدیک در اتصال پایش آفت به هشدار و توصیه مدیریتی؛ Hu and You (2023) در یکپارچه‌سازی مدل محصول، اقلیم و کنترل پیش‌بین؛ Mertens *et al.* (2023) در تولید شاخص‌های فیزیولوژیک قابل استفاده برای کنترل؛ Svensen *et al.* (2024) به‌عنوان بستر ریاضی مناسب برای تبدیل ریسک سلامت به قید کنترلی. Rustia *et al.* (2022) as a closely related example linking pest monitoring to warning

	synchronize the temporal scales of sensing, prediction, decision-making, and control.	generation and management recommendations; Hu and You (2023) on integrating crop, climate, and model predictive control models; Mertens et al. (2023) on generating physiological indicators that can be used for control; Svensen *et al*. (2024) as a suitable mathematical framework for translating health-related risk into control constraints.

چشم‌انداز کاربرد در گلخانه‌های ایران

یافته‌های این مرور برای شرایط ایران اهمیتی دوچندان دارد. گلخانه‌های تجاری کشور با چالش‌های خاصی روبرو هستند که سامانه‌های سلامت‌محور می‌توانند در مدیریت آن‌ها نقشی کلیدی ایفا کنند: کم‌آبی مزمن که بهینه‌سازی مصرف آب را از یک انتخاب به یک ضرورت تبدیل کرده، نوسانات شدید دمایی تابستان و زمستان که مدیریت اقلیم را دشوار می‌سازد، و هزینه بالای انرژی که هرگونه کاهش مصرف را از نظر اقتصادی جذاب می‌کند. علاوه بر این، ورود ریزگردها در مناطق جنوبی و مرکزی می‌تواند با کاهش نور و مسدود کردن روزنه‌ها تنش‌های فیزیولوژیک جدیدی ایجاد کند. یک سامانه یکپارچه پایش و کنترل سلامت‌محور می‌تواند با تشخیص زودهنگام این تنش‌ها و اعمال خودکار اقدامات اصلاحی (مانند تغییر زمان آبیاری، تنظیم دریچه‌ها، یا مه‌پاشی)، بخش قابل توجهی از خسارت‌های رایج در گلخانه‌های کشور را کاهش دهد. از این رو، سرمایه‌گذاری پژوهشی و صنعتی بر روی پر کردن شکاف‌های شناسایی‌شده در این مقاله، نه‌تنها یک اولویت علمی، بلکه یک ضرورت راهبردی برای توسعه پایدار کشاورزی کنترل‌شده در ایران است.

محدودیت‌های مرور

این مرور با رویکرد ساختاریافته و PRISMA-lite انجام شد، اما چند محدودیت دارد که باید در تفسیر نتایج در نظر گرفته شود. نخست، جست‌وجوی اصلی این مرور به پایگاه Scopus محدود شد. دلیل این انتخاب، پوشش گسترده Scopus از مجلات و مقالات کنفرانسی در حوزه‌های بین‌رشته‌ای کشاورزی، علوم گیاهی، مهندسی کنترل، سنجش تصویری و هوش مصنوعی، و نیز امکان دسترسی کامل و قابل‌تکرار نویسندگان به این پایگاه در زمان انجام مطالعه بود. با این حال، به دلیل محدودیت دسترسی سازمانی به برخی پایگاه‌های دیگر مانند Web of Science و IEEE Xplore، این منابع به‌عنوان پایگاه‌های اصلی جست‌وجو وارد فرایند مرور نشدند. بنابراین، این احتمال وجود دارد که برخی مطالعات مرتبط که فقط در پایگاه‌های دیگر نمایه شده‌اند، در مجموعه اولیه رکوردها وارد نشده باشند. برای کاهش این محدودیت، راهبرد جست‌وجو به‌صورت چندبخشی و با رشته‌های بولی مکمل طراحی شد تا محورهای اصلی مرور، یعنی پایش سلامت گیاه، هشدار زودهنگام، کنترل پیش‌بین و یکپارچه‌سازی سلامت‌محور، تا حد امکان در دامنه Scopus پوشش داده شوند.

