

马 晓,邢 雪,武青海. 基于改进 ConvNext 的复杂背景下玉米叶片病害分类[J]. 江苏农业科学,2023,51(19):190-197.  
doi:10.15889/j.issn.1002-1302.2023.19.028

# 基于改进 ConvNext 的复杂背景下玉米叶片病害分类

马 晓<sup>1</sup>,邢 雪<sup>1</sup>,武青海<sup>1,2</sup>

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

**摘要:**针对玉米叶片病害分类过程中存在叶片背景复杂且背景与被识别叶片具有较高相似度的问题,提出一种改进的 ConvNeXt 算法。首先通过随机遮挡等数据增强操作多样化病害数据集,增强网络的抗干扰能力,从而提高了模型的鲁棒性。其次,为了提高网络的分类准确度,在 ConvNeXt 网络的基础上融合多个注意力模块,使网络更加关注具有判别性的特征,以减少背景的干扰,并在注意力模块中使用 LeakyReLU 激活函数从而避免网络在输入为负值时神经元不学习的情况。最后,以具有 3 种玉米常见叶片病害的图像和健康叶片作为分类样本,采用改进后的 ConvNeXt 模型与相同样本数量和条件下的原 ConvNeXt、ResNet50 以及 Swin Transformer 进行试验和对比分析,试验表明,改进后的网络模型在测试集的平均分类准确率为 91.77%,优于 ResNet50 (85.64%)、ConvNeXt-T (79.91%) 和 Swin Transformer (89.09%) 3 个对比模型,证明了通过改进后的 ConvNeXt 进行叶片病害的特征提取,提高了在复杂背景下玉米叶片病害的分类精度。

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

**中图分类号:**S126;TP181 **文献标志码:**A **文章编号:**1002-1302(2023)19-0190-08

玉米作为我国主要的粮食作物,种植面积和总产量仅次于小麦和水稻居第 3 位。玉米不仅是重要的粮食作物、畜牧业的优良饲料,而且还是发展轻工、医药工业的重要原料<sup>[1]</sup>。在生产过程中,植物的病害是导致产量减少、质量变差的重要原因,因病害导致玉米产量常年损失 10%~15%<sup>[2]</sup>。目前发生普遍而又严重的叶部病害主要有大斑病、小斑病、锈病、灰斑病等,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,所以说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<sup>[5]</sup>。人工智能的不断发展对政府提出的科技强农政策具有重大意义<sup>[6]</sup>。目前国内外对玉米叶片病害的分类主

要有 2 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。

玉米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高<sup>[7]</sup>。吕洁等利用 Gabor 小波提取纹理特征,并借助局部线性嵌入降维,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,其中特征提取是其中最重要的一个环节,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<sup>[8]</sup>。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玉米叶片病害进行自动提取特征,从而实现病害分类,这大大降低了特征提取的难度。Priyadharshini 等通过将深度可分离卷积引入 LeNet,使得玉米叶片病害分类精度达到 97.89%<sup>[11]</sup>。黄英来等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

收稿日期:2023-02-10

基金项目:吉林省智慧农业工程研究中心项目(编号:JLNKU2015);吉林省特色高水平学科新兴交叉学科“数字农业”(编号:JLXK20180319);吉林省高等教育教学改革研究课题(编号:JLJY202338594176)。

作者简介:马 晓(1999—),女,山东临沂人,硕士研究生,研究方向为人工智能图像分类。E-mail:1925709084@qq.com。

通信作者:武青海,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。

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<sup>[12]</sup>。刘合兵等通过将 MobileNetV2 与迁移学习相结合的方式提高玉米叶部病害识别效率、精度,这种轻量化网络模型更适合部署在移动端<sup>[13]</sup>。

现有研究大多是针对在较单一背景下采集的玉米叶片病害图像<sup>[14-16]</sup>,本研究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玉米叶片图像作为训练、验证及测试样本,开展玉米叶片病害分类研究。通过随机遮挡被识别叶片模拟真实采集中遇到的遮挡情况,提高网络的鲁棒性,并通过融合注意力机制提高网络对具有判别性特征的权重,减少背景干扰,最后通过采用 LeakyReLU 激活函数克服输入为负值时神经元不学习的情况。基于所提出的改进型 ConvNeXt 模型提取玉米叶片病害图像中的病害特征,从而实现在复杂背景干扰情况下的玉米叶片病害分类。

