

苏闪闪, 吴建军, 李智慧, 等. 轻量级网络模型在玉米病害识别与产量预测方面的研究进展[J]. 江苏农业学报, 2025, 41(8): 1655-1664.

doi: 10.3969/j.issn.1000-4440.2025.08.022

轻量级网络模型在玉米病害识别与产量预测方面的研究进展

苏闪闪^{1,2}, 吴建军^{1,2}, 李智慧^{1,2}, 甄彤^{1,2}

(1.河南工业大学信息科学与工程学院, 河南 郑州 450001; 2.河南工业大学粮食信息处理与控制教育部重点实验室, 河南 郑州 450001)

摘要: 随着智慧农业的发展, 轻量级网络模型因其计算效率高、模型参数少等优势, 在资源受限的农业环境中显示出巨大潜力。本文从轻量级网络模型的定义、特点及主流模型的特点等方面对近年来轻量级网络模型在玉米病害识别与产量预测方面的研究进行综述, 详细分析了轻量级网络模型在玉米病害识别和产量预测中的实际应用效果, 同时指出其在实际应用中面临的挑战, 结合现有研究基础提出了针对性的解决方向, 旨在帮助研究人员快速、系统了解该领域的相关研究成果, 推动轻量级网络模型在农业领域的广泛应用, 促进智慧农业的进一步发展。

关键词: 轻量级网络模型; 玉米病害识别; 产量预测

中图分类号: TP391; S435.131 **文献标识码:** A **文章编号:** 1000-4440(2025)08-1655-10

Research progress of lightweight network models in corn disease identification and yield prediction

SU Shanshan^{1,2}, WU Jianjun^{1,2}, LI Zhihui^{1,2}, ZHEN Tong^{1,2}

(1. College of Information Science and Engineering, Henan University of Technology, Zhengzhou 450001, China; 2. Key Laboratory of Grain Information Processing and Control, Ministry of Education, Henan University of Technology, Zhengzhou 450001, China)

Abstract: With the development of smart agriculture, lightweight network models have shown great potential in resource-constrained agricultural environments due to their advantages such as high computational efficiency and few model parameters. This paper reviews the research on lightweight network models in corn disease identification and yield prediction in recent years, covering aspects such as the definition and characteristics of lightweight network models and features of mainstream models. It analyzes in detail the practical application effects of lightweight network models in corn disease identification and yield prediction, and points out the challenges in their implementation. Based on existing research, targeted solutions are proposed. The purpose is to help researchers quickly and systematically understand the relevant research findings in this field, promote the wide application of lightweight network models in the agricultural field, and facilitate the further development of smart agriculture.

Key words: lightweight network models; corn disease identification; yield prediction

收稿日期: 2025-03-17

基金项目: 国家重点研发计划项目(2018YFD0401404)

作者简介: 苏闪闪(1999-), 女, 河南商丘人, 硕士研究生, 研究方向为农业病害识别与深度学习。(E-mail) 3087920853@qq.com

通讯作者: 吴建军, (E-mail) 13939003632@163.com

玉米作为全球重要的粮食作物之一, 其产量和品质直接影响粮食安全和农业经济。然而, 由于病害频发和气候变化加剧使得玉米产量预测和病害识别成为农业生产中的重大挑战。传统的病害识别方法依赖人工视觉检查和实验室检测, 效率低且成本

高,难以满足大规模种植的需求。传统的产量预测方法主要基于统计模型和遥感数据,泛化能力有限,难以应对复杂的田间环境。

近年来,随着人工智能和深度学习技术的迅猛发展,农业领域的智能化和精细化管理成为现实。深度学习技术在玉米病害识别和产量预测中展现出巨大潜力。然而,传统的深度学习网络由于模型复杂导致计算成本高,难以在资源受限的环境中广泛应用。因此,轻量级网络模型应运而生,以高效、低成本的特点逐渐成为农业智能化研究的热点。轻量级网络模型在玉米病害识别与产量预测中的应用,既能提高模型的推理速度和实时性,又能在保持较高精度的前提下,减少对硬件资源的依赖。随着移动终端与边缘计算技术的深度演进,轻量级网络模型有望成为推动农业智能化落地的核心技术引擎,为农业生产效率提升与智慧决策系统构建提供技术支撑体系。

本文旨在系统总结近年来轻量级网络模型在玉米病害识别与产量预测领域的研究进展,分析不同网络模型的特点,探讨其在实际应用中的潜力与挑战,并展望未来研究和发展的方向。

1 轻量级网络模型的概述

1.1 轻量级网络模型的定义与特点

轻量级网络模型是指通过架构设计、参数优化等手段,在保证模型性能(如识别精度)的前提下,大幅度降低模型参数量、计算量和内存占用的神经网络。轻量级神经网络以其高效性和资源友好性,广泛应用于资源受限环境中的深度学习任务。通过减少计算复杂度和模型参数,这些网络能够在嵌入式设备和移动设备上实现实时推理,适合在智慧农业领域应用,例如玉米病害识别和产量预测等。

农业场景对模型的实时性和低功耗需求尤为突出,如田间病害图像的实时处理、传感器数据的快速分析等。轻量级网络模型在这些应用中,通过引入深度可分离卷积^[1]、通道混洗(Channel shuffle)^[2]等技术显著降低了计算成本,同时保持了较高的分类和识别精度。这种特性为农业物联网设备在农业生产中的部署提供了可能性。

1.2 轻量级网络模型

1.2.1 MobileNet 系列轻量级卷积神经网络模型

MobileNet 系列模型是轻量级网络模型的代表,尤其是 MobileNetV2 模型^[3]和 MobileNetV3 模型^[4]。如图 1 所示,MobileNetV2 的倒置残差结构和线性瓶颈结构^[5]在减少计算量的同时保持了特征表达能力,这种方法适合处理高分辨率的作物叶片图像。因其高效的深度可分离卷积^[6]设计而被广泛应用于农业病害识别中。MobileNetV3 进一步结合自动架构搜索(NAS)和 SE 模块优化方法^[7],在实际农业场景下实现了更高的性能与效率,其模型架构如图 2 所示。