دوم، مرور فقط مقالات انگلیسی و عمدتاً مقالات پژوهشی/مروری و مقالات کنفرانسی را پوشش داد. بنابراین، گزارش‌های فنی، پایان‌نامه‌ها، اسناد صنعتی، استانداردهای تجاری و مطالعات غیرانگلیسی وارد تحلیل نشدند. این موضوع به‌ویژه در حوزه سامانه‌های تجاری گلخانه و کنترل صنعتی اهمیت دارد، زیرا بخشی از دانش کاربردی ممکن است در مقالات علمی منتشر نشده باشد.

سوم، این مطالعه یک مرور نظام‌مند کامل با ارزیابی رسمی خطر سوگیری نبود. اگرچه انتخاب و تحلیل ۴۴ مطالعه هسته بر اساس معیارهایی مانند ارتباط موضوعی، شفافیت روش، اعتبار منبع انتشار، امکان استخراج داده و نزدیکی به زنجیره «پایش ← سلامت ← پیش‌بینی ریسک ← کنترل» انجام شد، اما از ابزارهای رسمی ارزیابی کیفیت یا خطر سوگیری مانند چک‌لیست‌های استاندارد مرورهای نظام‌مند استفاده نشد. بنابراین، نتایج این مرور باید به‌عنوان یک سنتز ساختاریافته برای

شناسایی روندها و شکاف‌های پژوهشی تفسیر شوند، نه به‌عنوان رتبه‌بندی قطعی کیفیت شواهد یا ارزیابی رسمی اعتبار روش‌شناختی هر مطالعه.

چهارم، برخی مفاهیم مانند تشخیص پیش از ظهور علائم، هشدار زودهنگام، گیاه‌محور اهداف و سلامت‌محور قیود در ادبیات تعریف یکنواختی ندارند. در این مرور، این مفاهیم با معیارهای عملیاتی مشخص کدگذاری شدند؛ اما ممکن است در برخی موارد مرز میان تشخیص زودهنگام و پیش‌بینی، یا گیاه‌محور و سلامت‌محور، تا حدی تفسیری باشد. برای کاهش این مشکل، کدگذاری‌ها در قالب ماتریس شواهد انجام شد و در تحلیل، میان تشخیص، شدت، پیش‌بینی و کنترل تمایز گذاشته شد.

پنجم، دسترسی به متن کامل همه مقالات در ابتدا یکسان نبود و در برخی موارد از مطالعات جایگزین یا نسخه‌های دسترس‌پذیر استفاده شد. با این حال، مجموعه نهایی شواهد بر اساس ۴۴ مطالعه یکتا با اطلاعات قابل استخراج بسته شد. این محدودیت باید در مقاله ذکر شود، اما چون تحلیل نهایی بر متن کامل مقالات در دسترس و ماتریس شواهد انجام شده، اعتبار کلی مرور را تضعیف نمی‌کند.

ششم، تمرکز این مقاله بر گلخانه و محیط‌های کنترل شده است و نتایج آن لزوماً به‌طور مستقیم به کشاورزی فضای باز قابل تعمیم نیست. فضای باز با تغییرات شدیدتر نور، باد، بارندگی، خاک، پس‌زمینه و مقیاس مکانی روبه‌روست. در مقابل، گلخانه محیط کنترل‌پذیرتری دارد، اما از نظر تراکم گیاهی، رطوبت، نور مصنوعی، مسیرهای محدود رباتیک و نیاز به کنترل اقلیم، چالش‌های خاص خود را دارد.

