

## DB-DAB-Net:一种用于玉米叶片病害识别的高效新型网络

刘海佳<sup>1,2</sup>, 邓伟豪<sup>1,2</sup>, 陈昊瑞<sup>1,2</sup>, 麻海志<sup>1,2</sup>, 刘拥民<sup>1,2\*</sup>

1. 中南林业科技大学电子信息与物理学院, 湖南 长沙 410004

2. 中南林业科技大学智慧林业云研究中心, 湖南 长沙 410004

**摘要:** 玉米是全球重要的粮食作物,其生产过程易受各种病害的侵袭,在复杂背景下,由于现有的深度学习模型具有多尺度特征提取能力不足和上下文信息融合效率低等缺陷,易导致病害识别准确率降低。为此,本文提出一种双分支特征提取结构与注意力机制融合的玉米叶片病害识别模型(DB-DAB-Net),首先构建深度可分离卷积(Depthwise Separable Conv)的双分支特征提取结构,提取复杂特征和空间细节,并降低计算量和参数量,利用动态融合门控机制自适应双分支,提升特征提取效率和模型鲁棒性。其次,在每个阶段后加入融合通道注意力和空间注意力的MCSA(Multi-scale Combination-Selective Attention)模块,并引入双向交互权重机制,实现对全局和局部信息的精细化捕捉,降低计算成本。最后,在平均池化层前加入BiFPN(Bidirectional Feature Pyramid Network,双向特征金字塔网络)模块,通过双向特征金字塔网络进行不同尺度的特征融合,使用可学习权重动态调整各尺度特征,并采用Swish激活函数保证梯度稳定性,进一步提升模型对多尺度目标的感知能力。实验结果表明,DB-DAB-Net在玉米病害数据集上具有良好的识别性能,识别查准率、召回率、F1分数、准确率分别达到了97.58%、97.47%、97.49%、97.47%,同时模型的参数量和浮点计算量分别为2.53 M和5.56 G。在复杂环境下,DB-DAB-Net模型能够有效提高玉米叶片病害识别的准确性,同时为农业病害监测提供了一种新的技术思路。

**关键词:** 玉米叶片病害; 双分支网络; 多尺度特征融合; 注意力机制; 智慧农业

中图法分类号: S435.13

文献标识码: A

文章编号: 1000-2324(2026)02-0283-12

## DB-DAB-Net: An Efficient Novel Network for Maize Leaf Disease Identification

LIU Hai-jia<sup>1,2</sup>, DENG Wei-hao<sup>1,2</sup>, CHEN Hao-rui<sup>1,2</sup>, MA Hai-zhi<sup>1,2</sup>,  
LIU Yong-min<sup>1,2\*</sup>

1. School of Electronic Information and Physics/Central South Forestry University of Science and Technology, Changsha 410004, China

2. Intelligent Forest Cloud Research Center/Central South Forestry University of Science and Technology, Changsha 410004, China

**Abstract:** Maize is a vital global food crop, yet its production is vulnerable to various diseases. Under complex backgrounds, the existing deep learning models often suffer from insufficient multi-scale feature extraction and inefficient fusion of contextual information, leading to low accuracy in disease identification. To address these issues, this paper proposes a maize leaf disease recognition model (DB-DAB-Net), which combines a two-branch feature extraction structure with the attention mechanism. Firstly, Depthwise Separable Conv is constructed as a two-branch feature extraction structure to capture complex features and spatial details while reducing computational cost and parameter count. A dynamic fusion gating mechanism is introduced to adaptively integrate the double branch, enhancing the feature extraction efficiency and model robustness. Then, MCSA module is incorporated after each stage, which combines channel attention and spatial attention. A bidirectional interactive weight mechanism is introduced to achieve fine capture of global and local information while minimizing calculation cost. Finally, BiFPN module is added in front of the average pooling layer, which performs multi-scale feature fusion through the bidirectional feature pyramid network, dynamically adjusts features at different scales using learnable weights, and employs Swish activation function to ensure gradient stability, so as to further improve the model's perception ability of multi-scale targets. The experimental results show that DB-DAB-Net achieves good identification performance on maize disease data set, with the identification accuracy rate, recall rate, F1 score and accuracy

收稿日期: 2025-04-24

修回日期: 2026-03-09

基金项目: 国家自然科学基金(31870532); 长沙市科技计划项目(kq2402265)

第1作者简介: 刘海佳(2000-),女,硕士研究生,研究方向:人工智能、医学图像处理。E-mail: 2502058715@qq.com

\*通讯作者: Author for correspondence. E-mail: T20040550@csuft.edu.cn

rate reaching 97.58%、97.47%、97.49% and 97.47%, respectively. The number of parameters and floating-point operations of the model are 2.53 M and 5.56 G, respectively. In complex environment, DB-DAB-Net model can effectively improve the accuracy of maize leaf disease detection, providing a new technical idea for agricultural disease monitoring.

**Keywords:** Maize leaf disease; double-branch network; multi-scale feature fusion; attention mechanism; smart agriculture

玉米是仅次于小麦和水稻的全球第三大种植作物<sup>[1]</sup>,同时也是全球最重要的经济粮食作物之一。随着种植面积的持续扩大,玉米病害的发生率正在逐步增加,这给农业生产造成了巨大的经济损失。玉米病害的发生不仅与生物因素密切相关,还受到环境因素的显著影响,特别是在高温高湿等易诱发病害的气候背景下更加显著<sup>[2]</sup>。在众多病害中,叶部病害因其发病率高、传播速度快和对产量影响大,成为制约玉米产量提升的主要生物胁迫因素。例如,由玉米全蚀病引起的干腐病可导致叶片干枯甚至整株死亡,严重影响植株正常生长<sup>[3]</sup>。根据当前研究与生产实践,玉米常见的叶部病害包括大斑病、灰斑病和普通锈病。这三种病害在田间表现症状明显,是玉米病害防控的重点对象<sup>[4]</sup>。尽管这些病害在理论上具有一定的可识别性,但传统依赖人工经验的诊断方法存在耗时长、效率低、依赖专业性等问题,难以满足现代农业生产的需求。近年来,计算机视觉与深度学习技术的快速发展为病害自动识别提供了新路径。基于深度学习的识别流程一般包括数据采集、模型构建、训练与推理验证等环节,已在多个研究中展现出良好的性能。例如,Mehta等<sup>[5]</sup>提出的玉米病害联邦学习CNN模型测试准确率89.4%,适应性良好,但大规模复杂场景下精度不足。为此,马春悦<sup>[6]</sup>等基于改进ResNet18引入金字塔卷积和多尺度特征,提升了复杂环境单叶片识别能力及准确率,但小数据集限制了其泛化能力。曾鹏滔<sup>[7]</sup>等人提出的CB-SE-ResNet18模型引入通道和空间注意力机制,同时替换激活函数为SeLU,引入Alpha Dropout来增强模型的泛化能力,随机裁剪分支,提高了模型对图像变化的适应性。尽管该模型在农田环境下的玉米病害数据集中取得了94.42%的准确率,但在复杂背景下,特征提取能力仍面临挑战,尤其在光照变化、遮挡及病斑小而分散的情况下,模型的性能可能受到影响。Ramadan等人<sup>[8]</sup>采用卷积神经网络与Transformer架构相结合的方式提出了ViT-B/16模型,准确率达到94.51%,但相比于CNN模

