

基于人工智能的农田景观中 害虫发生预测与展望*

杨璐嘉** 门兴元***

(山东省农业科学院植物保护研究所, 山东省农业有害生物绿色防控重点实验室, 济南 250100)

摘要 农田景观中害虫发生、扩散和危害, 导致了作物减产、农产品质量下降, 并深刻影响了农业生态系统的稳定性和可持续性。作为农业生产管理的关键环节, 害虫种群监测与发生预测, 有助于提前预警和合理防控决策, 在保障粮食安全和推动生态农业建设中发挥着至关重要的作用。传统的害虫预测方法主要利用种群调查、环境监测、景观遥感以及历史数据的统计建模, 但在应对全球气候变化和农田景观变化、提高预测精准度以及实现动态监测方面仍面临诸多局限。随着人工智能 (AI) 技术的进步, 基于机器学习和深度学习在农田景观中害虫预测系统成为研究热点。本文系统综述了农田景观中害虫预测技术的演进路径及智能预警机制的理论与应用, 重点讨论了基于 AI 驱动在农田景观害虫预测中的应用潜力、深度学习模型在害虫智能识别中的实践应用、以及多模态数据融合技术在害虫-天敌互作监测中的潜力等方面。本文还详细分析了当前 AI 模型在害虫预测中可能面临的技术瓶颈与挑战, 展望了通过强化跨学科合作与技术集成, AI 技术对农田景观中的害虫预测的深度应用将进一步优化农业生态管理策略, 提高害虫防控的精准性和时效性。

关键词 农田景观; 害虫预测; 人工智能; 时空建模; 深度学习

Prediction and prospects of pest occurrence in agricultural landscapes based on artificial intelligence

YANG Lu-Jia** MEN Xing-Yuan***

(Shandong Key Laboratory for Green Prevention and Control of Agricultural Pests, Institute of Plant Protection, Shandong Academy of Agricultural Science, Jinan 250100, China)

Abstract The occurrence, spread and damage of pests within agricultural landscapes lead to reduced crop yields, lower quality of agricultural products, and impacts on the stability and sustainability of agroecosystems. As a key component of agricultural management, pest population monitoring and occurrence prediction contributes to early warning and rational prevention and control decisions and plays an important role in ensuring food security and promoting ecological agriculture. Traditional pest prediction methods mainly use population surveys, environmental monitoring, landscape remote sensing, and statistical modeling based on historical datasets, while they still face significant limitations in responding to the change of global climate and agricultural landscapes, improving prediction accuracy, and achieving dynamic monitoring. With the advancements of artificial intelligence (AI) technology, pest prediction systems based on machine learning and deep learning in agricultural landscapes have become a hot research topic. This study provides a systematic overview of the evolutionary trajectory of pest prediction technologies and the theoretical foundations and applications of intelligent early warning mechanisms in agricultural landscapes, focusing on the potential application of AI-driven pest prediction in agricultural landscapes based on AI, the practical application of deep learning models for intelligent pest recognition, and the potential of multimodal data fusion technologies in pest-natural enemy interactions monitoring. This study also analyzes in detail the

*资助项目 Supported project: 国家重点研发计划 (2023YFD1400800)

**第一作者 First author, E-mail: ylj0818@126.com

***通讯作者 Corresponding author, E-mail: menxy2000@hotmail.com

收稿日期 Received: 2025-01-03; 接受日期 Accepted: 2025-04-14

current technical bottlenecks and challenges that AI models may face in pest prediction, and foresees that by strengthening interdisciplinary cooperation and technical integration, the in-deep application of AI for pest prediction in agricultural landscapes will further optimize agro-ecological management strategies, and improve the precision and timeliness of pest prevention and control.

Key words agricultural landscape; pest prediction; artificial intelligence; space-time modeling; deep learning

农田生态系统的健康与稳定是全球农业可持续发展的基石。然而,气候变化、生物多样性下降、病虫害加剧以及入侵物种扩散等多重威胁对农业生产的可持续性构成了严峻挑战。昆虫是农田生态系统平衡不可或缺的一部分,全球昆虫种类超过 100 万种,这些昆虫中既包括害虫,也包括天敌和授粉昆虫等益虫,广泛分布于农田及周边不同生境中 (Chakrabarty *et al.*, 2024)。据统计,全球约 10% 的粮食产量因虫害而损失 (沈艳艳等, 2023), 有效管理农田中害虫种群对于保障粮食安全十分重要。

作物物候和轮作制度是调控昆虫丰度、多样性与行为模式的重要驱动因素,决定了昆虫赖以生存的资源在时间与空间上的可用性与连续性,从而影响种群的生命周期过程和稳定性。农田景观是由作物与非作物生境共同构成的复杂镶嵌体,其景观结构和空间异质性在决定害虫及天敌昆虫的分布、扩散及其互作关系方面发挥核心作用 (欧阳芳和戈峰, 2011; 戈峰等, 2014; 李民龙, 2020)。例如,不同耕作模式及田块时空分布格局中寄主植物为害虫提供连续的食物资源,害虫种群数量可能快速积累,导致虫害暴发 (Lu and Baker, 2013; Tsafack *et al.*, 2016)。同时,作物种植结构的变化也会通过影响迁移和扩散等方式改变害虫和天敌昆虫的种群动态及其食物网平衡 (戈峰, 2001; Schellhorn *et al.*, 2014)。以麦长管蚜 *Macrosiphum avenae* 为例,其生活史需要在不同生境之间迁移,非作物生境为其提供关键的中间栖息地,从而降低其向作物田迁入的数量 (Mitchell *et al.*, 2022)。这些生态效应通常表现为显著的时空异质性和非线性特征,受物种生态位、景观配置及气候背景等多重因素的协同调节。

传统的害虫监测与预测方法往往基于单变量指标,忽视了时空动态变化与复杂生态反馈的

综合效应,难以满足当前精准农业和生态调控的实际需求。近年来,人工智能 (Artificial intelligence, AI) 技术的快速发展为这一领域提供了全新的研究工具和技术支持。AI 方法通过融合专家知识和数据驱动算法,能够从海量观测数据中挖掘潜在规律,识别多变量之间的高阶关联性,特别是在处理时序特征与空间相关性方面展现出独特优势 (Cláudia *et al.*, 2023)。借助 AI 和物联网 (IoT) 技术的集成,可以高效整合来自不同生境和作物的数据,自动归类并精准分析昆虫图像,筛选和应用适配的分类模型,进而实现对农田景观中昆虫种群的精确分类、动态监测和发生预测 (Gryshova *et al.*, 2024; Kariyanna and Sowjanya, 2024)。这种新兴的智能化方法,不仅提升了预测的准确性和效率,还为智能防控决策和推进生态友好的虫害防控提供了基础。

基于此,本文从农田景观结构与种植活动对害虫种群动态的影响机制出发,系统梳理了现有研究的主要进展,进一步总结了 AI 等新兴技术在农作物病虫害预测中的应用现状和技术优势,并探讨了当前面临的技术瓶颈与挑战,提出未来研究的关键方向与技术路径,以为农田景观中害虫的精准预测和生态防控提供科学依据和实践指导。

1 农田景观中害虫预测的传统生态模型路径

20 世纪 90 年代至 21 世纪,戈峰研究员从提出害虫生态调控概念出发,逐步构建了系统化的农田景观中害虫生态调控理论、方法与实践,丰富和完善了农田景观中害虫种群动态调节与控制的理论框架与技术体系 (欧阳芳和戈峰, 2001; 戈峰等, 2014)。在此背景下,关于农田景观格局对害虫发生影响的研究取得了较为深

入的进展,重点解析了景观格局中作物和非作物生境以及景观参数与害虫种群数量之间的关系,明确了不同尺度的农业景观格局通过影响昆虫栖息地的空间分布和资源可利用性,直接影响了害虫及其天敌昆虫的分布、扩散及其互作关系。这些研究不仅定量评估了农田景观结构对害虫种群动态的影响,还为探索生态友好的农业害虫管理方式提供了理论依据,对于提升农业生产的可持续性具有重要意义。

