

陆煜, 俞经虎, 朱行飞, 等. 基于卷积神经网络的轻量级水稻叶片病害识别模型[J]. 江苏农业学报, 2024, 40(2): 312-319.
doi:10.3969/j.issn.1000-4440.2024.02.013

基于卷积神经网络的轻量级水稻叶片病害识别模型

陆煜^{1,2}, 俞经虎^{1,2}, 朱行飞^{1,2}, 张不凡^{1,2}

(1. 江南大学机械工程学院, 江苏 无锡 214122; 2. 江苏省食品先进制造装备技术重点实验室, 江苏 无锡 214122)

摘要: 水稻病害一直是影响水稻产量的重要因素之一, 为了快速、准确地检测水稻病害, 本研究提出了一种基于卷积神经网络的轻量级水稻叶片病害识别模型。首先, 从参数量的角度对注意力机制进行改进, 得到轻量级注意力机制模块, 对水稻叶片病害特征图中的潜在注意力信息进行深度挖掘; 其次, 使用深度可分离卷积代替部分标准卷积, 进一步降低模型的参数量; 最后, 为了提高模型的泛化能力, 让模型学习过程更快、更稳定, 采用了自带内部归一化属性的扩展型指数线性单元函数(SELU)与外部组归一化模块相结合的方法。通过在公共数据集中进行验证, 本研究构建模型的平均精度最高(0.990 0), 模型在参数量和平均单次迭代时间方面也有一定优势, 与其他模型相比, 具有相对较好的性能。

关键词: 水稻病害; 组归一化; 激活函数; 深度可分离卷积; 注意力机制

中图分类号: S511 **文献标识码:** A **文章编号:** 1000-4440(2024)02-0312-08

A lightweight rice leaf disease recognition model based on convolutional neural network

LU Yu^{1,2}, YU Jing-hu^{1,2}, ZHU Xing-fei^{1,2}, ZHANG Bu-fan^{1,2}

(1. School of Mechanical Engineering, Jiangnan University, Wuxi 214122, China; 2. Jiangsu Key Laboratory of Advanced Food Manufacturing Equipment & Technology, Wuxi 214122, China)

Abstract: Rice diseases have always been one of the important factors affecting rice yield. In order to quickly and accurately detect rice diseases, this study proposed a lightweight rice leaf disease recognition model based on convolutional neural network. Firstly, from the perspective of the number of parameters, the attention mechanism was improved to obtain a lightweight attention mechanism module, and the potential attention information in the rice leaf disease feature map was deeply mined. Secondly, the depthwise separable convolution was used to replace some standard convolutions to further reduce the parameters of the model. Finally, in order to improve the generalization ability and make the model learning process faster and more stable, a method of combining the scaled exponential linear unit (SELU) activation function with internal normalization attribute and the external group normalization module was adopted. By verifying in the public data

set, the average accuracy of the model constructed in this study was the highest (0.990 0). The model also had certain advantages in terms of parameter quantity and average single iteration time. Compared with other models, it had relatively higher performance.

Key words: rice disease; group normalization; activation functions; depthwise separable convolution; attention mechanism

收稿日期: 2023-04-23

基金项目: 国家自然科学基金项目(51375209); 江苏省先进食品制造装备与技术重点实验室资助项目(FMZ201901)

作者简介: 陆煜(1998-), 男, 安徽滁州人, 硕士研究生, 主要从事农业工程、深度学习研究。(E-mail) jnluyu@stu.jiangnan.edu.cn

