

蒋东山, 刘金洋, 张浩森, 等. 基于 CNN 和 Transformer 的绿豆干旱胁迫识别模型[J]. 江苏农业学报, 2025, 41(1): 87-100.
doi:10.3969/j.issn.1000-4440.2025.01.011

基于 CNN 和 Transformer 的绿豆干旱胁迫识别模型

蒋东山^{1,2,3}, 刘金洋^{2,3}, 张浩森^{1,2}, 李士丛², 罗仔秋¹, 余骥远^{1,2}, 李洁^{1,2},
陈新², 袁星星^{2,4}, 高尚兵^{1,4}

(1. 淮阴工学院计算机与软件工程学院, 江苏 淮安 223003; 2. 江苏省农业科学院经济作物研究所, 江苏 南京 210014)

摘要: 为了解决传统绿豆干旱胁迫识别方法存在识别率低、时效性差的问题, 本研究建立了基于卷积神经网络(CNN)和转换器(Transformer)的绿豆干旱胁迫识别模型 Mungbean-droughtNet。该模型采用双分支结构, 利用全局特征提取模块(GFEM)分支和局部特征提取模块(LFEM)分支分别从输入图像提取局部特征和全局特征。最后利用多层感知器(MLP)模块将局部特征和全局特征进行融合, 实现分类。在实际数据分析中, 共采集 14 536 张干旱胁迫下的绿豆叶绿素荧光图像, 分为 HR、R、MR、S、HS 和对照 6 类。利用 Mungbean-droughtNet 模型对叶绿素荧光图像数据集进行分析, 结果表明, Mungbean-droughtNet 模型对测试集中叶绿素荧光图像的平均识别准确率为 95.57%, 平均精度为 98.18%, 平均召回率为 98.40%, 平均 F1 分数为 98.28%。和目前先进模型 EfficientNetV2 和 Swin Transformer 相比, Mungbean-droughtNet 模型准确率分别提高了 3.56 个百分点和 2.62 个百分点, 表现出更强的鲁棒性和更好的识别效果。本研究结果为绿豆干旱胁迫研究和耐旱基因挖掘提供了基础。

关键词: 绿豆; 干旱胁迫; 卷积神经网络; 转换器; 图像识别; 叶绿素荧光图像

中图分类号: S522 **文献标识码:** A **文章编号:** 1000-4440(2025)01-0087-14

Drought stress recognition model of mung bean based on CNN and Transformer

JIANG Dongshan^{1,2,3}, LIU Jinyang^{2,3}, ZHANG Haomiao^{1,2}, LI Shicong², LUO Zaiqiu¹, YU Jiyuan^{1,2},
LI Jie^{1,2}, CHEN Xin², YUAN Xingxing^{2,4}, GAO Shangbing^{1,4}

(1. Faculty of Computer and Software Engineering, Huaiyin Institute of Technology, Huai'an 223003, China; 2. Institute of Economic Crops, Jiangsu Academy of Agricultural Sciences, Nanjing 210014, China)

Abstract: To address the issues of low recognition rate and poor timeliness in traditional methods for identifying drought stress in mung beans, this study established a mung bean drought stress recognition model named Mungbean-droughtNet based on convolutional neural network (CNN) and transformer. The model employed a dual-branch structure, utilized the global feature extraction module (GFEM) branch and the local feature extraction module (LFEM) branch to

extract local and global features from the input images, respectively. Finally, multilayer perceptron (MLP) module was used to fuse the local and global features for classification. In the actual data analysis, a total of 14 536 chlorophyll fluorescence images of mung beans under drought stress were collected and classified into six categories, including HR, R, MR, S, HS and the control group. The Mungbean-droughtNet model was applied to analyze the chlorophyll fluorescence image dataset, the re-

收稿日期: 2024-04-07

基金项目: 国家食用豆产业技术体系岗位科学家项目(CARS-09-G13); 江苏省种业揭榜挂帅项目[JBGS(2021)004]; 江苏省研究生实践创新计划项目(SJCX24_2146)

作者简介: 蒋东山(1998-), 男, 江苏南京人, 硕士, 研究方向为深度学习、计算机视觉。(E-mail) dongshanJiang2022@163.com。刘金洋为共同第一作者。

通讯作者: 高尚兵, (E-mail) 11060036@hyit.edu.cn; 袁星星, (E-mail) 20090049@jaas.ac.cn

sults showed that the Mungbean-droughtNet model achieved an average recognition accuracy of 95.57%, an average precision of 98.18%, an average recall ratio of 98.40%, and an average $F1$ -score of 98.28% for the chlorophyll fluorescence images in the test set. Compared with the current advanced models EfficientNetV2 and Swin Transformer, the accuracy of the Mungbean-droughtNet model increased by 3.56 percentage points and 2.62 percentage points, respectively, demonstrating stronger robustness and better recognition performance. This study provides a foundation for research on mung bean drought stress and the excavation of drought-resistant genes.

Key words: mung bean; drought stress; convolutional neural network; transformer; image recognition; chlorophyll fluorescence image

绿豆[*Vigna radiata* (L.) Wilczek]属豆科豇豆属一年生直立草本植物,在中国有2 000多年的栽培史,是重要的杂粮作物^[1]。绿豆富含维生素、矿物质和活性物质,具有抗菌、抗肿瘤、降血压和解毒等作用,属于药食同源作物^[2]。然而,在中国北方干旱半干旱区,绿豆栽培区常受到干旱的影响,干旱已成为绿豆生长过程中的主要非生物胁迫。研究结果表明,中国每年因干旱造成的损失约占各类自然灾害损失总额的70%,直接经济损失占国民生产总值的3%~6%^[3-4]。目前,传统的干旱诊断方法如土壤水分监测和农业气象预报等,主要基于对土壤和气象的间接监测,易出现准确性低和滞后问题^[5]。此类方法往往依赖专家经验,难以实现自动化和智能化,因而在大规模监测和应用中受到限制。叶绿素荧光参数作为植物响应环境变化的内在指标,被广泛用于植物逆境胁迫的研究,通过分析叶绿素荧光参数的变化评估植物干旱胁迫状态是一种可靠的方法^[6]。

为解决传统方法识别准确率低、时效性差等问题,国内外学者将机器学习技术引入生物和非生物胁迫识别中。岳焕然等^[7]提取了不同干旱胁迫状态的玉米图像的颜色和纹理特征,并利用BP神经网络对玉米干旱胁迫状态进行识别,研究结果表明,该模型对玉米干旱胁迫状态的识别准确率均超过90%。Naik等^[8]分别将10种机器学习方法用于大豆缺铁黄化病的识别,结果表明,模型的平均识别精度为96%。龙燕等^[9]结合狄利克雷分布(LDA)、支持向量机(SVM)和K近邻(KNN)算法,以及叶绿素荧光参数和荧光图像特征,构建番茄苗期干旱胁迫状态识别模型,结果表明其识别准确率可达97.8%。Zhou等^[10]将叶绿素荧光技术和支持向量机(SVM)、径向基函数(RBF)、BP神经网络等学习方法相结合,成功识别植物体内水分含量和氮素水平。

