



刘芳军,李玥,武陵,等.基于改进 ResNet18的胡麻干旱胁迫识别与分类研究[J].江西农业大学学报,2023,45(6):1517-1527.

LIU F J,LI Y,WU L,et al.Identification and classification of flax drought stress based on improved ResNet18[J].Acta agriculturae universitatis Jiangxiensis,2023,45(6):1517-1527.

基于改进 ResNet18 的胡麻干旱胁迫识别与分类研究

刘芳军¹,李玥^{1*},武陵²,吴丽丽¹

(1.甘肃农业大学 信息科学技术学院,甘肃 兰州 730070;2.兰州交通大学 网络信息中心,甘肃 兰州 730070)

摘要:【目的】为实现在移动端对胡麻干旱胁迫实时监测,解决传统机器学习方法在识别分类时准确率低、速度慢的问题,提出一种基于改进 ResNet18 的胡麻干旱胁迫分类识别方法。【方法】首先在网络中添加卷积块注意力(CBAM)模块,强化网络对胁迫特征的提取能力;其次调整残差块中批标准层、激活函数、卷积块的连接顺序,实现对输入的样本数据进行归一化操作;最后将 ReLU 激活函数替换成 LeakyReLU 激活函数,避免出现神经死亡现象。试验分为无胁迫、轻度干旱、重度干旱 3 个水分胁迫处理,分批次采集不同干旱程度胡麻叶片图像,数据样本按 3:1 分为训练集与测试集,并使用数据增强的方法增加样本的多样性。【结果】改进 ResNet18 模型分类准确率高达 98.67%,相比于 ResNet18 和 VGG16 分别提高 6.14 和 4.87 个百分点,而模型所需参数大小仅为 42.80 MB,单幅图像推理时间为 17.50 ms。【结论】该文模型对胡麻干旱胁迫具有更好的分类识别效果,能够实现嵌入式设备上胡麻干旱胁迫识别的实时性要求。可为胡麻干旱监测、机械化生产等研究提供技术支持。

关键词:胡麻干旱胁迫;图像识别;ResNet18;迁移学习;深度学习

中图分类号:S565.9 文献标志码:A

开放科学(资源服务)标识码(OSID):

文章编号:1000-2286(2023)06-1517-11



Identification and Classification of Flax Drought Stress Based on Improved ResNet18

LIU Fangjun¹, LI Yue^{1*}, WU Ling², WU Lili¹

(1. College of Information Science and Technology, Gansu Agricultural University, Lanzhou 730070, China; 2. Network Information Center, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: [Objective] In order to realize the real-time monitoring of flax drought stress on the mobile terminal, and solve the problem of low accuracy and slow speed of traditional machine learning methods in recognizing and classifying, this study proposes a classification and recognition method of flax drought stress based on improved ResNet18. [Method] Firstly, the Convolutional Block Attention (CBAM) module is added to the network to strengthen the network's ability to extract features; secondly, the connection order of the batch

收稿日期:2023-06-10 修回日期:2023-08-13

基金项目:国家自然科学基金项目(32060437)和甘肃省科技计划-自然科学基金重点项目(23JRRA1403)

Project supported by the National Natural Science Foundation of China (32060437) and Gansu Provincial Science and Technology Program-Natural Science Foundation Key Projects (23JRRA1403)

作者简介:刘芳军,硕士生,orcid.org/0009-0007-0870-1652,930340087@qq.com; *通信作者:李玥,副教授,博士,主要从事智慧农业、大数据分析挖掘等研究,orcid.org/0000-0003-1461-0742,liyue@gsau.edu.cn。

standard layer, activation function, and convolutional block in the residual block is adjusted to achieve the normalization operation of the input sample data; and lastly, the ReLU activation function is replaced by the LeakyReLU activation function to avoid the phenomenon of neural death. The experiment was divided into three water stress treatments, namely, coercionless, mild coercion and severe coercion, and the images of flax leaves with different drought degrees were collected in batches, the data samples were divided into the training set and the test set based on the proportion of 3:1, and the method of data enhancement was used to increase the diversity of the samples. [Result] The test results show that the classification accuracy of the improved ResNet18 model is as high as 98.67%, which is 6.14 and 4.87 percentage points higher than that of ResNet18 and VGG16, respectively, while the required parameter size of the model is only 42.80 MB, and the inference time for a single image is 17.50 ms. [Conclusion] The model of this study has a better classification and recognition effect on flax drought stress. It can realize the real-time requirements of flax drought stress recognition on embedded devices, thus providing technical support for the research of flax drought monitoring, mechanized production and so on.

Keywords: flax drought stress; image recognition; ResNet18; transfer learning; deep learning

