



# 基于改进 ConvNeXt 的大豆叶片病害分类研究

马 晓<sup>1,2</sup>, 董天亮<sup>1,2</sup>, 钟闻宇<sup>1</sup>, 薄小永<sup>1</sup>, 黄 斌<sup>1</sup>, 武青海<sup>1,2</sup>

(1. 吉林农业科技学院 电气与信息工程学院, 吉林 吉林 132101; 2. 吉林化工学院 信息与控制工程学院, 吉林 吉林 132022)

**摘 要:**针对现有的卷积神经网络在大豆叶片病害分类中存在复杂背景干扰的问题,提出一种改进的 ConvNeXt 算法,并对大豆两种常见病害以及健康叶片进行分类识别。通过在传统 ConvNeXt 算法的基础上增加多个注意力模块,使网络更能关注具有辨别性的特征,并选用 LeakyReLU 激活函数代替 ReLU 激活函数,避免神经元失活的现象。此外通过对数据集进行数据增强,操作多样化病害数据集,提升网络的鲁棒性。结果表明:改进的 ConvNeXt 算法对大豆叶片病害在测试集上的平均分类准确率均优于原 ConvNeXt、ResNet50 以及 Swin Transformer 3 个对比模型。在数据增强后,测试集上的平均识别准确率达到 85.42%,研究结果可为解决复杂背景信息干扰情况下大豆叶片病害图像分类提供参考。

**关键词:**图像分类; ConvNeXt; 注意力机制; 数据增强; 大豆叶片病害

## Soybean Leaf Diseases Classification Method Based on Improved ConvNext

MA Xiao<sup>1,2</sup>, DONG Tianliang<sup>1,2</sup>, ZHONG Wenyu<sup>1</sup>, BO Xiaoyong<sup>1</sup>, HUANG Bin<sup>1</sup>, WU Qinghai<sup>1,2</sup>

(1. Electrical and Information Engineering College, Jilin Agricultural Science and Technology University, Jilin 132101, China; 2. School of Information and Control Engineering, Jilin Institute of Chemical Technology, Jilin 132022, China)

**Abstract:** To solve the complex background interference problem of existing convolutional neural networks in soybean leaf disease classification, an improved ConvNeXt algorithm is proposed, and two common diseases of soybean as well as healthy leaves are classified and identified. By adding multiple attention modules to the traditional ConvNeXt algorithm, the network is made more capable of focusing on discriminative features and the LeakyReLU activation function is chosen instead of the ReLU activation function to avoid the neuron deactivation phenomenon. In addition, the robustness of the network was improved by performing data enhancement on the dataset to diversify the disease dataset. The results showed that the improved ConvNeXt algorithm outperforms the original ConvNeXt, ResNet50 and Swin Transformer, all three comparison models, in terms of average classification accuracy on the test set. The average recognition accuracy on the data enhanced test set reached 85.42%, and the research results can provide reference for solving the classification of soybean leaf disease images under complex background information interference.

**Keywords:** image classification; ConvNext; attention mechanism; data enhancement; soybean leaf disease

大豆作为我国主要的经济作物之一,不仅可以制成多种食品,同时还是重要的饲料作物<sup>[1]</sup>。在大豆生产过程中,病害是影响大豆产量的主要因素之一,叶片病害的发生会引起叶片颜色变化甚至脱落,叶片大量脱落会使得大豆对病害的抵抗力降低,从而导致大豆产量和品质的下降<sup>[2]</sup>。目前普遍发生的严重叶部病害主要有:大豆叶斑病和豆锈病等,根据病害的治疗方案大多都强调在发病初期采取相应的措施,所以能够及时准确地发现病害是非常有必要的<sup>[3]</sup>。传统的病害识别需要人工进行,由于叶片病害复杂多样,需要丰富的经验才能准确识别病害的类别,存在耗时耗力的问题<sup>[4]</sup>。随着机器学习和神经网络的发展,各种算法被应用到植物叶

片病害的识别中<sup>[5]</sup>。同时人工智能的不断发展对落实科技强农政策具有重大意义<sup>[6]</sup>。目前国内外对植物叶片病害的分类主要有两个方向:基于传统机器学习算法的叶片病害识别和基于深度学习的病害识别。

植物叶片病害分类的方法有很多,比较传统的是使用基于传统机器学习算法进行特征提取并分类,这种方法具有识别速度快,对硬件要求低等优点。Panigrahi 等<sup>[7]</sup>将传统机器学习算法如朴素贝叶斯、决策树、K-最近邻、支持向量机和随机森林用于玉米病害检测,并对这些方法进行比较分析,发现随机森林较其他算法准确率最高。吕洁等<sup>[8]</sup>利用 Gabor 小波提取纹理特征,并借助局部线性嵌入

