

作物表型组学关键共性技术研究综述与展望

郭子越^{1,2†}, 沈煜韬^{1,2†}, 陆旭琦^{1,2†}, 李玥^{1,2}, 黄梓宸^{1,2}, 岑海燕^{1,2,3*}

1. 浙江大学生物系统工程与食品科学学院, 植被结构功能与建造全国重点实验室, 杭州 310058

2. 农业农村部光谱检测重点实验室, 杭州 310058

3. 浙江省农业遥感与信息技术重点实验室, 杭州 310058

† 同等贡献

* 联系人, E-mail: hycen@zju.edu.cn

2026-04-03 收稿, 2026-05-10 修回, 2026-05-27 接受, 2026-05-29 网络版发表

国家自然科学基金(32371985)和国家重点研发计划(政府间国际科技创新合作)(2024YFE0115000)资助

摘要 传感技术、人工智能算法及高性能计算能力的飞速发展正推动作物表型检测从单一性状描述向多尺度、智能化感知体系的转变. 在此背景下, 作物表型智能检测应运而生, 其核心原理在于解析电磁波谱与植物组织相互作用的物理机制, 即不同波段的光子与植物组织发生电子跃迁、分子振动及热辐射等能量交换, 从而携带形态结构、生理生化及环境互作等多维信息. 基于此, 本文系统阐述了可见光成像、三维成像、光谱成像、叶绿素荧光成像、热红外成像等传感器的技术特性与适用场景, 并梳理了从细胞/组织到器官、单株及群体水平的表型检测平台, 比较了不同平台的应用场景及其优势与局限. 针对当前多源数据异构性高、标准化体系缺失及模型泛化能力不足等核心瓶颈, 本文提出发展作物表型智能检测的关键路径: 建立面向多平台的数据标准化采集与校准体系, 从源头保证数据质量; 发展鲁棒性强、可迁移的智能解析算法, 推动表型解析从传统特征工程向视觉基础模型及多模态大模型的演进; 构建符合FAIR(findable, accessible, interoperable, and reusable)原则的共享数据库, 打破“数据孤岛”现象; 明确模型在不同物种、环境及生育阶段的适用边界, 提升其在真实农业场景下的可靠性与泛化能力. 利用智能检测技术实现作物表型的高通量、精准化解析, 是未来作物表型组学发展的必然趋势, 也为智慧育种与精准农业提供核心技术与理论支撑.

关键词 作物表型组学, 多源传感器, 多尺度检测, 人工智能, 数据标准化

全球农业正面临前所未有的系统性挑战. 据预测, 至2050年全球人口将增至近百亿, 伴随膳食结构的持续演变, 全球粮食供给总量需在现有基础上至少提升70%^[1]. 然而, 当前全球四大主粮作物的单产年均增长率仍远低于实现产量倍增所需的目标^[2]. 在耕地资源日趋紧缺与极端气候事件频发的双重压力下, 传统育种方法与种植管理模式已难以满足农业可持续发展的迫切需求. 以人工智能、大数据、物联网为代表的新一轮科技革命, 正为推动农业生产变革、实现精准育种与智慧管理提供重要机遇.

过去20年间, 高通量测序技术的快速发展使作物基因型数据呈现指数级增长, 单样本测序成本降至数百元^[3]. 然而, 精准、高效、全生育期的作物表型信息获取技术发展却相对滞后^[4]. 传统表型采集主要依赖人工测量, 不仅耗时费力、破坏性强, 且难以实现对株型结构、生理功能、胁迫响应等复杂性状的动态监测与规模化获取. 基因型与表型数据之间的发展鸿沟已成为制约复杂农艺性状遗传解析、基因功能验证及育种效率提升的关键瓶颈. 作物表型组学作为一门新兴交叉学科, 正是在突破这一瓶颈的迫切需求下应运而生.

引用格式: 郭子越, 沈煜韬, 陆旭琦, 等. 作物表型组学关键共性技术研究综述与展望. 科学通报, 2026, 71: 4865–4881

Guo Z, Shen Y, Lu X, et al. Review and perspective of key generic technologies in crop phenomics (in Chinese). Chin Sci Bull, 2026, 71: 4865–4881, doi: 10.1360/CSB-2026-0435

近年来,传感技术、人工智能算法及高性能计算能力的飞速发展,作物表型检测已从单一性状的人工测定逐步发展为涵盖“室内-田间”多场景、“细胞/组织-器官-单株-群体”多尺度的智能化感知体系。基于可见光、多光谱、热成像、激光雷达等传感器的融合应用,结合深度学习等智能解析算法,提升了形态结构、生理生化及环境互作等表型信息的获取通量与解析精度。作物表型组学的核心内涵已不再局限于感知硬件的集成,而是逐步演化为以多组学数据融合为基础,系统解析基因型-环境-管理措施互作机制的科学范式。基于此,本综述旨在系统梳理作物表型智能检测技术的研究进展,重点探讨从物理感知机理到智能解析算法的共性关键技术,分析其在种质挖掘与保护、作物育种、智慧种植等的应用前景,以期作为作物表型组学及相关领域的理论研究和工程实践提供参考。

1 作物表型智能检测的技术路径

植物表型受基因型、环境、管理措施等多重因素影响,反映了植物结构及组成、植物生长发育过程及结果的全部物理、生理、生化特征和性状。作物表型智能检测通常涵盖图谱采集、数据处理、模型构建与表型应用四个核心环节(图1),旨在通过搭载不同传感器的多尺度表型平台获取作物图谱数据,结合图谱处理技术和模型算法,实现形态结构、生理生化、生育动态、产量品质等表型性状的高效解析,为种质资源挖掘与保护、作物育种、智慧种植等提供高质量表型数据支撑。

在表型图谱采集与处理环节,现有的检测体系涵盖了从显微成像、无人车、龙门架到无人机平台的多尺度图谱感知系统。然而,不同表型平台在传感器性能、采集条件、操作规范等方面存在差异,导致数据质量参差不齐,噪声干扰大、标定精度低、时空一致性差等问题普遍存在,严重制约了模型的泛化能力与解析精度。此外,多源传感器的数据格式各异,呈现出高度的异构化、互融互通性差的特点,进一步加大了后续表型解析的难度。在解析模型与表型应用环节,尽管基于编码器-解码器(encoder-decoder)等架构的深度学习模型已被广泛引入,但面对复杂的农业环境以及作物表型本身的时空异质性,现有模型普遍存在解析精度低、跨环境迁移能力不足的问题。

基于上述挑战,亟需构建覆盖数据产生、处理到应用全链条的协同研究范式,其关键共性技术包括:统

一传感器参数、采集条件与标定标准,从源头保障数据质量;发展多场景下的数据清洗与标准化处理技术,以抑制噪声干扰、提升时空一致性;构建鲁棒性好、可迁移能力强的智能解析模型,实现从原始数据到表型性状的精准解析。通过三项技术的协同攻关与应用,形成高质量数据与高精度模型双轮驱动的迭代优化机制,切实支撑作物表型的精准感知与解析,提升其在相关研究中的实用价值。

2 作物表型检测原理与传感器

作为快速精准、安全可靠、非接触式的波谱或成像技术,光学检测技术通过解析电磁波与植物组织相互作用所产生的反射、透射及发射信号,来定量反演作物的形态结构、生理、生化等指标,已成为作物表型检测领域的主流技术。

2.1 光与植物组织的相互作用机制

光在植物组织中的传输与分布规律本质上取决于电磁波谱能级跃迁的物理规律^[5]。如图2所示,在电磁波谱的短波区域,波长小于10 nm的X射线主要由原子内层电子受激发产生。凭借其极强的穿透能力,X射线能够深入植物组织内部,实现对根系形态、种子结构等的无损检测^[6,7]。在可见光(400~760 nm)区域,植物的反射特征主要受叶绿素等光合色素的电子跃迁控制,呈现为红光吸收峰与绿光反射峰,构成了植被识别的基础。进入近红外波段后,由于光子能量不足以激发电子跃迁,植物组织的光学响应转而由分子内部的振动跃迁主导^[8]。其中,短波红外(1400~2500 nm)区域对水分、干物质(如蛋白质、纤维素)及含氢基团高度敏感,为定量反演作物养分与水分状态提供了有效手段^[9]。在热红外(8~14 μm)波段,植物与电磁波的相互作用主要表现为由分子振动能级跃迁引起的热辐射,可用于无损监测作物叶温动态。而对于电磁波谱长波段的核磁共振(1~5 m),其物理本质涉及原子核的自旋跃迁,为解析根系系统分布以及追踪水分迁移过程奠定了物理基础^[10]。

光在植物组织中的传输具有尺度效应。在叶片尺度,入射光达到表皮层后,大部分光进入叶片组织内部,发生复杂的光子吸收与多重散射。其中,吸收主要由生化组分(如叶绿素、水分等)决定,吸收的光能主要用于光化学反应、热耗散以及荧光发射;散射则主要受细胞形态、叶肉结构及细胞间隙等物理结构特征影