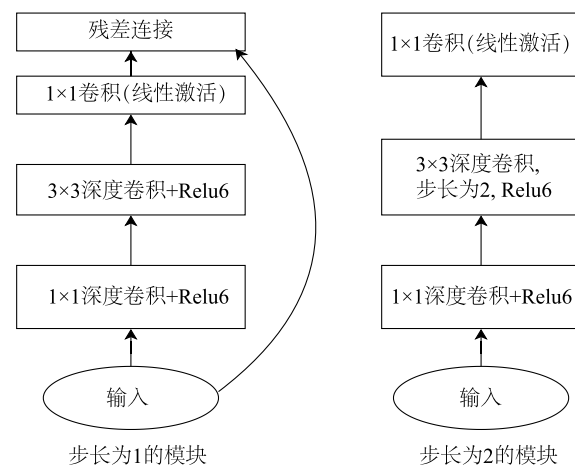


图 1 MobileNetV2 模型两种步长模块结构示意图

Fig.1 Schematic diagrams of two stride modules in MobileNetV2 model

1.2.2 EfficientNet 高效卷积神经网络模型 EfficientNet 模型^[8]在玉米病害识别与产量预测任务中表现出色。如图 3 所示,凭借其独特的复合缩放策略,在网络深度、宽度和图像分辨率之间实现了良好平衡^[9]。其系统性优化方法使得模型在提高识别精度的同时大幅度减少了计算和存储开销。特别是在病害识别中,EfficientNet 的高效特征提取能力能够更加精准地识别病害。

1.2.3 ShuffleNetV2 轻量级卷积神经网络模型

ShuffleNetV2 模型通过创新的通道混洗操作优化网络的运行效率,特别适用于移动设备上的实时推理。其设计更关注内存访问成本和平台特性,这使得该网络在农业现场设备中的运行速度得到显著提升^[10]。当涉及空间下采样操作^[11]时,对相关单元进行简单调整,移除通道分离操作符,即可让输出通

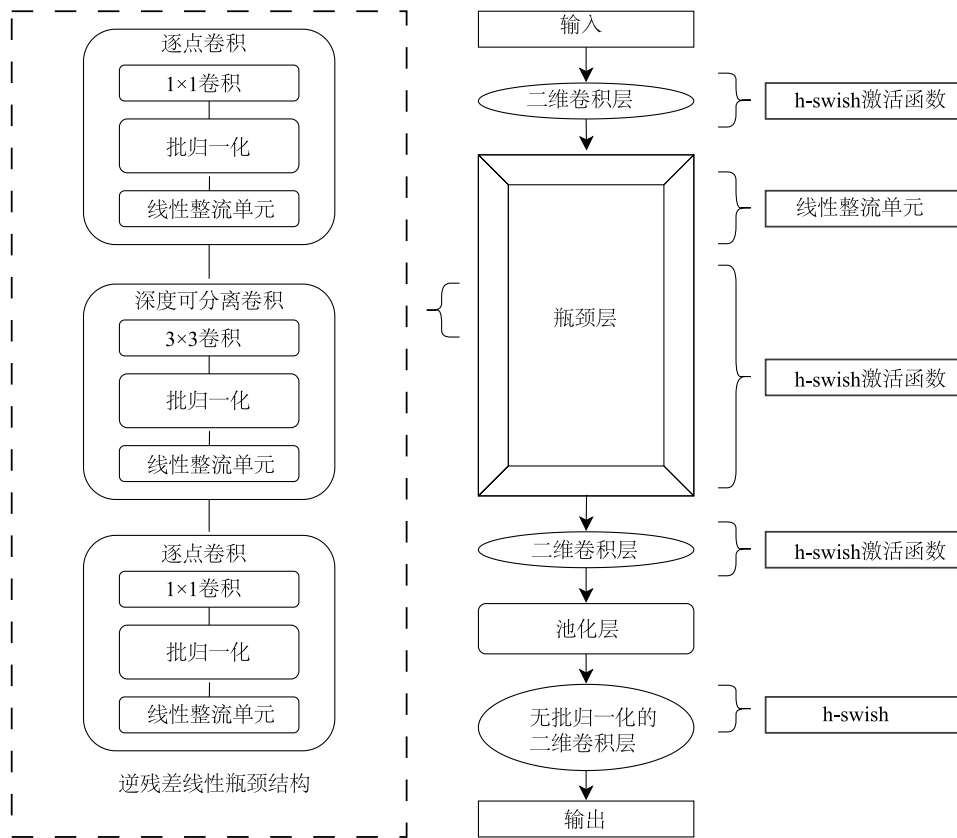


图2 MobileNetV3 模型核心模块与层结构示意图

Fig.2 Schematic diagrams of core modules and layer structures in MobileNetV3 model

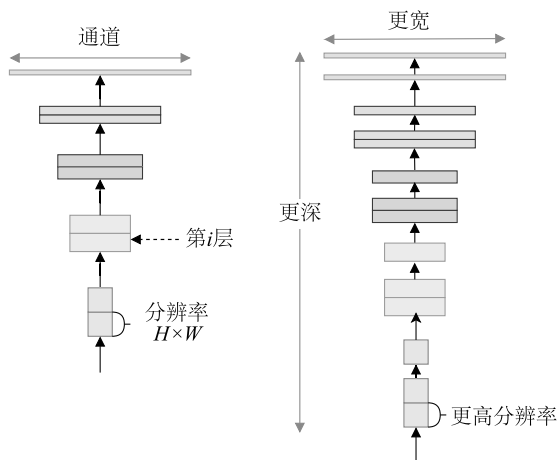


图3 EfficientNet 模型基线与复合缩放策略结构对比

Fig.3 Structural comparison between baseline and compound scaling strategy of EfficientNet model

道的数量增加 1 倍^[12]。具体结构见图 4。Shuffle-NetV2 模型已被用于作物病害识别,能够快速处理病叶图像并生成识别结果。

1.2.4 GhostNet 轻量级卷积神经网络模型 Ghost-Net 的设计通过减少冗余计算生成更多特征图^[13],其 Ghost 瓶颈结构和 Ghost 模块能够高效提取关键特征^[14],适合对大规模农作物图像进行分析。Ghost 模块如图 5 所示,Ghost 瓶颈模块如图 6 所示。Wang 等^[15]提出步长为 2 时 Ghost 瓶颈模块具有标准瓶颈结构的布局,并保持步长为 1 时的结构特征。作为一种新型轻量级网络模型,其在玉米病害识别和精准农业中的应用潜力逐步显现。