## 1 网络模型结构设计

### 1.1 数据增强

在玉米病害分类过程中,由于病害图像采集过程中会遇到不同天气、其他叶片遮挡病斑等情况,会导致模型的泛化能力和鲁棒性不佳,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>[17]</sup>。本研究通过采用旋转、高斯模糊、添加随机噪声、添加随机位置的遮挡以及亮度调节等数据增强方法分别模拟在图像采集中不同角度、其他背景叶片的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,同时提升模型的鲁棒性和泛化能力<sup>[18]</sup>。为避免数据集信息发生泄漏,先对原数据集按照 6 : 2 : 2 的比例划分训练集、验证集与测试集。本试验针对玉米种植中 3 种常见病害玉米灰斑病、玉米锈病以及玉米大斑病和健康叶片进行试验研究。以 PlantVillage dataset<sup>[19]</sup> 公开数据集和吉林农业科技学院“智慧农业”平台数据集作为试验对象,最终采用图像增强前数据集总量为 1 829 张,数据增强后共 16 452 张,数据集在各个类别上的分布如表 1 所示,玉米病害图像如图 1 展示,并如图 2 展示部分数据增强效果。

表 1 玉米叶片病害数据集详情

病害名称	原始图像数量(张)	数据增强后数量(张)
健康叶片	430	3 861
灰斑病	409	3 681
锈病	500	4 500
大斑病	490	4 410
共计(张)	1 829	16 452




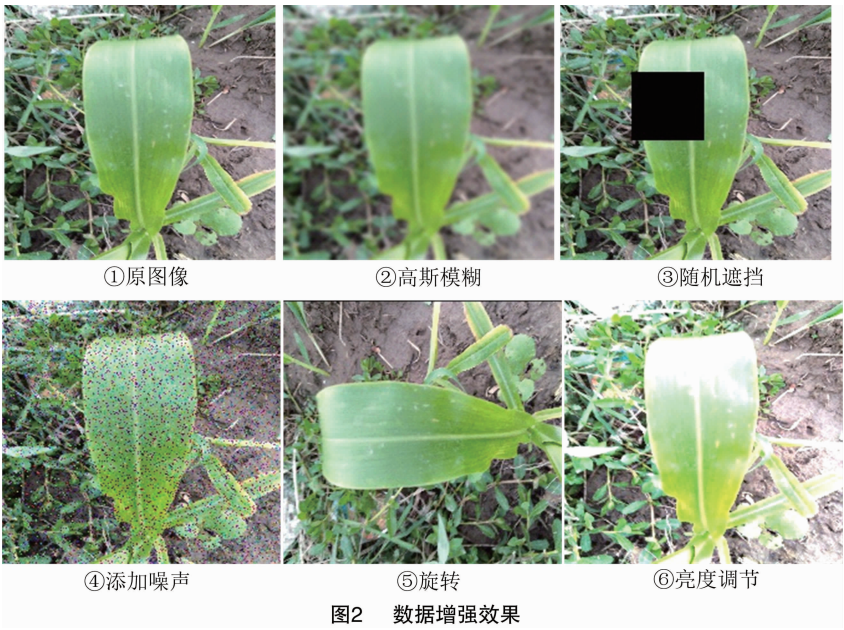
图1 玉米常见病害

### 1.2 注意力机制

注意力机制(attention mechanism)是受到人类视觉系统的启发,可以迅速将注意力集中在场景中重要区域,从而使得在处理复杂的信息时能够将神经网络的计算资源更多地投入到重要的任务中,并且利用反向传播指导注意力模块,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>[20]</sup>。注意力机制被广泛用于各个领域当中<sup>[21-24]</sup>,其中常用的注意力机制有 SE - Net<sup>[25]</sup> (squeeze and excitation)、ECA - Net<sup>[26]</sup> (efficient

channel attention)、SK - Net<sup>[27]</sup> (selective kernel networks)、CBAM<sup>[28]</sup> (convolutional block attention module)等。

SE - Net 显式地建模特征通道之间的相互依赖关系,即通过学习的方式来自动获取每个通道的重要程度。ECA - Net 提出了一种不降维的局部跨信道交互策略和自适应选择一维卷积核大小的方法。CBAM 包含 2 个部分:空间注意力模块 SAM (spatial attention module) 和通道注意力模块 CAM (channel attention module),用来分别汇总空间和通道 2 个方