图 1 (网络版彩色)作物表型智能检测的技术路径。作物表型解析包括四个核心环节：基于多尺度感知平台的图谱数据采集、多源异构数据的处理与标准化、基于深度神经网络等算法的表型解析模型构建，以及表型数据在种质挖掘与保护、作物育种和智慧种植中的应用。图中 $-\log_{10}(P)$ 代表全基因组关联分析中的常用统计量。图中的卡通标识由人工智能工具(Nano Banana)辅助生成

Figure 1 (Color online) Technical pathway of intelligent crop phenotypic detection. Crop phenotypic analysis comprises four core stages: image data acquisition based on multi-scale sensing platforms, processing and standardization of multi-source heterogeneous data, construction of phenotypic analytical models based on algorithms such as deep neural networks, and the application of phenotypic data in germplasm discovery and protection, crop breeding, and smart farming. The $-\log_{10}(P)$ scale in the figure represents a common statistic in genome-wide association studies (GWAS). The cartoon logo in the picture is generated with the assistance of artificial intelligence tools (Nano Banana)

响。从叶片的二维平面拓展至植株或冠层的三维空间尺度，光与植物的交互作用变得更为复杂。叶片的吸收和散射特性受到株型结构、叶面积指数以及叶倾角分布等多重结构参数的影响。冠层内部，上层叶片的遮挡效应形成纵向光梯度，而土壤背景、种植密度等因素则进一步加剧了辐射场的空间异质性。由此可见，在植株及冠层尺度，传感器所获取的光谱反射信号实际上是叶片结构、生化信息与冠层结构信息深度耦合的结果，其中土壤背景等因素的叠加效应使得信号解析更加复杂。因此，从复杂的光学信号中准确解析植物表型参数，需考虑辐射传输机理描述光与植物相互作用的

物理过程，同时融合人工智能算法提高对高维、异质数据的处理能力。

2.2 可见光成像传感器

可见光成像(或RGB成像)传感器作为作物表型组学研究中应用最广泛的成像设备，通过捕捉物体在可见光波段(400~760 nm)的反射光，实现对植物形态、颜色及纹理特征的直观展现。其成像质量受光学系统的参数影响，快门速度与感光度决定了图像的信噪比与动态范围，光圈大小控制进光量及景深范围，而焦距与景深的合理配置，则决定了图像中前后景物的清晰范




图 2 (网络版彩色)不同电磁波段的光谱响应^[6]。阐释了不同波段电磁波与植物组织相互作用的物理机理及其在表型检测中的应用。随着电磁波长从短到长,光子能量与植物组织的交互方式依次表现为内层电子跃迁、价电子跃迁、分子振动跃迁及原子核自旋转动跃迁,使各波段能够分别携带作物形态结构、光合色素、水分/养分状态及内部根系分布等多维表型信息。γ-rays, 伽马射线; X-rays, X射线; VIS, 可见光; NIR/SWIR, 近红外/短波红外; TIR, 热红外; NMR, 核磁共振; Radar/Radio, 雷达/无线电波

Figure 2 (Color online) Spectral response characteristics of different electromagnetic waves^[6]. This figure elucidates the physical mechanisms of electromagnetic interaction with plant tissues and their applications in phenotypic detection. As the wavelength increases, the interaction modes between photons and plant tissues transition from inner-shell electronic transitions to valence electronic transitions, molecular vibration transitions, and nuclear spin transitions. These energy exchanges allow various spectral bands to carry multidimensional phenotypic information, including morphological structure, photosynthetic pigments, water/nutrient status, and internal root distribution. γ-rays: gamma rays; X-rays: X-rays; VIS: visible light; NIR/SWIR: near-infrared/short-wave infrared; TIR: thermal infrared; NMR: nuclear magnetic resonance; Radar/Radio: radar/radio waves

围,是保障复杂植株或冠层结构下成像完整性与后续背景分割以及特征提取精度的关键因素^[11]。

可见光成像因其数据直观、环境适应性强且易集成于各类移动或固定平台,已成为作物表型获取的主要技术手段之一^[12]。为发挥该技术的实用价值,通常会结合目标检测、语义分割等计算机视觉方法,用于提取作物的形态结构,如株高、冠层覆盖度、分蘖数等^[13~15]。同时,基于可见光波段构建的光谱指数(如超绿指数、红绿比值指数)可用于评估作物受水分或养分胁迫引起的叶片失绿、枯黄及病斑扩散等生理变化过程^[16~19]。凭借其在大规模群体筛查与田间动态监测中的适用性,可见光成像为解析基因型与环境互作下的表型可变性和可塑性提供了重要的数据支撑。

2.3 三维传感器

三维传感器能够突破二维图像在空间信息表达上的局限,实现对作物三维形态结构的高精度重建。其硬件实现主要分为被动式视觉重建与主动式深度感测两

大类。被动式方法如运动恢复结构重建方法通过匹配多角度序列图像中的特征点,利用三角测量原理恢复物体的空间几何坐标^[20];主动式传感则主要包括飞行时间相机与激光雷达,前者基于光脉冲发射与接收的时间差获取深度信息,后者则利用高频激光脉冲的反射信号,可用于获取不同尺度的高密度三维点云数据^[21]。此外,针对植物内部组织及根系等器官,计算机断层扫描(computerized tomography, CT)与磁共振成像技术利用高能射线穿透或核磁共振原理,可以实现对植物内部结构的无损检测^[22]。

三维点云能够还原作物的真实空间拓扑结构与几何尺寸,有效弥补了平面成像中固有的透视畸变与深度信息缺失问题。在表型解析方面,三维数据不仅可以用于提取株高、叶面积指数、冠层体积及分枝角度等关键结构参数,还能通过与光谱信息融合实现冠层生理生化组分的空间分布反演^[13,23,24]。针对根系等地下器官,CT等技术能够在非破坏条件下构建相应的三维数字模型,为解析地下部分发育与水分迁移过程提供

独特视角^[25]。三维点云不仅实现了作物形态结构的高保真数字化表达,也为精准评价基因型在三维空间中的结构表现、解析冠层光能利用效率等参数提供了重要技术支撑^[26]。

2.4 光谱成像传感器

光谱成像技术通过整合空间成像与光谱(400~2500 nm)探测功能,实现了作物“图谱合一”的高维度信息获取。根据光谱分辨率差异,该技术可分为多光谱成像与高光谱成像。多光谱成像通常利用多镜头组合、滤光轮或分光滤镜阵列,在数个至十余个离散的宽波段内获取目标特征,其系统结构相对简单,适用于高通量、实时性要求较高的表型获取场景。高光谱成像则能够以纳米级的光谱分辨率,在连续数十至数百个波段上同步记录目标的图像与光谱信息。根据扫描方式的不同,其主要分为摆扫式、推扫式、凝视式及快照式四种类型^[27]。摆扫式成像通过扫描镜在两个方向上的机械摆动,逐点获取地物反射光谱,可灵活适用于高空中或地面移动平台的成像任务,但其成像效率受机械运动速度限制。推扫式成像利用面阵探测器配合平台运动,沿垂直于飞行或移动方向逐行采集空间信息,同时每个像元均可获取连续的光谱曲线,具有光通量高、数据采集效率高的特点,是目前高光谱成像系统中应用最为广泛的模式。凝视式成像通过分光元件在固定视场内逐波段调谐获取完整的三维数据立方体,无需平台移动即可完成数据采集,对成像平台的稳定性要求较高,适用于室内或近距离观测场景。快照式成像则借助先进的分光结构与探测器阵列,在一次曝光时间内同时获取完整的三维数据立方体,在基于无人机等移动平台的表型检测中具有广泛的应用前景。

光谱成像因其可以同时采集空间和光谱信息,在同步解析植物的形态结构与生理功能中具有强大潜力。在实际应用中,该技术广泛用于作物叶绿素含量^[28]、氮素含量^[29]、蛋白质^[30]及水分含量^[31]等关键组分的空间分布反演,并可实现对病害侵染^[32]、重金属胁迫^[33]及干旱^[34]等生理逆境的早期识别与动态预警。光谱成像所获取的高维数据为构建作物功能性状的时空动态变化提供了重要手段,使其在基因型-表型关联分析、种质资源评价以及栽培管理等方面展现出不可替代的应用价值。作为连接作物外部形态结构与内部生理机理的感知手段,光谱成像技术推动了作物表型组学研究从单一形态描述向多维度、跨尺度的功能解析

的深入发展。

2.5 叶绿素荧光及成像传感器

叶绿素荧光是作物光合作用的探针,能够直接反映光系统的功能状态。叶绿素荧光成像技术通过记录叶片或冠层在650~800 nm波段的荧光发射信号,实现对光合作用的空间分布可视化与定量评估。根据激发光源的不同,该技术可分为基于人工光源的主动式叶绿素荧光成像与基于自然光的被动式叶绿素荧光探测两类^[35]。