通讯作者: 俞经虎, (E-mail) jnjxjinghu@163.com

水稻病害作为除天气因素外对水稻产量影响最大的因素之一,长久以来备受人们关注^[1]。快速、准确的水稻病害检测技术对于水稻的生长管理具有重要意义。为了提高植物病害诊断速度以及诊断结果的准确性,研究人员基于机器学习算法[如随机森林法、支持向量机法(SVM)]对自动化植物病害诊断进行了大量的研究^[2-4]。王献锋等^[5]通过提取叶片病灶的颜色、形状、质地特征,并结合环境信息开发了一种判别分析方法来识别黄瓜病灶。Zhang等^[6]提取了病灶分割后的植物叶片病灶颜色、形状、纹理特征,然后利用近邻算法(K-nearest neighbor, KNN)分类器对5种类型的玉米叶片进行分类识别等。Xie等^[7]提出了一种具有多级学习特征的田间作物害虫自动分类器。Sankaran等^[8]开发了植物健康监测传感器系统,帮助监测田间条件下的植物健康和疾病状况。Li等^[9]提出了一种改进的用于农业作物害虫自动定位和计数的深度学习管道,该管道集成了Zeiler、Fergus模型的卷积神经网络(CNN)和非极大值抑制(NMS)的区域提议网络(RPN)。孟亮等^[10]针对CNN模型存在训练参数数量大而无法应用于硬件条件受限的场合这一问题,提出一种轻量级CNN农作物病害识别模型,能够在保证模型识别准确率的情况下简化模型结构,扩大模型的适用场景。


虽然深度学习在农业机械领域应用越来越广泛,在水稻叶片病害识别方面的应用中取得了优异的成果,但在网络模型性能方面依旧存在改进空间。为了缩短模型训练收敛时间,减少当前大多数网络模型的参数量,提高识别精度,本研究拟构建一种新的轻量级水稻叶片病害识别模型,通过对卷积注意力机制模块(CBAM)进行改进,得到轻量级Conv_L2_CBAM模块进行特征的重新校准,从而对卷积神经网络通道中的特征进行加权,采用深度可分离卷积替换标准卷积,进一步降低神经网络模型的计算量和参数量,此外使用扩展型指数线性单元函数(SELU)以及外部组归一化(GN)^[11]模块提高神经网络的收敛性能,以期能快速、准确地检测水稻病害提供技术支持。

1 材料与方法

1.1 基于深度学习的水稻病害识别模型构建

1.1.1 轻量级注意力机制模块设计 使用注意力

机制模块的深度学习模型通常能在图像识别分类任务上取得更加理想的处理效果。CBAM^[12]作为一种常在卷积神经网络中引入的注意力机制模块,它在多种视觉任务中皆表现出优良的性能,它包含通道注意力模块(CAM)和空间注意力模块(SAM)2个子模块,分别用于进行通道和空间上的注意力操作,这样能够在节约参数和减少计算开销的基础上,保证其能够作为即插即用的模块集成到现有的网络架构中的同时不会对神经网络的整体复杂性产生影响。为了帮助我们的水稻叶片病害识别模型更有效地利用计算资源,达到轻量化的目的,我们将注意力机制模块引入到水稻叶片病害模型检测中并改进,即使用L2池化操作替换CBAM模块中的最大池化,结构如图1所示。



L2Pool 表示 L2 池化; AvgPool 表示平均池化; Shared MLP 表示相同特征的转换和提取; Channel Attention 表示通道注意力。

