刘拥民, 胡魁, 聂佳伟, 等. 基于 MSDB-ResNet 的水稻病虫害识别 [J]. 华南农业大学学报, 2023, 44(6): 978-985. LIU Yongmin, HU Kui, NIE Jiawei, et al. Rice disease and pest identification based on MSDB-ResNet[J]. Journal of South China Agricultural University, 2023, 44(6): 978-985.

基于 MSDB-ResNet 的水稻病虫害识别

刘拥民^{1™},胡 魁¹,聂佳伟²,谢铁强¹ (1中南林业科技大学 计算机与信息工程学院/智慧林业云研究中心,湖南 长沙410004;2华南农业大学 动物科学学院,广东广州510642)

摘要:【目的】水稻产量关乎全人类的粮食安全,如何有效地预防和高效地检测水稻病虫害是智慧农业领域的重要课题。深度学习由于具备自主学习图像特征等优异性能,成为水稻病虫害识别的首选方法。但在自然环境下,数据集偏小,且容易受到复杂背景的影响,在训练过程中容易产生过拟合,以及细微特征难以提取等问题。本研究致力于解决上述问题。【方法】提出一种基于改进 ResNet 的多尺度双分支结构的水稻病虫害识别模型 (MSDB-ResNet)。在 ResNet 模型的基础上,引入 ConvNeXt 残差块,以优化残差块的计算比例,构建双分支结构,通过调整每条分支的卷积核大小,提取输入病害图像中大小不同的病害特征。针对现实环境复杂、数据集太小、过拟合等问题,利用从自然环境拍摄到的 5932 张水稻病虫害图像,使用随机亮度、运动模糊等数据预处理方法,以及镜像、裁剪、缩放等数据增强方法,将数据集扩充到 20000 张,训练 MSDB-ResNet 模型识别 4 种常见的水稻病害。【结果】MSDB-ResNet 在水稻病虫害数据集上具有良好的识别性能,识别准确率高达 99.10%,较原 ResNet 模型提高了 2.42 个百分点,明显优于 AlexNet、VGG、DenseNet 和 ResNet 等经典网络。该模型具有良好的泛化能力和极强的鲁棒性。【结论】MSDB-ResNet 模型在水稻病虫害识别中具有一定的可行性和先进性,可为实现复杂背景下的水稻病虫害识别提供参考。

关键词: 智慧农业: 水稻病虫害: 深度学习: 图像识别: ResNet: 数据增强

中图分类号: S435.11; TP183 文献标志码: A 文章编号: 1001-411X(2023)06-0978-08

Rice disease and pest identification based on MSDB-ResNet

LIU Yongmin¹, HU Kui¹, NIE Jiawei², XIE Tieqiang¹

(1 School of Computer and Information Engineering/Research Center of Smart Forestry Cloud, Central South University of Forestry and Technology, Changsha 410004, China; 2 School of Animal Science,

South China Agricultural University, Guangzhou 510642, China)

Abstract: 【Objective】 The yield of rice is related to food security of all mankind. How to effectively prevent and detect rice diseases and pests is an important topic in the field of smart agriculture. Deep learning has become the preferred method for identifying rice diseases and pests due to its excellent performance in self-learning image features. However, in natural environments, the dataset is relatively small and susceptible to complex backgrounds, resulting in overfitting and difficulty in extracting subtle features during training. This study aims to address the aforementioned issues. 【Method】 We proposed a rice disease and pest identification

