arXiv:2601.00243v1 [cs.CV] 1 Jan 2026

面向精准农业的情境感知农药推荐：基于小样本害虫识别

Anirudha Ghosh[1], Ritam Sarkar[2], 和 Debaditya Barman[1], *

[1] 印度圣蒂尼克坦 Visva-Bharati 计算机与系统科学系[2] 印度库奇贝哈尔北孟加拉农业大学技术学院

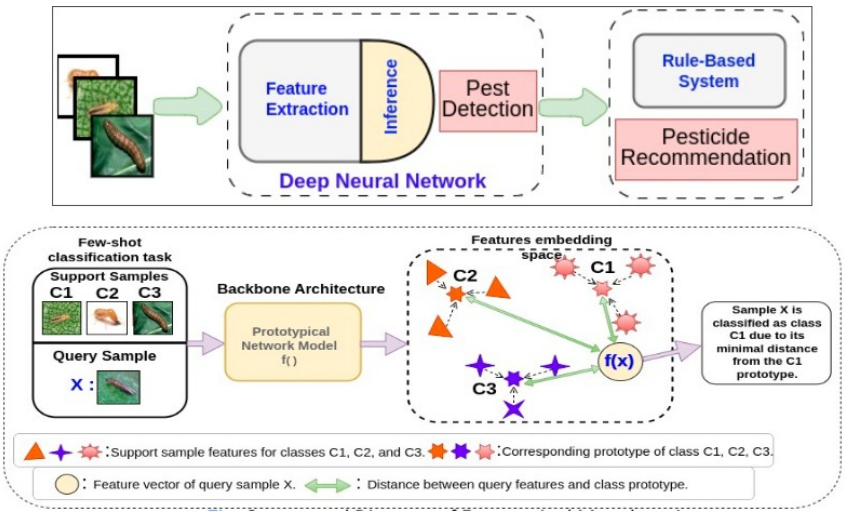

图 1：所提出框架的概览。该框架将用于小样本害虫检测的轻量级原型网络与基于规则的决策支持系统相结合（将害虫检测结果与环境因素整合），以推荐情境感知型农药。

摘要。 有效的害虫管理对于提高农业生产力至关重要，尤其是甘蔗和小麦等极易遭受害虫侵袭的作物。传统的害虫管理方法高度依赖人工田间检查和化学农药的使用。这些方法通常成本高、耗时长、劳动强度大，并且可能对环境产生负面影响。为应对这些挑战，本研究提出了一种轻量级的害虫检测与农药推荐框架，专为智能手机和无人机等低资源设备设计，适合小农户和边际农户使用。

* 通讯作者。电子邮箱：debaditya.barman@visva-bharati.ac.in

所提出的框架包括两个主要组成部分。第一部分是害虫检测模块，该模块采用紧凑、轻量级的卷积神经网络（CNN），结合原型元学习，即使只有少量训练样本，也能准确识别害虫。第二部分是农药推荐模块，该模块纳入作物类型和生长阶段等环境因素，以推荐安全、环保的农药。为训练和评估该框架，我们通过整合多个公开可用的数据集，构建了一个全面的害虫图像数据集。最终数据集包含具有不同视角、害虫尺寸和背景条件的样本，从而确保良好的泛化能力。

实验结果表明，所提出的轻量级卷积神经网络在显著降低计算复杂度的同时，取得了较高的准确率，性能与当前最先进的模型相当。该决策支持系统还通过减少对传统化学农药的依赖并鼓励可持续实践，进一步改善了害虫管理，展现出其在精准农业实时应用中的潜力。

关键词： 害虫检测 · 农药推荐 · 深度学习 · 害虫管理 · 原型元学习 · 少样本分类 · 边缘计算 · 可持续农业 · 精准农业。

1 引言

害虫会破坏作物并造成重大经济损失。由于甘蔗 [18]和小麦 [16]种植范围广、经济意义重大，因此尤其容易受到影响。甘蔗象甲、白蚁和切叶蚁侵袭甘蔗，小麦锈病和地老虎侵害小麦，这些害虫侵袭可能会大幅降低产量。这些损失不仅会影响农民，还会扰乱供应链，并威胁全球数百万人的粮食供应。因此，有效的害虫管理对于维持农业生产力、保障全球粮食安全 [14]至关重要。