尽管机器学习算法在分析生物和非生物胁迫的研究中取得了显著成果,但其仍存在无法自动提取特

征及难以处理海量图像的问题^[11]。随着计算机视觉技术的发展,为解决图像特征自动提取和海量图像处理的难题,人们开始寻求精度更高、更自动化的图像识别技术用于干旱诊断。以卷积神经网络(CNN)为代表的深度学习技术,因其卓越的图像识别能力和分辨能力,已被广泛用于产量估算^[12]、病虫害检测^[13-15]、作物品种分类^[16]等多个领域。近年来,CNN在生物和非生物胁迫诊断中被广泛应用^[17]。赵奇慧等^[18]采集了共2 000张番茄叶片图像,利用Mask R-CNN进行叶片分割,结合DenseNet169网络对番茄干旱胁迫状态进行识别,研究结果表明,该模型在测试集上的识别准确率高达94.68%。利用AlexNet、GoogLeNet和InceptionV3模型对玉米、秋葵和大豆的干旱胁迫状况进行识别,研究结果表明,GoogLeNet模型的准确率最高^[19-20]。刘芳军等^[21]提出了一种基于改进ResNet18模型的胡麻干旱胁迫状态识别方法,该方法识别准确率高达98.67%,且能够满足在嵌入式设备上实时检测的要求。Xia等^[22]发现,在识别番茄光谱数据方面,多层感知器分类器(MLPC)算法和一对多分类器(ORC)算法的性能优于卷积神经网络算法。Kuo等^[23]提出了1D-ResGC-Net模型,其中包含残差全局上下文(ResGC)模块,用于处理番茄叶片的可见光和近红外光谱数据,从而实现了对番茄干旱胁迫的早期识别。

干旱胁迫会影响植物的光合作用,因此可以利用叶绿素荧光技术检测植物的光合作用,从而评估植物的干旱胁迫状态。研究结果表明,最大光量子效率(F_v/F_m)与植物的光合作用密切相关,是植物响应干旱胁迫的重要参数^[24-31]。Bresson等^[32]研究发现,在干旱胁迫的第14 d,转基因植株叶片与野生型植株叶片的 F_v/F_m 值差异显著。而且, F_v/F_m 参数还与植株在干旱条件下的生存率有关。梁欢等^[33]使用叶绿素荧光参数对不同品种的紫花苜蓿幼苗的抗旱性进行了比较,在109份紫花苜蓿中,筛

选出了 14 份抗旱性强且光合效率高的种质。

综上所述,深度学习技术结合叶绿素荧光图像能够准确反映叶片光合特征的时空异质性,从而有效鉴定绿豆的抗旱性,同时还能及时准确地识别出绿豆受到的干旱胁迫程度,为采取措施缓解旱情提供依据。目前,对绿豆的研究主要集中在病虫害防治及产量提升等方面^[34-36],而结合深度学习技术和叶绿素荧光图像鉴定绿豆干旱胁迫状态的研究较少。本研究拟以 230 份绿豆种质资源为试验材料,构建数据集,设计一种准确率高、时效性强的绿豆干旱胁迫识别网络模型,为监测绿豆生长发育情况和绿豆品种选育提供有效工具。

1 材料与方法

1.1 试验设计

试验所用绿豆种质资源来源于江苏省农业科学院经济作物研究所豆类研究室。2023 年 10 月至 11 月,在江苏省农业科学院经济作物研究所智能温室中对 230 份绿豆种质资源进行干旱胁迫处理。有研究表明,利用高含量的聚乙二醇 6000 ($\geq 20\%$) 模拟干旱胁迫,植物的光合作用会受到影响^[37-38]。具体步骤如下:选取无破损、大小一致、饱满的绿豆种子,用 20% 过氧化氢溶液对绿豆种子进行消毒;将种子播种于 10 cm × 10 cm 的塑料盆中,适量浇水并记录发芽情况;待水培至第 5 d,绿豆种子长出新叶,将 40 mL 20% 的聚乙二醇 6000 溶液加入培养液中,观察绿豆幼苗的生长情况。另设对照,在培养液

中加入 40 mL 水。在干旱胁迫处理的第 5 d,每份绿豆种质资源的干旱胁迫处理和对照各取 3 株幼苗,置于叶绿素荧光成像系统 (FluorCam) 的置物台上。通过 FluorCam7 软件进行叶绿素荧光图像的采集和数据分析。

1.2 数据预处理

利用 FluorCam 7.0 软件对采集到的荧光图像进行预处理,包括感兴趣区域选择 (ROI)、背景分割、阈值设定、图像裁剪与归一化处理等。通过感兴趣区域选择提取图像的关键特征,减少无关信息的干扰。为叶绿素荧光参数 (F_v/F_m) 设定 1 个阈值区间,保留处于区间内的像素点。将叶绿素荧光图像裁剪为 224 × 224 像素,并进行归一化处理^[39]。预处理后的图像数据集按照 8 : 1 : 1 的数量比例划分为训练集、验证集和测试集。

1.3 干旱胁迫等级划分

干旱胁迫对抗旱能力较强的绿豆品种的影响较小,抗旱能力较强的绿豆品种适应性和耐受力较强。最大光量子效率 (F_v/F_m) 可以间接评估绿豆对干旱胁迫的响应程度, F_v/F_m 值越小表示绿豆抗旱性越弱,干旱对植物的影响越大。通过分析绿豆幼苗的叶绿素荧光图片,可以鉴定绿豆的抗旱能力,从而确定绿豆受到的干旱胁迫等级,并筛选出抗旱的种质资源。本研究基于最大光化学效率 F_v/F_m 值,结合文献[40]中的分级方法,评估绿豆抗旱性,并进行相应的胁迫等级划分,具体分级标准如表 1 所示,不同抗旱性的叶绿素荧光图像如图 1 所示。

表 1 绿豆抗旱性和干旱胁迫等级


Table 1 Drought resistance and drought stress level of mung bean

最大光量子效率 (F_v/F_m)	抗旱性	干旱胁迫等级	叶片特征
>0.83	极强	无胁迫	叶片自然伸展,颜色翠绿或深绿
0.82~0.83	强	轻度	叶片边缘略有卷缩
0.79~0.81	中等	中度	叶片边缘卷起,叶面褶皱
0.70~0.78	弱	重度	叶片卷缩成筒状,叶片大面积干枯,发黄
<0.70	极弱	极度	极度干旱,叶片严重失水,植株枯死

1.4 数据增强

在深度学习中,增加样本数量能够提升模型效果,增强模型的泛化能力。因此,为了提高模型的泛化能力和鲁棒性,本研究采用数据增强技术^[41]对数据集进行扩充。数据增强技术包括平移和翻转、裁

剪和缩放、添加噪声点、添加遮罩、二值化^[42]。如表 2 所示,经过数据增强后的数据集包含 14 536 张图片,其中训练集有 11 630 张图片,验证集有 1 453 张图片,测试集有 1 453 张图片。数据增强后的叶绿素荧光图像如图 2 所示。



HR:抗旱性极强;R:抗旱性强;MR:抗旱性中等;S:抗旱性弱;HS:抗旱性极弱;CK:对照。

图 1 不同抗旱性绿豆的叶绿素荧光图像

Fig.1 Chlorophyll fluorescence images of mung beans with different drought resistance


表 2 数据集构成

Table 2 Composition of the dataset

类别	原始数据集构成			增强后的数据集构成		
	训练集	验证集	测试集	训练集	验证集	测试集
HR	124	16	16	874	109	109
HS	124	16	16	869	108	108
MR	424	53	53	2 969	371	371
CK	340	42	42	2 375	297	297
R	449	56	56	3 142	393	393
S	200	25	25	1 401	175	175
总计	1 661	208	208	1 1630	1 453	1 453

HR:抗旱性极强;R:抗旱性强;MR:抗旱性中等;S:抗旱性弱;HS:抗旱性极弱;CK:对照。


如图 3 所示,在原始数据集中,抗旱性极强 (HR)的绿豆图像有 156 张,经数据增强后,图像数量增加到1 092张;在原始数据集中,抗旱性强 (R)的绿豆图像有 561 张,经数据增强后,图像数量增加到3 928张;原始数据集中抗旱性中等 (MR)的绿豆图像有 530 张,经数据增强后,图像数量增加到 3 711张;在原始数据集中,抗旱性弱 (S)的绿豆图像有 250 张,经数据增强后,图像数量增加到1 751张图像;在原始数据集中,抗旱性极弱 (HS)的绿豆图像有 156 张,经数据增强后,图像数量增加到1 085 张图像;在原始数据集中,无干旱胁迫对照的绿豆图像有 424 张,经数据增强后,图像数量增加到2 969 张图像。