نتیجه‌گیری

این مرور نشان داد که پایش سلامت گیاه در گلخانه با بهره‌گیری از فناوری‌های متنوع بینایی ماشین و سنسورهای تصویری شامل تصویربرداری رنگی مرئی، حرارتی، فراطیفی/چندطیفی، فلورسانس و سامانه‌های چندسنسوری، طی سال‌های اخیر به پیشرفت‌های قابل ملاحظه‌ای دست یافته است. در حوزه بیماری‌ها، مدل‌های یادگیری عمیق مبتنی بر تصاویر رنگی مرئی و سنسورهای طیفی/فلورسانس توانسته‌اند طیف وسیعی از بیماری‌های مهم گلخانه‌ای را با دقت بالا تشخیص دهند و در برخی موارد، چندین روز پیش از ظهور علائم، هشدار اولیه صادر کنند. در حوزه آفات، الگوریتم‌های تشخیص اشیای کوچک روی تله‌های چسبنده، امکان شمارش خودکار و پایش روند جمعیت را فراهم کرده و نمونه‌هایی موفق از اتصال این داده‌ها به سامانه‌های تصمیم‌یار مدیریتن تلفیقی آفات ارائه شده است. در حوزه تنش‌های غیرزیستی نیز سنسورهای حرارتی، فراطیفی و فلورسانس، برآورد کمیت‌های فیزیولوژیک حیاتی مانند تعرق، شاخص تنش آبی و کمبود عناصر غذایی را ممکن ساخته‌اند و این بخش نزدیک‌ترین پیوند را با مدیریت خودکار آب و تغذیه دارد.