随着边缘计算与物联网技术的快速发展,面向极低功耗设备的 TinyML 等轻量级网络模型迎来蓬勃发展的机遇^[16]。这类模型凭借低能耗、高实时性的特性,在农业领域的应用场景不断拓展,从田间作物病害智能识别到产量精准预测均展现出显著优势。未来,通过融合图像数据、光谱数据、土壤数据等多模态信息,并引入注意力机制优化模型结构,轻量级网络模型有望推动农业智能化水平实现新的突破。

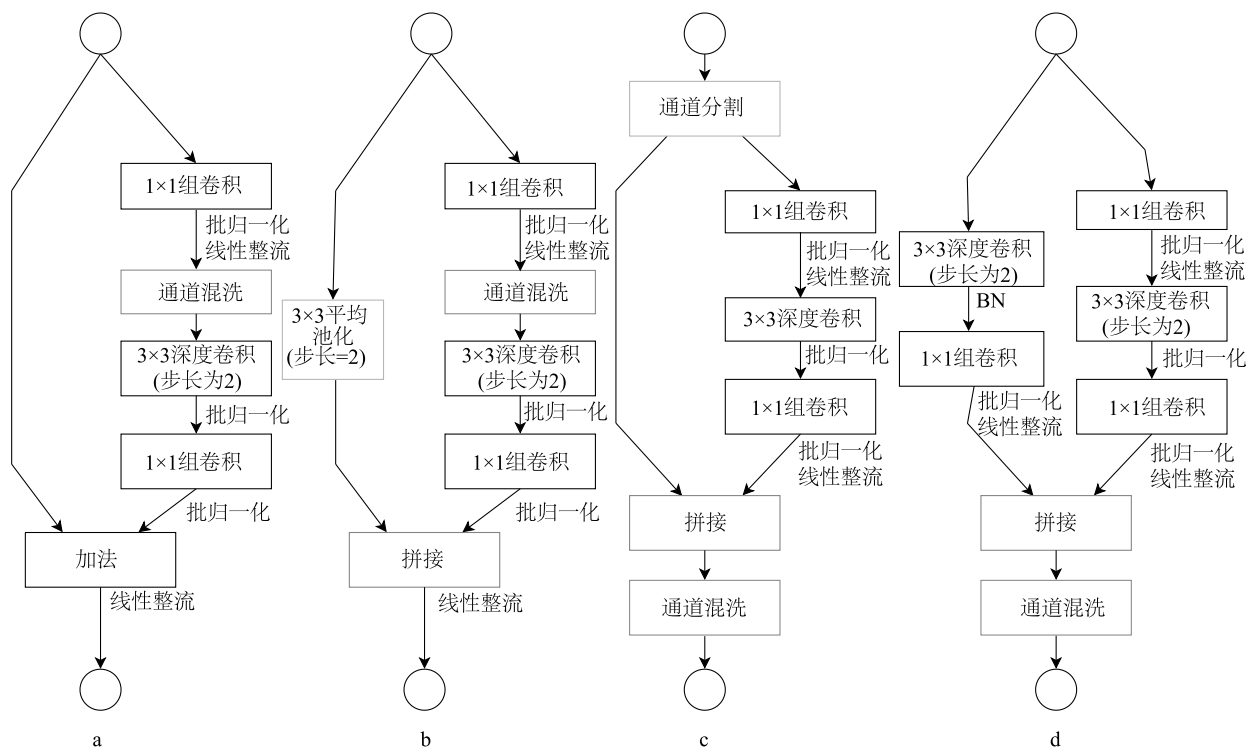


图 4 ShuffleNetV2 模型通道混洗与模块结构演进示意

Fig.4 Schematic diagram of channel shuffling and module structure evolution in ShuffleNetV2 model

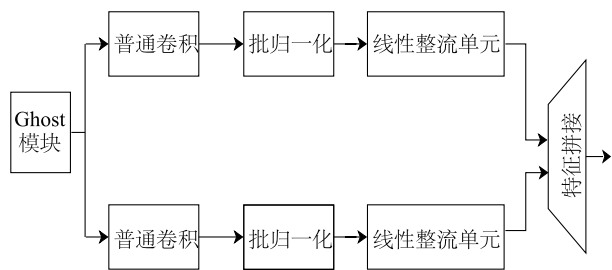


图 5 Ghost 模块特征生成流程

Fig.5 Feature generation process of Ghost module

2 玉米病害识别的研究现状

2.1 传统的玉米病害识别方法

玉米是世界范围内重要的粮食作物,但常见的 3 种玉米叶部病害(玉米大斑病、玉米锈病和灰叶斑病)^[17]会显著影响其产量和品质。传统的病害识别方法包括人工视觉检查和实验室检测。虽然这些方法在一定条件下有效,但存在效率低、成本高、依赖经验等缺点,不符合大规模种植的需求。