型,ViT模型对计算资源的要求较高,可能导致实际应用中的识别效率不足。

尽管现有深度学习模型在实验室条件下取得了良好效果,但在实际应用中仍存在识别准确率不足、特征提取能力受限、数据集规模偏小、特征融合效率低,以及难以在算力受限的终端上部署等一系列问题。针对这些问题,本文提出了一种玉米叶片病害识别的高效新型网络DB-DAB-Net,该网络引入深度可分离卷积并设计双分支特征提取结构,在每个阶段后加入MCSA机制,实现对全局和局部信息的精细化捕捉,并将输出特征通过BiFPN进行融合,在玉米叶片病害数据集中进行训练,以实现玉米叶片的多种病害的高效高精度识别。

## 1 数据及模型构建

### 1.1 数据集的获取

本文研究的数据集源自AI Challenger 2018公开的玉米叶片病害数据集,涵盖自然语言处理和计算机视觉等领域,常用于测试图像分类、目标检测和分割算法的鲁棒性,是农业计算机视觉领域的基准资源<sup>[9]</sup>。该数据集通过标准化田间图像采集和三级标注体系,解决了复杂背景干扰、病害程度量化及跨设备泛化等关键问题<sup>[10]</sup>。它包含10种植物、27种病害,其中24种病害按“一般/严重”程度细分为61个标签。玉米叶片病害部分涵盖灰斑病、锈病和大斑病三种,共约4 354张图像。相较于实验室数据集,其优势在于真实田间场景、病害连续状态和细粒度标注,为农业病害智能诊断提供了高可信度基础,有力支持了本文模型的初步训练。各类别样本如图1所示。按8:1:1的数量比例划分为训练集、验证集和测试集,具体划分情况如表1所示。

### 1.2 数据增强

为了进一步增强训练模型的泛化能力,本文采用了多种数据增强策略。这些方法包括模糊图像以提升对图像模糊现象的适应能力,提升其在面对真实场景中由于焦距问题或运动模糊等




图 1 玉米叶片病害样本

Fig. 1 Maize leaf disease sample

表 1 玉米叶片数据集的划分

Table 1 Division of maize leaf data set

病害种类	训练集	验证集	测试集
Disease type	Training set	Validation set	Test set
锈病	954	119	119
灰斑病	800	100	100
健康	930	116	116
大斑病	800	100	100

因素导致的图像模糊情况下的鲁棒性,添加噪声以提高模型对图像质量变化的鲁棒性,以及使用提高图像的亮度来模拟现实中可能出现的亮度

高图像。通过这些增强手段,在不改变图像内容的前提下,通过空间几何变换,改变图像中的像素空间位置,增加样本数量,避免过拟合的发生,使模型能够更好地适应玉米田间环境的复杂性,提高在不同场景下的检测准确性。本文使用的玉米病害数据集使用数据增强方法,将训练集和验证集从原始的3 919张图像扩充至7 830张,为模型训练提供了更丰富、更具代表性的数据支持,有助于提高模型的识别准确率和泛化能力。本文使用的玉米病害数据集,图像大小为224像素×224像素。数据增强后的图片如图2所示。




图 2 数据增强后的玉米叶片图像

Fig. 2 Maize leaf image after data enhancement

### 1.3 模型构建

针对当前玉米病害检测中存在的模型特征提取能力不足,信息融合效率低且计算速度慢,以及检测精度低等问题,本研究提出一种玉米叶片病害识别模型 DB-DAB-Net。该模型通过多个模块的优化和改进,实现了更高的识别精度和更低的计算成本。如图3所示,DB-DAB-Net模

型结构包括主干网络(Stem)、阶段网络(Stage Networks)、BiFPN网络、分类头组成。主干网络主要由一个7×7卷积、BN层、ReLU激活函数层以及一个3×3最大池化层,用于对输入图像进行初步的特征提取和降维,生成初步的特征表示。这些特征表示为后续的高级特征提取和分类任务提供了基础,同时减少了计算量和参数量,提

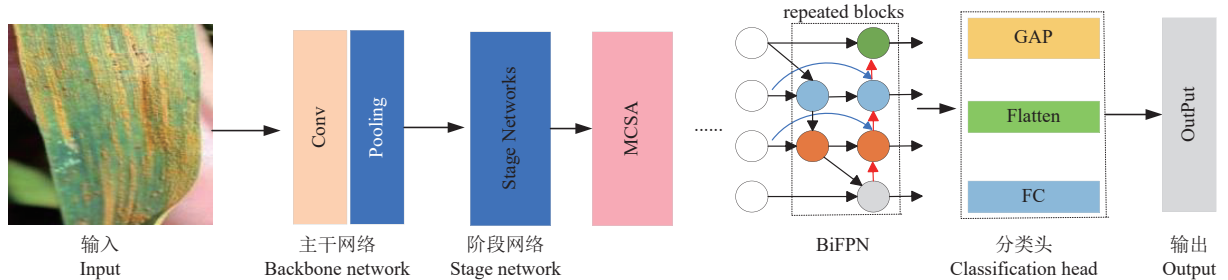


图 3 我们提出的玉米叶病害识别方法的架构

Fig. 3 Architecture of the proposed maize leaf disease recognition method

高了模型的计算效率。阶段网络型包含四个阶段网络(Stage1 到 Stage4),每个阶段网络由多个双分支特征提取模块组成且每个阶段网络后面接一个MCSA 注意力模块,通过逐步增加通道数和特征的抽象层次,模型能够捕获从低级到高级的特征,为最终的分类任务提供丰富的特征表示。为提升多尺度特征融合效果及识别准确率,

引入 BiFPN。该结构简化融合路径,减少冗余连接与操作,从而降低计算复杂度;并通过优化融合结构与路径,在提升检测性能时维持低计算成本与参数量。最后,通过一个分类头进行最终的分类预测。分类头由一个全局平均池化层、一个展平层和一个全连接层组成,输出类别数为4。具体结构如图4所示。