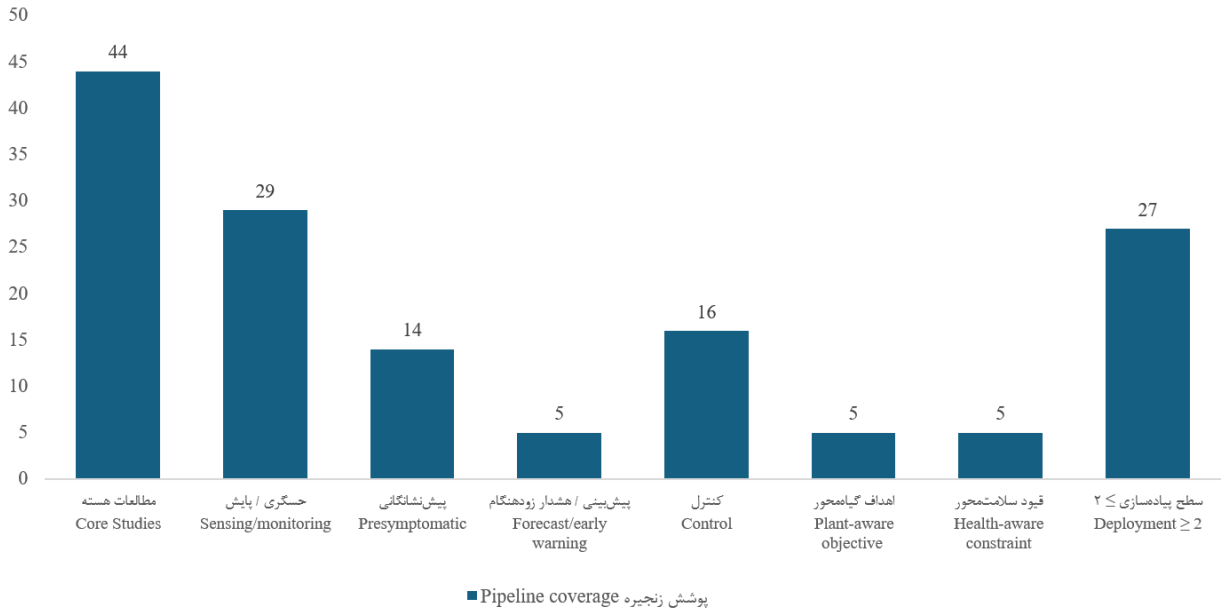

شکل ۵- پوشش قابلیت‌های کلیدی در طول زنجیره مدیریت سلامت هوشمند گلخانه در ۴۴ مطالعه هسته. این نمودار میله‌ای، تعداد مطالعاتی را نشان می‌دهد که هر یک از قابلیت‌های هفت‌گانه زنجیره «پایش تا کنترل سلامت‌محور» را دارا هستند (یک مطالعه می‌تواند چندین قابلیت را هم‌زمان پوشش دهد). این قابلیت‌ها به ترتیب عبارت‌اند از: حسگری/پایش (۲۹ مطالعه)، تشخیص پیش‌نشانگانی (۱۴ مطالعه)، پیش‌بینی/هشدار زودهنگام (پنج مطالعه)، کنترل (۱۶ مطالعه)، اهداف گیاه‌محور (پنج مطالعه)، قیود سلامت‌محور (پنج مطالعه) و آمادگی پیاده‌سازی در سطح گلخانه و بالاتر (Deployment $\geq$ 2) (۲۷ مطالعه). افت محسوس تعداد مطالعات در مراحل «پیش‌بینی/هشدار» و «کنترل سلامت‌محور» نسبت به «حسگری» و «کنترل صرف»، شکاف اصلی در تبدیل داده‌های پایش سلامت گیاه به اقدامات کنترلی خودکار و پیش‌گیرانه را برجسته می‌کند.

Fig. 5. Coverage of key capabilities along the smart greenhouse plant health management pipeline across the 44 core studies. This bar chart illustrates the number of studies possessing each of the seven capabilities in the "monitoring to health-aware control" pipeline (a single study may cover multiple capabilities). The capabilities, from left to right, are: Sensing/Monitoring (29 studies), Pre-symptomatic Detection (14 studies), Forecast/Early Warning (5 studies), Control (16 studies), Plant-aware Objective (5 studies), Health-aware Constraint (5 studies), and Deployment Readiness $\geq$ 2 (Greenhouse-level or higher) (27 studies). The sharp drop in the number of studies at the "Forecast/Early Warning" and "Health-aware Control" stages, compared to "Sensing" and "General Control," highlights the principal gap in translating plant health monitoring data into automated, preventive control actions.

با این حال، تحلیل ۴۴ مطالعه نهایی نشان داد که عمده این دستاوردها هنوز در لایه «تشخیص» یا «پایش» باقی مانده‌اند. تنها پنج مطالعه به مفهوم پیش‌بینی روند و هشدار زمانی نزدیک شده‌اند و شمار اندکی از پژوهش‌ها خروجی سلامت گیاه را به‌طور مستقیم وارد یک حلقه کنترل خودکار کرده‌اند. در سوی دیگر، سامانه‌های کنترل هوشمند اقلیم و منابع در گلخانه اگرچه از نظر روش‌های پیش‌بینی، مدیریت قیود و برخورد با عدم‌قطعیت‌ها بسیار پیشرفت کرده‌اند، اما همچنان عمدتاً بر محور متغیرهای محیطی عمل می‌کنند و شاخص‌های مستقیم سلامت گیاه در آن‌ها غایب است.

یافته اصلی این مرور آن است که مسیر آینده گلخانه‌های هوشمند، نه در افزایش تدریجی دقت مدل‌های تشخیص یا توسعه کنترل‌کننده‌های پیچیده‌تر، بلکه در ایجاد یک زنجیره عملیاتی منسجم از «پایش سلامت ← پیش‌بینی ریسک ← اقدام کنترلی خودکار» نهفته است. در این چارچوب، خروجی سامانه‌های بینایی ماشین باید از برچسب‌های ساده (سالم/بیمار، وجود/عدم آفت) به شاخص‌های پیوسته و کمّی مانند امتیاز ریسک، کمبود تعرق، فشار آفت، یا احتمال عبور از آستانه بحرانی تبدیل شود. سپس این شاخص‌ها می‌توانند به‌عنوان ورودی یا قید وارد کنترل‌کننده‌های پیش‌بین شوند تا اقدامات اصلاحی پیش از وقوع خسارت انجام گیرد.