主动式叶绿素荧光成像通常采用脉冲振幅调制(pulse amplitude modulation, PAM)技术,通过施加特定强度的饱和脉冲光与测量光,精确调控光系统II的激发状态,记录从最小荧光到最大荧光的诱导动力学过程。该技术可获取最大光量子效率、实际光量子效率、光化学淬灭及非光化学淬灭等荧光参数,从光能转化效率、光化学反应活性及热耗散能力等维度定量描述光系统的功能状态。被动式叶绿素荧光探测主要以日光诱导叶绿素荧光(sun-induced chlorophyll fluorescence, SIF)为主,利用植物在自然光照下发射的荧光信号与太阳夫琅禾费暗线进行光谱分离,通常在O₂-B波段(约687 nm)和O₂-A波段(约760 nm)等极窄波段内实现荧光信号的提取,可在田间及卫星尺度实现非接触、连续性的光合功能监测。

在作物表型组学研究中,叶绿素荧光成像技术常用于评估作物在高温、干旱胁迫及病害侵染等逆境条件下的光系统损伤程度与恢复能力,并实现大尺度作物整体初级生产力的评估,为高光效种质筛选、光合相关数量性状位点解析以及作物光能利用效率的环境响应机制研究提供表型依据^[36-38]。作为监测作物光合系统的技术手段,叶绿素荧光成像是作物表型组学多模态感知体系的重要补充。

2.6 热红外成像传感器

热红外成像技术通过探测目标物体的热辐射特性,实现对作物表面温度空间分布的非接触式监测。该技术主要利用长波红外传感器(通常为8~14 μm波段)接收植物发射的热辐射信号,并根据斯蒂芬-玻尔兹曼定律将辐射能转化为温度空间影像^[33]。其硬件核心主要分为制冷型与非制冷型两类,制冷型探测器(如碲镉汞、量子阱探测器)通常配备低温制冷模块,具有较高的热灵敏度和信噪比,适用于对温度分辨率要求较高的精

细表型分析;非制冷型焦平面阵列探测器则依托微测辐射热计技术,无需制冷系统,结构紧凑、功耗低,更适于集成至高通量田间表型平台或无人机载系统^[39]。

热红外成像对气孔运动及植物水分状态具有较高的敏感性,能够捕捉蒸腾速率的动态波动。研究表明,热红外成像传感器可用于获取作物叶温动态分布,并结合环境气象参数计算作物水分胁迫指数,从而实现对植物水分盈亏状态、气孔导度变化及抗旱性能的评估^[40]。作为监测作物水分代谢与逆境预警的技术手段,热红外成像为研究植物水分利用效率及环境响应机制提供了重要观测维度。

综上所述,涵盖可见光至热红外波段的多源传感器已成为作物表型感知的硬件基础,但当前检测技术与传感设备仍面临诸多技术瓶颈。首先,传感器在空间分辨率、探测深度与检测通量之间存在固有矛盾。常规光学传感器虽能实现高通量植物表型信息获取,但受电磁波穿透能力限制,难以有效探测根系等深层组织;X射线、核磁共振等技术能够实现植物内部组织及根系的高精度无损检测,但受限于设备体积、扫描效率与安全约束,难以在温室或大田环境中实现原位、高通量检测。其次,传感器在开放环境下的物理感知鲁棒性亟待提升。光谱传感器的光电转换机制对光照突变及温湿度变化敏感,主动式三维扫描设备易受田间风场扰动导致点云重影,现有硬件普遍缺乏针对复杂环境的抗干扰设计。最后,多模态传感器的物理集成与时空同步仍面临挑战,当前多模态感知多采用不同传感器的分立式组合模式,各传感器在视场、分辨率、曝光时间及触发机制上的差异,易引入系统性误差和时空配准误差。因此,研发兼顾深层探测与高通量需求的新型传感器,提升传感器的环境适应性,突破多模态传感的芯片级集成,是未来作物表型传感器发展的重要方向。

3 多尺度作物表型检测技术与平台

当前的表型检测已构建起覆盖“细胞/组织-器官-植株-群体”的多尺度检测体系。针对不同尺度的表型检测需求,分别开发部署了差异化的硬件平台,实现了从微观机理到宏观性状的系统性解析。为系统评估植物表型检测技术的发展水平,本文引入了技术成熟度(technology readiness level, TRL)作为评价框架,用于衡量各类传感器及检测平台在获取表型参数时的实用程度。TRL 1~3代表概念提出阶段,TRL 4和5为实验室

环境下的原理验证阶段,TRL 6和7代表在温室、大田等真实场景下的系统原型验证阶段,TRL 8和9则代表技术已趋于成熟,能够支撑高通量表型采集的规模化应用(图3)^[41,42]。

3.1 微观表型解析

微观层面的细胞与组织结构是作物宏观生理功能及环境适应性的结构基础。传统的破坏性显微切片观察正逐渐被高通量、三维无损的数字化解析硬件取代,包括基于显微CT(Micro-CT)的三维数字化系统,以及集成高光谱或荧光模块的显微成像平台。前者通过多角度投影重建技术,可在微米级分辨率下实现叶片、根系及籽粒内部结构的无损三维成像;后者则在获取细胞形态信息的同时,同步捕捉组织内部的生化组分分布及光系统能量传递特征^[43~45]。两类平台在完全不破坏样本物理结构的前提下,为“微表型”特征的高通量解析提供了硬件基础。

基于上述平台,现代微观表型的解析能力已从单一的形态描述拓展至多维度特征的量化。在结构形态层面,气孔大小的自动化提取技术已趋于成熟,借助深度学习网络在水稻叶片上可实现0.97的识别精度^[46];小麦根部维管束面积、皮层厚度及木质部体积等三维结构参数通过Micro-CT实现了高保真重构,但受限于样本通量,其规模化应用仍面临挑战^[47,48]。在生理功能层面,油菜叶片的理论最大气孔导度的估算误差可控制在3.8%以内^[49];而针对模式植物(拟南芥)叶片细胞含水量、胞间CO₂浓度及代谢物浓度的原位测定则依赖核磁共振或拉曼光谱等高端设备,目前主要停留在实验室验证阶段^[50,51]。在生育动态层面,共聚焦活体成像技术可实现细胞分裂、扩张及迁移过程的动态追踪,但其高通量检测能力仍有待提升^[52]。在品质性状层面,水稻、玉米的籽粒内淀粉粒尺寸的高通量显微测定较为成熟,蛋白质粒径及细胞壁纤维素含量的原位光学检测也在稳步推进^[53,54]。

3.2 器官表型解析

器官尺度(叶、茎、穗、果实及根系等)是连接微观功能与个体表现的中间层级,其表型检测依赖于面向不同器官类型开发的多类硬件平台。地上部器官三维重建平台主要利用结构光、手持激光扫描仪或多视角立体视觉等技术,实现穗、果实、茎秆等器官的精细形态重构与结构表型参数提取^[55]。光谱成像平台集




图 3 (网络版彩色)多尺度作物表型检测关键技术与平台。技术成熟度(technology readiness level, TRL)是衡量一项技术发展现状的指标, 将其运用于表型检测技术, 旨在系统评估一项表型检测技术是处于早期的理论概念验证阶段(TRL 1~3), 还是受控实验室环境测试阶段(TRL 4~6), 抑或是已完成在大田真实环境中实现商业化高通量部署(TRL 7~9)。以全球主栽的禾谷类、油料作物为例, 选取了代表性表型参数, 通过检索近5年来发表的72篇研究文献报道对相应的表型检测技术进行了TRL评级

Figure 3 (Color online) Key technologies and platforms for multi-scale crop phenotypic detection. Technology readiness level (TRL) serves as an indicator for assessing the maturity of a given technology. When applied to phenotypic detection technologies, TRL enables systematic evaluation of whether a technology remains at the early conceptual or proof-of-concept stage (TRL 1–3), is undergoing testing in controlled laboratory or greenhouse environments (TRL 4–6), or has achieved commercial-scale, high-throughput deployment in real-world field conditions (TRL 7–9). Taking globally cultivated cereal and oil crops as examples, representative phenotypic traits were selected, and the corresponding detection technologies were rated for TRL based on a review of 72 research articles published in the past five years

成高光谱或热红外传感器, 用于反演叶片尺度的叶绿素、氮素、水分等生化组分含量, 并捕捉病害侵染或养分胁迫引起的早期异常^[56,57]。根系原位检测平台则包括微根管系统与CT系统, 前者通过埋设透明管实现根系动态的长期连续观测, 后者采用透明基质模拟土

壤环境, 能够完整重建根系三维拓扑构型^[58,59]。

器官尺度各项参数解析的技术成熟度也存在差异。结构参数中, 水稻、玉米、油菜等作物叶面积、根长等几何特征的提取已高度自动化, 三维点云对器官面积的测算精度普遍达95%; 叶片卷曲度、根系形态等

空间拓扑结构的量化已完成实验验证^[60-62]。生理参数方面,基于光谱反演的叶片叶绿素及氮含量已进入商业化应用阶段,叶片含水量预测表现出高度可靠性,基于荧光测量叶片的光合强度也具备良好准确性^[57,63,64]。动态特征方面,叶片生长率依赖自动化平台的高频时序成像以实现动态追踪,而根系生长率的原位监测仍受土壤介质遮挡的物理限制,精度较低^[65,66]。产量品质方面,水稻、小麦等禾谷类作物的千粒重、穗粒数、结实率及淀粉含量等参数需先人工脱粒送入相应检测设备后,依托X射线CT及光谱技术实现自动化提取,基于深度学习的饱满与干瘪籽粒分类准确率可达90%以上^[67,68]。