收稿日期:2023-01-25

**基金项目:**吉林省特色高水平学科新兴交叉学科“数字农业”项目(20231103);吉林省教育厅科学技术研究规划项目(JJKH20230431KJ);吉林省科技发展规划项目(YDZJ202201ZYTS692)。

**第一作者:**马晓(1999—),女,硕士研究生,主要从事人工智能图像分类研究。E-mail:1925709084@qq.com。

**通讯作者:**武青海(1978—),男,硕士,副教授,主要从事图形图像处理及农业信息化研究。E-mail:57922126@qq.com。

降维,最终采用孪生支持向量机(TWSVM)完成分类。基于机器学习算法的图像识别的一般步骤为图像预处理、特征提取和分类器训练3个部分,其中特征提取是最重要的环节,它直接影响着分类的好坏,传统方式的特征提取主要通过人工设计,提取特征难度较大。基于传统机器学习的图像识别存在识别准确率低,特征提取设计困难等问题<sup>[9]</sup>。

随着神经网络以及深度学习<sup>[10]</sup>的发展,国内外学者开始通过神经网络对植物叶片病害特征进行自动提取,从而实现病害分类,这大大降低了特征提取的难度。Lin 等<sup>[11]</sup>针对病害形态存在多样性的问题提出 GrapeNet 轻量级模型,用于识别葡萄叶片病害的不同症状阶段,使得识别准确率提高的同时减少了参数量。黄英来等<sup>[12]</sup>针对传统玉米叶片识别方法正确率不高、速度慢等问题,通过改变残差网络内第一层卷积的卷积核和改变激活函数等方法,提出一种基于改进深度残差网络模型的玉米叶片图像识别算法,使得模型的准确度大幅度提升,鲁棒性进一步增强。黄乾峰等<sup>[13]</sup>通过改进 MobileNetV2 解决番茄叶片病害类别间差异小及分类模型参数量大、识别率较低等问题,这种轻量化网络模型更适合部署在移动端。

现有大豆叶片病害识别研究相对较少,且大多是针对在较单一背景下采集的大豆叶片病害图像<sup>[14-16]</sup>,本文针对在实际采集中通常存在复杂背景干扰的问题,并基于具有复杂背景信息的大豆叶片图像作为训练、验证及测试样本,开展大豆叶片病害分类研究,提出一种改进型 ConvNeXt 模型的大豆叶片病害图像分类算法,用改进后的模型提取图像中的病害特征,从而实现在复杂背景干扰情况下的大豆叶片病害分类。本研究旨在为解决复杂背景信息干扰情况下大豆叶片病害图像分类提供参考。

1 材料与方法

1.1 ConvNeXt

ConvNeXt 算法<sup>[17]</sup>的网络结构图如图 1 所示,ConvNeXt 算法是在 ResNet<sup>[18]</sup>的基础上分别在宏观和微观两个方面依次借鉴 Swin Transformer<sup>[19]</sup>的思

想,最终得到 ConvNeXt 的核心结构。它不仅保留了传统卷积的优点,还避免了 transformer 结构的缺点,并且在性能上也有提升。





图 1 ConvNeXt 网络结构

Fig. 1 ConvNeXt network structure

1.2 图像预处理

针对病害图像在采集过程中复杂背景干扰的影响,为了提高模型的分类准确度以及模型的泛化能力及鲁棒性,通常会使用图像数据增强的正则化方法<sup>[20]</sup>。本文采用一系列数据增强方法分别模拟在图像采集中不同角度、遮挡以及不同天气等外界因素的干扰,从而防止模型过拟合<sup>[21]</sup>,同时提升模型的鲁棒性和泛化能力。图 2 展示了部分数据的增强效果。



注：A. 未经过任何数据增强操作处理的图像；B. 经过高斯模糊处理后的图像；C. 经过随机位置遮挡后的图像；D. 经过添加随机噪声后的图像；E. 经过旋转后的图像；F. 经过亮度调节后的图像。

Note: A. Images without any data enhancement operations; B. Images after Gaussian blurring; C. Images after random position masking; D. Images after adding random noise; E. Images after rotation; F. Images after brightness adjustment.

图 2 数据增强效果展示

Fig. 2 Display of data enhancement effects

1.3 注意力机制

注意力机制 (attention mechanism) 可以通过参数更新来判断哪些是重要特征,从而高效准确地完成响应任务<sup>[22]</sup>。注意力机制被广泛用于各个领域当中<sup>[23-26]</sup>,其中常用的注意力机制有 SE-Net<sup>[27]</sup> (Squeeze and Excitation)、ECA-Net<sup>[28]</sup> (Efficient Channel Attention)、SK-Net<sup>[29]</sup> (Selective Kernel Networks) 和 CBAM<sup>[30]</sup> (Convolutional Block Attention Module) 等。

本文选用的是 CBAM 注意力,其包含空间注意力模块 SAM (Spatial Attention Module) 和通道注意力模块 CAM (Channel Attention Module) 两个部分,分别用来计算来自空间和通道两个方面的注意力权重,其整体结构如图 3 所示。CAM 的计算公式如公式(1)所示,其中  $\sigma$  代表 sigmoid 激活函数,  $F_{avg}$  与