برای تحقق این چشم‌انداز، پژوهش‌های آینده باید چند گام مشخص را دنبال کنند:

۱. تولید مجموعه‌داده‌های طولی چندفصلی در گلخانه‌های واقعی که به‌طور هم‌زمان تصاویر سلامت گیاه، داده‌های اقلیمی و اقدامات کنترلی را ثبت کرده باشند.

۲. توسعه مدل‌های پیش‌بینی‌کننده که به‌جای برچسب دودویی، احتمال وقوع تنش را در افق‌های زمانی مشخص (۱۲، ۲۴ و ۴۸ ساعت آینده) تخمین بزنند.

۳. طراحی کنترل‌کننده‌هایی که شاخص‌های سلامت مبتنی بر بینایی ماشین را به‌عنوان متغیر حالت یا قید نرم دریافت کنند.

٤. تعریف آستانه‌های هشدار و مداخله برای محصولات مهم گلخانه‌ای (گوجه‌فرنگی، خیار، فلفل، توت‌فرنگی و سبزی‌های برگی) متناسب با اقلیم‌های مختلف ایران.

در نهایت، مفهوم «مدیریت پیش‌گیرانه سلامت‌محور» می‌تواند سنگ‌بنای نسل بعدی گلخانه‌های هوشمند باشد؛ گلخانه‌هایی که نه‌تنها دما، رطوبت، CO_2 و انرژی را با دقت کنترل می‌کنند، بلکه وضعیت واقعی گیاه را نیز می‌بینند، تحلیل می‌کنند و بر اساس آن تصمیم می‌گیرند. تحقق این هدف می‌تواند به کاهش هم‌زمان مصرف آب، سموم و انرژی، افزایش کیفیت و سلامت محصول، کاهش ضایعات و در نهایت، پایداری اقتصادی و زیست‌محیطی صنعت گلخانه‌داری، به‌ویژه در اقلیم‌های چالش‌برانگیزی مانند ایران، کمک شایانی نماید.

References منابع

Abioye, E. A., Zainal Abidin, M. S., Aman, M. N., Mahmud, M. S. A., & Buyamin, S. (2021). A model predictive controller for precision irrigation using discrete Laguerre networks. *Computers and Electronics in Agriculture, 181*, 105953.

Abioye, A. E., Zainal Abidin, M. S., Mahmud, M. S. A., Buyamin, S., Mohammed, O. O., Otuoze, A. O., Oleolo, I. O., & Mayowa, A. (2023). Model based predictive control strategy for water saving drip irrigation. *Smart Agricultural Technology, 4*, 100179.

Achour, Y., Ouammi, A., Zejli, D., & Sayadi, S. (2020). Supervisory model predictive control for optimal operation of a greenhouse indoor environment coping with food-energy-water nexus. *IEEE Access, 8*, 211562-211575.

Chen, M., Zhang, S., Zhai, X., Hu, P., Wang, Z., Zhu, H., Li, Z., Wang, F., Han, Z., Zhang, F., Wei, M., & Shi, Y. (2025). Intelligent detection of wilted cucumber leaves with deep learning model in real greenhouse conditions. *Industrial Crops and Products, 235*, 121723.

Chen, W. H., & You, F. (2021). Smart greenhouse control under harsh climate conditions based on data-driven robust model predictive control with principal component analysis and kernel density estimation. *Journal of Process Control, 107*, 103-113.

Chen, W. H., Mattson, N. S., & You, F. (2022). Intelligent control and energy optimization in controlled environment agriculture via nonlinear model predictive control of semi-closed greenhouse. *Applied Energy, 320*, 119334.

Chen, X., Shi, D., Zhang, H., Sánchez Pérez, J. A., Yang, X., & Li, M. (2024). Early diagnosis of greenhouse cucumber downy mildew in seedling stage using chlorophyll fluorescence imaging technology. *Biosystems Engineering, 242*, 107-122.

Das Choudhury, S., Guadagno, C. R., Bashyam, S., Mazis, A., Ewers, B. E., Samal, A., & Awada, T. (2024). Stress phenotyping analysis leveraging autofluorescence image sequences with machine learning. *Frontiers in Plant Science, 15*, 1353110.