收稿日期:2022-08-01 网络首发时间:2023-07-07 14:41:34

首发网址: https://kns.cnki.net/kcms2/detail/44.1110.S.20230707.1325.004.html

作者简介:刘拥民,教授,博士,主要从事深度学习、智慧农业研究,E-mail: T20040550@csuft.edu.cn

基金项目:国家自然科学基金 (31870532); 湖南省自然科学基金 (2021JJ31163); 湖南省教育科学"十三五"规划基金 (XJK20BGD048)

model with multi-scale dual branch structure based on improved ResNet (MSDB ResNet). On the basis of the ResNet model, ConvNeXt residual blocks were introduced to optimize the calculation proportion of residual blocks, construct a dual branch structure, and extract disease features of different sizes from the input disease image by adjusting the convolution kernel size of each branch. In response to issues such as complex real world environments, small datasets, and overfitting, a total of 5932 rice pest and disease images captured from natural environments was utilized. Using data preprocessing methods such as random brightness and motion blur, as well as data augmentation methods such as mirroring, cropping, and scaling, the dataset was expanded to 20 000 pictures. The MSDB-ResNet model was trained to identify four common rice diseases. 【Result】 MSDB-ResNet had good recognition performance on rice disease and pest datasets, with a recognition accuracy of 99.10%, which was 2.42 percentage points higher than the original ResNet model and obviously superior to classic networks such as AlexNet, VGG, DenseNet, ResNet, etc. This model had good generalization ability and strong robustness. 【Conclusion】 The MSDB ResNet model is feasible and progressiveness in the identification of rice diseases and pests, which provides a reference for the identification of rice diseases and pests under complex background.

Key words: Smart agriculture; Rice diseases and pests; Deep learning; Image recognition; ResNet; Data enhancement

预计到 2030 年世界总人口将超过 85 亿,而随着气候不断变化和城市急剧扩张,全球可用耕地面积一直在萎缩,同时气候变化带来的农作物病虫害问题不断攀升,粮食安全问题无疑成为当今世界面临的紧急性问题,以中国为例,根据农作物病虫害监测网站的报告,长江流域的广大产粮区,2017 年农作物病虫害发生面积同比增长 26.6%,仅2020 年,中国农作物重大病虫害累计发生面积就高达3亿 hm²,病虫害不单影响粮食产量,还可能带来重大经济损失[1-3]。

随着深度学习的不断发展,特别是在农作物病 虫害识别领域的应用研究不断深入,通过对病害图 像的特征提取、分类识别,能够做到对农作物病虫 害的正确识别和及时预防,大大节省人力、物力,有 望将经济损失降到最低[4-5]。基于深度学习的农作物 病虫害识别流程包括数据的采集、训练模型的构建 以及推理验证[6-7]。陆健强等[8] 提出了一种基于 Mixup 算法和卷积神经网络的柑橘黄龙病识别模 型,通过数据增强和迁移学习,最终模型的识别准 确率达到 94.29%。黄林生等[9] 以 ResNet 为基础模 型,结合 Inception 模块,对不同尺度病害特征进行 提取,并引入注意力机制,提出了在复杂环境下的 农作物叶片病害识别模型,平均识别准确率达到了 95.62%。骆润玫等[10] 以 YOLOv5s 为基础模型, 通 过引入多尺度特征融合模块,提出了一种基于 YOLOv5-C的广佛手病虫害识别方法,在复杂背景 下,识别准确率达到 93.61%。于合龙等[11] 提出一种面向水稻病虫害的知识图谱构建方法和基于图像的水稻病虫害检索算法,诊断算法正确率达到 86.25%。Chen等[12] 以水稻病害为研究对象,利用 VGGNet 在大型标记数据集 ImageNet 上进行预训练来初始化权值,然后进行迁移学习,将预训练得到的初始化权值转移到目标数据集上进行训练,试验表明,复杂的背景条件下,对水稻病害图像识别平均精度达到 92.00%。袁培森等[13] 利用 Inception模块的特征提取能力,提出了一种基于迁移学习结合 ResNet-v2 网络的菌菇识别方法,以此来提高对菌菇图像细粒度特征提取的能力,对细粒度菌类表型识别的准确率达到 93.94%。上述基于深度学习的农作物病虫害识别方法,为目前农作物病虫害识别研究提供了重要参考。

