doi:10.6041/j.issn.1000-1298.2025.07.048

基于深度特征局部重采样融合的多种类水稻种子识别

张长胜[1]　李得恺[1]　杨忠义[2]　王　蒙[1]　张付杰[3]　张庭源[1]

(1.昆明理工大学信息工程与自动化学院,昆明 650500;
2.云南省农业科学院生物技术与种质资源研究所,昆明 650205;
3.昆明理工大学现代农业工程学院,昆明 650500)

摘要:针对多种类水稻种子识别过程中,形态特征较多、分类难度较大的问题,本文提出了一种基于深度特征局部重采样融合(Depth feature local resampling fusion,DFLRF)的分类网络,对 36 种水稻种子进行分类识别。首先,该方法使用 ConvNeXt 作为骨干网络提取水稻种子特征;其次,采用特征强化注意力模块(Feature intensification attention module,FIAM)构造全局特征采集分支,使用多通道卷积局部重采样模块(Multi-channel convolutional local resampling module,MCLRM)和 FIAM 构建局部特征采集分支;最后,将输出的全局特征和局部特征进行融合,在 CosFace 损失约束下准确识别出具有近似特征的不同种类水稻种子。本研究使用自采数据集,实验得出,新模型 ConvNeXt-DFLRF 总体准确率达到 86.90%,较基础模型提高 5.88 个百分点,与 InceptionResNetV2 和 EfficientNetV2 等主流模型相比,总体识别准确率提升 2.92~8.80 个百分点,整体识别效果最优。本文所提出模型能够有效地对 36 种水稻种子进行分类,为多种类水稻种子分类识别的研究提供了一种新颖且有效的方法。

关键词:水稻种子分类;多种类;深度特征;局部重采样;特征融合

中图分类号:TP391.4　　**文献标识码**:A　　**文章编号**:1000-1298(2025)07-0522-10　　**OSID**:

Multi-type Rice Seed Recognition Based on Local Resampling Fusion of Deep Features

ZHANG Changsheng[1]　LI Dekai[1]　YANG Zhongyi[2]　WANG Meng[1]　ZHANG Fujie[3]　ZHANG Tingyuan[1]

(1. *Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming* 650500, *China*
2. *Biotechnology and Germplasm Resources Institute, Yunnan Academy of Agricultural Sciences, Kunming* 650205, *China*
3. *Faculty of Modern Agriculture Engineering, Kunming University of Science and Technology, Kunming* 650500, *China*)

Abstract: In the process of using rice seeds, it was essential to classify them, but this problem was highly challenging because rice seeds have similar visual appearance. To address the challenges associated with recognizing multiple rice seed varieties, specifically the abundance of morphological features and the high classification complexity, a classification network based on depth feature local resampling fusion (DFLRF) was proposed to classify and identify 36 types of rice seeds. ConvNeXt was adopted as the backbone network to extract feature representations of the seeds. Subsequently, a global feature extraction branch was constructed by using the feature intensification attention module (FIAM), while the local feature extraction branch was built by using both the multi-channel convolutional local resampling module (MCLRM) and FIAM. The global and local features were then fused, and under the supervision of the CosFace loss, rice seed varieties with highly similar visual characteristics were accurately identified. A self-collected dataset was utilized. Experimental results demonstrated that the proposed ConvNeXt-DFLRF model achieved an overall accuracy of 86.90%, marking a 5.88 percentage points improvement over the baseline model. When compared with mainstream architectures such as InceptionResNetV2 and EfficientNetV2, the proposed model exhibited improvements ranging from 2.92 to 8.8 percentage points, achieving the highest recognition performance among the tested methods. These findings confirmed that the proposed model was effective in classifying 36 rice seed varieties and provided a novel and efficient solution for multi-type rice seed classification and recognition tasks.

Key words: rice seed classification; multi-type; deep feature; local resampling; feature fusion

收稿日期:2024-04-17　修回日期:2024-05-07

基金项目:国家自然科学基金项目(62062048)和云南省科技计划项目(202201AT070113)

作者简介:张长胜(1970—),男,副教授,主要从事复杂工业过程建模和计算机图像处理等研究,E-mail:122832170@qq.com

0　引言

水稻是继小麦和玉米之后第三大种植作物[1]，世界上一半以上的人口对水稻产品有消费需求[2]，其对全世界特别是亚洲地区人民的生存具有举足轻重的意义。

从各种农业观点来看，在使用水稻种子的过程中，对其分类必不可少，但因为水稻种子具有相似的视觉外观导致该问题具有较高的挑战性。现有的水稻种子分类方法主要有基于荧光扫描的鉴定方法、化学鉴定方法、电泳鉴定方法和形态学方法[3]等；荧光扫描、化学鉴定等方法成本较高，并且涉及专业操作和分析问题，农民不容易获得该技术；而形态学方法，由于人在识别物体时的决定是不一致、主观且缓慢的，即使是具有较多经验的相关领域专家也会不可避免地出现误判。且在市场交易过程中，往往会有以次充好的情况，损害农民的利益，影响粮食生产[4]。因此，开发非破坏性、经济高效、易于获取且快速准确分类水稻种子的技术非常必要。

