doi:10.6041/j.issn.1000-1298.2026.18.001

作物病虫害多模态智能管控技术研究进展

王　波[1]　仵　懿[2]　王雪雨[1]　徐　畅[1]　张领先[1,3]

(1.中国农业大学信息与电气工程学院,北京 100083;2.厦门大学马来西亚分校计算与数据科学学院,雪邦 43900;
3.农村农业部国家数字农产品流通(供应链与物流)创新分中心,北京 100083)

摘要:作物病虫害具有发生机理复杂、影响因素多、时空异质性强等特点,现有研究多聚焦单一模态或单项任务,难以支撑诊断、监测、预警和防控服务的协同开展。在总结国内外相关研究进展的基础上,对作物病虫害多模态智能管控关键技术进行了系统分析与讨论。梳理作物病虫害发生机理与多因素耦合特征,归纳显微图像、可见光图像、多/高光谱、热红外、环境气象、遥感观测、农事记录和电子病历等多模态数据类型及其预处理方法;构建"点-面-时空"多尺度智能管控框架,并进一步提出作物病虫害多模态智能管控总体技术框架;围绕点尺度智能识别与精准防治、面尺度区域监测与精准作业、时空尺度动态预警与决策服务、全流程智能管控系统集成与应用示范等方面总结相关研究进展。综述分析结果表明,作物病虫害智能管控正由单一识别向多模态、多尺度协同分析发展,由传统智能模型向知识增强农业大模型与智能体发展,由方法研究向云边端协同与机器人闭环服务发展。但在数据标准化、模型泛化、平台协同、实时控制和推广落地等方面仍存在明显不足。未来应推动多源异构数据联通、知识增强建模、智能装备协同和可信闭环服务体系建设,为作物病虫害精准、高效和绿色防控提供技术支撑。

关键词:作物病虫害;多模态智能管控;精准防治;区域监测;动态预警

中图分类号:S431.9;S126　　**文献标识码**:A　　**文章编号**:1000-1298(2026)18-0001-15　　**OSID**:

Research Progress in Multimodal Intelligent Management and Control Technologies for Crop Pests and Diseases

Wang Bo[1]　Wu Yi[2]　Wang Xueyu[1]　Xu Chang[1]　Zhang Lingxian[1,3]

(1. *College of Information and Electrical Engineering, China Agricultural University, Beijing* 100083, *China*
2. *School of Computing and Data Science, Xiamen University Malaysia, Sepang* 43900, *Malaysia*
3. *National Digital Agricultural Product Circulation (Supply Chain and Logistics) Innovation Sub-Center, Ministry of Agriculture and Rural Affairs, Beijing* 100083, *China*)

Abstract: Crop pests and diseases are characterized by complex occurrence mechanisms, multiple influencing factors, and strong spatiotemporal heterogeneity. Existing studies have mostly focused on single modalities or individual tasks, making it difficult to support the coordinated implementation of diagnosis, monitoring, early warning, and prevention-control services. Based on a review of domestic and international research progress, it systematically analyzed the key technologies for multimodal intelligent management and control of crop pests and diseases. Firstly, the occurrence mechanisms and multi-factor coupling characteristics of crop pests and diseases were summarized, and the multimodal data types and preprocessing methods were reviewed, including microscopic images, visible images, multispectral/hyperspectral images, thermal infrared images, environmental and meteorological data, remote sensing observations, farming records, and plant electronic medical records. Secondly, a "point - area - spatiotemporal" multi-scale intelligent management framework was constructed, and an overall technical framework for multimodal intelligent management and control of crop pests and diseases was further proposed. Finally, research progress was summarized in terms of point-scale intelligent identification and precise prevention-control, area-scale regional monitoring and precision operation, spatiotemporal dynamic early warning and decision-support services, and the integration and application demonstration of

收稿日期:2026-05-11　修回日期:2026-05-31

基金项目:国家自然科学基金项目(62376272、62176261)和中国高校产学研创新基金-云中大学专项(二期)课题(2024MU050)

作者简介:王波(2000—),男,博士生,主要从事农业信息化研究,E-mail:1601207481@qq.com

通信作者:张领先(1970—),男,教授,博士生导师,主要从事农业信息化研究,E-mail:zhanglx@cau.edu.cn

full-process intelligent management systems. It showed that intelligent management and control of crop pests and diseases was developing from single-task identification toward multimodal and multi-scale collaborative analysis, from traditional intelligent models toward knowledge-enhanced agricultural foundation models and agents, and from methodological research toward edge-cloud-end collaboration and robotic closed-loop services. However, significant challenges remained in data standardization, model generalization, platform collaboration, real-time control, and practical deployment. In the future, promoting multi-source heterogeneous data interconnection, knowledge-enhanced modeling, intelligent equipment collaboration, and trustworthy closed-loop service systems would provide technical support for precise, efficient, and green prevention and control of crop pests and diseases.

Key words: crop diseases and pests; multimodal intelligent control; precise prevention and treatment; regional monitoring; dynamic early warning

0 引言

作物病虫害是影响农业生产安全和制约农业可持续发展的重要生物胁迫因素[1-2]。与一般农业问题相比,作物病虫害发生发展具有明显的复杂性和动态性,形成过程受寄主作物、病原或虫源、环境条件等多因素共同影响[3-7],并表现出显著的时空异质性。在田间环境中,病虫害传播途径多样、区域差异明显、演变过程复杂,传统依赖人工巡查和经验判断的防控方式已难以适应精准、高效和绿色防控的现实需求[8]。因此,面向复杂农业场景开展作物病虫害智能诊断、监测、预警与防控研究,已成为现代植保领域的重要方向[9]。

作物病虫害智能管控技术可大体划分为田间识别诊断、病情严重度评估、区域监测预警与动态决策支持等类型。其中,田间识别诊断技术主要依托显微图像、可见光图像、多/高光谱图像、热成像及环境传感数据,对病虫害症状、虫体形态和作物受害特征进行自动识别,在病虫害检测、严重度评估和动态监测等方面取得了较大进展[10]。区域监测预警技术则更多依托无人机、卫星遥感和地面传感网络,通过获取多尺度、连续化的作物长势、环境条件和病虫害发生信息,为区域尺度监测与时序分析提供了新的手段[11-14]。然而,从现有研究来看,不同类型技术之间仍存在较为明显的割裂:部分方法偏重单一模态识别,部分方法侧重特定空间尺度监测,往往只能刻画病虫害发生过程局部特征,难以同时兼顾外部症状、内部生理变化、环境诱因和历史演化信息,导致模型在复杂田间环境中鲁棒性和泛化能力受到限制。由此,多模态数据融合逐渐成为作物病虫害智能管理研究的重要趋势[15-20]。通过综合利用图像、光谱、环境、遥感及农事记录等多源异构信息,可全面地表征“作物-病原/虫源-环境”耦合关系,为病虫害精准识别、区域监测和动态预测提供支撑[21]。

尽管围绕多模态感知和多尺度管理的研究不断增多,但现有综述多侧重于特定算法[22-23]、特定数据类型[24-25]或单一场景任务[26],尚缺乏面向作物病虫害多模态智能管控的系统性总结。为此,本文从多模态数据融合与多尺度协同管理的视角出发,围绕作物病虫害发生机理与多因素耦合特征、多模态数据获取与预处理、“点-面-时空”多尺度智能管控框架以及关键技术进展进行综述,并进一步分析当前研究存在的主要难点与未来发展趋势,以期为作物病虫害多模态智能管控理论研究和技术应用提供参考。

1 作物病虫害多模态智能管控技术概述

从作物病虫害发生机理与多因素耦合特征出发,分析多模态数据获取与预处理技术基础,进而构建“点-面-时空”多尺度智能管控框架,为后续关键技术综述提供理论依据与结构支撑。

1.1 作物病虫害发生机理与多因素耦合特征

作物病虫害发生与演化并非由单一因素决定,而是寄主作物、病原或虫源、环境条件等多因素共同作用的结果,如图 1 所示。从植物病理学视角看,病害形成可由“寄主-病原-环境”关系加以解释[27-28],虫害发生同样受作物生长状态、虫源数量与活动能力、温湿光等环境因子以及人为管理措施的耦合影响。不同作物品种和生育阶段对病虫害敏感性存在明显差异,病原菌毒力、害虫种群密度与传播能力也会改变危害程度,而温度、湿度、降雨、光照、土壤条件及施肥灌溉方式等环境与管理因素,则进一步影响病虫害扩散和暴发过程。作物病虫害本质上是由生物因素、环境因素和人为因素耦合作用的复杂农业生态过程。

这种多因素耦合作用使作物病虫害在空间上表现出局部聚集、区域差异明显等特征,在时间上则呈接触、侵入、潜育、发病到扩散蔓延的连续演化过程,如图 2 所示。病虫害早期往往首先表现为微观组织