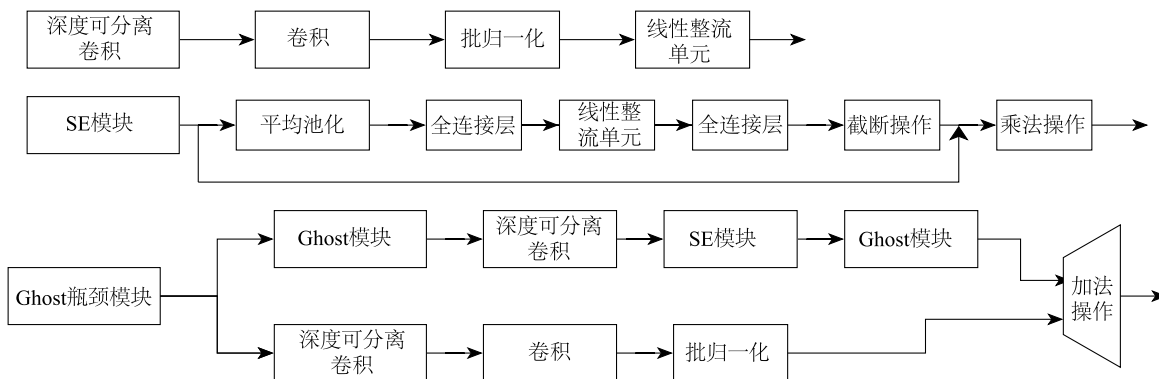


图 6 Ghost 瓶颈模块多组件融合结构

Fig.6 Multi-component fusion structure of Ghost bottleneck module

2.2 深度学习在玉米病害识别中的应用

深度学习引入了卷积神经网络(CNN),实现了从海量图像数据中自动提取复杂特征的能力,这一特性大幅度提升了图像识别精度。Amin等^[18]借助预训练的CNN模型结合数据增强技术,成功在计算资源受限的情况下实现了高效病害识别。Haque等^[19]采用基线训练方法,结果表明,即使面对不同背景的田间图像,表现最优的模型仍能有效识别玉米病害;Waheed等^[20]则开发出基于深度学习的优化DenseNet模型,该模型在玉米叶部病害识别中准确率达到了98.06%。

3 玉米产量预测的研究现状

随着全球人口增长和气候变化的加剧,准确预测玉米产量在指导农业生产规划、保障粮食安全、优化资源配置和助力市场调控等方面越来越重要。传统的产量预测方法主要包括基于统计模型、遥感数据和机器学习等方法^[21]。

3.1 传统的玉米产量预测方法

玉米产量预测传统方法包括基于统计模型和遥感数据的预测。这些方法主要依赖于历史数据和线性特征^[22]。Ji等^[23]探索了一种基于遥感植被指数的物候学方法来预测美国玉米带内314个县玉米产量。Yang等^[24]利用物候指标与无人机多光谱遥感技术结合随机森林模型,在玉米不同生长阶段比较精确地预测产量。Ma等^[25]开发的贝叶斯神经网络模型能够精准预测正常及极端天气下县级玉米产量。基于遥感技术的植被指数和土壤湿度数据虽然提高了预测精度,但是仍受限于模型的泛化能力。

3.2 基于深度学习的玉米产量预测方法

深度学习模型通过融合遥感和气象数据,显著提高了对作物产量的预测精度^[26]。例如, Khaki等^[27]提出的YieldNet模型利用迁移学习在多作物产量预测中表现出色。Jiang等^[28]开发的LSTM模型,融合多源数据,有效提高了对玉米产量预测的精度。Yang等^[29]研究发现,融合高光谱和彩色图像的CNN模型提高了对玉米产量预测的准确性。然而,基于深度学习的玉米产量预测模型对计算资源要求较高,限制了其在田间应用。

4 轻量级网络模型在玉米病害识别中的应用

轻量级网络模型的优势在于其较小的参数量和

计算成本,能够在资源有限的环境中实现高效的病害识别。通过减少卷积层的复杂性和模型参数量,可以快速处理农田中的大量图像数据,适应无人机采集的大规模数据处理需求。

4.1 基于 MobileNet 模型的改进

Ali等^[30]利用MobileNet作为基础网络模型,通过改进的Faster-RCNN方法有效提高了对玉米害虫识别和分类的准确性,同时保证模型的高效性和泛化能力。其方法通过深度可分离卷积降低了计算的复杂度,但在处理复杂背景图像时仍有局限。Chen等^[31]提出了一种改进的MobileNet-V2模型,该模型通过引入定位软关注机制和两阶段渐进策略,显著提高了对作物病害识别的准确率。注意力机制包括坐标注意力、空间注意力和通道注意力等,能够提升模型对病害特征的聚焦能力。Chen等^[32]提出的DF-CANet轻量级玉米病害识别模型主要包括带有坐标注意力的双特征融合模块和下采样模块,专门用于识别田间玉米叶片病害,平均识别准确率达到98.47%,并且模型参数和浮点运算量都较低,适合在资源受限的设备上部署。轻量级网络模型已广泛应用于田间病害识别,特别是在无人机采集图像的处理和移动终端的实时推理中。Gao等^[33]的研究结果表明,基于MobileNet V3-small模型的病害识别在复杂环境中依然表现出较高的检测精度和速度。Bi等^[34]通过改进MobileNetV3模型来识别玉米叶片病害,该模型在混合开源数据集上表现出高准确率和召回率,有效提高了玉米病害鉴定的效率和准确性。Ma等^[35]通过两阶段深度迁移学习方法,利用轻量级CNN模型在田间玉米叶片病害识别中实现了较高的准确率,证明了其在小样本情况下的高效性和可行性。

4.2 基于 EfficientNet 模型的优化

Cai等^[36]提出的FCI-EfficientNet模型是一种基于EfficientNet的改进型深度学习模型,它通过坐标注意力模块和自适应融合模块提高了对玉米病害识别的准确性,同时保持了模型的轻量级,可以在移动设备上实时识别。Liu等^[37]提出了一种基于迁移学习的EfficientNet模型参数微调方法,可以提高玉米病害数据集小样本网络识别的准确性和速度。王大庆等^[38]基于深度迁移学习理论提出一种两阶段迁移学习的EfficientNet模型,有效解决了识别复杂背景玉米叶部病害过程中出现的域迁移和小样本问题。经ImageNet至Plant Village及Plant Village

至本地数据集的两阶段迁移学习后,微调的 EfficientNet 模型与先进的深度网络模型在预留的玉米病叶数据集上对玉米叶片病害进行识别。章赵威等^[39]开发了一种基于 EfficientNet_b0 模型的深度学习模型,该模型具有较高的平衡准确率(96.3%)和较低的模型复杂度,基于 EfficientNet_b0 模型开发的安卓平台能够实现对玉米叶片病害的实时识别,为玉米种植者提供了一种便捷、高效和智能的玉米叶片病害诊断工具。蔡季桐^[40]介绍了两个基于 EfficientNet 改进的深度学习模型(FCA-Efficient Net 模型和 SDFB-Efficient Net 模型)在提高玉米病害识别准确性和效率方面的表现,以及集成这两个模型的玉米病害识别系统。Verma 等^[41]开发了一种轻量级卷积神经网络模型,用于识别玉米、水稻和小麦的病害,即使在资源受限的环境中也能实现高准确率的实时作物病害识别。Liu 等^[42]介绍了一种经过改进的轻量级卷积神经网络模型,通过引入多尺度卷积核和协调注意力机制,提高了对作物病害识别的准确率,并在性能与效率之间取得了良好平衡,适合部署在资源受限的设备上。