传统的害虫管理实践虽然在一定程度上足够有效，但仍面临多重挑战。通过人工评估进行害虫检测需要投入大量时间和熟练劳动力，因此不适用于大规模农业生产。此外，尽管过度依赖化学农药能迅速见效，却造成了长期的健康与环境损害 [4]。这些影响包括水污染、土壤退化 [6], 害虫与农药拮抗以及生物多样性丧失 [10]。因此，需要高效、可持续且可扩展的害虫管理解决方案，以应对这些日益严峻的挑战。

为克服上述挑战，本研究致力于开发一种轻量级框架，专门用于甘蔗和小麦作物的害虫检测与农药推荐。该框架采用原型元学习[19]结合少样本学习 [13] 策略，即使数据有限（训练样本较少），也能有效运行。该策略可快速

调整模型以适应不同的害虫类型，同时保持较高的准确率。此外，结合决策支持系统可实现情境感知农药推荐，促进环保实践并减少化学品使用。

本研究的主要贡献包括：构建了涵盖甘蔗和小麦的综合性害虫数据集，开发了稳健、轻量级的害虫检测深度神经网络，以及构建了基于规则的农药推荐系统。该框架注重实用性，可兼容无人机、智能手机等资源有限的边缘设备，使农民能够借助实时害虫管理工具。本研究凸显了将机器学习技术与可持续农业技术相结合，以应对严峻害虫管理挑战的潜力。

2 相关工作

传统害虫管理策略依赖人工检查和化学农药施用。尽管这些方法在某些情况下有效，但耗时费力，也不适用于大规模农业作业。过度依赖化学农药已导致环境退化、农药抗性以及健康风险 [4, 6]。深度学习的最新进展彻底改变了害虫分类，为应对这些挑战提供了精准且可扩展的解决方案，助力精准农业发展。

卷积神经网络（卷积神经网络）已成为解决害虫检测与分类问题的主流方法。[9], 中的研究开发了一种基于全局与局部特征的混合害虫监测系统，在多类别害虫检测中取得了较高准确率。同样，[11],中的研究将 AlexNet 和 DenseNet201 等卷积神经网络模型与基于显著性的方法相结合，对害虫图像进行分类，并报告称其在较小数据集上的准确率为 92.43%，在 IP102数据集上的准确率为 61.93%。[7] 开展的研究采用区域建议网络（RPNs）和数据增强策略进行害虫定位，平均精度均值（mAP）达到 83.23%。[15], 中的作者提出了一种基于 YOLOv4 的细粒度检测模型，平均精度均值（mAP）达到 96.29%，展示了基于卷积神经网络的方法在农业害虫检测中的稳健性。

近年来，研究人员提出了轻量级卷积神经网络，以应对在无人机和智能手机等资源受限设备上部署模型时面临的计算约束。例如，[17] 通过动态学习率和适当的数据增强对MobileNetV2进行了优化，在IP102数据集上取得了71.32%的准确率。[21], 开展的研究使用DenseNet169结合迁移学习，在番茄害虫分类任务中达到了88.83%的准确率。这些轻量级模型显著降低了计算开销，使其适用于实时应用。然而，它们对大型数据集的依赖限制了其在数据采集稀少且环境无结构的害虫上的泛化能力。

少样本学习（FSL）近年来已成为解决训练数据稀缺问题的一种方案。少样本学习使模型能够利用有限的标注数据泛化到未知类别。在 [2], 的研究中，作者通过采用微调技术，证明模型在单样本场景下的准确率有所提升——

度。在综述 [20], 中，作者将 MobileNet 等轻量级架构用于小样本害虫检测，取得了显著的性能提升。[12] 的研究探讨了用于少样本害虫分类的度量学习策略，并在多个真实场景中检测棉花害虫，取得了良好效果。

尽管害虫检测取得了进展，但将害虫检测系统与可执行的农药建议相结合仍有待研究。 [8] 的研究展示了利用 ResNet152 进行多类别害虫检测，但缺少具有情境感知能力的农药建议。同样， [12] 利用 Faster R-CNN 获得了较高的检测准确率，但仍需集成决策支持系统。本研究提出了一种与决策支持系统（DSS）集成的轻量级卷积神经网络，以解决这些不足。