【研究意义】胡麻是我国北方种植的一种重要经济作物,具有较多功效,且用途广泛^[1]。既可以制作成品质优良的食用油,也可以增强人体免疫能力,降低血脂和血压,还可以抑制癌细胞转移,表现良好的抗癌效果,胡麻的保健功效已受到越来越多的学者和专家重视^[2]。胡麻的生长发育对水分要求较高,适宜的水分能促进胡麻的产量和品质。不同干旱胁迫水平对胡麻生长和产量有不同的影响。同时,不同干旱胁迫水平的胡麻需要不同的灌溉量^[3]。因此,实现胡麻干旱胁迫的准确监测,对于胡麻精准灌溉、确保胡麻高产具有重要意义。【前人研究进展】早期的干旱胁迫诊断方法是土壤水分检测和农业气象预报等,这种方法主要通过采集土壤含水量和分析气象数据间接地对干旱进行监测,该技术效率低下,且精度不高,不适合用于干旱胁迫下植物的早期鉴定。在干旱胁迫下,植株叶子会出现萎蔫、叶片表面变黄等表型特征^[4]。因此,植株的表型特征可以直接监测出干旱情况,基于表型特征对植株进行干旱胁迫识别和分类是快速、无损的方法^[5]。传统的机器学习方法主要提取植物的颜色、纹理等特征^[6],然后将其用作研究分析。庄硕^[7]通过人工设计一组候选特征从颜色和纹理2个角度,有效地表达玉米植株的表型信息,与两阶段分类模型相结合快速检测出田间群体玉米的干旱胁迫状态。Gutiérrez等^[8]利用热成像技术和机器学习模型,通过对成像分析来评估葡萄园的水分胁迫状态。虽然传统的机器学习在生物胁迫的识别中取得不错的效果,但需要对采集的图像进行分割和人工提取,人工提取到的特征也容易受环境影响,识别和分类的准确程度不高。与传统的机器学习方法相比,深度学习处理技术提供自动特征提取和分析的优点,在生物干旱胁迫识别中,具有更好的性能。采用卷积神经网络并借助已有的预训练模型进行迁移学习是最常见的模型训练方法,在实际应用的过程中取得较好效果,大大提高了识别的准确率,缩短了训练时间。钟仁海等^[9]在深度学习的玉米估产模型中嵌入注意力机制的长短期记忆神经网络对玉米生长过程时序特征进行提取,通过多任务学习方法对玉米产量进行估测,总体估产精度提升11%~19%,在气象胁迫年份提升幅度更明显(20%~23%)。赵奇慧等^[10]通过Mask R-CNN网络对番茄叶片进行实例分割,使用微调的DenseNet169模型对温室番茄叶片水分胁迫程度进行识别分类。Chandel等^[11]测试了AlexNet、GoogLeNet和InceptionV3模型,以确定玉米、秋葵、大豆的干旱胁迫,结果发现GoogLeNet的性能优于其他模型。Alsharman等^[12]使用改进的GoogleNet模型,对COVIDCT数据集的胸部CT冠状病毒图像进行识别。【本研究切入点】基于深度学习的方法在图像识别与分类过程中表现出良好的性能^[13],但其准确率和效率仍有待改进。【拟解决的关键问题】本研究提出一种基于改进ResNet18的胡麻干旱识别与分类研究算法。首先引入卷积块注意力模块CBAM进行自适应的特征细化^[14];其次通过修改ResNet18网络结构排列顺序,提高网络提取特征能力,最大程度降低了过拟合;最后将ReLU激活函数替换成LeakyReLU激活函数,解决神经死亡问题,增强模型的鲁棒性。以此来解决胡麻干旱胁迫识别分类时准确率低、速度慢的问题,为胡麻干旱胁迫的预防和监测提供了一种自动化方案。

1 胡麻图像识别网络模型构建

1.1 图像数据采集

该试验于 2023 年 6—7 月在甘肃省定西市农科院西寨油料站(35°34'48"N,104°37'12"E)进行,拍摄胡麻开花期包括早上、中午、傍晚等不同时间段。胡麻的干旱状态是逐渐发生的,通过控制施水量来控制胡麻的胁迫状态。使用土壤湿度传感器测量土壤相对含水量,设置 3 种不同干旱处理,分别为无胁迫即适宜水分(土壤相对含水量为 75%~90%)、轻度胁迫(土壤相对含水量为 60%~70%)和重度胁迫(土壤相对含水量为 25%~35%)。不同干旱胁迫下胡麻叶片表型特征如表 1 所示。

表 1 3 种不同胁迫下叶片图像的叶片特征

Tab.1 Leaf characteristics of leaf images under three different stresses

胁迫类别 Coercion category	叶片特征 Leaf characteristics
无胁迫 Coercionless	叶片自然伸展,颜色为翠绿或深绿
轻度胁迫 Mild coercion	叶片略有萎焉下垂,叶边缘有卷起,叶面褶皱
重度胁迫 Severe coercion	叶片严重萎焉下垂,整片叶子蜷缩卷起

利用海康机器人开发的 MV-CA004-10GM,分辨率 720×540 的工业相机,拍摄时间为 08:00 至 18:00,选取 3 种干旱胁迫下的胡麻图像各 500 张,试验样本总计 1 500 张。图像样本示例如图 1 所示。



图 1 胡麻干旱胁迫图像
Fig.1 Flax drought stress image

1.2 残差网络模型

ResNet 是 2016 年由何凯明团队提出的一种影响深远的网络模型,在 ImageNet 的分类比赛上将网络深度直接提高到了 152 层,ImageNet 的目标检测以碾压的优势成功夺得了当年识别和目标检测的冠军,COCO 数据集的目标检测和图像分割比赛上同样碾压夺冠,可以说 ResNet 的出现对深度神经网络来说具有重大的历史意义。

与传统的网络结构相比,ResNet 增加了“短路”连接(shortcut connection)或称为跳跃连接(skip connection),如图 2 所示:

ResNet 添加了一个短路连接到第二层线性整流函数(ReLU)之前,那么线性整流函数的输入就由原来的输出 $H(x)=F(x)$ 变为了 $H(x)=F(x)+x$ 。在 ResNet 中,这种输出等于输入的操作成为恒等映射,图 2 残差块结构中的 identity 保证了恒等映射。引进 identity 之后,身份映射将改变网络层的方向,即 $F(x)+x \rightarrow x$,采用该方法可以实现跨层数据流,以确保模型仍然处于最优状态,并且

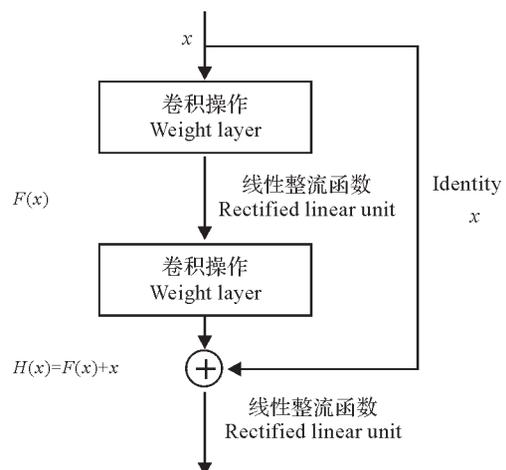


图 2 残差块结构
Fig.2 Structure of residual block

可以加快网络收敛。

在解决梯度弥散的问题上,通过如下的公式分析。

$$X_L = X_1 + \sum_{i=1}^{L-1} F(X_i, W_i) \tag{1}$$

式(1)中, X_L 表示网络第 L 层的特性,即浅层单元 1 的特征 X_1 加上一个残差函数映射 $\sum_{i=1}^{L-1} F(X_i, W_i)$, 表明模型在任意单元内都具有残差特性。可以看出在残差网络中,下面层次残差块的输出都可以由上面的某一层确定。