1.1 实地调查和经验模型

传统的害虫预测方法通常依赖植物保护专业人员的现场实地调查及长期经验分析判断。通过结合环境变量(如温度、降水量、天敌种群)、农田中作物与非作物生境的时空结构变化和农田管理措施,建立了经验预测模型,用于评估虫害发生期、程度和损失预估。农田景观中的生态过程受作物栽培模式、耕作方式、植物群落结构等多重因素的综合影响,这些因素贯穿昆虫生长发育的各个阶段,是决定种群波动的重要影响因素。导致基于经验的预测方法往往对气候和农田景观因素变化的响应能力不足,进行虫情诊断的方式判断效率低、主观性强,使得对结果的诊断和预警管理具有滞后性和延迟性。

1.2 基于统计与生态建模的方法

随着生态统计学的发展,多元回归、时间序列分析、生命表模型等方法被广泛用于害虫发生预测。多元回归模型可用于分析环境变量和景观变量(如土地利用类型、非作物生境面积等)与害虫种群数量之间的关系(表 1),用来揭示变量之间的潜在联系,为农田景观中害虫种群发生预测提供理论支持。时间序列分析适合于处理具有周期性或季节性波动的种群数据(表 1)。通过生命表数据和发育速率,可以模拟种群增长和季节波动,以深入理解种群动态。在研究农田景观格局对害虫发生影响时,研究人员需要收集并分析历史害虫发生的记录,识别与特定时间和环境条件相关的模式,同时综合考虑农田景观结构和不同时期的景观格局中不同生境类型对害虫

种群动态的作用。这种多维度的分析方法能够更全面地解析景观因素对害虫种群的影响,为生态调控措施的制定提供数据支持。然而,这些方法也面临诸多挑战。例如模型的构建和验证需要大量数据和复杂算法的支持,容易受到数据不足、不平衡以及质量问题的限制。此外,模型强依赖历史数据,而这些数据可能无法充分反映当前和未来快速变化的生态环境,成为生态学研究亟待解决的问题。

1.3 多尺度景观结构对害虫动态的建模方法

戈峰等(2017)系统阐述了区域性农田景观中格局特征与人类种植活动对昆虫的生态学效应,并提出了构建基于区域性农田景观多元化的有害生物生态调控体系。以景观生态学为指导思想,空间尺度是农田景观格局的重要特征,通常划分为田块尺度、景观尺度和区域尺度。田块尺度主要涉及个体、种群、群落和农田生态系统的研究,重点关注局部范围内探索农田景观结构调整对农业昆虫种群发生的影响及相关的生物和非生物因子(杨龙,2020)。在景观尺度和区域尺度,通过应用地统计学技术,能够解析和计算农业景观的空间结构和布局,定量分析不同尺度下景观结构对害虫种群及其自然天敌控害功能的影响和机制(Men *et al.*,2004;欧阳芳等,2013)(表 1)。杨龙(2016)研究表明,林地和休耕地等非作物生境能够促进早期麦田中瓢虫种群的发生,且非作物生境面积的增加有利于小麦拔节以及扬花期僵蚜的发生率。李民龙(2020)研究发现,华北地区不同景观格局影响玉米田主要害虫(二点委夜蛾 *Athetis lepigone*、玉米螟 *Ostrinia furnacalis* 和桃蛀螟 *Conogethes punctiferalis*)成虫密度,揭示了景观异质性在害虫发生的关键作用。然而,目前较少研究从生物学机制角度深入解析农田景观结构与害虫发生数量的直接联系,因此往往难以明确这种关系中起关键性作用的生境资源及其功能。

生态景观设计方法通过确定农田景观最优的空间尺度和功能性植物的类型,根据害虫在农田景观生境斑块的转移扩散规律,对景观中多种

生境斑块进行空间布局以及时间序列上的设计,形成多功能的马赛克循环体,为昆虫群落提供丰富的食物资源、栖息地、越冬场所及繁殖环境(赵紫华等, 2013a, 2013b; 戈峰等, 2014)。当前研究利用 3S 技术(即 RS、GIS 和 GPS),能够高效提取景观范围内农作物种植结构变化的数据,并结合景观格局指数与景观转移矩阵,分析景观格局变化与害虫种群数量之间的动态关系(Schellhorn *et al.*, 2015)。通过在大尺度空间范围内找出影响虫害发生的关键宏观因子,明确农田景观中各个要素对害虫种群的作用(Zhao *et al.*, 2013a, 2013b, 2024)。同时应用景观生态学中的多样性指数、镶嵌度指数、距离指数和景观破碎化指数等指标,以定量化方式描述农田景观板块的组成、结构和过程,以及这些景观特征与多种昆虫种群动态之间的关系(表 1)。通过分析景观要素之间的物种迁移、扩散规律,以及物质流、能流与信息流等生态过程,深入解析景观格局如何影响害虫种群的时空分布(Popescu *et al.*, 2023; Ziesche *et al.*, 2024)。尽管 3S 技术能够提供大量的景观和环境数据,但这些数据的空间分辨率和时间分辨率可能不足以捕捉害虫种群的微尺度动态。此外,不同生境之间的边界效应、景观要素的空间配置与时序动态对昆虫种群的潜在影响,尚未充分阐明。

1.4 害虫-天敌生态调控机制建模

农田害虫种群动态不仅受到寄主植物物候、气候等外部环境因子的驱动,更显著受到天敌密度调节与景观结构配置的影响。在害虫-天敌关系建模方面,已有多种生态建模路径被广泛应用于揭示种间互作机制及其动态演变过程(表 1)。其中,典型模型包括 Lotka-Volterra 方程、生态位模型、功能反应模型等。这些模型能够描述害虫与其天敌之间的数量关系、种群反馈以及资源调控机制,广泛应用于预测生态系统中控害效率的动态变化。Ouyang 等(2020)构建了小麦-玉米-棉花(轮作-间作)生态系统试验模型,发现轮作-间作生态系统有助于增加天敌昆虫龟纹瓢虫 *Propylea japonica* 的数量,进而促进中心棉田蚜虫的减少。该研究揭示了在多作物农田景观系

统中,贯穿整个作物生长周期的天敌发生过程、害虫动态演变机制及其生态控制服务的维持路径,强调了轮作-间作格局在提升农田生态系统稳定性与生物调控功能中的潜在作用。González-Chang 等(2019)研究发现,具有中等景观异质性且包含非作物生境如林带、草地或灌木带等农田景观格局,为天敌提供了越冬场所、补充性食物资源及庇护环境,更有利于提升天敌昆虫的生产和繁殖,从而提高对害虫的生物调控功能。然而,也有研究指出,景观多样性提升并不在所有生态情境下都带来正向控害效应(Holland *et al.*, 2020; Rouabah *et al.*, 2022),说明害虫-天敌互作机制具有较强的情景依赖性,其调控功能常受生态背景、物种功能属性及农业管理方式的综合影响。此外,研究者也广泛采用遥感与 GIS 技术逐步将其引入害虫-天敌调控研究中,用于量化农田景观格局的空间特征,如破碎度、镶嵌度、多样性等景观指标(Zhao *et al.*, 2014; Scowen *et al.*, 2021; Ziesche *et al.*, 2024)。通过遥感影像提取和空间数据分析,研究能够在在大尺度上识别关键景观要素与害虫-天敌种群分布之间的关系,辅助评估不同景观结构对控害功能的贡献。尽管该类方法在揭示生态调控机制方面具有一定优势,但仍存在一些局限性,如模型对生物学参数精度要求较高、部分模型缺乏对空间结构动态变化的表达能力、遥感数据在微尺度响应监测上的分辨率和时效性受限等,限制了模型的广泛适用性和实地推广价值。

2 AI 驱动下农田景观中害虫预测的新范式

近年来,AI 技术的应用为农田景观中害虫精准监测、预测和管理带来了发展契机。AI 凭借其强大的数据处理和模式识别能力,可以有效识别农田景观中的作物及害虫、天敌昆虫的特征变化,精准预测害虫种群的动态变化,已在极端气候监测、害虫暴发预警和高风险决策支持中展现出显著优势,为制定科学的虫害管理策略提供支持。