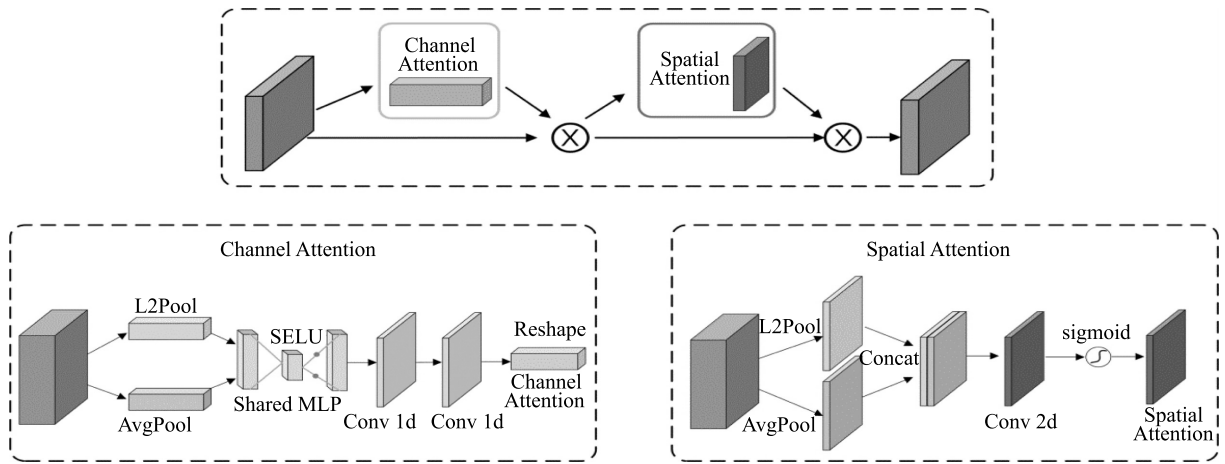
图1 改良的通道注意力机制模块结构图

Fig.1 The structure diagram of the improved channel attention mechanism module

相较于最大池化, L2 池化的表现更好, 可以提高模型的分类准确率。这是因为 L2 池化的运算过程比最大池化更加平缓, 将最大池化替换为 L2 池化可以消除水稻叶片病害特征中的一些不必要的边缘信息, 从而使水稻叶片病害识别模型可以更好地学习任务的关键特征, 避免一些过拟合情况的发生。

此外, 为了使使用注意力机制模块的神经网络模型达到轻量化的目的, 需要尽可能降低模型的参数量, 本研究提出一种在使用 L2 池化操作的基础上, 使用卷积层代替全连接层来进行改良的 Conv_L2_CBAM 注意力机制模块, 结构如图2所示。

由于全连接层存在大量参数, 因此需要更多的计算能力和存储空间, 与卷积层相比, 会增加训练和



Channel Attention 表示通道注意力; Spatial Attention 表示空间注意力; L2Pool 表示 L2 池化; AvgPool 表示平均池化; Shared MLP 表示相同特征的转换和提取; SELU: 扩展型指数线性单元函数; Conv 1d 表示一维卷积; Conv 2d 表示二维卷积; sigmoid 表示 S 型激活函数; Concat 表示连接; Reshape 表示重塑。

图 2 Conv_L2_CBAM 注意力机制模块结构图

Fig.2 The structure diagram of Conv_L2_CBAM module

推理的时间以及资源成本。Conv_L2_CBAM 模块结构参照 CBAM 结构由通道注意力模块和空间注意力模块 2 个部分组成。Conv_L2_CBAM 模块与 CBAM 模块的区别在于在通道注意力模块中用了 2 个卷积层来替换全连接层,并在卷积层之间添加非线性激活函数 Scaled ELU。与 CBAM 模块相比,Conv_L2_CBAM 模块的优点在于卷积层的参数仅与输入和输出的尺寸有关,而与卷积核的尺寸无关,因此可以大大减少参数量,从而降低模型的容量,避免过拟合问题,并且卷积层主要依赖矩阵乘法加速,能够显著降低计算需要的时间和资源。

1.1.2 轻量级卷积模块设计 标准卷积运算所涉及的参数量较多,计算量大,而 Howard 等^[13]提出的深度可分离卷积算法为模型的轻量化提供了新的方法。为了降低水稻叶片病害识别模型的计算量,本研究选用深度可分离卷积(DWConv)代替原卷积神经网络中的标准卷积,使模型获得更小体积的同时,还能降低模型的计算量,避免了大体积模型只能在高算力的服务器中运行的缺点,方便应用于受硬件资源和算力限制的移动设备。

深度可分离卷积主要分为深度卷积和逐点卷积 2 个部分,具体见图 3。深度卷积是对输入特征图的每个通道独立进行卷积操作,对于每个通道,都有一个单独的卷积核,这些卷积核的大小通常较小。由于每个通道的卷积操作是独立的,因此深度卷积可

以大大减少计算量。逐点卷积是在深度卷积的基础上进行的,它使用 1×1 的卷积核对深度卷积的输出特征图进行卷积操作。逐点卷积的目的是将深度卷积得到的特征图进行线性组合,从而得到最终的输出特征图。

标准卷积参数量 N 的计算参照公式(1):

$$N = Y \times Z \times D \times M \quad (1)$$

深度可分离卷积参数量 N_d 的计算参照公式(2):

$$N_d = Y \times Z \times D + 1 \times 1 \times D \times M \quad (2)$$

标准卷积计算量 C 的计算参照公式(3):

$$C = Y \times Z \times (W - Y + 1) \times (H - Z + 1) \times M \times D \quad (3)$$

深度可分离卷积计算量 C_d 的计算参照公式(4):

$$C_d = Y \times Z \times (W - Y + 1) \times (H - Z + 1) \times D + 1 \times 1 \times Y \times Z \times D \times M \quad (4)$$