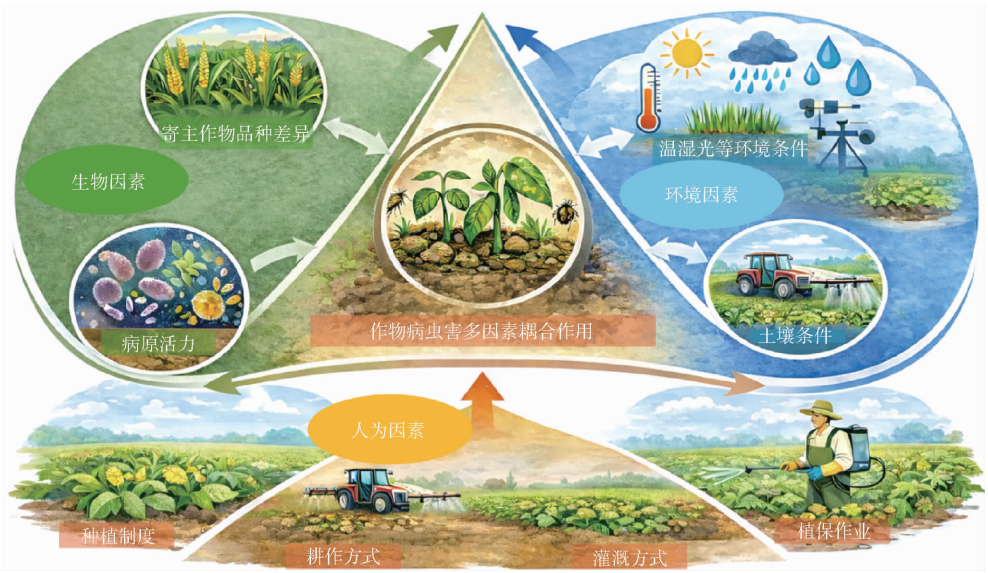

图 1　作物病虫害多因素耦合作用

Fig. 1　Multi-factor coupling effects in crop pests and diseases

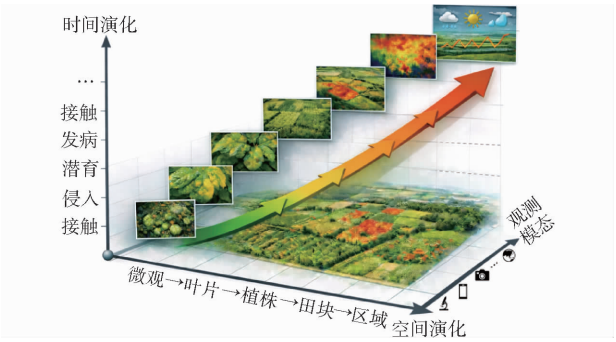

图 2　作物病虫害时空演化

Fig. 2　Spatiotemporal evolution of crop pests and diseases

或内部生理变化[29]，随后才逐渐形成叶片退绿、斑点、卷曲、坏死、虫孔等可见症状，说明其表征具有从微观到宏观、从局部到区域、从静态到动态的多尺度特性。意味着仅依赖单一观测手段难以全面揭示病虫害发生机理，须综合利用显微图像、可见光图像、多/高光谱、热成像、环境气象数据等多源信息，才能较完整刻画作物病虫害发生、发展与传播规律。

1.2　作物病虫害多模态数据获取与预处理

作物病虫害多模态智能管控的数据基础具有显著的多源异构特征，既包括表征外部症状的显微图像、可见光图像、深度图像，也包括反映内部生理变化的多/高光谱图像、热红外图像、叶绿素荧光图像，以及用于描述病虫害发生环境与传播条件温度、湿度、降雨、风速、光照、土壤含水率和养分等环境气象数据，如表 1 所示。

表 1　常见作物病虫害多模态数据类型及其适用任务

Tab. 1　Crop pests and diseases multimodal data types and their applicable tasks

数据模态	表征信息	获取方式	优势	局限	适用任务
显微图像	孢子、菌丝、虫卵等微观形态	显微镜、数字显微成像设备	能表征早期微观侵染特征	设备依赖强，采集成本高，难覆盖大范围	病原识别、虫体识别、早期侵染分析
可见光图像	颜色、纹理、病斑形态、取食痕迹	手机、相机、田间监控、无人机	获取方便、成本低、应用广	易受光照、遮挡和背景干扰	分类识别、目标检测、病斑分割、严重度估算
多/高光谱图像	叶绿素、土壤含水率、养分及生理异常	光谱仪、多/高光谱相机、机载/星载平台	可识别隐性胁迫，适合早期诊断	设备昂贵，维度高，处理复杂	早期诊断、病害分级、胁迫识别
热红外成像	温度异常、蒸腾变化、水分胁迫	热红外相机、无人机热载荷	对早期异常较敏感，可补充可见症状	易受环境条件影响，单模态特异性有限	异常检测、严重度评估、融合诊断
荧光/深度成像	光合活性、结构形态、三维信息	荧光成像、深度相机	可从功能和结构层面补充表型信息	通用性较弱，获取和处理较复杂	精细表型分析、辅助诊断、多模态融合
环境与气象数据	温度、湿度、降雨、光照、风速等	气象站、物联网传感器	能反映发生诱因，适合风险建模	难直接反映病症，需与其他数据结合	风险评估、发生预警、条件分析
遥感观测数据	区域长势、光谱异常、温度异常	卫星、无人机、航空遥感平台	覆盖范围大，适合区域连续监测	受时空分辨率和天气条件限制	区域监测、分布制图
农事管理数据	品种、施肥、施药、灌溉、轮作等	农机记录、管理平台、农户填报	可补充管理背景，解释区域差异	标准不统一，完整性和连续性不足	处方优化、差异化防控、因果分析
电子病历（PEMRs）	症状、环境、处方记录	植物诊所、问诊平台、专家系统	可统一组织多源信息，支撑持续服务	标准化和共享性不足，维护成本较高	辅助诊断、处方推荐、风险分析、知识挖掘

在空间尺度上,这些数据可来自显微成像平台、田间固定传感节点、手持终端、地面移动设备、无人机平台和卫星遥感平台。在管理与决策层面,还包括农事操作记录、专家诊断意见、处方信息、农户咨询文本和现场图像等结构化与非结构化数据。尤其是电子病历(Plant electronic medical records, PEMRs),可将作物、症状、环境、诊断结果和防治建议等多类信息组织到统一记录中[30-31],为病虫害智能诊断、区域风险分析和精准防治提供综合数据支撑,如图 3 所示。作物病虫害多模态数据并不仅指多种数据的叠加,而是覆盖病虫害外部表型、内部生理状态、环境诱因、时空分布及管理过程的多层次信息集合。

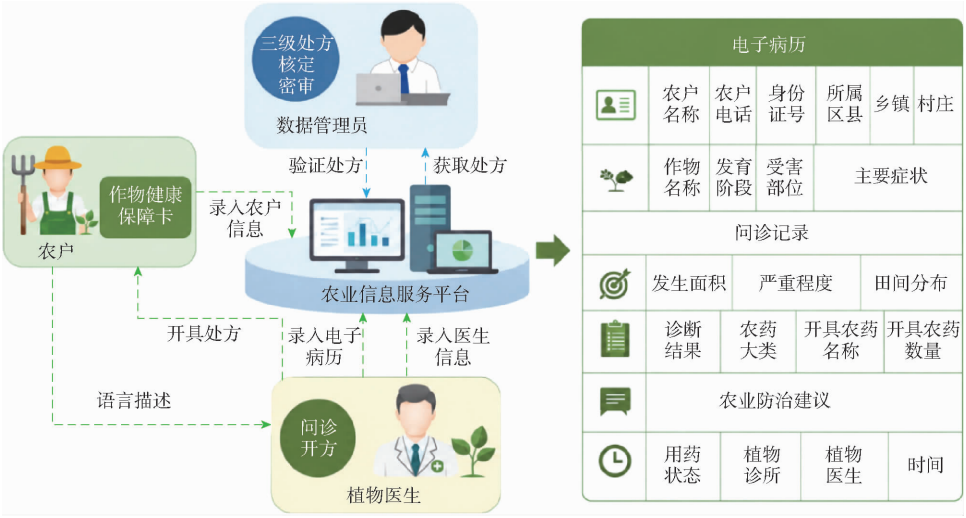

图 3 电子病历数据获取流程

Fig. 3 Plant electronic medical record data acquisition process

由于不同模态数据在来源、尺度、精度、格式和时间分辨率等方面存在明显差异,多模态数据进入智能分析前通常需进行系统预处理[31],如图 4 所示。其主要环节包括原始数据整理与格式转换、重复值与异常值剔除、缺失值处理、一致化处理、标签构建、结构化编码以及不同模态之间的时空配准与尺度统一。对于图像与光谱数据,常需进行去噪、增强、特征标准化和样本均衡处理;对于环境、气象和遥感时序数据,则需关注时间同步、连续性修复和多尺度对齐;对于电子病历、问诊文本和处方记录等文本型或表格型数据,还需进行术语规范化、字段清洗、类别编码和语义统一。

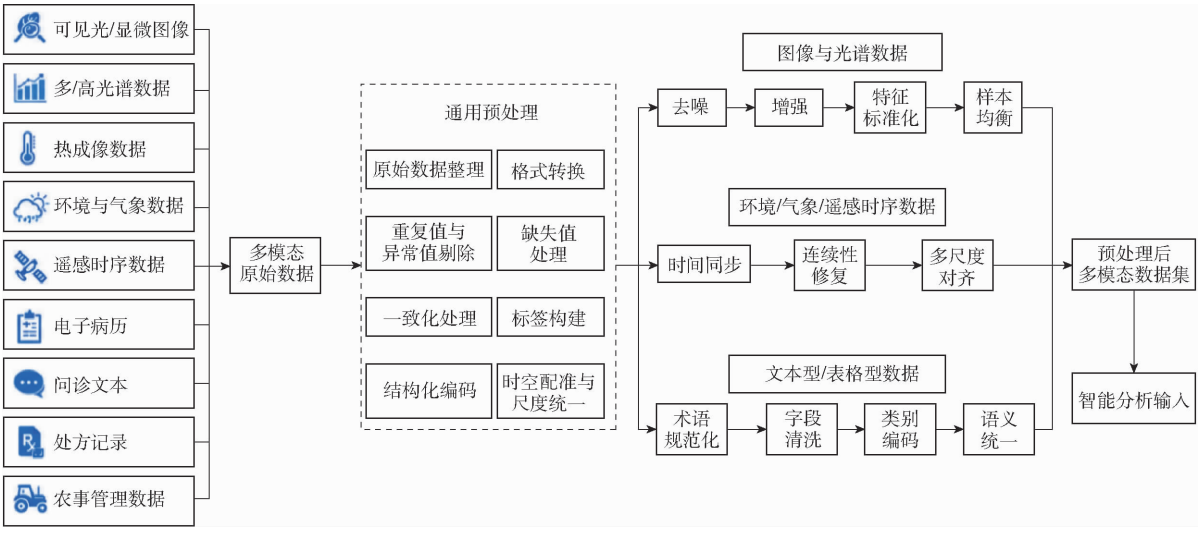

图 4 作物病虫害多模态数据预处理流程

Fig. 4 Multimodal data preprocessing process for crop pests and diseases

1.3 作物病虫害“点-面-时空”多尺度智能管控框架

作物病虫害发生、扩散与防控具有显著的跨尺度特征,单一尺度上的监测与管理难以完整支撑复杂农业场景下的智能管控需求。为此,需从多模态数据融合和多尺度任务协同的角度构建“点-面-时空”一体化智能管控框架,如图 5 所示。其中,“点”尺度主要面向单株、单叶、单果、单虫体或局部病斑等对象,重点解决病虫害早期识别、定量诊断和精准