表 1 传统害虫预测方法对比分析
Table 1 Comparative analysis of traditional pest prediction methods

方法类型 Method type	数据依赖性 Digital dependency	空间/ 时间分辨率 Spatial/temporal resolution	模型自动化 程度 Degree of model automation	对生态复杂关系的 建模能力 Ability to model ecologically complex relationships	优势 Dominance	局限性 Limitation
实地调查法 Field assessment method	高 High	低 Low	低 Low	弱 Weak	直观可靠, 经验积累丰富 Intuitive and reliable, with rich empirical accumulation	主观性强, 耗时费力, 难以大规模应用 Highly subjective, time-consuming, labor-intensive, and difficult to scale
经验预测法 Empirical prediction method	中 Moderate	中 Moderate	中 Moderate	弱-中 Weak-moderate	易于构建, 适合短期预警 Easy to construct, suitable for short-term early warning	对新环境/景观变化适应性差 Poor adaptability to new environments or landscape changes
相关性分析 Correlation analysis	中 Moderate	中 Moderate	低 Low	弱 Weak	简单直观, 适合初步变量筛选与趋势分析 Simple and intuitive, suitable for preliminary variable screening and trend analysis	仅揭示线性关系, 不能体现因果或非线性交互 Only reveals linear relationships; cannot reflect causality or nonlinear interactions
多元回归模型 Multiple regression model	中 Moderate	中-高 Moderate-high	中 Moderate	中 Moderate	可量化多个因子之间关系 Quantify relationships among multiple	变量独立性假设过强, 难处理非线性 Assumes variable independence, struggles with nonlinearity
时间序列分析 Time series analysis	中-高 Moderate-high	高 High	中 Moderate	弱-中 Weak-moderate	适合周期性、季节性害虫预测 Suitable for cyclical and seasonal pest	忽略空间结构, 难以处理突发性 Ignore spatial structure and struggles with abrupt changes
种群动态模型 Population dynamics model	中 Moderate	中 Moderate	中 Moderate	中-强 Moderate-strong	可建模种间关系, 生命周期过程, 捕食/寄生等生态反馈 Models interspecific relationships, life cycles, predation/parasitism feedback	参数敏感性高, 缺乏空间维度, 实际数据拟合困难 Sensitive to parameters, lacks spatial dimension, difficult to fit real data

续表 1 (Table 1 continued)

方法类型 Method type	数据依赖性 Digital dependency	空间/ 时间分辨率 Spatial/temporal resolution	模型自动化 程度 Degree of model automation	对生态复杂关系的 建模能力 Ability to model ecologically complex relationships	优势 Dominance	局限性 Limitation
生态位模型 Ecological niche model	高 High	高 High	中 Moderate	中-强 Moderate-strong	强调物种-环境关系 Emphasizes species-environment	高质量分布数据要求高 Requires high-quality distribution
景观格局建模 Landscape pattern model	高 High	高 High	中-高 Moderate-high	强 Strong	能解析景观要素对种群分布的调控机制 Reveals how landscape elements influence population distribution	对遥感与 GIS 数据依赖大, 建模复杂度高 Heavy reliance on remote sensing and GIS data; high modeling complexity
灰色系统理论 Gray systems theory	低-中 Low-moderate	中 Moderate	中 Moderate	中 Moderate	适用于小样本, 不确定系统预测, 能在信息不足时建模 Applicable to small samples and uncertain systems when data is limited	对参数变化敏感, 解释能力较弱, 适用场景受限 Parameter-sensitive with weak interpretability; limited applicable scenarios
人工神经网络 Artificial neural network	高 High	高 High	高 High	强 Strong	非线性建模能力强, 可自动学习数据特征, 适用于图像/时间序列预测等 Strong nonlinear modeling ability, capable of learning data features automatically; suitable for image/time series prediction	需大量训练数据, “黑箱”问题严重, 可解释性差, 易过拟合 Requires large training datasets; “black-box” nature with poor interpretability; prone to overfitting

2.1 机器学习与深度学习: 识别害虫种群动态的核心工具

机器学习 (Machine learning, ML) 是 AI 的核心组成部分之一, 其核心原理在于通过构建特定算法, 使计算机能够从海量历史数据中自动学习潜在规律 (图 1)。根据学习模式的不同, ML 可分为有监督学习和无监督学习两种类型: 有监督学习通过利用已标注的数据集训练分类器, 实现对新数据的准确分类; 而无监督学习则通过聚类算法对未知类别的数据进行分析和探索。ML 通过反复训练优化过程识别数据模式或最小回归误差, 已广泛应用于作物生长监测、病虫害识别、气象预测及农业资源调度等多个领域 (Lary *et al.*, 2016)。尤其在解析气候变化、景观结构对农田昆虫系统的驱动机制方面, 相较于

传统统计模型展现出更高的灵活性与建模能力, 具有重要的应用潜力。

深度学习 (Deep learning, DL) 作为机器学习的一大分支, 其特点通过对不同网络层输入不同特征在网络内部进行特征的提取, 并且随着网络层数的增加, 输出的结果也不断从具体化到抽象化, 最终实现模型的识别和分类的目的 (王铁伟, 2022) (图 1), 具有卓越的特征提取能力, 能够深入学习数据的复杂特性 (Paul *et al.*, 2024), 使其在处理复杂场景中农业虫害检测和非结构化数据方面具有明显优势。例如, DL 模型可量化特定天敌在特定景观斑块中的控害贡献, 进而反向优化天敌生境配置与非农缓冲带布局。通过重构生态互作网络, 有望识别影响害虫种群波动的核心调控因子, 从而提升控制效率与系统稳定性, 成为机器学习中极具潜力的发展方向。