对于反向传播,假设损失函数为 E ,根据反向传播的链式求导法则,可以得到残差网络的梯度公式^[15]。

$$\frac{\partial \mathcal{E}}{\partial X_i} = \frac{\partial \mathcal{E}}{\partial X_L} \frac{\partial X_L}{\partial X_i} = \frac{\partial \mathcal{E}}{\partial X_L} \left(1 + \frac{\partial}{\partial X_i} \sum_{i=1}^{L-1} F(X_i, W_i) \right) \tag{2}$$

公式(2)被分为两部分,即不通过权重层传递的 $\frac{\partial \mathcal{E}}{\partial X_i}$ 和通过权重层传递的 $\frac{\partial \mathcal{E}}{\partial X_L} \left(1 + \frac{\partial}{\partial X_i} \sum_{i=1}^{L-1} F(X_i, W_i) \right)$, $\frac{\partial \mathcal{E}}{\partial X_i}$ 保证了传递直接可以传回任意的浅层 X_i ,这是多层普通神经网络映射上的结果。即使新增的多层神经网络的梯度为 0 时,残差网络的梯度更新会多一个“1”。这样可以保证不会出现梯度消失的现象,深层的梯度可以直接通到上一层,使得浅层的网络层参数得到有效的训练。

1.3 改进 ResNet18 模型构建

为了保证胡麻干旱胁迫分类任务的准确率和效率,选择网络层数较小的 ResNet18 网络为基础模型。ResNet18 即保证网络深度的同时又实现快速收敛,也可以嵌入到物联网设备中,用于该领域的实时干旱监测。

1.3.1 增加卷积块注意力模块 卷积块注意力模块(convolutional block attention module, CBAM)有两个子模块:通道模块和空间模块。通过 CBAM 中间特征图在深度网络的每个卷积块上进行自适应地细化,可以提高特征表达能力,让网络学会关注重点信息。CBAM 是一个轻量级的注意模块,它几乎可以嵌入到任何卷积神经网络中^[16],而引入的计算量和参数几乎可以忽略不计,并且可以与基础 CNN 一起进行端到端训练,如图 3 所示。

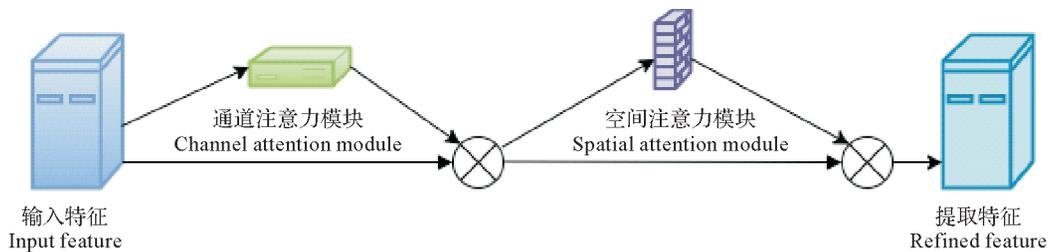


图 3 通道模块与空间模块在 CNN 中的连接方式

Fig.3 Connection mode of channel attention and spatial attention in CNN

在原始网络 ResNet18 中添加卷积块注意力模块 CBAM,构成 ResNet18-CBAM。如果直接把 CBAM 模块添加 ResNet18 中,模型的网络结构将发生变化,导致无法使用预训练参数。本研究在 ResNet18 中添加了两个 CBAM 模块,经过测试,两个模块的位置分别设置在第一层卷积和最后一层卷积之后,如图 4 所示。该组合在识别处具有较高的权重系数,增强了 ResNet18 的分类效果。

1.3.2 网络结构的调整 图 5 表示传统的残差网络结构,依次按照卷积层、标准化层、激活函数的顺序连接^[17],这样的连接顺序没有对输入的样本数据进行归一化操作,并未发挥出批标准层的重要作用。

因此,本研究对传统的残差网络排列顺序进行了调整,图 6 为改进之后的残差块网络结构。在卷积层之前增加了批标准化和激活函数,不仅使梯度变大,加快学习收敛速度,避免梯度消失,也保留了残差块结构中的恒等映射。

