

基于改进 MobileNetV3 的水稻病害识别模型

崔金荣^{1,2} 魏文钊^{1,2} 赵敏³

(1. 华南农业大学数学与信息学院, 广州 510642; 2. 广州市智慧农业重点实验室, 广州 510642;

3. 深圳市人工智能与机器人研究院, 深圳 518129)

摘要: 针对水稻病害识别方法准确度低、模型收敛速度缓慢的问题, 本文提出了一种高性能的轻量级水稻病害识别模型, 简称为 CA(Coordinate attention)–MobileNetV3。通过微调的迁移学习策略完善了模型的训练, 提升了模型收敛速度。首先创建 10 个种类的数据集, 其中包含 9 种水稻病害和 1 种水稻健康叶片。其次使用 CA 模块, 在通道注意力中嵌入空间坐标信息, 提高模型的特征提取能力与泛化能力。最后, 将改进后的 MobileNetV3 网络作为特征提取网络, 并加入 SVM 多分类器, 提高模型精度。实验结果表明, 在本文构建的水稻病害数据集上, 初始的 MobileNetV3 识别准确率仅为 95.78%, F1 值为 95.36%; 加入 CA 模块后识别准确率和 F1 值分别提高至 96.73% 和 96.56%; 再加入 SVM 多分类器, 通过迁移学习后, 改进模型的识别准确率和 F1 值分别达到 97.12% 和 97.04%, 参数量和耗时仅为 2.99×10^6 和 0.91 s, 明显优于其他模型。本文提出的 CA–MobileNetV3 水稻病害识别模型能够有效识别水稻叶部病害, 实现了轻量级、高性能、易部署的水稻病害分类识别算法。

关键词: 水稻病害; 改进 MobileNetV3; 卷积神经网络; 注意力机制; 支持向量机

中图分类号: S435.116 文献标识码: A 文章编号: 1000-1298(2023)11-0217-08

OSID: 

Rice Disease Identification Model Based on Improved MobileNetV3

CUI Jinrong^{1,2} WEI Wenzhao^{1,2} ZHAO Min³

(1. College of Mathematics and Informatics, South China Agricultural University, Guangzhou 510642, China

2. Guangzhou Key Laboratory of Intelligent Agriculture, Guangzhou 510642, China

3. Shenzhen Institute of Artificial Intelligence and Robotics, Shenzhen 518129, China)

Abstract: For the problems of low accuracy of rice disease identification methods and slow convergence of models, a high-performance lightweight rice disease identification model was proposed, referred to as coordinate attention (CA)–MobileNetV3. The training of the model was optimized by fine-tuning the migration learning strategy, and the convergence speed of the model was improved. Firstly, a ten species dataset was created, containing nine rice diseases and healthy rice leaves. Secondly, the CA module was also used to embed spatial coordinate information in the channel attention to improve the feature extraction and generalization ability of the model. In addition, the improved MobileNetV3 network was used as the feature extraction network and the SVM multi-classifier was added to improve the model accuracy. The experimental results showed that on the rice disease dataset constructed, the initial MobileNetV3 recognition accuracy was only 95.78% and the F1 score was 95.36%, and then the recognition accuracy and F1 score were improved to 96.73% and 96.56%, respectively, after adding the CA module, and then the SVM multi-classifier was added, and the recognition accuracy and F1 scores reached 97.12% and 97.04%, respectively, the number of parameters and the time taken were only 2.99×10^6 and 0.91 s, which were significantly better than that of other models. The experimental results showed that the CA–MobileNetV3 rice disease recognition model proposed can effectively recognize rice leaf diseases and achieve a lightweight, high-performance and easy-to-deploy rice disease classification and recognition algorithm.

Key words: rice disease; improved MobileNetV3; convolutional neural network; attention mechanism; support vector machine

0 引言

水稻是主要粮食作物之一^[1]。目前全球水稻种植面积超过 $1.55 \times 10^8 \text{ hm}^2$, 水稻总产量超过 $6.6 \times 10^8 \text{ t}$ 。在亚洲约有 3.0×10^9 人从水稻的衍生产品中获取超过 70% 的热量^[2]。然而水稻病虫害将会大大影响水稻产量, 因此, 快速检测出水稻的病害类型并对其做出针对性治疗, 保证水稻的产量非常关键。

近年来, 随着计算机硬件水平的提高以及计算机视觉技术的不断进步, 针对水稻病害的检测工作已经取得了较大进展。检测方法主要分为两类: 基于传统计算机视觉技术的水稻病害检测和基于深度网络模型的病害检测。在基于传统计算机视觉技术的水稻病害检测方法中, 许多学者通过对水稻病害图像手工设计特征, 再利用这些特征训练各种分类算法, 如支持向量机(Support vector machine, SVM)和决策树(Decision tree, DT)等。例如, 针对水稻矿物质缺乏症, PRITIMOY 等^[3]构建了一个基于颜色和纹理特征的多层次感知器神经网络, 其中包含 40 个纹理特征的隐藏层以及 70 个颜色特征的隐藏层。马超等^[4]对水稻病害图像提取了方向梯度直方图(Histogram of oriented gradient, HOG)的特征, 并以 HOG 特征为输入训练了支持向量机分类器, 得到了一个用于病害检测的分类器。BIKASH 等^[5]提出了一种基于双支持向量机(Twin support vector machine, TSVM)技术的水稻病害图像识别技术, 使用 K-means 聚类来分割病害图像, 使用灰度共生矩阵(Gray-level co-occurrence matrix, GLCM)来提取特征, 最后使用双支持向量机进行分类。