干预等问题；“面”尺度主要面向田块、地块和区域空间单元，重点关注病虫害空间分布、发生范围、聚集特征及差异化作业需求[32-33]；“时空”尺度则面向病虫害发生发展的连续过程[34]，重点分析动态演化、传播扩散、风险变化与区域联防联控决策[35-37]。该框架将微观诊断、区域监测和动态预测 3 类任务统一到同一技术体系中，解决以往研究中多模态融合与多尺度管理相互割裂的问题。

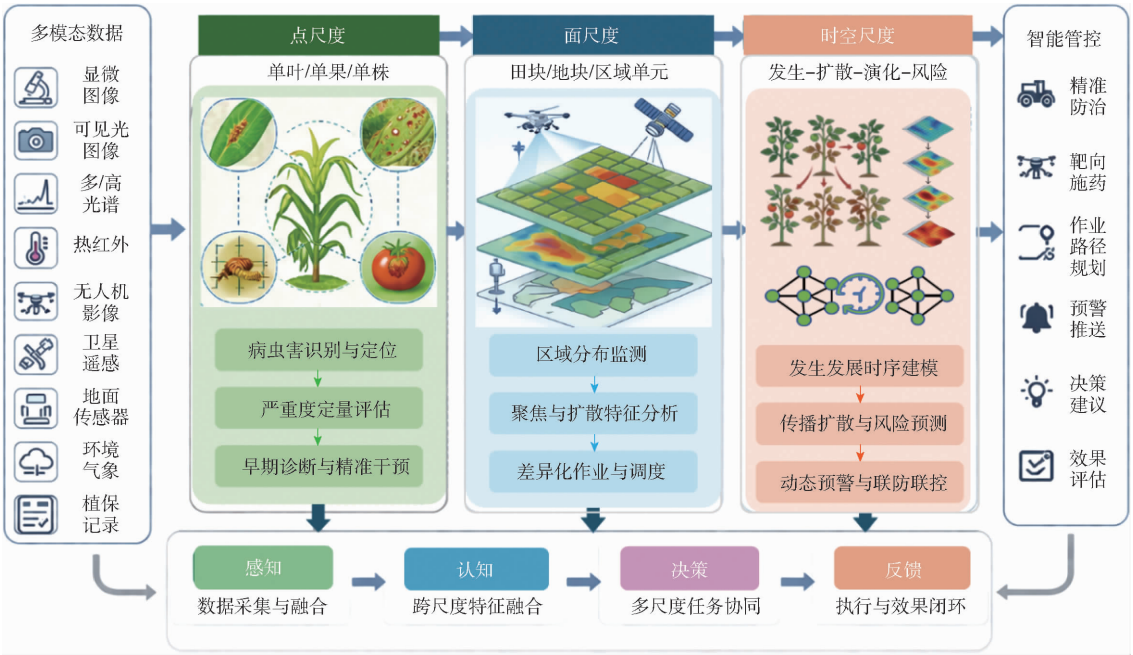

图 5　作物病虫害“点-面-时空”多尺度智能管控框架

Fig. 5　Point - area - spatiotemporal multi-scale intelligent management and control framework for crop pests and diseases

在这一框架下，多模态数据贯穿作物病虫害智能管控全过程，如表 2 所示。点尺度利用显微图像、可见光图像、光谱和热信息等多源数据实现病虫害识别与严重度评估，为精准防治提供依据；面尺度综合无人机、卫星遥感、地面传感器以及环境气象数据，实现区域监测、分布分析和精准作业，为田间和区域管理提供空间支撑；时空尺度进一步融合历史监测记录、环境时序、传播机理和电子病历等信息，实现动态预警、传播预测与决策服务，从而为宏观层面的防控部署提供依据。特别是电子病历（PEMRs）可将作物、症状、环境、诊断结果和处方建议等多类信息组织到统一记录中，为点尺度诊断、面尺度风险分析和时空尺度决策支持提供跨尺度数据纽带。“点-面-时空”多尺度智能管控框架不仅是作物病虫害多模态研究的逻辑组织方式，也是实现全流程智能感知、精准干预和持续优化的重要理论基础。

在上述作物病虫害发生机理、多模态数据基础和“点-面-时空”多尺度管控框架基础上，进一步从

表 2　“点-面-时空”多尺度协同智能管控

Tab. 2　Point - area - spatiotemporal multi-scale collaborative intelligent management and control

尺度	核心目标	主要数据类型	代表方法	典型输出	典型应用场景
点	实现单株、单叶、单果或局部病斑的识别与诊断	显微图像、RGB、多/高光谱、热红外、局部环境数据、PEMRs	分类、检测、分割、多模态融合	病虫害类别、病斑位置、严重度、诊断结论	单株诊断、田间巡检
面	实现田块和区域尺度的分布识别与风险评估	遥感、地面传感、环境气象、农事信息、区域病历	遥感反演、空间分析、多源数据融合	分布图、热区图、风险等级图、作业处方图	区域监测、精准施药、差异化防控
时空	实现发生过程预测、传播分析与动态预警	多时相遥感、连续气象、历史病历、传播知识	时序预测、时空建模、传播模型	预警信息、演化趋势、传播路径、防控建议	预警发布、联防联控、资源调度
点-面协同	将点位诊断结果外推到区域监测层	点位诊断结果、遥感、环境和农事数据	尺度映射、联合建模	区域发生分布、局部到整体外推结果	抽样诊断支撑区域治理
面-时空协同	将区域监测结果与历史过程联动分析	多期遥感、环境时序、历史记录	时空序列分析、动态图建模	区域风险演化、连续预警结果	区域预警平台、趋势研判
点-面-时空协同	贯通感知、认知、决策和反馈全过程	多模态感知数据、PEMRs、平台与作业反馈数据	多源数据融合、知识图谱、闭环优化	诊断-预警-推荐-作业全流程结果	全流程智能管控系统

全文角度构建作物病虫害多模态智能管控总体技术框架，如图 6 所示。该框架以作物病虫害发生发展过程为对象，以多源异构数据获取为基础，通过数据治理、时空配准、尺度统一和知识组织，实现显微图像、可见光图像、多/高光谱、热红外、环境气象、遥感观测、农事记录和电子病历等多模态信息的协同表达。在此基础上，综合运用多模态融合、时空建模、知识图谱、农业大模型和智能决策模型，支撑点尺度识别诊断、面尺度区域监测、时空尺度动态预警以及精准防治决策。进一步通过植物诊所、监测预警平台、无人机、植保机器人和变量施药装备等应用载体，将模型输出转化为可执行的防控措施，并通过作业结果和服务反馈实现数据、模型和决策的持续优化。该总体框架将感知、认知、决策、执行和反馈纳入统一闭环，可作为作物病虫害多模态智能管控研究整体技术路线和理论基础。



图 6 作物病虫害多模态智能管控总体技术框架

Fig. 6 Overall technical framework for multimodal intelligent management and control of crop diseases and pests

2 作物病虫害多模态智能管控关键技术

在前述多尺度智能管控框架基础上，围绕“点-面-时空”3 个层级系统梳理作物病虫害多模态智能管控关键技术。其中，点尺度重点分析基于多源数据融合的病虫害智能识别与精准防治方法；面尺度重点总结区域监测与差异化精准作业技术；时空尺度重点讨论动态预警、传播预测与决策支持方法；在此基础上，进一步综述“点-面-时空”协同的全流程智能管控系统集成与应用示范。

2.1 “点”尺度：作物病虫害智能诊断与精准防治技术

2.1.1 基于多源数据融合的作物病虫害智能识别

作物病虫害智能识别是“点”尺度智能管控的基础环节，核心任务是在单株、单叶、单果、单虫体或局部病斑等微观对象层面，实现病虫害类型判别、受害部位定位和发生程度识别。现有研究表明，点尺度识别已由早期依赖单一图像和人工特征的方法，逐步发展为融合显微图像、可见光图像、多光谱/高光谱图像、热红外、荧光及局部环境信息的多源协同识别模式[38]。相关研究技术如表 3 所示。

(1)面向病原或虫体等微观对象的早期识别。这类研究通常以病菌孢子、侵染结构、虫体或虫卵等为识别对象，依托成像平台获取高分辨率图像，再结合图像分割、特征提取和分类建模实现自动识别。已有研究表明，显微图像识别能够较早反映病虫害侵染过程微观变化[39]，因此在侵入前期和潜育阶段具有重要应用价值。在具体方法上，既有基于形态、纹理等人工特征的传统识别方法[40-45]，也有利用深度神经网络开展端到端识别的深度学习方法[46-54]。

(2)面向作物器官表型症状的识别与诊断。该方向通常以叶片、茎秆、果实等器官为对象，利用 RGB 图像描述病斑颜色、纹理、边缘和形态等外部症状，并借助分类、目标检测和图像分割模型实现病虫害识别。在此基础上，多光谱/高光谱、热红外和荧光成像被逐步用于表征叶绿素、含水率、温度和光

合作用变化等内部生理响应，使识别任务由可见症状识别进一步拓展为表型-机理协同诊断。相关研究中，卷积神经网络[55]、迁移学习[56]、多尺度特征融合[57]、注意力机制[58-59]等已被广泛用于病斑识别、严重度估算和虫害检测。

（3）多源数据融合驱动的综合识别。这类研究不再局限于单一图像模态，而是将可见光、光谱、热信息、局部环境感知数据，甚至文本记录和结构化观测信息联合输入模型，通过多模态特征融合[60]、多任务学习[61-62]等方式，同时刻画病虫害的外部表型和内部生理状态。相关研究表明，在复杂田间背景、光照变化明显、早期症状不突出或多病虫共存的条件下，多源融合方法通常较单模态方法具有更好的鲁棒性和更强的早期识别能力[63]。

表 3　基于多源数据融合的作物病虫害智能识别技术

Tab. 3　Intelligent identification technologies for crop pests and diseases based on multi-source data fusion

研究角度	识别对象	数据基础	代表方法	主要优势	主要局限
面向病原或虫体等微观对象的早期识别	病菌侵染结构、虫体、虫卵等	显微图像、局部高分辨率图像	图像分割、图像分类、目标检测	可较早反映微观变化，适合侵入前期与潜育阶段识别	设备依赖较强，应用场景较窄，样本获取成本较高
面向作物器官表型症状的识别与诊断	叶片、茎秆、果实等的病斑区域	RGB 图像、多光谱/高光谱、热红外、荧光图像	图像分类、目标检测、图像分割、迁移学习、注意力机制	可同时利用外部症状与内部生理响应，适合表型-机理协同诊断	易受复杂背景、光照变化和遮挡干扰，跨场景泛化仍有限
多源数据融合驱动的综合识别	复杂田间背景下的受害对象	可见光、光谱、热信息、局部环境数据、文本记录、结构化观测信息	多模态融合、多任务学习	鲁棒性更强，早期识别能力更好，更适应复杂田间场景	数据同步、配准与融合难度较大，对样本规模和标注质量要求较高