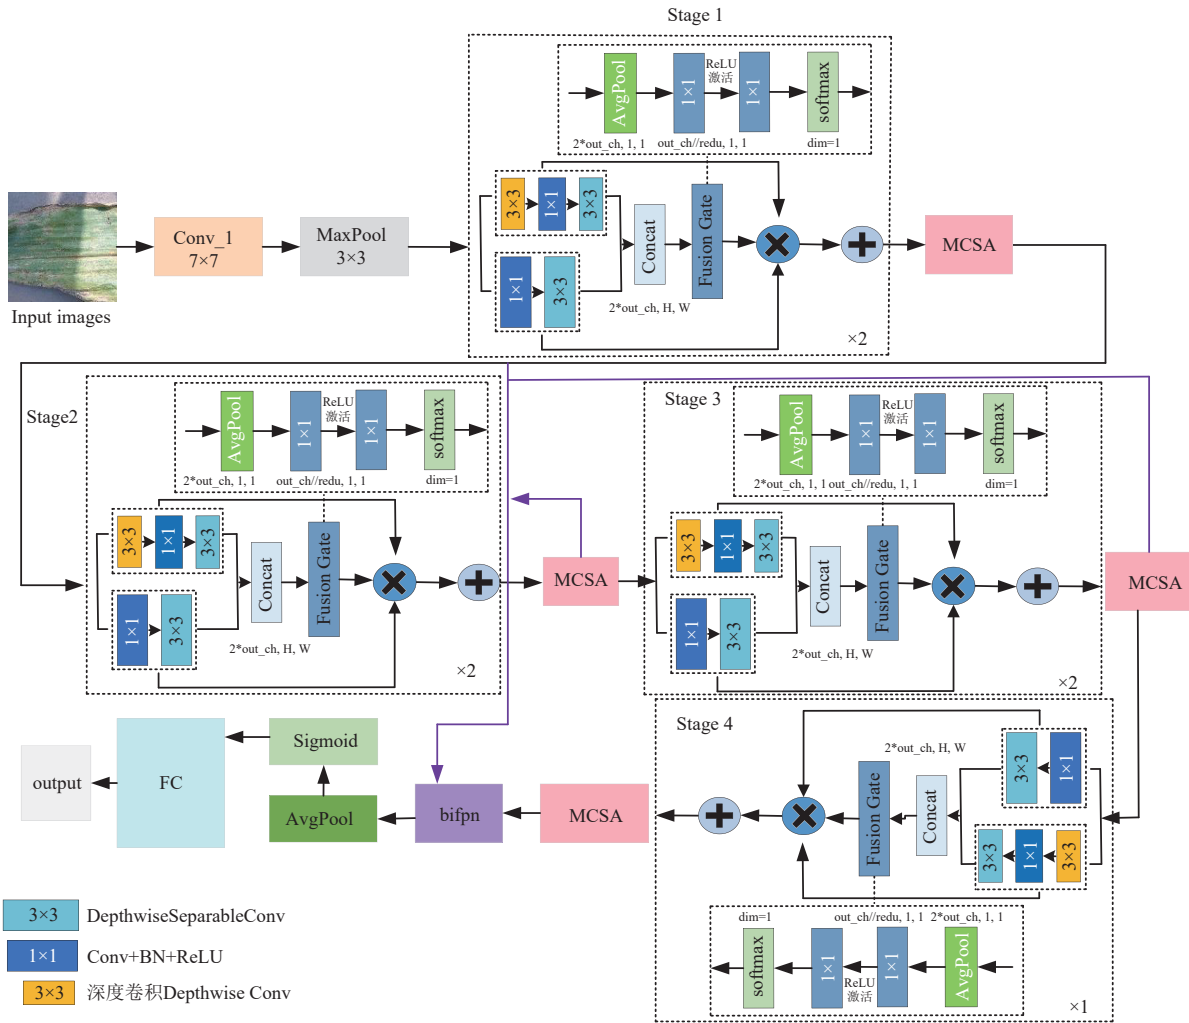


图4 DB-DAB-Net 网络的详细结构图

Fig. 4 Detailed structure of the DB-DAB-Net network

1.3.1 深度可分离卷积 标准卷积计算量大、参数量高,导致计算冗余严重,且对硬件资源要求高。为提高计算效率,在模型设计中引入深度可分离卷积<sup>[11]</sup>,它将标准卷积分解为深度卷积和逐点卷积,大幅减少计算量和参数的同时保持较好的特征提取能力。如图 5a 所示,标准卷积通过 3×3 卷积集成空间特征提取与通道信息融合;如图 5b 所示,输入特征通过深度卷积,对每个输

入通道独立进行空间特征提取,再通过逐点卷积跨通道融合信息并调整输出维度。两阶段均通过 BN+ReLU 稳定训练并增强非线性。

深度可分离卷积结构如图6所示,通过两个顺序步骤实现特征提取:在深度卷积阶段,每个输入通道独立采用 3×3 卷积核进行空间特征提取,生成通道数不变的等量特征图;在逐点卷积阶段,使用 4 个 1×1 卷积核融合通道信息并扩展

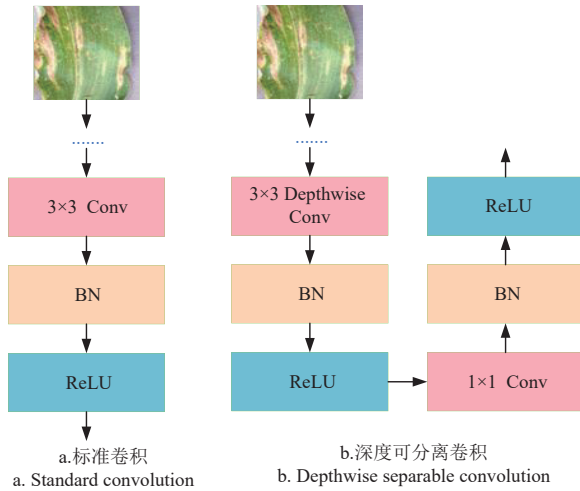


图 5 标准卷积和深度可分离卷积对比结构图

Fig. 5 Contrast structure of standard convolution and depth-separable convolution