综上, 基于传统计算机视觉技术的水稻病害检测研究虽然取得了一定的成果, 识别精度有所提高, 但是其仍存在不足和缺陷: 手工设计特征的过程比较繁琐, 不仅费时费力, 而且通用性低, 存在泛化能力差的缺陷; 提取到特征是由多种因素决定的, 不同的特征会对识别精度产生较大影响。手工设计特征时主观性较强, 很难选择所有合适的特征, 从而导致识别效率低的问题。而近年来, 随着以卷积神经网络(Convolutional neural networks, CNN)为代表的深度学习模型不断发展, 深度学习模型与日常生活的结合越来越紧密, 在计算机视觉各个领域都表现出了优越的性能。卷积神经网络相较于传统机器学习, 在特征提取能力上更具客观性与稳定性, 泛化能力更强。而自动提取特征也可以避免繁琐、费时费力的人力劳动。

LI 等^[6]提出了一种基于 Fast R - CNN 的视频

检测架构, 用于视频中的水稻害虫检测, 该架构是通过将视频转换为静止帧, 然后用 Fast R - CNN 检测, 最后将静止帧合成为视频。RAHMAN 等^[7]以 VGG - 16 和 Inception 为基本框架, 对其进行了微调, 并优化了其网络结构, 降低了模型复杂度, 在水稻病害识别中具有较高的准确性。SALEEM 等^[8]提出了一种基于变异粒子群优化(Mutant particle swarm optimization, MUT - PSO)算法的方法, 为水稻叶病分类寻找最佳的 CNN 结构。SATHYA 等^[9]提出了一种重构疾病感知卷积神经网络(Reconstructed disease aware - convolutional neural networks, RDA - CNN), 该网络以水稻作物的低分辨率图像为输入, 使用超分辨率层将低分辨率图像转换为超分辨率图像, 以恢复水稻植株不同部位的外观, 如斑点、腐烂和损坏。

基于深度学习模型的水稻病害检测研究, 解决了使用手工设计特征的缺陷, 取得了较高的识别效果和识别速度。但是基于深度学习模型的水稻病害检测研究也存在缺点和不足: 基于深度学习模型的研究方案大多采用传统的卷积神经网络, 往往需要大量参数和复杂网络结构才能保证较高的识别精度, 计算量大, 实时性弱, 难以在移动设备上部署; 由于某些水稻病害的类间差异较小, 如稻瘟病的急性型和胡麻斑病在叶片上都表现为椭圆形的病斑, 较易混淆, 因此现有水稻病害识别模型识别精度仍有提高的空间。

因此, 针对上述现有研究中存在的问题, 本文提出一种高性能、轻量级的水稻病害识别模型, 命名为 CA - MobileNetV3。利用微调参数的迁移学习策略将模型在 ImageNet 大型数据集上预训练得到的参数权重迁移至本文提出的改进模型 CA - MobileNetV3 上进行微调, 再将模型上提取的特征用于训练 SVM 多分类器, 以期解决现阶段识别精度不高的问题。

1 数据集构建

本文选用 9 种常见的水稻病害和健康叶片构成数据集, 均获取自 Kaggle 官方网站(<https://www.kaggle.com>)。该数据集是在复杂背景下的稻田拍摄, 比简单背景下的图像样本泛化能力更好, 可以更好地应用在实际生产中。这 9 种常见的病害为细菌性叶枯病、细菌性条斑病、细菌性穗枯病、稻瘟病、胡麻斑病、枯心病、霜霉病、希斯帕病和东格鲁病。包括健康叶片在内共 10 407 幅图像。该数据集按照比例 8:1:1 进行划分, 其中标签和对应的样本数量如表 1 所示, 该数据集部分图像样本如图 1 所示。

表 1 水稻病害数据集构成

Tab. 1 Rice disease dataset composition

标签	水稻病害	样本图像数/幅
a	细菌性叶枯病	479
b	细菌性条斑病	380
c	细菌性穗枯病	337
d	稻瘟病	1 738
e	胡麻斑病	965
f	枯心病	1 442
g	霜霉病	620
h	希斯帕病	1 594
i	健康叶片	1 764
j	东格鲁病	1 088