随着机器学习的发展，计算机视觉技术为自动化识别水稻种子提供了一种无损的替代方法；它是一种非破坏性、经济高效[5]且快速准确的技术，与传统人工方法相比，只需要提取水稻种子形状、颜色、稃毛、尺寸和纹理等特征[6]在内的数据便可指导网络进行分类。

目前已有较多学者采用统计机器学习方法、深度学习模型（或单独采用，或结合投票法等），使用常规二维成像[7-14]、表面三维点云数据[15-16]（与二维图像相比，水稻种子三维信息能够更全面准确地展示水稻种子外观特征）和高光谱成像[17-20]（与图像信息相比，高光谱成像系统可以同时获取水稻种子空间和光谱互补信息）等不同维度的数据集，对水稻种子分类识别进行了单一模态下或多模态融合的研究。

但目前深度学习用于水稻种子分类识别领域的研究相对较少，已发表的文献中几乎没有研究超过 14 个水稻品种，且水稻品种之间的特征十分近似，种内水稻种子之间特征也存在一定区别，增加了多种类水稻种子分类识别难度。使用水稻分类相关研究中提到的深度学习网络（如 ResNet[21]、VGG16[22]、InceptionResNetV2[23]等）对本文水稻种子数据集进行实验后得到的结果不理想，而相较于二维图像，结合高光谱成像和 3D 点云数据的研究成本相对较高。

为解决上述问题，本文提出一种基于深度特征局部重采样融合（Depth feature local resampling fusion，DFLRF）的水稻种子分类网络，使用 ConvNeXt[24]作为骨干网络提取特征，去除其全局平均池化层及以后结构，使用多通道卷积局部重采样模块（Multi-channel convolutional local resampling module，MCLRM）和特征强化注意力模块（Feature intensification attention module，FIAM）构造全新的局部特征和全局特征采集分支，将输出的局部特征和全局特征进行融合，在 CosFace[25]损失约束下，训练和学习水稻种子图像，能够准确地识别出具有近似特征的不同种类水稻种子。

1　数据集

1.1　数据集准备

本文共使用 36 种中国境内的水稻种子，既包含市面已推广品种（如川种优 6099、荷优五香、丽晶优 211、太和香糯、袁糯优 126 等，共 11 种），也包含从中国某农业研究院收集的品种，为方便辨识，对其使用标号进行命名（如 D16、D33、D245、D525、X966 等，共 25 种）。各类水稻种子如图 1 所示。

使用乐越高清工业电子显微镜（图 2）采集水稻种子数据集。具体操作简述如下：首先固定好工业电子显微镜，随后将黑色亚克力板放置在其金属底座即操作台上，并在黑色亚克力板上方放置水稻种子，调整好焦距后即可进行拍摄，输出图像格式为 JPG，尺寸为 1 280 像素 ×720 像素。

在拍摄过程中，为模拟日常水稻交易和农业科研院所的实验环境，采取使水稻种子暴露在环境光下的拍摄方式，并使用工业电子显微镜提供的 LED 补光灯和外配补光灯进行补光，采集含有干扰（如划痕、种子霉变、灰尘等）和无干扰两类图像（图 3）。并为保证自采数据集的真实性和可靠性，由农业科研院所的相关专家对采集后的水稻种子数据集进行了多次筛选，尽可能保证数据集的可靠性和降低人为原因造成的误差。

1.2　数据集构建和图像预处理

本研究的重难点主要在于类内种子特征的多样性和类间种子特征的相似性；为了能够有效解决上述问题，确保实验结果的准确性和有效性，并希望能够在相对少量数据集的条件下就能达到相对较好的效果，本文为每种水稻种子采集尽可能多的覆盖其几乎所有外观特征的图像样本。最终，共采集水稻种子图像 11 880 幅，其中，每个水稻种类分别采集 330 幅；并按照比例 8∶1∶2 划分训练集、验证集和测试集，即训练集、验证集和测试集分别为 8 640、1 080、2 160 幅图像，每类水稻种子分别为 240、30、



图 1 各类水稻种子图示

Fig. 1 Illustration of various types of rice seeds

60 幅图像。

为了防止出现过拟合,在网络训练过程中,对训练集图像采用数据增强技术,增加训练数据的多样性和样本量:在训练集图像载入网络后,对每幅图像采取随机翻转、剪切等操作,使模型暴露在更大范围的图像变化中,减少训练特定样本的机会。

2 研究方法

水稻种子分类研究为细粒度图像分类问题[26],由于不同种类的水稻种子仅在形状、稃毛、颜色、尺寸和纹理等外观特征方面存在细微差异,识别种类增多到 36 种后,采用传统的图像识别网络(如 ResNet、VGG16、InceptionResNetV2 等)识别效果不