2.1.2　基于电子病历多模态数据融合的作物病虫害精准防治

基于电子病历多模态数据融合的作物病虫害精准防治，是“点”尺度智能管控由识别诊断走向干预决策的关键环节，其核心任务是在已有诊断结果基础上，综合利用作物种类、生育阶段、症状描述、田间分布、图像记录、环境信息、专家意见及处方方案等多源数据，形成面向具体对象的防治建议。相关研究表明，电子病历能够将结构化信息与非结构化信息统一组织，为病虫害诊断推理、处方推荐和精准防治提供数据支撑[64]。在此基础上，相关研究主要围绕 3 个方向展开，如表 4 所示。

表 4　基于电子病历多模态数据融合的作物病虫害精准防治技术

Tab. 4　Precision control technologies for crop pests and diseases based on electronic medical record multimodal data fusion

研究角度	关键技术	主要优势	主要局限	适用场景
基于诊断推理的处方推荐	案例匹配、规则推理	能较好反映诊断与处方形成过程，逻辑清晰	对历史病历质量和规则体系依赖较强，复杂场景适应性有限	单一病虫害推荐
基于知识图谱和语义关联的精准防治决策	知识图谱构建、图数据挖掘	能表达多关系知识，适合复杂决策和语义扩展，解释性较好	图谱构建和更新成本较高，知识标准化与维护难度较大	知识服务平台、智能问答
多模态数据联合驱动的精准防治	多模态融合、多任务学习	可同时提升诊断精度和处方推荐效果，更贴近真实生产场景	数据采集与融合要求高，模型训练复杂，泛化能力仍需增强	多作物病害场景下的诊疗一体化应用

（1）基于诊断推理的处方推荐。以植物诊所积累的电子病历为基础，通过挖掘作物类型、病害症状、受害部位、环境条件、诊断结果与历史处方之间的关联关系，为植物医生或生产者提供防治建议。已有研究认为，电子病历数据兼具回溯性、可查询性和连续积累特征，能够较好反映病虫害诊断与处方形成过程，因此适合用于构建基于案例匹配、规则推理和历史经验挖掘的推荐模型[65-66]。

（2）基于知识图谱和语义关联的精准防治决策。病虫害精准防治不再是简单的诊断结果-药剂输出映射，而是被建模为作物、病虫害类型、症状特征、环境因素、处方措施和管理目标之间的多关系推理过程。相关研究已将知识图谱和图数据挖掘引入电子病历挖掘，通过构建病虫害知识网络，提取病因-症状-处方之间的关联规则，实现单一病害处方推荐、多作物多病害语义匹配推荐以及面向复杂场景的多目标决策支持[67-68]。

（3）多模态数据联合驱动的精准防治。相关研究表明，将田间图像、诊断记录和结构化信息共同输入模型，可同时提升病虫害诊断精度和处方推荐效

果[69]。已有研究基于 PEMRs 构建深度学习模型，将病害类别预测与防治措施推荐同时纳入统一框架，并在草莓、番茄、黄瓜等病害场景中取得了较高的推荐精度[70]，说明电子病历多模态融合已具备支撑点尺度精准防治的现实基础。

2.2 “面”尺度：作物病虫害区域监测与精准作业技术

2.2.1 基于多源信息融合的作物病虫害区域监测

作物病虫害区域监测是“面”尺度智能管控的核心内容，主要任务是在田块、地块及区域范围内识别病虫害的空间分布、发生范围和聚集格局。该研究方向关键不在于预测未来如何变化，而在于利用多源观测手段实现区域病虫害发生信息快速获取、准确表达和空间可视化，如表 5 所示。

主要从以下方面展开研究：

（1）基于遥感影像的病虫害空间识别。无人机和卫星平台能够提供大范围、重复性的冠层观测数据，被广泛用于病虫害区域监测。相关研究表明，

表 5 作物病虫害区域监测中不同观测手段的任务适配关系

Tab. 5 Task adaptation relationships of different observation methods in regional monitoring of crop pests and diseases

观测手段	区域覆盖能力	局部细节表达	重复观测能力	发生范围提取	分布边界识别	热点区识别	局部核验能力	适用定位
卫星遥感	高	中	高	强	中	强	弱	适合大范围普查、时序跟踪与区域态势监测
无人机	中	高	中	强	强	强	中	适合田块尺度精细识别、边界提取与热点详查
地面传感网络	低	高	高	弱	弱	中	强	适合局部连续监测、环境诱因感知与现场核验
空-地协同监测	高	高	高	强	强	强	强	适合复杂田间背景下的综合区域监测与精细表达

RGB、多光谱、高光谱和热红外遥感均可用于区域病虫害识别，方法由传统的阈值分割和经验判读[71]逐步发展为结合机器学习[72]、目标检测[73]和语义分割[74]的自动识别模式。

（2）空-地多源信息融合的区域监测模式。已有研究表明，卫星遥感、无人机影像和地面传感网络的联合能够实现跨尺度、跨分辨率的区域感知，使监测结果既具有较好的覆盖范围，又能兼顾局部细节表达[75]。相较单一影像数据，多源数据融合能够更有效应对田间复杂背景、冠层结构差异、光照变化和局部遮挡等问题，从而更准确地识别病虫害空间分布边界、斑块特征和受害强弱差异。

（3）作物病虫害发生范围提取、空间分布分析和区域态势表达。相关研究不仅关注病虫害在区域内存在与否，还进一步分析空间聚集特征、热点区域、受害强度和地块差异[76]，为后续风险区划和精准作业提供基础。

2.2.2 基于区域监测结果的作物病虫害精准作业

基于区域监测结果的作物病虫害精准作业，是“面”尺度智能管控的重要应用方向，核心在于将区域监测形成的病虫害分布信息转换为差异化防控措施。相关研究表明，多模态感知和区域监测的意义不仅在于提高病虫害识别精度，更在于为后续响应性更强、资源配置更优的区域防控提供依据[77-78]，区域监测结果与精准作业决策对应关系如表 6 所示。

表 6 区域监测结果向精准作业决策转换的对应关系

Tab. 6 Correspondence between regional monitoring results and precision operation decision-making

区域监测结果	对应作业方式	关键优化内容	预期效果
病虫害发生范围	分区作业	划定作业区与非作业区	避免全田统一作业，减少无效投入
受害强度分级	变量作业	调整施药剂量、作业强度和资源投入	提高投入精准性，降低药剂浪费
空间聚集特征	重点区域优先作业	确定重点防控区和优先顺序	提升区域防控针对性
分布边界信息	边界约束作业	优化喷施边界、减少重喷漏喷	提高作业质量与边界一致性
热点区识别结果	强化作业	强化局部治理与资源集中投放	提高热点区治理效率
作业后再监测结果	协同反馈作业	调整策略、补喷补防、动态更新方案	形成监测-作业-反馈闭环

（1）基于区域监测结果的分区作业。根据区域内病虫害发生程度和空间聚集特征确定作业对象，而不是沿用传统全田统一防控模式。对于病虫害分布呈现明显斑块化、边界化和局部聚集的场景，分区作业能够较好地将空间监测结果转化为面向地块的具体管理措施[79-81]，使区域防控建立在客观监测基础之上。

（2）基于区域信息的变量作业与参数优化。已有研究通常将区域监测结果与施药剂量、作业顺序、作业边界、航线规划和资源配置等参数优化结合起来[82]，使作业过程与病虫害空间格局保持一致。多源信息融合还可将病虫害空间监测结果与环境、气

象和作物长势等因素联合考虑[83]，使精准作业不仅体现空间差异，也兼顾作业条件适宜性。

（3）基于监测结果反馈的区域协同作业。区域监测不仅为作业提供初始依据，作业实施后的结果也可以反向作用于后续监测和区域管理[84]。相较于单次静态施药，这种协同作业模式更强调持续更新区域病虫害状态，并根据监测变化动态调整作业策略。

2.3 “时空”尺度：作物病虫害动态预警与决策支持技术

2.3.1 基于多模态时序信息的作物病虫害动态预警

作物病虫害动态预警是“时空”尺度智能管控的重要前端环节，核心任务是在病虫害尚未大范围显现或扩散之前，基于多模态时序信息识别风险变化、发现早期异常并形成预警输出，本质上是对病虫害风险形成与异常显现过程的连续判识。现有研究大体可归纳为以下 2 类：

（1）病虫害发生风险判定。通常综合温度、湿度、降雨、风速、光照、土壤含水率等环境气象时序信息，以及作物生育阶段、历史发病记录和区域病虫害统计规律，对病虫害发生的有利条件进行判别，并进一步估计高风险时段和潜在暴发窗口。随着时序建模方法的发展，这类研究已由早期经验阈值和统计分析[85-88]，扩展为融合多源环境与生产信息的风险判识模式[89-91]。

（2）病虫害早期异常预警。通常依托连续获取的 RGB 图像、多光谱/高光谱、热红外、荧光及局部传感信息，监测叶片颜色变化[92]、冠层温度异常[93]、叶绿素波动[94]等早期胁迫特征。这类研究更关注病虫害已经引起的作物响应，而不是外部风险条件本身。已有研究表明，多节点图像采集与环境参数联合的感知方式，可提高病源定位和早期预警的自动化与敏感性[95-96]。

2.3.2 基于传播机理与时空建模的作物病虫害决策服务支持

基于传播机理与时空建模的决策服务支持关注病虫害在区域尺度上的传播路径、扩散过程和管理响应。相关研究通常不再停留于单时刻风险判别，而是将环境气象时序、作物物候、区域空间位置、历史发生记录以及遥感监测结果等信息联合起来，分析病虫害在时间和空间上的演化规律，并在此基础上形成决策支持输出，时空尺度分析结果向防控决策转换的对应关系如表 7 所示。

表 7　时空尺度分析结果向防控决策转换的对应关系

Tab. 7　Correspondence between spatiotemporal scale analysis results and control decision-making