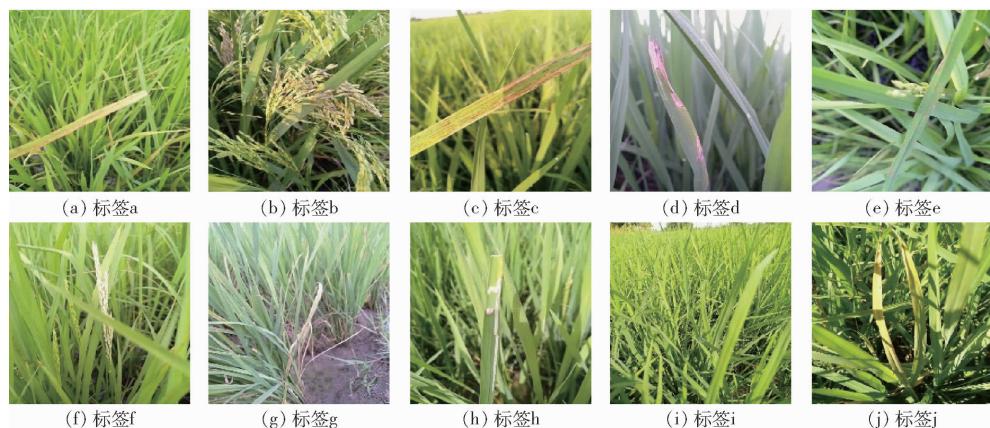


图 1 不同水稻病害和健康叶片的样本图像

Fig. 1 Sample images of different rice diseases

表 2 MobileNetV3 - large 结构参数

Tab. 2 MobileNetV3 - large structure

输入	操作	SE 模块	激活函数	步长
$224^2 \times 3$	conv2d	-	HS	2
$112^2 \times 16$	bneck, 3×3	-	RE	1
$112^2 \times 16$	bneck, 3×3	-	RE	2
$56^2 \times 24$	bneck, 3×3	-	RE	1
$56^2 \times 24$	bneck, 5×5	✓	RE	2
$28^2 \times 40$	bneck, 5×5	✓	RE	1
$28^2 \times 40$	bneck, 5×5	✓	RE	1
$28^2 \times 40$	bneck, 3×3	-	HS	2
$14^2 \times 80$	bneck, 3×3	-	HS	1
$14^2 \times 80$	bneck, 3×3	-	HS	1
$14^2 \times 80$	bneck, 3×3	-	HS	1
$14^2 \times 80$	bneck, 3×3	✓	HS	1
$14^2 \times 112$	bneck, 3×3	✓	HS	1
$14^2 \times 112$	bneck, 5×5	✓	HS	2
$7^2 \times 160$	bneck, 5×5	✓	HS	1
$7^2 \times 160$	bneck, 5×5	✓	HS	1
$7^2 \times 160$	Conv2d, 1×1	-	HS	1
$7^2 \times 960$	Pool, 7×7	-	-	1
$1^2 \times 960$	Conv2d, 1×1 , NBN	-	HS	1
$1^2 \times 1 280$	Conv2d, 1×1 , NBN	-	-	1

注: “✓”表示添加该模块, “-”表示不添加该模块。

2.2 CA - MobileNetV3 模型

基于 MobileNetV3 网络进行改进, 提出 CA - MobileNetV3 网络, 整体结构示意图如图 2 所示。

2 水稻叶片病害识别模型

2.1 MobileNetV3 模型

MobileNetV3 模型继续沿用 MobileNetV2 模型^[10]中的深度可分离卷积和倒置残差模块以保证其轻量化的特性, 并改进了 bottleneck 结构, 加入 SE 模块, 引入 hard-swish 激活函数, 最后对网络结构进行优化^[11], 进一步提升了精度。根据资源量将 MobileNetV3 模型分为 large 模型与 small 模型, 本文采用的基准是 MobileNetV3 - large 模型, 其结构参数如表 2 所示。

首先, 在 MobileNetV3 的网络结构中将原本 SE 注意力机制模块替换为 CA 注意力机制模块, 提升网络对位置信息的捕获。其次将 CA - MobileNetV3 网络作为特征提取网络, 将提取得到的特征用于 SVM 分类器训练, 并将 SVM 分类器作为最后的分类层。这些部分共同构成了 CA - MobileNetV3 的网络结构。

2.2.1 引入 CA 注意力机制

由于 MobileNetV3 中使用的 SE 模块只考虑了编码通道之间的信息来衡量每个通道的重要性^[12], 却忽略了对捕捉识别对象结构至关重要的位置信息。而 ECA 模块以 SE 模块为基础进行改进, 避免了降维, 更高效地捕获了跨通道交互的信息^[13]。虽然较 SE 模块有所提升, 但本质上仍然只考虑通道间的信息^[14]。因此, 为了提高模型识别率, 增强模型对水稻病害位置信息的捕捉, 必须考虑坐标信息。因此本文引入 CA 注意力机制来改进 MobileNetV3, 将 MobileNetV3 结构中的 SE 模块替换为 CA 模块。

CA 注意力机制不仅可以捕捉到跨通道信息, 还可以捕捉到位置敏感信息^[15], 对关键的像素坐标位置给予较大的权重, 同时 CA 模块的计算开销也很

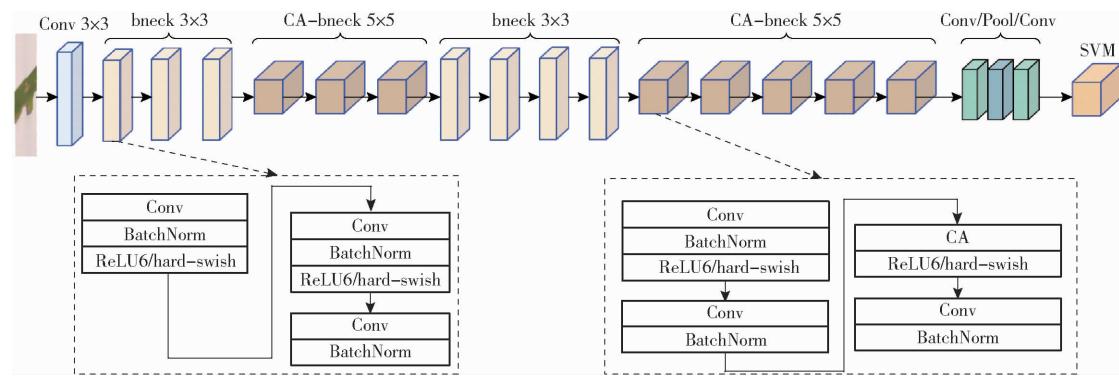


图 2 改进后的 MobileNetV3 结构图

Fig. 2 Structure diagram of improved MobileNetV3

小,符合本文的要求。CA 注意力机制与使用二维全局池化将特征张量转换为单个特征向量的通道注意力机制不同,CA 注意力机制将通道注意力拆分为 2 个一维特征编码过程,将垂直和水平方向的输入特征分别聚合为 2 个独立的方向感知特征图,从而有效实现了将空间坐标信息整合到注意图中。此外,上述分解操作允许沿一个空间方向捕获长距离依赖关系,同时保留沿另一个空间方向的精确位置信息。最后,通过乘法将 2 个方向上的注意力权重与输入特征图相乘,最终得到带有权重的特征图,从而可以对感兴趣的目标给予更大的关注。