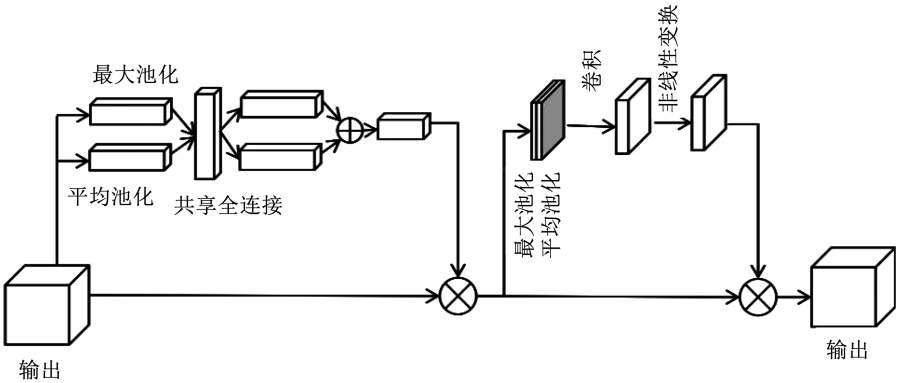
$F_{max}$  分别代表由全局平均池化和全局最大池化输出的结果,  $W_0$  和  $W_1$  表示两层不同的神经网络操作。SAM 的计算公式如公式(2)所示,其中  $f_{7\times7}$  代表卷积核大小为  $7\times7$  的卷积操作,  $[]$  代表进行通道拼接。CBAM 总体流程可以由公式(3)和公式(4)两个式子表示,其中输入特征  $F(F\in\{R^{C\times H\times W}\})$ ,通道注意力模块输出  $CAM(CAM\in\{R^{C\times1\times1}\})$ ,空间注意力模块输出  $SAM(SAM\in\{R^{1\times H\times W}\})$ ,通道注意力输出结果  $F'$  和空间注意力输出结果  $F''$ 。

$$CAM(F) = \sigma(W_1(W_0(F_{avg}^c)) + W_1(W_0(F_{max}^c))) \tag{1}$$

$$SAM(F) = \sigma(f^{7\times7}([F_{avg}^s; F_{max}^s])) \tag{2}$$

$$F' = CAM(F) \otimes F \tag{3}$$

$$F'' = SAM(F') \otimes F' \tag{4}$$



注：图中左侧分支为通道注意力模块,右侧分支为空间注意力模块。

Note: The left-hand branch of the diagram is the channel attention module and the right-hand branch is the spatial attention module.

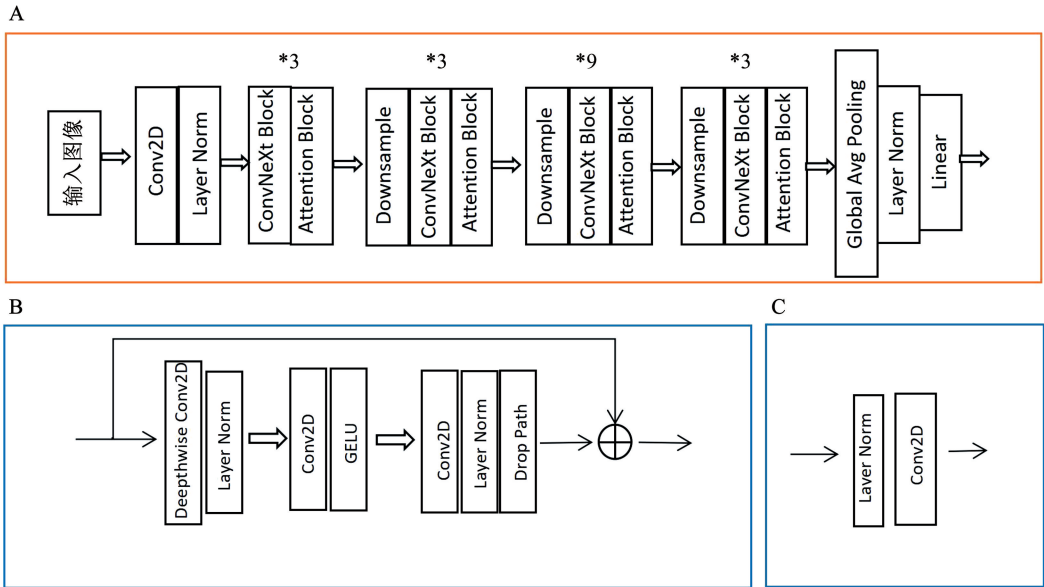
图 3 CBAM 整体结构

Fig. 3 Overall CBAM structure

1.4 改进型 ConvNeXt

本文提出的改进型 ConvNeXt (CBAM-ConvNeXt) 结构如图 4 所示,该网络主要由 ConvNeXt Block 模块、Downsample 模块以及 CBAM 注意力模块 3 部分构成。本实验通过对 SE-Net、ECA-Net、SK-Net 以及