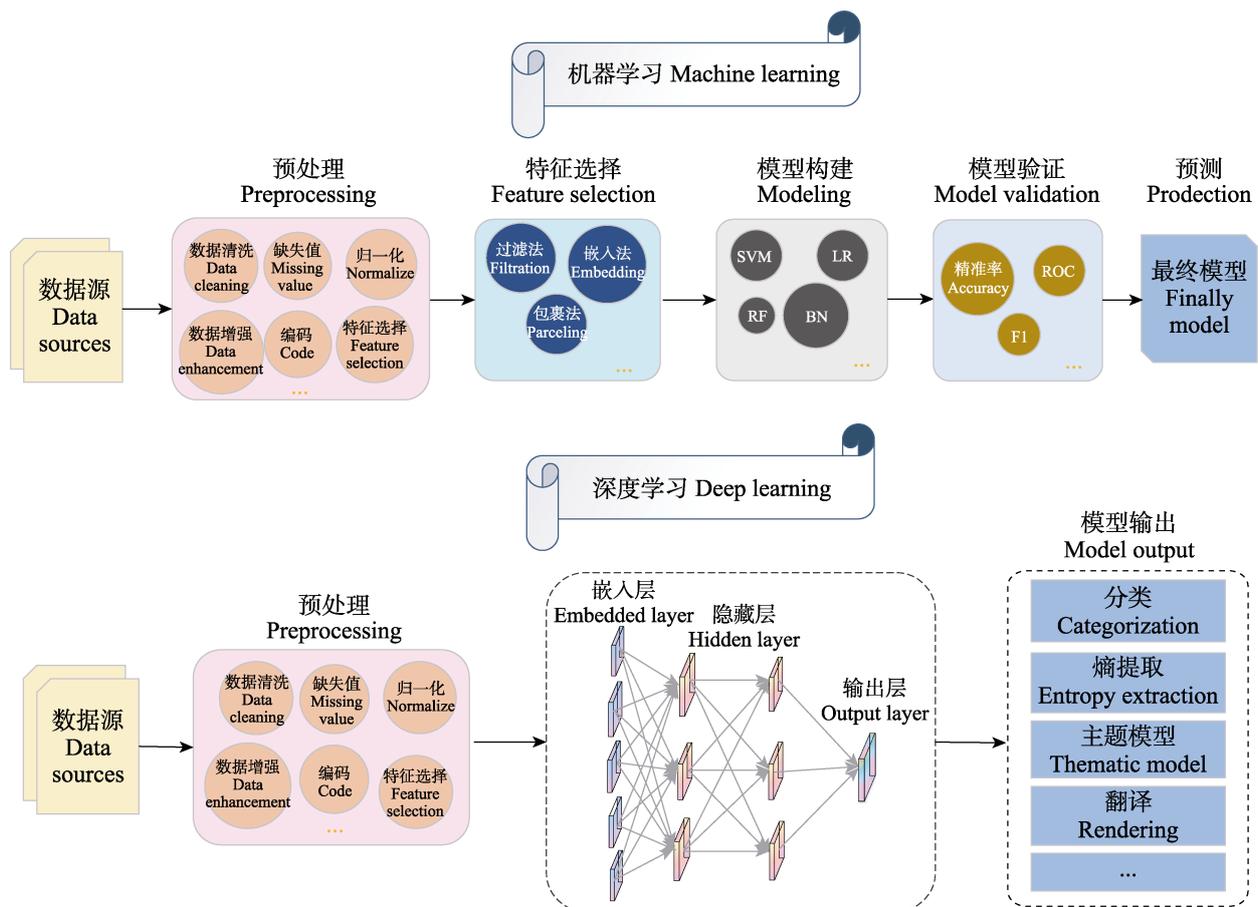


图 1 机器学习和深度学习在建模流程中的理论框架示意图

Fig. 1 Theoretical framework diagram of machine learning and deep learning in modeling workflows

2.2 常见 AI 模型及其在农田景观中害虫发生预测的典型应用

近年来,机器学习在农业病虫害检测中的应用日益广泛 (Khanna *et al.*, 2024), 包含大量的算法和模型。目前,常见的机器学习方法包括支持向量机、随机森林、贝叶斯网络、决策树、神经网络等方面。已广泛应用于病虫害检测、果实识别与计数、植物识别、土壤覆盖分类以及杂草识别等多个方向。

(1) **支持向量机 (Support vector machine, SVM)** 是广泛应用于分类和回归任务的机器学习技术。其核心原理是通过找到不同类别之间的最大边界来实现精确分类,使其在处理高维数据时表现出色。SVM 无需复杂的特征选择,便能在数据量较小且特征复杂的场景中展现出良好的分类能力,尤其适合昆虫生态学、病虫害监测及农田景观研究等领域。例如, Ebrahimi 等 (2017) 利用 SVM 分类算法分析作物冠层图像上的蓟马,实现了较高的分类准确率; Rani 和 Amisni (2016) 采用 SVM 分类器检测农田害虫 (如粉虱、蚜虫和蓟马) 对叶片的侵染面积,显著提高了检测精度。Hu 等 (2018) 利用探照灯诱捕器捕获了 23 种迁飞昆虫建立了基于决策树支持向量机方法的分类模型。此外, SVM 的稳定性和高精度使其在遥感影像分类中也具有显著优势。通过分析景观特征, SVM 能够准确划分景观类型和评估昆虫生态网络的动态变化。这些研究表明, SVM 在昆虫种群监测中具有重要价值,使得 SVM 成为处理复杂生态系统问题的重要工具。

(2) **随机森林 (Random forest, RF)** 是一种基于集成学习的高效分类和回归方法,其核心思想是通过构建多个决策树模型,并对这些树的预测结果进行回归或分类任务,以提高模型的预测准确性和鲁棒性。RF 的优势在于其稳健性和对复杂数据的处理能力,尤其是在非线性、多变量交互的环境下表现尤为出色 (Duarte *et al.*, 2022)。RF 能够高效处理复杂、高维和非线性数据,在物种分布模型构建、生态系统评估以及动态变化预测等任务中表现出色。Haarika 等

(2023) 利用 RF 分类器成功地将虎甲虫分为 Cicindelini 和 Collyridini 两类,分类准确率高达 97.65%,充分体现了 RF 在复杂生物分类任务中的优势。此外,通过集成多个决策树,RF 能够对影响因子 (如气候变量、景观结构和土地利用类型) 进行特征选择和重要性排序,从而构建高效的预测模型。这种能力使其不仅能预测害虫种群动态,还能应用于植被覆盖监测、生境适宜性评估以及生态环境检测等领域。

(3) **贝叶斯网络模型 (Bayesian network, BN)** 是一种基于概率图的机器学习方法,通过构建节点 (变量) 之间的条件依赖关系,能够对复杂系统中的不确定性进行建模和推理。BN 因其灵活性和高效性,被广泛用于分类、预测和决策支持等任务。通过分析农业数据,该模型能够精准预测农作物的生长状况和病虫害发生的概率,有助于制定科学的生产决策问题。将农业多源数据与 BN 模型相结合,可构建用于害虫风险预警与应对的决策支持系统,为农户提供科学的作物保护策略。例如,当系统监测到连续降雨和低温等高风险气象条件时, BN 模型可综合历史虫情数据、气象变量及作物物候信息,动态评估目标害虫的暴发概率,并提供是否提前施行防治措施的建议,从而实现虫害早期预警与精准干预。同时,可揭示影响害虫发生的主导因子,并判断变量之间的因果路径,有助于识别关键控制点。此外, BN 模型在昆虫活动预测中的应用也取得了显著成果。Pawson 等 (2017) 利用 BN 模型预测森林昆虫的飞行活动,通过分析温度、风速、相对湿度等气象条件对昆虫活动的影响,评估昆虫飞行活动的概率。该模型不仅能够为植物检疫风险评估提供重要依据,还可辅助制定有效的预防和控制措施。这种方法在跨学科应用中展现了强大的通用性和实际价值。

(4) **长短期记忆网络 (Long short-term memory, LSTM)** 是一种特殊的循环神经网络 (RNN), 在处理时间序列数据方面表现优异。LSTM 的设计旨在解决传统 RNN 在长时间序列中面临的梯度消失和梯度爆炸问题。通过其独特的门控机制 (输入门、遗忘门和输出门), LSTM

能够有效选择性地记忆或遗忘时间序列中的关键信息,从而实现间隔或延迟较长的事件的准确预测。LSTM 在气象数据和历史病虫害数据的时序预测中具有显著优势,不仅能够捕捉长期依赖关系,还支持多元预测机制。例如,肖晴欣(2019)利用 LSTM 模型预测棉花病虫害的发生,通过对模型的反复训练和迭代优化,显著提高了预测的精度和可靠性。因此,LSTM 的适用范围并不仅限于单一任务,该模型能够高效处理多维输入数据,为多因素影响下的病虫害发生提供科学预测。

(5) 卷积神经网络 (Convolutional neural networks, CNN) 是一种 AI 驱动的图片识别方法,在农田景观区域图像分析中备受关注,广泛用于作物和病虫害分类的研究。CNN 是深度学习中的核心技术之一,以其在处理视觉数据方面的卓越性能而闻名。CNN 能够直接处理原始图像数据识别目标害虫及其分布范围,无需依赖复杂的图像预处理或手动设计的特征提取算法,与传统图像识别方法相比具有显著优势。其基本结构包括输入层、卷积层、激活层、池化层和全连接层,每一层在特征提取、数据表示和分类决策中扮演着独特的角色。CNN 通过卷积层对输入数据进行特征提取,能够自动学习图像中的空间特征,从而降低数据维度,提高计算效率。这种特性使其在处理复杂农业图像数据时表现出色,尤其适合大规模图像数据集的训练和应用。目前,基于 CNN 的 AI 系统在农作物病虫害检测中已取得显著成果。例如,Zhong 和 Zhao (2020) 开发了一种基于深度学习的苹果病害检测 AI 系统,其检测精度显著提高;Mohanty 等 (2016) 使用 CNN 检测水稻病害,实验结果显示其准确率高达 98.5%。此外,张博等 (2019) 提出了一种基于空间金字塔池化和改进 YOLOv3 深度卷积神经网络的作物害虫种类识别算法,精准解决了作物害虫和尺度多样性导致的识别精度问题,为农作物害虫分类提供了一种高效解决方案。陈峰等 (2020) 针对东北寒地玉米常见害虫,结合机器视觉与 CNN 技术,开发了一种精准、实时的害虫识别方法。该方法不仅能够监测植物生长

