

基于多层信息融合和显著性特征增强的农作物病害识别

杜海顺^{1,2} 张春海¹ 安文昊¹ 周毅^{1,2} 张镇¹ 郝欣欣¹

(1. 河南大学人工智能学院, 郑州 450046; 2. 河南省车联网协同技术国际联合实验室, 郑州 450046)

摘要: 现有基于深度学习的农作物病害识别方法对网络浅层、中层、深层特征中包含的判别信息挖掘不够,且提取的农作物病害图像显著性特征大多不足,为了更加有效地提取农作物病害图像中的判别特征,提高农作物病害识别精度,提出一种基于多层信息融合和显著性特征增强的农作物病害识别网络(Crop disease recognition network based on multi-layer information fusion and saliency feature enhancement, MISF-Net)。MISF-Net主要由ConvNext主干网络、多层信息融合模块、显著性特征增强模块组成。其中,ConvNext主干网络主要用于提取农作物病害图像的特征;多层信息融合模块主要用于提取和融合主干网络浅层、中层、深层特征中的判别信息;显著性特征增强模块主要用于增强农作物病害图像中的显著性判别特征。在农作物病害数据集AI challenger 2018及自制数据集RCP-Crops上的实验结果表明,MISF-Net的农作物病害识别准确率分别达到87.84%、95.41%,F1值分别达到87.72%、95.31%。

关键词: 农作物; 病害识别; 多层信息融合; 显著性特征; 神经网络

中图分类号: TP181

文献标识码: A

文章编号: 1000-1298(2023)07-0214-09

OSID:



Crop Disease Recognition Based on Multi-layer Information Fusion and Saliency Feature Enhancement

DU Haishun^{1,2} ZHANG Chunhai¹ AN Wenhao¹ ZHOU Yi^{1,2} ZHANG Zhen¹ HAO Xinxin¹

(1. School of Artificial Intelligence, Henan University, Zhengzhou 450046, China

2. International Joint Laboratory for Cooperative Vehicular Networks of Henan, Zhengzhou 450046, China)

Abstract: Crop disease recognition is a prerequisite for rational pesticide application and a powerful guarantee for promoting healthy and stable agricultural development. Existing deep learning-based crop disease recognition methods mainly use classical networks such as VGG and ResNet or networks that use attention mechanisms for disease recognition. Although these deep learning-based crop disease recognition methods have achieved better disease recognition results than traditional methods, they do not sufficiently mine the discriminative information contained in the shallow, middle and deep features of networks, and most of the extracted saliency features of crop disease images are insufficient. To extract discriminative features in crop disease images more effectively and improve crop disease recognition accuracy, a crop disease recognition network based on multi-layer information fusion and saliency feature enhancement (MISF-Net) was proposed. Specifically, MISF-Net mainly consisted of a ConvNext backbone network, a multi-layer information fusion module (MIFM), and a saliency feature enhancement module (SFEM). The ConvNext backbone network was mainly used to extract features of crop disease images. The multi-layer information fusion module was mainly used to extract and fuse the discriminative information from the shallow, medium and deep layers of the backbone network. The saliency feature enhancement module was mainly used to enhance the saliency discriminative features in crop disease images. The experimental results on the crop disease dataset AI challenger 2018 and the homemade dataset RCP-Crops showed that the crop disease recognition accuracies of MISF-Net reached 87.84% and 95.41%, and the F1 values reached 87.72% and 95.31%, respectively.

Key words: crop; disease recognition; multi-layer information fusion; saliency feature; neural network

收稿日期: 2023-03-25 修回日期: 2023-05-08

基金项目: 国家自然科学基金项目(62176088)和河南省科技发展规划项目(222102110135)

作者简介: 杜海顺(1977—),男,教授,博士,主要从事计算机视觉、模式识别和机器学习研究,E-mail: jddhs@vip.henu.edu.cn

0 引言

我国作为农业大国,粮食产量稳居世界首位。粮食丰收的前提是农作物的健康成长,而农作物病害是造成农产品产量和品质下降的重要原因^[1]。合理施用农药是防治农作物病害的主要手段,而合理施用农药的前提是准确识别农作物病害的类型^[2]。传统农作物病害识别主要靠农民凭经验进行。受专业知识的限制,农民常常对一些农作物病害无法判断或误判,从而使农作物病害难以得到准确及时的防治。因此,若能及时准确地识别农田中出现的农作物病害,不仅可以减少农药化肥的使用,降低生产成本、节约资源,而且可以减少化学污染、保护环境,进一步增加农民的收入,提高农产品的产量与品质,推动国家农业现代化的进程。