式中, Y 为卷积核数量; Z 为内核数量; D 为输入通道数; M 为输出通道数; H 为输入图像高度; W 为输入图像宽度。

将标准卷积与深度可分离卷积的计算公式进行比较,发现深度可分离卷积的参数量和计算量要明显少于标准卷积。

1.1.3 激活函数和归一化算法的改进 2017 年,基于线性整流函数(ReLU),Klambauer 等^[14]提出了激活函数 SELU,该激活函数可以使神经网络自带内部

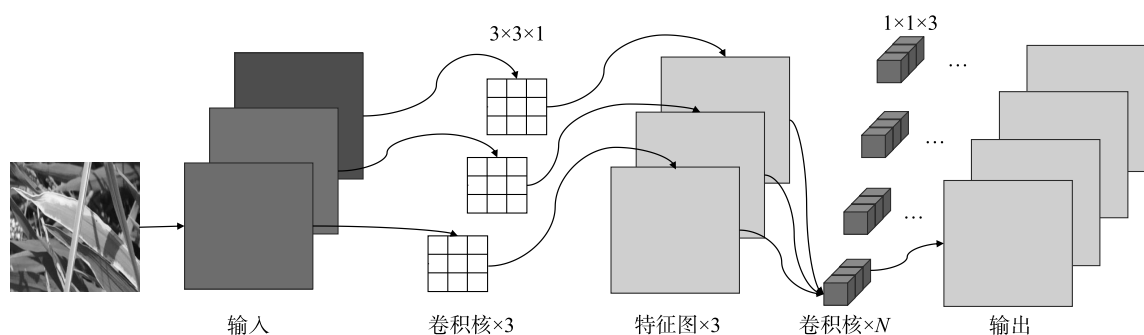


图3 深度可分离卷积示意图

Fig.3 Schematic diagram of depthwise separable convolution

归一化属性。为了在消除使用 ReLU 的神经网络模型所产生的神经元失活、梯度消失和梯度爆炸等问题的基础上,加速模型的收敛,提高模型的泛化能力,本研究采用激活函数 SELU 代替传统神经网络的激活函数 ReLU。

激活函数 SELU 方程式见公式(5):

$$\text{selu}(x) = \lambda \begin{cases} x & x > 0 \\ \alpha e^x - \alpha & x \leq 0 \end{cases} \quad (5)$$

式中, $\lambda = 1.673\ 263\ 242\ 354\ 377\ 284\ 817\ 042\ 991\ 671\ 7$; $\alpha = 1.050\ 700\ 987\ 355\ 480\ 493\ 419\ 334\ 985\ 294\ 6$; x 为神经元的输入信号。

此外,为了降低水稻叶片病害识别模型对硬件算力的依赖,本研究采用 GN 代替批归一化(BN)^[15]作为神经网络模型算法的外部归一化模块,GN 的归一化方式是将输入数据在通道方向分成多个组,然后在每个组内的所有通道上计算均值和方差,这样计算与批次大小无关,不受其约束,而 BN 则是在一个批次中的所有样本的同一通道上计算均值和方差,直接对整个批次的数据进行归一化。因此在特征捕捉方面,GN 更适用于捕捉水稻叶片病害图像的局部特征。对于不同的批次大小,GN 所表现出的性能和精度都较为稳定,使算法具有更广泛的适用性。

1.1.4 水稻叶片病害识别模型构建 本研究对 VGG16 卷积神经网络模型结构进行修改,由以 SELU 作为激活函数的 3 个二维卷积层(Conv2d)和 6 个可分离卷积层(DWConv)以及改良后的轻量级 CBAM 模块和 GN 模块组成。通过注意力机制模块前的卷积层对训练图像的特征由低到高进行自主学习,其中更深的卷积层降低了更多的特征图分辨率,

并提取更多抽象的高级特征,将 GN 模块插入卷积层以改善中间层数据分布,改善模型的泛化能力,减少过拟合,提高模型的准确率,它可以帮助模型更好地捕捉目标图像的局部特征,并且可以使模型更快地收敛。