但基于深度学习的农作物病虫害识别方法依然存在着不足,当前农作物病虫害数据集大多为室内采集图像,然而在实际应用中,自然环境下的样本图像具有复杂背景,在训练过程中模型容易受到复杂背景的影响,深度学习训练模型容易学习到复杂背景中的无关特征,忽视对微小病害特征的提取,导致识别准确率下降。并且在自然环境条件下,田间作物叶片往往处于强烈光照、运动摇曳的状态,这会影响到模型对病害特征的提取。同时,在实际场景中拍摄的数据集样本数太少,在训练中容易产生过拟合现象,在模型验证过程中会导致识

别准确率急剧下降。针对以上问题,本研究提出一种基于改进 ResNet 的多尺度双分支 (Multi-scale dual-branch, MSDB) 结构水稻病虫害识别模型 (MSDB-ResNet),首先利用随机亮度、运动模糊等数据预处理方法来模拟复杂环境下作物叶片状态,让深度学习模型提前训练这类复杂样本图像,加强模型的泛化能力和鲁棒性,同时对获取到的5932 张水稻病虫害图像进行数据增强处理,将数据集扩充到 20000 张,以缓解训练中的过拟合现象。在模型构建中,为了更好地提取微小病害特征,同时避免过拟合的发生、提高识别准确率,在 ResNet模型的基础上,引入 ConvNeXt中的残差模块,以优化 ResNet 模型中的残差块计算比例,同时构建多尺度的双分支结构,利用不同尺度的卷积核分别提取不同尺度的病害特征,然后进行特征融合,最后

经过 Softmax 层输出分类结果,以解决复杂背景导致的微小病害难以提取的问题,最终提高模型识别准确率。

1 数据及模型构建

1.1 试验数据

1.1.1 试验数据获取 本数据集包含 4 类水稻叶片病害图片,共 5932 张,其中,水稻白叶枯病 1584 张,水稻稻瘟病 1440 张,水稻褐斑病 1600 张,水稻桐木病 1308 张,均拍摄于自然环境下,保存为 JPG 格式[14],图像大小调整为 224 像素×224 像素。按照 8:2 的数量比例将该数据集划分为训练集和验证集,在随机打乱的情况下,进行训练和验证。部分样本图像如图 1 所示。



a: 水稻白叶枯病 a: Rice bacterial blight



b: 水稻稻瘟病 b: Rice blast



c: 水稻褐斑病 c: Rice brown spot



d: 水稻桐木病 d: Rice tungro

图 1 水稻病害样本图片

Fig. 1 Sample images of rice diseases

1.1.2 数据预处理 现实场景中,强烈的光照直射会影响模型对病害特征的提取,水稻叶片往往相互交错,互相遮挡使病害特征更加难以提取,晃动的叶片不容易聚焦,考虑到以上实际因素,本文通过高斯噪声、随机遮挡、随机亮度、运动模糊等图像预处理方法^[15],对原始数据集进行预处理。在对

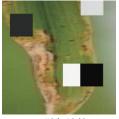
原始数据集图像进行批量化预处理后,构建新的增强数据集。让模型在训练过程中,能够学到更多复杂环境下的病害特征,以达到模拟实际场景的目的,提高模型验证准确率。图 2 为部分图像预处理样本。



a: 高斯噪声 a: Gaussian noise



b: 随机亮度 b: Random brightness



c: 随机遮挡 c: Random occlusion



d: 运动模糊 d: Motion blur

图 2 数据预处理样本图片

Fig. 2 Sample images of pre-processing

1.1.3 数据增强 在农作物病虫害识别领域,数据增强的方法主要应用在小样本数据集或病虫害类别图像样本不平衡数据集上,以此来增加样本数或让数据集尽量平衡。随着深度学习模型的深入,参

数越来越庞大,为了让小型数据集能够正常训练,提高准确率,数据增强的方法尤为重要,由于本研究的数据集样本数量不足,各病害类别数量存在不平衡的情况,因此通过镜像、裁剪、缩放、平移和旋

转等数据增强方法^[16],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。本研究使用的水稻病害数据集包含 4 类水稻病害,共 5 932 张,使用数据增强方法,将每类病害样本扩充到 5000 张图片 (增强数据集),其中,训练集和验证集数量比为 1:4, 共计20000 张图片。