状态,还为农业的智能化和可持续发展提供了重要支持。这些研究表明,CNN 的深度学习技术为农田景观中昆虫检测和识别提供了全新的思路和方法。

2.3 AI 驱动下害虫-天敌的互作系统

在农田生态系统中,构建时空动态模型以模拟多营养级种群响应,正成为害虫预测与生物控制研究的重要方向。借助 LSTM、Transformer 等时间序列神经网络,可实现农田景观格局变化(如边界密度、多样性指数)与害虫、天敌诱捕数量、气象变量等多维数据的联合建模,从而建立起“景观变化-种群响应-控害效应”的闭环预测系统。Rouabah 等 (2022) 在谷物系统中系统比较了线性模型、回归树与 RF 三种建模策略,在预测蚜虫丰度、寄生率及三类天敌(瓢虫、食蚜蝇、草蛉)数量方面的表现。该研究凸显了 AI 技术在揭示害虫-天敌互作网络、解析生态调控机制中的潜在优势。这类模型不仅能够提前预警害虫高发期,还能刻画天敌的滞后响应机制与局部控制能力阈值,为精准防控策略提供科学依据。进一步地,图神经网络(Graphical neural network, GNN)与结构方程模型(Structural equation model, SEM)嵌入 AI 建模框架,可将多物种间的生态互作关系表示为图结构,识别不同景观条件下的关键物种节点与交互路径,能够更有效地处理大数据,将是害虫在农田景观中的种群发生模式和发生规律预测的最佳工具,生成更准确、更可靠的预测模型,为农业害虫管理研究提供技术支持。

3 深度学习与遥感融合驱动农业景观格局识别与昆虫预测的新技术

3.1 深度学习重塑遥感图像理解

作为 ML 的重要分支,DL 具备强大的特征学习能力,能够自动从海量数据中提取复杂的非线性规律,有效规避了传统图像分析方法中对人工特征构建的依赖。其主要流程包括图像采集、图像分割、特征提取及分类识别,在虫源信息检

测中的表现尤为突出 (Delfani *et al.* 2024)。通过模仿人类多层次认知结构, DL 可实现从低级特征提取到高级语义抽象的多层表达, 显著提高了模型图像理解能力和识别精度 (Kamilaris and Prenafeta-Boldú, 2018; Selvaraj *et al.*, 2019; 南亚平, 2022)。

在 AI 技术未广泛应用之前, 农田景观格局的研究主要依赖于传统遥感图像处理技术, 借助相机等工具自动获取昆虫的图像或光谱数据, 以智能化方式检测害虫的侵扰情况 (Aartsma *et al.*, 2019; Alexandridis *et al.*, 2021)。然而, 这些方法面临操作繁琐、效率低下以及识别精度有限的挑战。随着高分辨率遥感影像的普及与深度学习方法的发展, 研究者已可利用卫星或无人机采集的遥感影像中提取景观格局特征, 结合语义分割和目标检测技术, 实现对不同土地覆被类型的自动识别、昆虫类群的热点区域和害虫分布范围 (Wang *et al.*, 2022; Khanna *et al.*, 2024; Pandey and Mishra, 2024)。同时, 遥感系统提供的景观变量和气象因子可以作为模型输入, 能够有效拟合局部区域的害虫发生概率和时间趋势 (何邦科等, 2024), 为区域性害虫防控提供数据支持。

进一步地, DL 的引入也推动了遥感图像空间表达方式的创新发展。近年来, 研究者尝试引入空间变换与区域同质性分割方法, 在模型训练阶段自动将复杂的异质景观划分为多个生态同质子区 (Camps-Valls *et al.*, 2025), 从而提升模型对空间变化的解析能力和建模精度。此外, 借助深度强化学习模型 (Deep Q-network, DQN), 可构建仿真化的农田生态系统, 对作物布局、非作物带配置与耕作时间等景观管理因子的干预效应进行模拟。在特定气候条件或虫害高风险时期, 该系统可基于历史虫情与模型预测, 输出天敌覆盖率最优、成本最小的景观干预路径, 从而实现种植格局与生态调控策略的协同优化, 提升农田生态系统的稳定性与调控韧性。

3.2 深度学习算法在害虫识别与监测中的典型应用

近年来, DL 技术与遥感技术的结合在农业

领域展现了强大的潜力。通过 CNN、YOLO 等目标检测算法对多源遥感图像 (包括无人机航拍、卫星影像、多光谱与热红外图像) 进行自动化分析, 可高精度提取包括非作物生境、田边结构、耕地边界、作物类型与种植模式在内的关键景观构件。例如, 基于 YOLOv5 的单阶段目标检测模型, 用于识别十字花科作物中重要的昆虫及其损害症状。该研究比较了 YOLOv5 的 5 个变体 (nano、small、medium、large 和 extra-large) 的性能指标、损失函数、计算成本和推理速度, 发现 YOLOv5l 在测试准确度上表现最佳, 达到了 99.5% (Chakrabarty *et al.*, 2024)。此外, Faster-RCNN、ResNet50、Mask-RCNN、ResNet50 和 Darknet53 等算法也被用于不同数据集上的害虫检测, 其性能对比研究进一步推动了算法的优化 (Li *et al.*, 2022)。Cláudia 等 (2023) 系统性综述了使用深度学习自动检测害虫的研究, 包括基于物联网和深度学习的实时远程监测系统, 以及使用图像处理和被动红外传感器检测昆虫的方法, 将 AI 方面的最新技术运用的农业领域, 弥补农田景观在该方面的空白。

尽管 DL 技术和遥感技术在农业景观中的应用取得了显著进展, 但仍存在若干亟待解决的挑战, 包括: (1) 农田景观中害虫预测涉及遥感影像、气象数据和田间传感器数据等多模态数据。这些数据在格式、尺度和质量上的差异, 增加了高效融合的难度。模态缺失问题、数据不一致性及现有模型对低质量数据的适应性较差是多模态数据融合面临的主要挑战。(2) 模型的可解释性是必须解决的关键问题。DL 模型的“黑箱”特性使其在生态政策制定中的应用受到限制。缺乏透明性和决策依据的模型难以获得用户的信任, 景观生态学领域对决策过程的可靠性和透明度要求较高。(3) 昆虫图像数据样本不平衡问题严重影响了模型的泛化能力, 尤其在少见或稀有害虫的识别中, 模型可能难以提供稳定的性能。(4) DL 模型的训练和部署需要高性能计算资源, 这可能增加技术应用的成本。此外, 模型的实际适用性和可扩展性仍需进一步验证。

4 基于 AI 技术与多源数据融合, 构建精准预测的知识驱动平台

如何利用多源数据实现精准预报是我国重大科学产业技术问题之一。通过整合田间多源传感器数据、气象数据和遥感影像, 并经过数据清洗、融合和关联建模, 可以将多源异构数据进行有效整合, 为精准预测和管理提供数据基础 (图 2)。例如, 由美国佛蒙特大学开发的 ARIES 模型结合多尺度过程和贝叶斯概率模型, 模拟了多种生态系统服务从供给区到服务受益区的流动过程, 并提供了一个智能建模平台, 从而灵活调整模型以适应空间、时间或其他环境动态的变化 (Villa *et al.*, 2009)。Turkoglu 等 (2022) 提出了一种结合多模型 LSTM 和预训练的 CNN 的检测系统, 构建了一个稳健的苹果病虫害检测混合模型。该方法通过 LSTM 网络处理时间序列数