Elvanidi, A., Katsoulas, N., Augoustaki, D., Loulou, I., & Kittas, C. (2018). Crop reflectance measurements for nitrogen deficiency detection in a soilless tomato crop. *Biosystems Engineering, 176*, 1-11.

Guo, Y., Lan, Y., & Chen, X. (2022). CST: Convolutional Swin Transformer for detecting the degree and types of plant diseases. *Computers and Electronics in Agriculture, 202*, 107407.

Hu, G., & You, F. (2023). An AI framework integrating physics-informed neural network with predictive control for energy-efficient food production in the built environment. *Applied Energy, 348*, 121450.

Laekeman, B., Bonte, J., Dermauw, W., Christiaens, A., Gobin, B., Van Huylenbroeck, J., Dhooghe, E., & Lootens, P. (2025). Species-level detection of thrips and whiteflies on yellow sticky traps using YOLO-based deep learning detection models. *Frontiers in Plant Science, 16*, 1668795.

Li, W., Wang, D., Li, M., Gao, Y., Wu, J., & Yang, X. (2021). Field detection of tiny pests from sticky trap images using deep learning in agricultural greenhouse. *Computers and Electronics in Agriculture, 183*, 106048.

Li, Y., Zhang, Y., Wang, Y., Chen, H., Han, X., Mao, Y., Sun, L., Shen, J., & Ding, Z. (2026). A lightweight hybrid transformer approach for hyperspectral imaging-based drought tolerance evaluation in tea plants. *Plant Methods, 22*, 11.

Lin, D., Hu, M., Ren, Z., Dong, Y., Ye, X., Fan, Y., & Zhang, L. (2026). Hierarchical model predictive control of greenhouse energy systems considering energy-water-carbon-food nexus. *Energy, 347*, 140421.

Mac, T. T., Nguyen, T. D., Dang, H. K., Nguyen, D. T., & Nguyen, X. T. (2024). Intelligent agricultural robotic detection system for greenhouse tomato leaf diseases using soft computing techniques and deep learning. *Scientific Reports, 14*, 23887.

Mahmood, F., Govindan, R., Bermak, A., Yang, D., & Al-Ansari, T. (2023). Data-driven robust model predictive control for greenhouse temperature control and energy utilisation assessment. *Applied Energy, 343*, 121190.

Mahmood, F., Govindan, R., & Al-Ansari, T. (2025). Efficient energy management and temperature control of a high-tech greenhouse using an improved data-driven model predictive control. *Energy Conversion and Management: X, 26*, 100939.

Mertens, S., Verbraeken, L., Sprenger, H., De Meyer, S., Demuynck, K., Cannoot, B., Merchie, J., De Block, J., Vogel, J. T., Bruce, W., Nelissen, H., Maere, S., Inzé, D., & Wuyts, N. (2023). Monitoring of drought stress and transpiration rate using proximal thermal and hyperspectral imaging in an indoor automated plant phenotyping platform. *Plant Methods, 19*, 132.

Navarro, A., Nicastro, N., Costa, C., Pentangelo, A., Cardarelli, M., Ortenzi, L., Pallottino, F., Cardi, T., & Pane, C. (2022). Sorting biotic and abiotic stresses on wild rocket by leaf-image hyperspectral data mining with an artificial intelligence model. *Plant Methods, 18*, 45.

Ouammi, A., Achour, Y., Zejli, D., & Dagdougui, H. (2020). Supervisory model predictive control for optimal energy management of networked smart greenhouses integrated microgrid. *IEEE Transactions on Automation Science and Engineering, 17*(1), 117-128.

Prasad, K. M. A., & Pushpa, B. R. (2025). WMC-Leafset: A dataset of wax gourd and Mangalore cucumber plants for leaf miner and pest infestation diseased object detection. *Data in Brief, 63*, 112231.