面的注意力信息,其整体结构如图 3 所示,其 CAM 与 SAM 模块分别如图 4 和图 5 所示。通道注意力模块的计算公式如公式(1)所示,其中  $\sigma$  表示 sigmoid 激活函数,  $F_{\text{avg}}$  与  $F_{\text{max}}$  分别表示全局平均池化和全局最大池化的输出结果,  $W_0$  和  $W_1$  表示 2 层不同的神经网络操作。空间注意力模块的计算公式如公式(2)所示,  $f_{7 \times 7}$  代表卷积核大小为  $7 \times 7$  的卷积操作,  $[]$  代表通道拼接操作。CBAM 总体流程可以由公式(3)和公式(4)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  $CAM(CAM \in$

$\{R^{C \times 1 \times 1}\})$ , 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  $F''$ 。本研究就是使用的这种通道与空间结合的注意力模块。

$$CAM(F) = \sigma \{ W_1 [ W_0 ( F_{\text{avg}}^c ) ] + W_1 [ W_0 ( F_{\text{max}}^c ) ] \}; \quad (1)$$

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

$$F' = CAM(F) \otimes F; \quad (3)$$

$$F'' = SAM(F') \otimes F'。 \quad (4)$$

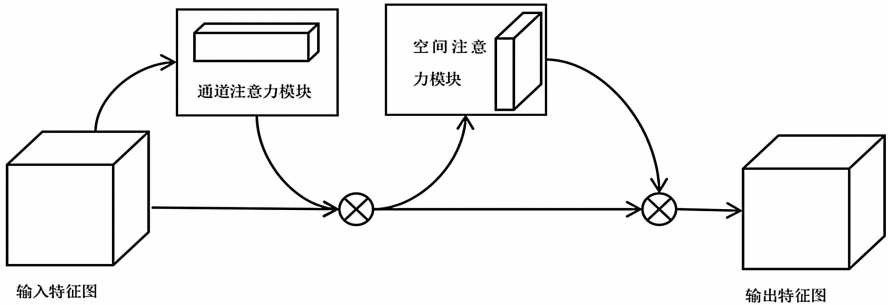


图3 CBAM 整体结构




图4 CAM 结构




图5 SAM 结构

### 1.3 改进型 ConvNeXt

本试验用到的 ConvNeXt - T<sup>[29]</sup> 模型是基于 ResNet50<sup>[30]</sup> 并根据 SwinTransformer<sup>[31]</sup> 的思想进行改进得到的。本研究提出的改进型 ConvNeXt (CBAM - ConvNeXt) 结构如图 6 所示, 网络结构主要包含用于特征提取的 ConvNeXt 模块(图 7)、用于下采样的拆分降采样模块(图 8), 以及为消除复杂背景干扰所增加的注意力模块, 本试验通过对

SENet、ECANet、SKNet 以及 CBAM 注意力模块进行对比分析, 最终选用 CBAM 作为本模型的注意力模块。CBAM 是结合通道以及空间 2 个角度的注意力机制, 它将提取到的中间特征依次映射到通道维度和空间维度进行注意力分析, 最后将得到的注意力分数与输入的中间特征图进行相乘得到添加注意力后的特征图, 进而进行下一步的卷积操作。