据, 并利用预训练的 CNN 提取图像特征, 最后采用集成多数投票的分类器进行预测, 进一步提升了检测精度和系统的稳健性。以下是几种关键的集成技术及其应用: (1) 时空数据融合技术是实现精准预测的关键手段。通过融合不同时间尺度和空间尺度的数据, AI 系统可以全面捕捉害虫种群的动态变化趋势, 同时感知关键生态变量 (如温度、湿度和光照) 在时空维度上的变化。这种融合技术不仅为害虫种群动态监测提供了全面的数据支持, 还可用于物种分布预测、栖息地质量评估以及生态系统动态变化的长期监测。通过多维数据整合, 时空数据融合技术显著提升了预测模型的精度和适应性, 为农业生态管理提供了强大的技术支撑。(2) 作物生长模型与昆虫预测模型相结合的作物-昆虫共生模型, 是生态系统协同预测的重要工具。该模型可以整合多种动态变量, 揭示复杂生态网络中的关键机制。还

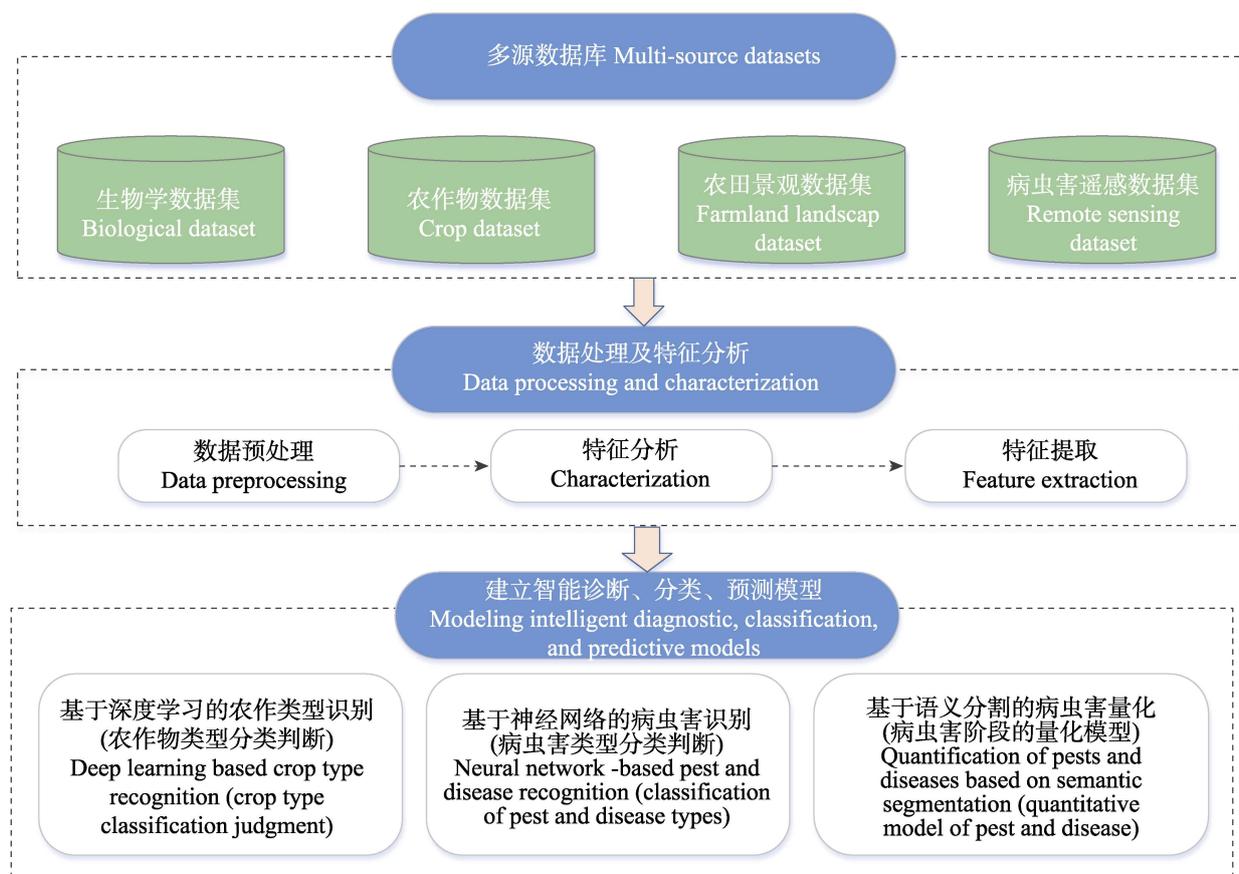


图 2 基于 AI 技术的多源数据驱动的病虫害智能识别与分类建模流程图

Fig. 2 Workflow of multi-source data-driven intelligent identification and classification modeling for pest and disease analysis based on AI technology

能够有效预测作物生长与昆虫发生之间的交互关系,从而提升病虫害防控的时效性和准确性,为智慧农业的发展提供了重要助力。(3) AI 驱动的害虫识别与景观优化系统,通过 AI 技术开发的害虫识别系统能够评估不同景观格局组成对害虫与天敌种群动态的影响,识别出增强害虫自然调控能力的关键田间景观因素。该系统融合了宏观尺度的遥感观测数据和微观层面的昆虫图像识别技术,能够从整体格局到局部细节多尺度地揭示农田景观结构的复杂性及其与害虫种群动态之间的交互关系。以上这些技术的发展和应用,为生态学研究 and 环境保护提供了新的视角和工具。不仅有助于优化农田景观布局,还能提升生态调控功能,为构建生态友好型农田管理模式提供了科学依据和决策支持。

综上所述, AI 算法以其强大的数据处理和建模能力,实现知识引导的机器学习以及应用深度学习算法等方面,为农田景观中虫害监测和识别提供了全新的技术解决方案,精准预测虫害的发生时间和范围,优化害虫防控决策。通过深入的数据洞察、提高预测准确性、优化治理策略和保护措施,为生态调控提供了强有力的技术支持。

5 总结与展望

在全球气候变化持续加剧和种植业制度快速调整的双重背景下,我国农业昆虫种群演替规律的研究正面临新的挑战 and 更高的科学要求。特别是在种植业结构大范围调整之前,如何精准预测关键害虫的发生动态,是实现生态友好型农业病虫害管理的核心难题。AI 技术的快速发展为农田景观中昆虫的监测、预测与防控提供了系统化、智能化的解决路径,助力实现从数据采集、处理到分析和决策的全流程自动化。未来研究方向应侧重于:

(1) 在预测手段上,未来害虫预测体系应注重整合无人机或卫星遥感、物联网数据和气象数据,构建多时空尺度融合的农田监测体系。例如,基于集成多光谱传感器的遥感探针,来实现对作物长势、土壤墒情及病虫害的多指标综合分析,进一步将景观格局(如边缘密度、非农生境比例)

与温度、降水等非生物因子结合起来,拟合昆虫种群数量等响应变量建立响应昆虫种群密度变化的高精度时空预测模型,以提升模型的稳定性与推广价值。

(2) 在方法集成上,应推动深度学习与多源遥感数据、地面观测数据、历史虫情记录的协同融合,实现农田景观精细特征的识别与建模。例如,通过多模态数据的语义融合和渐进式集成策略,提升模型对农田异构结构的解析能力,精准划分耕地边界、作物种类与种植结构分布,为景观优化与生态保护提供数据支撑。与此同时,借助知识引导的机器学习模型,可增强预测系统对复杂景观-生物交互过程的适应性与可迁移性,从而提高在多种气候与农业情境下的泛化能力。

(3) 在分子生态学方面,未来应加强分子生物学与 AI 建模的跨学科融合,利用微卫星、SNP 等分子标记手段结合深度学习算法,追踪关键昆虫种群的迁飞路径与溯源机制,揭示其空间扩散模式及演替规律。此类方法有助于建立昆虫种群动态的“生态指纹”,为实现跨区域虫害联合监测与生态治理提供理论支撑与数据基础。

(4) 在管理平台与应用层面,加强生态学、农业科学、数据科学和人工智能领域的跨学科合作,推动 AI 技术在农业生态系统中的深度应用。开发面向不同用户(如农民、科研人员、农业政策制定者)的智能化农业管理平台。平台应集成可视化决策工具、实时数据分析与模型预测功能,为农业虫情防控、景观调控及资源优化配置提供高效决策支持。同时,结合机器视觉系统在农田复杂环境中的应用潜力,未来农业机器人应具备在自然光条件下进行病虫害识别、采摘与除草等任务的能力。通过视差、纹理、颜色等多特征融合识别算法,可实现农业生产作业的自主化、精细化与高效化,显著降低劳动力依赖,提升整体作业效率。