CBAM 注意力模块进行对比分析,实验结果表明 CBAM 注意力机制能更好地与 ConvNeXt 网络相融合,提升网络模型的准确率,故最终选用 CBAM 作为本模型的注意力模块。



注：A. CBAM-ConvNeXt 整体结构图；B. ConvNeXt Block 结构图；C. Downsample 结构图。  
Note: A. Overall CBAM-ConvNeXt structure image; B. ConvNeXt Block structure image; C. Downsample structure image.

图4 CBAM-ConvNeXt 整体结构  
Fig. 4 Overall structure of the CBAM-ConvNeXt

同时本实验在 CBAM 注意力模块中使用 *LeakyReLU*<sup>[31]</sup> 激活函数,通过修正它的非线性单元从而克服输入为负值时神经元失活的情况, *LeakyReLU* 激活函数如公式 (5) 所示,函数图像如图 5 所示。

$$LeakyReLU = \begin{cases} x, & x > 0 \\ ax, & x \leq 0 \end{cases} \quad (5)$$

CBAM-ConvNeXt 模型首先将大小为 224 × 224 的三通道大豆叶片病害图像经过一个卷积核大小为 4 × 4 步长为 4 的卷积操作进行浅层特征的提取,并经过 Layer Normlization 层归一化,输出大小为 56 × 56 通道数为 96 的特征图。接下来就是经过 4 个 ConvNeXt 块和 4 个 CBAM 注意力模块以及 3 个下采样模块进行进一步的特征提取、添加注意力分数以及下采样操作,使得网络更加关注病害特征而减少对复杂背景的关注从而减少干扰。




图5 LeakyReLU 函数图像  
Fig. 5 LeakyReLU function image

2 实验准备工作

2.1 实验环境与设置

本实验采用 PaddlePaddle 2.3.2 深度学习框架,编程语言为 python 3.7,并采用 4 核 CPU 以及 Tasla V100 的 GPU 加速训练。网络采用交叉熵损失函数 (Cross Entropy Loss) 结合自适应矩估计 (Adam) 作为优化器进行训练,该优化器可以根据训练参数对学习率进行自适应调整<sup>[32]</sup> 训练迭代 100



次, batch size 设置为 64, 学习率( Learning Rate) 设置为 0.000 001。

2.2 数据集

本实验针对大豆种植中 2 种常见病害大豆叶斑病以及大豆锈病和健康叶片进行实验研究, 并对原

数据集按照 6:2:2 的比例划分训练集、验证集与测试集。以吉林农业科技学院“智慧农业”平台数据集作为实验对象, 最终采用未图像增强前数据集总量为 1 296 张, 数据增强后共 11 655 张, 数据集在各个类别上的分布如表 1 所示。

表 1 大豆叶片病害数据集详情

Table 1 Details of the soybean leaf disease dataset

病害名称	原始图像数量	数据增强后数量
Disease	Number of original images/张	Number after data enhancement/张
叶斑病 Leaf spot disease	432	3888
豆锈病 Bean rust	436	3924
健康叶片 Health Leaf	428	3843
共计 Total	1296	11655

2.3 评价标准

本文使用 Softmax 函数的输出, 作为模型的输出, 进而计算被预测对象所属的类别, Softmax 的表达式为:

$$Y(P) = P(y = p \mid x, \theta_p) = \frac{e^{x^T \theta_p}}{\sum_{p=1}^c e^{x^T \theta_p}} \quad (6)$$

并用交叉熵损失函数来作为进行网络优化的标准, 同时采用 Adam 优化器对模型参数进行优化, 其中在多分类任务中交叉熵损失函数的表达式为:

$$\min_{\{W, b; \theta\}} \mathcal{E}(W, b; \theta) = \frac{1}{N} \sum_{n=1}^N \left[ - \sum_{p=1}^c \gamma(y_n = p) \log P(y = p \mid x, \theta_p) \right] + \lambda R(\theta) \quad (7)$$

为方便进行不同模型之间的对比, 本实验引入准确率 ( Accuracy)、精确率 ( Precision)、召回率 ( Recall)  $f_1$ -score 对模型进行评估<sup>[33]</sup>。正确率可以表示模型整体的预测精准度, 但是在样本不平衡的情况下, 正确率并不能很好地作为衡量模型好坏的标准; 精确率代表在正样本结果中预测的准确程度; 召回率则是在所有正样本中正确预测为正样本的概率。准确率、精确率、召回率  $f_1$ -score 在二分类中的公式定义如下:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (9)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (10)$$

$$f_1\text{-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (11)$$

其中 TP ( True Positive) 表示正样本预测答案正确, FP ( False Positive) 表示错将负样本预测为正样本, TN ( True Negative) 表示负样本预测答案正确, FN ( False Negative) 表示错将正样本预测为负样本。