1.2 模型构建

1.2.1 卷积神经网络理论 卷积神经网络的组成部分主要包括卷积层、池化层和全连接层。卷积层通过卷积核对输入的图像样本进行卷积计算,提取图像中的关键特征,卷积层的输出是输入在空间维度上某一级的表征,也叫特征图 (Feature map)[17],卷积层输入和输出之间的关系可用式 (1) 表示。

$$H_i = \varphi(H_{i-1}W_i + b_i), \tag{1}$$

式中, H_i 表示第 i 层的特征图; H_{i-1} 表示第 i-1 层的特征,即上一层的特征输入当前卷积层; W_i 表示第 i 层的权重,为可学习参数; b_i 为第 i 层的偏置量; $\varphi()$ 为激活函数。池化层可缓解卷积层对位置的过度敏感性,分为最大值池化和平均池化,分别取池化窗口中输入元素的最大值和平均值作为输出,其输出通道和输入通道保持一致。池化层计算公式如式 (2) 所示。

$$X_j^l = \operatorname{down}\left(X_j^{l-1}, s\right), \tag{2}$$

式中, X_j^l 代表当前池化层的输出特征,down()为下采样函数, X_j^{l-1} 为上一层的特征向量,s 为池化窗口大小。经过卷积层的卷积运算和池化层的池化运算之后,将输出的特征向量输入全连接层中,对提取的特征进行分类。本研究中,采用 Softmax 分类器进行分类计算,具体的计算公式如式 (3) 所示。

Softmax
$$(Z)_j = e^{z_j} / \sum_{K=1}^K e^{z_k} (j = 1, \dots, K),$$
 (3)

Softmax 函数是 $0\sim1$ 之间的映射,由于各类别输出的概率值之和不等于 1,利用 e^{z_j} 对每个类别的输出概率进行 e 指数运算,然后进行求和 $\sum_{K=1}^{K}$ e^{z_k} ,最后得出的结果 Softmax(Z) $_j$ 为 $0\sim1$ 。由于 Sigmoid 极容易导致梯度消失问题,为解决该问题,本研究中采用非饱和激活函数 ReLU 作为本试验的激活函数 \mathbb{R} \mathbb{R}

考虑到本研究为多分类试验,采用随机梯度下降 (Stochastic gradient descent, SGD) 作为优化器^[19]。 具体的计算如式 (4) 所示。

$$\theta_j := \theta_j + \alpha \left[y^{(i)} - h_\theta \left(x^{(i)} \right) \right] x_j^{(i)}, \tag{4}$$

式中, α 代表步长, $h_{\theta}(x^{(i)})$ 代表假设函数 (Hypotheses function), θ_j 的初始值可为任意值,按照梯度下降的方向不断迭代、更新参数。

1.2.2 ResNet 残差理论 为解决梯度消失问题,2016 年 He 等[20] 提出了 ResNet,其核心思想是上一层输出的X,在经过本层的卷积计算得到F(X)后,将X与F(X)相加得到H(X),这样做的目的是在进行反向传播求导时,即使F(X)梯度趋近 0,梯度消失时,X这一项还会留下 1,巧妙的避免了在反向传播时梯度消失的问题。ResNet 中核心的残差结构如图 3 所示。

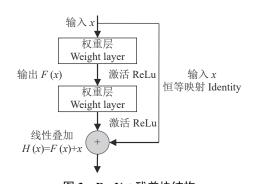


图 3 ResNet 残差块结构 Fig. 3 ResNet residual block structure

尽管 ResNet 网络良好地避免了过拟合的问题,但还存在可改进的地方,ResNet 模型在设计之初,模型主要由含有不同数量瓶颈模块的 4 个阶段组成,每个阶段中的瓶颈模块数量比例很大程度上是根据经验提出来的,其中 ResNet50 的比例为3:4:6:3,ResNet101 的比例为3:4:23:3,ResNet152 的比例为3:8:36:3。可见,每个阶段中的瓶颈模块数量比例还存在更加优异的比例,优化模型性能。