3 方法

3.1 框架概述

我们提出的框架由两个主要模块构成，旨在实现甘蔗和小麦作物的高效实时害虫管理:

– **害虫检测模块：** 该模块采用轻量级卷积神经网络（CNN），用于实时害虫检测。模型分析从田间采集的图像，并利用原型元学习与小样本策略，以最少的数据将害虫准确分类到预定义类别中。这种轻量化设计确保其兼容智能手机和无人机等资源受限设备，从而能够随时随地识别害虫。

– **农药推荐模块：** 基于规则的决策支持系统（DSS）通过将害虫分类结果与作物类型、生长阶段和害虫严重程度等环境因素相结合，为害虫检测模块提供补充。DSS 使用知识映射表推荐适用的农药，同时强调环保和减少化学品使用的操作流程。这种集成确保了具备情境感知能力的可持续害虫管理解决方案。

3.2 数据集创建

甘蔗和小麦害虫数据集采用结构化流程构建，以确保数据均衡且质量可靠；每种害虫类别均从免版权资源库中收集了 30 个样本。甘蔗害虫图像包括甘蔗象甲、切叶蚁、红棕象甲、甘蔗绵蚜和白蚁；小麦害虫图像包括地老虎、小麦茎蜂、白蚁、小麦蓟马和小麦叶锈病。预处理包括将图像调整为 100×100 像素，并确保所有样本的质量和一致性。研究团队对数据集进行了人工处理，以剔除无关样本并保证质量。最终数据集按作物和害虫类别进行层级组织，共包含 300

张图像，每个类别 30 个样本，确保数据具有足够的多样性，并可用于通过轻量级卷积神经网络进行测试。

3.3 模型架构

害虫检测模块采用针对边缘设备优化的轻量级卷积神经网络架构，并利用原型元学习，使模型能够在小样本场景下以最少的数据有效识别害虫。这种设计确保了其与资源受限环境的兼容性。

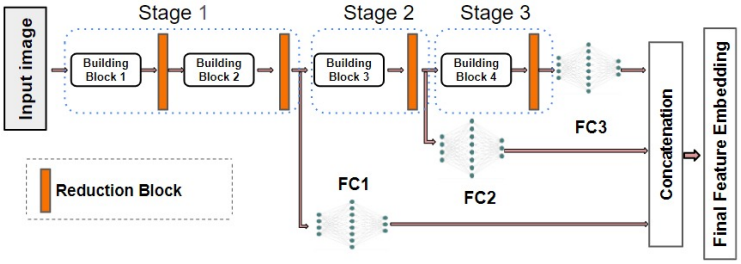

图2：所提出的轻量级原型网络骨干架构。

图2所示的轻量级原型网络骨干（LPN-Backbone）架构，相较于 ResNet18 和 DenseNet169，大幅减少了可学习参数。ResNet18 和 DenseNet169 分别约有 1200 万和 1400 万个参数，而 LPN 约有 1000 万个参数。LPN 分为三个阶段，以分层提取特征。该网络由四个特征提取构建块（FEBB）和四个降维块（RB）组成。第一阶段包含两个 FEBB，每个后接一个 RB；第二和第三阶段则各包含一个 FEBB 和一个 RB。每个阶段结束时，一个包含三个密集连接层的全连接模块（FC）会将提取的特征整合为最终的特征嵌入。