3.3 单株表型解析

单株尺度的表型检测旨在获取作物个体瞬时生长状态及全生育期的连续生长轨迹,解析其与环境互作的过程,其核心支撑是面向单株水平的各类自动化表型平台。根据部署方式与硬件结构的差异,这些平台可分为温室传送带式高通量平台、龙门架式平台以及可移动地面机器人平台三类。传送带式平台将待测植株依次通过固定安装的检测室,集成RGB、高光谱、荧光及热红外等多模态传感矩阵,可在全生育期内实现高频次、非破坏性的连续扫描^[69]。龙门架式平台沿轨道运行,避免了植株移动所导致的成像扰动,更适用于对震动敏感的生理指标监测及长期定位逆境试验。面向温室的机器人平台搭载多自由度机械臂与多传感器组合,可以通过感知算法实现主动拨开遮挡叶片,采集冠层内部数据^[70]。

借助上述平台,单株尺度的表型解析可同时实现静态测量与动态监测。在形态结构维度,常规的株高、叶倾角等参数的提取已被广泛整合进育种流程,基于深度学习的水稻有效分蘖计数与实测值的相关系数可达 $R=0.97$,相对误差小于5%,但需要在水稻成熟收割后进行检测,具有滞后性;作物植株尺度的占空比及分支数等结构描述可通过三维点云实现精准计算^[24,71,72]。在生理功能维度,整株叶绿素含量及光合强度可通过荧光成像系统实现无损诊断,而氮利用率及水分利用率的精准估算因涉及整株代谢建模,目前仍处于原型验证阶段^[73-75]。在生育动态维度,高频时序成像使出苗率、生育期的捕捉高效可靠,而叶倾角动态变化及稻、麦作物的分蘖动态等精细参数的提取受遮挡影响,精度相对较差^[71,76,77]。在产量品质维度,稻穗、麦穗数及

地上部总生物量的非破坏性估算模型已具备较高吻合度(预测值与实际值的决定系数 $R^2>0.86$),但受限于生育后期冠层结构复杂,单株产量及收获指数的直接预测仍具有挑战^[78,79]。

3.4 群体表型解析

群体尺度检测面向时空异质性强、环境噪声复杂的大田场景,数据采集需兼顾效率与质量。当前应用于群体尺度的表型平台主要包括无人机平台、地面移动平台与定点观测平台三类。无人机平台以多旋翼无人机为主,搭载可见光、多光谱、轻量化激光雷达等多源传感器,能够以厘米级,甚至毫米级分辨率快速覆盖成百上千个育种小区,识别不同小区间冠层形态结构(株高、覆盖度),生理功能(光合强度),生化组分(叶绿素含量)等参数之间的差异,为优良品种选育提供高通量数据支撑^[13,20,80]。地面移动平台包括无人车与龙门架,无人车可在作物行间移动,获取下层叶片的倾角分布、茎秆粗细及冠层孔隙度等精细结构数据^[81,82];龙门架沿轨道运行,适用于在同一田块进行高频次、长时序观测的试验。定点观测平台则是布设于田间固定位置的自动化气象站与作物传感系统,集成光谱、热红外及环境传感器,为群体尺度动态监测提供长期稳定的时间序列数据。

在大田环境下,群体尺度的表型解析聚焦于宏观参数的高通量获取。结构特征方面,水稻、小麦、玉米、油菜、棉花等作物的覆盖度、叶面积指数、冠层体积及群体倒伏面积是应用最为成熟的表型参数,利用无人机搭载激光雷达提取冠层高度的决定系数可达0.91以上,均方根误差稳定在厘米级^[14,83,84]。生理监测方面,针对水稻的冠层温度及叶绿素含量的高通量反演模型可以实现跨地区泛化,冠层水含量及氮含量的光谱诊断精度稳步提升,但大面积冠层光合强度的测算精度较低^[85-87]。动态追踪方面,时序数据被成功用于提取冠层覆盖度变化及关键物候期,基于集成机器学习的水稻物候期识别准确率突破96%,水稻抽穗动态等参数亦展现出较强的多品种泛化性^[11,27]。产量预测方面,适用于水稻、小麦、玉米、大豆、油菜的群体生物量及单产的预测模型已得到广泛验证,但受大田复杂环境的影响,模型泛化性相对较低^[88,89]。

4 作物表型图谱数据处理与分析

在获取了海量原始图谱数据后,如何从包含环境

噪声且模态各异的光学图谱中提取具有生物学意义的表型性状,是作物表型组学研究面临的核心挑战^[70,90,91]。这一挑战主要体现在两方面。一方面,数据获取环节的复杂性增加了后续解析的难度。多源传感器(可见光相机、光谱相机、叶绿素荧光、热红外相机等)与多平台(如箱体式平台、地面移动平台、无人机等)的广泛应用虽提升了图谱数据采集效率,但也引入了复杂的系统性误差,如光照变化导致辐射漂移、传感器姿态与地形起伏易引起几何畸变,而遮挡及风场等影响则会造成三维数据的结构缺失与配准误差;另一方面,数据解析模型的技术迭代也影响着表型解析的精度与效率。早期研究更多依赖变量间相关关系描述的统计分析和人工设计特征的机器学习方法对单一表型性状进行解析。近年来,计算机视觉与深度学习技术的突破推动了以卷积神经网络、Transformer等为代表的端到端深度学习模型的发展。这类模型能够直接从原始图谱中自动学习多层次特征表示,降低了多人工干预和先验知识的依赖,使多任务协同学习与大规模表型数据的自动化解析成为可能^[92]。在此基础上,人工智能大模型的兴起进一步推动了更具普适性和逻辑推理能力的农业基础模型构建,为复杂场景下的作物表型精准解析提供了新的技术路径(图4)。

4.1 图谱数据校正

随着表型组学进入高通量时代,数据规模持续扩大,但数据质量正逐渐成为制约表型解析精度的主要因素。同一性状若在不同时间、地点或传感器条件下获取,缺乏标准的预处理与校正流程,即便是先进的算法也难以在噪声数据中提取有效信号。因此,建立规范的图谱数据校准体系,最大限度消除系统性误差,是提升数据在时空维度上的一致性与复用性的根本前提。

以可见光成像为例,其数据获取虽最为便捷,但因移动平台运动、相机抖动、镜头畸变以及田间光照变化等因素,导致几何偏差和颜色失真。针对上述问题,需从几何与色彩层面分别进行校正。在几何校正层面,首先需利用相机内参标定消除镜头畸变,进而通过运动结构恢复算法重建相机位姿。在大尺度田间场景下,结合地面控制点进行地理参考校正,可生成具备精确空间坐标的高质量正射影像,实现多时相数据的像素级对齐,有利于作物株高、冠层覆盖度等形态结构参数的准确计算^[95,96]。在可见光图像的色彩校正层面,为

实现不同时相图像间颜色的一致性和准确性,提升表型图谱数据的跨时空复用性,Lu等人^[16]采用作物与标准色卡同光场成像的方法,结合颜色校正矩阵对不同光照条件下的图像颜色进行标准化处理。此外,田间复杂的阴影也是影响作物颜色信息的常见干扰因素,通常需结合局部阈值分割或光照不变特征变换等方法进行有效去除。

光谱图像数据反映了作物的生理生化信息,但其采集过程易受太阳高度角、冠层结构等因素干扰,影响传感器接收的辐射能量。因此,光谱预处理的核心在于辐射校正,目的是将传感器记录的量化数字值(digital number, DN)转化为反映植物真实物理属性的反射率光谱^[97]。常用方法是在光谱数据采集时,同步获取已知反射率的标准反射板,从而将传感器获取的DN值校正为反射率。该方法在成像环境稳定的条件下可以采集良好的二维光谱数据,但如果需要在三维空间中表示光谱的分布,受到植物各向异性反射的影响,需要采集已知反射率的标准反射半球结合光场分布来计算每个位置的反射率^[23]。此外,采集大范围光谱数据时,在光照变化剧烈的场景容易产生“阴阳图”,有研究提出利用上置光谱仪同步采集太阳入射光谱以实时校正多光谱图像,反射光谱提取的准确性提升超20%^[93]。针对特定天气或高空飞行,有时还需叠加大气传输模型进行大气校正^[98]。此外,受光谱传感器感光元器件的影响,前期处理还需特别强化暗电流扣除与杂散光修正^[99]。

三维点云能够真实还原作物的空间结构,但受限于枝叶遮挡、风场扰动或扫描盲区,原始点云常存在噪声点、密度不均与结构缺失等问题^[100,101]。前期预处理主要包括点云去噪和下采样,利用统计离群点移除等滤波算法滤除环境噪声,并通过体素下采样等策略均衡点云密度、降低计算复杂度。而作物器官交叉遮挡导致的点云缺失是目前三维表型精准重建所面临的核心难点。对于单株作物,视角缺失会导致部分器官残缺,随着计算机图形学的发展,通过定义叶片等器官的形状规则,可以在一定程度上补全残缺区域^[102]。然而,对于群体内部的遮挡区域,则无法通过规则定义缺失区域的形状,为此,Guo等人^[94]提出了一种基于多分辨率动态图卷积与点金字塔解码器的点云补全网络,通过虚实融合的仿真策略构建遮挡标注数据集,成功实现田间遮挡条件下油菜及水稻群体残缺点云的补全,为后续作物三维形态结构指标(如冠层体积、叶倾角