为更加直观地看到模型在各个类别中的分类效果, 本文采用混淆矩阵<sup>[34]</sup>来对分类结果进行展示, 其每一列代表了预测的标签类别, 每一行表示数据真实的标签类别, 对角线上的数值越大说明模型分类效果越好。

2.4 设置对比实验

为验证本文改进的 CBAM-ConvNeXt 模型的性能, 共设置了 4 组对比实验: 改进模型使用增强数据集进行训练的效果与使用原数据集进行训练的效果之间的对比; 改进模型与原模型之间的性能对比; 改进模型与 ResNet50 改进模型与 Swin Transformer 模型之间的性能对比。

3 结果与分析

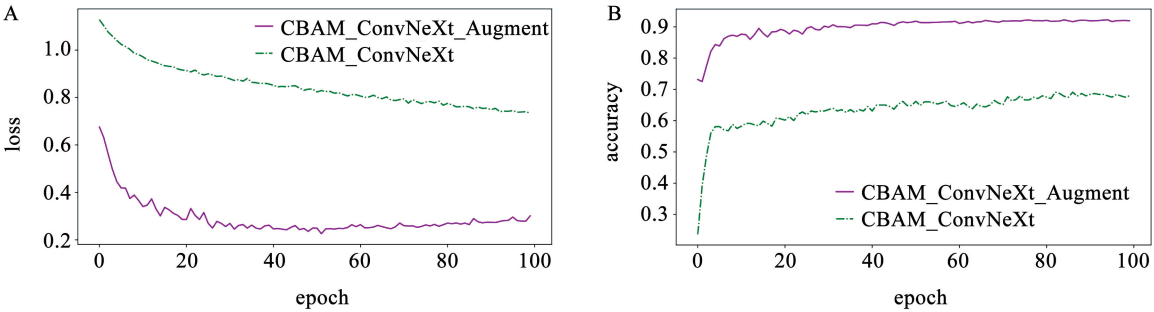
3.1 数据增强实验效果对比

为了验证数据增强方法对模型效果的提升, 分别将原始数据集与进行数据增强后的数据集输入到 CBAM-ConvNeXt 模型进行训练。模型训练过程中在验证集上的损失值和准确率对比如图 6 所示, 最终对测试集分类效果的混淆矩阵如图 7 所示, 混

淆矩阵中对角线上的值越大、颜色越深说明分类模型的效果越好。

由图 6 可以看出,经过增强后的数据集训练的模型其训练过程中的损失值和分类准确率不论是收敛速度还是最终稳定的值都优于数据增强前的数据训练的模型。数据增强前后实验效果对比如


表 2 所示,经过数据增强后训练出的模型,在测试集的准确率、精确率、召回率以及  $f_1$ -score 都有一定程度的提升。综上所述,本文采用的数据增强方法能够在数据预处理阶段提升网络模型的泛化能力和鲁棒性,对大豆叶片病害分类起到积极作用。



注：A. 数据增强前后训练过程中损失值的变化曲线；B. 数据增强前后训练过程中准确率的变化曲线。  
Note：A. Curves of change in loss values during training before and after data enhancement；B. Curves of change in accuracy rates during training before and after data enhancement.

图 6 数据增强前后损失值与准确率曲线

Fig. 6 Loss value and accuracy curve before and after data enhancement



注:A. 原始数据集作为训练数据集得到的混淆矩阵;B. 数据增强后的数据集作为训练数据集得到的混淆矩阵。

Note：A. Original dataset as the confusion matrix obtained from the training dataset；  
B. Data-enhanced dataset as the confusion matrix obtained from the training dataset.

图 7 数据增强前后混淆矩阵对比

Fig. 7 Confusion matrix comparison before and after data enhancement

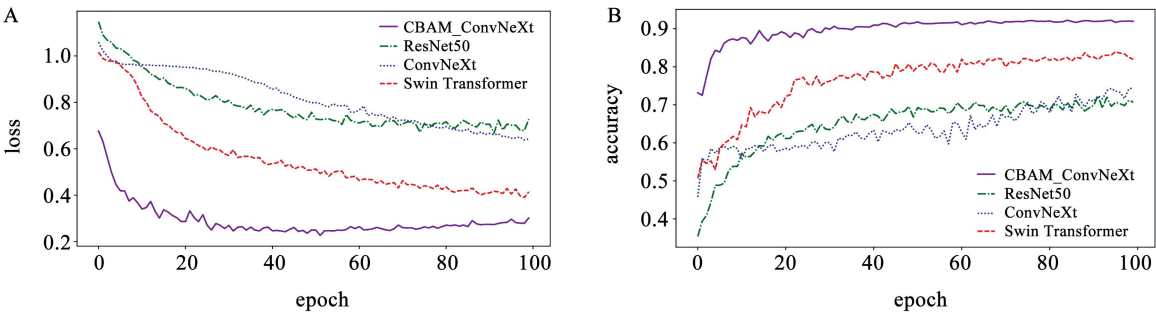
表 2 数据增强前后实验效果对比

Table 2 Comparison of experimental effects before and after data enhancement				单位：%
数据集 Dataset	准确率 Accuracy	精确率 Precision	召回率 Recall	$f_1$ -score
原始数据集 Original dataset	67.19	66.56	67.52	66.57
数据增强后 After data enhancement	88.28	88.35	88.44	88.37