20 世纪 80 年代以来,国内外学者在农作物病害图像识别方面展开了诸多研究,提出许多传统的农作物病害图像识别方法^[3-9]。例如,张燕等^[3]提出了一种基于核相互子空间法的番茄病害快速识别模型。该模型通过将叶部病害图像的颜色及纹理特征映射到高维空间进行主成分分析,建立非线性病害特征空间,并基于非线性特征空间的最小正则角实现了番茄病害识别。虽然这些传统病害识别方法大多已经用于实践,但是它们过于依赖病斑分割的效果和特征设计的质量,从而无法满足现代农业生产对农作物病害准确识别的需求。

近年来,随着人工智能技术的快速发展,国内外学者开始尝试采用卷积神经网络对农作物病害进行识别^[10-12]。例如,赵恒谦等^[10]对 VGG16 和 ResNet 网络进行分步迁移训练,取得了较好农作物病害识别效果。刘洋等^[11]通过对 MobileNet 和 Inception V2 2 种轻量级卷积神经网络的迁移学习,得到 2 种作物病害识别模型并将它们分别移植到 Android 手机端,实现了识别精度、运算速度以及网络尺寸之间的平衡。虽然这些方法在农作物病害识别方面取得了较好的效果,但是它们都没有对网络提取的特征做进一步处理,也没有引导网络去关注更具判别力的显著性特征。为了解决这一问题,一些学者通过在网络中引入注意力机制或特征融合策略来改善农作物病害识别精度^[13-23]。例如,黄林生等^[13]提出一种多尺度卷积结构与注意力机制结合的农作物病害识别模型,不仅通过引入 Inception 模块对不同尺度的病害特征进行提取,提高了特征的丰富度,还通过在残差结构中引入注意力模块,增强了网络对显著性特征的提取能力。于明等^[14]提出了一种基于颜色掩膜和通道自适应自注意力机制的农作物病害识

别网络,根据叶片颜色变化、病斑范围与病斑间的位置关系,有效地提取了叶片病害颜色和位置特征,实现了农作物叶部病害的识别。姜红花等^[21]提出了一种基于 ResNet18 的苹果叶部病害分类模型,通过引入空间和通道注意力机制,来增强网络对显著性特征的提取,从而提高识别精度;还通过采用随机裁剪分支来扩充样本,训练网络模型,达到了更好的分类效果。虽然这些方法通过在网络中使用注意力机制来提取农作物病害图像的显著性特征,取得了较好的病害识别效果,但是这些方法提取的病害图像显著性特征大多不足,且对网络不同层特征中包含的判别信息挖掘不够。

为了更加有效地提取农作物病害图像中的判别特征,提高农作物病害识别精度,本文提出一种基于多层信息融合和显著性特征增强的农作物病害识别网络(MISF-Net)。MISF-Net 主要由 ConvNext^[24]主干网络、多层信息融合模块(Multi-layer information fusion module, MIFM)以及显著性特征增强模块(Saliency feature enhancement module, SFEM)组成。其中 ConvNext 主干网络主要用于提取农作物病害图像的特征;MIFM 模块主要用于提取和融合主干网络浅层、中层、深层特征中的判别信息;SFEM 模块主要用于提取和增强农作物病害图像中的显著性特征。

1 本文方法

本文提出的 MISF-Net 整体架构如图 1 所示。由图 1 可以看出,整体网络模型由 ConvNext 主干网络、多层信息融合模块(MIFM)以及显著性特征增强模块(SFEM)组成。

如图 1 所示,在训练阶段,首先对输入农作物病害图像进行随机裁剪、亮度与对比度调整等预处理;然后,将预处理的图像输入嵌入 SFEM 模块的 ConvNext 主干网络处理得到浅层特征图 F_1 、 F_2 ,中层特征图 F_3 及深层特征图 F_4 ;更进一步,将 F_1 、 F_2 、 F_3 、 F_4 输入多层信息融合模块,进一步提取和融合它们包含的判别信息,得到最终融合特征 F_m ;最后,将深层特征图 F_4 经全局平均池化处理得到的特征和融合特征 F_m 分别输入相应的全连接层 FC 处理得到输出预测值,同时采用交叉熵损失函数监督网络训练。在测试阶段,采用融合特征 F_m 作为农作物图像的最终特征。

