

基于 MobileNetV3Small - ECA 的水稻病害轻量级识别研究

袁培森¹ 欧阳柳江¹ 翟肇裕¹ 田永超^{1,2}

(1. 南京农业大学人工智能学院, 南京 210095; 2. 南京农业大学农学院, 南京 210095)

摘要: 为实现水稻病害的轻量化识别与检测, 使用 ECA 注意力机制改进 MobileNetV3Small 模型, 并使用共享参数迁移学习对水稻病害进行智能化轻量级识别和检测。在 PlantVillage 数据集上进行预训练, 将预训练得到的共享参数迁移到对水稻病害识别模型上微调优化。在开源水稻病害数据集上进行试验测试, 试验结果表明, 在非迁移学习下, 识别准确率达到 97.47%, 在迁移学习下识别准确率达到 99.92%, 同时参数量减少 26.69%。其次, 通过 Grad-CAM 进行可视化, 本文方法与其他注意力机制 CBAM 和 SENET 相比, ECA 模块生成的结果与图像中病斑的位置和颜色更加一致, 表明网络可以更好地聚焦水稻病害的特征, 并且通过可视化和各水稻病害分析了误分类原因。本文方法实现了水稻病害识别模型的轻量化, 使其能够在移动设备等资源受限的场景中部署, 达到快速、高效、便携的目的。同时开发了基于 Android 的水稻病害识别系统, 方便于在边缘端进行水稻病害识别分析。

关键词: 水稻病害识别; 迁移学习; 高效通道注意力机制; MobileNetV3Small; 移动端部署

中图分类号: TP391

文献标识码: A

文章编号: 1000-1298(2024)01-0253-10

OSID:



Lightweight Identification of Rice Diseases Based on Improved ECA and MobileNetV3Small

YUAN Peisen¹ OUYANG Liujiang¹ ZHAI Zhaoyu¹ TIAN Yongchao^{1,2}

(1. College of Artificial Intelligence, Nanjing Agricultural University, Nanjing 210095, China

2. College of Agriculture, Nanjing Agricultural University, Nanjing 210095, China)

Abstract: In order to realize the lightweight identification and detection of rice diseases, the ECA attention mechanism was used to improve the MobileNetV3Small model, and shared parameter transfer learning was used to carry out intelligent lightweight identification and detection of rice diseases. Pre-training was performed on the PlantVillage dataset, and the shared parameters obtained from the pre-training were transferred to the rice disease recognition model for fine-tuning and optimization. Experiments were on the open-source rice disease dataset. The experimental results showed that the recognition accuracy rate reached 97.47% under non-transfer learning, and 99.92% under transfer learning, while reducing the number of parameters by 26.69%. Secondly, the Grad-CAM was used for visualization. Compared with other attention mechanisms CBAM and SENET, the results generated by the ECA module were more consistent with the position and color of the disease spots in the image, indicating that the network can better focus on rice diseases. Characteristics, and the causes of misclassification were analyzed through visualization and each rice disease. The proposed method realized the lightweight of the rice disease recognition model, so that it can be deployed in resource-constrained scenarios such as mobile devices, and achieved the purpose of fast, efficient and portable. At the same time, an Android-based rice disease identification system was developed, which can facilitate the identification and analysis of rice diseases at the edge.

Key words: rice disease identification; transfer learning; ECA attention mechanism; MobileNetV3Small; mobile deployment

收稿日期: 2023-06-19 修回日期: 2023-08-27

基金项目: 国家自然科学基金项目(61502236)和江苏省农业科技自主创新资金项目(CX(21)3059)

作者简介: 袁培森(1980—), 男, 副教授, 博士, 主要从事智能数据处理与服务研究, E-mail: peiseny@njau.edu.cn

通信作者: 田永超(1975—), 男, 教授, 博士生导师, 主要从事作物生长遥感监测与作物精确管理研究, E-mail: yctian@njau.edu.cn

0 引言

水稻是我国第一大口粮作物^[1],有着悠久的种植历史,并且在全世界也有广泛种植,而我国也是世界水稻种植面积和产量最高的国家^[2]。随着水稻大面积种植,水稻病害^[3]成为了水稻产量下降的主要原因之一。“预防为主、综合防治”成为提高水稻产量的方法之一^[4]。表型组学(Phenomics)是生物学领域近年来迅猛发展的方向之一^[5],植物表型^[6](Plant phenotype)是通过观察植物生长过程中的各种形态和性状来区分健康植物和受到不同病原体侵袭植物的手段^[7]。

现有大多数水稻病害识别方法比较传统,传统植物表型检测依靠人工观察和测量,效率低,实时性差。传统的机器学习^[8-10]又严重依赖于特征提取,普适性差。深度学习^[11-13]是近年来图像识别领域重要的技术手段,利用深度学习技术对水稻病害图像进行识别,可以更有效地对表型数据进行分类和识别^[14]。近年来出现了许多优秀的基础神经网络,比如 VGG16^[15]、Xception^[16]等,这些卷积神经网络可以准确地识别水稻病害表型困难问题,但是早期的卷积神经网络很少考虑参数量和计算量,参数计算量过大导致传统网络已经无法满足需求^[17-18]。