HR:抗旱性极强;R:抗旱性强;MR:抗旱性中等;S:抗旱性弱;HS:抗旱性极弱;CK:对照。

图 2 数据增强后的绿豆叶绿素荧光图像

Fig.2 Chlorophyll fluorescence images of mung beans after data augmentation



HR:抗旱性极强;R:抗旱性强;MR:抗旱性中等;S:抗旱性弱;HS:抗旱性极弱;CK:对照。

图 3 不同抗旱性绿豆叶绿素荧光图像在原始数据集和增强数据集分布

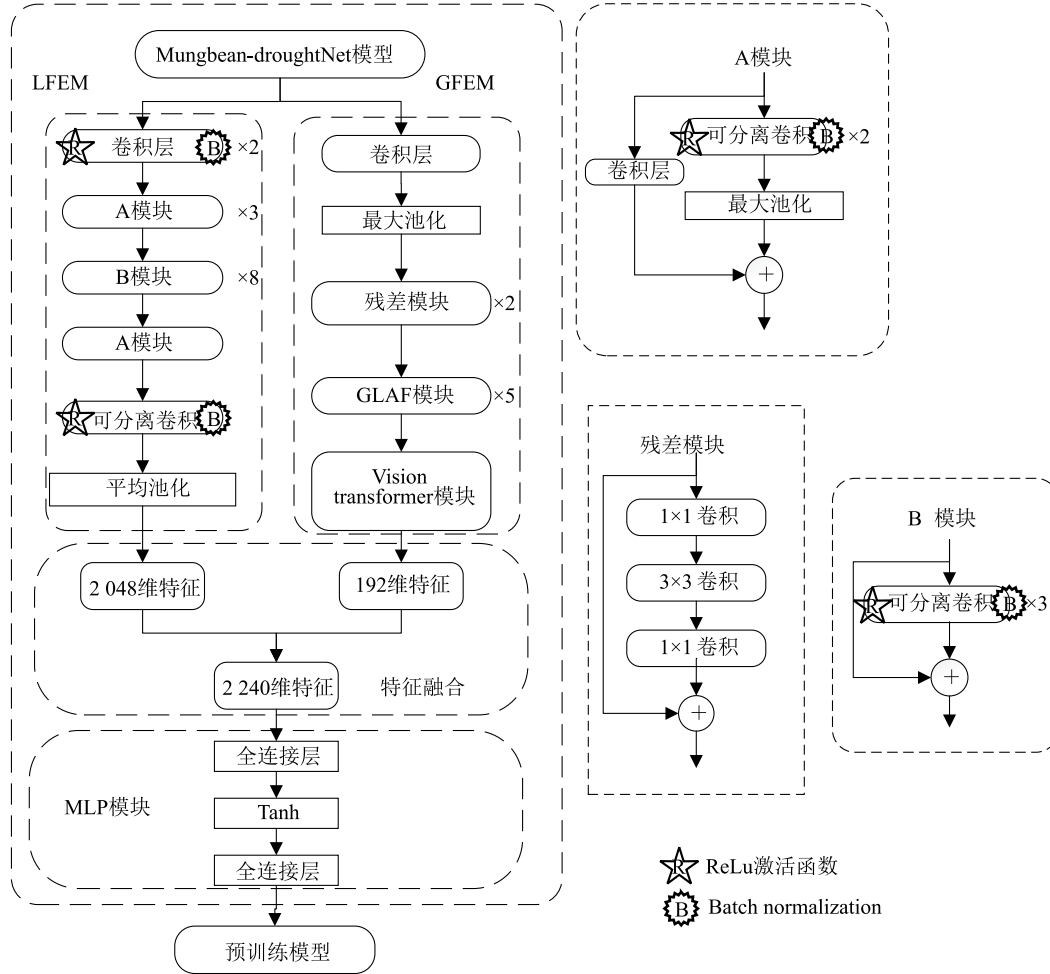
Fig.3 Distribution of chlorophyll fluorescence images of mung beans with different drought resistances in the original dataset and the augmented dataset

1.5 Mungbean-droughtNet 模型框架

采用 Mungbean-droughtNet 模型对数据增强后的叶绿素荧光图像进行特征提取和识别。Mungbean-droughtNet 模型结构如图 4 所示,该模型为双分支结构,包括全局特征提取模块 (Global feature extraction module,GFEM)分支和局部特征提取模块 (Local feature extraction module,LFEM)分支。LFEM 分支包括 A 模块、B 模块和可分离卷积等;GFEM 模块包括残差模块、全局到局部的裂变和聚合 (Global-

to-local aggregation and fission, GLAF) 模块和视觉转换器 (Vision transformer) 模块;MLP 模块包括 2 个全连接层和 1 个 Tanh 激活函数。上述 2 个分支分别

对同一图像进行全局特征提取和局部特征提取,从而更好地捕捉上下文信息。最后使用 MLP 模块进行特征融合并分类。



LFEM:局部特征提取模块;GFEM:全局特征提取模块;GLAF:局部和全局注意力特征模块;MLP:多层感知器模块;Tanh:激活函数;Vision transformer:视觉转换器模块;Batch normalization:归一化。

图4 Mungbean-droughtNet 模型结构

Fig.4 Structure of the Mungbean-droughtNet model

LFEM 分支包含 4 个 A 模块和 11 个 B 模块,主要用于叶绿素荧光图像的局部特征提取。A 模块的主要功能是降低特征图的空间维度,同时采用可分离卷积将普通卷积分解为深度卷积和逐点卷积,这样可以在保证特征提取能力的同时,显著减少模型的参数量。B 模块通过聚焦更多有用信息从而优化特征。LFEM 分支采用不同模块串联堆叠的方式,这种设计既能有效降低参数量,又保证了模型能够提取叶绿素荧光图像中的细微特征。

GFEM 分支主要由残差模块、GLAF 模块以及 Vi-

sion transformer 模块构成。初始卷积核对输入图像进行初步特征提取,并通过下采样降低特征图的维度。在 GFEM 中,共有 2 个残差模块,每个残差模块均由 2 个 1x1 卷积核和 1 个 3x3 的卷积核串联组成。在第 1 个残差模块中,第 1 层和第 2 层卷积核的数量均为 64 个,而第 3 层卷积核的数量为 256 个;第 2 个残差模块各层卷积核数量为第 1 个残差模块的 2 倍。引入 2 个残差模块有助于充分利用网络的深度,让模型能够学习更多复杂的叶绿素荧光图像特征,从而提高模型的性能。GLAF 模块通过整合不同通道的注意力特


征,增强了信息交互能力。经过 GLAF 模块整合后的注意力特征再通过 Vision transformer 模块进行处理,进一步提取全局特征。综上,GFEM 分支先利用残差模块增强网络深度,然后通过 GLAF 模块整合不同通道的注意力特征,最后利用 Vision transformer 模块进一步关注图像的关键特征,这种结构可以从时间和空间维度上增强模型交互能力,从而提升对叶绿素荧光图像的处理效果。

在分支的末端,将 GFEM 模块提取到的 192 维全局特征与 LFEM 模块提取到的 2 048 维局部特征进行融合,得到 2 240 维的完整特征向量。接着,利用包含 2 个全连接层和 1 个 Tanh 激活函数的 MLP 分类模块不断调整权重和阈值,使 Mungbean-droughtNet 模型能够从叶绿素荧光图像中提取更多差异性特征,从而提升网络性能。