时空分析结果	含义	可直接支持决策	部署时点	使用优势	使用风险
高风险时段	未来一段时间具备暴发条件	提前加密监测、提前备药、提前安排植保作业窗口	暴发前	把防控从被动响应转为前置准备	仅凭风险判断可能出现过度预防
早期异常区	局部区域已出现初发征兆	现场核查、局部先行干预、重点复测	初发前后	把异常控制在扩散前阶段	局部噪声可能导致误报
高风险区域	区域内风险强弱存在明显空间差异	分区防控、重点区域优先治理、资源倾斜配置	预警发布后	提高区域治理针对性	热点识别不稳会影响资源配置效率
传播路径与扩散方向	病虫害可能沿特定空间关系继续蔓延	设置阻断带、跨地块协同防控、联防联控部署	扩散前或扩散中	支撑区域协同防治，而非单点处置	路径预测偏差会影响协同调度
关键时间窗口	干预效果最敏感的时期	优化施药或处置时机、调整作业顺序	作业前	提高作业时效性和防控收益	错过窗口会明显降低控制效果
趋势演化结果	风险整体可能加剧、平稳或缓解	动态调整监测频次、防控强度和资源投放	连续监测阶段	形成持续滚动优化机制	对连续数据质量依赖较强

现有研究内容大体分为以下 2 个方面：

（1）基于传播机理解析的时空预测。将病虫害传播过程视为受气象条件、作物物候、栖息环境和农事活动共同影响的动态系统[97]，在建模时显式引入植保知识或流行病学原理。当前不少研究沿用这一路径构建病害预测模型，并将时间因素与空间因素共同纳入决策支持系统[98]，以增强模型可解释性。

（2）基于多模态时空信息的传播过程建模。采用深度学习和图建模方法描述病虫害在区域间的传播过程。融合天气、土壤和作物信息的模型已能够在病害暴发前数周实现较高精度预测[99-101]。同时，基于 PEMRs 构建的连续时序数据[34]和区域图结构[102]，也被用于区域历史病害动态重建与跨区域传播分析。这类研究通过多源时空信息联合建模，将原本离散的病情记录转换为可计算的传播过程表达。

2.4 “点-面-时空”全流程智能管控系统集成与应用示范

现有作物病虫害智能管理系统已发展为集田间感知、在线诊断、区域监测、动态预警、处方推荐和管

理服务于一体的综合系统。从应用形态看,现有系统主要包括 3 类:

(1)电子病历驱动的诊疗服务系统。依托线下植物诊所、线上问诊和专家咨询服务,将作物类型、生育期、症状描述、田间图像、环境信息、诊断结果和处方建议等内容沉淀为电子病历(PEMRs),从而形成面向在线问诊、病虫害辅助诊断、处方推荐、病历管理与专家咨询服务的持续性数据平台,如图 7 所示。现有研究显示,北京地区已建立较为完整的植物健康服务体系,包含 115 个植物诊所、4 个区级二级植物医院和 1 个植物总医院,服务范围覆盖多个区县与乡村,并积累了大规模电子病历数据[64]。相关应用研究将这些病历数据用于处方智能推荐[70]、区域目标决策[34]和时空趋势预测[102]。

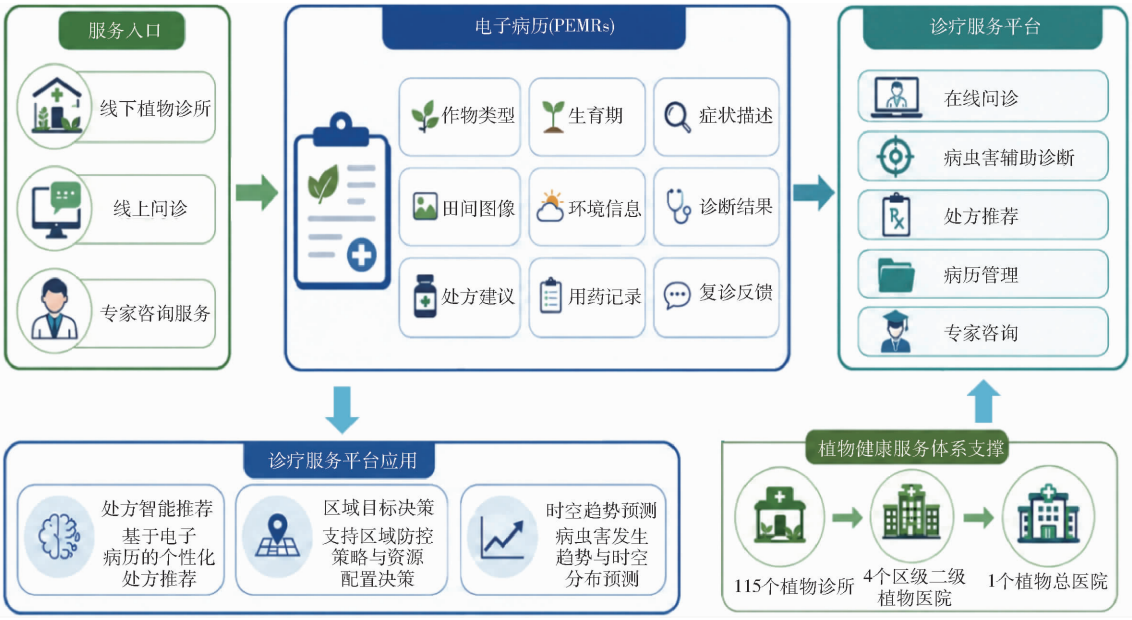

图 7 电子病历驱动的诊疗服务系统

Fig. 7 Electronic medical record-driven diagnosis and treatment service system

(2)多源观测支撑的监测预警平台。以无人机、卫星遥感、地面传感器和环境气象监测为主要数据来源,通过多源观测结果汇聚形成区域病虫害分布图、热点区识别结果、风险区划信息和动态态势图,用于支撑区域监测、重点区识别和差异化防控部署。现有研究普遍采用空-地协同模式,将卫星和无人机提供的大范围观测能力,与地面节点提供的局部连续感知能力结合起来,实现跨尺度、跨分辨率的病虫害监测[103-104]。在此基础上,监测结果进一步与历史病情记录、专家知识和防控需求结合,形成区域预警和防控建议。

(3)多模态融合支撑的决策服务系统。以病虫害管理流程协同为重点,将病虫害诊疗、区域监测、时空分析和防控服务在同一平台或业务框架中联通起来,主要功能包括病情信息汇聚、风险态势分析、重点防控区识别、干预时机建议、联防联控部署以及区域资源配置优化等[105-107]。

3 作物病虫害多模态智能管控技术研究难点与发展趋势

3.1 作物病虫害多模态智能管控技术研究难点

3.1.1 多模态数据获取与标准化难点

作物病虫害智能管控的数据来源非常分散,既包括显微图像、RGB 图像、多/高光谱、热成像和荧光数据,也包括温湿度、降雨、风速、土壤水分等环境气象数据,以及遥感影像、电子病历、处方记录和农事管理信息。这些数据的空间尺度、时间频率和表达形式完全不同:显微图像对应病菌孢子层面,田间 RGB 图像对应器官层面,无人机和卫星遥感对应地块和区域层面,而 PEMRs 又混合了文本和结构化字段,导致数据很难直接对齐。尤其在田间场景中,缺失值、噪声、类别不平衡、标注成本高和标准不统一等问题,会直接削弱后续模型训练和系统集成效果。

3.1.2 智能模型构建与泛化应用难点

点尺度病虫害识别模型往往在特定作物、特定病害和相对干净的图像条件下能取得较高精度,但一旦换到复杂背景、不同地区、不同年份或不同作物类型,性能就容易下降。区域监测和时空预测模型也存在类似问题,尤其在跨区域迁移时更明显。多模态融合虽然理论上能补足单模态短板,但实际建模中又会遇到模态缺失、采样不同步、融合策略复杂和模型可解释性弱等问题,使模型训练成本更高、部署难度更大。

3.1.3 装备平台协同与实时控制难点

现有病虫害智能管理应用虽然已涵盖植物诊所

系统、区域监测预警平台和综合决策服务系统，但不同装备、不同平台和不同业务环节之间的协同仍不充分。当前空-地协同监测多依赖卫星、无人机和地面节点的组合使用，但在数据同步、任务衔接、边缘计算能力和实时处理效率方面仍存在明显制约。同时，诊断系统、监测平台与作业装备之间往往缺乏统一接口和标准化的数据传输机制，使识别结果、区域监测结果和作业控制参数之间难以形成闭环。对于实时控制而言，病虫害监测、诊断、预警和作业执行之间存在时间差和信息损耗，尤其在复杂田间环境下，传感节点部署成本高、物联网实施难、设备可靠性受限等问题，使得一体化平台建设仍面临较大工程挑战。

3.1.4　系统集成验证与推广落地难点

现有研究已经提出了较完整的“点-面-时空”框架，也已经出现了植物诊所、区域监测平台和虚拟植物诊所等应用形态，但这些成果距离大规模落地仍有距离。很多研究缺少跨季节、跨区域、跨作物和长期运行条件下的系统性评估，因此很难说明系统在真实生产中是否稳定可靠。另外，农业场景本身高度异质，不同地区种植制度不同、病虫害谱系不同、技术服务能力不同，小农户分散经营与区域协同治理之间也存在落差，这使统一化推广非常困难。特别是像 PEMRs 这类系统，虽然已经在北京形成了较大规模的植物诊所和病历积累，但从局部示范走向广域复制，还涉及数据持续更新、专家知识维护、运维成本、服务组织和用户接受度等一整套问题。

3.2　作物病虫害多模态智能管控技术发展趋势

（1）由单一识别向多模态、多尺度协同分析发展。未来作物病虫害智能管控将不再局限于单一图像识别或单一环境因子分析，而是进一步强化显微图像、可见光图像、多/高光谱、热成像、环境气象、遥感观测和电子病历等异构信息的联合表达。在此基础上，研究任务也将由静态分类识别拓展到早期诊断、严重度评估、区域监测、动态预警和传播预测，使“点-面-时空”不同层级之间形成连续衔接。尤其在复杂田间环境中，早期弱症状识别、多病虫共存诊断、时空演化分析和跨区域传播模拟将成为重要方向，推动病虫害智能管理由单点认知向全过程感知与预测发展。