使用改进后的 CBAM 系列嵌入式注意力机制模块重新校准通道维度中的原始特征,减少训练参数的同时优化了模型的收敛性,从而提高了模型的分精度。本研究使用随机梯度下降优化方法在数据集上训练模型。改进的水稻叶片病害识别模型的网络结构如图 4 所示,主要操作流程如图 5 所示。

1.2 试验准备


为了评估改进后的模型性能,模型各项参数经过微调测试后,所有试验采用统一的参数,训练轮数为 50,学习率为 0.000 1,批次大小为 32,优化器为 Adam,试验环境的配置见表 1。

表 1 试验环境配置

Table 1 Laboratory equipment

名称	相关参数
中央处理器(CPU)	I7-8700 k
图形处理器(GPU)	RTX 3090 Ti
内部存储器大小(RAM)	16.00 GB
GPU 加速库	Cudnn-10.0
编程语言	Python 3.9
深度学习框架	Tensorflow 1.14.0

所有的试验都是由深度学习框架 Tensorflow 实现的。此外,以准确率作为评估网络模型性能的指标。精度是指校正的正预测数与整个正预测数的比值,具体见公式(6):



Conv2d 表示二维卷积;DWConv 表示可分离卷积;SELU 表示扩展型指数线性单元函数;GN 表示组归一化;FC 表示全连接;CBAM 表示注意力机制模块。

图 4 本研究构建的轻量级水稻叶片病害识别模型

Fig.4 The lightweight rice leaf disease recognition model constructed in this study

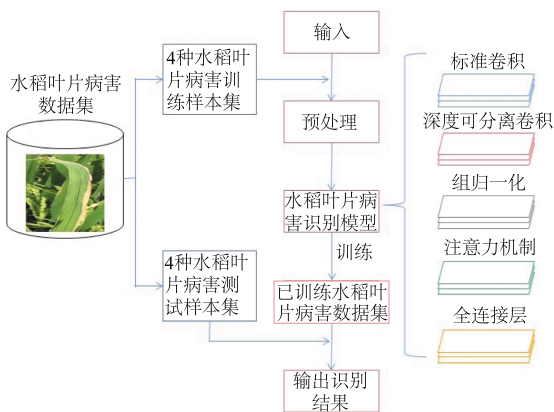


图 5 轻量级水稻叶片病害识别模型主要操作流程


Fig.5 The main operational process of the lightweight rice leaf disease recognition model

$$Accuracy = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (6)$$

其中, N_{TP} 是校正的正预测数; N_{FP} 是错误的正预测数。

水稻叶片病害数据集制作:本研究以桑巴尔普尔大学(Sambalpur University)提供的水稻叶片病害公共数据集(<http://bcch.ahnw.gov.cn/Right.aspx>)为研究对象,数据集中包含 4 种水稻叶片病害的 5 932 张图像,即患白叶枯病水稻叶片图像 1 569 张、患稻瘟病水稻叶片图像 1 455 张、患褐斑病水稻叶片图像 1 597 张、患东格鲁病水稻叶片图像 1 311 张,部分样本如图 6 所示。

由于原始数据集中存在样本数量不平衡的问



A:患白叶枯病水稻叶片图像;B:患稻瘟病水稻叶片图像;C:患褐斑病水稻叶片图像;D:患东格鲁病水稻叶片图像。

图 6 4 种水稻叶片病害的样本图像

Fig.6 Sample images of four rice leaf diseases

题,并且患病叶片图像的收集是随机的,因此,本研究对原始水稻叶片病害数据集进行数据增强的处理^[16],增加样本的数量,降低模型对某些属性的依赖,从而提高模型的泛化能力。本研究采用的数据增强方式包括旋转、剪裁、平移、缩放。数据增强之

后,水稻叶片病害图像数据集包含7 054张图像,其中6 254张图像用于训练集,800张图像用于验证集。每个疾病类别的图像数量见表2。

表2 水稻叶片病害数据集统计

Table 2 Statistics of rice leaf disease data set


水稻叶片 病害种类	训练集数量 (数据增强前)	训练集数量 (数据增强后)	验证集数量 (数据增强后)
白叶枯病	1 569	1 654	185
稻瘟病	1 455	1 500	215
褐斑病	1 597	1 610	197
东格鲁病	1 311	1 490	203