1.5.1 残差连接 由于深度网络容易出现梯度消失和梯度爆炸等问题,因此采用残差连接来加深网络深度,提升模型的性能。残差连接的核心思想是在网络的某些层中,将输入信号直接连接到输出,从而实现跳跃连接。跳跃连接可以加速模型的训练,从而降低训练难度。其结构图如图 5 所示,计算公式如下:

$$X_{i+1} = X + F(X) \quad (1)$$

式中, X 表示前一层的输入信号, X_{i+1} 表示当前层的特征映射。



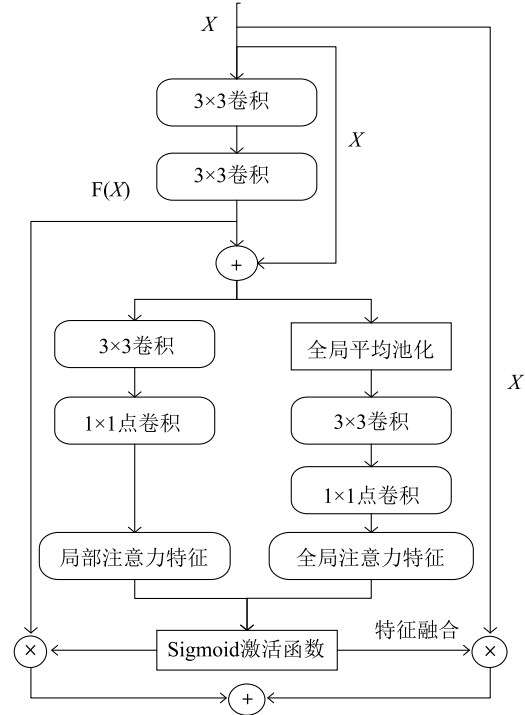
X :前一层的输入特征向量; $F(X)$:残差映射; ReLu :激活函数。

图 5 残差连接结构

Fig.5 Structure of the residual connection

1.5.2 全局到局部的裂变和聚合 (GLAF) 模块 如图 6 所示,在 GLAF 模块中,特征向量首先经过 2 个 3×3 的卷积层处理,得到低层的特征映射。然后采用双分支结构分别提取局部注意力特征和全局注意力特征。其中,全局平均池化层用于去除多余的空

间信息,保留全部的全局注意力特征,点卷积则用于降低特征图的维度。最后,引入非线性激活函数 Sigmoid,增强网络的表达能力。



X 表示前一层的输入特征向量, $F(X)$ 表示残差映射数。

图 6 全局和局部的注意力特征 (GLAF) 模块结构

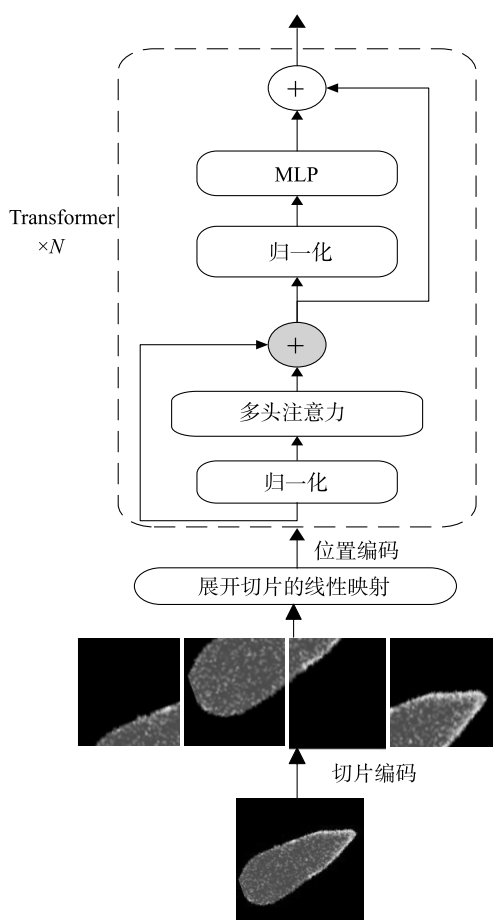
Fig. 6 Structure of the global and local attention feature (GLAF) module

1.5.3 视觉转换器模块 为了弥补卷积神经网络只能关注局部特征的不足,在 Mungbean-droughtNet 模型中引入视觉转换器 (Vision transformer) 模块对绿豆叶绿素荧光图像进行全局特征提取。如图 7 所示,Vision transformer 模块主要包括切片编码层、转换器 (Transformer) 模块以及多层感知器 (MLP) 模块。首先,切片编码层将输入图像分割成多个切片。然后,将展平后的多个切片经过特征映射,得到多个 token 编码,并与位置编码进行拼接,从而将局部特征信息转化为全局特征信息,输入到 Transformer 模块中。最后,将编码后的结果传入 Transformer 模块进行进一步处理。

2 结果与分析

2.1 试验环境

为了验证 Mungbean-droughtNet 模型对不同绿



Transformer:转换器;N:个数;MLP:多层感知器。

图7 视觉转换器模块结构

Fig.7 Structure of the vision transformer module

豆干旱胁迫等级图像的识别能力,本研究在 pytorch 2.0.1 框架上,使用制作的绿豆叶绿素荧光图像数据集进行试验。试验平台的软硬件信息如表 3 所示。

表3 试验平台的软硬件信息

Table 3 Hardware and software information of the experimental platform

软件名称	试验配置
CUDA	11.3
GPU	Quadro RTX 4000
CPU	Intel Xeon Silver 4210R
RAM	8 G DDR4
Python	3.6.15

2.2 试验参数与训练策略

根据绿豆在不同干旱胁迫下的荧光特征调整 Mungbean-droughtNet 模型的训练参数,以此确保试

验结论的可靠性和真实性。在试验过程中,使用 Adam 优化器更新网络的权重,最小化损失函数。选择交叉熵损失函数来衡量模型预测结果与真实标签之间的差异,学习率设置为 0.000 1,批量大小 (Batch size) 为 16,最大迭代次数为 300。

2.3 评价指标

本研究使用多个常用的评价指标来衡量 Mungbean-droughtNet 模型的识别性能,包括准确率 (Accuracy)、精度 (Precision)、召回率 (Recall) 和 F1 分数 (F1-score)。准确率为模型正确识别的样本数占总样本数的比例。精度为模型识别的正样本中,实际正样本的占比。召回率为实际正样本中,模型正确识别的正样本的占比。F1 分数综合考虑了精度和召回率的表现,其计算方法如公式(2)~(5)所示。

此外,为了更加直观地展示模型对各个类别图像的识别准确性,本研究采用了混淆矩阵。混淆矩阵的行表示预测的抗旱等级,列表示实际的抗旱等级,主对角线上的数值表示该模型对该类别图像的识别精度。主对角线上的数值越大,表明模型对该类别图像的识别精度越高。

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

$$F1-score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (5)$$

式(2)~式(5)中,TP 表示正样本被正确识别的数量;FP 表示负样本被错误识别为正样本的数量;FN 表示正样本被错误识别为负样本的数量;TN 表示负样本被正确识别的数量。

2.4 Mungbean-droughtNet 识别性能

在绿豆叶绿素荧光图像数据集上验证 Mungbean-droughtNet 模型的有效性和适应性。如表 4 所示,在验证集上,Mungbean-droughtNet 模型的平均精度为 97.60%,平均召回率为 96.58%,平均 F1 分数为 97.60%。如表 5 所示,在测试集上,Mungbean-droughtNet 模型的平均精度为 98.18%,平均召回率为 98.40%,平均 F1 分数为 98.28%,通过对比分析,可以发现 Mungbean-droughtNet 模型在验证集和测试集上的总体性能差异不大,表明 Mungbean-

droughtNet 具有良好的泛化性能。同时使用混淆矩阵对 Mungbean-droughtNet 模型在验证集上每种抗旱等级的识别结果进行可视化分析。如图 8 所示,混淆矩阵的主对角线值都达到了最大,且在抗旱性极弱(HS)和对照上的识别精度都达到了 100%,这表明 Mungbean-droughtNet 模型具有良好的识别性能。

Mungbean-droughtNet 模型的参数量为 107.04 M,计算复杂度为 9.27 GMac(Mac 表示乘积累加操作数)。训练集包含 11 630 张图片,经过 300 次迭代后,总训练时间为 17.5 h。测试集包含 1 453 张图片,总的测试时间为 24 s,平均每张图片的识别时间大约为 0.016 s。