1.2.3 ConvNeXt 残差模块 2022 年 Facebook 人工智能研究院提出 ConvNeXt 卷积神经网络^[21-22],在 ImageNet top-1 数据集上实现了 87.8%的精度,超过了此前 Swin transformer 取得的最高准确率 (81.3%)^[23-24],其中 ConvNeXt 网络中的残差块计算比例借鉴 Transformer 的设计比例 (1:1:3:1),ConvNext 网络中的残差块比例为 3:3:9:3,将模型的精度从 78.8%提高到 79.4%。ConvNeXt 模型中残差块的提出,优化了每个阶段中的瓶颈模块的数量比例。本研究以 ResNet50 为基础模型,将ConvNext 中的残差块引入 ResNet50,通过优化残差块的数量比例,在原有基础上提高原始 ResNet50的模型精度。具体模型参数如表 1 所示,模型整体架构由 2 个分支构成,每个分支主要由 1 个根茎层和 4 个阶段组成,根茎层由一个 7×7 的卷积层和一

表 1 模型计算参数 Table 1 Model computation parameter

阶段	输出大小	分支 Branch	
Stage	Output size	MSDB-ResNet-I	MSDB-ResNet- II
stem	56×56	7×7, 64, stride 2	7×7, 64, stride 2
		3×3 max pool, stride 2	3×3 max pool, stride 2
res2	56×56	1×1,64 3×3,64×3	1×1, 64 3×3, 64×3
	•••	1×1,256	1×1, 256
res3	28×28	$1 \times 1,128$ $3 \times 3,128 \times 3$ $1 \times 1,128$	$1 \times 1,128$ $5 \times 5,128 \times 3$ $1 \times 1,128$
res4	14×14	1×1,256 3×3,256×9 1×1,1024	1×1,256 5×5,256×9 1×1,1024
res5	7×7	1×1,512 3×3,512×3 1×1,2048	1×1,512 3×3,512×3 1×1,2048

个 3×3 的最大值池化层组成,以保持输出特征分辨率不变。4 个阶段包含不同数量的瓶颈模块,其比例为 3:3:9:3。

多尺度双分支结构 模型中常见的卷积核 1.2.4 大小为 1×1、3×3、5×5 和 7×7, 由于卷积核的大小各 异,模型在训练中容易出现丢失小特征,或是容易 学习到复杂背景中的特征的现象,导致识别准确率 不高[25]。针对该问题,本文提出基于改进 ResNet 的 多尺度双分支结构,以 ResNet-50 为基础架构,构建 双分支的 ResNet 模型,将大卷积核和小卷积核分 别放在不同的2条支路中,分别用来提取不同大小 的病害特征,同时降低复杂背景的影响。模型框架 如图 4 所示,输入图像经过数据预处理和数据增强 后,分别输入2条不同的分支中,在每条分支前经 过含有 1 个由 7×7 的卷积层、ReLu 激活层以及 1个3×3的最大值池化层组成的基茎层。之后进入 4个不同的阶段中,其中第1个、第2个和第4个阶 段中含有3个瓶颈模块结构,第4个阶段中含有 9个瓶颈模块结构。瓶颈模块结构如图 4 所示, 先 经过1个带有1×1卷积层的残差连接1个2个恒 等映射 X 的残差连接, 以避免模型训练中过拟合的 发生。分支1中的瓶颈模块结构,其卷积层构成主 要为 1×1、3×3 卷积核,分支 2 中的瓶颈模块结构,