CA 注意力机制的计算过程如图 3 所示。假设输入为一个 $C \times H \times W$ 的特征图,其中 C 为通道数, H 为特征图高度, W 为特征图宽度。CA 将二维全局池化操作转换为一对不同方向上的一维全局池化操作,并将长宽方向上的特征信息进行拼接和 1×1 卷积降维,得到一个 $C/r \times 1 \times (W+H)$ 的中间特征图,其中 r 为用于缩减通道数的缩放因子。随后再将中间特征图分解为 2 个方向上的特征图,再次通过 1×1 卷积升回到原来的维度并通过 Sigmoid 激活函数得到长宽方向上最终的特征图。最后,通过元素相乘的操作将输入特征图和 2 个最终的方向特征图转换为最终的输出特征图。

2.2.2 使用 SVM 分类器

MobileNetV3 网络层提取到的特征最终会被输入到 SVM 分类层中以完成水稻叶片病害的分类。虽然本文数据集有约 1×10^4 幅图像,但部分种类的数据集仅有几百幅,样本分布并不均匀,在求解问题时可能会产生较大的误差。而 SVM 算法是基于结构风险最小化原则,能够避免因部分训练数据较少带来的过拟合问题,可以提升模型的泛化能力^[16]。此外,SVM 分类算法可以表示为一个凸优化问题,因此可以发现目标函数的全局最优解,而其他分类方法大多采用基于贪婪学习的策略实现,因此只能获得局部最优解。

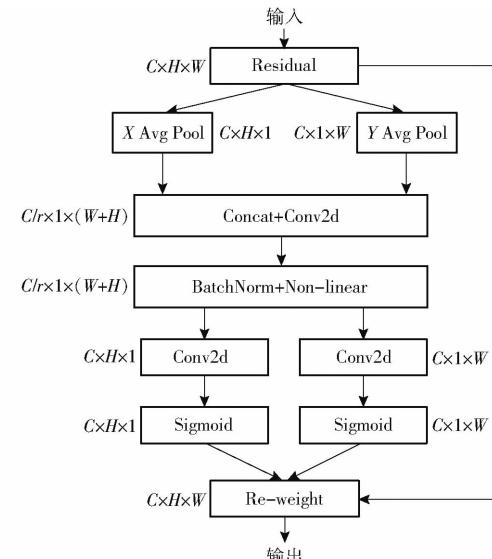


图 3 CA 注意力机制的计算流程图
Fig. 3 Flowchart of calculation of coordinate attention

由于 SVM 的分类效果很大程度上取决于 SVM 惩罚因子 C 和核函数参数 γ ,其中 C 用于控制对分类错误样本的惩罚程度, γ 用于控制核函数的宽度。但是,对于 SVM 参数的设置,目前并没有统一的方法,因此本文使用粒子群优化算法(PSO)来确定 SVM 参数的最佳解^[17]。具体来说,将 C 和 γ 以向量的形式进行编码,作为 PSO 的粒子,将预测精度作为目标函数,因此可以构造适应度函数为

$$\text{fitness}(x) = \frac{1}{m} \sum_{i=1}^m (f_i(x) - y_i(x))^2 \quad (1)$$

式中 $f_i(x)$ —预测值 $y_i(x)$ —真实值
 m —总迭代次数

PSO 算法在每一次迭代更新中,不断更新粒子 C 和 γ 的值,直到达到最大迭代次数或适应度达到阈值,更新公式为

$$v_{id}^k = w v_{id}^{k-1} + c_1 r_1 (\rho_i - x_{id}^{k-1}) + c_2 r_2 (g_i - x_{id}^{k-1}) \quad (2)$$

$$x_{id}^k = v_{id}^{k-1} + x_{id}^{k-1} \quad (3)$$

式中 w —惯性权重
 x_{id}^k —粒子当前位置

i ——所有粒子个数

d ——解向量维度 v_{id} ——粒子速度

c_1, c_2 ——加速度因子

r_1, r_2 —— $[0, 1]$ 之间的随机数

ρ_i ——全局最优解

g_i ——个体最优解

通过上述过程对 C 和 γ 进行不断迭代后, 即可获得最优的参数, 以获得更好的水稻叶片病害分类效果。

2.3 迁移学习

任何模型中都有大量的参数需要训练, 而训练需要大量的数据支持。然而, 并不是所有的任务都可以构建足够大的数据集进行训练。迁移学习能够解决上述问题。迁移学习可以使同一个模型很容易应用于另一个研究中^[18]。不同样本之间有一些共性, 相互之间有类似特征, 所以可以利用已经在较大的数据集进行充分训练过的模型基础上再针对当前任务进行再训练, 这样可以达到一个较好的训练效果和较快的收敛速度。因此, 为了充分利用现有的标记数据, 同时保证模型在新任务上的识别精度, 本文采用迁移学习来优化模型并选择冻结部分卷积层的微调方法作为模型的迁移学习优化方案。

3 实验与结果分析

3.1 实验平台

本研究使用的实验平台硬件环境为 Intel Xeon E5-2620 v3 处理器, NVIDIA RTX3060 12 GB 显卡, 16 GB 内存; 软件环境为 Ubuntu 20.04 系统, Python 3.7, 使用的深度学习框架为 Pytorch。

3.2 性能指标

为了能较为客观地评价出本文提出的方法是否有效, 采用准确率、查全率、查准率和 F1 值 4 种评价指标^[19] 对本文提出的 CA-MobileNetV3 进行性能评估。

3.3 实验

首先以 MobileNetV3 为基准进行消融实验, 以证明本文提出方法的有效性。再用不同的迁移学习方法、不同的注意力机制进行消融实验。最后, 将本文提出的模型与其他方法在测试集上进行比较。实验批量大小均设置为 32, 迭代批次 (epoch) 均为 200。所有训练均采用 Adam 优化器^[20], 学习率设置为 0.001。