3.2 模型改进实验效果对比

为了验证本文改进模型在大豆叶片病害分类中有效提升了分类的准确率,将数据增强后的数据集依次输入原 ConvNeXt、ResNet50 以及 Swin

Transformer 模型进行训练,并得到验证集的损失值与准确率的对比曲线图(图 8),在训练过程中验证集上的准确率与损失值明显优于其他 3 种模型,且收敛速度更快。各个模型实验结果对比如表 3 所示。



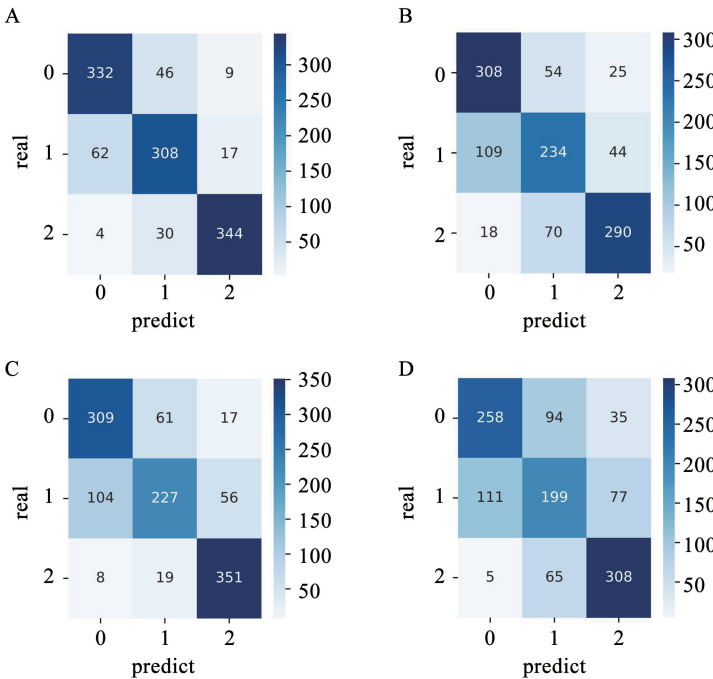
注: A. CBAM-ConvNeXt、ResNet50、原 ConvNeXt-T 以及 Swin Transformer 各个模型在训练过程中损失值的变化曲线; B. CBAM-ConvNeXt、ResNet50、原 ConvNeXt-T 以及 Swin Transformer 各个模型在训练过程中准确率的曲线。  
Note: A. Curves of loss values during training for each model of CBAM-ConvNeXt, ResNet50, original ConvNeXt-T and Swin Transformer; B. Curves of accuracy for each model of CBAM-ConvNeXt, ResNet50, original ConvNeXt-T and Swin Transformer during the change curve of accuracy during training.

图 8 各模型损失值和准确率曲线  
Fig. 8 Loss values and accuracy curves of each model

表 3 各模型实验结果对比

Table 3 Comparison of the experimental results of each model					单位: %
数据集 Dataset	准确率 Accuracy	精确率 Precision	召回率 Recall	$f_1$ -score	
ResNet50	72.22	72.32	72.26	72.15	
ConvNeXt-T	66.41	65.97	66.52	66.14	
Swin Transformer	77.00	76.71	77.12	76.48	
CBAM-ConvNeXt	85.42	85.53	85.46	85.87	

此外还使用混淆矩阵对模型进行对比,如图 9 所示。从混淆矩阵中可以看出,错误分类主要发生在 0 和 1 之间,主要由于它们病斑特征存在较高的相似性,但相对其它 3 个模型来说本文提出的改进型 ConvNeXt 在具有相似病斑特征的识别中有较好的识别能力。



注: A. 在 CBAM-ConvNeXt 模型下分类得到的混淆矩阵; B. 在 ResNet50 模型下分类得到的混淆矩阵; C. 在 Swin Transformer 模型下分类得到的混淆矩阵; D. 在原 ConvNeXt 模型下分类得到的混淆矩阵。  
Note: A. Confusion matrix obtained by classification under the CBAM-ConvNeXt model; B. Confusion matrix obtained by classification under the ResNet50 model; C. Confusion matrix obtained by classification under the Swin Transformer model; D. Confusion matrix obtained by classification under the original ConvNeXt model.