4.3 基于 ShuffleNet 模型的创新

Lu 等^[43]出了一种基于 ShuffleNetV2 的轻量级深度学习模型,用于识别玉米种子的表型病害。加入了高效通道注意模块来提升网络模型性能,引入 7×7 深度卷积层来扩大网络的有效感受野,并减少了 ShuffleNetV2 的基本单元以简化网络结构。该模型在参数数量、计算量和识别准确率方面都有良好表现,能够在移动设备上快速推理,为在移动设备上部署提供了有效的解决方案。Zhu 等^[44]提出的 MC-ShuffleNetV2 是一种为玉米病害图像识别设计的轻量级卷积神经网络模型。它结合了 Mish 激活函数、卷积块注意力模块和 ShuffleNetV2 架构,通过修改深度可分离卷积核和应用剪枝操作来优化模型。对玉米病害数据集中玉米病害的测试准确率达到 99.86%,模型参数和计算量都显著低于其他主流模型,适合在农业移动终端上部署。罗鸣等^[45]研究了基于迁移学习和轻量级卷积神经网络的农作物病害识别模型,利用 GhostNet 等预训练模型对玉米等作物的病害进行识别,识别准确率高达 99.27%,模型大小仅 4.02 MB。

轻量级网络模型在玉米病害识别中的研究主要集中于网络结构的优化和注意力机制的融合。未

来,针对田间数据的多样性和复杂性,探索更加高效的多模态数据融合策略是轻量级网络模型发展的重要方向。

5 轻量级网络模型在玉米产量预测中的应用

5.1 基于 MobileNet 模型的产量预测

MobileNet 系列网络模型因其结构简单、计算量低,被广泛用于图像处理。近年来,研究人员尝试将 MobileNet 模型应用于农业时序数据^[46]和图像数据融合的产量预测中。Ye 等^[47]提出了一种融合深度可分离卷积结构的 MobileNet 预测模型,该模型能在低功耗设备上高效运行,实现对玉米产量和小麦产量的快速估算。Mashudi 等^[48]基于 MobileNet 模型对农业天气图像进行识别,并利用结果预测作物产量,在试验中取得了 81% 的预测准确率。此外,Liang 等^[49]将 MobileNet 模型与时间序列模型 Prophet 结合,构建了一种涵盖玉米生长阶段识别与产量估计的一体化系统,降低了预测误差并设计了信息闭环反馈系统。这一研究强调了模型在时间序列预测中的灵活性和可靠性。Gao 等^[50]提出的改进 YOLOv4 轻量级神经网络模型,通过引入多尺度特征融合模块,显著提升了玉米幼苗数量检测的精度和效率,为后续产量估算提供了更可靠的数据支撑。Ilyas 等^[51]通过集成轻量级网络模型 MobileNetV2 和遥感数据,提出模糊混合集成法,用于作物分类与产量估算,效果优且适合配置在嵌入式设备上。

5.2 基于 EfficientNet 模型的产量预测

EfficientNet 模型具备较强的特征提取能力,适合处理高分辨率农作物遥感图像和多源数据,在产量预测中应用效果好。Reddy 等^[52]将 EfficientNet B7 模型用于植物表型时间序列分析任务,以提高玉米等作物产量预测的准确性。Casado-García 等^[53]利用 EfficientNet 架构融合遥感图像和地面特征数据,在短时间内处理大批异构数据,表现出较高的预测精度。

5.3 基于 ShuffleNet 模型的产量预测

ShuffleNetV2 模型具有出色的运行效率和低内存访问开销,适用于对实时性要求高的农业终端场景。尽管在玉米产量预测方面的文献相对较少,但已有部分研究探索将 ShuffleNet 架构用于农业环境信息提取与动态预测。例如,有学者尝试将 Shuf-

fleNet 模型与注意力机制结合^[54],提升对作物生长期图像中关键区域的关注能力,以提高预测模型的表现。此外,在集成学习框架中引入 ShuffleNet 作为子模型,也被用于增强模型多样性与鲁棒性,从而改善对作物产量预测的效果。

5.4 基于 GhostNet 模型的产量预测

GhostNet 模型创新引入 Ghost 模块,以轻量化操作生成丰富的特征图,在大幅度削减模型计算量与参数数量的同时,保持良好性能,非常适合部署在田间嵌入式设备上。Li 等^[55]将 GhostNet 结构与 YOLOv8s 目标检测框架融合,开发出 GhostNet_Triplet_YOLOv8s 模型,实现了玉米田间病害目标的快速检测,并进一步用于实时检测病虫害对产量的影响。此外,Khaki 等^[56]开发的 WheatNet 轻量级网络模型虽然主要针对小麦穗头检测,但在玉米产量预测场景中也表现出良好性能,验证了 GhostNet 类模型在多种作物上通用的可行性。

综合来看,这些研究结果表明,借助模型结构优化与轻量化策略,能够在不显著影响性能的前提下,实现对玉米产量的高效预测与分析。尽管轻量级网络模型在玉米产量预测中展现了诸多优势,但现有研究仍存在局限性。例如,大多数研究依赖于单一数据源^[57],难以充分刻画影响玉米产量的多维因素。此外,一些模型在实际部署中受限于田间环境的复杂性,泛化能力有待进一步提升。因此,未来可以通过多模态数据融合(如遥感图像与气候数据的结合)^[58]、跨领域迁移学习和高效模型压缩技术,进一步提升轻量级网络模型在精准农业中的应用效果。