表 4 Mungbean-droughtNet 模型对验证集中叶绿素荧光图像的识别性能

Table 4 Recognition performance of the Mungbean-droughtNet model for chlorophyll fluorescence images in the validation set

标签	类别	精度 (%)	召回率 (%)	F1 分数 (%)
0	HR	98.10	93.60	95.79
1	HS	100.00	98.10	99.04
2	MR	95.70	94.90	95.29
3	CK	100.00	100.00	100.00
4	R	94.10	97.50	95.77
5	S	97.70	95.40	99.70
	平均	97.60	96.58	97.60


HR:抗旱性极强;R:抗旱性强;MR:抗旱性中等;S:抗旱性弱;HS:抗旱性极弱;CK:对照。

表 5 Mungbean-droughtNet 模型对测试集中叶绿素荧光图像的识别性能

Table 5 Recognition performance of the Mungbean-droughtNet model for chlorophyll fluorescence images in the test set

标签	类别	精度 (%)	召回率 (%)	F1 分数 (%)
0	HR	94.60	97.20	95.88
1	HS	100.00	100.00	100.00
2	MR	97.60	97.60	97.60
3	CK	100.00	100.00	100.00
4	R	96.90	96.70	96.79
5	S	100.00	98.90	99.45
	平均	98.18	98.40	98.28

HR:抗旱性极强;R:抗旱性强;MR:抗旱性中等;S:抗旱性弱;HS:抗旱性极弱;CK:对照。



HR:抗旱性极强;R:抗旱性强;MR:抗旱性中等;S:抗旱性弱;HS:抗旱性极弱;CK:对照。

图 8 Mungbean-droughtNet 模型的混淆矩阵

Fig.8 Confusion matrix of the Mungbean-droughtNet model

2.5 Mungbean-droughtNet 与其他模型的性能比较

在相同数据集和试验参数的基础上,将 Mungbean-droughtNet 模型与基于 CNN 的模型和基于 Transformer 的模型进行比较,从而探索本研究提出的模型与现有模型在农业图像识别中的性能差异。

本研究选取的基于 CNN 的网络模型包含经典模型 ResNet50、ConvNext 以及轻量级模型 MobileNetV2、ShuffleNetV2 和 EfficientNetV2。如表 6 所示,本研究提出的 Mungbean-droughtNet 模型在验证集上的识别准确率最高,为 95.57%,分别比 ResNet50、ConvNext、MobileNetV2、ShuffleNetV2 以及 EfficientNetV2 高 1.11 个百分点、4.13 个百分点、1.35 个百分点、3.56 个百分点和 3.56 个百分点。Mungbean-droughtNet 模型的精度、召回率和 F1 分数均优于表 6 中的其他模型。

选取 4 个常用的基于 Transformer 的模型和 Mungbean-droughtNet 模型进行对比,选取的模型为 ViT、DeiT、MobileViT 和 Swin Transformer。如表 6 所示,Mungbean-droughtNet 模型的总体性能最佳。与基于 Transformer 的模型 Swin Transformer 相比,Mungbean-droughtNet 模型准确率提高了 2.62 个百分点,精度提高了 2.12 个百分点,召回率提高了 3.04 个百分点,F1 分数提高了 2.62 个百分点。试验结果证明了本研究提出方法的有效性和创新性。此外,本研究还分析了不同模型在训练过程中的准

确率和损失值曲线,如图 9 所示,性能排名第 2 的模型 EfficientNetV2 的准确率曲线和损失值曲线在 270 次迭代和 280 次迭代中逐渐收敛,排名第 3 的模型 ResNet50 的准确率曲线和损失值曲线在 280 次迭代和 260 次迭代中逐渐收敛。而 Mungbean-droughtNet

模型的准确率曲线和损失值曲线均在 250 次迭代中逐渐收敛。结果表明,与其他深度学习模型相比,Mungbean-droughtNet 模型对绿豆叶绿素荧光数据集的识别性能更好,收敛速度更快。

表 6 不同模型对验证集中叶绿素荧光图像的识别性能对比

Table 6 Comparison of the recognition performance of different models for chlorophyll fluorescence images in the validation set

模型	精度 (%)	召回率 (%)	F1 分数 (%)	准确率 (%)	训练损失值	验证集上最高准确率 (%)
ResNet50	96.81	96.15	96.43	94.46	0.036	96.48
MobileNetV2	95.68	96.43	96.00	94.22	0.055	96.13
ShuffleNetV2	93.85	93.10	93.40	92.01	0.079	93.65
EfficientNetV2	97.06	97.23	97.08	92.01	0.043	97.31
ConvNext	93.86	92.16	92.86	91.44	0.050	93.51
ViT	94.35	94.55	94.38	92.14	0.147	95.23
Deit	93.60	93.26	93.40	92.17	0.095	93.92
Swin Transformer	96.06	95.36	95.66	92.95	0.144	95.92
MobileViT	93.63	92.88	93.18	93.02	0.055	93.78
Mungbean-droughtNet	98.18	98.40	98.28	95.57	0.039	98.14




图 9 不同模型的损失值和准确率曲线

Fig.9 Loss and accuracy curves for different models

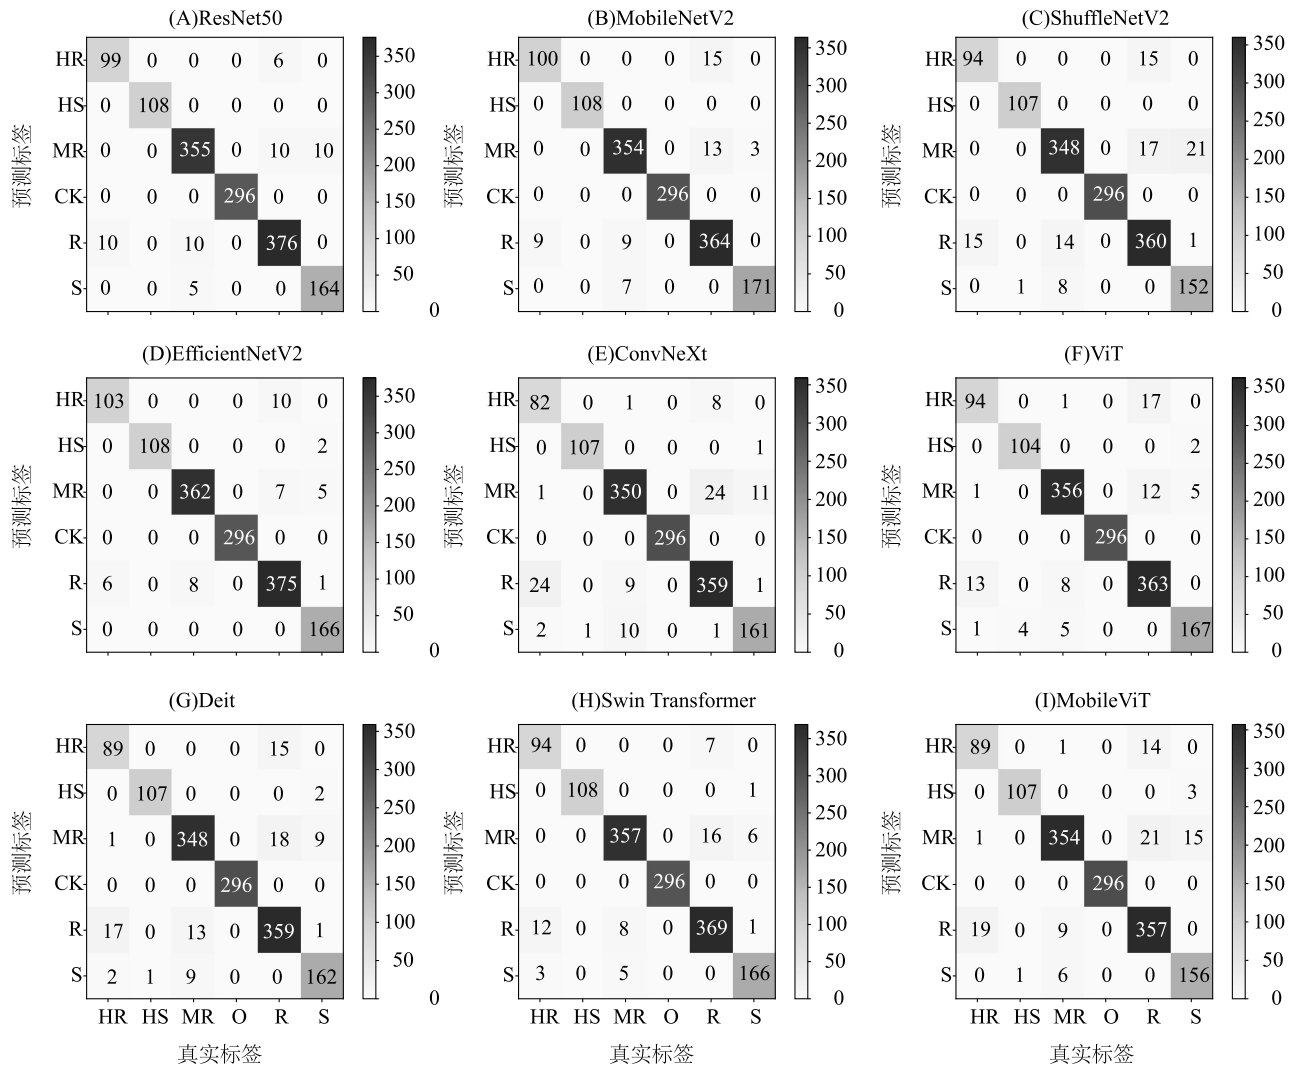
利用训练得到的最优的 9 个模型权重绘制混淆矩阵图。如图 10 所示,其中 ResNet50、MobileNetV2、EfficientNetV2 和 Swin Transformer 模型混淆矩阵的主对角线数值较高,表明 ResNet50、MobileNetV2、EfficientNetV2 和 Swin Transformer 对各类抗旱等级的识别性能均较好。将图 8 和图 10 进行对比,对于 HR、R、S、HS 类别,Mungbean-droughtNet 模型混淆矩阵主对角线上数值高于或等于其他模型,仅对于 MR 类别,Mungbean-droughtNet 模型混淆矩阵主对角线上数值低于 EfficientNetV2 模型。总体而言,Mungbean-droughtNet 模型对各类抗旱等级绿