图3所示的每个 FEBB 由三个定向学习块（TLB）组成，并通过残差连接将第二个定向学习块的输入连接到第三个定向学习块的输出，从而解决梯度消失问题并提高稳定性。

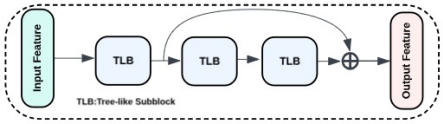

图3：FEBB 的架构

用于训练。每个 FEBB 之后，RB 使用结合批归一化（BN）和 ReLU 激活的 (3Œ3) 卷积层来降低特征维度。

每个 FEBB 的核心是 TLB，它通过三个独立分支提取多样化特征，每个分支都采用独特的卷积操作：

– **分支 A：** 使用 (3×3) 深度可分离卷积提取空间特征，随后通过 (1×1) 卷积融合跨通道信息。对输出应用批归一化（BN）和 ReLU 激活，以确保输出一致。– **分支 B：** 受 ResNet 启发，该分支首先使用 (1×1) 卷积减小输入尺寸，随后使用 (3×3) 分组卷积聚焦于关键特征。通过残差连接将输入加回输出，以确保特征得到保留。应用 BN 和 ReLU 激活，生成形状一致的最终特征。– **分支 C：** 结合 (1×1) 逐点卷积以简化通道维度，并使用 (3×3) 空洞卷积覆盖更大的输入区域。该设计无需额外计算即可捕获更多上下文信息。应用 BN 和 ReLU 激活，以保持稳定的输出。

3.4 决策支持系统（DSS）

DSS 将害虫检测结果以及环境和特定生长阶段因素作为输入，为甘蔗和小麦推荐农药解决方案。它依靠基于规则的知识将害虫类型映射到最佳农药选择，如表 1 和表 2 所示。如这些表中所详述，DSS 的建议会明确每种害虫适用的农药类型、其对应的作物，以及环境和生长阶段条件。然而，表中未明确列出剂量和施用时间，必须根据具体的虫害严重程度和当地指南确定。

表 1：甘蔗害虫知识库

Pest	**生长阶段**	**环境条件**	**推荐农药的**
砍伐象鼻虫（*Apion*属）	早期生长	高湿度	Mild 杀虫剂（例如，毒死蜱）
切叶象甲 Ants（*Atta*属）	营养生长期	温暖干燥	基于诱饵的农药（例如，Hydram-乙基壬烯）
Red Palm 象鼻虫（*Rhynchophorus ferrugineus*）	任何阶段	高湿度	基于信息素的诱饵和诱捕器
甘蔗绒毛状蚜虫（*Siphunculus*属）	营养生长期	适中温度，高湿度	自然捕食者（瓢虫甲虫) or 吡虫啉
白蚁（各种物种）	任何阶段	土壤干燥条件	土壤处理（例如，氟虫腈）

表 2：影响小麦的害虫知识库

Pest	**生长阶段**	**环境条件**	**农药推荐-建议**
地老虎 (夜蛾属 夜蛾属)	早期生长	凉爽、湿润	生物 害虫防治剂 cide (例如, 苏云金芽孢杆菌 苏云金芽孢杆菌)
小麦茎蜂 （小麦茎蜂）	营养生长期	Dry	信息素诱捕器或低毒杀虫剂
小麦 蓟马 (烟蓟马)	营养生长期	温暖干燥	黏性 板 or 高效氯氟氰菊酯
小麦 Leaf Rust (小麦叶锈菌)	营养生长期	高湿度	(例如, 杀菌剂 丙环唑）
白蚁 （各种物种）	任何阶段	土壤干燥条件	土壤施用杀虫剂 (例如, 剂 氯-吡啶）

4 实验设置

4.1 训练

训练数据集 我们的框架采用原型元学习进行少样本分类，这要求通过包含迷你任务的大规模训练集合来有效模拟多种场景。为满足这一要求，我们结合了来自 Kaggle 的三个公开数据集，构建了一个全面的训练数据集。第一个数据集“危险农场昆虫数据集” [1]，包含 15 种农业环境中常见有害昆虫的图像。第二个数据集“农业害虫图像数据集” [5], 包含 12 个害虫类别：蚂蚁、蜜蜂、甲虫、毛虫和象鼻虫。最后，作物害虫数据集 [3]包含四种害虫类型的图像：水稻螟虫、稻绿叶蝉、稻蝽和稻纵卷叶螟。这些多样化的图像集合能够创建不同的训练任务，为采用少样本学习策略进行模型学习和泛化奠定基础。

预处理与数据增强 预处理与数据增强流程包括将图像调整为 100Œ100 像素，应用随机颜色抖动（亮度、对比度、饱和度和色调），并执行随机缩放幅度最高达 15% 的仿射变换。随后，我们以 50% 的概率分别进行随机水平翻转和垂直翻转，最后执行三通道灰度转换，并使用 ImageNet 统计数据进行归一化。