（2）由传统智能模型向知识增强农业大模型与智能体发展。随着大语言模型、大视觉模型和多模态大模型的发展，作物病虫害智能管控将由单项识别和单点预测，逐步转向具备知识理解、图文推理、问答交互和辅助决策能力的农业智能体[108-109]。未来可将病虫害图像、环境气象、遥感监测、电子病历、专家知识和防治规范等纳入统一知识增强框架，构建面向诊断问答、处方推荐、风险解释和联防联控决策的智能模型[110]。与传统深度学习模型相比，农业大模型更有利于实现跨任务迁移、自然语言交互和知识驱动决策，但仍需解决农业高质量语料不足、知识更新滞后、模型幻觉、推理可解释性和安全可靠性等问题。

（3）由方法研究向云边端协同与机器人闭环服务发展。未来技术演进的重点将不只是提高单个模型精度，而是推动诊断、监测、预警、处方推荐和精准作业的系统集成，使模型输出真正转化为可执行的防控措施。围绕这一方向，应构建云端知识服务、边缘智能分析和终端快速响应相结合的云边端协同体系[111-112]，并与植保无人机、地面移动机器人、变量施药装备和智能农机等执行终端深度结合[113]，形成“监测-诊断-决策-作业-反馈”的闭环管控模式。同时，应加强可信 AI 研究，将不确定性评估、可解释推理、专家审核和安全约束嵌入全过程，以降低模型误判、数据偏差和处方不当带来的应用风险[114]。

参　考　文　献

[1] Jafar A, Bibi N, Naqvi R A, et al. Revolutionizing agriculture with artificial intelligence: plant disease detection methods, applications, and their limitations[J]. Frontiers in Plant Science, 2024, 15: 1356260.

[2] Kumar Y, Singh R, Moudgil M R, et al. A systematic review of different categories of plant disease detection using deep learning-based approaches[J]. Archives of Computational Methods in Engineering, 2023, 30: 4757-4779.

[3] González-Rodríguez V E, Izquierdo-Bueno I, Cantoral J M, et al. Artificial intelligence: a promising tool for application in phytopathology[J]. Horticulturae, 2024, 10(3): 197.

[4] Colbach N, Duby C, Cavelier A, et al. Influence of cropping systems on foot and root diseases of winter wheat: fitting of a statistical model[J]. European Journal of Agronomy, 1997, 6(1): 61-77.

[5] Amezrou R, Ducasse A, Compain J, et al. Quantitative pathogenicity and host adaptation in a fungal plant pathogen revealed by whole-genome sequencing[J]. Nature Communications, 2024, 15: 1933.

[6] Muskett A E. Plant pathology and the plant pathologist[J]. Annual Review of Phytopathology, 1967, 5: 1-17.

[7] Preston G M. Profiling the extended phenotype of plant pathogens: challenges in bacterial molecular plant pathology[J]. Molecular Plant Pathology, 2017, 18(3): 443-456.

[8] Wang D, Wang J, Li W, et al. T-CNN: trilinear convolutional neural networks model for visual detection of plant diseases

[J]. Computers and Electronics in Agriculture, 2021, 190: 106468.
[9] Madhuri E V, Rupali J S, Sharan S P, et al. Transforming pest management with artificial intelligence technologies: the future of crop protection[J]. Journal of Crop Health, 2025, 77: 48.
[10] Shakoor N, Lee S, Mockler T C. High throughput phenotyping to accelerate crop breeding and monitoring of diseases in the field[J]. Current Opinion in Plant Biology, 2017, 38: 184 - 192.
[11] Bohnenkamp D, Kuska M T, Mahlein A K. et al. Hyperspectral signal decomposition and symptom detection of wheat rust disease at the leaf scale using pure fungal spore spectra as reference[J]. Plant Pathology, 2019, 68(6): 1188 - 1195.
[12] Hatfield P L, Pinter P J. Remote sensing for crop protection[J]. Crop Protection, 1993, 12(6): 403 - 413.
[13] Huang Y, Ren Z, Li D, et al. Phenotypic techniques and applications in fruit trees: a review[J]. Plant Methods, 2020, 16: 107.
[14] Zhou C, Bucklew V G, Edwards P S, et al. Portable diffuse reflectance spectroscopy of potato leaves for pre-symptomatic detection of late blight disease[J]. Applied Spectroscopy, 2023, 77(5): 491 - 499.
[15] Azam M A, Khan K B, Salahuddin S, et al. A review on multimodal medical image fusion: compendious analysis of medical modalities, multimodal databases, fusion techniques and quality metrics[J]. Computers in Biology and Medicine, 2022, 144: 105253.
[16] Kline A, Wang H, Li Y, et al. Multimodal machine learning in precision health: a scoping review[J]. Npj Digital Medicine, 2022, 5: 171.
[17] Stahlschmidt S R, Ulfenborg B, Synnergren J. Multimodal deep learning for biomedical data fusion: a review[J]. Briefings in Bioinformatics, 2022, 23(2): 569.
[18] Zhang X, Demiris Y. Visible and infrared image fusion using deep learning[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(8): 10535 - 10554.
[19] Yuan Y, Li Z, Zhao B. A survey of multimodal learning: methods, applications, and future[J]. ACM Computing Surveys, 2025, 57(7): 1 - 34.
[20] Awais M, Naseer M, Khan S, et al. Foundation models defining a new era in vision: a survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2025, 47(4): 2245 - 2264.
[21] Li J, Hong D, Gao L, et al. Deep learning in multimodal remote sensing data fusion: a comprehensive review[J]. International Journal of Applied Earth Observation and Geoinformation, 2022, 112: 102926.
[22] Rodríguez-Lira D C, Córdova-Esparza D M, Álvarez-Alvarado J M, et al. Trends in machine and deep learning techniques for plant disease identification: a systematic review[J]. Agriculture, 2024, 14(12): 2188.
[23] Wang S, Xu D, Liang H, et al. Advances in deep learning applications for plant disease and pest detection: a review[J]. Remote Sensing, 2025, 17(4): 698.
[24] Zhu H, Lin C, Liu G, et al. Intelligent agriculture: deep learning in UAV-based remote sensing imagery for crop diseases and pests detection[J]. Frontiers in Plant Science, 2024, 15: 1435016.
[25] Anam I, Arafat N, Hafiz M S, et al. A systematic review of UAV and AI integration for targeted disease detection, weed management, and pest control in precision agriculture[J]. Smart Agricultural Technology, 2024, 9: 100647.
[26] Vinayaka, Prasad P R C. AI-enhanced remote sensing applications in Indian sugarcane research: a comprehensive review[J]. Sugar Tech., 2024, 26: 609 - 628.
[27] Johnson T W. Review of plant pathology, by G. N. Agrios[J]. The Bryologist, 1970, 73(4): 736.
[28] Busby P E, Ridout M, Newcombe G. Fungal endophytes: modifiers of plant disease[J]. Plant Molecular Biology, 2016, 90: 645 - 655.
[29] Mahlein A K. Plant disease detection by imaging sensors-parallels and specific demands for precision agriculture and plant phenotyping[J]. Plant Disease, 2015, 100(2): 241 - 251.
[30] Xu C, Ding J, Qiao Y, et al. Tomato disease and pest diagnosis method based on the stacking of prescription data[J]. Computers and Electronics in Agriculture, 2022, 197: 106997.
[31] 张领先,韩梦瑶,丁俊琦,等. 作物病害智能诊断与处方推荐技术研究进展[J]. 农业机械学报,2023, 54(6): 1 - 18.
Zhang Lingxian, Han Mengyao, Ding Junqi, et al. Research progress in intelligent diagnosis and prescription recommendation of crop diseases[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 1 - 18. (in Chinese)
[32] Zhang J, Huang Y, Pu R, et al. monitoring plant diseases and pests through remote sensing technology: a review[J]. Computers and Electronics in Agriculture, 2019, 165: 104943.
[33] Li L, Dong Y, Xiao Y, et al. Combining disease mechanism and machine learning to predict wheat fusarium head blight[J]. Remote Sensing, 2022, 14(12): 2732.
[34] Xu C, Zhao L, Wen H, et al. Spatial-temporal analysis and trend prediction of regional crop disease based on electronic medical records[J]. Applied Soft Computing, 2024, 167: 112423.
[35] Guo Z, Chen X, Li M, et al. Construction and validation of peanut leaf spot disease prediction model based on long time series data and deep learning[J]. Agronomy, 2024, 14(2): 294.
[36] Hasanzadeh M, Mohammadi N, Safaie N, et al. Spatial-temporal analysis of wheat leaf rust disease (Puccinia triticina Eriks) in Southwestern Iran[J]. Journal of Crop Protection, 2024, 13(1): 55 - 74.
[37] Kong J, An Y, Shi X, et al. Meteorological-data-driven rubber tree powdery mildew model and its application on

spatiotemporal patterns: a case study of Hainan island[J]. Sustainability, 2023, 15(16): 12119.

[38] Ma X, Zhang X, Guan H, et al. Recognition method of crop disease based on image fusion and deep learning model[J]. Agronomy, 2024, 14(7): 1518.

[39] Long Y, Huang W, Wang Q, et al. Integration of textural and spectral features of Raman hyperspectral imaging for quantitative determination of a single maize kernel mildew coupled with chemometrics[J]. Food Chemistry, 2022, 372: 131246.

[40] Andersson M A, Salo J, Kedves O, et al. Bioreactivity, guttation and agents influencing surface tension of water emitted by actively growing indoor mould isolates[J]. Microorganisms, 2020, 8(12): 1940.

[41] Loutfi H, Fayad N, Pellen F, et al. Morphological study of bacillus thuringiensis crystals and spores[J]. Applied Sciences, 2021, 11(1): 155.

[42] Dhal K G, Das A, Ray S, et al. Nature-inspired optimization algorithms and their application in multi-thresholding image segmentation[J]. Archives of Computational Methods in Engineering, 2020, 27: 855 – 888.

[43] Zhang J, Zhao X, Jiang T, et al. An application of pixel interval down-sampling (PID) for dense tiny microorganism counting on environmental microorganism images[J]. Applied Sciences, 2022, 12(14): 7314.

[44] Ippoliti P, Nargi F, Han J, et al. Highly accurate classification of biological spores by culture medium for forensic attribution using multiple chemical signature types and machine learning[J]. Analytical and Bioanalytical Chemistry, 2020, 412: 4287 – 4299.