1.1 多层信息融合模块

卷积神经网络浅层的感受野较小,其输出的特征图包含丰富的边缘、纹理、形状等细节信息。随着网络层数加深,感受野越来越大,其输出的特征图包




图 1 MISF-Net 基本框架

Fig.1 Basic framework of MISF-Net

含的抽象语义信息也越来越多。为了充分挖掘主干网络浅层、中层、深层特征图中包含的判别信息,本文设计 1 个多层信息融合模块 (MIFM),如图 2 所示。由图 2 可以看出,该模块主要由 2 个浅层信息处理模块 (Shallow information processing module, SIM)、1 个全局自适应平均池化操作 (Global adaptive average pooling, GAP) 和 1 个深层信息处理模块 (Deep information processing module, DIM) 组成。其中,2 个浅层信息处理模块分别用于处理主干网络 Layer1 和 Layer2 输出的浅层特征图 F_1 和 F_2 ,全局自适应平均池化操作用于处理主干网络 Layer3 输出的中层特征图 F_3 ,而深层信息处理模块用于处理主干网络 Layer4 输出的深层特征图 F_4 。




图 2 多层信息融合模块

Fig.2 Multi-layer information fusion module

(1) 浅层信息处理模块 (SIM)

如图 3 所示,浅层信息处理模块由 1 个自适应平均池化 Adp、1 个全连接层 FC 和 1 个 ReLU 激活函数组成。




图 3 浅层信息处理模块

Fig.3 Shallow information processing module

给定一个输入特征图 $F_s \in \mathbf{R}^{C \times H \times W}$ (C 、 H 、 W 分别表示特征图的通道数、高、宽),SIM 输出的特征 $A_s \in \mathbf{R}^{\frac{Ck^2}{r} \times 1}$ 可表示为

$$A_s = \delta(\mathbf{W}_1 \mathbf{R}_{\text{reshape}}(\text{Adp}_k(F_s))) \tag{1}$$

其中 $\mathbf{W}_1 \in \mathbf{R}^{Ck^2 \times \frac{Ck^2}{r}}$
式中 $\text{Adp}_k(\cdot)$ ——将尺寸为 $C \times H \times W$ 的特征图自适应平均池化为尺寸为 $C \times k \times k$ 的特征图函数
 $\mathbf{R}_{\text{reshape}}(\cdot)$ ——将尺寸为 $C \times H \times W$ 的特征图改变形状为 $C \times HW$ 的特征图函数

$\mathbf{W}_1$ ——全连接层权重
 r ——降维比
 $\delta(\cdot)$ ——ReLU 激活函数

首先将输入的浅层信息进行自适应平均池化处理得到 $C \times k \times k$ 的特征图,以保留更多的有助于病害分类的浅层信息;然后,采用全连接层对浅层信息进一步处理,以提取更具有判别力的病害图像特征。

(2) 深层信息处理模块 (DIM)

如图 4 所示,深层信息处理模块由 1 个通道池化操作 Cmp、1 个全局自适应平均池化层 GAP、1 个全连接层 FC 和 1 个 ReLU 激活函数组成。




图 4 深层信息处理模块

Fig.4 Deep information processing module

给定一个输入特征图 $F_d \in \mathbf{R}^{C \times H \times W}$,DIM 的输出特征 $A_d \in \mathbf{R}^{\frac{C}{n} \times 1}$ 可表示为

$$A_d = \delta(\mathbf{W}_2 \text{GAP}(\text{Cmp}_n(F_d))) \tag{2}$$

其中 $\mathbf{W}_2 \in \mathbf{R}^{\frac{C}{n} \times \frac{C}{r}}$
式中 $\text{Cmp}_n(\cdot)$ ——将特征图按通道顺序均分为 C/n 组后,对每组进行沿通道方向最大池化处理函数
 $\text{GAP}(\cdot)$ ——全局自适应平均池化
 $\mathbf{W}_2$ ——全连接层权重

在 DIM 中,通过通道池化 $\text{Cmp}_n(\cdot)$ 操作,对特征图的每 n 个通道沿通道方向进行最大池化处理,能够保留较多的重要深层语义信息。此外,采用全连接层对深度语义信息进一步处理,能够提取其中更具判别力的病害图像特征。

(3) 多尺度特征融合

将浅层特征图 F_1 和 F_2 经浅层信息处理模块 (SIM) 处理得到特征 A_1 和 A_2 , 中层特征图 F_3 经全局自适应平均池化操作处理得到 A_3 , 深层特征图 F_4 通过深层信息处理模块 (DIM) 处理得到 A_4 后,将它们进行拼接融合,得到的融合特征 F_m 为

$$F_m = \text{Cat}(A_1, A_2, A_3, A_4) \quad (3)$$

式中 $\text{Cat}(\cdot)$ ——通道维度上拼接函数

特别地,本文采用参数 $k=4$ 和 $r=4$ 的 SIM 来处理主干网络 Layer1 输出的浅层特征,采用参数 $k=2$ 和 $r=2$ 的 SIM 来处理主干网络 Layer2 输出浅层特征,采用参数 $n=2$ 和 $r=2$ 的 DIM 来处理由主干网络输出的深层特征。