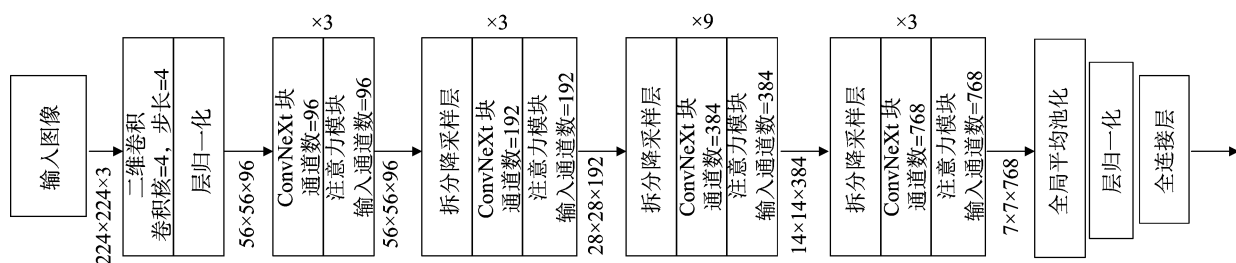


图6 CBAM-ConvNeXt 整体结构

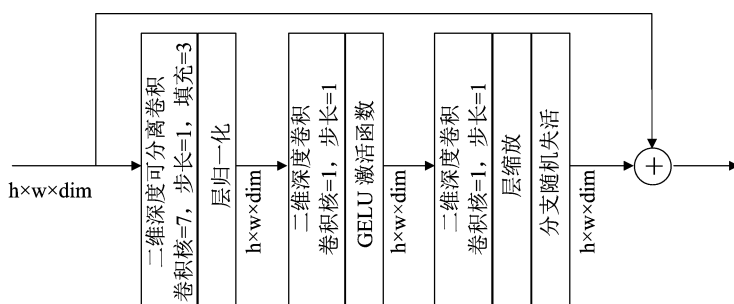


图7 ConvNeXt 块结构




图8 拆分降采样模块

图像如图 9 所示。




图9 LeakyReLU 函数图像

同时本试验在 CBAM 注意力模块中的使用 LeakyReLU<sup>[32]</sup> 激活函数, 通过修正 ReLU 激活函数的非线性单元从而克服输入为负值时神经元不学习的情况, LeakyReLU 激活函数如公式 (5) 所示, 函数

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

改进型 ConvNeXt 模型首先将大小为  $224 \times 224$  的三通道彩色玉米叶片病害图像经过一个大小为  $4 \times 4$  步长为 4 的卷积操作进行浅层特征的提取,并经过层归一化,输出大小为  $56 \times 56$  通道数为 96 的特征图,经过卷积操作得到的特征图的宽高计算公式为公式(6)和公式(7),其中  $H$ 、 $W$  为经过卷积后特征图的高、宽,  $h$ 、 $w$  为卷积前的高宽,  $k$  为卷积核的大小,  $p$  为填充的大小,  $s$  为卷积的步长。接下来就是经过 4 个 ConvNeXt 块和 4 个注意力模块以及 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。

$$H = (h - k + 2p) / s + 1; \quad (6)$$

$$W = (w - k + 2p) / s + 1. \quad (7)$$

## 2 试验准备工作

### 2.1 试验环境与设置

本试验采用 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训练迭代 100 次,批量大小设置为 64,学习率设置为 0.000 001。

### 2.2 评价标准

本研究通过 Softmax 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

$$Y(P) = P(y = p | x, \theta_p) = \frac{e^{x^T \cdot \theta_p}}{\sum_{p=1}^c e^{x^T \cdot \theta_p}} \quad (8)$$

并用交叉熵损失函数来作为进行网络优化的标准,并使用 Adam 优化器对模型参数进行优化,交叉熵损失函数的表达式为

$$\min_{W, b; \theta} \mathcal{E}(W, b; \theta) = \frac{1}{N} \sum_{n=1}^N \left[ - \sum_{p=1}^C \gamma(y_n = p) \cdot \lg P(y = p | \theta_p) \right] + \lambda R(\theta). \quad (9)$$

为更加直观地观察网络模型的好坏进行模型的对比,本试验引入准确率 (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:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}; \quad (10)$$

$$Precision = \frac{TP}{TP + FP}; \quad (11)$$

$$Recall = \frac{TP}{TP + FN}; \quad (12)$$

$$F_1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (13)$$

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分类的效果,采用混淆矩阵<sup>[35]</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,数据越集中在对角线上说明模型分类效果越好。

## 3 试验结果对比

为验证改进的 CBAM-ConvNeXt 模型的性能,共设置了 4 组对比试验: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 以及改进模型与 Swin Transformer 模型之间的性能对比。

### 3.1 数据增强试验效果对比

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 10 所示,最终对测试集分类效果的混淆矩阵如图 11 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 10 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。数据增强前后试验效果对比如表 2 所示,由表 2 可以看出,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,本研究采用的数据增强方法能够在数据预处理阶段提升网







表 2 数据增强前后试验效果对比

数据集	准确率 (%)	精确率 (%)	召回率 (%)	$F_1$ -score (%)
原数据集	88.89	88.64	88.75	88.89
增强后	91.77	91.90	91.77	91.77