训练流程 训练过程包括使用前文所述的训练数据集，对两个基础网络 ResNet18 和 DenseNet169 以及所提出的 LPN 进行元训练。模型经过了 200 个元训练任务（回合），每个回合包含若干独立的迷你任务。每个迷你任务训练 40 个训练轮次，以完成元训练阶段。在

训练过程中采用 k 路 n 样本协议，其中 k（类别数量）和 n（每个类别的支持样本数量）分别在 5 到 10 之间、1 到 15 之间随机选取。Adam 优化器用于最小化训练损失，所有网络的学习率（LR）均设为 0.002。为使所有模型正则化并防止过拟合，采用了 30% 的丢弃率。这种训练策略增强了模型有效泛化到新的、未见过的任务的能力。

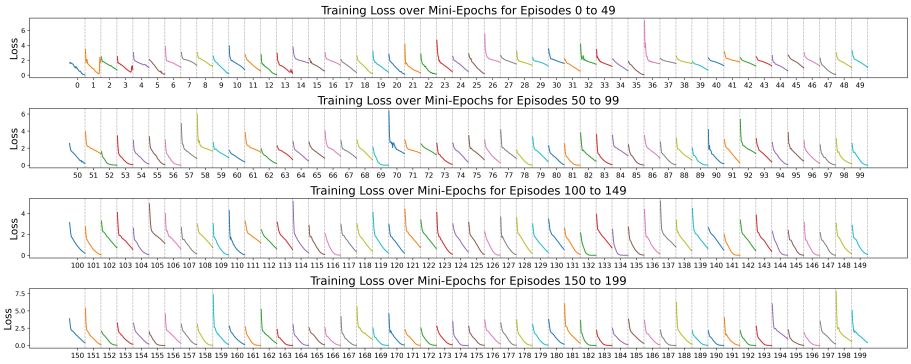

图 4：ResNet18 的训练损失。

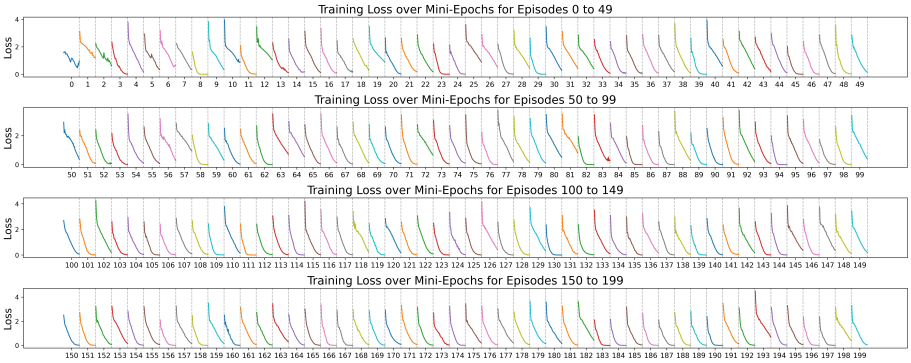

图 5：DensNet169 的训练损失。

图 4 展示了 ResNet18 的训练损失，而图 5 展示了 DenseNet169 的训练损失。同样，图 6 描绘了所提出的 LPN 模型的训练损失，突出了其在元训练阶段的收敛行为。