3.3.1 消融实验

将注意力机制 CA 模块替换 SE 模块和用 SVM 替换 Softmax 分类层进行消融实验, 结果如表 3 所示。

表 3 基于 MobileNetV3 的消融实验

Tab. 3 MobileNetV3-based ablation experiments %

序号	coordinate attention	SVM	准确率	查准率	查全率	F1 值
1			95.78	95.32	95.40	95.36
2	√		96.73	96.86	96.27	96.56
3		√	96.35	95.49	95.44	95.46
4	√	√	97.12	96.81	97.29	97.04

从表 3 中可看出, 在分别加入 CA 注意力机制模块和 SVM 后, 模型效果都有一定提升, 而在同时采用 2 种方法时, 效果更佳, 病害识别准确率达到 97.12%, F1 值达到 97.04%, 高于单独采用其中一种方法或不采用任何方法的情况。而由于使用 SVM 分类器时需要将模型中提取到的特征再用于 SVM 分类器的训练, 所以训练时间比基准模型 MobileNetV3 更长一些, 但实现了更好的分类效果。训练完成后, 识别水稻病害所有样本的时间也仅需要 0.91 s, 参数量也仅稍稍大于 ShuffleNetV2, 为 2.99×10^6 , 所以并不影响最终在移动设备上识别的效率, 小参数量也对在移动设备上部署有利。改进模型 CA-MobileNetV3 并使用 SVM 分类器的综合性能优于初始模型。

3.3.2 训练方式对比实验

迁移学习分为 3 种方式, 分别是冻结所有卷积层、只训练全连接层的全参数迁移方法 (Full migration), 只使用模型结构而不使用模型预训练参数的重用模型方法 (Reuse model), 以及冻结部分卷积层的微调方法 (Fine tuning), 本文采用了只冻结部分卷积层的微调方法。为了测试本文采用的微调方法的有效性, 分别采用上述 3 种迁移学习方法训练 3 个模型, 在都以本文改进后的 MobileNetV3 模型为基准、都采用相同的实验数据等条件下进行实验, 实验结果见表 4。3 种迁移学习方法的训练与验证精度变化曲线见图 4、5。

表 4 3 种迁移方法的测试集实验结果

Tab. 4 Experiments of three migration methods on

迁移方法	test set			%
	准确率	查准率	查全率	F1 值
Fine tuning	97.12	96.81	97.29	97.04
Full migration	96.45	95.96	96.29	96.12
Reuse model	96.92	96.53	96.73	96.62

从图 4、5 中可看出, 在相同实验条件下, 微调参数方法的精度最高, 而全迁移方法精度最低, 而且微调参数方法的 F1 值也是 3 个方法中最高。在全参数迁移方法中, 模型的所有初始参数都是通过预先训练得到, 只对全连接层进行训练, 所以很难有针对性

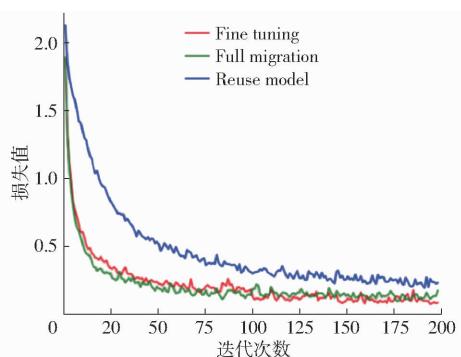


图 4 3 种迁移方法在训练集上损失值变化曲线

Fig. 4 Loss variation curves of three migration methods on training set

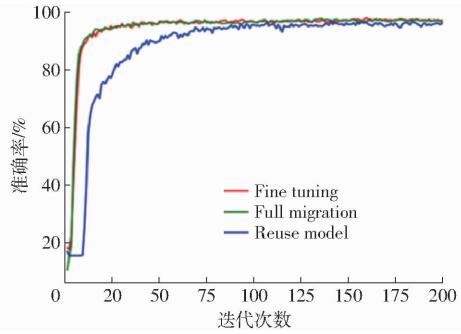
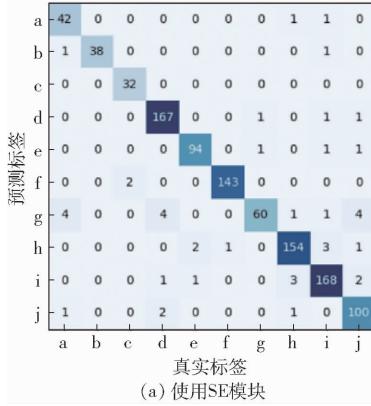


图 5 3 种迁移方法在验证集上准确率变化曲线

Fig. 5 Accuracy variation curves of three migration methods on validation set



(a) 使用SE模块

图 6 基于 MobileNetV3 加入不同注意力机制得到的混淆矩阵

Fig. 6 Confusion matrix obtained based on MobileNetV3 with different attention mechanisms

如表 5 所示。

表 5 基于 MobileNetV3 的不同注意力机制对比实验结果

Tab. 5 Comparison experiments of different attention mechanisms based on MobileNetV3 %