[45] Zhao Y, Liu S, Hu Z, et al. Separate degree based otsu and signed similarity driven level set for segmenting and counting anthrax spores[J]. Computers and Electronics in Agriculture, 2020, 169: 105230.

[46] Qiao C, Li K, Zhu X, et al. Detection of cucumber downy mildew spores based on improved YOLOv5s[J]. Information Processing in Agriculture, 2025, 12(2): 179 – 194.

[47] Zhang Z, Liu K, Zha Z, et al. YOLOv11 – DAFNet: a multi-directional attention and multi-dilated residual fusion network for cucumber downy mildew sporangia detection in microscopic images[J]. Smart Agricultural Technology, 2025, 12: 101535.

[48] Zhang D, Zhang W, Cheng T, et al. Segmentation of wheat scab fungus spores based on CRF_ResUNet + +[J]. Computers and Electronics in Agriculture, 2024, 216: 108547.

[49] 张一丁,韩宗桓,乔琛,等. 基于 PG – YOLO v8s 的黄瓜白粉病菌显微图像精准检测[J].农业机械学报,2025, 56(12): 522 – 533.
Zhang Yiding, Han Zonghuan, Qiao Chen, et al. Accurate detection of cucumber powdery mildew fungus in microscopic images based on PG – YOLO v8s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(12): 522 – 533. (in Chinese)

[50] 张一丁,乔琛,张领先,等. 基于改进 YOLO v8s – OBB 的黄瓜霜霉病菌分生孢子梗与孢子囊定量检测[J]. 农业机械学报,2025, 56(12): 479 – 489.
Zhang Yiding, Qiao Chen, Zhang Lingxian, et al. Quantitative detection of conidiophores and sporangium of cucumber downy mildew based on improved YOLO v8s – OBB[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(12): 479 – 489. (in Chinese)

[51] 乔琛,韩宗桓,张一丁,等. 基于改进 YOLO v7 的黄瓜霜霉病菌侵染结构识别方法[J].农业机械学报,2025, 56(11): 528 – 537.
Qiao Chen, Han Zonghuan, Zhang Yiding, et al. Method for identifying infection structures of cucumber downy mildew based on improved YOLO v7 model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(11): 528 – 537. (in Chinese)

[52] Zhu X, Chen F, Qiao C, et al. Cucumber pathogenic spores' detection using the GCS – YOLOv8 network with microscopic images in natural scenes[J]. Plant Methods, 2024, 20: 131.

[53] Qiao C, Han Z, Wang Y, et al. Recognition and temperature effect analysis of cucumber gray mold spore germination based on dual lightweight YOLOv8s[J]. Computers and Electronics in Agriculture, 2026, 247: 111662.

[54] Han Z, Qiao C, Zhang Y, et al. Dynamic analysis of the infection process of cucumber powdery mildew based on instance segmentation[J]. Biosystems Engineering, 2026, 263: 104395.

[55] Kurmi Y, Saxena P, Kirar B S. et al. Deep CNN model for crops' diseases detection using leaf images[J]. Multidimensional Systems and Signal Processing, 2022, 33: 981 – 1000.

[56] Chen J, Chen J, Zhang D, et al. Using deep transfer learning for image-based plant disease identification[J]. Computers and Electronics in Agriculture, 2020, 173: 105393.

[57] Zhang K, Wu Q, Chen Y, et al. Detecting soybean leaf disease from synthetic image using multi-feature fusion Faster R – CNN [J]. Computers and Electronics in Agriculture, 2021, 183: 106064.

[58] Liu W, Wu G, Wang H, et al. Lightweight pyramidal multi-scale attention residual network for plant disease recognition[J]. IEEE Access, 2025, 13: 61526 – 61536.

[59] 代聪,唐兴隆,张涛,等. 基于改进 YOLOv10 的复杂田间场景的小目标农业害虫高效检测[J]. 农业工程学报,2025, 41(21): 196 – 202.
Dai Cong, Tang Xinglong, Zhang Tao, et al. Efficient detection of small agricultural pests in complex field scenarios based on an improved YOLOv10 approach[J]. Transactions of the CSAE, 2025, 41(21): 196 – 202. (in Chinese)

[60] Saleh H, Alsamhi S H, McCann M, et al. AI meets climate: advanced transformer multimodal model for early and accurate plant disease detection[C]// 2024 10th International Conference on Computing, Engineering and Design (ICCED), 2024: 1-6.

[61] Fu R, Wang X, Wang S, et al. PMJDM: a multi-task joint detection model for plant disease identification[J]. Frontiers in Plant Science, 2025,16:1599671.

[62] Xu C, Zhao L, Wen H, et al. A novel cascaded multi-task method for crop prescription recommendation based on electronic medical record[J]. Computers and Electronics in Agriculture, 2024, 219: 108790.

[63] Njoroge T K N, Mugoye K S, Kibuku R. Edge optimized multimodal cross fusion model with statistical validation for multi crop disease detection[J]. International Journal of Advances in Intelligent Informatics, 2025, 11(3): 439-458.

[64] 张领先,丁俊琦,陈菲菲,等. 基于电子病历多模态数据的作物病害多元场景处方推荐方法研究[J]. 农业机械学报, 2025, 56(1): 25-36.
Zhang Lingxian, Ding Junqi, Chen Feifei, et al. Multi-scenario prescription recommendations for crop diseases based on multi-modal data of electronic medical records[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(1): 25-36. (in Chinese)

[65] 张领先,赵聃桐,丁俊琦,等. 基于 CDSSM 的作物病害处方推荐方法[J]. 农业机械学报,2023, 54(3): 308-317.
Zhang Lingxian, Zhao Dantong, Ding Junqi, et al. Recommendation method of crop disease prescription based on CDSSM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(3): 308-317. (in Chinese)

[66] Ding J, Qiao Y, Zhang L. Plant disease prescription recommendation based on electronic medical records and sentence embedding retrieval[J]. Plant Methods, 2023, 19: 91.

[67] 王波,丁俊琦,吴奇峰,等. 基于多源异构数据和知识图谱的作物病害关联分析[J]. 农业机械学报,2025, 56(12): 546-559.
Wang Bo, Ding Junqi, Wu Qifeng, et al. Association analysis of crop diseases based on multi-source heterogeneous data and knowledge graph[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(12): 546-559. (in Chinese)

[68] 徐畅,张领先,乔岩. 基于电子病历的作物病虫害关联挖掘及智能诊断[J]. 智能化农业装备学报(中英文),2023, 4(4): 1-10.
Xu Chang, Zhang Lingxian, Qiao Yan. Association mining of crop diseases and intelligent diagnosis based on electronic medical records[J]. Journal of Intelligent Agricultural Mechanization, 2023, 4(4): 1-10. (in Chinese)

[69] 丁俊琦,李博,乔岩,等. 基于植物电子病历多类型数据融合的作物病害诊断方法[J]. 农业机械学报,2023, 54(1): 196-204.
Ding Junqi, Li Bo, Qiao Yan, et al. Crop disease diagnosis method based on fusion of multiple types of data from plant EMRs [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(1): 196-204. (in Chinese)

[70] Xu C, Ding J, Wang B, et al. Multimodal-information-based optimized agricultural prescription recommendation system of crop electronic medical records[J]. Journal of Industrial Information Integration, 2025, 43: 100748.

[71] Bock C H, Poole G H, Parker P E, et al. Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging[J]. Critical Reviews in Plant Sciences, 2010, 29(2): 59-107.

[72] Ouhami M, Hafiane A, Es-Saady Y, et al. Computer vision, Iot and data fusion for crop disease detection using machine learning: a survey and ongoing research[J]. Remote Sensing, 2021, 13(13): 2486.

[73] Cai P, Chen G, Yang H, et al. Detecting individual plants infected with pine wilt disease using drones and satellite imagery: a case study in Xianning, China[J]. Remote Sensing, 2023, 15(10): 2671.

[74] Liu J, Zhang Y, Chen X. PGCNet: a Transformer-CNN hybrid segmentation model for pine wilt disease identification[J]. Frontiers in Plant Science, 2026, 17: 1760648.

[75] Yuan L, Bao Z, Zhang H, et al. Habitat monitoring to evaluate crop disease and pest distributions based on multi-source satellite remote sensing imagery[J]. Optik, 2017, 145: 66-73.

[76] Been T H, Beniers J E, Wolf J M. Determining the spatial pattern of blackleg diseased potato plants in the field and simulated post-harvest tuber infections in potato crates[J]. Potato Research, 2022, 65: 395-416.

[77] Zhai Z, Martínez J F, Beltran V, et al. Decision support systems for agriculture 4.0: Survey and challenges[J]. Computers and Electronics in Agriculture, 2020, 170: 105256.

[78] Rosselló N B, Rossini L, Speranza S, et al. Towards pest outbreak predictions: are models supported by field monitoring the new hope? [J]. Ecological Informatics, 2023, 78: 102310.

[79] Alves Md C, Silva F Md, Pozza E A, et al. Modeling spatial variability and pattern of rust and brown eye spot in coffee agroecosystem[J]. Journal of Pest Science, 2009, 82: 137-148.

[80] Mahmud M S, He L, Zahid A, et al. Detection and infected area segmentation of apple fire blight using image processing and deep transfer learning for site-specific management[J]. Computers and Electronics in Agriculture, 2023, 209: 107862.

[81] Christoforides E, Chronopoulos K, Kamoutsis A, et al. A geospatial model for identifying high-risk locations for downy mildew (*Plasmopara viticola*) infestation in vineyards of Greece[J]. Agriculture, 2026, 16(5): 511.

[82] 胡军,鲍德瑞,石航,等. 精准变量喷药技术发展现状与展望[J]. 植物保护学报,2026, 53(1): 54-66.

Hu Jun, Bao Derui, Shi Hang, et al. Current status and prospect of precision variable spraying technology[J]. Journal of Plant Protection, 2026, 53(1): 54 – 66. (in Chinese)

[83] Björkman M, Klingen I, Birch A N E, et al. Phytochemicals of brassicaceae in plant protection and human health-influences of climate, environment and agronomic practice[J]. Phytochemistry, 2011, 72(7): 538 – 556.

[84] Suresh T, Fallah M H, Anand U, et al. Edge computing for real-time crop health monitoring in precision agriculture[C]// 2025 International Conference on Innovations and Emerging Technologies In AI & Communication Systems (IETACS), 2025: 1496 – 1501.