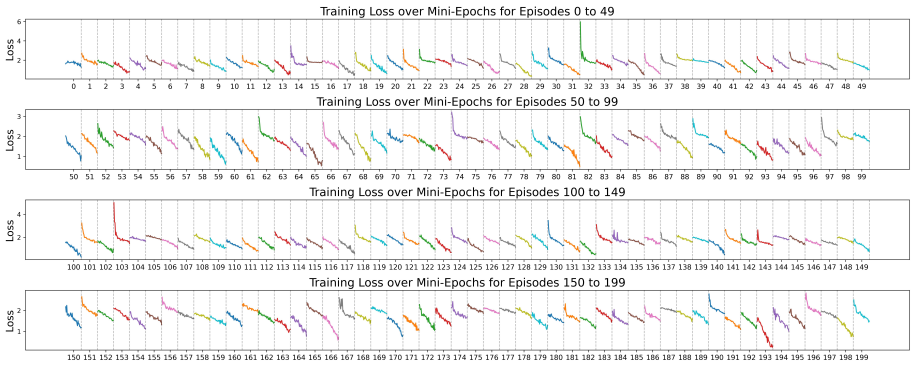

图6：我们提出的 LPN 的训练损失。

测试流程 甘蔗和小麦测试数据集的测试流程均采用小样本策略，每个数据集都包含五个类别。测试采用 5-way 单样本、三样本和 5样本设置。在单样本设置中，每个类别随机选取一张支持图像。三样本设置在单样本支持图像的基础上，为每个类别再加入两张随机图像。同样，5样本设置在三样本设置的基础上，为每个类别再增加两张随机支持图像。

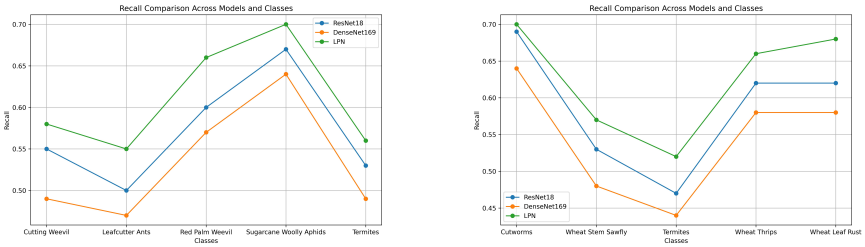

（a）甘蔗中害虫检测在 1样本、三样本和 5样本样本配置下的召回率图；（b）小麦中害虫检测在 1样本、三样本和 5样本样本配置下的召回率图

图7：甘蔗和小麦中不同样本配置下害虫检测的召回率和精确率比较。

5 结果与讨论

5.1 性能指标

采用小麦和甘蔗害虫的单样本、三样本和 5样本配置，对所有模型的害虫检测性能进行了评估。表3和表4所列结果表明，与基线模型（ResNet18 和 DenseNet169）相比，我们提出的 LPN 模型表现最为出色。表中每个数据点均根据十次独立测试任务的结果得出。对于小麦害虫（表3），LPN 在所有配置下的表现均始终优于基线模型。在单样本设置中，LPN 对地老虎的准确率达到 72.00%，对小麦叶锈病的准确率达到 69.71%，显著高于 ResNet18 和 DenseNet169。在 5样本配置下，LPN 的性能进一步提升，展现出有效利用额外支持图像的能力。

同样，LPN 模型在甘蔗害虫检测中表现出更优的性能（表4）。在三样本配置下，其对甘蔗象甲的准确率达到 69.44%，对甘蔗绵蚜的准确率达到 77.62%，优于 ResNet18 和 DenseNet169。在 5样本设置下，LPN 模型继续保持领先，对红棕象鼻虫的准确率为 74.81%，对白蚁的准确率为 68.43%。

此外，甘蔗害虫的害虫检测召回率图（图7a）和小麦害虫的召回率图（图7b）进一步验证了我们模型的有效性，表明在各种样本数设置下，召回率均得到持续提升。这些结果凸显了 LPN 模型的稳健性和适应性，尤其是在少样本学习场景中。

表3：甘蔗害虫检测的性能指标（准确率 %）

模型	少样本配置—率	砍伐象鼻虫—vil	切叶象甲 Ants	Red Palm 象鼻虫	甘蔗绵蚜 绵蚜	白蚁
ResNet18	单样本	55.11 ś 0.05	50.21 ś 0.03	61.23 ś 0.04	67.48 ś 0.03	53.21 ś 0.07
	三样本	60.23 ś 0.06	55.37 ś 0.04	66.01 ś 0.05	71.15 ś 0.04	58.47 ś 0.06
	5样本	64.78 ś 0.07	59.84 ś 0.05	67.54 ś 0.06	73.89 ś 0.05	61.95 ś 0.08
DenseNet169	单样本	49.92 ś 0.06	47.04 ś 0.04	58.17 ś 0.05	64.93 ś 0.04	49.92 ś 0.08
	三样本	55.12 ś 0.07	52.09 ś 0.05	62.43 ś 0.06	68.31 ś 0.05	54.35 ś 0.09
	5样本	60.87 ś 0.08	56.47 ś 0.06	66.09 ś 0.07	71.56 ś 0.06	58.74 ś 0.10
LPN	单样本	58.51 ś 0.05	55.68 ś 0.03	66.11 ś 0.04	71.21 ś 0.03	57.38 ś 0.07
	三样本	64.87 ś 0.06	61.22 ś 0.04	72.35 ś 0.05	74.97 ś 0.04	63.19 ś 0.06
	5样本	**69.44 ś 0.07**	**66.71 ś 0.05**	**74.81 ś 0.06**	**77.62 ś 0.05**	**68.43 ś 0.08**