轻量级神经网络^[19-21]识别方法能够快速、准确地识别水稻病害表型。常见的轻量级神经网络模型有 SqueezeNet^[22]、MobileNet^[23]、EfficientNet^[24]等。本文选择的网络是 MobileNet 系列中的 MobileNetV3Small, MobileNetV3^[25]是一种效率更高的轻量级卷积神经网络,该模型结合 MobileNetV1 和 MobileNetV2 模型的优势,进一步提高了模型精度。MobileNetV3 有 2 个版本,分别是 Large 和 Small。它们的整体结构一致,区别在于基本单元 Bottleneck 的数量以及内部参数设置。Small 版本适用于移动设备等资源受限的场景。由于 MobileNetV3Small 更加适合部署在资源受限的移动端上,因此本文选择 MobileNetV3Small。

本文提出一种用于水稻病害识别和检测的轻量级卷积神经网络 MobieNetV3Small - ECA。该网络基于 MobileNetV3Small 模型,并使用 ECA (Efficient channel attention) 注意力机制^[26]进行改进。MobileNetV3Small 具有较高的识别精度,在减少参数量和计算量的同时保持高精度,适合在资源受限的设备上应用。在 MobileNetV3Small 的基础上,引入 ECA 注意力机制,进一步提高识别精度,并减少参数量,适合在移动设备等资源受限的场景中部署。此外,使用迁移学习^[27-31]将 PlantVillage 数据集上

预训练的特征及参数迁移到水稻病害数据集上。

1 基于 MobileNetV3Small - ECA 的水稻病害识别系统框架及实现

1.1 系统框架

MobileNetV3Small - ECA 模型通过替换 SE (Squeeze-and-excitation) 注意力机制为 ECA 注意力机制来提高模型的性能表现。具体来说,可以定义一个新的卷积块,它基于 MobileNetV3Small 中的原始设计,但使用 ECA 注意力机制来替代原来的 SE 注意力机制。这样,在训练过程中,网络可以自适应地学习每个通道之间的相关性,并将其应用于每个特征图中的通道加权。

与 SE 注意力机制不同,ECA 注意力机制不涉及压缩 (Squeeze) 和激励 (Excitation) 操作,而是直接利用通道特征的相关性进行自适应加权。具体来说,ECA 通过计算不同通道之间的相对重要性,得到一个可学习的通道权重系数,并将其应用于输入特征图中的每个通道。

图 1 为本文搭建的 MobileNetV3Small - ECA 整体结构图。ECA 为图 1 中的虚线框部分,该模型主要创新点在于用 ECA 注意力机制取代 SE 注意力机制,避免了降维操作,可以减少参数量。




图 1 MobileNetV3Small - ECA 整体结构图

Fig. 1 MobileNetV3Small - ECA overall structure diagram

1.2 MobileNetV3Small

MobileNetV3Small^[25]是一种轻量级卷积神经网络架构,旨在实现更快速、更高效的移动端图像分类和目标检测。该模型相比于前两代模型,在准确率和速度之间有了更好的平衡。

1.2.1 MobileNetV3Small 网络结构

如表 1 所示,MobileNetV3Small 的总体架构包括 3 部分。第 1 部分和第 3 部分主要处理卷积和分类任务,而第 2 部分则进行深度可分离卷积和 SE 通道注意力机制的处理。这种架构使得 MobileNetV3Small 能够有效地在移动设备等纵向场景中运行,具有更快的速度和更低的能耗,适用于图像分类、目标检测、人脸识别等领域的应用。

表 1 MobileNetV3Small 特征提取网络参数

Tab. 1 Parameters of MobileNetV3Small network

参数	输入尺寸	输出尺寸
Input		224 × 224 × 3
Conv	224 × 224 × 3	112 × 112 × 16
Bottleneck	112 × 112 × 16	56 × 56 × 16
Bottleneck	56 × 56 × 16	28 × 28 × 24
Bottleneck	28 × 28 × 24	28 × 28 × 24
Bottleneck	28 × 28 × 24	14 × 14 × 40
Bottleneck	14 × 14 × 40	14 × 14 × 40
Bottleneck	14 × 14 × 40	14 × 14 × 40
Bottleneck	14 × 14 × 40	14 × 14 × 48
Bottleneck	14 × 14 × 48	14 × 14 × 48
Bottleneck	14 × 14 × 48	7 × 7 × 96
Bottleneck	7 × 7 × 96	7 × 7 × 96
Bottleneck	7 × 7 × 96	7 × 7 × 96
Conv	7 × 7 × 96	7 × 7 × 576
Pool	7 × 7 × 576	1 × 1 × 576
Conv	1 × 1 × 576	1 × 1 × 576
Conv	1 × 1 × 576	1 × 1 × 1 024

MobileNetV3Small 网络第 1 部分包括 1 个卷积层和 1 个批归一化层,在这里,输入数据将首先经过一个大小为 3×3 、步长为 2 和填充为 1 的卷积层。该卷积层可以理解为用于特征提取的滤波器,其作用是将图像进行卷积、抽取特征并减小图像体积。卷积操作会在图像的每个位置上重复执行,得到一组新的特征图。然后,这些特征图通过一个批归一化层进行标准化处理。批归一化主要是将每个特征图缩放到相同尺度,以便更高效地传递到下一层。