6 挑战与展望

在玉米病害识别方面,轻量级网络模型能够快速从图像中提取特征并进行分类,从而帮助农民及时识别和防治病害,降低减产风险。在产量预测方面,这些网络模型能够分析来自田间的多源数据,如玉米生长周期的图像、土壤湿度和气候条件等,以预测最终产量,为农业决策提供科学依据。然而,随着农业数据的复杂性和对模型准确性要求的提高,轻量级网络模型在实际应用中还面临着一系列挑战。

6.1 挑战

6.1.1 数据稀缺与标注成本 在农业领域标注数据的获取往往存在困难。虽然轻量级网络模型能够

在小样本条件下运行^[59],但获取高质量标注样本仍存不足,而高质量标注样本对预测结果至关重要。然而,大多数农业病害的样本数量有限,且标注过程耗时费力。因此,如何高效收集和标注数据是一个亟待解决的挑战,尤其是在新病害或新品种出现时。

6.1.2 模型的泛化能力 尽管轻量级网络模型在特定场景展现出良好性能,但其泛化能力通常存在局限性。在玉米种植领域,面对复杂多变的环境因素,如气候条件的波动、土壤质地的差异等,这类网络模型难以保持稳定的预测精度和泛化能力。此外,为降低计算成本而削减参数数量的策略,使得轻量级网络模型在处理大规模数据时表现欠佳。而在玉米病害精准识别与产量科学预测等对模型精度要求极高的应用场景中,这一缺陷严重制约其实际应用效果。

6.1.3 计算资源限制与实时性要求 轻量级网络模型虽然因其较低的资源消耗,非常适合在计算能力受限的设备上运行,但在实际农业应用场景中,这些网络模型面临着不断变化的环境因素的挑战。除了气候等不确定性外,病虫害的突发性也对模型的实时性提出了更高要求。为了确保这些模型在农业生产中的实际应用既高效又可靠,研究者需要探索和开发先进的优化策略。这不仅涉及到模型结构的改进以适应动态环境,还涉及到算法的调整以提高其在各种条件下的泛化能力和鲁棒性。

此外,还需要考虑模型的可扩展性和灵活性,使其能够快速适应新的数据和环境变化,从而在不降低预测精度和检测性能的前提下,实现在智慧农业系统中的稳定部署和有效运行。特别是在无人机等设备采集的高分辨率图像和多模态数据融合时,如何确保实时处理和快速响应是未来研究的重要方向。

6.2 展望

6.2.1 数据增强与迁移学习 为了应对数据稀缺问题,可以着重开发数据增强技术,通过生成对抗网络(GAN)等方法生成更多的合成样本。Xin 等^[60]开发的 AWGAN 模型是一种基于 Wasserstein GAN 损失函数的增强型 GAN 模型,用来解决植物病害叶片训练图像数量有限的问题,该模型能够生成数量足够多且具有明显病灶的玉米叶片病害图像,同时还能提高识别的准确率。Yang 等^[61]提出的 YPM-GAN-GAT 模型是一种基于生成对抗网络和图

环注意力网络的玉米产量预测模型,通过建立多环境测试样本的时空相关性来填补缺失的性状属性并实现对玉米产量的预测。此外,迁移学习的应用可以有效利用已有的相关领域数据,提升轻量级网络在新环境下的表现,使其能够更好地应对稀缺样本的挑战。

6.2.2 集成学习与多模态融合 结合集成学习方法可以提升模型的鲁棒性和预测精度。例如,Shahhosseini 等^[62]将卷积神经网络与深度神经网络(CNN-DNN)集成新型机器学习模型,研究其在预测县级玉米产量方面的性能,结果表明,同质集成模型在异构集成的改进下,有更加准确的产量预测能力,有助于农艺决策者设计可靠的产量预测工具。He 等^[63]提出的一种新型作物叶部病害识别集合学习方法(ELCDR),该方法通过模型训练过程中的特征提取性能分配不同权重,改进传统的投票策略,结果表明,ELCDR 对不同作物病害图像识别准确率均优于单一模型和传统集成学习策略。同时,探索多模态数据融合,如图像、气象、土壤和遥感数据的整合,能够全面提高玉米病害识别和产量预测的准确性。

6.2.3 与边缘计算和物联网的结合 轻量级网络模型与物联网以及与边缘计算技术的结合是农业领域的重要发展方向。Maurya 等^[64]研究了一种使用人工智能在物联网设备上检测植物病害的新方法。使用轻量级多层感知混合器(MLP-Mixer)和长短期记忆网络(LSTM)模型的组合,在玉米、棉花病害图像数据集上的测试结果显示,这种方法分类准确率高、预测时间短、参数少,适用于资源有限的环境。张光梅^[65]提出借助传感器可实现对玉米产量的动态记录与监测,通过计数等方式准确测量收割的玉米数量,从而帮助农民了解作物生长情况,预估作物产量。Zeng 等^[66]提出了一种用于玉米叶部病害图像识别的轻量级密集尺度网络(LDSNet)模型,通过无人机辅助图像采集,提高作物病害分类准确性;通过将轻量级网络模型部署在边缘设备上,可以实现实时的玉米病害识别和产量预测。这不仅能够提高数据传输速度,还能降低对云端计算资源的依赖,推动农业精准化管理。

参考文献:

- [1] HAASE D, AMTHOR M. Rethinking depthwise separable convolutions: how intra-kernel correlations lead to improved mobilenets [C]//IEEE. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020; 14600-14609.
- [2] WANG L, HE D. Image super-resolution reconstruction algorithm based on channel shuffle [C]//IEEE. 2021 Asia-Pacific Conference on Communications Technology and Computer Science (ACCTCS). Shenyang: IEEE, 2021; 225-229.
- [3] DONG K, ZHOU C J, RUAN Y H, et al. MobileNetV2 model for image classification [C]//IEEE. 2020 2nd International Conference on Information Technology and Computer Application (IT-CA). Guangzhou: IEEE, 2020; 476-480.
- [4] KOONCE B. Convolutional neural networks with Swift for TensorFlow: image recognition and dataset categorization [M]. Berkeley: Apress, 2021.
- [5] DAS P K, MEHER S. An efficient deep convolutional neural network based detection and classification of Acute Lymphoblastic Leukemia [J]. Expert Systems with Applications, 2021, 183: 115311.
- [6] YU H L, CHE M H, YU H, et al. Research on weed identification in soybean fields based on the lightweight segmentation model DCSAnet [J]. Frontiers in Plant Science, 2023, 14: 1268218.
- [7] QIAN S Y, NING C R, HU Y P. MobileNetV3 for image classification [C]//IEEE. 2021 IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE). Nanchang: IEEE, 2021; 490-497.
- [8] TAN M, LE Q. EfficientNet: rethinking model scaling for convolutional neural networks [C]//PMLR. International Conference on Machine Learning. Long Beach: PMLR, 2019; 6105-6114.
- [9] ZHOU Y, CHEN S C, WANG Y M, et al. Review of research on lightweight convolutional neural networks [C]//IEEE. 2020 IEEE 5th Information Technology and Mechatronics Engineering Conference (ITOEC). Chongqing: IEEE, 2020; 1713-1720.
- [10] CHEN Y J, ZHENG B L, ZHANG Z H, et al. Deep learning on mobile and embedded devices [J]. ACM Computing Surveys, 2021, 53(4): 1-37.
- [11] LIU D, DU J C, LI C H, et al. Multi-unit stacked architecture: an urban scene segmentation network based on UNet and ShuffleNetv2 [J]. Applied Soft Computing, 2024, 165: 112065.
- [12] HAFIZ A M. A survey on light-weight convolutional neural networks: trends, issues and future scope [J]. Journal of Mobile Multimedia, 2023, 19(5): 1277-1297.
- [13] HAN K, WANG Y H, TIAN Q, et al. GhostNet: more features from cheap operations [C]//IEEE. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020; 1577-1586.
- [14] CHI J, GUO S H, ZHANG H P, et al. L-GhostNet: extract better quality features [J]. IEEE Access, 2023, 11: 2361-2374.
- [15] WANG Z, LI T. A lightweight CNN model based on GhostNet [J]. Computational Intelligence and Neuroscience, 2022, 2022(1): 8396550.
- [16] XU K R, LI Y S, ZHANG H W, et al. EtinyNet: extremely tiny

- network for TinyML[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(4):4628-4636.
- [17] ARORA J, AGRAWAL U, SHARMA P. Classification of maize leaf diseases from healthy leaves using Deep Forest[J]. Journal of Artificial Intelligence and Systems, 2020, 2(1):14-26.
- [18] AMIN H, DARWISH A, HASSANIEN A E, et al. End-to-end deep learning model for corn leaf disease classification[J]. IEEE Access, 2022, 10:31103-31115.
- [19] HAQUE M A, MARWAHA S, DEB C K, et al. Deep learning-based approach for identification of diseases of maize crop[J]. Scientific Reports, 2022, 12(1):6334.
- [20] WAHEED A, GOYAL M, GUPTA D, et al. An optimized dense convolutional neural network model for disease recognition and classification in corn leaf[J]. Computers and Electronics in Agriculture, 2020, 175:105456.
- [21] YANG C, ZHAI J J, TAO G H. Deep learning for price movement prediction using convolutional neural network and long short-term memory[J]. Mathematical Problems in Engineering, 2020, 2020(1):2746845.
- [22] SCHLENKER W, ROBERTS M J. Nonlinear temperature effects indicate severe damages to U.S. crop yields under climate change[J]. Proceedings of the National Academy of Sciences of the United States of America, 2009, 106(37):15594-15598.
- [23] JI Z L, PAN Y Z, ZHU X F, et al. Prediction of crop yield using phenological information extracted from remote sensing vegetation index[J]. Sensors, 2021, 21(4):1406.
- [24] YANG B, ZHU W X, REZAEI E E, et al. The optimal phenological phase of maize for yield prediction with high-frequency UAV remote sensing[J]. Remote Sensing, 2022, 14(7):1559.
- [25] MA Y C, ZHANG Z, KANG Y H, et al. Corn yield prediction and uncertainty analysis based on remotely sensed variables using a Bayesian neural network approach[J]. Remote Sensing of Environment, 2021, 259:112408.
- [26] YUAN Z W, LU C X. Research on image classification of light-weight convolutional neural network[C]//IEEE. 2021 IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE). Nanchang: IEEE, 2021: 498-501.
- [27] KHAKI S, PHAM H, WANG L Z. Simultaneous corn and soybean yield prediction from remote sensing data using deep transfer learning[J]. Scientific Reports, 2021, 11(1):11132.
- [28] JIANG H, HU H, ZHONG R H, et al. A deep learning approach to conflating heterogeneous geospatial data for corn yield estimation: a case study of the US Corn Belt at the county level[J]. Global Change Biology, 2020, 26(3):1754-1766.
- [29] YANG W, NIGON T, HAO Z Y, et al. Estimation of corn yield based on hyperspectral imagery and convolutional neural network[J]. Computers and Electronics in Agriculture, 2021, 184:106092.
- [30] ALI F, QAYYUM H, IQBAL M J. Faster-PestNet: a lightweight deep learning framework for crop pest detection and classification[J]. IEEE Access, 2023, 11:104016-104027.
- [31] CHEN J D, ZHANG D F, SUZAUDDOLA M, et al. Identifying crop diseases using attention embedded MobileNet-V2 model[J]. Applied Soft Computing, 2021, 113:107901.
- [32] CHEN Y, CHEN X, LIN J W, et al. DFCANet: a novel light-weight convolutional neural network model for corn disease identification[J]. Agriculture, 2022, 12(12):2047.
- [33] GAO A, GENG A J, SONG Y P, et al. Detection of maize leaf diseases using improved MobileNet V3-small[J]. International Journal of Agricultural and Biological Engineering, 2023, 16(3):225-232.
- [34] BI C G, XU S Z, HU N, et al. Identification method of corn leaf disease based on improved MobileNetV3 model[J]. Agronomy, 2023, 13(2):300.
- [35] MA Z, WANG Y, ZHANG T S, et al. Maize leaf disease identification using deep transfer convolutional neural networks[J]. International Journal of Agricultural and Biological Engineering, 2022, 15(5):187-195.
- [36] CAI J T, PAN R Y, LIN J W, et al. Improved EfficientNet for corn disease identification[J]. Frontiers in Plant Science, 2023, 14:1224385.
- [37] LIU J C, WANG M T, BAO L, et al. EfficientNet based recognition of maize diseases by leaf image classification[J]. Journal of Physics: Conference Series, 2020, 1693(1):012148.
- [38] 王大庆, 禄琳, 于兴龙, 等. 基于深度迁移学习的 EfficientNet 玉米叶部病害识别[J]. 东北农业大学学报, 2023, 54(5):66-76.
- [39] 章赵威, 冯向萍, 张世豪. 基于深度学习的玉米叶片病害识别方法研究[J]. 现代计算机, 2024, 30(13):1-8, 77.
- [40] 蔡季桐. 基于注意力机制与改进 EfficientNet 模型的细粒度玉米病害识别研究[D]. 贵阳: 贵州大学, 2024.
- [41] VERMA S, KUMAR P, SINGH J P. A unified lightweight CNN-based model for disease detection and identification in corn, rice, and wheat[J]. IETE Journal of Research, 2024, 70(3):2481-2492.
- [42] LIU Y, GAO G Q, ZHANG Z H. Crop disease recognition based on modified light-weight CNN with attention mechanism[J]. IEEE Access, 2022, 10:112066-112075.
- [43] LU L, LIU W, YANG W, et al. Lightweight corn seed disease identification method based on improved ShuffleNetV2[J]. Agriculture, 2022, 12(11):1929.
- [44] ZHU S Q, GAO H T. MC-ShuffleNetV2: a lightweight model for maize disease recognition[J]. Egyptian Informatics Journal, 2024, 27:100503.
- [45] 罗鸣, 方睿, 徐铭美, 等. 基于迁移学习和轻量级卷积神经网络农作物病害识别[J]. 现代计算机, 2021, 27(32):16-21.
- [46] REDDY P C S, SURESHBABU A. Soft computing and signal processing[M]. Singapore: Springer, 2020.
- [47] YE J X, YU Z H, WANG Y X, et al. WheatLFANet: in-field detection and counting of wheat heads with high-real-time global re-