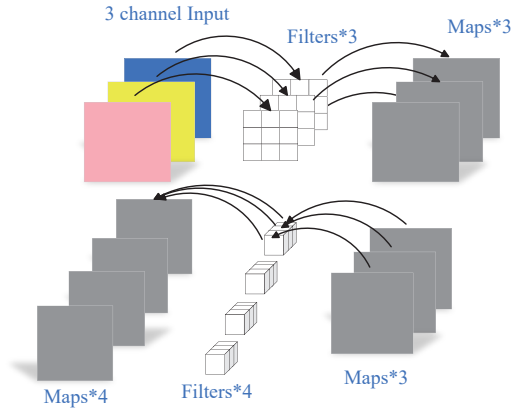


图 6 深度可分离卷积结构图

Fig. 6 Depthwise separable convolution structure diagram

维度,实现通道间的全连接操作。每个卷积层后均执行批量归一化(BN)与 ReLU 激活,确保训练稳定性及非线性表达能力。

深度可分离卷积的参数量与计算量分析如下:设输入特征图尺寸为  $H \times W$ ,输入、输出通道数为  $C, N$ ,卷积核尺寸  $K \times K$ 。标准卷积参数量、计算量如公式(1)(2)所示,深度可分离卷积参数量、计算量如公式(3)(4)所示。参数量与计算量减少比例均为  $\frac{C \times (K \times K + N)}{K \times K \times C \times N} = \frac{1}{N} + \frac{1}{K^2}$ ,当  $N$  较大时,二者可降至标准卷积的  $\frac{1}{K^2}$ 。因此,深度可分离卷积通过拆分标准卷积为深度卷积和逐点卷积,显著降低计算复杂度,在保留特征提取能力的同时实现轻量化,适配资源受限场景。

$$\text{Param} = K \times K \times C \times N \quad (1)$$

$$\text{FLOPs} = K \times K \times C \times N \times H \times W \quad (2)$$

$$\text{Param} = K \times K \times C + C \times N \quad (3)$$

$$\text{FLOPs} = K \times K \times C \times H \times W + C \times N \times H \times W \quad (4)$$

1.3.2 双分支特征提取网络 为了提升特征表达能力并优化信息融合,本文设计了双分支特征提取网络。传统的双分支特征提取网络虽通过多分支提取不同特征或尺度信息,但存在分支功能区分不明确、融合方式固定的问题,且其多尺度设计初衷并非针对特定特征类型互补提取<sup>[12]</sup>。而本文的双分支网络通过独特的分支设计和自适应融合机制,更精准地应对农业病害识别中特定病斑特征差异大的问题。以大斑病为例,如图 7 所示,第一分支利用  $1 \times 1$  卷积和深度可分离卷积提取大面积病斑的全局特征,第二分支采用轻量级深度可分离卷积提取小而分散病斑的局部细节特征。其自适应融合模块(Fusion Gate)能够根据输入病斑的特点动态调整分支权重,避免固定融合方式带来的局限性。双分支特征提取网络的结构如图 8 所示,第一分支采用  $1 \times 1$  卷积和深度可分离卷积进行特征提取, $1 \times 1$  卷积用于通道变换,深度可分离卷积通过分解标准卷积为深度卷积和逐点卷积,在减少参数量的同时保持强大的特征提取能力,并采用批量归一化(BN)和 ReLU 激活函数提高训练稳定性和非线性表达能力;第二分支则采用更精简的深度可分离卷积结构,通过深度卷积和逐点卷积的组合减少冗余计算,并使用额外的深度可分离卷积进一步强化特征提取能力,其轻量化设计适配资源受限设备。为了有效融合双分支的提取特征,在该结构中加入自适应融合模块。该模块首先对两个分支的特征图进行平均池化,提取通道维度上的全局信息。然后,利用  $1 \times 1$  卷积降维,以减少计算负担,并通过 ReLU 激活增强非线性表达能力。随后,该模块通过另一个  $1 \times 1$  卷积生成两个融合权重,并通过 Softmax 归一化,确保两个分支的权重总和为 1,从而保证融合的稳定性和合理性。在前向传播过程中,第一分支和第二分支分别计算得到特征映射  $F_1$  和  $F_2$ ,然后通过融合权重  $W_1$  和  $W_2$  进行加权求和,最终获得融合后的特征,如公式(5)所示。

$$F_{out} = W_1 \times F_1 + W_2 \times F_2 \quad (5)$$

这种融合机制能够根据输入特性动态调整




图 7 不同分支病害可视化

Fig. 7 Visualization of different branch diseases

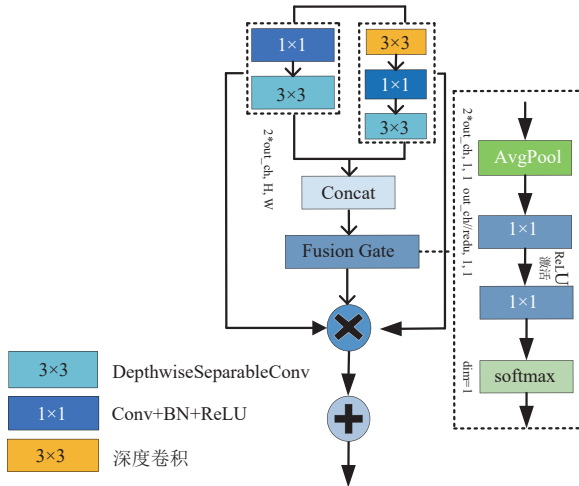


图 8 双分支特征提取结构

Fig. 8 Double-branch feature extraction structure

第一分支与第二分支的贡献,使得模型能够在不同复杂度的任务上保持较优的表现,同时避免了固定结构带来的计算冗余问题。相比于现有 CNN 结构,它具备更高的计算效率,深度可分离卷积减少计算量,也提高了模型的灵活性<sup>[13]</sup>。

**1.3.3 MCSA 机制** 随着深度学习技术的快速发展,注意力机制已成为提升神经网络性能的重要工具。尤其在计算机视觉领域,如 CBAM<sup>[14]</sup>、SE<sup>[15]</sup>、ECA<sup>[16]</sup>等机制已被广泛应用于特征提取和图像识别任务。然而,这些机制在处理复杂数据时仍存在一些局限性,例如对多尺度特征的整合能力不足和计算效率问题。为此,本文提出了 MCSA 机制,它是集成了改进的 EMA 机制的一种新的注意力机制。高效多尺度 EMA<sup>[17]</sup> (Efficient Multil-scale Attention) 机制,是一种灵活且轻量级的机制,对于给定的输入特征图,EMA 将 H 跨通道维度方向分为多个  $g$  ( $g \ll C$ ) 子特征,以学习不同语义的信息。在  $1 \times 1$  分支中采用两个 1D 全局平均池化操作分别沿两个空间方向对通道进行编码,并且在  $3 \times 3$  分支中仅堆叠单个  $3 \times 3$  以捕获多尺度特征表示。此外,EMA