1.2 显著性特征增强模块

显著性特征对农作物病害识别至关重要。为了增强农作物病害图像的显著性特征,设计 1 个显著性特征提取增强模块 (SFEM),如图 5 所示。




图 5 显著性特征增强模块

Fig.5 Saliency feature enhancement module

给定一个输入特征图 $F \in \mathbf{R}^{C \times H \times W}$, 首先对输入特征分别沿 H 维度和 W 维度进行平均池化得到 A_1, A_2 ; 然后, 分别对 A_1, A_2 进行二维卷积和 Sigmoid 激活操作后, 将得到的 2 个特征图对应元素相乘得到权重特征图 h ; 更进一步, 将权重特征图 h 与输入特征图 F 进行对应元素相乘得到显著性特征图, 将输入特征图 F 经 $\tanh$ 函数激活处理后的特征图与 $1-h$ 相乘得到非显著性特征图; 最后, 将显著性特征图与非显著性特征图进行拼接后再经过二维卷积处理, 得到增强后的显著性特征图 $F_A \in \mathbf{R}^{C \times H \times W}$ 。上述过程可公式化为

$C \times 1 \times 1$ 的卷积函数

由于深层特征的显著性信息更有益于农作物病害识别, 因此本文将显著性特征增强模块插入到主干网络的 Layer3 与 Layer4 之后, 如图 1 所示。

1.3 损失函数

如图 1 所示, 在训练阶段, 主干网络输出的特征 F_4 和多层信息融合模块输出的融合特征 F_m 分别输入相应的全连接层 FC, 得到相应的预测输出值。采用预测标签与真实标签的交叉熵损失来训练网络模型。综上, 模型的总损失为

$$L = \lambda L_{ce1} + L_{ce2} \quad (5)$$

式中 L_{ce1} ——融合特征分支预测标签与真实标签的交叉熵损失

L_{ce2} ——主干网络预测标签与真实标签的交叉熵损失

λ —— L_{ce1} 与 L_{ce2} 间的平衡参数

特别地, 在交叉熵损失函数中采用标签平滑策略来增强网络的泛化能力, 带标签平滑的交叉熵损失函数定义为

$$L_{cls} = - \sum_{n=1}^N \sum_{k=1}^K q_k^{(n)} \lg(p_k^{(n)}) \quad (6)$$

$$\begin{cases} A_1 = \text{Reshape}_1(g_W(F)) \\ A_2 = g_H(F) \\ h = \text{Sigmoid}(\text{Conv1}(A_1)) \otimes \text{Sigmoid}(\text{Conv1}(A_2)) \\ F_A = \text{Conv2}(\text{Cat}(h \times F, (1-h) \times \tanh(F))) \end{cases} \quad (4)$$

式中 $g_W(\cdot), g_H(\cdot)$ ——沿着宽和高维度进行平均池化

$\text{Reshape}_1(\cdot)$ ——将尺寸为 $C \times H \times W$ 的特征图改变形状为 $C \times W \times H$ 的函数

$\text{Conv1}(\cdot), \text{Conv2}(\cdot)$ —— $C \times C \times 1 \times 1, 2C \times$

其中

$$q_k^{(n)} = \begin{cases} \frac{\varepsilon}{K} & (y^{(n)} \neq k) \\ 1 - \varepsilon \frac{K-1}{K} & (y^{(n)} = k) \end{cases}$$

式中 N 、 K ——一个批次中的图像数量和类别数
 $q_k^{(n)}$ ——第 n 幅图像属于第 k 类的真实标签值
 $p_k^{(n)}$ ——第 n 幅图像预测为第 k 类的概率
 $y^{(n)}$ ——第 n 幅图像的真实标签值
 ε ——标签平滑系数

2 实验

2.1 数据集和相关设置

2.1.1 数据集

本实验在 AI challenger 2018 农作物病害数据集和自制 RCP - Crops 数据集上验证 MISF - Net 的有效性。2 个数据集的相关信息如表 1 所示。




图 6 AI challenger 2018 数据集中部分病害图像
Fig.6 Some disease images in AI challenger 2018 dataset

(2)RCP - Crops 数据集

RCP - Crops 数据集中的图像均在河南省信阳市固始县和新县的农田中拍摄。图像采集时间为 2022 年 3—10 月,采集装置为荣耀 v20 手机。采集对象为玉米、水稻、小麦、棉花和花生 5 种农作物。该数据集共包含花生褐斑病、玉米锈病、玉米小斑病、小麦白粉病、棉花网纹型枯萎病以及水稻