2 结果与分析

2.1 模型消融试验结果分析

精度作为衡量模型预测能力的指标,可以反映出模型正确预测的样本数占总样本数的比例。图7显示,使用深度可分离卷积以及组归一化算法可以一定程度上加速算法模型的收敛,此外,Conv_L2_CBAM作为轻量级注意力机制模块,可以进一步帮助模型更好地理解解析水稻叶片病害特征数据,使模型注意力集中在重要的信息上,避免在不相关的信息上浪费计算资源,相较于VGG16模

型,本研究提出的改进模型对水稻叶片病害识别的精度较高。



GN:组归一化;DWConv:深度可分离卷积;Conv_L2_CBAM:轻量级注意力机制模块。

图7 模型精度示意图

Fig.7 Schematic diagram of model accuracy

此外,为了更直观地比较激活函数 SELU 对模型的影响,本研究采用感受性曲线来比较水稻叶片病害识别模型使用 sigmoid、tanh、ReLU 和 SELU 4 类不同激活函数的性能。采用感受性曲线图(图8)来考察模型的性能,可以更直观地看到在任意界限值时模型对水稻叶片病害的识别能力。当感受性曲线越靠近左上角,感受性曲线同坐标轴形成的面积越大时,模型的准确性越高。

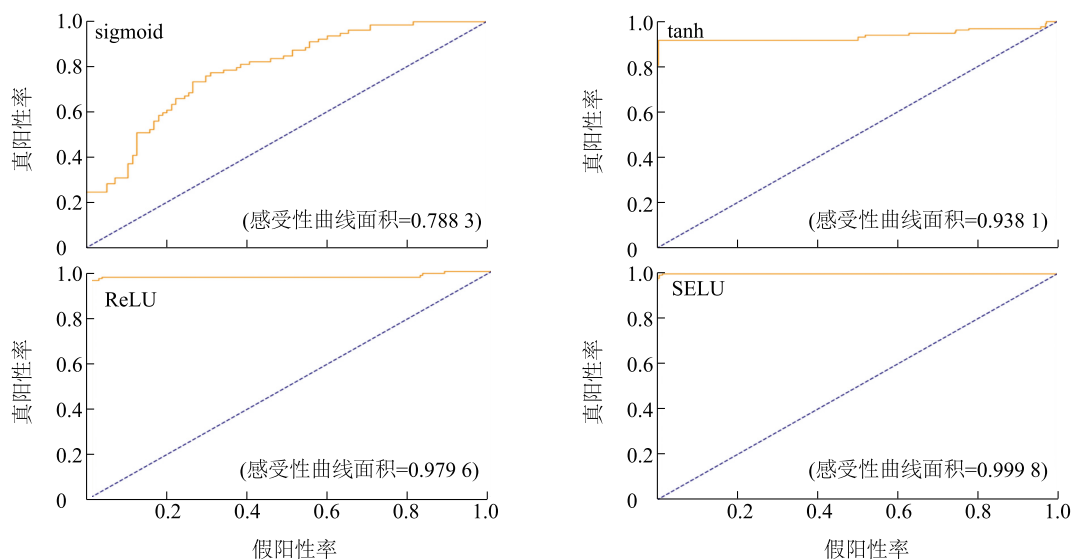


图8 使用各类激活函数的模型感受性曲线图

Fig.8 Receiver operating characteristic curves for models using various activation functions

表3显示,在水稻叶片病害的识别方面,激活函

数 SELU 具有帮助模型很好地处理梯度消失和梯度

爆炸的特性以及自身的平滑性,相较于 ReLU 等激活函数,使用 SELU 作为模型的激活函数,可以很大程度地提高网络模型在训练过程中的稳定性。

2.2 模型对比试验结果分析


本研究采用 BP、AlexNet、VGG16 模型在自制水稻叶片病害图像数据集上进行训练,并将训练结果同本研究构建模型的结果进行对比。结果(图 9、表 4)表明,本研究构建模型执行单批次训练所需时长要短于 VGG16 等模型,同时由于深度可分离卷积和轻量级注意力机制 Conv_L2_CBAM 的使用,相较于其他模型,本研究构建模型可以提高模型收敛速度,