MobileNetV3Small 网络第 2 部分包括多个深度可分离卷积层和 1 个逐点卷积层。其中,深度可分离卷积层是 MobileNetV3Small 的核心组成部分,它采用深度卷积和逐点卷积。深度卷积可以看作是扩展特征通道的过程,而逐点卷积则可以简化计算量大的卷积过程。这样能使网络不仅快速而且准确。在 MobileNetV3Small 中,深度可分离卷积包括深度卷积和逐点卷积。深度卷积使用 1×1 的卷积核来扩张通道数量,逐点卷积则使用 3×3 的卷积核来实现特征提取。这些卷积核被设计的相对较小但功能强大,能够有效地降低网络的参数数量和计算量,提高网络的效率。在 MobileNetV3Small 中,每个深度可分离卷积层后面都跟随了一层逐点卷积层,这样做有助于精细化特征的提取。此外,MobileNetV3Small 还引入了 SE 通道注意力机制,以增强对不同特征通道的关注。

MobileNetV3Small 网络第 3 部分由 1 个平均池化层和 2 个全连接层组成。平均池化层的作用是

将特征图的每个通道进一步压缩,以得到更高级别的特征表示。全连接层则负责将特征图映射为输出类别,并用 Softmax 函数来计算各个分类的概率。

1.2.2 Bottleneck 结构

MobileNetV3Small 的核心在于 Bottleneck 层的设计,如图 2 所示,Bottleneck 层由通道可分离卷积-SE 通道注意力机制-残差连接组成。




图 2 Bottleneck 结构图

Fig. 2 Diagram of Bottleneck structure

在通道可分离卷积中,特征图的每个通道都被单独地进行卷积操作,以增加特征图的表示能力。具体而言,通道可分离卷积包括 DepthwiseConv2D 和 Conv2D 2 个操作,前者仅在每个输入通道上执行轻量级过滤器卷积,后者是一个正常的卷积操作,用于融合特征图的所有通道。这样可以大幅减少网络中需要学习的参数数量,从而使得模型更加轻量化。

SE 注意力机制是一种用于提高网络感受野的方法,它包括 Squeeze 和 Excitation。Squeeze 用于将特征图的每个通道压缩为一个标量,而 Excitation 利用全连接层对这些标量进行加权,以获得不同通道的重要性。在 MobileNetV3Small 中,SE 模块用于通道可分离卷积的输出,以增强网络表示能力。

残差连接是一种用于防止信息丢失的方法,它将模型某一层输入直接添加到较深层的输出中,从而将原始特征信息传递到后续层,并减轻梯度消失问题。在 MobileNetV3Small 中,Bottleneck 层与其输入之间存在残差连接,以保留重要信息并简化模型训练。

综上所述,MobileNetV3Small 中的 Bottleneck 层由通道可分离卷积、SE 通道注意力机制和残差连接组成,旨在提高模型表示能力、感受野和稳定性。

1.3 注意力机制改进

ECA 结构是一种轻量级的通道注意力机制,用于优化卷积神经网络中特征图的表达能力。相比 SE 结构,ECA 结构不需要降维,具有更快的速度和更少的参数。ECA 结构通过计算每个通道内的信息交互获得权重分布,从而使模型更加关注关键通道特征。

如图 3 所示,SE 结构需要压缩 (Squeeze) 和激励 (Excitation) 操作,如图 4 所示,ECA 注意力机制避免了降维操作并减少参数量。与 SE 注意力机制不同,ECA 注意力机制不涉及降维操作,而是直接利用通道特征的相关性进行自适应加权。




图 3 SE 结构图
Fig. 3 SE structure diagram




图 4 ECA 结构图
Fig. 4 ECA structure diagram

ECA 结构对每个通道内的特征进行一个全局的特征描述,然后使用 1 个一维卷积核对每个通道内的特征向量进行卷积,卷积结果通过 Sigmoid 函数进行归一化处理,并与原始特征向量按元素相乘,从而获得最终的加权特征向量。

与其他注意力机制相比,ECA 结构在提高特征表达能力的同时,能够降低计算复杂度和存储需求,适用于轻量级的卷积神经网络。

SE 注意力机制首先对输入特征图进行了通道压缩,而这样的压缩降维对于学习通道之间的依赖关系有不利影响,基于此理念,ECA 注意力机制避免降维,用一维卷积高效实现了局部跨通道交互,提取通道间的依赖关系。具体步骤如下:

(1)全局平均池化:将输入特征图进行全局平均池化,即将输入特征图 (H, W, C) 变成 $(1, 1, C)$ 。首先输入一个特征图 $U \in \mathbf{R}^{H \times W \times C}$,其中 H, W, C 分别表示输入的高度、宽度和通道数。然后通过 GAP 操作将 (H, W, C) 降到 $(1, 1, C)$,即

$$Z_c = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W U_c(i, j) \tag{1}$$

式中 U_c ——输入特征向量

Z_c ——输出特征向量

$U_c(i, j)$ ——特征图 U_c 的第 i 行、第 j 列元素

(2)计算自适应卷积核大小:通过 1 个全连接层计算得到 1 个自适应的卷积核大小,用于后续的卷积操作。即

$$k = \varphi(C) = \left\lfloor \frac{\log_2^C}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}} \tag{2}$$