Qi, J., Liu, X., Liu, K., Xu, F., Guo, H., Tian, X., Li, M., Bao, Z., & Li, Y. (2022). An improved YOLOv5 model based on visual attention mechanism: Application to recognition of tomato virus disease. *Computers and Electronics in Agriculture, 194*, 106780.

Ramezani, S. F., Vafa, E., Fakhroleslam, M., & Shahrokhi, M. (2023). Adaptive predictive control of a fan-ventilated tunnel greenhouse with evaporative cooling. *Journal of Process Control, 129*, 103060.

Renò, V., Cardellicchio, A., Romanjenko, B. C., & Guadagno, C. R. (2024). AI-assisted image analysis and physiological validation for progressive drought detection in a diverse panel of *Gossypium hirsutum* L. *Frontiers in Plant Science, 14*, 1305292.

Rivera-Romero, C. A., Palacios-Hernández, E. R., Muñoz-Minjares, J. U., Vite-Chávez, O., Olivera-Reyna, R., & Reyes-Portillo, I. A. (2025). Recognition in the early stage of powdery mildew damage for cucurbits plants using spectral signatures. *Biosystems Engineering, 252*, 144-158.

Rustia, D. J. A., Chiu, L. Y., Lu, C. Y., Wu, Y. F., Chen, S. K., Chung, J. Y., Hsu, J. C., & Lin, T. T. (2022). Towards intelligent and integrated pest management through an AIoT-based monitoring system. *Pest Management Science, 78*(10), 4288-4302.

Schor, N., Bechar, A., Ignat, T., Dombrovsky, A., Elad, Y., & Berman, S. (2016). Robotic disease detection in greenhouses: Combined detection of powdery mildew and tomato spotted wilt virus. *IEEE Robotics and Automation Letters, 1*(1), 354-360.

Si, G., Ling, P., Testen, A. L., & Zhu, H. (2026). Early detection of tomato bacterial spot in controlled environment using machine learning processed spectral information. *HortScience, 61*(1), 14-22.

Su, Y., & Xu, L. (2021). Greenhouse climate setpoint optimization: An online decision strategy. *IEEE Access, 9*, 140299-140313.

Sun, S., Zhu, L., Liang, N., He, Y., Wang, Z., Chen, S., Liu, J., Cen, H., He, Y., & Zhou, Z. (2023). Monitoring drought induced photosynthetic and fluorescent variations of potatoes by visible and thermal imaging analysis. *Computers and Electronics in Agriculture, 215*, 108433.

Svensen, J. L., Cheng, X., Boersma, S., & Sun, C. (2024). Chance-constrained stochastic MPC of greenhouse production systems with parametric uncertainty. *Computers and Electronics in Agriculture, 217*, 108578.

Thao, L. Q., Cuong, D. D., Anh, N. T., Minh, N., & Tam, N. D. (2022). Pest early detection in greenhouse using machine learning. *Revue d'Intelligence Artificielle, 36*(2), 209-214.

Tran, D., Najdenovska, E., Dutoit, F., Plummer, C., Wallbridge, N., Mazza, M., Camps, C., & Raileanu, L. E. (2024). Advanced assessment of nutrient deficiencies in greenhouse with electrophysiological signals. *Horticulture, Environment, and Biotechnology, 65*, 567-580.

Valábek, P., Vargan, J., & Paulen, R. (2025). Adaptive optimal control of lettuce growth in greenhouses using sensitivity-driven measurement collection. *IFAC-PapersOnLine, 59*(6), 516-521.

van Laatum, B., Msaad, S., van Henten, E. J., Mcallister, R. D., & Boersma, S. (2026). Stochastic model predictive control with reinforcement learning for greenhouse production systems under parametric uncertainty. *Control Engineering Practice, 169*, 106787.

Wadinger, M., Fáber, R., Pavlovičová, E., & Paulen, R. (2025). Carbon neutral greenhouse: Economic model predictive control framework for education. *European Journal of Control, 86*, 101297.

Wei, X., Johnson, M. A., Langston, D. B., Jr., Mehl, H. L., & Li, S. (2021). Identifying optimal wavelengths as disease signatures using hyperspectral sensor and machine learning. *Remote Sensing, 13*(14), 2833.