并且模型参数量最少,水稻叶片病害识别平均精度比 VGG16 模型高。

表 3 使用各类激活函数的模型的训练结果

Table 3 Training results of models using various activation functions

激活函数	感受性曲线下面积
线性整流函数(ReLU)	0.979 6
S 型激活函数(sigmoid)	0.788 3
双曲正切函数(tanh)	0.938 1
扩展型指数线性单元函数(SELU)	0.999 8



A:BP 神经网络模型;B:AlexNet 模型;C:VGG16 模型;D:本研究构建模型。

图 9 各类神经网络模型训练准确率

Fig.9 Training accuracy of various neural network models

表 4 各类模型性能的对比如

Table 4 Comparison of the performance of various models

模型	平均精度	平均单次迭代时间 (s)	模型参数量 (个)
BP	0.700 2	386	1.5×10^7
AlexNet	0.922 7	304	6.0×10^8
VGG16	0.949 4	344	1.6×10^8
本研究构建模型	0.990 0	291	5.2×10^6

3 结论

本研究提出了一种基于卷积神经网络的轻量级水稻叶片病害识别模型。首先,引入注意力机制对

模型结构进行改进,得到轻量级注意力机制模块,将水稻叶片病害特征图中的潜在注意力信息进行深度挖掘;其次,使用深度可分离卷积代替部分标准卷积,进一步降低模型的参数量;最后,为了提高模型的泛化能力,让模型学习过程更快、更稳定,采用了自带内部归一化属性的激活函数 SELU,并与外部组归一化模块相结合。通过在公共数据集中进行验证,本研究构建模型的平均精度最高(0.990 0),并且在参数量和平均单次迭代时间方面相较于 VGG16 等模型也有一定优势。

参考文献:

[1] 许娜,叶桥平. 水稻种植与病虫害防治技术研究[J]. 种子科

- 技,2022,40(21):46-48.
- [2] ES-SAADY Y, MAMMASS I E, YASSA M E, et al. Automatic recognition of plant leaves diseases based on serial combination of two SVM classifiers [C]. Tangiers:IEEE,2016.
- [3] GAVHALE K R, GAWANDE U. An overview of the research on plant leaves disease detection using image processing techniques [J]. Iosr Journal of Computer Engineering (IOSR-JCE),2014,16(1):10-16.
- [4] WANG G, SUN Y, WANG J. Automatic image-based plant disease severity estimation using deep learning[J]. Computational Intelligence and Neuroscience,2017. DOI:10.1155/2017/2917536.
- [5] 王献锋,张善文,王震,等. 基于叶片图像和环境信息的黄瓜病害识别方法[J]. 农业工程学报,2014,30(14):148-153.
- [6] ZHANG S W, SHANG Y J, WANG L. Plant disease recognition based on plant leaf image [J]. Journal of Animal and Plant Sciences,2015,25(3):42-45.
- [7] XIE C, WANG R, ZHANG J, et al. Multi-level learning features for automatic classification of field crop pests[J]. Computers and Electronics in Agriculture,2018,152:233-241.
- [8] SANKARAN S, ASHISH M, REZA E, et al. A review of advanced techniques for detecting plant diseases[J]. Computers and Electronics in Agriculture,2010,72(1):1-13.
- [9] LI W, CHEN P, WANG B, et al. Automatic localization and count of agricultural crop pests based on an improved deep learning pipeline[J]. Scientific Reports,2019,9:7024.
- [10] 孟亮,郭小燕,杜佳举,等. 一种轻量级 CNN 农作物病害图像识别模型[J]. 江苏农业学报,2021,37(5):1143-1150.
- [11] WU Y, HE K. Group normalization[J]. International Journal of Computer Vision,2018,128(3):742-755.
- [12] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]. Munich:ECCV,2018.
- [13] HOWARD A G, ZHU M, CHEN B, et al. MobileNets:efficient convolutional neural networks for mobile vision applications[J]. ArXiv,2017. DOI:10.48550/arXiv.1704.04861.
- [14] KLAMBAUER G, UNTERTHINER T, MAYR A, et al. Self-normalizing neural networks[J]. Advances in Neural Information Processing Systems,2017,30:972-981.
- [15] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]. Lille: PMLR,2015.
- [16] 王建国,陈响育,杨自忠,等. 不同数据增强方法对模型识别精度的影响[J]. 计算机科学,2022,49(增刊1):418-423.

(责任编辑:王妮)