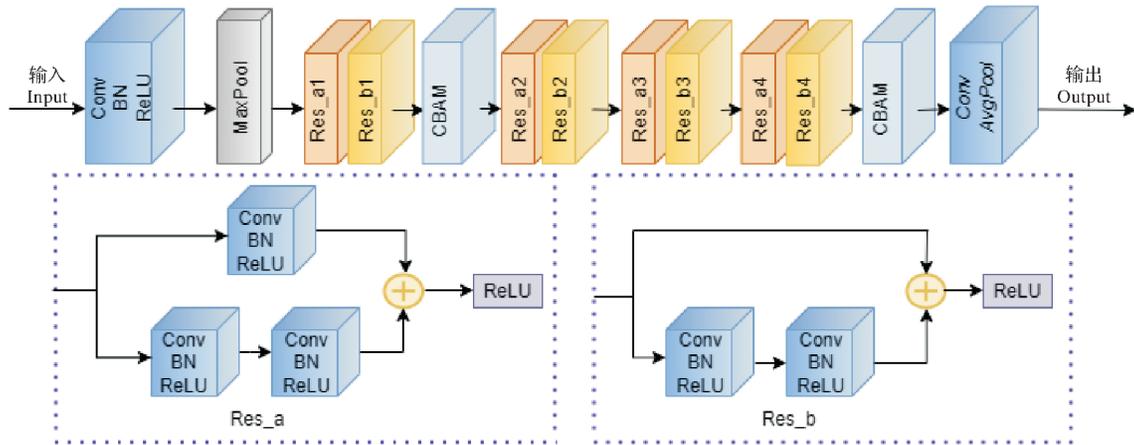


图 4 ResNet18-CBAM 网络结构

Fig.4 ResNet18-CBAM network structure

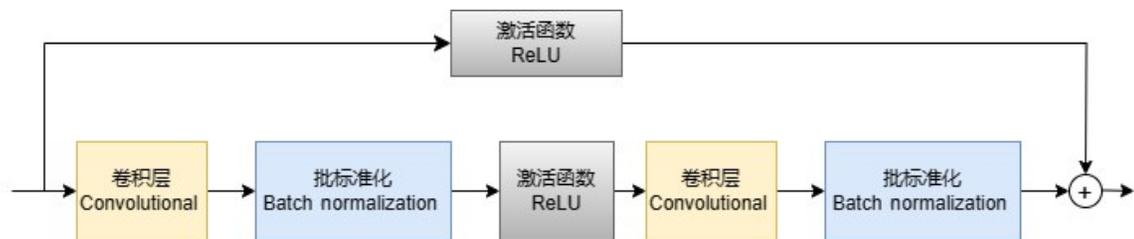


图 5 传统残差块网络结构

Fig.5 Traditional residual block network structure

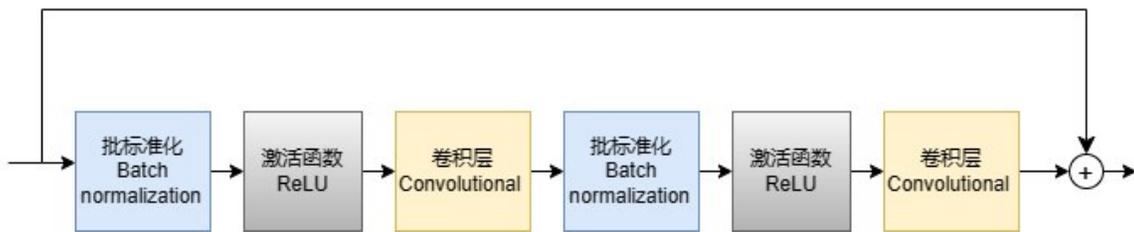


图 6 改进残差块网络结构

Fig.6 Improved residual block network structure

1.3.3 LeakyReLU 激活函数 ReLU 是在神经网络中常用的激活函数,通常意义如下,其指代数学中的斜坡函数,即 $ReLU(x)=\max(0,x)^{[18]}$ 。ReLU 对应的函数图像和公式如图 7 和式(3)所示。

$$ReLU(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (3)$$

由图 7 和公式(3)可以看出,随着训练的进行,只有输入 x 的取值为正数时,ReLU 激活函数才会起作用;当输入的值负值时,ReLU 会出现神经元死亡的问题,导致权重无法更新。为解决这一问题,本研究使用 LeakyReLU 替换 ReLU 作为中间层的激活函数,使训练期间在负区域的激活功能更加活跃,解决了神经死亡问题。LeakyReLU 激活函数的图像和公式如图 8 和式(4)所示。

LeakyReLU 与 ReLU 很相似,仅在输入小于 0 的部分有差别,ReLU 输入小于 0 的部分值都为 0,而 LeakyReLU 输入小于 0 的部分,值为负,且有微小的梯度。

$$LeakyReLU = \begin{cases} x, & x > 0 \\ \alpha x, & x \leq 0 \end{cases} \quad (4)$$

式(4)中, α 通常取较小的值。使用 LeakyReLU 的优势在于:在反向传播过程中,当 LeakyReLU 输入小于 0 的值时,也可以计算得到梯度,这样不仅避免了训练过程中出现死节点现象,还增强了模型的鲁棒性。

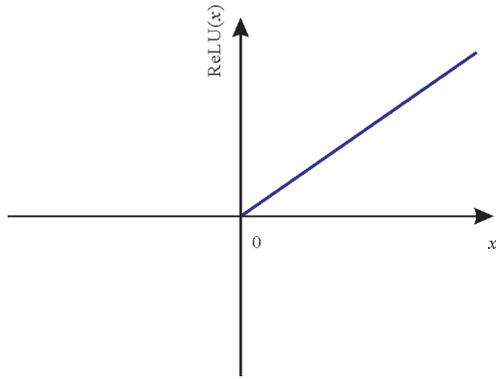


图7 ReLU激活函数
Fig.7 ReLU activation function

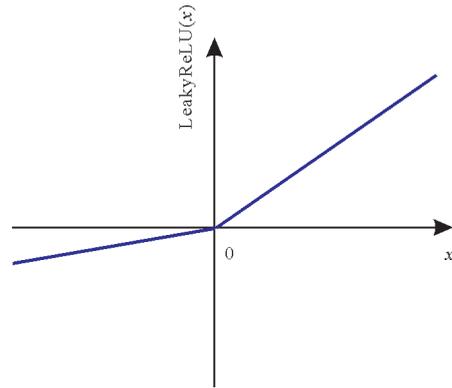


图8 LeakyReLU激活函数
Fig.8 LeakyReLU activation function

1.4 迁移学习

迁移学习是一种机器学习方法,它利用现有知识来解决不同相关领域的问题^[19-20]。其目标是完成相关领域之间的知识转移。对于卷积神经网络,迁移学习是成功地将特定数据集上训练的“知识”应用于新领域。

通常有两种方法可以将迁移学习应用于卷积神经网络。一种是使用具有学习权重的预训练模型来获得新问题中要使用的特征,即使用预训练模型作为特征提取器。此时,网络的输出在最后一个完整连接层前面的部分中提取感兴趣的特征。另一种是使用新的数据集来训练网络以微调网络权重。在这种情况下,必须修改输出图层结点的数量以匹配新问题中的类别数量。此外,在这两种情况下,输入数据都必须与预训练网络的输入大小匹配。具体的迁移学习方法取决于目标数据集和原始数据集在大小上的差异和相似性,如果目标数据集非常小且相似,为了防止过度拟合,可以使用预先训练过的模型作为特征提取器,反之则使用微调。