图 7 RCP - Crops 数据集中部分病害图像
Fig.7 Some disease images in RCP - Crops dataset

2.1.2 实验设置

本实验使用 PyTorch 深度开源框架实现,并在

表 1 AI challenger 2018 与 RCP - Crops 数据集信息统计

Tab.1 Information statistics of AI challenger 2018 and RCP - Crops datasets					
数据集	农作物 种类	总类 别数	病害 种类	受害程度	图像 数量
AI challenger 2018	10	59	26	一般、严重	36 258
RCP - Crops	5	28	25		1 665

(1)AI challenger 2018 数据集

该数据集共包含番茄、草莓、马铃薯、辣椒、桃、柑桔、葡萄、玉米、樱桃、苹果等 10 种农作物,划分了 59 种病害类别。其中,健康类别 10 种,病害类别 26 种。病害类别中有 23 种病害还分为一般和严重两种程度,如图 6 所示。该数据集是在原有公开数据集 Plant Village^[25] 的基础上,根据不同病害类型的病害程度进行更细的划分,同时也增加了新的农作物病害图像。该数据集共包含 36 258 幅图像,其中的 31 718 幅用于训练,4 540 幅用于测试。

叶黑粉病等 25 种农作物病害,共包含 1 665 幅图像。与 AI challenger 2018 数据集相比,RCP - Crops 数据集的训练样本数占比较低,这是由于农作物病害数据集采集的时间成本和投入成本较高,为了实现高效训练,将其中的 1 011 幅用于训练,654 幅用于测试。该数据集部分图像如图 7 所示。

搭载 i7 - 10700F CPU 和 NVIDIA 3090 GPU 的计算平台上训练。采用在 ImageNet 数据集^[26] 预训练的

ConvNext 作为主干网络。在训练阶段和测试阶段,所有图像的分辨率都调整为 224 像素 × 224 像素。在训练阶段,对所有训练图像进行裁剪、亮度和对比度随机转换、水平翻转等数据增强处理。采用权重衰减因子为 0.05 的 Adam 优化器训练网络,共训练 100 个周期,设置训练批次大小为 64。优化器的初始学习率设置为 5×10^{-4} ,并使用学习率预热策略。在训练过程中,优化器的学习率将在第 40、50、70 个周期分别减小为原来的 1/10。采用准确率和 F1 值作为评价指标。

2.2 与目前先进方法对比

为了验证 MISF-Net 的有效性,在 AI challenger 2018 公开数据集和 RCP-Crops 自制数据集上与其他方法进行了实验对比。

MISF-Net 与其他方法在 AI challenger 2018 数据集上的实验结果如表 2 所示。由表 2 可以得出,MISF-Net 的准确率、F1 值分别达到 87.84%、87.72%。相比于 GoogleNet,MISF-Net 在准确率上提升 1.48 个百分点,在 F1 值上提高 1.50 个百分点。相比于文献[13]方法,MISF-Net 在准确率上提升 1.37 个百分点,在 F1 值上提高 1.38 个百分点。这说明本文的 MISF-Net 能够更加精确地识别农作物病害。

表 2 MISF-Net 和目前先进方法在 AI challenger 2018 数据集上的性能对比

Tab.2 Performance comparison of MISF-Net and current state-of-the-art methods on AI challenger 2018 dataset			%
模型	准确率	F1 值	
VGG19 ^[27]	85.08	84.93	
GoogleNet ^[28]	86.36	86.22	
ResNet50 ^[29]	86.67	86.59	
DenseNet121 ^[30]	85.66	85.42	
MobileNet ^[11]	86.03	85.94	
TL-SE-ResNeXt-101 ^[18]	86.96	86.80	
文献[13]方法	86.47	86.34	
ConvNext ^[24]	85.83	85.71	
MISF-Net	87.84	87.72	

MISF-Net 与其他方法在 RCP-Crops 数据集上的实验结果如表 3 所示。由表 3 可以得出,MISF-Net 的准确率、F1 值分别达到 95.41%、95.31%。相比于 TL-SE-ResNeXt-101^[18],MISF-Net 在准确率上提升 1.83 个百分点,在 F1 值上提高 2.06 个百分点。相比于 ResNet50,MISF-Net 在准确率上提升 0.61 个百分点,F1 值提高 0.72 个百分点。这进一步说明了本文的 MISF-Net 可以实现农作物病害的高精度识别。

表 3 MISF-Net 与目前先进方法在 RCP-Crops 数据集上的性能对比

Tab.3 Performance comparison of MISF-Net and current state-of-the-art methods on RCP-Crops dataset			%
模型	准确率	F1 值	
ResNet50 ^[29]	94.80	94.59	
文献[13]方法	92.35	91.93	
TL-SE-ResNeXt-101 ^[18]	93.58	93.25	
ConvNext ^[24]	94.34	93.75	
MISF-Net	95.41	95.31	