图 9 混淆矩阵对比  
Fig. 9 Confusion matrix contrast

4 讨论

目前很少有针对大豆叶片病害识别的研究,有关大豆叶片病害的数据集数量有限,本文通过相应的数据增强操作多样化大豆叶片病害数据集,使模型能够在相对较小数据集的前提下可以取得较好的分类效果。实验证明,相较于由未数据增强操作训练出的网络模型,经过数据增强后训练出的网络模型能够在分类准确率上提高 20.38%,性能提升显著。

此外,由于在实地采集的大豆叶片病害往往会存在复杂背景的干扰,且背景与被识别病斑叶片相似度较高,所以本文通过融合注意力机制,使网络可以将具有辨别性的特征区域附上较大的权重,从而达到更加关注病斑区域的目的。实验证明,相较于原始模型,融合注意力机制后的模型在分类准确率上提高 19.01%。但是随着模型的复杂化,往往会受到算力的限制,且容易出现过拟合以及不易部署到移动端等问题,因此在保证分类准确率的前提下如何尽可能地使模型轻量化需要进一步的完善和研究。

5 结论

本文改进的 CBAM-ConvNeXt 网络在原有 ConvNeXt 网络模型的基础上融合了 4 个 CBAM 注意力模块,从而提升了网络对特征图通道间以及空间位置的关注度,同时通过在 CBAM 注意力中使用 LeakyReLU 激活函数,克服了在输入为负值时神经元失活的问题。通过在大豆叶片病害数据集上进行的消冗实验,结果表明,CBAM-ConvNeXt 在模型的泛化能力以及鲁棒性上的表现都优于其他网络模型,在数据增强后的测试集上平均识别准确率为 85.42%,均高于实验中相同条件下的其他网络模型,从而说明了本文模型的改进方法对大豆叶片病害分类具有积极作用。

参考文献

[1] 吴丽丽,李海侠,吴成久. 大豆高产种植技术[J]. 特种经济动植物,2023,26(1): 116-118. (WU L L, LI H X, WU C J. High-yield soybean planting technology[J]. Special Economic Animals and Plants, 2023, 26(1): 116-118. )

[2] 查霆,钟宣伯,周启政,等. 我国大豆产业发展现状及振兴策略[J]. 大豆科学,2018,37(3): 458-463. (ZHA T, ZHONG X B, ZHOU Q Z, et al. Development status of China's soybean industry and strategies of revitalizing[J]. Soybean Science, 2018, 37(3): 458-463. )

[3] 董星辰. 大豆主要叶部病害的发生与防治研究[J]. 农业开发与装备,2021(7): 227-228. (DONG X C. Study on the occurrence and control of major leaf diseases in soybean[J]. Agricultural Development & Equipments, 2021(7): 227-228. )

[4] DHAKAL A, SHAKYA S. Image-based plant disease detection with deep learning[J]. International Journal Computer Trends Technology, 2018, 61(1): 26-29.

[5] NGUGI L, ABELWAHAB M, ABO-ZAHHAD M. Recent advances in image processing techniques for automated leaf pest and disease recognition-a review[J]. Information Processing in Agriculture, 2021, 8(1): 27-51.

[6] 赵春江, 李瑾, 冯献. 面向 2035 年智慧农业发展战略研究[J]. 中国工程科学, 2021, 23(4): 1-9. (ZHAO C J, LI J, FENG X. Research on the development strategy of smart agriculture in 2035[J]. Chinese Journal of Engineering Science, 2021, 23(4): 1-9. )

[7] PANIGRAH K P, DAS H, SAHOO A K, et al. Maize leaf disease detection and classification using machine learning algorithms[J]. Advances in Intelligent Systems and Computing, 2020, 1119(1): 659-669.

[8] 吕洁, 卖雄发, 谢妙. 基于二维 Gabor 小波和孪生支持向量机的图像识别算法[J]. 南京理工大学学报, 2022, 46(1): 113-118. (LYU J, MAI X F, XIE M. Image recognition algorithm based on two-dimensional Gabor wavelets and twin SVM[J]. Nanjing University of Science and Technology, 2022, 46(1): 113-118. )

[9] WAGLE S A, HARIKRISHNAN R. Comparison of plant leaf classification using modified AlexNet and support vector machine[J]. Traitement du Signal: Signal Image Parole, 2021, 38(1): 79-87.

[10] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(1): 436-444.

[11] LIN J, CHEN X, PAN R, et al. GrapeNet: A lightweight convolutional neural network model for identification of grape leaf diseases[J]. Agriculture, 2022, 12(6): 887.