由于本试验中使用的数据集较小,过拟合的可能性相对较大,因此将经过训练的ResNet18网络模型作为特征提取器,即用预先训练过的模型提取图像的特征,最后提取的特征放到Softmax分类器中进行分类训练。

2 基于改进ResNet18的胡麻干旱胁迫分类试验

2.1 图像数据预处理

数据增强可以提高模型的识别精度,克服过拟合问题。首先将每幅图像尺寸缩放到224×224像素,以最小化训练时间,并调整强度值填充整个强度范围[0,255],然后随机将75%的样本设置为训练集,25%的样本设置为测试集。

由于本研究采集的数据样本较小,为了增加训练集的数据量,提高模型的泛化能力^[21],因此采用预处理技术对图像数据进行增强,以便提高模型的识别精度并克服过度拟合。本试验采用宽度偏移、高度偏移、水平垂直翻转、剪切和缩放等方式对数据集进行扩充,扩充后的图像共7 500张,数据增强的具体参数值:宽度偏移为0.1,高度偏移为0.1,剪切为0.2,缩放为0.2,水平垂直旋转为True。

2.2 试验平台与训练参数

所有试验均在Python3.8.5、PyTorch1.8.0环境下进行,硬件环境CPU为Intel Core i7-8750H,主频2.20 GHz;GPU为NVIDIA GeForce GTX1050Ti,4 GB显卡内存,操作系统为Windows10 64位。

为了验证改进ResNet18的有效性,将改进后的分类算法与其他主流网络模型进行对比测试。试验中6个对比模型分别为:ResNet18,VGG16,在ResNet18网络中添加CBAM注意力机制的ResNet18-CBAM模型,改变残差块中批标准层、激活函数、卷积块的连接顺序的ResNet18-调整结构模型,改变ReLU激活函数的ResNet18-LeakyReLU模型以及原始网络为ResNet18且同时添加CBAM模块、调整网络结构、改变ReLU激活函数的本研究的方法。在训练期间,所有模型的超参数都是一致的,试验

具体参数设置: Batch-size 为 16, Epochs 为 50, Optimizer 为 Adam, Learning rate 为 0.001, Loss function 为 CrossEntropyLoss。

2.3 评价指标

本研究采用准确率(accuracy),召回率(recall),精确率(precision), F_1 值(F_1 -score),模型大小(model size/MB)以及单幅图像的推理时间(time/ms)来评估网络的性能。

$$\text{accuracy} = \frac{TP + TN}{TP + FP + TN + FN} \quad (5)$$

$$\text{recall} = \frac{TP}{TP + FN} \quad (6)$$

$$\text{precision} = \frac{TP}{TP + FP} \quad (7)$$

$$F_1 = \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (8)$$

式中,accuracy 为算法对所有预测中正确预测的比率;recall 为正确预测结果与所有预测的比率;precision 表示被分为正样本的示例中实际为正的比率; F_1 -score 是一个综合评价指标。TP 和 FN 分别表示样本中正样本和负样本的数量;FP 和 TN 表示预测负样本为正和负的样本数量。model size 为模型大小,一般使用参数量 parameter 来衡量,但由于该文中使用的模型参数量太大,所以用单位 MB 来表示。Time 表示单幅图像的推理时间,即从接收输入数据到输出结果所需要的时间。

3 结果与分析

3.1 损失函数

在训练集上各网络的损失函数变化情况如图9所示。

从图9损失曲线可以看出,与其他网络相比,VGG16 不仅有较大的损失值,损失曲线的震幅也较大。而原始网络为 ResNet18 的模型则相对稳定一些,且添加 CBAM 注意力机制、调整网络结构和改变激活函数的模型在训练期间表现更好。本研究所提模型的损失曲线最稳定,也低于其他模型,不到 1 000 步时就已经开始稳定。

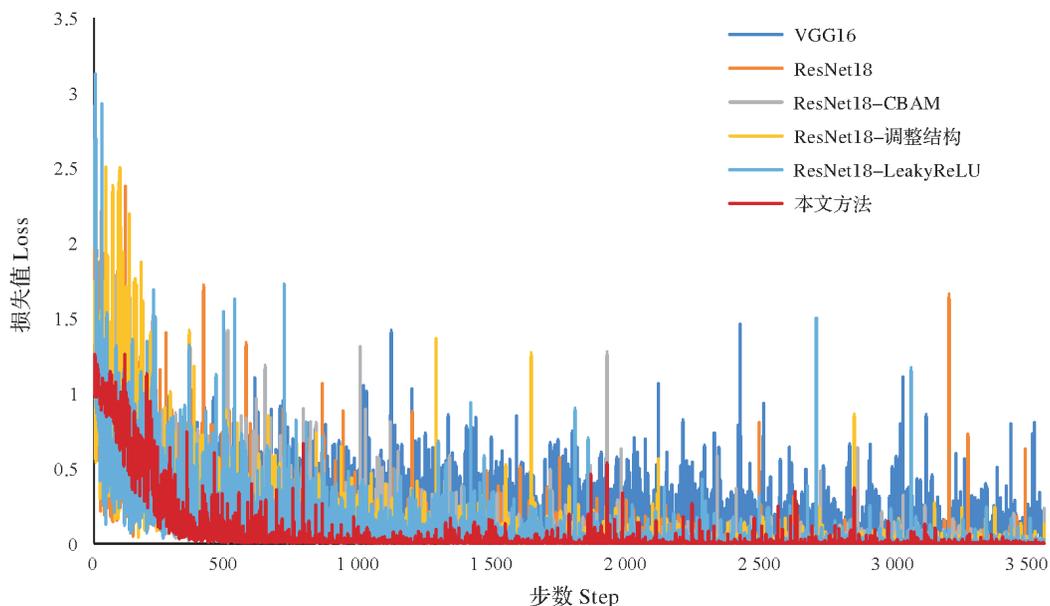


图9 各分类模型在训练期间的损失曲线

Fig.9 Training loss curve of each classification model

3.2 不同网络模型对比

为了对比6种网络模型在不同胡麻干旱胁迫条件下的分类性能,选择准确率、精度、召回率、 F_1 值、模型大小和平均单幅图像的推理时间作为评价指标,在测试集上的试验结果如表2所示。