图 4 (网络版彩色)作物表型图谱数据校正与解析模型^[16,93,94]。在数据校正层面,主要包括可见光的几何与颜色校正、光谱的辐射校正,以及三维点云的去噪与补全,旨在从源头保障数据的高保真度;在解析模型构建层面,其发展历程从传统机器学习模型发展到端到端深度学习模型,并进一步迈向融合多源特征的农业多模态大模型。 ΔE , 色差; DVI, 差值植被指数; NDVI, 归一化植被指数; CNN, 卷积神经网络; Transformer/Attention, 基于注意力机制的深度学习架构。图中的卡通标识由人工智能工具(Nano Banana)辅助生成

Figure 4 (Color online) Calibration and analytical models for crop phenotypic data^[16,93,94]. At the data calibration level, it primarily encompasses geometric and color correction for visible light imagery, radiometric calibration for spectral data, as well as denoising and completion for 3D point clouds, aiming to ensure high data fidelity from the source. At the analytical model construction level, its evolutionary trajectory progresses from traditional machine learning models to end-to-end deep learning models, and further advances towards agricultural multimodal large models that integrate multi-source features. ΔE : color difference; DVI: difference vegetation index; NDVI: normalized difference vegetation index; CNN: convolutional neural network; Transformer/Attention: deep learning architectures based on attention mechanisms. The cartoon logo in the picture is generated with the assistance of artificial intelligence tools (Nano Banana)

等)的精准提取以及产量预测奠定了坚实的数据基础。

4.2 解析模型构建

表型解析模型的核心任务是将经过前期处理的多源、高维图谱数据,转化为具有明确生物学意义的定量性状指标(如形态结构、生理生化、生育动态、产量品质等),从而为下游的作物遗传机理挖掘与智能育种决策提供直接的数据支撑。随着计算科学与人工智能技术的交叉融合,作物表型解析算法不断演进,其发

展大体可归纳为三个主要阶段:早期依赖专家先验知识与特征工程的传统机器学习方法、当前作为主流研究手段的端到端深度学习模型,以及近年来开始在复杂表型解析中逐步引入的智能大模型^[103]。

传统表型解析方法主要基于显式特征提取与统计建模。针对可见光图像,通常从颜色、纹理、形状与几何统计等维度设计特征^[104];处理光谱数据时,则侧重于光谱平滑、降维、特征波段选择等方法来解决光谱数据的高维共线性问题^[105];而对于点云数据,常通过

高度分位数、冠层粗糙度、体素占据率、结构统计量等实现结构性状估测^[106]。相应的代表性建模方法包括线性/岭回归、偏最小二乘回归、支持向量机、随机森林等^[107~109]。上述建模方法的特点在于,模型性能高度依赖特征质量,而特征质量又受限于数据预处理手段与相应的先验知识。尽管如此,传统机器学习在表型领域至今仍具不可替代的价值,其一,针对采集条件差异大(跨地区、跨年份)或样本量少的数据,传统模型结构简单,往往不易过拟合,表现出较好的稳健性;其二,由于现代农业育种不仅关注预测精度,更需要探明性状背后的生物学机理与遗传关联,传统模型能够提供清晰的变量重要性评估与误差溯源,满足了农学应用对模型可解释性的需求。

在深度学习阶段,各类端到端网络模型针对不同模态的数据展现出强大的表型解析能力。以二维图像为例,卷积神经网络与其衍生结构被广泛用于冠层覆盖度提取、病斑检测以及器官目标识别^[110]; U-Net (U-shaped convolutional neural network)、Mask R-CNN (mask region-based convolutional neural network)等结构使小区、植株、器官级分割与形态学测量更加自动化^[111]; YOLO(you only look once)系列等单阶段检测器进一步提升了田间数据处理的效率^[112]; 基于密度图估计与关键点定位的深度学习方法在穗数、果实数等计数任务中表现出对遮挡场景的优异适应性^[113]。对于三维点云数据, PointNet/PointNet++、基于体素或稀疏卷积的网络逐步用于点云分割、器官识别与结构参数(株高、叶倾角、冠层体积等)计算,推动点云由可视化效果呈现转向表型的精准提取^[21]。此外,作物的生长发育与环境胁迫响应是一个连续的动态过程,其表型特征表现出特定的时序演变规律。由此,时序CNN(convolutional neural network)、LSTM/GRU(long short-term memory/gated recurrent unit)、时序Transformer等模型开始用于生育期判别、性状动态预测与群体生长过程建模,动态表征了作物的多时相性状^[27]。

进入大模型阶段,表型解析方法的发展呈现出多元化的技术途径。一方面,自监督预训练与视觉基础模型提供更通用的视觉表征,使在少量标注条件下的迁移学习具备现实可行性,传统深度学习高度依赖海量人工标注,而SAM(segment anything model)凭借强大的零样本分割能力,能够通过简单的点、框提示即时获取精确的器官掩码,将标注效率提升数倍,有效突破了复杂田间场景下大规模高质量数据集构建的瓶

颈^[20]; 另一方面,多模态大模型实现了专家经验、气象数据、栽培管理与图谱数据的深度融合,模型不仅能提取表型性状,还能通过自然语言交互,结合环境上下文进行多模态推理,提供决策支持^[114]; 此外,不同于传统模型在面对新物种或极端环境时需反复重训练,大模型通过海量数据的预训练,表现出较好的跨物种适配性,其具备的少样本学习能力对新样本的表型解析也能够达到可接受的灵敏度和精度。

尽管人工智能模型的迭代显著提升了表型特征的提取能力,但作物表型的高效解析仍面临算法架构创新未能有效融合生物学机理的瓶颈。现有解析方法多局限于对单一性状指标的精度提升,尚未形成针对不同育种阶段目标性状的标准化检测体系。未来研究应着力构建融合作物生物学机理、专家知识以及育种和栽培经验的植物系统模型,将基因型、环境与管理措施等多源信息纳入统一框架,推动场景驱动的植物表型解析从单纯的数据处理升级为知识引导的智能决策。

5 结语

在全球气候变化与粮食安全战略的双重驱动下,新一轮人工智能革命正加速推动现代农业发展。作物表型组学的未来发展将突破传统单一图谱数据采集与表型提取的局限,迈向系统性建模与智能决策的全新阶段。在通用人工智能时代,依托视觉基础模型、多智能体协同感知以及作物数字孪生等前沿技术,通过农业工程、计算机科学、生物信息学、作物科学与生物育种的深度交叉融合,作物表型组学不仅限于形态感知的工具,更将全面赋能优良种质的精准设计与定向培育,重塑现代种业的科学范式。

围绕上述发展目标,亟待在底层感知硬件与共性数据算法上取得关键性突破。首先,应攻克底层传感技术瓶颈,研发兼顾深层穿透力与高通量的新型多模态集成硬件,提升复杂大田环境下的动态感知精度与鲁棒性。其次,建立涵盖“硬件标定-数据采集-清洗校正”的全链条标准化体系,并全面推行FAIR原则,这是从根本上打破“数据孤岛”、释放表型大数据价值的前提。此外,突破现有解析模型的跨时空泛化瓶颈,构建具备生物学机制约束的农业垂域大模型,跨越技术落地鸿沟。

立足最终产业应用愿景,作物表型组学将为智能育种、精准种植与自主农业系统提供不可替代的驱动力。在基础研究与育种端,高精度、长时序的表型大数

据将全面支撑全基因组关联分析与关键功能基因位点挖掘,紧密结合真实育种需求,加速从“经验育种”向“智能设计育种”跨越。在生产端,多尺度表型感知将动态揭示作物生长状态,为大田作物提供实时、精准的水

肥药施用管控决策。最终,表型智能检测技术将与机器人、物联网等技术深度融合,构建高度自主化的智慧农业生产系统,为应对未来极端气候挑战、实现全球农业可持续发展贡献核心力量。