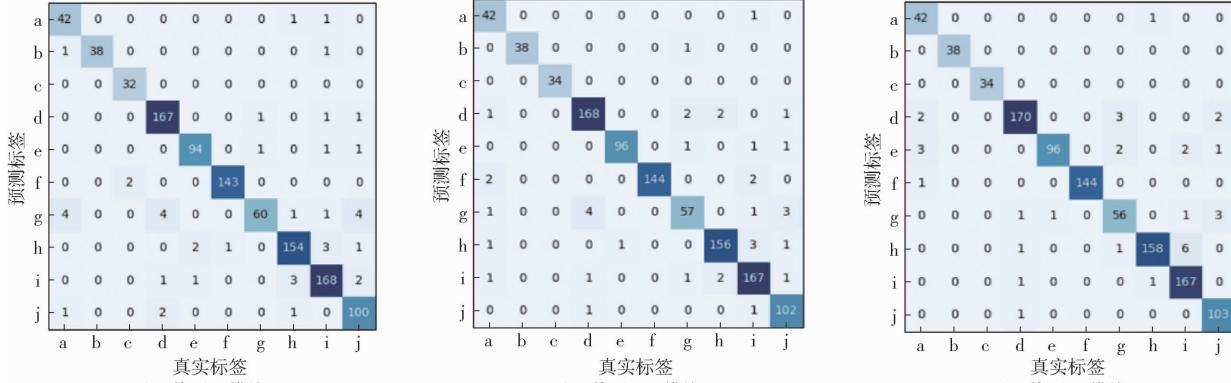
方法	准确率	查准率	查全率	F1 值
SE	95.78	95.32	95.40	95.36
ECA	96.35	96.33	96.10	96.21
CA	96.73	96.86	96.27	96.56

从表 5 可看出,由于捕捉了关键位置的敏感信息,替换了 CA 模块的模型分类精度、F1 值等都达到 3 个模块中的最高,在热力图中表现出使用了 CA 模块的模型相较于其他模块更加注重了图中的有效

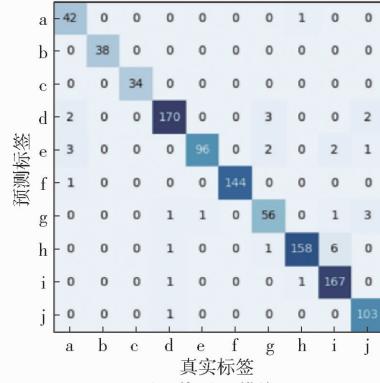
性地优化模型的参数。在重用模型方法中,模型初始参数随机设置,要提高模型的识别精度需要较长时间。而在微调方法中,模型一些初始参数是经过大量数据训练后得到,而不是随机设置,能够更快得到更适合模型的参数。此外,微调方法对模型中部分卷积层进行重新训练,使模型参数能够更适合本文研究的水稻疾病识别任务。综合实验中 4 个指标可看出,本文使用的微调转移学习方法比其他 2 种转移学习方法更有效。

3.3.3 不同注意力机制对比实验

在现有的注意力机制中,SE 模块、ECA 模块和 CA 模块是最常见的 3 种机制。在本文中,MobileNetV3 中的 SE 模块被替换为可以捕捉位置敏感信息的 CA 模块。为了测试本文使用的 CA 模块的有效性,在相同实验数据、相同模型结构和其他条件下,将替换后模型与 MobileNetV3 和用 ECA 模块替换 MobileNetV3 中的 SE 模块的模型进行比较。在相同实验数据、相同模型结构和其他条件下,采用微调的迁移学习方式,训练 200 个周期,对 3 种注意力机制分类结果绘制混淆矩阵图(图 6)^[21],图中可以清晰看到每个种类的分类结果。其中,主对角线上的数字表示的是正确分类样本的数量。实验结果



(b) 使用ECA模块



(c) 使用CA模块

位置,针对关键像素坐标位置给予了更大权重。而初始模型 MobileNetV3(即采用 SE 模块)的分类精度和 F1 值最低。由于 SE 模块和 ECA 模块都忽略了对捕捉识别对象结构至关重要的位置信息,而 CA 模块通过将通道注意力分成 2 个一维特征编码过程,提高了模型识别率,增强了模型对水稻病害坐标位置信息的捕获,因此比使用 SE 和 ECA 模块的模型更有效。

图 6 中的混淆矩阵的英文字母对应了表 1 中的不同样本,正对角线的数量表示了每种样本正确分类的数量。由图 6 可看到,CA 模块正确分类的数量是最多的,然而样本 h(希斯帕病)中有 6 个样本被

错误识别为样本 i(健康叶片), 可能由于样本 h 的病害特征不够明显, 为白色条纹, 再加上光照及拍摄参数设置等影响导致模型将样本 h 与样本 i 的特征有所混淆, 但模型整体分类准确率仍然比较可观, 其他各项数值也在一个较高的位置, 表明模型分类效果较为良好。

对部分病害样本进行可视化操作, 从而可以更加直观观察到不同注意力机制重点关注的区域, 如图 7 所示。该方法是由基于梯度的类激活图(Gradient-weighted class activation mapping, Grad-CAM)实现的。由图 7 可看出, CA 注意力机制比另外 2 个通道注意力机制更能关注对于模型较为重要的部分, 这是因为 CA 注意力机制的 2 个并行的一维特征编码过程可以有效地把空间坐标信息整合到生成的注意图, 从而使得模型能更准确地定位和识别感兴趣的对象。