2.3 消融实验与超参数分析

2.3.1 消融实验

为了评估 MIFM 和 SFEM 模块对模型整体性能的贡献,在 AI challenger 2018 数据集上进行了消融实验。采用 ConvNext 作为主干网络(Baseline),并在此基础上构建了 3 个网络:①Baseline + SFEM。②Baseline + MIFM。③Baseline + SFEM + MIFM。

消融实验结果如表 4 所示。从表 4 可以看出,相比于 Baseline,Baseline + SFEM 的准确率提高 1.11 个百分点,F1 值提高 1.06 个百分点。这说明 SFEM 模块能够有效地增强农作物病害图像中的显著性判别特征,进而提高网络的病害识别精度。与 Baseline 相比,Baseline + MIFM 的准确率提高 1.26 个百分点,F1 值提高 1.37 个百分点。这说明 MIFM 模块能够有效地提取和融合主干网络浅层、中层、深层特征中的判别信息,进而提高网络的性能。此外,与 Baseline 相比,Baseline + SFEM + MIFM 的准确率提升 2.01 个百分点,F1 值提高 2.01 个百分点。这充分说明在主干网络中同时加入 SFEM 和 MIFM 模块,可以显著地提高网络性能。

表 4 AI challenger 2018 数据集上的消融实验结果

Tab.4 Results of ablation experiments on AI challenger 2018 dataset				%
SFEM	MIFM	准确率	F1 值	
		85.83	85.71	
√		86.94	86.77	
	√	87.09	87.08	
√	√	87.84	87.72	

注:√表示在 Baseline 中加入对应模块。

2.3.2 超参数分析

MISF-Net 中只有损失函数平衡参数 λ 一个超参数。为了研究这个超参数的取值对网络整体性能的影响,在 AI challenger 2018 数据集上进行了实验,实验结果如图 8 所示。

由图 8 可以看出,随着损失函数平衡参数 λ 的增大,网络模型的准确率和 F1 值都呈先上升后下降




图 8 准确率和 F1 值随损失函数平衡参数 λ 的变化曲线

Fig.8 Accuracy and F1 value variation curves with balance parameter λ of loss function

的趋势,这表明了较小的损失函数平衡参数会过度强调 SFEM 模块作用,而较大的损失函数平衡参数又会过度强调 MIFM 模块作用。因此,当 $\lambda = 1$ 时效果最优。

2.4 模型混淆矩阵

根据 AI challenger 2018 数据集中 8 类共 353 幅农作物病害图像的识别结果,得到如图 9 所示的农作物病害分类混淆矩阵。

从图 9 可以看出,MISF-Net 的农作物病害种类识别效果很好,极少出现错误。虽然 MISF-Net 在识别农作物病害程度时也取得了很好的效果,但仍存在一些将农作物病害程度识别错误的现象。这可能是因为农作物病害程度不仅取决于病斑面积,还取决于病斑的颜色、分布等诸多因素,从而增加了病害程度的识别难度。为此,在今后将重点研究病斑部位的特征提取策略。

2.5 特征图可视化

图 10 为可视化的 Baseline 和 MISF-Net 提取




图 9 农作物病害分类混淆矩阵

Fig.9 Confusion matrix for crop disease classification

的农作物病害图像特征。从图 10 可以看出,虽然 Baseline 能够提取到病害图像的部分显著性信息,但是它对病斑部位的显著性信息提取不足,进而导致提取特征的判别力较弱。与 Baseline 相比,MISF-Net 能够提取到更多的显著性信息,从而取得了更高的病害识别精度。

3 结论

(1)为了充分挖掘 ConvNext 主干网络浅层、中层、深层特征中包含的判别信息,设计了一个多层信息融合模块,对主干网络的浅层、中层、深层特征进行提取和融合,得到了更具判别力的农作物病害特征表示。




图 10 特征图可视化

Fig.10 Visualization of feature maps

- (2)设计了一个显著性特征增强模块并将其插入在 ConvNext 主干网络的 Lyayer3 和 Layer4 之后,有效地增强了农作物病害图像中的显著性特征。
- (3)基于设计的多层信息融合模块和显著性增强模块,设计了一个端到端的农作物病害识别网络 MISF - Net,并分别在农作物病害数据集 AI challenger 2018 和自制数据集 RCP - Crops 上对其进行了测试。
- (4)在农作物病害数据集 AI challenger 2018 上,MISF - Net 的病害识别准确率和 F1 值分别达到 87.84% 和 87.72%,高于 ResNet50 (86.67%、86.59%) 和 TL - SE - ResNeXt - 101 (86.96%、86.80%)。在自制数据集 RCP - Crops 上,MISF - Net 的病害识别准确率和 F1 值分别达到 95.41% 和 95.31%,高于 ResNet50 (94.80%、94.59%) 和 TL - SE - ResNeXt - 101 (93.58%、93.25%)。