式中 b ——自适应卷积核时偏置

γ ——缩放全局平均池化输出系数

k ——卷积核大小

φ ——映射函数

$\lfloor \cdot \rfloor_{\text{odd}}$ ——最近奇数对象

(3)权重计算:将自适应卷积核应用于一维卷积操作中,得到特征图中每个通道自适应的权重。进行卷积核大小为 k 的一维卷积操作,并经过 σ 激活函数得到各个通道权重 w ,计算公式为

$$w = \sigma(\text{Conv}_k(y)) \tag{3}$$

式中 y ——输入特征

Conv_k ——卷积核大小为 k 的一维卷积操作

(4)特征加权:将归一化的权重与原输入特征图逐通道相乘,获得加权后的特征图。这个加权操作可以增强模型对于重要特征的学习和提取。

总之,自适应全局池化自注意力机制通过自适应计算卷积核大小和通道权重,实现了对输入特征图中各个通道的动态关注和加权,从而增强了神经网络的特征学习和表示能力。

1.4 迁移学习

本研究使用 MobileNetV3Small - ECA 模型进行迁移学习,并应用于水稻病害图像的识别。首先,使用 PlantVillage 数据集,这是一个公开可用的图像数据集,目的是用于训练和测试机器学习模型在植物叶片疾病分类方面的性能。数据集共包含 38 154 幅图像,涵盖 15 种植物疾病以及其他健康叶片图像。为了扩充数据量和提高模型训练效果,该数据集经过数据增强处理,即对原始数据进行旋转、平移、翻转、缩放等操作。由于 PlantVillage 数据集是植物病害系列,与本文研究水稻病害数据集类似,所以本文选择该数据集进行迁移学习。

如图 5 所示,采用大型数据集作为网络预训练的源域,并将预训练得到的模型权重等信息迁移到对水稻病害数据集识别的模型上。通过利用已有的先验知识,可以在类似的识别任务中实现高效的处




图 5 水稻病害迁移学习示意图

Fig. 5 Schematic of rice disease transfer learning

理。在水稻病害图像训练的过程中,对模型中的参数进行微调,以得到最终的水稻病害识别模型。在水稻病害数据集的训练中,将提取到的特征输入分类器,对病害类别进行预测。最终,将网络的输出转换为适合于水稻病害分类任务的 4 类输出,实现对水稻病害任务的准确预测。

2 试验设计

2.1 试验环境

硬件环境为 Intel (R) Core (TM) i5 - 9300H CPU @ 2.40 GHz; 内存 20 GB; GeForce RTX1650 GPU 4 GB。软件环境为 Windows 10 操作系统、Python 3.8、TensorFlow 2.6.0 和 Keras 2.6.0。

2.2 数据集

本文使用的数据集是 4 类水稻病害的数据集 (<https://data.mendeley.com/datasets/fwcj7stb8r/1>), 这 4 类水稻病害在病斑或纹理特征上有明显的区别,包括斑点颜色、形状、分布等方面。选择这 4 类水稻病害作为研究对象是因为它们对水稻产量损失影响较大,研究这些病害可以有助于改进病害防治策略,保障粮食生产。此外,这 4 类病害也代表了水稻病害的多样性,涵盖了不同类型的病原体和病害机制。因此,通过研究这些病害,可以深入了解水稻病害的发病机理、传播途径以及潜在的防治方法,有助于提高水稻产量和质量。该水稻数据集包含 5 932 幅数字图像,包括白叶枯病、稻瘟病、褐斑病和东格鲁病。表 2 为水稻病害图像数据集信息,按照 8:2 划分为训练集、测试集,图像数量分别为 4 745、1 187 幅。

表 2 水稻病害图像数据集分布
Tab.2 Rice disease image dataset 幅

病害类别	训练集	测试集
白叶枯病	1 267	317
稻瘟病	1 152	288
褐斑病	1 280	320
东格鲁病	1 046	262

图 6 为水稻病害数据集病害示例。迁移学习数据集是从 PlantVillage 数据集 (<https://data.mendeley.com/datasets/tywbtsjrjv/1>) 中选取的 10 类数据。PlantVillage 数据集包含来自世界各地的数万幅农作物图像,其中包括多种常见作物,如马铃薯、玉米、小麦、柑橘、青椒等,以及这些作物所患的多种疾病和大量线虫和虫害。表 3 为试验所用到的 10 类图像以及数量。数据集有 11 553 幅图像,按照 8:2 划分为训练集、测试集,图像数量分别为 9 240、2 313 幅。




图 6 水稻数据集病害示例

Fig.6 Rice dataset examples

表 3 PlantVillage 图像数据集样本分布

Tab.3 Sample distribution of PlantVillage image dataset

图像类别	训练集	测试集
苹果结瘤	800	200
苹果黑腐病	800	200
苹果雪松、锈病	800	200
苹果健康	1 316	200
蓝莓健康	1 201	329
樱桃白粉病	800	301
樱桃健康	841	200
玉米尾孢子虫叶斑病、灰叶斑病	800	211
玉米康蒙锈病	953	239
玉米健康	929	233

图 7 为 PlantVillage 数据集中 10 种不同类别的示例图。




图 7 PlantVillage 迁移学习数据集示例图

Fig.7 Example diagrams of PlantVillage transfer learning dataset

2.3 性能评估指标

选择准确率 (Accuracy)、宏召回率 (Recall)、宏精确率 (Precision) 和宏 F1 值作为评价指标。对于分类评价指标来说,数值越接近 1 表示模型预测效果越好。