[12] 黄英来, 艾昕. 改进残差网络在玉米叶片病害图像的分类研究[J]. 计算机工程与应用, 2021, 54(23): 178-184. (HUANG L Y, AI X. Research on classification of corn leaf disease image by improved residual network[J]. Computer Engineering and Applications, 2021, 54(23): 178-184. )

[13] 黄乾峰, 董琴, 韦静. 改进 MobileNetV2 算法的番茄叶片病害种类识别[J]. 计算机系统应用, 2023, 32(1): 385-391. (HUANG Q F, DONG Q, WEI J. Improved tomato leaf disease species identification by MobileNetV2 algorithm[J]. Computer Systems &



Applications,2023,32(1): 385-391. )

[14] 马晓丹,关海鸥,祁广云,等. 基于改进级联神经网络的大豆叶部病害诊断模型[J]. 农业机械学报,2017,48(1): 163-168. (MA X T, GUAN H O, QI G Y, et al. A diagnostic model of soybean leaf disease based on an improved cascade neural network [J]. Chinese Society for Agricultural Machinery, 2017, 48(1): 163-168. )

[15] ELFATIMI E, REYIGIT R, ELFATIMI L. Beans leaf diseases classification using MobileNet models[J]. IEEE Access, 2022, 10:9471-9482.

[16] YU M, MA X D, GUAN H O, et al. A recognition method of soybean leaf diseases based on an improved deep learning model [J]. Frontiers in Plant Science,2022,13:878834.

[17] LIU Z, MAO H, WU C Y, et al. A convNet for the 2020s [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2022:11976-11986.

[18] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//IEEE Conference on Computer Vision and Pattern Recognition(CVPR),2016:770-778.

[19] LIU Z, LIN Y, CAO Y, et al. Swin Transformer: Hierarchical vision transformer using shifted windows [C]//IEEE/CVF International Conference on Computer Vision (ICCV), 2021: 10012-10022.

[20] FUJITA E, KAWASKI Y, UGA H, et al. Basic investigation on a robust and practical plant diagnostic system[J]. 2016 15th IEEE International Conference Machine Learning Applications, 2016: 989-992.

[21] 管正雄. 基于深度生成模型的数据增强方法研究[D]. 南京: 南京信息工程大学, 2019. (GUAN Z X. Research on data augmentation methods based on a deep generative model[D]. Nanjing: Nanjing University of Information Science and Technology, 2019. )

[22] 张宸嘉,朱磊,俞璐. 卷积神经网络中的注意力机制综述[J]. 计算机工程与应用,2021,57(20): 64-72. (ZHANG C J, ZHU L, YU L. Summary of attention mechanisms in convolutional neural networks [J]. Computer Engineering and Applications, 2021, 57(20): 64-72. )

[23] GUO W J, FENG Q, LI X Z, et al. Grape leaf disease detection based on attention mechanisms [J]. International Journal of Agricultural and Biological Engineering, 2022,15(5): 205-212.

[24] WANG Y Y, TAO J, GAO H. Corn disease recognition based on attention mechanism network[J]. Axioms,2022,11(9): 480.

[25] ZHANG M, SU H, WEN J. Classification of flower image based on attention mechanism and multi-loss attention network [J]. Computer Communications,2021,179(1): 307-317.

[26] QIAN Z Z, MU J, TIAN F, et al. Facial expression recognition based on strong attention mechanism and residual network [J]. Multimedia Tools and Applications, 2022, 81(30): 44109-44121.

[27] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-Excitation networks[C]//IEEE Conference on Computer Vision and Pattern Recognition(CVPR),2018:7132-7141.

[28] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR),2020:11534-11542.

[29] LI X, WANG W, HU X, et al. Selective kernel networks [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR),2020:510-519.

[30] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//Proceeding of the European Conference on Computer Vision(ECCV),2018:3-19.

[31] XU B, LI M, WANG N, et al. Empirical evaluation of rectified activations in convolutional network [DB/OL]. [2023-01-10]. <https://doc.taixueshu.com/foreign/arXiv150500853.html>,2015.

[32] 杨观赐,杨静,李少波,等. 基于 Dropout 与 ADAM 优化器的改进 CNN 算法[J]. 华中科技大学学报(自然科学版),2018,46(7): 122-127. (YANG G C, YANG J, LI S B, et al. Improved CNN algorithm based on Dropout and ADAM optimizer [J]. Huazhong University of Science and Technology (Natural Science Edition), 2018, 46(7): 122-127. )

[33] 肖经纬,田军委,王沁,等. 基于改进残差网络的果实病害分类方法[J]. 计算机工程,2020,46(9): 221-225. (XIAO J W, TIAN J W, WANG Q, et al. Fruit disease classification method based on an improved residual network [J]. Computer Engineering,2020,46(9): 221-225. )

[34] 宋亚飞,王晓丹,雷蕾. 基于混淆矩阵的证据可靠性评估[J]. 系统工程与电子技术,2015,37(4): 974-978. (SONG Y F, WANG X T, LEI L. Assessment of evidence reliability based on the confusion matrix[J]. Systems Engineering and Electronics, 2015, 37(4): 974-978. )