表4：小麦害虫检测的性能指标（%准确率）

模型	样本配置-方案	地老虎	小麦茎蜂	白蚁	小麦蓟马 小麦	Leaf Rust
ResNet18	单样本	69.92 ś 0.05	54.75 ś 0.06	48.69 ś 0.04	64.16 ś 0.07	63.14 ś 0.05
	三样本	75.03 ś 0.06	58.89 ś 0.07	53.42 ś 0.05	68.72 ś 0.08	67.39 ś 0.06
	5样本	78.56 ś 0.07	63.21 ś 0.08	57.98 ś 0.06	72.93 ś 0.09	71.64 ś 0.07
DenseNet169	单样本	65.92 ś 0.05	49.76 ś 0.06	45.73 ś 0.04	60.56 ś 0.07	59.51 ś 0.05
	三样本	70.14 ś 0.06	53.88 ś 0.07	50.21 ś 0.05	64.98 ś 0.08	63.18 ś 0.06
	5样本	73.56 ś 0.07	58.14 ś 0.08	54.13 ś 0.06	69.82 ś 0.09	67.92 ś 0.07
LPN	单样本	72.00 ś 0.05	59.01 ś 0.06	53.15 ś 0.04	68.15 ś 0.07	69.71 ś 0.05
	5样本	76.58 ś 0.06	63.87 ś 0.07	57.61 ś 0.05	72.48 ś 0.08	73.23 ś 0.06
	5样本	**80.12 ś 0.07**	**68.52 ś 0.08**	**61.19 ś 0.06**	**76.98 ś 0.09**	**75.96 ś 0.07**

5.2 分析与讨论

实验结果凸显了轻量级 LPN 模型的卓越性能：它始终优于 ResNet18 和 DenseNet169，尤其是在三样本和 5样本设置下，展现出利用额外支持样本提升分类准确率的能力。配对 t 检验证实，在甘蔗和小麦害虫数据集上，这些性能提升均具有统计显著性（$p < 0.05$），从而证明了所提方法的可靠性。该模型计算需求低，非常适合部署在资源受限设备上进行实时应用。此外，集成决策支持系统（DSS）通过提供可行的农药建议进一步完善了该框架，并优先推荐环保方案，以减少化学农药使用。LPN 模型与 DSS 为精准农业提供了一种稳健、高效且可持续的解决方案。

6 结论与未来工作

本研究开发了一种轻量级模型，能够准确检测害虫，并构建了一个用于提供有针对性的农药解决方案建议的决策支持系统。该框架有效兼顾了少样本场景下的高性能与较低的计算需求，使其适用于资源有限环境中的实时应用。通过结合环境因素和作物特性，该框架有助于促进可持续的害虫管理实践。未来将致力于通过增加更多害虫种类来扩充数据集，利用物联网设备接入实时环境数据，并扩展框架以支持更多种类的作物和农业条件。

致谢

第一作者谨此感谢 DST-INSPIRE 奖学金提供的资助，该资助帮助他开展了这项研究。

参考文献

1. Dalal, T.：《危险昆虫数据集》（2023），https://www.kaggle.com/datasets/tarundalal/dangerous-insects-dataset，访问日期：2024-08-20 2. Dhillon, G.S.、Chaudhari, P.、Ravichandran, A.、Soatto, S.：少样本图像分类的基线方法。arXiv预印本 arXiv:1909.02729（2019） 3. Ghosh, P.：《作物害虫数据集》（2023），https://www.kaggle.com/datasets/pialghosh/crop-pest-dataset，访问日期：2024-08-20 4. Kandalkar, G.、Deorankar, A.、Chatur, P.：使用DWT和反向传播神经网络对农业害虫进行分类。《国际计算机科学与信息技术杂志》**5**(3)，4034–4037（2014）