参考文献 (References)

- Aartsma Y, Cusumano A, Fernández de Bobadilla M, Rusman Q, Vosteen I, Poelman EH, 2019. Understanding insect foraging in complex habitats by comparing trophic levels: Insights from

- specialist host-parasitoid-hyperparasitoid systems. *Current Opinion Insect Science*, 32: 54–60.
- Alexandridis N, Marion G, Chaplin-Kramer R, Dainese M, Ekroos J, Grab H, Jonsson M, Karp DS, Meyer C, O'Rourke ME, Pontarp M, Poveda K, Seppelt R, Smith HG, Martin EA, Clough Y, 2021. Models of natural pest control: Towards predictions across agricultural landscapes. *Biology Control*, 163: 104761.
- Camps-Valls G, Fernández-Torres MÁ, Cohrs KH, Höhl A, Castelletti A, Pacal A, Robin C, Martinuzzi F, Papoutsis I, Prapas I, Pérez-Aracil J, Weigel K, Gonzalez-Calabuig M, Reichstein M, Rabel M, Giuliani M, Mahecha MD, Popescu OI, Pellicer-Valero OJ, Ouala S, Salcedo-Sanz S, Sippel S, Kondylatos S, Happé T, Williams T, 2025. Artificial intelligence for modeling and understanding extreme weather and climate events. *Nature Communications*, 16(1): 1919.
- Chakrabarty S, Shashank PR, Deb CK, Haque MA, Thakur P, Kamil D, Marwaha S, Dhillion MK, 2024. Deep learning-based accurate detection of insects and damage in cruciferous crops using YOLOv5. *Smart Agricultural Technology*, 9: 100663.
- Chen F, Gu JT, Li YL, Peng XX, Han TJ, 2020. Recognition method of corn pests in northeast cold region based on machine vision and convolutional neural network. *Jiangsu Agricultural Science*, 48(18): 237–244. [陈峰, 谷俊涛, 李玉磊, 彭晓溪, 韩天甲, 2020. 基于机器视觉和卷积神经网络的东北寒地玉米害虫识别方法. *江苏农业科学*, 48(18): 237–244.]
- Cláudia TA, José R, Raul M, Sousa Joaquim J, António C, 2023. A systematic review on automatic insect detection using deep learning. *Agriculture*, 13(3): 713.
- Delfani P, Thuraga V, Banerjee B, Chawade A, 2024. Integrative approaches in modern agriculture: IoT, ML and AI for disease forecasting amidst climate change. *Precision Agriculture*, 25(5): 2589–2613.
- Duarte A, Borralho N, Cabral P, Caetano M, 2022. Recent advances in forest insect pests and diseases monitoring using UAV-based data: A systematic review. *Forests*, 13(6): 911.
- Ebrahimi MA, Khoshtaghaza MH, Minaei S, Jamshidi B, 2017. Vision-based pest detection based on SVM classification method. *Computers and Electronics in Agriculture*, 137: 52–58.
- Ge F, 2001. The principles, methods and practices of regional ecological regulation and management of pests. *Entomological Knowledge*, 38(5): 337–341. [戈峰, 2001. 害虫区域性生态调控的理论、方法及实践. *昆虫知识*, 38(5): 337–341.]
- Ge F, Ouyang F, Men XY, 2017. Ecological effects of regional agricultural landscape on insect and its prospect. *Bulletin of Chinese Academy of Sciences*, 32(8): 830–835. [戈峰, 欧阳芳, 门兴元, 2017. 区域性农田景观对昆虫的生态学效应与展望. *中国科学院院刊*, 32(8): 830–835.]
- Ge F, Ouyang F, Zhao ZH, 2014. Ecological management of insects based on ecological services at landscape scale. *Chinese Journal of Applied Entomology*, 51(3): 597–605. [戈峰, 欧阳芳, 赵紫华, 2014. 基于服务功能的昆虫生态调控理论. *应用昆虫学报*, 51(3): 597–605.]
- González-Chang M, Tiwari S, Sharma S, Wratten SD, 2019. Habitat management for pest management: Limitations and prospects. *Annals of the Entomological Society of America*, 112(4): 302–317.
- Gryshova I, Balian A, Antonik I, Miniailo V, Nehodenko V, Nyzhnychenko Y, 2024. Artificial intelligence in climate smart in agricultural: Toward a sustainable farming future. *Access-Access to Science, Business, Innovation in the Digital Economy*, 5(1): 125–140.
- Haarika R, Babu T, Nair RR, 2023. Insect classification framework based on a novel fusion of high-level and shallow features. *Procedia Computer Science*, 218: 338–347.
- He BK, Zhu WQ, Shi PJ, Zhang H, Liu RY, Yang XY, Zhao CL, 2024. A fine-scale remote sensing estimation method for fractional vegetation cover in complex terrain areas: A case study in the Qinghai-Tibet Plateau mountainous regions. *Acta Ecologica Sinica*, 44(20): 9039–9052. [何邦科, 朱文泉, 史培军, 张慧, 刘若杨, 杨欣怡, 赵涔良, 2024. 复杂地形区植被覆盖度遥感精细估算方法——以青藏高原山地区为例. *生态学报*, 44(20): 9039–9052.]
- Holland JM, Jeanneret P, Moonen AC, van der Werf W, Rossing WAH, Antichi D, Entling MH, Giffard B, Helsen H, Szalai M, Rega C, Gibert C, Veromann E, 2020. Approaches to identify the value of seminatural habitats for conservation biological control. *Insects*, 11(3): 195.
- Hu C, Kong SY, Wang R, Long T, Fu XW, 2018. Identification of migratory insects from their physical features using a decision-tree support vector machine and its application to radar entomology. *Scientific Reports*, 8(1): 5449.
- Kamilaris A, Prenafeta-Boldú FX, 2018. Deep learning in agriculture: A survey. *Computer Electronics in Agriculture*, 147: 70–90.
- Kariyanna B, Sowjanya M, 2024. Unravelling the use of artificial intelligence in management of insect pests. *Smart Agricultural Technology*, 8: 100517.
- Khanna M, Atallah SS, Heckelet T, Wu LH, Storm H, 2024. Economics of the adoption of artificial intelligence-based digital technologies in agriculture. *Annual Review of Resource*