豆的识别性能均优于其他模型。

为了增加模型预测的可信度,本研究在测试集的每类图像中各挑选了 1 张难以区分的图像用于测试,并利用经过预训练的 10 个模型权重对图像类别进行识别。每个模型的识别结果如图 11 所示,10 个模型对对照图像识别准确率均高达 100%。对 HR、R、MR、S、HS 类别图像进行识别,ResNet50、ShuffleNetV2、EfficientNetV2、ConvNext、ViT、Deit、Swin Transformer 以及 MobileViT 均有 2 个或以上的识别错误,其中 MobileNetV2 将真实标签为 MR 的类别错误识别为 S 类别。而 Mungbean-droughtNet 模

型对 HR、R、MR、S、HS 5 个类别的识别准确率分别高达 98.8%、97.9%、99.0%、99.8%、99.6%。由此

可见,本研究提出的 Mungbean-droughtNet 模型对绿豆抗旱等级的识别性能最佳。



HR:抗旱性极强;R:抗旱性强;MR:抗旱性中等;S:抗旱性弱;HS:抗旱性极弱;CK:对照。

图 10 不同模型的混淆矩阵

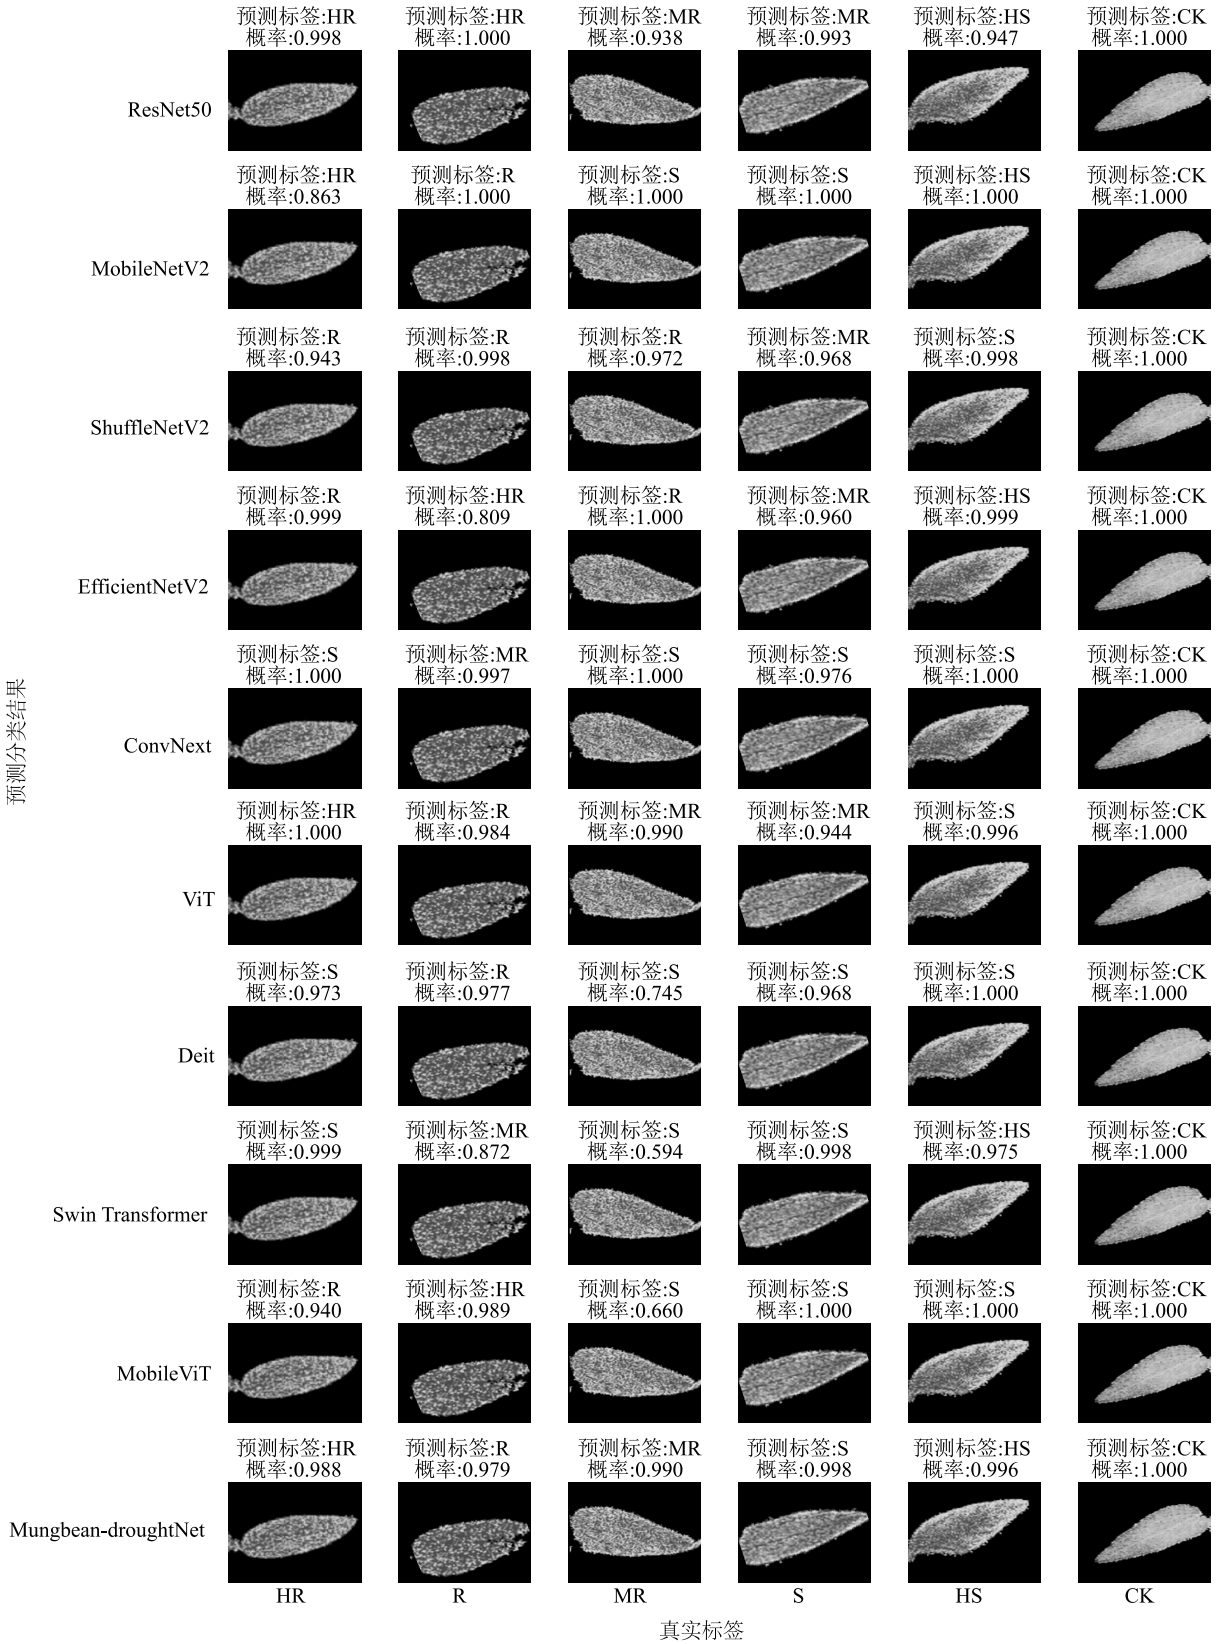
Fig.10 Confusion matrix diagrams of different models