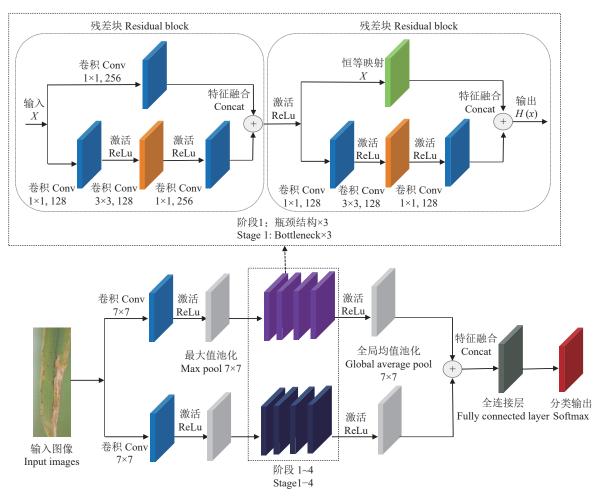


图 4 MSDB-ResNet 框架

Fig. 4 MSDB-ResNet architecture

其卷积层主要由 5×5 卷积核构成,通过不同大小的卷积核算子,提取不同尺度的特征,避免细微病害特征被复杂背景影响,导致关键病害没有提取到。经过 2 条不同尺度的网络分支提取特征后,进行ReLu 激活连接和全局均值池化,输入 Concat 层进行特征融合,最后输入全连接层和 Softmax 层,输出分类结果。

2 试验结果与分析

2.1 试验环境

试验软件环境为 Windows 10 64 位系统, 采用 Pytorch 深度学习开源框架, 选用 Python 作为编程语言。计算机内存为 16 GB, 搭载 AMD Ryzen 7 5800H with Radeon Graphics 处理器, 并采用 NVIDIA GeForce RTX 3070 Laptop 显卡。

2.2 试验参数

本研究采用 SGD 优化算法、CrossEntropyLoss 损失函数,每批次训练样本数 (Batch size) 设置为32,训练轮数为20,初始学习率设置为0.01,并设置动量为0.9,权重衰减 (Weight decay) 设置为1×10⁴。

2.3 模型评价指标

本文采用平均识别准确率 (Accuracy) 作为模型的评价指标:

Accuracy =
$$\frac{1}{c} \sum_{j=1}^{c} \frac{n_{jj}}{n_j} \times 100\%,$$
 (5)

式中,c 表示类别数, n_j 表示第 j 类数量, n_{jj} 表示第 j 类预测正确数量。

2.4 数据预处理与增强试验

为验证本研究所提出的模型性能,对数据预处理、数据增强方法以及模型改进方法分别进行了多次试验。其中,对数据预处理和数据增强方法分别在基础模型 ResNet-50 和 MSDB-ResNet 模型上进行对比试验。对模型改进方法分别在原始数据集、数据预处理和数据增强后的数据集上进行试验。试验结果如图 5 所示。

ResNet-50 模型对原始数据集识别准确率为96.68%,对增强数据集的识别准确率为98.26%,提升了1.58个百分点。可见,利用高斯噪声、运动模糊、随机亮度、随机遮挡等数据预处理和数据增强方法,能够提升模型识别准确率。ResNet-50 模型对原始数据集的识别准确率为96.68%;引入ConvNet 残差模块,同时构建双分支的MSDB-ResNet 模型对原始数据集的识别准确率为99.06%,较ResNet-50提升了2.38个百分点。可

— ResNet-50 原始数据集 Original dataset of ResNet-50 — MSDB-ResNet 原始数据集 Original dataset of MSDB-ResNet — ResNet-50 增强数据集 Augument dataset of ResNet-50 — MSDB-ResNet 增强数据集 Augument dataset of MSDB-ResNet

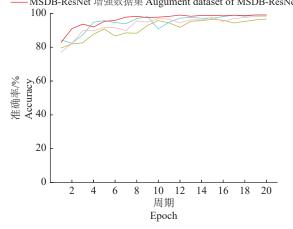


图 5 准确率曲线 ig. 5 Accuracy curves

见,MSDB-ResNet 具有良好的性能,能够显著提升模型识别准确率。MSDB-ResNet 对增强数据集的识别准确率为99.10%,相比于原始的 ResNet50 未进行数据增强所取得的准确率,显著提升了2.42 个百分点。可见,MSDB-ResNet 能够提升水稻病虫害识别准确率。