表2 不同模型评估标准对比

Tab.2 Comparison of evaluation criteria of different models

分类模型 Classification model	准确率/% Accuracy	精度/% Precision	召回率/% Recall	F_1 值/% F_1 -score	时间/ms Time	模型大小/MB Model size
VGG16	93.80	92.67	93.00	92.83	17.88	512.21
ResNet18	92.53	92.67	92.67	92.67	17.06	42.68
ResNet18-CBAM	97.07	97.00	97.00	97.00	17.56	42.81
ResNet18-调整结构	95.20	95.00	95.33	95.16	17.13	82.07
ResNet18-LeakyReLU	94.13	94.33	94.33	94.33	16.31	82.08
本研究 The study	98.67	98.67	98.67	98.67	17.50	42.80

从表2可以看出,本研究所提出的在ResNet18中添加CBAM注意力机制、调整网络结构和改变激活函数结合起来构建的新模型,对胡麻干旱胁迫的分类精度为98.67%,优于原始的ResNet18(92.67%),这也进一步说明本研究所提网络的可靠性。与此同时,本研究提出的3种改进策略在胡麻干旱胁迫数据集上的准确率都略高于ResNet18和VGG16网络模型,分别提升4.53、2.67、1.6和3.27、1.4、0.33个百分点。其中添加CBAM注意力机制方法提升的效果最为明显,这是因为引入CBAM之后,特征覆盖到了胡麻叶片的更多部位,且最终判别的几率也更高,CBAM注意力机制让网络学会关注重点信息。

将3种改进策略结合的网络比只有一种改进模块的准确率都要高,且精度和召回率达到98.67%。在胡麻叶部干旱胁迫分类对比试验中,所提出的模型大小较原始ResNet18网络模型几乎没有增加,训练耗费的时间变化不大,说明其性能提升的同时,并没有增加时间复杂度和空间复杂度,进一步体现了模型改进的有效性。上述结果进一步表明,本研究提出的胡麻干旱胁迫分类模型具有轻量化、实时性强且容易部署在嵌入式设备上等优点。

为了进一步探究模型对不同干旱胁迫的分类差异,各类样本的分类精度、召回率和 F_1 值如表3所示。

表3 不同模型的精度、召回率和 F_1 值对比Tab.3 Comparison of precision, recall and F_1 -score of different models

类别 Category	模型 Model	精度/% Precision	召回率/% Recall	F_1 值/% F_1 -score
无胁迫 Coercionless	VGG16	95.00	97.00	95.99
	ResNet18	94.00	97.00	94.98
	ResNet18-CBAM	96.00	98.00	96.99
	ResNet18-调整结构	96.00	97.00	96.50
	ResNet18-LeakyReLU	95.00	98.00	96.48
轻度胁迫 Mild coercion	本研究	99.00	97.00	97.99
	VGG16	90.00	93.00	91.48
	ResNet18	91.00	93.00	91.99
	ResNet18-CBAM	97.00	97.00	97.00
	ResNet18-调整结构	94.00	95.00	94.50
重度胁迫 Severe coercion	ResNet18-LeakyReLU	94.00	93.00	93.50
	本研究	97.00	100.00	98.48
	VGG16	93.00	89.00	90.96
	ResNet18	93.00	88.00	90.43
	ResNet18-CBAM	98.00	96.00	96.99
	ResNet18-调整结构	95.00	94.00	94.50
	ResNet18-LeakyReLU	94.00	92.00	92.99
	本研究	100.00	99.00	99.50

从表 3 可以看出,所提模型的召回率、 F_1 值都很高,3 种胁迫的分类精确度均在 97.00% 以上,特别是对重度胁迫的分类精度达到 100%。说明本研究提出的模型有效提升了胡麻干旱胁迫分类的准确性,且具有较好的泛化性能,能够出色的处理分类任务。

3.3 分类结果的混淆矩阵

混淆矩阵是用来可视化地展示分类模型的性能,是评估网络结果的重要指标。为进一步了解各类干旱胁迫分类的识别情况,6 种分类网络对 3 种胁迫分类准确率如图 10 所示。图中明确标出各模型将某个干旱胁迫类别识别为其他类别的比例,可以更加直观地展示出各模型的错误分类情况。