[85] 李祚泳,彭荔红. 基于人工神经网络的农业病虫害预测模型及其效果检验[J]. 生态学报,1999, 19(5): 759 – 762.
Li Zuoyong, Peng Lihong. Agricultural pest and disease prediction model based on artificial neural network and its effectiveness verification[J]. Journal of Ecology, 1999, 19(5): 759 – 762. (in Chinese)

[86] 李华峰,郭淑芳,宋赫. 基于长期气象观测的农业病虫害发生规律分析[J]. 河北农机,2025(13): 112 – 114.

[87] 田家榛,孙炜琳. 设施蔬菜农户病虫害综合防控行为风险评估:基于贝叶斯分类统计方法的实证分析[J]. 中国农业资源与区划,2019, 40(2): 21 – 30.
Tian Jiazhen, Sun Weilin. Risk assessment of integrated pest and disease prevention behavior among facility vegetable farmers: empirical analysis based on Bayesian classification statistical method[J]. China Agricultural Resources and Zoning, 2019, 40(2): 21 – 30. (in Chinese)

[88] 杨林菲. 洛阳市苹果主要病虫害风险区划[J]. 现代农业科技,2017(24): 113 – 115.
Yang Linfei. Risk zoning of major apple pests and diseases in Luoyang City[J]. Modern Agricultural Science and Technology, 2017(24): 113 – 115. (in Chinese)

[89] Tai C Y, Wang W J, Huang Y M. Using time-series generative adversarial networks to synthesize sensing data for pest incidence forecasting on sustainable agriculture[J]. Sustainability, 2023, 15(10): 7834.

[90] 张善文,张传雷,丁军. 基于改进深度置信网络的大棚冬枣病虫害预测模型[J]. 农业工程学报,2017, 33(19): 202 – 208.
Zhang Shanwen, Zhang Chuanlei, Ding Jun. Disease and insect pest forecasting model of greenhouse winter jujube based on modified deep belief network[J]. Transactions of the CSAE, 2017, 33(19): 202 – 208. (in Chinese)

[91] 王献锋,张传雷,张善文,等. 基于自适应判别深度置信网络的棉花病虫害预测[J]. 农业工程学报,2018, 34(14): 157 – 164.
Wang Xianfeng, Zhang Chuanlei, Zhang Shanwen, et al. Forecasting of cotton diseases and pests based on adaptive discriminant deep belief network[J]. Transactions of the CSAE, 2018, 34(14): 157 – 164. (in Chinese)

[92] 秦立峰,张熹,张晓茜. 基于高光谱病害特征提取的温室黄瓜霜霉病早期检测[J]. 农业机械学报,2020, 51(11): 212 – 220.
Qin Lifeng, Zhang Xi, Zhang Xiaoqian. Early detection of cucumber downy mildew in greenhouse by hyperspectral disease differential feature extraction[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(11): 212 – 220. (in Chinese)

[93] 李小龙,王库,马占鸿. 基于热红外成像技术的小麦病害早期检测[J]. 农业工程学报, 2014, 30(18): 183 – 189.
Li Xiaolong, Wang Ku, Ma Zhanhong. Early detection of wheat diseases based on thermal infrared imaging technology[J]. Transactions of the CSAE, 2014, 30(18): 183 – 189. (in Chinese)

[94] 杨燕,何勇. 基于高光谱图像的稻瘟病抗氧化酶值早期预测[J]. 农业工程学报,2013, 29(20): 135 – 141.
Yang Yan, He Yong. Early prediction of antioxidant enzyme value of rice blast based on hyper-spectral image[J]. Transactions of the CSAE, 2013, 29(20): 135 – 141. (in Chinese)

[95] 顾志强,朱武,王光东. 基于 LoRa 和 NB – IOT 的远程温室监控系统的设计与应用[J]. 工业仪表与自动化装置,2025(2): 48 – 53,75.
Gu Zhiqiang, Zhu Wu, Wang Guangdong. Design and application of a remote greenhouse monitoring system based on LoRa and NB – IoT[J]. Industrial Instrumentation and Automation Devices, 2025(2): 48 – 53,75. (in Chinese)

[96] He J, He F, Wang W. A precise identification and early warning model for garden plant diseases and pests integrating YOLOv8 with hyperspectral remote sensing[C]// 2026 International Conference on Communication Networks and Machine Learning (CNML), 2026: 717 – 721.

[97] 黄文江,张竞成,黄林生,等. 植被病虫害遥感监测预警研究进展与展望[J]. 遥感学报,2025, 29(6): 2065 – 2082.
Huang Wenjiang, Zhang Jingcheng, Huang Linsheng, et al. Progressof vegetation pest and disease monitoring and forecasting [J]. National Remote Sensing Bulletin, 2025, 29(6): 2065 – 2082. (in Chinese)

[98] Gégout-Petit A, Guérin-Dubrana L, Li S. A new centered spatio-temporal autologistic regression model with an application to local spread of plant diseases[J]. Spatial Statistics, 2019, 31: 100361.

[99] Glligan C A, Truscott J E, Stacey A J. Impact of scale on the effectiveness of disease control strategies for epidemics with cryptic infection in a dynamical landscape: an example for a crop disease[J]. J. R. Soc. Interface., 2007, 4(16): 925 – 934.

[100] Gopinath V, Sangeetha M. Spatial-temporal digital twin for crop disease prediction: a hybrid ConvLSTM-graph neural network approach[C]// 2025 3rd International Conference on Intelligent Cyber Physical Systems and Internet of Things (ICoICI), 2025: 570 – 575.

(下转第 61 页)

Journal of King Saud University Computer and Information Sciences, 2025, 37(4): 41.
[23] 李浩,张海明,聂珊,等. 融合知识图谱与动态门控机制的作物病虫害多模态识别方法[J/OL]. 微电子学与计算机, 2026-06-13. https://link.cnki.net/urlid/61.1123.tn.20260303.1503.006.
[24] 郝霞,周子钰,宋扬,等. 基于轻量化多模态 Blend-CNN 模型的小麦病虫害识别方法[J]. 农业机械学报,2025,56(12): 490-498,559.
Hao Xia, Zhou Ziyu, Song Yang, et al. Wheat disease and pest recognition method based on lightweight multimodal Blend-CNN model[J]. Transactions of the Chinese Society for Agricultural Machinery,2025,56(12):490-498,559. (in Chinese)
[25] 朱莉凯,柯灵. 基于数字图像的农业害虫精准检测算法及应用分析[J]. 南方农机,2026,57(4):63-66.
Zhu Likai, Ke Ling. Analysis of precision detection algorithms and applications for agricultural pests based on digital images [J]. Southern Agricultural Machinery, 2026, 57(4): 63-66. (in Chinese)
[26] Qiu X, Chen H, Huang P, et al. Detection of citrus diseases in complex backgrounds based on image-text multimodal fusion and knowledge assistance[J]. Frontiers in Plant Science, 2023, 14: 1280365.
[27] Liang F, Huang Z, Wang W, et al. Dynamic text prompt joint multimodal features for accurate plant disease image captioning [J]. The Visual Computer, 2025, 41(8): 5405-5419.
[28] 尚华胜,甘淑,袁希平,等. 级联语义分割和边缘检测的 GF-2 影像耕地提取[J]. 遥感信息,2024,39(4):134-143.
Shang Huasheng, Gan Shu, Yuan Xiping, et al. Extraction of cultivated land from GF-2 images based on level wise semantic segmentation and edge detection[J]. Remote Sensing Information, 2024, 39(4): 134-143. (in Chinese)

(上接第 15 页)

[101] Maneesha A, Suresh C, Kiranmayee B V. Prediction of rice plant diseases based on soil and weather conditions[C]// Proceedings of International Conference on Advances in Computer Engineering and Communication Systems, 2021.
[102] Xu C, Zhang Y, Zhao L, et al. Knowledge-guided adaptive spatial-temporal graph contrastive learning framework: regional crop diseases prediction based on electronic medical records[J]. Neural Networks, 2025, 189: 107597.
[103] Su J, Yi D, Su B, et al. Aerial visual perception in smart farming: field study of wheat yellow rust monitoring[J]. IEEE Transactions on Industrial Informatics, 2021, 17(3): 2242-2249.
[104] Mangewa L J, Ndakidemi P A, Munishi L K. Integrating UAV technology in an ecological monitoring system for community wildlife management areas in Tanzania[J]. Sustainability, 2019, 11(21): 6116.
[105] Marek K, Jakub S, Kniećˊ W, et al. Survey of drones for agriculture automation from planting to harvest[C]//2018 IEEE 22nd International Conference on Intelligent Engineering Systems (INES), 2018: 353-358.
[106] Ravlin F W. Development of monitoring and decision-support systems for integrated pest management of forest defoliators in North America[J]. Forest Ecology and Management, 1991, 39: 3-13.
[107] Jakubowska M, Bocianowski J, Nowosad K, et al. Decision support system to improve the effectiveness of chemical control against cutworms in sugar beet[J]. Sugar Tech., 2020, 22: 911-922.
[108] Jin Y, Li J, Gu T, et al. Efficient multimodal large language models: a survey[J]. Visual Intelligence, 2025, 3: 27.
[109] Wang Y, Pan Y, Su Z, et al. Large model based agents: state-of-the-art, cooperation paradigms, security and privacy, and future trends[J]. IEEE Communications Surveys & Tutorials, 2026, 28: 1906-1949.
[110] Sun J, Zheng C, Xie E, et al. A survey of reasoning with foundation models: concepts, methodologies, and outlook[J]. ACM Computing Surveys, 2025, 57(11): 1-43.
[111] Qu G, Chen Q, Wei W, et al. Mobile edge intelligence for large language models: a contemporary survey[J]. IEEE Communications Surveys & Tutorials, 2025, 27(6): 3820-3860.
[112] Xu M, Cai D, Yin W, et al. Resource-efficient algorithms and systems of foundation models: a survey[J]. ACM Computing Surveys, 2025, 57(5): 1-39.
[113] Din M, Akoram W, Saoud L, et al. Multimodal fusion with vision-language-action models for robotic manipulation: a systematic review[J]. Information Fusion, 2026,129:104062.
[114] Kazmierczak R, Berthier E, Frehse G, et al. Explainability and vision foundation models: a survey[J]. Information Fusion, 2025, 122: 103184.