参考文献

- Falcon W P, Naylor R L, Shankar N D. Rethinking global food demand for 2050. *Popul Dev Rev*, 2022, 48: 921–957
- Lipper L, Thornton P, Campbell B M, et al. Climate-smart agriculture for food security. *Nat Clim Change*, 2014, 4: 1068–1072
- Sun Y, Shang L, Zhu Q H, et al. Twenty years of plant genome sequencing: achievements and challenges. *Trends Plant Sci*, 2022, 27: 391–401
- Tang Y, Wang J L, Wang X, et al. Crop phenomics: progress in the past decade, current challenges, and future perspectives (in Chinese). *Sci Sin Vitae*, 2026, 56: 1239–1260 [汤延, 王江林, 王曦, 等. 作物表型组学: 近十年进展、挑战和展望. *中国科学: 生命科学*, 2026, 56: 1239–1260]
- Jacquemoud S, Verhoef W, Baret F, et al. PROSPECT+SAIL models: a review of use for vegetation characterization. *Remote Sens Environ*, 2009, 113: S56–S66
- Sun D, Xu Y, Cen H. Optical sensors: deciphering plant phenomics in breeding factories. *Trends Plant Sci*, 2022, 27: 209–210
- Herrero-Huerta M, Raunonen P, Gonzalez-Aguilera D. 4DRoot: root phenotyping software for temporal 3D scans by X-ray computed tomography. *Front Plant Sci*, 2022, 13: 1
- Hassan M A, Chang C Y Y. PhenoGazer: a high-throughput phenotyping system to track plant stress responses using hyperspectral reflectance, nighttime chlorophyll fluorescence and RGB imaging in controlled environments. *Plant Phenomics*, 2025, 7: 100047
- Tao H, Xu S, Tian Y, et al. Proximal and remote sensing in plant phenomics: 20 years of progress, challenges, and perspectives. *Plant Commun*, 2022, 3: 100344
- Hall R D, D’auria J C, Ferreira A C S, et al. High-throughput plant phenotyping: a role for metabolomics? *Trends Plant Sci*, 2022, 27: 549–563
- Lu X, Shen Y, Xie J, et al. Phenotyping of panicle number and shape in rice breeding materials based on unmanned aerial vehicle imagery. *Plant Phenomics*, 2024, 6: 0265
- Yang X, Lu X, Xie P, et al. PanicleNeRF: low tphone. *Plant Phenomics*, 2024, 6: 0279
- Shen Y, Lu X, Lyu M, et al. High-throughput phenotyping of individual plant height in an oilseed rape population based on Mask-RCNN and UAV images. *Precision Agric*, 2024, 25: 811–833
- Shu M, Li Q, Ghafoor A, et al. Using the plant height and canopy coverage to estimate maize aboveground biomass with UAV digital images. *Eur J Agronomy*, 2023, 151: 126957
- Liu T, Zhao Y, Wu F, et al. The estimation of wheat tiller number based on UAV images and gradual change features (GCFs). *Precision Agric*, 2023, 24: 353–374
- Lu X, Xie J, Yan J, et al. Precise image color correction based on dual unmanned aerial vehicle cooperative flight. *Plant Phenomics*, 2025, 7: 100101
- Zhang L, Zhang H, Han W, et al. Effects of image spatial resolution and statistical scale on water stress estimation performance of MGDEXG: a new crop water stress indicator derived from RGB images. *Agric Water Manage*, 2022, 264: 107506
- Banerjee A, Kumari M, Kumar A, et al. Multimodal RGB and optical coherence tomography imaging for enhanced machine learning classification of crop diseases and stress phenotyping. *Instrumentation Sci Tech*, 2026, 54: 62–85
- Yang H, Fei L, Wu G, et al. A novel deep learning framework for identifying soybean salt stress levels using RGB leaf images. *Industrial Crops Products*, 2025, 228: 120874
- Shen Y, Zhou H, Yang X, et al. Biomass phenotyping of oilseed rape through UAV multi-view oblique imaging with 3DGS and SAM model. *Comput Electron Agr*, 2025, 235: 110320
- Du R, Ma Z, Xie P, et al. PST: plant segmentation transformer for 3D point clouds of rapeseed plants at the podding stage. *ISPRS J Photogrammetry Remote Sens*, 2023, 195: 380–392
- Paulus S. Measuring crops in 3D: using geometry for plant phenotyping. *Plant Methods*, 2019, 15: 103–115
- Xie P, Ma Z, Du R, et al. An unmanned ground vehicle phenotyping-based method to generate three-dimensional multispectral point clouds for deciphering spatial heterogeneity in plant traits. *Mol Plant*, 2024, 17: 1624–1638
- Liu F, Song Q, Zhao J, et al. Canopy occupation volume as an indicator of canopy photosynthetic capacity. *New Phytol*, 2021, 232: 941–956
- Shao M R, Jiang N, Li M, et al. Complementary phenotyping of maize root system architecture by root pulling force and X-ray imaging. *Plant Phenomics*, 2021, 2021: 9859254

- 26 Patel A K, Park E S, Lee H, et al. Deep learning-based plant organ segmentation and phenotyping of sorghum plants using LiDAR point cloud. [IEEE J Sel Top Appl Earth Observations Remote Sens](#), 2023, 16: 8492–8507
- 27 Lyu M, Lu X, Shen Y, et al. UAV time-series imagery with novel machine learning to estimate heading dates of rice accessions for breeding. [Agric For Meteor](#), 2023, 341: 109646
- 28 Jin Y, Peng Y, Song H, et al. Combining hyperspectral imaging with ensemble learning for estimating rapeseed chlorophyll content under different waterlogging durations. [Plants](#), 2025, 14: 3713
- 29 Banerjee B P, Joshi S, Thoday-Kennedy E, et al. High-throughput phenotyping using digital and hyperspectral imaging-derived biomarkers for genotypic nitrogen response. [J Exp Bot](#), 2020, 71: 4604–4615
- 30 Wang Z S, Jia Y P, Zhang J, et al. Multispectral imaging and its applications in plant science research (in Chinese). [Chin Bull Bot](#), 2021, 56: 500–508 [王众司, 贾亚萍, 张瑾, 等. 多光谱成像技术在植物学研究中的应用. [植物学报](#), 2021, 56: 500–508]
- 31 Braga P, Crusiol L G T, Nanni M R, et al. Vegetation indices and NIR-SWIR spectral bands as a phenotyping tool for water status determination in soybean. [Precision Agric](#), 2021, 22: 249–266
- 32 Bhakta I, Phadikar S, Majumder K, et al. A novel plant disease prediction model based on thermal images using modified deep convolutional neural network. [Precision Agric](#), 2023, 24: 23–39
- 33 Zhai Y, Zhou L, Qi H, et al. Application of visible/near-infrared spectroscopy and hyperspectral imaging with machine learning for high-throughput plant heavy metal stress phenotyping: a review. [Plant Phenomics](#), 2023, 5: 0124
- 34 Chen D, Neumann K, Friedel S, et al. Dissecting the phenotypic components of crop plant growth and drought responses based on high-throughput image analysis. [Plant Cell](#), 2014, 26: 4636–4655
- 35 Mangalraj P, Cho B K. Recent trends and advances in hyperspectral imaging techniques to estimate solar induced fluorescence for plant phenotyping. [Ecol Indic](#), 2022, 137: 108721
- 36 Moustaka J, Moustakas M. Early-stage detection of biotic and abiotic stress on plants by chlorophyll fluorescence imaging analysis. [Biosensors](#), 2023, 13: 796–815
- 37 Jonard F, De Cannière S, Brüggemann N, et al. Value of sun-induced chlorophyll fluorescence for quantifying hydrological states and fluxes: current status and challenges. [Agric For Meteor](#), 2020, 291: 108088
- 38 Zait Y, Shemer O E, Cochavi A. Dynamic responses of chlorophyll fluorescence parameters to drought across diverse plant families. [Physiologia Plantarum](#), 2024, 176: e14527
- 39 Zhou Y, Huang Z, Zhou W, et al. Optimized transfer learning for chlorophyll content estimations across datasets of different species using sun-induced chlorophyll fluorescence and reflectance. [Remote Sens](#), 2024, 16: 1869
- 40 Chen S, Zhai L, Zhou Y, et al. Early diagnosis and mechanistic understanding of citrus Huanglongbing via sun-induced chlorophyll fluorescence. [Comput Electron Agr](#), 2023, 215: 108357
- 41 Hofmann T, Lowry G V, Ghoshal S, et al. Technology readiness and overcoming barriers to sustainably implement nanotechnology-enabled plant agriculture. [Nat Food](#), 2020, 1: 416–425
- 42 Arzuaga-Ochoa M E, Acosta-Coll M, Barrios Barrios M. The validation-deployment gap in agricultural information systems: a systematic technology readiness assessment. [Informatics](#), 2026, 13: 14–51
- 43 Dev A, Mohamed Y, Hamed A, et al. Automated phenotyping of herbaceous biomass using U-net architecture for μ -CT images segmentation. 2024 2nd International Conference on Artificial Intelligence, Blockchain, and Internet of Things (AIBThings), Mt Pleasant, MI, USA, 2024. 1–6
- 44 Wu D, Guo Z, Ye J, et al. Combining high-throughput micro-CT-RGB phenotyping and genome-wide association study to dissect the genetic architecture of tiller growth in rice. [J Exp Bot](#), 2019, 70: 545–561
- 45 Harter K, Meixner A J, Schleifenbaum F. Spectro-microscopy of living plant cells. [Mol Plant](#), 2012, 5: 14–26
- 46 Caine R S, Harrison E L, Sloan J, et al. The influences of stomatal size and density on rice abiotic stress resilience. [New Phytol](#), 2023, 237: 2180–2195
- 47 Zhai L, Yan A, Shao K, et al. *Large Vascular Bundle Phloem Area 4* enhances grain yield and quality in rice via source-sink-flow. [Plant Physiol](#), 2023, 191: 317–334
- 48 Du P, Zhu Y H, Weiner J, et al. Reduced root cortical tissue with an increased root xylem investment is associated with high wheat yields in central China. [Plants](#), 2024, 13: 1075
- 49 Wang Y, Wang Y, Tang Y, et al. Stomata conductance as a goalkeeper for increased photosynthetic efficiency. [Curr Opin Plant Biol](#), 2022, 70: 102310
- 50 Ievinsh G. Water content of plant tissues: so simple that almost forgotten? [Plants](#), 2023, 12: 1238
- 51 Barickman T C, Olorunwa O J, Sehgal A, et al. Yield, physiological performance, and phytochemistry of basil (*Ocimum basilicum* L.) under temperature stress and elevated CO₂ concentrations. [Plants](#), 2021, 10: 1072
- 52 Sablowski R, Gutierrez C. Cycling in a crowd: coordination of plant cell division, growth, and cell fate. [Plant Cell](#), 2022, 34: 193–208