- Economics*, 16: 41–61.
- Lary DJ, Alavi AH, Gandomi AH, Walker AL, 2016. Machine learning in geosciences and remote sensing. *Geoscience Frontiers*, 7(1): 3–10.
- Li ML, 2020. Effect of landscape pattern on adult abundance of three maize insect pests in north China. Master dissertation. Changchun: Jilin Agricultural University. [李民龙, 2020. 华北农田景观对三种玉米害虫成虫密度的影响. 硕士学位论文. 长春: 吉林农业大学.]
- Li W, Zhu TF, Li XY, Dong JZ, Liu J, 2022. Recommending advanced deep learning models for efficient insect pest detection. *Agriculture*, 12(7): 1065.
- Lu ZZ, Baker G, 2013. Spatial and temporal dynamics of *Helicoverpa armigera* (Lepidoptera, Noctuidae) in contrasting agricultural landscapes in northwestern China. *International Journal of Pest Management*, 59(1): 25–34.
- Men XY, Ge F, Yardim EN, Parajulee MN, 2004. Evaluation of winter wheat as a potential relay crop for enhancing biological control of cotton aphid in seedling cotton. *BioControl*, 49(6): 701–714.
- Mitchell MG, Hartley E, Tsuruda M, Gonzalez A, Bennett EM, 2022. Contrasting responses of soybean aphids, primary parasitoids, and hyperparasitoids to forest fragments and agricultural landscape structure. *Agriculture, Ecosystems and Environment*, 326: 107752.
- Mohanty SP, Hughes DP, Salathé M, 2016. Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7: 1419.
- Nan YP, 2022. Study on the diagnosis and early warning of diseased plants with artificial intelligence technology. Master dissertation. Handan: Hebei University of Engineering. [南亚平, 2022. 基于人工智能技术的农作物病虫害诊断及预警机制研究. 硕士学位论文. 邯郸: 河北工程大学.]
- Ouyang F, Ge F, 2011. Effects of agricultural landscape patterns on insects. *Chinese Journal of Applied Entomology*, 48(5): 1177–1183. [欧阳芳, 戈峰, 2011 农田景观格局变化对昆虫的生态学效应. 应用昆虫学报, 48(5): 1177–1183.]
- Ouyang F, Su WW, Zhang YS, Liu XH, Su JW, Zhang QQ, Men XY, Ju Q, Ge F, 2020. Ecological control service of the predatory natural enemy and its maintaining mechanism in rotation-intercropping ecosystem via wheat-maize-cotton. *Agriculture, Ecosystems and Environment*, 301: 107024.
- Ouyang F, Zhao ZH, Ge F, 2013. Insect ecological services. *Chinese Journal of Applied Entomology*, 50(2): 305–310. [欧阳芳, 赵紫华, 戈峰, 2013. 昆虫的生态服务功能. 应用昆虫学报, 50(2): 305–310.]
- Paul B, Paul M, Rub A, 2024. Advancements in AI-based pest and disease detection in agriculture: A comprehensive review of image recognition and disease modelling. <http://dx.doi.org/10.2139/ssrn.4843850>.
- Pawson SM, Marcot BG, Woodberry OG, 2017. Predicting forest insect flight activity: A Bayesian network approach. *PLoS ONE*, 12(9): e0183464.
- Pandey DK, Mishra R, 2024. Towards sustainable agriculture: Harnessing AI for global food security. *Artificial Intelligence in Agriculture*, 12: 72–84.
- Popescu D, Dinca A, Ichim L, Angelescu N, 2023. New trends in detection of harmful insects and pests in modern agriculture using artificial neural networks. *Frontiers in Plant Science*, 14: 1268167.
- Rani RU, Amsini P, 2016. Pest identification in leaf images using SVM classifier. *International Journal of Computational Intelligence and Informatics*, 6(1): 248–260.
- Rouabah A, Meiss H, Villerd J, Lasserre-Joulin F, Tosser V, Chabert A, Therond O, 2022. Predicting the abundances of aphids and their natural enemies in cereal crops: Machine-learning versus linear models. *Biological Control*, 169: 104866.
- Schellhorn NA, Bianchi FA, Hsu CL, 2014. Movement of entomophagous arthropods in agricultural landscapes: Links to pest suppression. *Annual Review of Entomology*, 59: 559–581.
- Schellhorn NA, Gagic V, Bommarco R, 2015. Time will tell: Resource continuity bolsters ecosystem services. *Trends in Ecology and Evolution*, 30(9): 524–530.
- Scowen M, Athanasiadis IN, Bullock JM, Eigenbrod F, Willcock S, 2021. The current and future uses of machine learning in ecosystem service research. *Science of the Total Environment*, 799: 149263.
- Selvaraj MG, Vergara A, Ruiz H, Safari N, Elayabalan S, Ocimati W, Blomme G, 2019. AI-powered banana diseases and pest detection. *Plant Methods*, 15(1): 92.
- Shen YY, Zhang JC, Shen D, Tian YY, Huang WJ, Yang XD, 2023. Research progress on habitat suitability assessment of crop diseases and pests by multi-source remote sensing information. *Chinese Journal of Eco-Agriculture*, 31(7): 1012–1025. [沈艳艳, 张竞成, 沈栋, 田洋洋, 黄文江, 杨小冬, 2023. 基于多源遥感信息的作物病虫害生境评价研究进展. 中国生态农业学报, 31(7): 1012–1025.]
- Tsafack N, Alignier A, Head GP, Kim JH, Goulard M, Menozzi P, Ouin A, 2016. Landscape effects on the abundance and larval diet of the polyphagous pest *Helicoverpa armigera* in cotton

- fields in North Benin. *Pest Management Science*, 72(8): 1613–1626.
- Turkoglu M, Hanbay D, Sengur A, 2022. Multi-model LSTM-based convolutional neural networks for detection of apple diseases and pests. *Journal of Ambient Intelligence and Humanized Computing*, 13(7): 3335–3345.
- Villa F, Ceroni M, Bagstad K, Johnson G, Krivov S, 2009. ARIES (Artificial Intelligence for Ecosystem Services): A new tool for ecosystem services assessment, planning, and valuation. In Proceedings of the 11th Annual BIOECON Conference on Economic Instruments to Enhance the Conservation and Sustainable Use of Biodiversity. Venice, Italy: 1–10.
- Wang DS, Cao WJ, Zhang F, Li ZL, Xu S, Wu XY, 2022. A review of deep learning in multiscale agricultural sensing. *Remote Sensing*, 14(3): 559.
- Wang TW, 2022. Research on recognition of orchard diseases and pests based on deep learning. Master dissertation. Qingdao: Qingdao Agricultural University. [王铁伟, 2022. 基于深度学习的果园病虫害识别研究. 硕士学位论文. 青岛: 青岛农业大学.]
- Xiao QX, 2019. Prediction of cotton pests and diseases based on long short-term memory network. Master dissertation. Hefei: Anhui University. [肖晴欣, 2019. 基于长短时记忆网络的棉花病虫害发生预测研究. 硕士学位论文. 合肥: 安徽大学.]
- Yang L, 2016. Effects of landscape pattern on enemy abundance and its control of wheat aphids in northern China. Master dissertation. Beijing: Chinese Academy of Agricultural Sciences. [杨龙, 2016. 农田景观格局对华北地区小麦蚜虫天敌发生与控害的影响. 硕士学位论文. 北京: 中国农业科学院.]
- Yang L, 2020. Effects of cropland use changes on population abundance of *Helicoverpa armigera* (Hübner): A landscape perspective. Doctor dissertation. Beijing: Chinese Academy of Agricultural Sciences. [杨龙, 2020. 景观尺度下作物种植结构调整对棉铃虫种群发生的影响. 博士学位论文. 北京: 中国农业科学院.]
- Zhang B, Zhang MH, Chen YZ, 2019. Crop pest identification based on spatial pyramid pooling and deep convolution neural network. *Transactions of the Chinese Society of Agricultural Engineering*, 35(19): 209–215. [张博, 张苗辉, 陈运忠, 2019. 基于空间金字塔池化和深度卷积神经网络的作物害虫识别. 农业工程学报, 35(19): 209–215.]
- Zhao ZH, Carey JR, Li ZH, 2024. The global epidemic of *Bactrocera* pests: Mixed-species invasions and risk assessment. *Annual Review of Entomology*, 69: 219–237.
- Zhao ZH, Hui C, Hardev S, Ouyang F, Dong ZK, Ge F, 2014. Responses of cereal aphids and their parasitic wasps to landscape complexity. *Journal of Economic Entomology*, 107(2): 630–637.
- Zhao ZH, Hui C, He DH, Ge F, 2013a. Effects of position within wheat field and adjacent habitats on the density and diversity of cereal aphids and their natural enemies. *BioControl*, 58(6): 765–776.
- Zhao ZH, Ouyang F, Men XY, Liu JH, He DH, Ge F, 2013b. Habitat management in biological control. *Chinese Journal of Applied Entomology*, 50(4): 879–889. [赵紫华, 欧阳芳, 门兴元, 刘军和, 贺达汉, 戈峰, 2013b. 生境管理——保护性生物防治的发展方向. 应用昆虫学报, 50(4): 879–889.]
- Zhong Y, Zhao M, 2020. Research on deep learning in apple leaf disease recognition. *Computers and Electronics in Agriculture*, 168: 105146.
- Ziesche TM, Ordon F, Schliephake E, Will T, 2024. Long-term data in agricultural landscapes indicate that insect decline promotes pests well adapted to environmental changes. *Journal of Pest Science*, 97(3): 1281–1297.