参 考 文 献

[1] 刘彬,杨选将,钟昌源,等. 基于实时农作物病害叶片语义分割模型的精准喷药智能小车[J]. 安徽科技学院学报, 2021, 35(3): 7 - 14.
LIU Bin, YANG Xuanjiang, ZHONG Changyuan, et al. Intelligent vehicle for precise spraying based on real-time semantic segmentation model of crop disease leaves[J]. Journal of Anhui Science and Technology University, 2021, 35(3): 7 - 14. (in Chinese)

[2] MANAVALAN R. Automatic identification of diseases in grains crops through computational approaches: a review [J]. Computers and Electronics in Agriculture, 2020, 178: 105802.

[3] 张燕,李庆学,吴华瑞. 基于核相互子空间法的番茄叶部病害快速识别模型[J]. 智慧农业(中英文), 2020, 2(3): 86 - 97.
ZHANG Yan, LI Qingxue, WU Huarui. Rapid recognition model of tomato leaf diseases based on kernel mutual subspace method[J]. Smart Agriculture, 2020, 2(3): 86 - 97. (in Chinese)

[4] 田凯,张连宽,熊美东,等. 基于叶片病斑特征的茄子褐纹病识别方法[J]. 农业工程学报, 2016, 32(增刊1): 184 - 189.
TIAN Kai, ZHANG Liankuan, XIONG Meidong, et al. Recognition of phomopsis vexans in solanum melongena based on leaf disease spot features[J]. Transactions of the CSAE, 2016, 32(Supp.1): 184 - 189. (in Chinese)

[5] SHRIVASTAVA V K, PRADHAN M K. Rice plant disease classification using color features: a machine learning paradigm[J]. Journal of Plant Pathology, 2021,103: 17 - 26.

[6] ZHANG Shanwen, WANG Haoxiang, HUANG Wenzhun, et al. Plant diseased leaf segmentation and recognition by fusion of superpixel, K-means and PHOG[J]. Optik, 2018, 157: 866 - 872.

[7] HLAING C S, ZAW S M M. Tomato plant diseases classification using statistical texture feature and color feature[C] // Proceedings of the IEEE/ACIS 17th International Conference on Computer and Information Science (ICIS), 2018: 439 - 444.

[8] 党满意,孟庆魁,谷芳,等. 基于机器视觉的马铃薯晚疫病快速识别[J]. 农业工程学报, 2020, 36(2): 193 - 200.
DANG Manyi, MENG Qingkui, GU Fang, et al. Rapid recognition of potato late blight based on machine vision [J]. Transactions of the CSAE, 2020, 36(2): 193 - 200. (in Chinese)

[9] 秦立峰,何东健,宋怀波. 词袋特征 PCA 多子空间自适应融合的黄瓜病害识别[J]. 农业工程学报, 2018, 34(8): 200 - 205.
QIN Lifeng, HE Dongjian, SONG Huaibo. Bag of words feature multi-PCA subspace adaptive fusion for cucumber diseases identification[J]. Transactions of the CSAE, 2018, 34(8): 200 - 205. (in Chinese)

[10] 赵恒谦,杨屹峰,刘泽龙,等. 农作物叶片病害迁移学习分步识别方法[J]. 测绘通报, 2021(7): 34 - 38.
ZHAO Hengqian, YANG Yifeng, LIU Zelong, et al. Step-by-step identification method of crop leaf diseases based on transfer learning[J]. Bulletin of Surveying and Mapping, 2021(7): 34 - 38. (in Chinese)

[11] 刘洋,冯全,王书志. 基于轻量级 CNN 的植物病害识别方法及移动端应用[J]. 农业工程学报, 2019, 35(17): 194 - 204.
LIU Yang, FENG Quan, WANG Shuzhi. Plant disease identification method based on lightweight CNN and mobile application [J]. Transactions of the CSAE, 2019, 35(17): 194 - 204. (in Chinese)

[12] 李森,王敬贤,李华龙,等. 基于 CNN 和迁移学习的农作物病害识别方法研究[J]. 智慧农业(中英文), 2019, 1(3): 46 - 55.
LI Miao, WANG Jingxian, LI Hualong, et al. Method for identifying crop disease based on CNN and transfer learning[J]. Smart Agriculture, 2019, 1(3): 46 - 55. (in Chinese)