- 53 Islam M A, Kulathunga J, Ray A, et al. Particle size reduction influences starch and protein functionality, and nutritional quality of stone milled whole wheat flour from hard red spring wheat. *Food Biosci*, 2024, 61: 104612
- 54 Li M, Zheng X, Sun B, et al. Effects of the interaction of different particle size wheat bran dietary fiber with gluten protein and starch on dough structure and properties. *Int J Biol Macromol*, 2025, 307: 142045
- 55 Zhang D W, Gajardo J, Medic T, et al. Wheat3DGS: in-field 3D reconstruction, instance segmentation and phenotyping of wheat heads with Gaussian splatting., 2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Nashville, TN, USA, 2025. 5399–5409
- 56 Chen X, Dong Z, Liu J, et al. Hyperspectral characteristics and quantitative analysis of leaf chlorophyll by reflectance spectroscopy based on a genetic algorithm in combination with partial least squares regression. *Spectrochim Acta Part A-Mol Biomol Spectr*, 2020, 243: 118786
- 57 Féret J B, Berger K, de Boissieu F, et al. PROSPECT-PRO for estimating content of nitrogen-containing leaf proteins and other carbon-based constituents. *Remote Sens Environ*, 2021, 252: 112173
- 58 Bello-Bello E, López-Arredondo D, Rico-Chambrón T Y, et al. Conquering compacted soils: uncovering the molecular components of root soil penetration. *Trends Plant Sci*, 2022, 27: 814–827
- 59 Gaggion N, Ariel F, Daric V, et al. ChronoRoot: high-throughput phenotyping by deep segmentation networks reveals novel temporal parameters of plant root system architecture. *GigaScience*, 2021, 10: giab052
- 60 Sun B, Zain M, Zhang L, et al. Stem-leaf segmentation and morphological traits extraction in rapeseed seedlings using a three-dimensional point cloud. *Agronomy*, 2025, 15: 276–292
- 61 Cui X, Sun L, Fan X, et al. A method to quantify the degree of leaf curl in nodular Chinese cabbage (*Brassica pekinensis*). *Sci Horticulturae*, 2024, 330: 113054
- 62 Lopez G, Ahmadi S H, Amelung W, et al. Nutrient deficiency effects on root architecture and root-to-shoot ratio in arable crops. *Front Plant Sci*, 2023, 13: 1–8
- 63 Zhang P, Zhang Z, Li B, et al. Photosynthetic rate prediction model of newborn leaves verified by core fluorescence parameters. *Sci Rep*, 2020, 10: 3013
- 64 Zhang R, Yang P, Liu S, et al. Evaluation of the methods for estimating leaf chlorophyll content with SPAD chlorophyll meters. *Remote Sens*, 2022, 14: 5144
- 65 Wang J, Du G, Tian J, et al. Effect of irrigation methods on root growth, root-shoot ratio and yield components of cotton by regulating the growth redundancy of root and shoot. *Agric Water Manage*, 2020, 234: 106120
- 66 Jaškūnė K, Armonienė R, Liatukas Ž, et al. Relationship between freezing tolerance and leaf growth during acclimation in winter wheat. *Agronomy*, 2022, 12: 859
- 67 Liu T, Wu W, Chen W, et al. A shadow-based method to calculate the percentage of filled rice grains. *BioSyst Eng*, 2016, 150: 79–88
- 68 Tanabata T, Shibaya T, Hori K, et al. *SmartGrain*: high-throughput phenotyping software for measuring seed shape through image analysis. *Plant Physiol*, 2012, 160: 1871–1880
- 69 He Y, Li X Y, Yang G F, et al. Research progress and prospect of indoor high-throughput germplasm phenotyping platforms (in Chinese). *Trans Chin Soc Agric Eng*, 2022, 38: 127–141 [何勇, 李禧尧, 杨国峰, 等. 室内高通量种质资源表型平台研究进展与展望. 农业工程学报, 2022, 38: 127–141]
- 70 Song P, Li Z D, Yang M, et al. Current status and prospects of crop phenotyping robots (in Chinese). *Trans Chin Soc Agric Mach*, 2025, 56: 1–17 [宋鹏, 李正达, 杨蒙, 等. 作物表型机器人研究现状与展望. 农业机械学报, 2025, 56: 1–17]
- 71 Jiang S, Wu X, Wang Q, et al. Auto-LIA: the automated vision-based leaf inclination angle measurement system improves monitoring of plant physiology. *Plant Phenomics*, 2024, 6: 0245
- 72 Yang W, Xu X, Duan L, et al. High-throughput measurement of rice tillers using a conveyor equipped with X-ray computed tomography. *Rev Sci Instruments*, 2011, 82: 025102
- 73 Hatfield J L, Dold C. Water-use efficiency: advances and challenges in a changing climate. *Front Plant Sci*, 2019, 10: 103
- 74 Congreves K A, Otchere O, Ferland D, et al. Nitrogen use efficiency definitions of today and tomorrow. *Front Plant Sci*, 2021, 12: 1
- 75 Sid'ko A F, Botvich I Y, Pisman T I, et al. Estimation of chlorophyll content and yield of wheat crops from reflectance spectra obtained by ground-based remote measurements. *Field Crops Res*, 2017, 207: 24–29
- 76 Tan S, Liu J, Lu H, et al. Machine learning approaches for rice seedling growth stages detection. *Front Plant Sci*, 2022, 13: 914771
- 77 Wang X H, Li X M, Tang Q Y, et al. Construction and application of dynamic tillering model for rice population (in Chinese). *Trans Chin Soc Agric Eng*, 2024, 40: 213–221 [王小卉, 李绪孟, 唐启源, 等. 水稻群体分蘖动态模型构建与应用. 农业工程学报, 2024, 40: 213–221]
- 78 Wu D, Yu L, Ye J, et al. Panicle-3D: a low-cost 3D-modeling method for rice panicles based on deep learning, shape from silhouette, and supervoxel clustering. *Crop J*, 2022, 10: 1386–1398
- 79 Xiang L, Bao Y, Tang L, et al. Automated morphological traits extraction for sorghum plants via 3D point cloud data analysis. *Comput Electron*