- gression network[J]. *Plant Methods*,2023,19(1):103.
- [48] MASHUDI N A, AHMAD N, SAM S M, et al. Deep learning approaches for weather image recognition in agriculture[C]//IEEE. 2022 IEEE Symposium on Future Telecommunication Technologies (SOFTT). Johor Baharu:IEEE,2022:72-77.
- [49] LIANG Q Y, ZHANG X L, GE Y Y, et al. Maize plant growth period identification based on MobileNet and design of growth control system[J]. *BioResources*,2024,19(3):5450-5466.
- [50] GAO J X, TAN F, CUI J P, et al. A method for obtaining the number of maize seedlings based on the improved YOLOv4 lightweight neural network[J]. *Agriculture*,2022,12(10):1679.
- [51] ILYAS Q M, AHMAD M, MEHMOOD A. Automated estimation of crop yield using artificial intelligence and remote sensing technologies[J]. *Bioengineering*,2023,10(2):125.
- [52] REDDY J, NIU H, DUFFIELD N. A CNN-LSTM model for cotton water stress classification[C]//ASABE. 2024 ASABE Annual International Meeting. Joseph:ASABE,2024:1.
- [53] CASADO-GARCÍA Á, HERAS J, MARTÍNEZ-GOÑI X S, et al. Estimation of crop production by fusing images and crop features [C]//IEEE. 2023 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW). Paris:IEEE,2023:525-530.
- [54] ZHAO J, LIU C Z, HAN J Y, et al. Real-time corn variety recognition using an efficient DenXt architecture with lightweight optimizations[J]. *Agriculture*,2025,15(1):79.
- [55] LI R J, LI Y D, QIN W B, et al. Lightweight network for corn leaf disease identification based on improved YOLO v8s[J]. *Agriculture*,2024,14(2):220.
- [56] KHAKI S, SAFAEI N, PHAM H, et al. WheatNet: a lightweight convolutional neural network for high-throughput image-based wheat head detection and counting[J]. *Neurocomputing*, 2022, 489:78-89.
- [57] GAO J, LI P, CHEN Z K, et al. A survey on deep learning for multimodal data fusion [J]. *Neural Computation*, 2020, 32(5): 829-864.
- [58] MAIMAITIJIANG M, SAGAN V, SIDIKE P, et al. Soybean yield prediction from UAV using multimodal data fusion and deep learning[J]. *Remote Sensing of Environment*,2020,237:111599.
- [59] 李丽丽. 基于深度学习的小样本苹果叶片病害识别与诊断研究[D]. 太原:山西农业大学,2022.
- [60] XIN M Y, ANG L W, PALANIAPPAN S. A data augmented method for plant disease leaf image recognition based on enhanced GAN model network[J]. *Journal of Informatics and Web Engineering*,2023,2(1):1-12.
- [61] YANG F, ZHANG D F, ZHANG Y Q, et al. Prediction of corn variety yield with attribute-missing data *via* graph neural network [J]. *Computers and Electronics in Agriculture*, 2023, 211: 108046.
- [62] SHAHHOSSEINI M, HU G P, ARCHONTOULIS S V. Forecasting corn yield with machine learning ensembles[J]. *Frontiers in Plant Science*,2020,11:1120.
- [63] HE Y, ZHANG G C, GAO Q. A novel ensemble learning method for crop leaf disease recognition[J]. *Frontiers in Plant Science*, 2024,14:1280671.
- [64] MAURYA R, MAHAPATRA S, RAJPUT L. A lightweight meta-ensemble approach for plant disease detection suitable for IoT-based environments[J]. *IEEE Access*,2024,12:28096-28108.
- [65] 张光梅. 智能化技术在玉米收割机中的应用[J]. *农业工程技术*,2023,43(29):65-66.
- [66] ZENG W H, LI H D, HU G S, et al. Lightweight dense-scale network (LDSNet) for corn leaf disease identification[J]. *Computers and Electronics in Agriculture*,2022,197:106943.

(责任编辑:黄克玲)