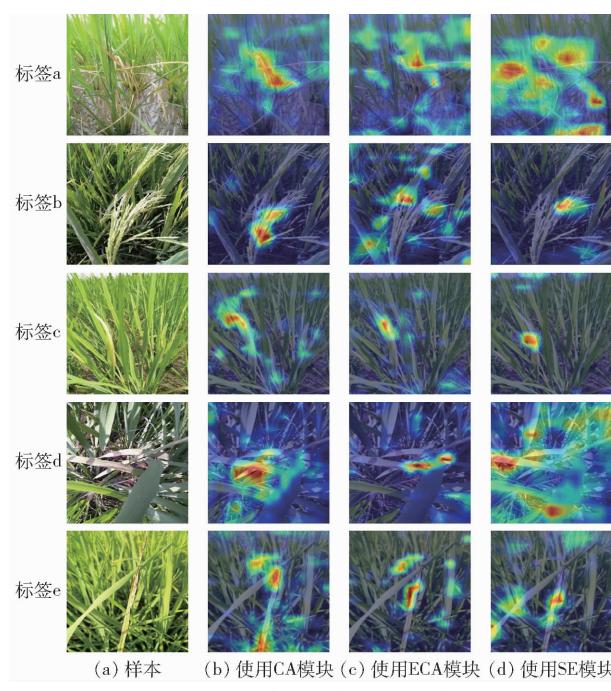


图 7 3 种注意力机制可视化特征图

Fig. 7 Visualization feature maps of three attention mechanisms

3.3.4 不同模型的对比实验

在图像分类问题上, ShuffleNetV2^[23] 和 MobileNet 系列是 2 个比较出色的轻量级卷积神经网络, 可以较为容易地部署在移动设备上。AlexNet^[24]、VGG-16^[25] 和 ResNet-50^[26] 是视觉任务中较为有代表性的卷积神经网络, 在视觉分类任务中^[27]都取得了非常好的成绩, 对本文提出的水稻病害识别方法具有一定参考价值与对比性。为了证明本文所有改进的有效性, 在相同实验数据、相同模型参数设置等条件下, 将改进后的模型与其余 4 个模型进行比较。这 4 个模型都将训练 200 个周期,

实验结果见表 6。

表 6 5 个模型在测试集上的实验结果

Tab. 6 Experiments of five models on test set

方法	参数量	耗时/s	准确率/%	查准率/%	查全率/%	F1 值/%
AlexNet	1.46×10^7	3.12	94.62	94.42	93.41	93.91
ShuffleNetV2	1.26×10^6	3.35	96.35	96.29	96.04	96.16
VGG-16	1.34×10^8	6.05	96.55	96.54	95.40	95.97
ResNet-50	2.35×10^7	4.17	97.02	96.72	96.56	96.63
本文方法	2.99×10^6	0.91	97.12	96.81	97.29	97.04

从表 6 中可看出, 本文设计的改进 MobileNetV3 准确率达到 97.12%, 超过了其他网络。得益于充分提取了样本的特征对 SVM 进行训练, 识别时间仅为 0.91 s, 为其中最快的模型。模型识别的 F1 值也是其中最高的, 其中模型参数量也仅仅略高于 ShuffleNetV2^[28], 保证了轻量化的同时也保证了识别性能。ResNet-50 的综合分数紧随其后, 虽然其性能较为出色, 但其模型较大的参数量需要耗费庞大的内存空间与计算资源, 不符合本文轻量化的出发点。ShuffleNetV2 的参数量为所有模型中最小的。虽其为轻量级卷积神经网络, 参数量小, 但其性能落后于本文提出的方法, 在识别速度上也没有优势。而 AlexNet 和 VGG-16 不仅参数量大于本文提出的方法, 在识别的精度、速度和 F1 值上也不如本文方法。综上所述, 本文提出的改进模型在得到较高识别精度和 F1 值的同时仍然保证了轻量化的特点。

4 结束语

提出了一种基于改进 MobileNetV3 的水稻病害识别分类算法, 即 CA-MobileNetV3。引入的 CA 注意力机制可以有效地捕获位置敏感信息, 在特征图中保留准确的位置信息, 增强了模型的感受野, 加强了对水稻病害位置的捕捉能力。实验表明, 将 MobileNetV3 中的 SE 模块替换为 CA 模块后, 准确率有所提升。此外, 使用的 SVM 分类器提升了模型识别精度, 从实验中也可以看出, 在加入 SVM 分类器后效果又得到进一步提升。微调迁移学习方法优化了模型训练, 加快了模型训练的收敛速度。实验结果表明, 本文提出的模型能够有效地识别各种水稻病害, 对数据集中 10 种水稻病害(包含一类健康叶片)的识别准确率、查准率、查全率和 F1 值分别达到 97.12%、96.81%、97.29% 和 97.04%, 参数量和耗时仅为 2.99×10^6 和 0.91 s。综上所述, 本文的模型具有识别精度高、易于部署的特点, 且较好地平衡了准确率、召回率和精确率, 具有优良的识别效果。为水稻病害防治的智能化、数字化提供了新思路。