- [Agr](#), 2019, 162: 951–961
- 80 Melandri G, Prashar A, McCouch S R, et al. Association mapping and genetic dissection of drought-induced canopy temperature differences in rice. [J Exp Bot](#), 2020, 71: 1614–1627
 - 81 Bailey B N, Mahaffee W F. Rapid measurement of the three-dimensional distribution of leaf orientation and the leaf angle probability density function using terrestrial LiDAR scanning. [Remote Sens Environ](#), 2017, 194: 63–76
 - 82 Magistri F, Marks E, Nagulavancha S, et al. Contrastive 3D shape completion and reconstruction for agricultural robots using RGB-D frames. [IEEE Robot Autom Lett](#), 2022, 7: 10120–10127
 - 83 Li X, Li X, Liu W, et al. A UAV-based framework for crop lodging assessment. [Eur J Agronomy](#), 2021, 123: 126201
 - 84 Jing L, Wei X, Song Q, et al. Research on estimating rice canopy height and LAI based on LiDAR data. [Sensors](#), 2023, 23: 8334
 - 85 Giménez-Gallego J, González-Teruel J D, Soto-Valles F, et al. Intelligent thermal image-based sensor for affordable measurement of crop canopy temperature. [Comput Electron Agr](#), 2021, 188: 106319
 - 86 Li Z, Zhang Q, Li J, et al. Solar-induced chlorophyll fluorescence and its link to canopy photosynthesis in maize from continuous ground measurements. [Remote Sens Environ](#), 2020, 236: 111420
 - 87 Wan L, Zhou W, He Y, et al. Combining transfer learning and hyperspectral reflectance analysis to assess leaf nitrogen concentration across different plant species datasets. [Remote Sens Environ](#), 2022, 269: 112826
 - 88 Chu Z, Yu J. An end-to-end model for rice yield prediction using deep learning fusion. [Comput Electron Agr](#), 2020, 174: 105471
 - 89 Mia M S, Tanabe R, Habibi L N, et al. Multimodal deep learning for rice yield prediction using UAV-based multispectral imagery and weather data. [Remote Sens](#), 2023, 15: 2511
 - 90 Mu J H, Chen Y Z, Feng H, et al. A new revolution in crop breeding: the era of high-throughput phenomics (in Chinese). [Plant Sci J](#), 2016, 34: 1–10 [穆金虎, 陈玉泽, 冯慧, 等. 作物育种学领域新的革命: 高通量的表型组学时代. [植物科学学报](#), 2016, 34: 1–10]
 - 91 Guo X Y, Wu S, Gou W B, et al. Review of integrated technology and equipment system for crop phenomics big data factory (in Chinese). [Trans Chin Soc Agric Mach](#), 2026, 57: 1–18, 61 [郭新宇, 吴升, 苟文博, 等. 农作物表型组大数据工厂成套技术装备研究综述. [农业机械学报](#), 2026, 57: 1–18, 61]
 - 92 Cen H Y, Zhu Y M, Sun D W, et al. Current status and future perspective of the application of deep learning in plant phenotype research (in Chinese). [Trans Chin Soc Agric Eng](#), 2020, 36: 1–16 [岑海燕, 朱月明, 孙大伟, 等. 深度学习在植物表型研究中的应用现状与展望. [农业工程学报](#), 2020, 36: 1–16]
 - 93 Xie J Y, Shen Y T, Cen H Y. Real-time reflectance generation for UAV multispectral imagery using an onboard downwelling spectrometer in varied weather conditions. 2024, arXiv, 2412.19527
 - 94 Guo Z, Yang X, Shen Y, et al. A novel point cloud completion model for three-dimensional reconstruction of complex, dynamic population-level crop canopy architecture. [Plant Commun](#), 2026, 7: 101675
 - 95 Agüera-Vega F, Carvajal-Ramírez F, Martínez-Carricondo P. Assessment of photogrammetric mapping accuracy based on variation ground control points number using unmanned aerial vehicle. [Measurement](#), 2017, 98: 221–227
 - 96 Taniguchi S, Sakamoto T, Imase R, et al. Prediction of heading date, culm length, and biomass from canopy-height-related parameters derived from time-series UAV observations of rice. [Front Plant Sci](#), 2022, 13: 1–4
 - 97 Clevers J G P W. The use of imaging spectrometry for agricultural applications. [ISPRS J Photogrammetry Remote Sens](#), 1999, 54: 299–304
 - 98 Aasen H, Honkavaara E, Lucieer A, et al. Quantitative remote sensing at ultra-high resolution with UAV spectroscopy: a review of sensor technology, measurement procedures, and data correction workflows. [Remote Sens](#), 2018, 10: 1091
 - 99 MacArthur A, Robinson I, Rossini M, et al. A dual-field-of-view spectrometer system for reflectance and fluorescence measurements (piccolo doppio) and correction of etaloning. In: [Proceedings of the Fifth International Workshop on Remote Sensing of Vegetation Fluorescence](#). European Space Agency, 2014
 - 100 Li D, Li J, Xiang S, et al. PSegNet: simultaneous semantic and instance segmentation for point clouds of plants. [Plant Phenomics](#), 2022, 2022: 9787643
 - 101 Li D, Wei Y, Zhu R. A comparative study on point cloud down-sampling strategies for deep learning-based crop organ segmentation. [Plant Methods](#), 2023, 19: 124–149
 - 102 Chen H, Liu S, Wang C, et al. Point cloud completion of plant leaves under occlusion conditions based on deep learning. [Plant Phenomics](#), 2023, 5: 0117
 - 103 Meraj T, Sharif M I, Raza M, et al. Computer vision-based plants phenotyping: a comprehensive survey. [iScience](#), 2024, 27: 108709
 - 104 Sarkar C, Gupta D, Gupta U, et al. Leaf disease detection using machine learning and deep learning: review and challenges. [Appl Soft Computing](#), 2023, 145: 110534
 - 105 Haghghattalab A, González Pérez L, Mondal S, et al. Application of unmanned aerial systems for high-throughput phenotyping of large wheat breeding nurseries. [Plant Methods](#), 2016, 12: 35–49

- 106 Paturkar A, Sen Gupta G, Bailey D. Plant trait measurement in 3D for growth monitoring. [Plant Methods](#), 2022, 18: 59–73
- 107 Cheng J H, Sun D W. Partial least squares regression (PLSR) applied to NIR and HSI spectral data modeling to predict chemical properties of fish muscle. [Food Eng Rev](#), 2017, 9: 36–49
- 108 Somvanshi M, Chavan P, Tambade S, et al. A review of machine learning techniques using decision tree and support vector machine. In: 2016 International Conference on Computing Communication Control and Automation (ICCUBEA), Pune, India, 2016. 1–7
- 109 Verrelst J, Alonso L, Camps-Valls G, et al. Retrieval of vegetation biophysical parameters using Gaussian process techniques. [IEEE Trans Geosci Remote Sens](#), 2012, 50: 1832–1843
- 110 Mohanty S P, Hughes D P, Salathé M. Using deep learning for image-based plant disease detection. [Front Plant Sci](#), 2016, 7: 1
- 111 Shi H, Shi D, Wang S, et al. Crop plant automatic detecting based on in-field images by lightweight DFU-Net model. [Comput Electron Agr](#), 2024, 217: 108649
- 112 Xu D, Huang X, Zhao Z, et al. Pha-YOLO: a multi-view Phalaenopsis flower detection and counting method based on improved YOLO11 with dynamic reference selection and adaptive thresholding. [Comput Electron Agr](#), 2026, 243: 111446
- 113 Tan C, Sun J, Song H, et al. A customized density map model and segment anything model for cotton boll number, size, and yield prediction in aerial images. [Comput Electron Agr](#), 2025, 232: 110065
- 114 Luan R. AgriM-LLM: an agriculture-specific multimodal large language model for intelligent crop disease and pest management. Preprints. 2026, 202601.0646.v1

Summary for “作物表型组学关键共性技术研究综述与展望”

Review and perspective of key generic technologies in crop phenomics

Ziyue Guo^{1,2†}, Yutao Shen^{1,2†}, Xuqi Lu^{1,2†}, Yue Li^{1,2}, Zichen Huang^{1,2} & Haiyan Cen^{1,2,3*}

¹ State Key Laboratory for Vegetation Structure, Function and Construction (Veglab), College of Biosystems Engineering and Food Science, Zhejiang University, Hangzhou 310058, China

² Key Laboratory of Spectroscopy Sensing, Ministry of Agriculture and Rural Affairs, Hangzhou 310058, China

³ Zhejiang Key Laboratory of Agricultural Remote Sensing and Information Technology, Hangzhou 310058, China

† Equally contributed to this work

* Corresponding author, E-mail: hycen@zju.edu.cn

Driven by the convergence of advanced sensing technologies, artificial intelligence, and high-performance computing, crop phenomics is undergoing a paradigm shift from individual trait measurement to multi-scale, intelligent perception systems that capture the full complexity of crop performance. The physical foundation of these sensing technologies is in the interaction of electromagnetic radiation with plant tissues, where photons across different wavebands induce electronic transitions, molecular vibrations, and thermal emissions, thereby providing information about morphological architecture, physiological status, biochemical composition, and genotype-by-environment (G×E) interactions. This review systematically describes the technical characteristics and applicable scenarios of primary optical sensors, including visible-light imaging, three-dimensional imaging, spectral imaging, chlorophyll fluorescence imaging, and thermal infrared imaging. Its further categories crop phenotyping platforms across different scales ranging from cellular and tissue levels to organs, individual plants, and populations in laboratory, climate-controlled chamber, greenhouse, and field conditions. Furthermore, their trade-offs in throughput, spatial resolution, environmental adaptation, and cost were also evaluated. Nevertheless, progress is constrained by several fundamental limitations. The heterogeneity of multi-source, multi-scale data, coupled with the absence of standardized protocols for radiometric and geometric calibrations, impedes data integration and reusability. Predictive models trained with data from specific genotypes or environmental conditions frequently fail to generalize across diverse crop species, climatic zones, or developmental stages. Moreover, the transition from handcrafted feature engineering to deep learning remains constrained by insufficient well-annotated datasets and the limited interpretability of many existing models. To overcome these challenges, several key priorities should be considered. First, standardized data acquisition and calibration protocols for different phenotyping platforms must be established to ensure data quality at the source. Second, the development of robust, transferable algorithms should be accelerated, moving beyond conventional feature engineering towards visual foundation models and multimodal architectures that integrate RGB images, spectral signatures, thermal data, and three-dimensional point clouds. Third, building shared, community-level databases that follow the FAIR (findable, accessible, interoperable, and reusable) principles is essential to break down data silos, and facilitate large-scale model training and validation. Fourth, model applicability across species, environments, and growth stages must be clearly defined for reliable deployment in real-world field conditions. Future efforts should focus on digital twins, edge-cloud computing, and explainable artificial intelligence to deliver real-time, non-destructive, and interpretable crop monitoring at unprecedented resolution and scale. In summary, high-throughput plant phenotyping technologies are promising for crop phenomics, offering the innovations and insights needed to accelerate genetic gain, optimize resource management, and advance smart breeding and precision agriculture.

crop phenomics, multi-source sensors, multi-scale phenotyping, artificial intelligence, data standardization

doi: [10.1360/CSB-2026-0435](https://doi.org/10.1360/CSB-2026-0435)