[13] 黄林生,罗耀武,杨小冬,等. 基于注意力机制和多尺度残差网络的农作物病害识别[J]. 农业机械学报, 2021, 52(10): 264 - 271.
HUANG Linsheng, LUO Yaowu, YANG Xiaodong, et al. Crop disease recognition based on attention mechanism and multi-scale residual network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(10): 264 - 271. (in Chinese)

[14] 于明,李若曦,阎刚,等. 基于颜色掩膜网络和自注意力机制的叶片病害识别方法[J]. 农业机械学报, 2022, 53(8): 337 - 344.
YU Ming, LI Ruoxi, YAN Gang, et al. Crop diseases recognition method via fusion color mask and self-attention mechanism [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(8): 337 - 344. (in Chinese)

[15] 龙吟, 刘昌华, 孙开琼. 基于深度卷积神经网络的农作物病害识别[J]. 武汉轻工大学学报, 2020, 39(3): 17–22.
LONG Yin, LIU Changhua, SUN Kaiqiong. Crop disease identification based on deep convolutional neural network[J]. Journal of Wuhan Polytechnic University, 2020, 39(3): 17–22. (in Chinese)

[16] 鲍文霞, 孙庆, 胡根生, 等. 基于多路卷积神经网络的大田小麦赤霉病图像识别[J]. 农业工程学报, 2020, 36(11): 174–181.
BAO Wenxia, SUN Qing, HU Gensheng, et al. Image recognition of field wheat scab based on multi-way convolutional neural network[J]. Transactions of the CSAE, 2020, 36(11): 174–181. (in Chinese)

[17] RAHMAN C R, ARKO P S, ALI M E, et al. Identification and recognition of rice diseases and pests using convolutional neural networks[J]. Biosystems Engineering, 2020, 194: 112–120.

[18] 王东方, 汪军. 基于迁移学习和残差网络的农作物病害分类[J]. 农业工程学报, 2021, 37(4): 199–207.
WANG Dongfang, WANG Jun. Crop disease classification with transfer learning and residual networks[J]. Transactions of the CSAE, 2021, 37(4): 199–207. (in Chinese)

[19] 郭小燕, 于帅卿, 沈航驰, 等. 基于全局特征提取的农作物病害识别模型[J]. 农业机械学报, 2022, 53(12): 301–307, 379.
GUO Xiaoyan, YU Shuaiqing, SHEN Hangchi, et al. Deep learning network for crop disease recognition with global feature extraction[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(12): 301–307, 379. (in Chinese)

[20] XU Yanlei, KONG Shuolin, GAO Zongmei, et al. HLNet model and application in crop leaf diseases identification[J]. Sustainability, 2022, 14(14): 8915.

[21] 姜红花, 杨祥海, 丁睿柔, 等. 基于改进 ResNet18 的苹果叶部病害多分类算法研究[J]. 农业机械学报, 2023, 54(4): 295–303.
JIANG Honghua, YANG Xianghai, DING Ruiyou, et al. Identification of apple leaf diseases based on improved ResNet18[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(4): 295–303. (in Chinese)

[22] 孙道宗, 丁郑, 刘锦源, 等. 基于改进 SqueezeNet 模型的多品种茶树叶片分类方法[J]. 农业机械学报, 2023, 54(2): 223–230, 248.
SUN Daozong, DING Zheng, LIU Jinyuan, et al. Classification method of multi-variety tea leaves based on improved SqueezeNet model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2): 223–230, 248. (in Chinese)

[23] 李大湘, 滑翠云, 刘颖. 面向苹果叶部病害识别的细粒度蒸馏模型[J]. 农业工程学报, 2023, 39(7): 185–194.
LI Daxiang, HUA Cuiyun, LIU Ying. Identifying apple leaf disease using a fine-grained distillation model[J]. Transactions of the CSAE, 2023, 39(7): 185–194. (in Chinese)

[24] LIU Zhuang, MAO Hanzhi, WU Chaoyuan, et al. A ConvNet for the 2020s[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 11966–11976.

[25] HUGHES D P, SALATHÉ M. An open access repository of images on plant health to enable the development of mobile disease diagnostics through machine learning and crowdsourcing[J]. ArXiv: 1511.08060, 2015.

[26] DENG Jia, DONG Wei, SOCHER R, et al. ImageNet: a large-scale hierarchical image database[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2009: 248–255.

[27] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv preprint arXiv: 1409.1556, 2014.

[28] SZEGEDY C, LIU Wei, JIA Yangqing, et al. Going deeper with convolutions[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1–9.

[29] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770–778.

[30] HUANG Gao, LIU Zhuang, MAATEN L V D, et al. Densely connected convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2261–2269.