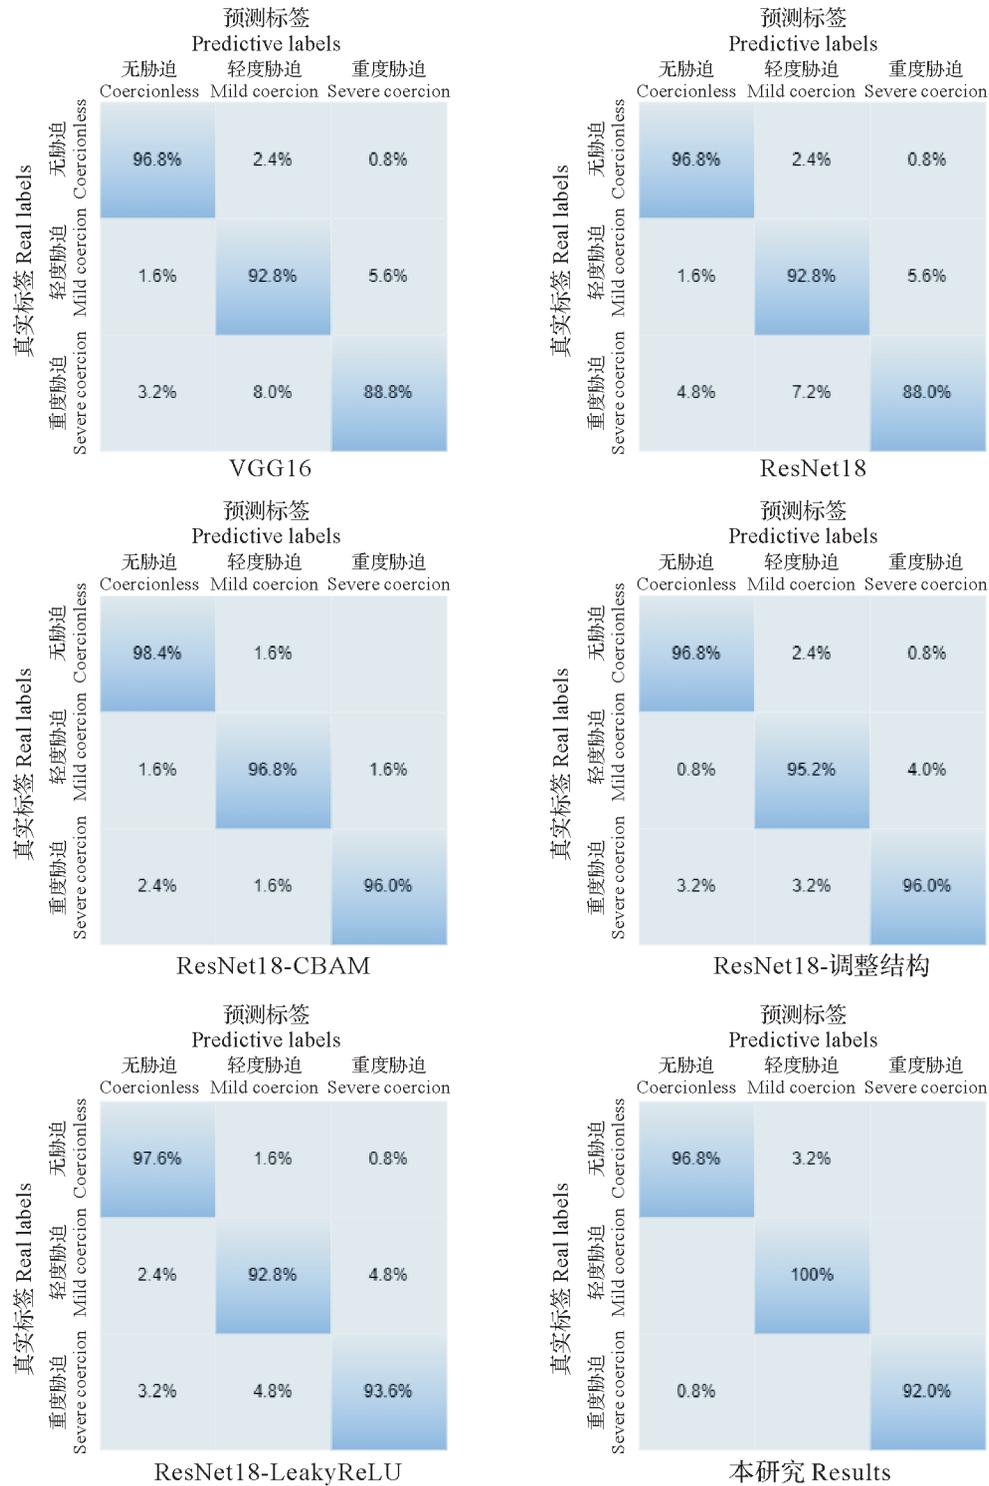


图 10 不同模型分类准确率对比

Fig.10 Comparison of classification accuracy of different models

分类混淆矩阵显示,尽管大多数图像被正确分类,但仍有少部分存在错误分类。适宜水分(无胁迫)很容易被错误地归类为轻度干旱,轻度干旱容易被误分类为适宜水分和重度干旱,重度干旱也容易被误以为轻度干旱。通过分析得出被错误分类的可能原因,一方面是由于数据集较少,导致样本不均匀;另一方面因为图像中存在不同的干旱胁迫胡麻植株和不同的表型特征,在同一胁迫处理中,有些叶子卷起特征较明显,有些不明显,这就导致样品分类不正确。此外土壤水分分布不均匀也会导致被错误分类。

总体来说,除了本文提出的模型之外,其他模型被错误分类的情况较为明显。可以看出本文改进的网络模型能够较好地胡麻干旱胁迫进行区分和判别,有效地降低了干旱胁迫识别误识率。

4 结 论

本研究提出了一种基于改进 ResNet18 胡麻干旱胁迫鉴定方法。通过增加卷积块注意力模块 CBAM,进行自适应的特征细化;改变残差块中批标准层、激活函数、卷积块的连接顺序,提高网络提取特征能力;将 ReLU 激活函数替换成 LeakyReLU 激活函数,解决神经死亡问题。试验结果表明,改进后的网络分类准确率达到 98.67%,优于 ResNet18(92.67%)和 VGG16(93.80%)。验证了改进方法的准确性,能够准确识别胡麻干旱,为胡麻干旱胁迫的预防和控制提供了一种自动化方案。

通过混淆矩阵可视化地对种类识别结果分析,3种干旱胁迫的精确度、召回率、 F_1 值都达到 98.67%,其中重度胁迫的精确度、召回率、 F_1 值基本达到 100%。证明了改进模型的性能优越,能够有效地辨别胡麻干旱胁迫。

改进后的模型大小仅为 42.80 MB,平均单幅图像的推理时间为 17.50 ms,可满足嵌入式设备上以提供实时、准确、广泛地胡麻干旱胁迫监测和预警。

参考文献 References:

- [1] 何丽,杜彦斌,王娜,等.胡麻抗旱综合性评价及种质资源分析[J].分子植物育种,2022,20(21):7270-7280.
HE L, DU Y B, WANG N, et al. Comprehensive evaluation of drought resistance and analysis of germplasm resources of flax [J]. Molecular plant breeding, 2022, 20(21): 7270-7280.
- [2] 曹秀霞,张信.胡麻籽营养保健功能成分研究综述[J].安徽农学通报,2009,15(21):75-76.
CAO X X, ZHANG X. A review of nutritional and healthcare functional components of caraway seed [J]. Anhui agricultural science bulletin, 2009, 15(21): 75-76.
- [3] 康佳,李玥,康亮河.胡麻生理生化代谢指标对干旱胁迫的响应及其模拟模型的研究[J].干旱区地理,2022,45(3):879-889.
KANG J, LI Y, KANG L H. Response of physiological and biochemical metabolism indices of flax to drought stress and its simulation model [J]. Arid land geography, 2022, 45(3): 879-889.
- [4] RAMOS-GIRALDO P, REBERG-HORTON C, LOCKE A M, et al. Drought stress detection using low-cost computer vision systems and machine learning techniques [J]. IT professional, 2020, 22(3): 27-29.
- [5] 贺露,万莉,高会议.基于高光谱成像技术识别番茄干旱胁迫[J].光谱学与光谱分析,2023,43(3):724-730.
HE L, WAN L, GAO H Y. Recognition of drought stress in tomato based on hyperspectral imaging [J]. Spectroscopy and spectral analysis, 2023, 43(3): 724-730.
- [6] ROPELEWSKA E, NAZARI L. The effect of drought stress of sorghum grains on the textural features evaluated using machine learning [J]. European food research and technology, 2021, 247(11): 2787-2798.
- [7] 庄硕.基于机器视觉的玉米早期表型分析与干旱识别研究[D].天津:天津大学,2020.
ZHUANG S. Early phenotypic analysis and drought identification of maize plants based on machine vision [D]. Tianjin: Tianjin University, 2020.
- [8] GUTIERREZ S, DIAGO M P, FERNANDEZ-NOVALES J, et al. Vineyard water status assessment using on-the-go thermal imaging and machine learning [J]. Plos one, 2018, 13(2): e0192037.
- [9] 钟仁海.基于深度学习的玉米单产估测方法和归因分析研究[D].杭州:浙江大学,2022.

- ZHONG R H. Deep learning based corn yield estimation method and attribution analysis [D]. Hangzhou: Zhejiang University, 2022.
- [10] 赵奇慧, 李莉, 张森, 等. 基于迁移学习的温室番茄叶片水分胁迫诊断方法 [J]. 农业机械学报, 2020, 51(S1): 340-347.
ZHAO Q H, LI L, ZHANG M, et al. Water stress diagnosis algorithm of greenhouse tomato based on fine-tuning learning [J]. Transactions of the Chinese society for agricultural machinery, 2020, 51(S1): 340-347.
- [11] CHANDEL S N, CHAKRABORTY K S, RAJWADE A Y, et al. Identifying crop water stress using deeplearning models [J]. Neural computing and applications, 2020, 33(10): 5353-5367.
- [12] ALSHARMAN N, JAWARNEH I. GoogleNet CNN neural network towards chest CT-Coronavirus medical image classification [J]. Journal of computer science, 2020, 16(5): 620-625.
- [13] 胡政. 基于高光谱成像技术的番茄早疫病无损检测方法研究 [D]. 贵阳: 贵州大学, 2022.
HU Z. Study on non-destructive detection method of tomato early blight based on hyperspectral imaging technology [D]. Guiyang: Guizhou University, 2022.
- [14] 刘斌, 徐皓玮, 李承泽, 等. 基于快照集成卷积神经网络的苹果叶部病害程度识别 [J]. 农业机械学报, 2022, 53(6): 286-294.
LIU B, XU H W, LI C Z, et al. Apple leaf disease identification method based on snapshot ensemble CNN [J]. Transactions of the Chinese society for agricultural machinery, 2022, 53(6): 286-294.
- [15] 席志红, 侯彩燕, 袁昆鹏, 等. 基于深层残差网络的加速图像超分辨率重建 [J]. 光学学报, 2019, 39(2): 89-98.
XI Z H, HOU C Y, YUAN K P, et al. Super-resolution reconstruction of accelerated image based on deep residual network [J]. Acta optica Sinica, 2019, 39(2): 89-98.
- [16] 丁睿柔. 基于卷积神经网络的苹果叶部病害识别与分割研究 [D]. 泰安: 山东农业大学, 2022.
DING R R. Research on apple leaf disease identification and segmentation based on convolutional neural network [D]. Tai'an: Shandong Agricultural University, 2022.
- [17] 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, 57(23): 178-184.
HUANG Y L, AI X. Research on classification of corn leaf disease image by improved residual network [J]. Computer engineering and applications, 2021, 57(23): 178-184.
- [18] 白金华. 自然环境下基于计算机视觉的果园苹果检测 [D]. 贵阳: 贵州民族大学, 2022.
BAI J H. Orchard apple detection based on computer vision in natural environment [D]. Guiyang: Guizhou Minzu University, 2022.
- [19] ZHUANG J Y, JIN X J, CHEN Y, et al. Drought stress impact on the performance of deep convolutional neural networks for weed detection in Bahiagrass [J]. Grass and forage science, 2022, 78(1): 214-223.
- [20] 刘颖, 雷研博, 范九伦, 等. 基于小样本学习的图像分类技术综述 [J]. 自动化学报, 2021, 47(2): 297-315.
LIU Y, LEI Y B, FAN J L, et al. Survey on image classification technology based on small sample learning [J]. Acta automatica Sinica, 2021, 47(2): 297-315.
- [21] 陈伟文, 邝祝芳, 王忠伟. 基于卷积神经网络的种苗病害识别方法 [J]. 中南林业科技大学学报, 2022, 42(7): 35-43.
CHEN W W, KUANG Z F, WANG Z W. Method of seed disease recognition based on convolutional neural network [J]. Journal of central south university of forestry & technology, 2022, 42(7): 35-43.