2.5 模型改进试验

为验证模型的鲁棒性和泛化能力,在使用相同 的增强数据集的情况下,将 MSDB-ResNet 与 AlexNet、VGG、DenseNet 和 ResNet 进行对比试 验,结果见图 6,在使用相同增强数据集的情况下, AlexNet 和 VGG-16 对验证集识别的准确率分别为 95.07% 和 95.79%, 远低于 MSDB-ResNet 的 99.10%, 说明在复杂环境背景下, 不断增加网络层 数不一定会提高模型识别准确率, 甚至可能会受复 杂背景所影响,从而导致模型识别准确率降低,而 MSDB-ResNet 模型对农作物的病虫害识别具有良 好的性能。DenseNet-121 与 ResNet-50 对验证集识 别的准确率分别为 96.53% 和 96.25%, 同样低于 MSDB-ResNet 所取得的 99.10%, 可见, 含有相同残 差连接的 DenseNet-121 与 ResNet-50 在相同数据 集上取得的识别准确率远低于 MSDB-ResNet, 模型 改进方法具有一定的可行性。

如图 6 所示,在准确率高于其他模型的情况下,MSDB-ResNet模型训练收敛速度同样远高于模型 AlexNet、VGG、DenseNet和 ResNet。以上结果表明,本研究所提出的 MSDB-ResNet水稻病虫害识别模型,在复杂背景环境下,具有良好的鲁棒性和泛化能力。图 7 为模型的卷积核与特征图可视化图。

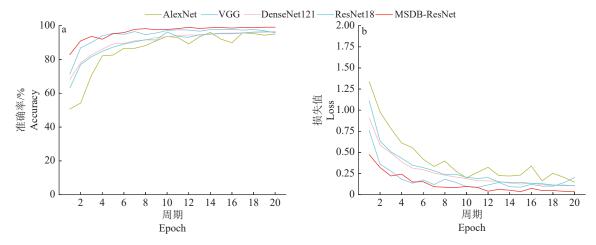


图 6 模型对增强数据集的准确率与损失值曲线

Fig. 6 Accuracies and loss curves of models to augument dataset

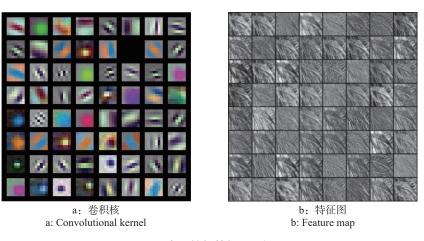


图 7 卷积核与特征图可视化

Visualization of the convolutional kernel and feature map

3 结论

农作物病虫害一直是影响世界粮食产量的重 要因素,由于优异的分类识别性能,深度学习中的 卷积神经网络广泛应用于农作物病虫害识别领域。 本研究以水稻白叶枯病、水稻稻瘟病、水稻褐斑病、 水稻桐木病作为研究对象,提出了1种新的卷积神 经网络模型 MSDB-ResNet, 用于水稻病害的识别。 利用高斯噪声、随机亮度、随机遮挡、运动模糊等数 据预处理方法对水稻病害数据集进行数据预处理、 数据增强和数据平衡,将5932张原始数据集扩充 到 20000 张。以 ResNet-50 为基础框架, 在此基础 上引入 ConvNeXt 中残差模块,将 ResNet-50 中 4个阶段中的瓶颈模块比例由 3:4:6:3 调整为 3:3:9:3,以此为基础,构建双分支结构,将输入的病 害图片分别输入2条分支之中,以提取不同大小的 病害特征,经 Concat 层进行特征融合,最后使用 Softmax 输出结果。试验结果表明,该模型在水稻 病虫害数据集上具有良好的识别性能, 在经过数据

预处理和数据增强的水稻病害数据集上,实现了99.10%的病害识别验证精度,相比于 ResNet-5096.68%的识别准确率提高了2.42个百分点,并明显高于 AlexNet、VGG-16、DenseNet-121等经典深度学习模型,具有良好的鲁棒性和泛化能力。后续计划进行模型轻量化研究,减少训练所需的数据集样本,并打算将其部署在移动设备上,应用在实际环境中,进行农作物病虫害识别。