采用跨空间学习策略,通过将  $1 \times 1$  和  $3 \times 3$  分支的输出结合,编码全局空间信息。这些输出通过全局平均池化和非线性函数处理,生成空间注意力图。这些注意力图通过点积运算相乘,形成对输入特征图的最终输出,确保了每个像素在全局上下文中的重要性。MCSA 机制在此次集成的过程中将 EMA 机制中的标准卷积  $1 \times 1$  和  $3 \times 3$  替换为深度可分离卷积。此改进通过深度卷积与逐点卷积,在保留 EMA 多尺度学习能力的同时显著降低计算负载。其设计过程分为几个关键步骤:首先,输入的特征图被划分为多个组,以便在每个组内执行改进的 EMA 机制。其次,对于原始特征图,通过  $7 \times 7$  卷积操作生成位置权重,用以突出输入图像中重要的空间区域。接下来,对输入的原始特征图进行通道注意力处理,通过 X 和 Y 方向的全局平均池化提取全局信息,并将其输入全连接层,经 Sigmoid 激活后生成通道权重,从而衡量每个通道的重要性。然后,将空间注意力和通道注意力的结果分别与特征图相乘,进一步强化重要特征。最后,对 EMA 注意力、空间注意力、通道注意力的输出进行融合,以生成注意力机制的最终输出。MCSA 机制通过对多尺度空间和通道特征的融合,有效提升了模型在复杂背景下的特征提取能力。MCSA 机制如图 9 所示。

**1.3.4 BiFPN 特征融合** BiFPN<sup>[18]</sup> 是一种优化后的特征金字塔网络,旨在提升多尺度目标检测中的特征融合效率。相较于传统 FPN 的单向信息流与静态融合方法<sup>[19]</sup>,BiFPN 通过双向跨尺度交互机制,显著优化了玉米病害图像中局部纹理细节与全局语义信息的协同表达。传统 FPN 通过自上而下的路径进行不同尺度的特征融合,而 BiFPN 则引入了双向的信息流动机制,既支持自上而下的融合,也支持自下而上的信息传递。这种双向特征融合方式不仅加强了特征在不同尺度之间的交互,还有效提升了多尺度目标的检测性能。传统特征融合方法需将不同分辨率特征调整为相同尺寸再融合,易因分辨率差异导致融合特征失衡。BiFPN 的加权融合机制中,引入了一种名为快速归一化融合的方法,该方法旨在提升训练效率。具体而言,BiFPN 并未采用 Softmax 进行归一化,它通过将权重值归一化到  $[0, 1]$  区间,从而加速了训练过程。BiFPN 通过

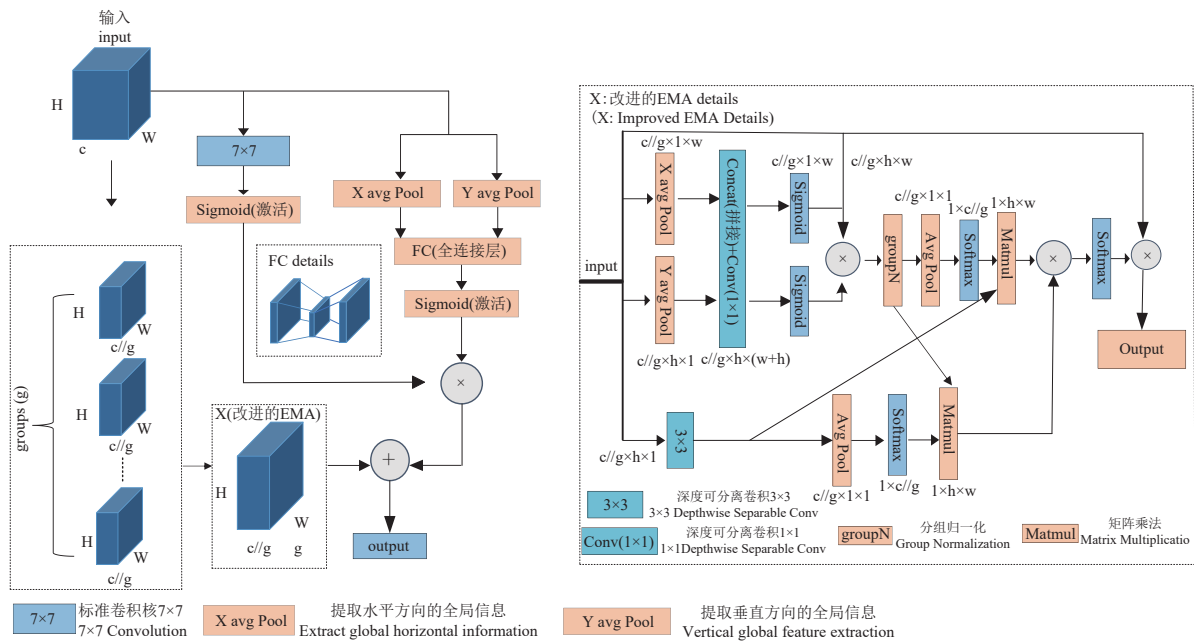


图9 MCSA 注意力机制  
Fig. 9 MCSA attention mechanism

引入跳跃连接和双向通道,实现了跨尺度特征的双向融合。本文模型提取 Stage(1-4)四个阶段层进行 BiFPN 融合,其结构如图 10 所示,橙色为高层特征,如 Stage 4 向低层传递病害类别与整体轮廓等语义信息;深蓝色是低层特征,如 Stage 1 向高层传递边缘、纹理等位置细节;灰白色是横向跨层连接,复用输入特征减少信息丢失,抑制多次采样导致的细节损失并加速梯度传播。




图 10 BiFPN 结构图  
Fig. 10 BiFPN structure diagram

## 2 实验结果与分析

### 2.1 模型训练环境与训练参数

本研究模型训练和测试的环境:64 位的 Windows10 操作系统;处理器 Intel(R)Core i5-9th Gen;显卡采用 NVIDIA GeForce RTX-3090,

显存为 12 GB;深度学习框架 pytorch,python 版本为 3.8;计算框架采用 Cuda11.8 版本。在训练之前,综合考虑图像样本的数量和计算机的硬件条件,设置批处理大小(batch size)为 32,模型迭代次数(epoch)为 100 次。使用 Adam 优化器,初始学习率 0.001,选取 ReLU 作为主要的激活函数。

### 2.2 模型评价指标

在农作物病虫害识别领域,使用定量评价指标可以帮助分析研究过程中存在的问题,从而优化模型结构并提升其性能。常用的评估指标包括查准率(Precision)、召回率(Recall)、准确率(Accuracy)和 F1 分数四个关键参数。

在训练模型进行分类识别时,通常将输入样本划分为四类,这四类变量在混淆矩阵中有所定义:TP(True Positive)指真实值为正且预测值也为正的样本数量;TN(True Negative)指真实值为负且预测值也为负的样本数量;FP(False Positive)指真实值为负但预测值为正的样本数量;FN(False Negative)指真实值为正,但预测值为负的样本数量。根据这些值可以计算出深度学习中的四个主要评价指标:

查准率(precision):是指所有预测值为正的样本中,真实值也为正的样本所占的比例,查准

率越高,表明模型的预测性能越好,如公式(6)所示。

$$P = \frac{TP}{TP + FP} \times 100\% \quad (6)$$

召回率(recall):在所有真实值为正的样本中,其中预测值为正的样本所占的比例,和查准率一样,召回率越高,表明模型的预测性能越好,如公式(7)所示。

$$R = \frac{TP}{TP + FN} \times 100\% \quad (7)$$

准确率(accuracy):预测完全正确的样本占总样本的比例,准确率通常用来评估深度学习模型的分类识别准确率,如公式(8)所示。

$$Acc = \frac{TP + TN}{TP + FN + TN + FP} \times 100\% \quad (8)$$

F1值(F1-score):通过计算精确率和召回率的调和平均数来评估模型的整体性能。F1值越高,说明模型在平衡精确率和召回率方面的能力越强,因此它常被用作衡量模型综合表现的重要指标,如公式(9)所示。

$$F1 - score = 2 \times \frac{P \times R}{P + R} \times 100\% \quad (9)$$

### 2.3 对比实验

2.3.1 不同卷积对比实验分析 为了验证深度可分离卷积的优势,研究选取了多种主流卷积方法进行了对比实验,包括 StdConv、GroupConv、

DilatedConv、DeformableConv、DynamicConv 和 DepthSepConv,如表 2 所示。实验主要从查准率(precision)、召回率(Recall)、F1 分数(F1-score)、准确率(Accuracy)、参数量、浮点计算量(FLOPs)几个方面进行评估。首先在查准率、召回率、F1 分数、准确率,深度可分离卷积表现最佳,分别达到了 97.58%、97.47%、97.49% 和 97.47%,优于所有其他卷积方法。在计算效率上,虽然 DepthSepConv 的浮点计算数为 5.56 G,略高于 GroupConv 和 DynamicConv,但仍保持在较低水平。它在提供高精度的同时,保持了相对较好的计算效率,适合在计算资源有限的环境中使用。在参数量上 DepthSepConv 的参数量为 2.53 M,远低于 StdConv 的 10.72 M,同时在 DynamicConv 和 DeformableConv 中也相对较少。这表明 DepthSepConv 在保持模型轻量化方面具有显著优势,适合对模型大小敏感的应用场景,其次,在减少参数量的同时并未降低模型性能,反而在效率和效果之间达到了最佳平衡。因此,DepthSepConv 是参数量优化方面的首选方法。综合来看 DepthSepConv 在多方面展现了其优势,通过平衡计算复杂度和参数量,提升了识别精度,同时保持了良好的计算效率。这使得 DepthSepConv 成为需要高准确率识别的应用场景中的理想选择。

表 2 不同卷积核的对比实验

Table 2 Comparative experiment of different convolution kernels

卷积 Conv	查准率/% Precision	召回率/% Recall	F1 分数/% F1-score	准确率/% Accuracy	参数量/M Parameters	浮点计算量/ GFLOPs
StdConv	94.90	94.85	94.83	94.85	10.72	32.26
GroupConv	95.03	94.95	94.92	94.95	1.11	3.18
DilatedConv	91.82	91.74	91.70	91.74	8.65	25.99
DeformableConv	95.54	95.53	94.50	95.54	1.32	15.73
DynamicConv	95.65	95.58	95.62	95.64	1.85	5.29
DepthSepConv	97.58	97.47	97.49	97.47	2.53	5.56

2.3.2 不同注意力机制对比实验 为了验证本研究中 MCSA 机制的有效性,在每个阶段网络后的相同位置分别加入主流 EMA、ECA、SE、CBAM、MCSA 机制进行对比。MCSA 机制与主流注意力机制在模型性能方面的对比情况如图 11 所示。从图中可以看出,在准确率方面,MCSA 达到了 97.52%,相较于无注意力机制的基准模型提升了 1.89%,同时也优于其他几种注

意力机制,表明其能够更有效地捕捉特征信息,增强模型对关键特征的关注能力,从而提高分类准确率。在浮点计算量方面,MCSA 的 FLOPs 为 5.56 G,略高于 EMA、ECA、CBAM 和 SE。这表明虽然 MCSA 引入了一定的计算开销,但仍在可接受范围内,并且其带来的准确率提升足以弥补这一开销。在参数量方面,MCSA 的参数量为 2.53 M,较其他注意力机制略高,但整体仍处于

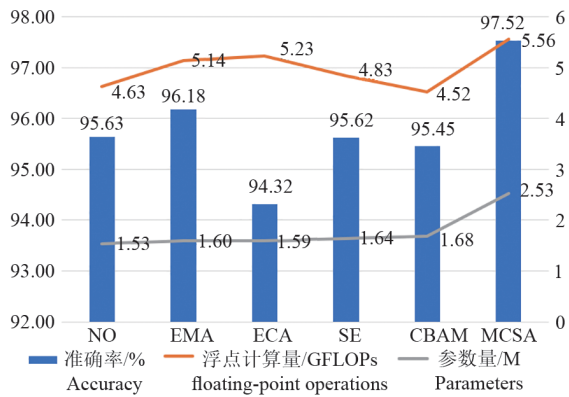


图 11 不同注意力机制对比实验图

Fig. 11 Comparison experiment of different attention mechanisms

较低水平,说明其在增加模型容量的同时并未造成参数量的大幅膨胀,有助于保持模型的轻量化和高效性。综合来看,MCSA在玉米叶片病害识别任务中,在准确率、计算复杂度和参数量方面展现出独特的优势,应用前景广阔。

2.3.3 基线网络对比实验 本研究通过对比 AlexNet<sup>[20]</sup>、GoogleNet<sup>[21]</sup>、ResNet50、MobileNetv2<sup>[22]</sup>、EPSANet<sup>[23]</sup>和 PPLC-Net<sup>[24]</sup>等主流模型,所选模

型覆盖标准卷积网络、残差结构、轻量化设计及注意力机制等关键架构,旨在从基础性能、效率优化及前沿技术多维度验证本文方法的综合优势,系统评估了DB-DAB-Net在玉米病害识别任务中的性能表现。如表3所示,DB-DAB-Net在精确度、召回率、F1分数和准确率均显著优于对比模型,分别达到了97.58%、97.47%、97.49%和97.47%,较PPLC-Net的准确率提升1.26个百分点,较主流模型GoogleNet的准确率提升2.09个百分点,验证了模型在复杂背景下对病害特征的精准捕捉能力。在模型效率方面,DB-DAB-Net参数量仅2.53 M,较MobileNetv2压缩25.5%,极大降低了存储需求;其计算量虽略高于AlexNet等轻量模型,但与ResNet50、PPLC-Net处于同一量级,通过动态注意力机制实现了精度与效率的平衡。如图12所示,训练损失与验证损失持续下降且后期趋于平稳,表明模型未出现过拟合且具备强泛化能力;模型的训练过程表现出优异稳定性,训练与验证准确率同步上升并最终收敛于96%以上。混淆矩阵如图13所示,在“Gray leaf spot”、“Healthy”和“Northern Leaf Blight”类别中