参考文献

- [1] SAMARENDU M, TAKASHI Y. Rice food security in India: emerging challenges and opportunities [M]. The Future Rice Strategy for India, 2017:1–13.
- [2] PAPADEMETRIOU M K. Rice production in the Asia – Pacific region: issues and perspectives [J]. Bridging the Rice Yield Gap in the Asia – Pacific Region, 2000, 220: 4 – 25.
- [3] PRITIMOY S, UJJWAL B, SUSANTA K P, et al. Color texture analysis of rice leaves diagnosing deficiency in the balance of mineral levels towards improvement of crop productivity [C] // International Conference on Information Technology. IEEE, 2007.
- [4] 马超,袁涛,姚鑫锋,等.基于HOG + SVM的田间水稻病害图像识别方法研究[J].上海农业学报,2019,35(5):131 – 136.
MA Chao, YUAN Tao, YAO Xinfeng, et al. Research on image recognition method of rice diseases in the field based on HOG + SVM [J]. Shanghai Journal of Agriculture, 2019, 35(5):131 – 136. (in Chinese)
- [5] BIKASH C, SANJEEV P P. Rice plant disease detection using twin support vector machine (TSVM) [J]. Journal of Science and Engineering, 2019, 7:61 – 69.
- [6] LI Dengshan, WANG Rujing, XIE Chengjun, et al. A recognition method for rice plant diseases and pests video detection based on deep convolutional neural network [J]. Sensors, 2020, 20(3):578.
- [7] 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.
- [8] SALEEM M A, AAMIR M, IBRAHIM R, et al. An optimized convolution neural network architecture for paddy disease classification [J]. Computers, Materials & Continua, 2022, 71(3):6053 – 6067.
- [9] SATHYA K, RAJALAKSHMI M. RDA – CNN: enhanced super resolution method for rice plant disease classification [J]. Computer Systems Science and Engineering, 2022, 42(1):33 – 47.
- [10] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: inverted residuals and linear bottlenecks [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2018.
- [11] 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.
- [12] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132 – 7141.
- [13] WANG Q, WU B, ZHU P, et al. ECA – Net: efficient channel attention for deep convolutional neural networks [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11534 – 11542.
- [14] 贾兆红,张袁源,王海涛,等.基于Res2Net和双线性注意力的番茄病害时期识别方法[J].农业机械学报,2022,53(7):260 – 266.
JIA Zhaohong, ZHANG Yuanyuan, WANG Haitao, et al. Identification method of tomato disease period based on Res2Net and bilinear attention mechanism [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(7):260 – 266. (in Chinese)
- [15] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713 – 13722.
- [16] 刘朝廷,刘姣娣,王明朋,等.基于SVM的蔗种坏芽检测识别[J].石河子大学学报(自然科学版),2022,40(4):481 – 486.
LIU Xuting, LIU Jiaodi, WANG Mingming, et al. Detection and recognition of sugarcane bad bud based on SVM [J]. Journal of Shihezi University (Natural Science Edition), 2022, 40(4):481 – 486. (in Chinese)
- [17] HUANG C L, DUN J F. A distributed PSO – SVM hybrid system with feature selection and parameter optimization [J]. Applied Soft Computing, 2008, 8(4): 1381 – 1391.
- [18] 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)
- [19] 孙俊,朱伟栋,罗元秋,等.基于改进MobileNet – V2的田间农作物叶片病害识别[J].农业工程学报,2021,37(22):161 – 169.
SUN Jun, ZHU Weidong, LUO Yuanqiu, et al. Recognizing the diseases of crop leaves in fields using improved MobileNet – V2 [J]. Transactions of the CSAE, 2021, 37(22):161 – 169. (in Chinese)
- [20] KINGMA D, BA J. Adam: a method for stochastic optimization [J]. Journal of the International Conference on Learning Representations (ICLR), 2014, 12(1):1 – 13.
- [21] 刘阳,高国琴.采用改进的SqueezeNet模型识别多类叶片病害[J].农业工程学报,2021,37(2):187 – 195.
LIU Yang, GAO Guoqin. Identification of multiple leaf diseases using improved SqueezeNet model [J]. Transactions of the CSAE, 2021, 37(2): 187 – 195. (in Chinese)

- integrated with a deep learning algorithm [J]. Sensors, 2021, 21(11): 3579.
- [19] 张亚婷,席磊,赵芙蓉.旱养对种鸭行为的影响观察[J].中国家禽,2017,39(13):67-69.
ZHANG Yating, XI Lei, ZHAO Furong. Observation on the effect of dry-feeding on breeding duck behavior [J]. China Poultry, 2017, 39(13): 67 - 69. (in Chinese)
- [20] WOOD K A, LACEY R, ROSE P E. Assessing trade-offs in avian behaviour using remotely collected data from a webcam [J]. PLOS ONE, 2022, 17(7): e0271257.
- [21] RELIC R, SOSSIDOU E, DEDOUSI A, et al. Behavioral and health problems of poultry related to rearing systems [J]. Ankara Universitesi Veteriner Fakultesi Dergisi, 2019, 66: 423 - 428.
- [22] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLO v4: optimal speed and accuracy of object detection [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2020.
- [23] HE K, ZHANG X Y, REN S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 37(9): 1904 - 1916.
- [24] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation [J]. Computer Vision and Pattern Recognition, 2018, 35(3): 8759 - 8768.
- [25] REDMON J, FARHADI A. YOLO v3: an incremental improvement [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2018.
- [26] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: inverted residuals and linear bottlenecks [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2018.
- [27] YANG L X, ZHANG R Y, LI L, et al. SimAM: a simple, parameter-free attention module for convolutional neural networks [C] // International Conference on Machine Learning, PMLR, 2021: 11863 - 11874.
- [28] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2019.
- [29] ZHU X Z, CHENG D Z, ZHANG Z, et al. An empirical study of spatial attention mechanisms in deep networks [C] // IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 6688 - 6697.
- [30] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C] // European Conference on Computer Vision (ECCV), 2018: 3 - 19.
- [31] DIEDERIK K, JIMMY B. Adam: a method for stochastic optimization [C] // The 3rd International Conference for Learning Representations, 2015.
- [32] GAI R, CHEN N, YUAN H. A detection algorithm for cherry fruits based on the improved YOLO - v4 model [J]. Neural Computing and Applications, 2023, 35: 13895 - 13906.

(上接第 224 页)

- [22] SELVARAJU R 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. IEEE, 2017.
- [23] MA N, ZHANG X, ZHENG H T, et al. ShuffleNet V2: practical guidelines for efficient cnn architecture design [C] // 15th European Conference on Computer Vision (ECCV), 2018: 122 - 138.
- [24] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J/OL]. Advances in Neural Information Processing Systems, 2012: 1097 - 1105. [https://papers.nips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b - Paper.pdf](https://papers.nips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf).
- [25] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [EB/OL]. [2014 - 12 - 19]. <https://arxiv.org/abs/1409.1556>.
- [26] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770 - 778.
- [27] 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 Ruirou, 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)
- [28] 彭红星,何慧君,高宗梅,等.基于改进 ShuffleNetV2 模型的荔枝病虫害识别方法 [J].农业机械学报,2022,53(12):290 - 300.
PENG Hongxing, HE Huijun, GAO Zongmei, et al. Litchi diseases and insect pests identification method based on improved ShuffleNetV2 [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(12):290 - 300. (in Chinese)