3 试验结果与分析

3.1 训练集和测试集试验结果

图 8 为 3 种网络在水稻病害表型训练集上测试的交叉熵损失值曲线。由图 8 可知,本文方法损失值下降迅速且平滑,在第 1 轮到第 6 轮快速下降后缓慢下降,最终稳定在 0.17。MobileNetV3Small 网络损失值下降也比较快,但略慢于本文方法。MobileNetV3Small - CBAM (CBAM 注意力机制替换 SE 注意力机制)网络损失值呈现 3 个阶段的变化速度,整体上比其他 2 个网络的损失值高。




图 8 非迁移学习网络在训练集上的损失值变化曲线
Fig. 8 Loss function curves of non-transfer learning network on training set

图 9 为 3 种网络在水稻病害表型测试集上的损失值曲线,本文方法与 MobileNetV3Small 网络的损失函数形态相似,都可以分为 3 个阶段。MobileNetV3Small - CBAM 网络的损失值形成 2 个阶段,第 1 阶段持续时间较长,损失值缓慢上升,第 2 阶段损失值下降平稳,但整体上损失值比其他 2 个网络高。




图 9 非迁移学习网络在测试集上的损失值变化曲线
Fig. 9 Loss function curves of non-transfer learning network on test set

图 10 为迁移学习后 3 种网络在训练集上的损失值。从图 10 可以看出,本文方法与 MobileNetV3Small 模型几乎一样的趋势,本文方法的初始损失值略高,但很快就下降到与 MobileNetV3Small 同步,说明模型学习到了较好的特征,而 MobileNetV3Small - CBAM 的损失值比其他 2 个网络高。

图 11 为 3 种网络迁移学习后在测试集上的损失值。从图 11 可以看出,初始损失值最高的是本




图 10 迁移学习网络在训练集上的损失值变化曲线
Fig. 10 Transfer learning network loss rate on training set




图 11 迁移学习网络在测试集上的损失值变化曲线
Fig. 11 Transfer learning network loss rate on test set

文方法,其次是 MobileNetV3Small,最低的是 MobileNetV3Small。在第 6 轮次后本文方法损失值下降比其他网络模型更快,收敛速度更快,在达到 30 个轮次后,3 个模型损失值曲线重叠,基本一致。

3.2 结果对比

在深度学习模型设计中,参数量和模型内存占用量都是重要指标。随着模型参数量的增加,模型存储空间和计算复杂度也会增加,从而降低了模型实际应用价值。因此,设计一个参数量少、模型内存占用量小、同时性能表现良好的模型是非常有必要的。

由表 4 可以发现,本文方法在保证性能的情况下减少的参数量约 26.69% 和模型内存占用量 4.9 MB。这意味着在使用 MobileNetV3Small - ECA 进行水稻病害识别时,可以通过更少的存储空间来运行模型。而 MobileNetV3Small - CBAM 相比 MobileNetV3Small 则参数量增加 221 849。试验表明,MobileNetV3Small - ECA 是一个在参数量和模型内存占用量上都比较小的模型。

表 4 模型参数量以及模型大小对比		
Tab. 4 Comparison of model parameter quantity and model size		
网络模型	参数量	内存占用量/MB
本文方法	1 126 116	13.5
MobileNetV3Small	1 536 118	18.4
MobileNetV3Small - CBAM	1 757 967	21.0

表 5 列出了本文方法以及 MobileNetV3Small 和

MobileNetV3Small – CBAM 模型在测试集上的分类评价指标。从表 5 中可以看出,本文方法在准确率、精确率、宏召回率和宏 F1 值上均优于其他两种模型,表现最好。

表 5 非迁移学习下分类评价指标

Tab.5 Classification evaluation index under non-transfer learning				%
模型	准确率	宏精确率	宏召回率	宏 F1 值
本文方法	97.47	97.55	97.43	97.44
MobileNetV3Small	96.29	96.27	96.37	96.30
MobileNetV3Small – CBAM	86.44	87.35	86.42	86.57

MobileNetV3Small 模型在测试集上的指标略低于本文方法,但也具有较好的分类能力。MobileNetV3Small – CBAM 的各项评价指标均最低,本文方法相比 MobileNetV3Small 模型在准确率、宏精确率、宏召回率、宏 F1 值上分别提升 1.18、1.28、1.06、1.14 个百分点。

表 6 为本文方法以及 MobileNetV3Small 和 MobileNetV3Small – CBAM 模型在测试集上的分类结果。从表中可以看出,本文方法在准确率、精确率、宏召回率和 F1 值上均优于其他两种模型,表现最好。

表 6 迁移学习下分类评价指标

Tab.6 Classification evaluation index under transfer learning				%
模型	准确率	宏精确率	宏召回率	F1 值
本文方法	99.92	99.92	99.91	99.92
MobileNetV3Small	99.83	99.83	99.84	99.83
MobileNetV3Small – CBAM	99.83	99.83	99.83	99.83

本文方法相比较 MobileNetV3Small 模型在准确率、宏精确率、宏召回率、宏 F1 值上分别提升 0.09、0.09、0.07、0.09 个百分点。表 7、8 为本文方法在迁移学习前后对各水稻病害识别效果。

表 7 非迁移学习下本文方法的各分类评价指标

Tab.7 Classification evaluation indicators of proposed method under non-transfer learning				%
病害类别	准确率	宏精确率	宏召回率	F1 值
白叶枯病	98.18	94.32	100	97.03
稻瘟病	96.81	98.89	92.67	95.70
褐斑病	99.04	99.68	99.04	99.36
东格鲁病	99.18	97.17	99.23	98.19