表3 不同网络的比较结果

Table 3 Comparison results of different networks

网络	查准率/%	召回率/%	F1分数/%	准确率/%	参数量/M	浮点计算量/
Network	Precision	Recall	F1-score	Accuracy	Parameters	GFLOPs
AlexNet	94.26	94.13	94.20	94.13	14.59	2.34
GoogleNet	95.64	95.38	95.51	95.38	10.32	1.58
ResNet50	96.33	96.29	96.24	96.29	23.52	4.13
MobileNetv2	94.93	94.84	94.73	94.84	3.40	0.33
EPSANet	96.15	95.93	96.10	95.93	22.56	3.64
PPLC-Net	96.32	96.21	96.29	96.21	26.03	4.14
DB-DBA-Net	97.58	97.47	97.49	97.47	2.53	5.56

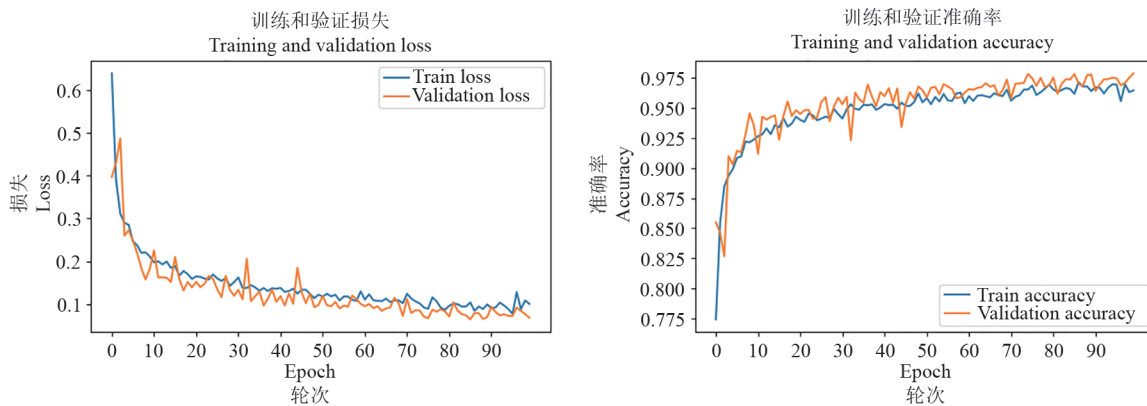


图 12 训练损失和验证损失(左图)和训练准确率和验证准确率(右图)

Fig. 12 Training loss and validation loss (left figure) and training accuracy and validation accuracy (right figure)

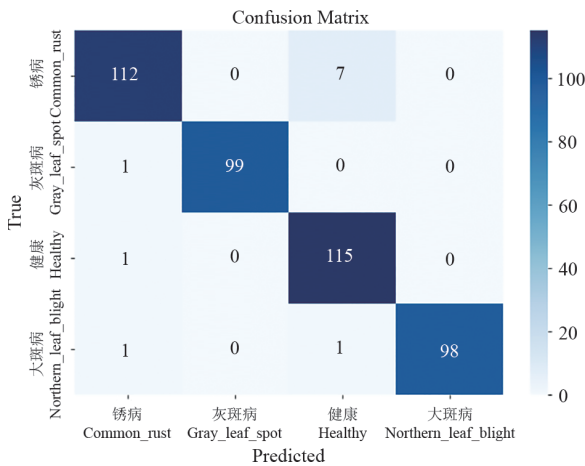


图 13 DB-DAB-Net 的混淆矩阵图

Fig. 13 Confusion matrix diagram of DB-DAB-Net

准确率均超 97%，仅“Common rust”存在少量误判，这主要与特征相似性相关，为后续针对性优化指明了方向。实验表明，DB-DAB-Net 通过减少参数数量和计算量的设计与高效特征融合策略，在保持最高分类精度的同时，显著优于参数量大或性能不足的对比模型，为农业边缘设备提供兼具高鲁棒性与实时诊断能力的端到端解决方案<sup>[25]</sup>，具有突出的田间应用价值。

### 2.4 消融实验

为了验证 DB-DBA-Net 网络模型的设计有效性，本研究针对其核心组件——双分支特征提取结构、深度可分离卷积、MCSA 模块以及 BiFPN 模块——开展消融实验。实验通过控制变量法，依次测试单一模块、关键两两组合及渐进式叠加的协同效应，已覆盖模块间的主要交互

场景，避免冗余组合对结论的干扰<sup>[26]</sup>。实验在统一训练环境与固定超参数配置下进行，并采用准确率 (Accuracy)、模型参数量 (Parameters) 及浮点计算量 (FLOPs) 作为量化评估指标。消融实验结果如表 4 所示，Model 1 为未添加任何模块的原始模型。Model 2 (使用深度可分离卷积)，准确率降至 94.48%，相比完整模型的 97.47% 显著下降，但参数量从 2.53 M 降至 0.72 M，浮点运算量大幅减少。这表明深度可分离卷积能有效降低计算成本和参数量，但单独使用会牺牲模型的表达能力和特征提取能力。Model 3 (使用双分支结构)，准确率为 94.80%，略高于 Model 2，表明双分支结构在一定程度上提升了模型的特征提取能力，但单独使用时效果有限。Model 5 (使用 BiFPN)，准确率为 94.94%，参数量为 4.30 M，浮点计算量为 13.09 G，相比完整模型准确率有所下降，但参数量和计算量显著增加，表明了 BiFPN 在特征融合方面具有优势，但单独使用时会增加模型的复杂度。从 Model 6 到 Model 9 (依次增加模块) 的实验结果可以看出，随着不同模块的组合使用，模型的准确率逐渐提升，同时参数量和浮点计算量也在一定程度上得到平衡。Model 6 结合了深度可分离卷积和双分支结构，准确率为 95.52%。而完整模型 (DB-DBA-Net) 则综合了所有模块的优势，在准确率、参数量和浮点计算量之间取得了最佳平衡，达到了 97.47% 的准确率，参数量为 2.53 M，浮点计算量为 5.56 G，使 DB-DAB-Net 在玉米病害识别任务中表现出色，同时保持模型的轻量化和高效性。

表 4 不同模型的消融实验比较结果

Table 4 Comparison results of different models for ablation experiments

模型 Model	深度可分离卷积 Depthwise separable convolution	双分支结构 Dual-branch structure	MCSA	BiFPN	准确率/% Accuracy	参数量/M Parameters	浮点计算量/ GFLOPs
Model 1	×	×	×	×	94.03	4.18	12.72
Model 2	√	×	×	×	94.48	0.72	2.25
Model 3	×	√	×	×	94.80	1.47	4.46
Model 4	×	×	√	×	96.01	4.32	12.94
Model 5	×	×	×	√	94.94	4.30	13.09
Model 6	√	√	×	×	95.52	1.47	4.46
Model 7	√	×	√	×	95.22	4.32	12.94
Model 8	×	√	√	×	94.03	1.61	4.68
Model 9	√	√	×	√	94.20	1.59	4.83
DB-DBA-Net	√	√	√	√	97.47	2.53	5.56