2.6 消融试验

为了研究模块 (GLAF 模块、Transformer 模块) 数对模型性能的影响,在自建数据集上设计了一系列消融试验。此外,本研究还测试了不同卷积内核的大小对 A 模块性能的影响,从而选择最佳的卷积内核大小。

2.6.1 全局和局部的注意力特征 (GLAF) 模块数的消融试验 GLAF 模块用于提取初级特征图的局部注意力特征和全局注意力特征。过多的模块会产生冗余信息,不仅增加了模型的参数量和大小,还会增

加模型运行时间。而模块数量过少,则难以捕捉完整的特征信息,从而导致模型的准确率降低。在保持其他参数不变的情况下,将模型的 GLAF 模块数分别设置为 4、5、6,各训练了 300 次。如表 7 所示,当 GLAF 模块数为 5 时,模型的各项指标均最优。和 GLAF 模块数为 4 相比,GLAF 模块数为 5 的模型精度、召回率、F1 分数分别高了 1.31 个百分点、1.53 个百分点、1.43 个百分点。因此,将 GLAF 模块的数量设置为 5,虽然牺牲一定的参数量,但是获得了最佳模型性能。



HR:抗旱性极强;R:抗旱性强;MR:抗旱性中等;S:抗旱性弱;HS:抗旱性极弱;CK:对照。

图 11 不同模型对每个类别叶绿素荧光图像的识别结果

Fig.11 Recognition results of chlorophyll fluorescence images of each category by different models

表 7 不同全局和局部的注意力特征 (GLAF) 模块数的模型性能对比

Table 7 Performance comparison of models with different numbers of global and local attention feature (GLAF) modules

GLAF 模块数	精度 (%)	召回率 (%)	F1 分数 (%)	准确率 (%)	训练损失值
4	96.87	96.87	96.85	95.46	0.047
5	98.18	98.40	98.28	95.57	0.039
6	96.66	96.83	96.72	95.57	0.041

GLAF:全局和局部的注意力特征。

2.6.2 转换器 (Transformer) 模块数的消融试验 视觉转换器 (Vision transformer) 模块中每个转换器模块都包含自注意力机制,能够帮助模型捕捉叶绿素荧光图像中不同位置之间的长距离依赖关系。在实际特征分析中,通过堆叠多个 Transformer 模块,模型能够逐步整合更广泛的上下文信息。为了验证不同数量的 Transformer 对模型性能的影响,将 Transformer 模块数分别设置为 2、3、4,并对模型性能进行对比。如表 8 所示,当 Transformer 模块数为 2 时,模型的平均精度高达 98.18%,比 Transformer 模块数为 3、4 时分别高了 2.47 个百分点、0.63 个百分点。综上,Transformer 模块数为 2 时,模型各方面的性能最佳,且模型体积最小。

表 8 不同转换器数的模型性能对比

Table 8 Performance comparison of models with different numbers of transformer

Transformer 模块数	精度 (%)	召回率 (%)	F1 分数 (%)	准确率 (%)	训练损失值
2	98.18	98.40	98.28	95.57	0.039
3	95.71	96.73	96.18	95.62	0.048
4	97.55	98.56	97.98	95.83	0.043

Transformer:转换器。

2.6.3 卷积核大小的消融试验 卷积核的大小影响了卷积层的感受野和特征提取能力,可分离卷积是 A 模块的核心组成部分,为了探究可分离卷积的卷积核大小对 A 模块的影响,本研究将卷积核的大小分别设置为 3×3、5×5、7×7,并训练了 300 次。如表 9 所示,卷积核为 5×5、7×7 的模型的整体性能明显不如卷积核为 3×3 的模型,且卷积核为 5×5、7×7 的模型很难提取到更多有效的特征。由此,最终选择 3×3 的卷积核。

表 9 不同卷积核大小的模型性能对比

Table 9 Performance comparison of different convolution kernel sizes

卷积核大小	精度 (%)	召回率 (%)	F1 分数 (%)	准确率 (%)	训练损失值
3×3	98.18	98.40	98.28	95.57	0.039
5×5	96.67	96.72	96.65	95.11	0.048
7×7	97.22	97.53	97.33	95.02	0.053

3 讨论

为了解决传统绿豆干旱胁迫状态诊断方法具有的识别率低、及时性差等问题,本研究提出了一种准确率更高、鲁棒性更强的绿豆干旱胁迫识别模型 Mungbean-droughtNet。Mungbean-droughtNet 模型对绿豆干旱胁迫下的叶绿素荧光图像数据集具有较好的识别性能,识别准确率最高可达到 98.14%,平均精度为 98.18%,平均召回率为 98.40%,平均 F1 分数为 98.28%。相比于其他方法,Mungbean-droughtNet 模型识别精度最高,鲁棒性最强,训练损失值最低,能够准确识别 6 类干旱胁迫,具有广阔的应用前景。并且该模型可以在移动端和嵌入式设备上应用。

本研究仍存在需要改进之处,主要包括以下几个方面:(1)在参数量方面仍有优化空间,可以进一步优化为轻量级网络;(2)由于目前缺乏公开的作物干旱胁迫荧光数据集,Mungbean-droughtNet 模型只能在自建数据集上验证其性能,无法在其他数据集上验证其泛化能力。未来可以通过增加数据集中每个类别的图像数量,使数据集更加全面。在保证模型精度的同时,利用剪枝算法或者量化感知训练等方法对模型进行裁剪,减少模型体积,进一步提升网络速度。

参考文献:

- [1] 李茉莉,孙桂华,赵阳. 小杂粮作物的开发价值及战略意义[J]. 园艺与种苗,2005(2):123-124.
- [2] 郑卓杰. 中国食用豆类学[M]. 北京:中国农业出版社,1997.
- [3] 《气候变化国家评估报告》编写委员会. 气候变化国家评估报告[M]. 北京:科学出版社,2007.
- [4] 翟盘茂,王萃萃,李威. 极端降水事件变化的观测研究[J]. 气候变化研究进展,2007,3(3):144-148.
- [5] OCHSNER T E, COSH M H, CUENCA R H, et al. State of the art in large-scale soil moisture monitoring[J]. Soil Science Society

- of America Journal, 2013, 77(6):1888-1919.
- [6] 金伟婷, 刘文辉, 刘凯强, 等. 全生育期干旱胁迫对‘青燕 1 号’燕麦叶绿素荧光参数的影响[J]. 草业学报, 2022, 31(6): 112-126.
 - [7] 岳焕然, 李茂松, 安江勇. 基于颜色和纹理特征的玉米干旱识别[J]. 中国农学通报, 2018, 34(24): 18-28.
 - [8] NAIK H S, ZHANG J, LOFQUIST A, et al. A real-time phenotyping framework using machine learning for plant stress severity rating in soybean[J]. Plant Methods, 2017, 13: 1-12.
 - [9] 龙 燕, 马敏娟, 王英允, 等. 利用叶绿素荧光动力学参数识别苗期番茄干旱胁迫状态[J]. 农业工程学报, 2021, 37(11): 172-179.
 - [10] ZHOU C Y, LE J, HUA D X, et al. Imaging analysis of chlorophyll fluorescence induction for monitoring plant water and nitrogen treatments[J]. Measurement, 2018, 136(6): 1-9.
 - [11] AN J, LI W, LI M, et al. Identification and classification of maize drought stress using deep convolutional neural network[J]. Symmetry, 2019, 11(2): 256.
 - [12] XIE W, WEI S, ZHENG Z, et al. A cnn-based lightweight ensemble model for detecting defective carrots[J]. Biosystems Engineering, 2021, 208(2): 287-299.
 - [13] KAMILARIS A, PRENAFETA-BOLDÚ F X. Deep learning in agriculture: a survey[J]. Computers and Electronics in Agriculture, 2018, 147: 70-90.
 - [14] ZHANG X, XUN Y, CHEN Y. Automated identification of citrus diseases in orchards using deep learning[J]. Biosystems Engineering, 2022, 223: 249-258.
 - [15] ABADE A D S, PORTO L F, FERREIRA P A, et al. NemaNet: a convolutional neural network model for identification of soybean nematodes[J]. Biosystems Engineering, 2022, 213: 39-62.
 - [16] KOZOWSKI M, GÓRCECKI P, SZCZYPINSKI P M. Varietal classification of barley by convolutional neural networks[J]. Biosystems Engineering, 2019, 184: 155-165.
 - [17] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
 - [18] 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, 51(增刊 1): 340-347.
 - [19] OCHSNER T E, COSH M H, CUENCA R H, et al. State of the art in large-scale soil moisture monitoring[J]. Soil Science Society of America Journal, 2013, 77(6): 1888-1919.
 - [20] 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.
 - [21] 刘芳军, 李 玥, 武 凌, 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.
 - [22] XIA J, ZHANG W Y, ZHANG W X, et al. A cloud computing-based approach using the visible near-infrared spectrum to classify greenhouse tomato plants under water stress[J]. Computers and Electronics in Agriculture, 2021, 181: 105966.
 - [23] KUO C E, TU Y K, FANG S L, et al. Early detection of drought stress in tomato from spectroscopic data: a novel convolutional neural network with feature selection[J]. Chemometrics and Intelligent Laboratory Systems, 2023, 239: 104869.
 - [24] CHEN D J, NEUMANN K, FRIEDEL S, et al. Dissecting the phenotypic components of crop plant growth and drought responses based on high-throughput image analysis[J]. The Plant Cell, 2014, 26(12): 4636.
 - [25] KAUTZ B, NOGA G, HUNSCHE M. Sensing drought-and salinity-imposed stresses on tomato leaves by means of fluorescence techniques[J]. Plant Growth Regulation, 2014, 73(3): 279-288.
 - [26] MISHRA K B, IANNAcone R, PETROZZA A, et al. Engineered drought tolerance in tomato plants is reflected in chlorophyll fluorescence emission[J]. Plant Science, 2012, 182: 79-86.
 - [27] WANG Y, AN Y, YU J, et al. Different responses of photosystem II and antioxidants to drought stress in two contrasting populations of sour jujube from the Loess Plateau, China[J]. Ecological Research, 2016, 31(6): 761-775.
 - [28] GUO Y Y, YU H Y, KONG D S, et al. Effects of drought stress on growth and chlorophyll fluorescence of *Lycium ruthenicum* murr. seedlings[J]. Photosynthetica, 2016, 54(4): 524-531.
 - [29] LOTFI R, PESSARAKLI M, GHARAVI-KOUCHEBAGH P, et al. Physiological responses of brassica napus to fulvic acid under water stress: chlorophyll a fluorescence and antioxidant enzyme activity[J]. Crop Journal, 2015, 3(5): 434-439.
 - [30] SHARMA D K, ANDERSEN S B, OTTOSEN C O, et al. Wheat cultivars selected for high F_v/F_m under heat stress maintain high photosynthesis, total chlorophyll, stomatal conductance, transpiration and dry matter[J]. Physiologia Plantarum, 2015, 153(2): 284-298.
 - [31] HUMPLIK J F, LAZAR D, FURST T, et al. Automated integrative high-throughput phenotyping of plant shoots: a case study of the cold-tolerance of pea (*Pisum sativum* L.)[J]. Plant Methods, 2015, 11: 1-11.
 - [32] BRESSON J, VASSEUR F, DAUZAT M, et al. Interact to survive: phyllobacterium brassicacearum improves *Arabidopsis* tolerance to severe water deficit and growth recovery[J]. PLoS One, 2014, 9(9): e107607.
 - [33] 梁 欢, 韦 宝, 陈 静, 等. 基于叶绿素荧光参数的紫花苜蓿种质苗期抗旱性评价[J]. 草地学报, 2020, 28(1): 45-55.
 - [34] 余骥远, 高尚兵, 李 洁, 等. 基于 MS-PLNet 和高光谱图像的绿豆叶斑病病级分类[J]. 江苏农业科学, 2023, 51(6): 178-186.
 - [35] 李 莉, 万正煌, 陈宏伟, 等. 不同群体密度对绿豆农艺性状和产量的影响[J]. 农业科学与技术, 2010, 11(7): 62-65.
 - [36] 王小英, 王 孟, 王 斌, 等. 不同氮肥用量对绿豆主要农艺性状及产量的影响[J]. 中国农学通报, 2020, 36(17): 95-98.
 - [37] 冯 蕊, 周 琪, 吴令上, 等. PEG6000 模拟干旱胁迫对铁皮石斛幼苗生理和叶绿素荧光特性的影响[J]. 浙江农林大学学报, 2024, 41(1): 132-144.

- [38] 浦 婵,董文渊,张孟楠,等. 聚乙二醇 6000 模拟干旱胁迫及复水对黄竹幼苗抗性生理特性的影响[J]. 东北林业大学学报,2018,46(8):31-37.
- [39] 姚松林. 基于卷积神经网络的荔枝病虫害图像识别技术研究[J]. 电脑编程技巧与维护,2023,12:133-135.
- [40] 李 静,徐其江. 干旱胁迫对绿豆农艺性状及产量的影响研究[J]. 新疆农垦科技,2017,40(7):8-11.
- [41] 冯晓硕,沈 樾,王冬琦. 基于图像的数据增强方法发展现状综述[J]. 计算机科学与应用,2021,11(2):13.
- [42] 温艳兰,陈友鹏,王克强,等. 基于机器视觉的病虫害检测综述[J]. 中国粮油学报,2022,37(10):271-279.

(责任编辑:成纾寒)