参考文献:

- [1] 姜玉英, 刘万才, 陆明红, 等. 2020 年全国农作物重大 病虫害发生趋势预报[J]. 中国植保导刊, 2016, 36(2): 37-42.
- [2] 边柯橙, 杨海军, 路永华. 深度学习在农业病虫害检测识别中的应用综述[J]. 软件导刊, 2021, 20(3): 26-33.
- [3] 汪京京, 张武, 刘连忠, 等. 农作物病虫害图像识别技术的研究综述[J]. 计算机工程与科学, 2014, 36(7): 1363-1370.
- [4] PATRÍCIO D I, RIEDER R. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review[J]. Computers and Electronics in

- Agriculture, 2018, 153: 69-81.
- [5] 胡林, 刘婷婷, 李欢, 等. 机器学习及其在农业中应用研究的展望[J]. 农业图书情报, 2019, 31(10): 12-22.
- [6] 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.
- [7] 周惠汝, 吴波明. 深度学习在作物病害图像识别方面应用的研究进展[J]. 中国农业科技导报, 2021, 23(5): 61-68.
- [8] 陆健强, 林佳翰, 黄仲强, 等. 基于 Mixup 算法和卷积神 经网络的柑橘黄龙病果实识别研究[J]. 华南农业大学 学报, 2021, 42(3): 94-101.
- [9] 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.
- [10] 骆润玫, 殷惠莉, 刘伟康, 等. 基于 YOLOv5-C 的广佛 手病虫害识别[J]. 华南农业大学学报, 2023, 44(1): 151-160.
- [11] 于合龙, 沈金梦, 毕春光, 等. 基于知识图谱的水稻病虫害智能诊断系统[J]. 华南农业大学学报, 2021, 42(5): 105-116.
- [12] 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. doi: 10.1016/j.compag.2020.105393.
- [13] 袁培森, 申成吉, 徐焕良. 基于迁移学习和双线性 Inception-ResNet-v2 的细粒度菌菇识别方法[J]. 农业机械学报, 2021, 52(7): 1-10.
- [14] SETHY P K, BARPANDA N K, RATH A K, et al. Deep feature based rice leaf disease identification using support vector machine[J]. Computers and Electronics in Agriculture, 2020, 175: 105527. doi: 10.1016/j.compag. 2020.105527.
- [15] WU H, WIESNER-HANKS T, STEWART E L, et al. Autonomous detection of plant disease symptoms directly from aerial imagery[J]. The Plant Phenome Journal, 2019, 2(1): 1-9.
- [16] CRUZ A C, LUVISI A, DE BELLIS L, et al. X-FIDO:

- An effective application for detecting olive quick decline syndrome with deep learning and data fusion[J]. Frontiers in Plant Science, 2017, 8: 1741. doi: 10.3389/fpls.2017. 01741.
- [17] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [18] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [19] LU Y, YI S J, ZENG N Y, et al. Identification of rice diseases using deep convolutional neural networks[J]. Neurocomputing, 2017, 267: 378-384.
- [20] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [21] LIU Z, MAO H Z, WU C Y, et al. A ConvNet for the 2020s[C]//2022 IEEE/CVE Conference on Computer Vision and Pattern Recognition. New Orleans, LA, USA: IEEE, 2022: 11966-11976.
- [22] Anon. GitHub repository: ConvNeXt[EB/OL]. [2022-08-01]. https://github.com/facebookresearch/ConvNeXt.
- [23] LIU Z, LIN Y, CAO Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]// 2021 IEEE/CVF International Conference on Computer Vision. Montreal, QC, Canada: IEEE, 2022: 9992-10002.
- [24] Anon. GitHub repository: Swin transformer[EB/OL]. [2022-08-01]. https://github.com/microsoft/Swin-Transformer.
- [25] 郭小清, 范涛杰, 舒 欣. 基于改进 Multi-Scale AlexNet 的番茄叶部病害图像识别[J]. 农业工程学报, 2019, 35(13): 162-169.

【责任编辑 霍 欢】