### 3 结论

玉米产量的一个主要挑战是病害的威胁。由于其卓越的分类识别性能,卷积神经网络(CNN)在农作物病害识别领域得到了广泛应用,而为了提高特征融合和特征提取能力,在卷积神经网络里引入注意力机制。本研究提出了一种新型的卷积神经网络DB-DAB-Net。通过对比度增强、模糊和噪声添加等方法对玉米病害数据集进行了扩展,从最初的3 919张图像扩充至7 830张。该网络通过创建双分支特征提取网络,在双分支里引入深度可分离卷积,使得模型的参数量和计算量大幅度减少,并通过堆叠双分支网络,使得网络能够在深层次提取更加丰富的特征信息。为了进一步提升模型对多尺度特征的融合能力,在每个stage后引入MCSA机制,最后通过BiFPN进行特征融合。实验数据表明该模型在玉米病害数据集上具有卓越的识别性能,模型的验证准确率达到97.47%,明显超越了EPSANet、AlexNet、GoogleNet、MobileNetv2等传统深度学习模型,证明了其良好的鲁棒性和泛化能力。通过在卷积模块、注意力机制和整体架构上的多重改进,新的玉米叶片病害识别网络在识别的精确度和效率上实现了显著提升,同时有效降低了计算复杂度和参数量。这些优化使其在实际应用中更具竞争力,尤其在资源受限的移动端设备上部署时展现出优势。

#### 参考文献

- [1] 张辉.施用污泥和秸秆堆肥对盐碱土壤理化性质的影响研究[J].大众科技,2025,27(01):68-70+91.
- [2] 单长林,李孝军,周圆,等.进境玉米穗腐病菌的分离鉴定[J].植物病理学报,2024,54(04):852-856.
- [3] 熊诗洁.花椒精油及其主要成分对番茄果腐病的抑制及机理[D].荆州:长江大学,2024.
- [4] 蔡广兴,王丽娟,刘可杰,等.玉米农家品种对玉蜀黍尾孢菌引起的灰斑病抗性鉴定[J].辽宁农业科学,2025(02):69-71.
- [5] Mehta S, Kukreja V, Gupta A. Revolutionizing maize disease management with federated learning CNNs: A decentralized and privacy-sensitive approach[C]. 2023 4th International Conference for Emerging Technology (INCET). IEEE, 2023:1-6.
- [6] 马春悦,郭秀茹,王琛,等.一种基于改进ResNet18神经网络的玉米叶片病害识别方法[J].山东农业大学学报(自然科学版),2024,55(03):356-366.
- [7] 曾鹏滔,撒金海,刘嘉.基于改进ResNet18的玉米叶片病害识别方法[J].内蒙古农业大学学报(自然科学版),2023,44(06):60-67.
- [8] Ramadan S T Y, Sakib T, Jahangir R, et al. Maize leaf disease detection using vision transformers(ViTs) and CNN-Based classifiers: Comparative analysis[C]. International Conference on Human-Centric Smart Computing. Singapore: Springer Nature Singapore, 2023:513-524.
- [9] Amrani A, Sohel F, Diepeveen D, et al. Insect detection from imagery using YOLOv3-based adaptive feature fusion convolution network[J]. Crop and Pasture Science, 2022, 6: 615-627.
- [10] 李新科,毛含莹,孙玉瑾,等.基于DCNN的水稻叶瘟病检测与取样装置设计实现[J].电子制作,2025,33(06):36-41.
- [11] 党宏社,肖利霞,张选德.不良光照场景下的交通标志识别算法[J].半导体光电,2025,46(01):142-148.
- [12] 戴佩玉,张欣,毛星,等.利用空间-光谱双分支特征和动态选择的高光谱影像农作物分类[J].农业工程学报,2023,39(16):160-170.
- [13] 骆津津,陈伟,田子建,等.基于YOLOv8-ECW的井下人员行为实时检测算法[J].矿业科学学报,2025,10(02):316-327.
- [14] Woo S, Park J, Lee JY, et al. Cbam: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision(ECCV), 2018:3-19.
- [15] 徐沁,梁玉莲,王冬越,等.基于SE-Res2Net与多尺度空谱融合注意力机制的高光谱图像分类[J].计算机辅助设计与图形学学报,2021,33(11):1726-1734.
- [16] Ni H, Shi Z, Karungaru S, et al. Classification of typical pests and diseases of rice based on the ECA attention mechanism[J]. Agriculture, 2023, 13(5): 1066.
- [17] Ouyang D, He S, Zhang G, et al. Efficient multi-scale attention module with cross-spatial learning[C]. ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2023:1-5.
- [18] Chen J, Mai HS, Luo L, et al. Effective feature fusion network in BIFPN for small object detection[C]. 2021 IEEE international conference on image processing (ICIP). IEEE, 2021:699-703.
- [19] Qiu M, Huang L, Tang BH. ASFF-YOLOv5: Multielement detection method for road traffic in UAV images based on multiscale feature fusion[J]. Remote Sensing, 2022, 14(14): 3498.

- [20] Nawaz SA, Li J, Li D, et al. Medical image zero watermarking algorithm based on dual-tree complex wavelet transform, AlexNet and discrete cosine transform [J]. Applied Soft Computing, 2025, 169:112556.
- [21] Subba AB, Sunaniya AK. Computationally optimized brain tumor classification using attention based GoogLeNet-style CNN[J]. Expert Systems with Applications, 2025, 260:125443.
- [22] Tanwar N, Turukmane AV. Modified MobileNetV2 transfer learning model to detect road potholes[J]. PeerJ Computer Science, 2025, 11:e2519.
- [23] Liu H, Dou Y, Wang K, et al. A skin disease classification model based on multi scale combined efficient channel attention module[J]. Scientific Reports, 2025, 15(1):6116.
- [24] Dai G, Fan J, Tian Z, et al. PPLC-Net: Neural network-based plant disease identification model supported by weather data augmentation and multi-level attention mechanism[J]. Journal of King Saud University-Computer and Information Sciences, 2023, 35(5):101555.
- [25] 代国威. 基于多层次深度学习的马铃薯叶片病害诊断模型构建与优化[D]. 北京:中国农业科学院, 2024.
- [26] 李广睿, 刘琼, 张熠卿, 等. 面向安检 X 光图像的违禁物品语义分割与识别研究[J]. 电子测量与仪器学报, 2024, 38(02):1-9.