本文方法在识别水稻白叶枯病时,表现出较高的准确性和精确性,宏召回率也较高,表明模型捕获了几乎所有实际情况。较高的 F1 值反映了模型在

表 8 迁移学习下本文方法的各分类评价指标

Tab.8 Classification evaluation indicators of proposed method under transferred learning				%
病害类别	准确率	宏精确率	宏召回率	宏 F1 值
白叶枯病	99.43	99.68	100	99.84
稻瘟病	99.78	99.65	99.65	99.65
褐斑病	100	100	100	100
东格鲁病	100	100	100	100

平衡宏精确率和宏召回率方面的良好表现。在水稻稻瘟病的识别中,准确率和宏精确率相对较高,尽管宏召回率稍低,但较高的宏精确率表明了较少的误报。水稻褐斑病的识别展现出优异的准确率、宏精确率、宏召回率和 F1 值,突显了模型在该类别中的出色性能。水稻东格鲁病的识别也表现良好,准确率和宏召回率均较高,稍低的宏精确率可能源于对其他类别样本的误分类。

迁移学习后的本文方法在水稻褐斑病、水稻东格鲁病上各个指标均为 100%,表明模型捕获了所有实际情况。在水稻白叶枯病、水稻稻瘟病中表现也较优,均高于 99%。

综合上述情况,导致误分类的主要原因可能有 2 方面:

(1)相似病害造成误识别。不同类型的水稻病害在视觉上呈现相似特征的情况下,相似之处可能包括颜色、形状、纹理等,使得模型难以区分。例如,水稻稻瘟病和水稻白叶枯病可能在某些病变阶段或者角度下具有相似的外观特征,这可能导致模型在识别时产生混淆,从而出现误分类。解决这个问题可能需要更深入的特征分析,例如采用更具区分性的特征或者更高级的图像处理技术。

(2)背景造成误识别。水稻病害图像背景可能对模型识别产生干扰。背景中其他物体、杂草或光照条件的变化可能会影响模型对病害叶片的分析。例如,病害叶片和周围环境的颜色或纹理相似,可能导致模型错误地将背景部分也视为病害。此外,背景中的一些干扰可能使模型无法准确捕获病害叶片的关键特征,从而导致识别错误。为了解决这个问题,可能需要对图像进行预处理,去除或减弱背景的影响,或者采用更具有鲁棒性的图像处理方法。

3.3 特征可视化网络

Grad – CAM^[32] 是一种可视化深度神经网络中处理特征图的重要技术,能够更好地理解模型在分类过程中的注意力集中。

为了更好地演示 ECA 模块的效果,图 12 展示了 4 类水稻病害图像的 Grad – CAM 类激活映射可




图 12 特征可视化热力图

Fig. 12 Feature visualization heat map

可视化示例,选择网络最后一层卷积作为目标层进行计算,因为卷积层是特征图的生成者,比其他层更直接地反映了目标类别的重要性。直观可见,本文方法与其他的注意力机制 CBAM 和 SENET 相比,ECA 模块生成的结果与图像中病斑的位置和颜色更加一致,表明网络可以更好地聚焦水稻病害的特征。

3.4 边缘端部署

为实现水稻病害识别,使用 Android Studio 和 TensorFlow Lite 进行水稻病害识别模型的部署,在系统中,用户通过移动端进行选择识别图像的操作,使用 TensorFlow Lite 将模型部署到移动端上进行推理,系统界面如图 13 所示。

用户可以通过拍照或从手机相册中选取需要分析的水稻病害图像。图像上传成功后返回主界面并且在主界面中生成预览图,通过上传目标图像到应用中进行分析。如图 13a 所示,从相册里面选择水稻病害图,选定后会返回主界面,并生成预览图。

在图像上传完成后,应用程序加载已经转换格式为 .tflite 的模型。用户选择需要分析的图像,当应用程序将输入的图像加载到模型后,根据经过训练得出的模型对图像进行分析和识别,最后返回最



图 13 水稻病害识别系统

Fig. 13 Rice disease identification system

可能输出类别的信息,如图 13b 所示,输出信息包括病害类别名称及该类别标签的概率。

4 结束语

提出了一种用于水稻病害识别和检测的轻量级卷积神经网络 MobileNetV3Small - ECA,通过引入 ECA 注意力机制,在不进行迁移学习下相比较 MobileNetV3Small 模型在准确率、宏精确率、宏召回率、宏 F1 值上分别提升 1.18、1.28、1.06、1.14 个百分点,在迁移学习下相比较 MobilenetV3Small 模型在准确率、宏精确率、宏召回率、宏 F1 值上分别提升 0.09、0.09、0.07、0.09 个百分点,参数量减少 26.69%,更适合在移动设备等资源受限的场景中部署。通过 Grad - CAM 进行可视化,本文方法与其他的注意力机制 CBAM 和 SENET 相比,ECA 模块生成的结果与图像中病斑的位置和颜色更加一致,表明网络可以更好地聚焦水稻病害的特征。同时将模型进行边缘部署,将训练好的模型移植至移动端,在边缘端进行模型推理和分类识别,以实现水稻病害的便捷识别。