络模型的泛化能力和鲁棒性,对玉米叶片病害分类起到积极作用。

3.2 模型改进试验效果对比

为了验证改进模型在玉米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 12)。由图 12 可以看出,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,收敛速度更快。各个模型试验结果对比见表 3。

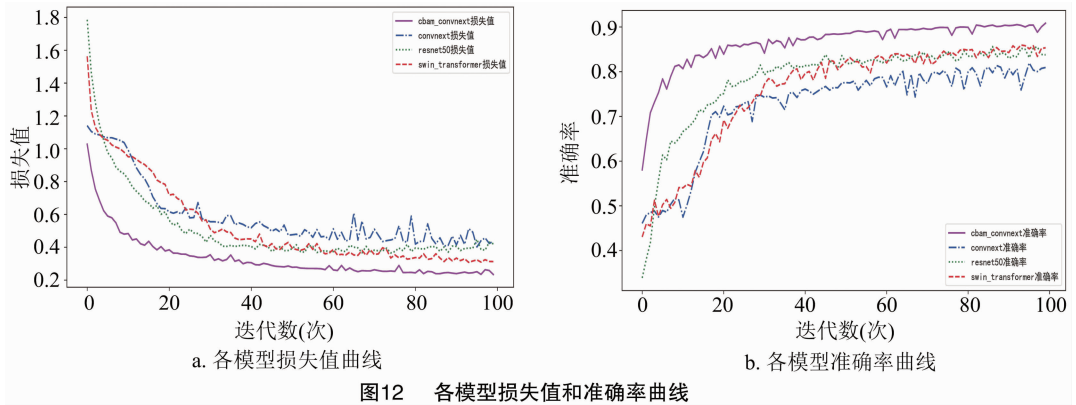


表 3 各模型试验结果对比

数据集	准确率 (%)	精确率 (%)	召回率 (%)	$F_1$ -score (%)
ResNet50	85.64	85.61	85.64	85.64
ConvNeXt-T	79.91	79.65	79.91	79.91
Swin Transformer	89.09	89.38	89.09	89.09
CBAM-ConvNeXt	91.77	91.90	91.77	91.77

此外,还使用混淆矩阵对模型进行对比,结果(图 13)表明,错误分类主要发生在 1 和 3 之间,分别代表灰斑病和大斑病,主要由于它们病斑特征存在较高的相似性,但相对其他 3 个模型来说本研究提出的改进型 ConvNeXt 在具有相似病斑特征的识别中有较好的识别能力。网络的识别效果见图 14。