5. Lanz, V.：《农业害虫图像数据集》（2023），https://www.kaggle.com/datasets/vencerlanz09/agricultural-pests-image-dataset，访问日期：2024-08-20 6. Larios, N.、Deng, H.、Zhang, W.、Sarpola, M.、Yuen, J.、Paasch, R.、Moldɔ6ke, A.、Lytle, D.A.、Correa, S.R.、Mortensen, E.N.等：通过局部外观特征的串联直方图实现自动昆虫识别：可变形物体的特征向量生成与区域检测。《机器视觉与应用》**19**，105–123（2008） 7. Li, R.、Wang, R.、Zhang, J.、Xie, C.、Liu, L.、Wang, F.、Chen, H.、Chen, T.、Hu, H.、Jia, X.等：田间基于CNN的害虫定位与识别的有效数据增强策略。IEEE Access **7**，160274–160283（2019） 8. Li, Z.、Jiang, X.、Jia, X.、Duan, X.、Wang, Y.、Mu, J.：基于深度学习的重要水稻害虫分类方法。《农学》**12**(9)，2096（2022） 9. Liu, L.、Xie, C.、Wang, R.、Yang, P.、Sudirman, S.、Zhang, J.、Li, R.、Wang, F.：基于深度学习、使用全局与局部混合激活特征的野生害虫多类别自动监测方法。IEEE《工业信息学汇刊》**17**(11)，7589–7598（2020） 10. Messelink, G.J.、Lambion, J.、Janssen, A.、van Rijn, P.C.：温室内及周边的生物多样性：对害虫管理的益处与潜在风险。《昆虫》**12**(10)，933（2021） 11. Nanni, L.、Maguolo, G.、Pancino, F.：基于仿生方法的昆虫害虫图像检测与识别。《生态信息学》**57**，101089（2020） 12. Nieuwenhuizen, A.、Hemming, J.、Suh, H.K.：使用Faster R-CNN检测和分类番茄作物粘虫板上的昆虫（2018） 13. Parnami, A.、Lee, M.：从少量示例中学习：少样本学习方法综述。arXiv预印本 arXiv:2203.04291（2022） 14. Pedigo, L.P.、Rice, M.E.、Krell, R.K.：《昆虫学与害虫管理》。Waveland Press（2021） 15. Roy, A.M.、Bose, R.、Bhaduri, J.：基于YOLOv4深度神经网络的快速、精确细粒度目标检测模型。《神经计算与应用》**34**(5)，3895–3921（2022） 16. Sehgal, M.、Jeswani, M.、Kalra, N.：印度河—恒河平原稻麦害虫、病害和线虫害虫的管理。《南亚稻麦种植制度》，第167–226页（2021） 17. Setiawan, A.、Yudistira, N.、Wihandika, R.C.：使用带有数据增强和正则化器的高效卷积神经网络进行大规模害虫分类。《计算机与电子农业》**200**，107204（2022） 18. Usman, M.、Akram, N.、Imtiaz, S.、Haider, S.M.：甘蔗：害虫引起的病害、害虫管理策略及影响甘蔗产量的因素。《美国工程、技术与科学研究杂志》（ASRJETS）**65**(1)，126–139（2020） 19. Wang, R.Q.、Zhang, X.Y.、Liu, C.L.：面向域无关少样本识别的元原型学习。IEEE《神经网络与学习系统汇刊》**33**(11)，6990–6996（2021） 20. Wang, X.、Huang, T.E.、Darrell, T.、Gonzalez, J.E.、Yu, F.：令人沮丧地简单的少样本目标检测。arXiv预印本 arXiv:2003.06957（2020） 21. Xia, D.、Chen, P.、Wang, B.、Zhang, J.、Xie, C.：基于改进卷积神经网络的昆虫检测与分类。《传感器》**18**(12)，4169（2018）