参 考 文 献

[1] 徐春春,闻军清,纪龙,等. 中国水稻种业发展现状、问题与展望[J]. 中国稻米, 2022, 28(5): 74 - 78.
XU Chunchun, WEN Junqing, JI Long, et al. Current situations, problems and prospects of rice seed industry in China[J]. China Rice, 2022, 28(5): 74 - 78. (in Chinese)

[2] 王跃星,魏祥进,徐春春,等. 我国水稻种业发展现状与对策浅析[J]. 中国稻米, 2022, 28(5): 62 - 65.
WANG Yuexing, WEI Xiangjin, XU Chunchun, et al. Current situation and countermeasures of rice breeding and seed industry development in China[J]. China Rice, 2022, 28(5): 62 - 65. (in Chinese)

[3] 杨雪,徐会永,臧昊昱,等. 水稻病害防控现状及对策建议[J]. 现代农药, 2022, 21(3): 1 - 5.
YANG Xue, XU Huiyong, ZANG Haoyu, et al. Current situation and countermeasures of rice disease control[J]. Modern Agrochemicals, 2022, 21(3): 1 - 5. (in Chinese)

[4] 郭先敏. 浅谈水稻种植与病虫害防治技术要点[J]. 种子科技, 2022, 40(24): 30 - 32.
GUO Xianmin. A discussion on rice planting and pest control techniques[J]. Seed Science & Technology, 2022,

- 40(24): 30–32. (in Chinese)
- [5] 张慧春,周宏平,郑加强,等. 植物表型平台与图像分析技术研究进展与展望[J]. 农业机械学报, 2020, 51(3): 1–17. ZHANG Huichun, ZHOU Hongping, ZHENG Jiaqiang, et al. Research progress and prospect in plant phenotyping platform and image analysis technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(3): 1–17. (in Chinese)
- [6] 岑海燕,朱月明,孙大伟,等. 深度学习在植物表型研究中的应用现状与展望[J]. 农业工程学报, 2020, 36(9): 1–16. CEN Haiyan, ZHU Yueming, SUN Dawei, et al. Current status and future perspective of the application of deep learning in plant phenotype research[J]. Transactions of the CSAE, 2020, 36(9): 1–16. (in Chinese)
- [7] 王晓婷,赵展,王阳,等. 基于改进 Mask R-CNN 的植物表型智能检测算法[J]. 中国农机化学报, 2022, 43(8): 151–157. WANG Xiaoting, ZHAO Zhan, WANG Yang, et al. Intelligent detection algorithm of plant phenotype based on improved Mask R-CNN[J]. Journal of Chinese Agricultural Mechanization, 2022, 43(8): 151–157. (in Chinese)
- [8] 王聃,柴秀娟. 机器学习在植物病害识别研究中的应用[J]. 中国农机化学报, 2019, 40(9): 171–180. WANG Dan, CHAI Xiujian. Application of machine learning in plant diseases recognition[J]. Journal of Chinese Agricultural Mechanization, 2019, 40(9): 171–180. (in Chinese)
- [9] VITHU P, MOSES J A. Machine vision system for food grain quality evaluation; a review[J]. Trends in Food Science & Technology, 2016, 56: 13–20.
- [10] 李辉,罗敏,岳佳欣. 基于计算机视觉技术的水稻病害图像识别研究进展[J]. 湖北农业科学, 2022, 61(4): 9–15. LI Hui, LUO Min, YUE Jiaxin. Research progress of recognition of rice disease images based on computer vision technology[J]. Hubei Agricultural Sciences, 2022, 61(4): 9–15. (in Chinese)
- [11] 翟肇裕,曹益飞,徐焕良,等. 农作物病虫害识别关键技术研究综述[J]. 农业机械学报, 2021, 52(7): 1–18. ZHAI Zhaoyu, CAO Yifei, XU Huanliang, et al. Review of key techniques for crop disease and pest detection[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 1–18. (in Chinese)
- [12] JIANG Feng, LU Yang, CHEN Yu, et al. Image recognition of four rice leaf diseases based on deep learning and support vector machine[J]. Computers and Electronics in Agriculture, 2020, 179: 105824.
- [13] 崔金荣,郑鸿,谭建伟,等. 基于智能化技术的水稻常见病害检测研究进展[J]. 智慧农业导刊, 2022, 2(13): 13–15. CUI Jinrong, ZHENG Hong, TAN Jianwei, et al. Research progress on detection of common rice diseases based on intelligent technology[J]. Journal of Smart Agriculture, 2022, 2(13): 13–15. (in Chinese)
- [14] WANG Yahong, SU Wenhao. Convolutional neural networks in computer vision for grain crop phenotyping; a review[J]. Agronomy, 2022, 12(11): 2659.
- [15] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv Preprint, arXiv:1409.1556, 2014.
- [16] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017.
- [17] 王冠,王建新,孙钰. 面向边缘计算的轻量级植物病害识别模型[J]. 浙江农林大学学报, 2020, 37(5): 978–985. WANG Guan, WANG Jianxin, SUN Yu. Lightweight plant disease recognition model for edge computing[J]. Journal of Zhejiang A&F University, 2020, 37(5): 978–985. (in Chinese)
- [18] 付佐毅,周世杰,李顶根. 轻量级目标识别深度神经网络及其应用[J]. 计算机工程与应用, 2020, 56(18): 131–136. FU Zuoyi, ZHOU Shijie, LI Dinggen. Lightweight target recognition deep neural network and its application[J]. Computer Engineering and Applications, 2020, 56(18): 131–136. (in Chinese)
- [19] 卫雅娜,王志彬,乔晓军,等. 基于注意力机制与 EfficientNet 的轻量化水稻病害识别方法[J]. 中国农机化学报, 2022, 43(11): 172–181. WEI Ya'na, WANG Zhibin, QIAO Xiaojun, et al. Lightweight rice disease identification method based on attention mechanism and EfficientNet[J]. Journal of Chinese Agricultural Mechanization, 2022, 43(11): 172–181. (in Chinese)
- [20] CHEN J D, CHEN J X, ZHANG D F, et al. Using deep transfer learning for image-based plant disease identification[J]. Computers and Electronics in Agriculture, 2020, 173: 105393.
- [21] FENG C G, JIANG M L, HUANG Q, et al. A lightweight real-time rice blast disease segmentation method based on DFFANet[J]. Agriculture, 2022, 12(10): 1543.
- [22] IANDOLA F N, HAN S, MOSKEWICZ M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size[J]. arXiv Preprint arXiv:1602.07360, 2016.
- [23] HOWARD A G, ZHU M L, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications[J]. arXiv Preprint arXiv:1704.04861, 2017.
- [24] TAN M, LE Q. Efficientnet: rethinking model scaling for convolutional neural networks[C] // International Conference on Machine Learning. PMLR, 2019:6105–6114.
- [25] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNetV3[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019:1314–1324.
- [26] WANG Q, WU B, ZHU P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C] //

Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2020.

[27] 刘建伟,刘俊文,罗雄麟. 深度学习中注意力机制研究进展[J]. 工程科学学报, 2021, 43(11): 1499 – 1511.
LIU Jianwei, LIU Junwen, LUO Xionglin. Research progress in attention mechanism in deep learning[J]. Chinese Journal of Engineering, 2021, 43(11): 1499 – 1511. (in Chinese)

[28] 皇甫晓瑛,钱惠敏,黄敏. 结合注意力机制的深度神经网络综述[J]. 计算机与现代化, 2023(2): 40 – 49.
HUANGFU Xiaoying, QIAN Huimin, HUANG Min. A review of deep neural networks combined with attention mechanism[J]. Computer and Modernization, 2023(2): 40 – 49. (in Chinese)

[29] 任欢,王旭光. 注意力机制综述[J]. 计算机应用, 2021, 41(增刊1): 1 – 6.
REN Huan, WANG Xuguang. Review of attention mechanism[J]. Journal of Computer Applications, 2021, 41(Supp. 1): 1 – 6. (in Chinese)

[30] 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)

[31] 庄福振,罗平,何清,等. 迁移学习研究进展[J]. 软件学报, 2015, 26(1): 26 – 39.
ZHUANG Fuzhen, LUO Ping, HE Qing, et al. Survey on transfer learning research[J]. Journal of Software, 2015, 26(1): 26 – 39. (in Chinese)

[32] SELVARAJU R, COGSWELL M, DAS A, et al. Grad – CAM: visual explanations from deep networks via gradient-based localization[C]//IEEE International Conference on Computer Vision (ICCV), 2017.

(上接第 211 页)

[23] 王照利,王浩伟,杨佳乐,等. 基于归一化植被点云的林分平均高及蓄积量反演[J]. 林业资源管理, 2021(6): 37 – 42.
WANG Zhaoli, WANG Haowei, YANG Jiale, et al. The inversion of average stand height and stock volume based on normalized vegetation point cloud[J]. Forest Resources Management, 2021(6): 37 – 42. (in Chinese)

[24] 潘俊虹,梁明. 多尺度分割的高分辨率遥感影像分类对比研究[J]. 现代计算机, 2022, 28(22): 56 – 60.
PAN Junhong, LIANG Ming. A comparative study of high-resolution remote sensing image classification based on multi-scale segmentation[J]. Modern Computer, 2022, 28(22): 56 – 60. (in Chinese)

[25] 赵各进,孙梦莲,宋贤芬,等. 无人机可见光遥感木麻黄人工林株数提取方法比较研究[J]. 西南林业大学学报(自然科学), 2023, 43(3): 127 – 135.
ZHAO Gejin, SUN Menglian, SONG Xianfen, et al. A comparative study of *Casuarina equisetifolia* number extraction methods based on UAV visible light remote sensing data[J]. Journal of Southwest Forestry University (Natural Science), 2023, 43(3): 127 – 135. (in Chinese)

[26] 刘旭光,肖啸,兰玉彬,等. 应用可见光遥感影像的林分植被分割方法[J]. 东北林业大学学报, 2023, 51(4): 62 – 67.
LIU Xuguang, XIAO Xiao, LAN Yubin, et al. Forest vegetation segmentation method with UAV visible light remote sensing images[J]. Journal of Northeast Forestry University, 2023, 51(4): 62 – 67. (in Chinese)

[27] 刘浩然,范伟伟,徐永胜,等. 基于无人机激光雷达点云数据的单木分割研究[J]. 中南林业科技大学学报, 2022, 42(1): 45 – 53.
LIU Haoran, FAN Weiwei, XU Yongsheng, et al. Research on single tree segmentation based on UAV LiDAR point cloud data [J]. Journal of Central South University of Forestry & Technology, 2022, 42(1): 45 – 53. (in Chinese)