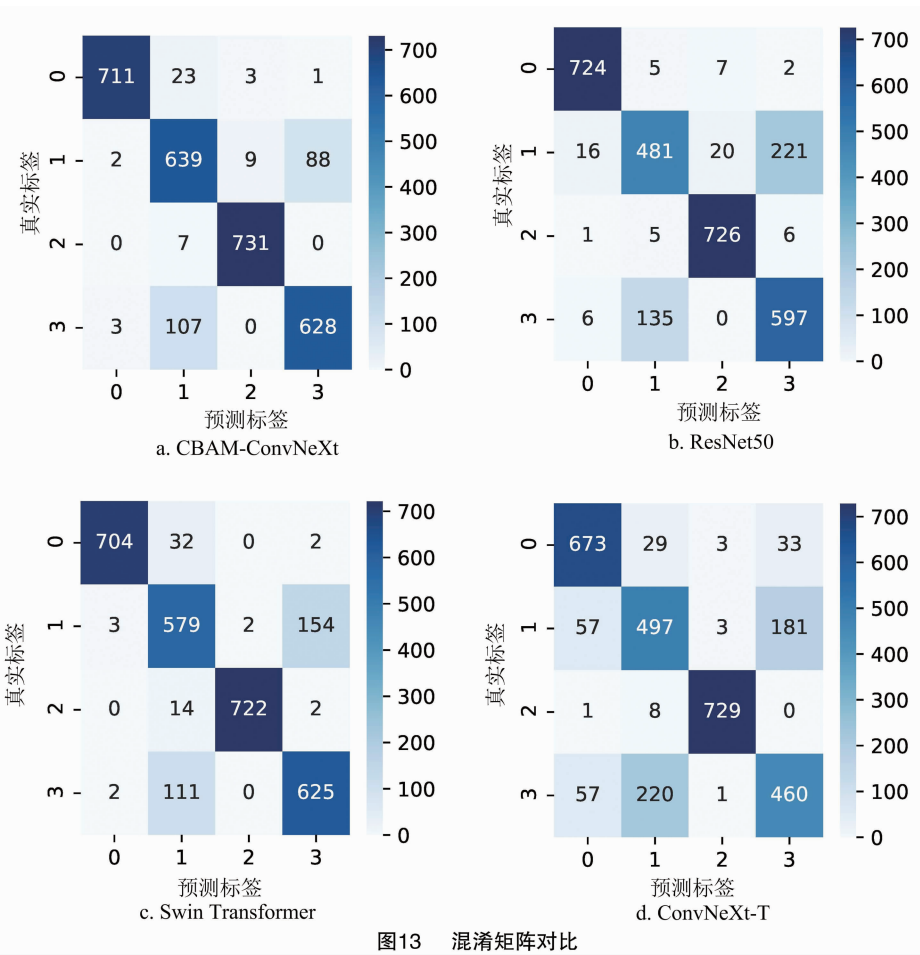


图 13 混淆矩阵对比




图 14 网络预测效果

4 结论

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 Leaky ReLu 激活函数,克服了在输入为负值时神经元失活的问题。通过在玉米叶片病害数据集上进

行的消冗试验, 结果表示, 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, 在测试集上的平均识别准确率为 91.77%, 均高于试验中相同条件下的其他网络模型, 从而说明了本模型的改进方法对玉米叶片病害分类具有积极作用。

#### 参考文献:

- [1] 傅俊范, 景殿玺, 刘震, 等. 玉米叶部病害流行动态及预测预警研究进展[J]. 吉林农业大学学报, 2016, 38(6): 651 – 655.
- [2] 曲维莉. 玉米常见病害防治措施[J]. 农民致富之友, 2018(13): 139.
- [3] 李颖. 玉米主要病虫害综合防治技术探究[J]. 农家参谋, 2022(16): 60 – 62.
- [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.
- [7] Panigrahy 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: 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.
- [9] Wagle S A, Harikrishna 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] Priyandarshini R A, Arivazhagan S, Arun M, et al. Maize leaf disease classification using deep convolutional neural networks[J]. Neural Computer & Application, 2019, 31(1): 8887 – 8895.
- [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.
- [13] 刘合兵, 鲁笛, 席磊. 基于 MobileNetV2 和迁移学习的玉米病害识别研究[J]. 河南农业大学学报, 2022, 56(6): 1041 – 1051.
- [14] Singh R K, Tiwari A, Gupta R K. Deep transfer modeling for classification of maize plant leaf disease[J]. Multimedia Tools and Application, 2022, 81(5): 6051 – 6067.
- [15] Lin Z, Mu S, Shi A, et al. A novel method of maize leaf disease image identification based on a multichannel convolutional neural network[J]. Transaction of the ASABE, 2018, 61(5): 1461 – 1474.
- [16] Xu Y L, Zhao B, Zhai Y T, et al. Maize diseases identification method based on multi – scale convolutional global pooling neural network[J]. IEEE Access, 2021, 9: 27959 – 27970.
- [17] Fujita E, Kawaski Y, Uga H, et al. Basic investigation on a robust and practical plant diagnostic system[J]. IEEE International Conference Machine Learning Applications, 2016, 15: 989 – 992.
- [18] 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.
- [19] Hughes D P, Salathe M. An open access repository of images on plant health to enable the development of mobile disease diagnostics[J]. Computer Science, 2015, 1: 1 – 13.
- [20] 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.
- [21] 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.
- [22] Wang Y Y, Tao J, Gao H. Corn disease recognition based on attention mechanism network[J]. Axioms, 2022, 11(9): 480.
- [23] 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.
- [24] 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.
- [25] 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.
- [26] 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: 1 – 12.
- [27] Li X, Wang W, Hu X, et al. Selective kernel networks[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2019: 1 – 12.
- [28] 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.
- [29] 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.
- [30] 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.
- [31] Liu Z, Lin Y, Cao Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C]//IEEE/CVF International Conference on Computer Vision, 2021: 10012 – 10022.
- [32] Xu B, Li M, Wang N, et al. Empirical evaluation of rectified activations in convolutional network[J]. arXiv, 2015, 27: 1 – 5.
- [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.
- [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.