Wspanialy, P., & Moussa, M. (2016). Early powdery mildew detection system for application in greenhouse automation. *Computers and Electronics in Agriculture, 127*, 487-494.

Wspanialy, P., & Moussa, M. (2020). A detection and severity estimation system for generic diseases of tomato greenhouse plants. *Computers and Electronics in Agriculture, 178*, 105701.

Xia, J., Zhang, W., Zhang, W., Yang, Y., Hu, G., Ge, D., Liu, H., & Cao, H. (2021). A cloud computing-based approach using the visible near-infrared spectrum to classify greenhouse tomato plants under water stress. *Computers and Electronics in Agriculture, 181*, 105966.

Xie, Y., Plett, D., Evans, M., Garrard, T., Butt, M., Clarke, K., & Liu, H. (2024). Hyperspectral imaging detects biological stress of wheat for early diagnosis of crown rot disease. *Computers and Electronics in Agriculture, 217*, 108571.

Xu, Y., Chen, Q., Kong, S., Xing, L., Wang, Q., Cong, X., & Zhou, Y. (2022). Real-time object detection method of melon leaf diseases under complex background in greenhouse. *Journal of Real-Time Image Processing, 19*, 985-995.

Zhang, X., Bu, J., Zhou, X., & Wang, X. (2023). Automatic pest identification system in the greenhouse based on deep learning and machine vision. *Frontiers in Plant Science, 14*, 1255719.

Iranian Journal of Horticultural Science and Technology 27 (1):87-112 (2025)
Research article

A Structured Review of Plant Health Monitoring and Preventive Management in Greenhouses: From Machine Vision and Early Warning to Intelligent Control

Zahra Ghavamipour[1*], Alireza Babaei[1], Mostafa Shamsi[2]

1. Faculty of Horticulture, Department of Agriculture, Tarbiat Modares University, Tehran, Iran
2. Faculty of Computer Science, Department of Mathematics and Computer Science, Amirkabir University, Tehran, Iran

*Corresponding author, Email: (Zahra.Ghavami@modares.ac.ir)

While state-of-the-art computer vision and multi-sensor technologies now offer presymptomatic detection of biotic and abiotic stresses in controlled environment agriculture, a critical strategic gap remains: the translation of this high-fidelity health data into automated, preventive control actions. Plant health monitoring systems largely remain stuck at the "current status diagnosis" layer, while intelligent climate and irrigation controllers operate in parallel, predominantly based on environmental setpoints (temperature, humidity, CO_2) and largely blind to direct plant health signals. This structured review, employing a PRISMA-lite methodology, a simplified adaptation of the PRISMA reporting framework, analyzed 44 core studies from 523 initial Scopus records to quantitatively dissect this disconnect. Our findings starkly illustrate the chasm: while 66% of studies feature health monitoring and 36% involve a control component, a mere 11% (only 5 studies) have explicitly linked a plant health output—such as a Crop Water Stress Index or pest pressure level—to a closed-loop automated control decision. The primary bottleneck is identified not in sensing or control architecture per se, but in the missing middle: the lack of predictive models capable of converting diagnostic imagery into a quantitative, time-bound "risk score" (e.g., probability of wilting within 24 hours) that can serve as a state variable for a model predictive controller. We propose a unified, health-aware framework where the outer control loop follows a "continuous monitoring → quantitative risk forecasting → early warning → preventive actuation" continuum, effectively placing the plant, rather than the environment, at the center of the decision-making paradigm. This review concludes that the future of truly intelligent greenhouses lies in this fundamental architectural shift from environment-centric to plant-centric control, unlocking profound, simultaneous reductions in water, pesticide, and energy consumption—a critical pathway to economic and environmental sustainability for water-scarce, arid climates like Iran.

Keywords: Plant health, water stress, presymptomatic diagnosis, intelligent greenhouse management, preventive control, water use optimization, protected cultivation.