图 2　乐越高清工业电子显微镜

Fig. 2　Leyue HD industrial electron microscope

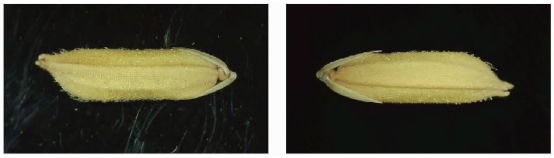

图 3　含有干扰和无干扰图像图示

Fig. 3　Illustration of images with and without interference

佳，该类问题类内方差大、类间方差小，现阶段是一项极具挑战的任务[27]。

为解决该问题，设计了一种基于深度特征局部重采样融合的分类方法。其中，ConvNeXt 作为主干网络提取图像特征，并将其第 3 个和第 4 个 Block 的输出分别作为局部特征处理分支和全局特征处理分支的输入，在局部分支和全局分支中进一步处理，最后将 2 个分支的输出进行融合，在 CosFace 损失的约束下进行分类。此外，在网络全局分支和局部分支中均采用特征强化注意力模块（FIAM），并在局部分支中融入多通道卷积局部重采样模块（MCLRM）。网络整体结构如图 4 所示，图中，X_i 表示输入种子图像，F_{global} 表示全局特征，F_{local} 表示局部特征；ConvNeXt Block 如图 5 所示，图中，H、W、D 分别表示特征高、宽和通道数量。

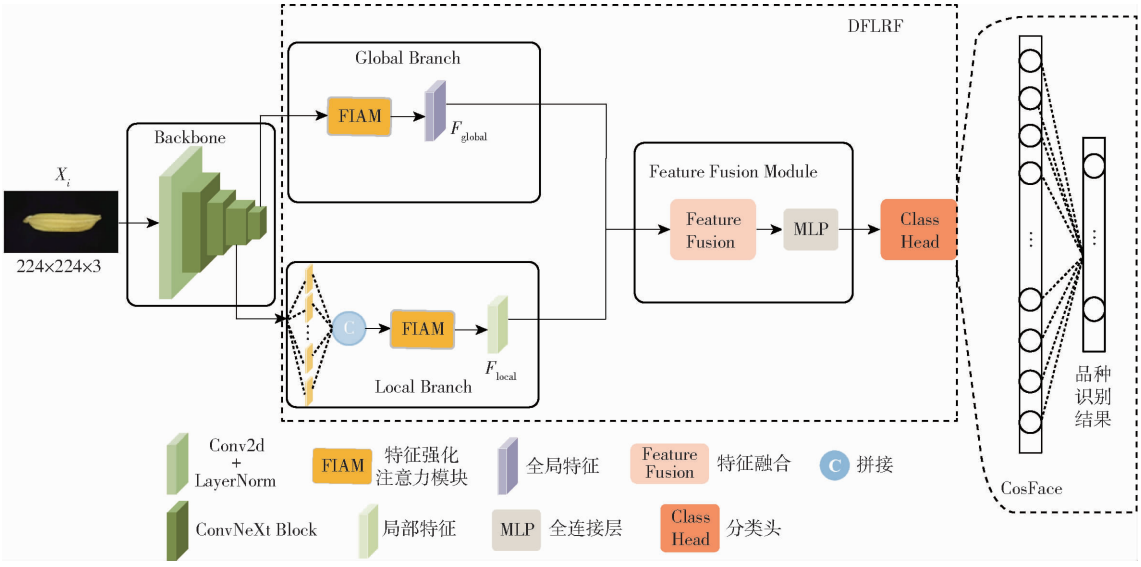

图 4　网络整体结构图

Fig. 4　Overall network structure diagram

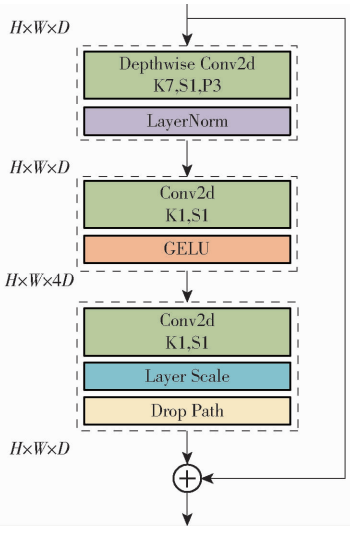

图 5　ConvNeXt Block

Fig. 5　ConvNeXt Block

2.1　全局特征处理分支

全局特征处理分支主要由特征强化注意力模块和自适应平均池化层组成，负责处理主干网络第 4 个 Block 输出的深度特征。

在采集水稻种子数据集时，为模拟日常交易和农业科研院所的实验环境，采集了含有干扰和无干扰的两类图像，其中有干扰的图像中存在划痕、灰尘和种子霉变等干扰项，这些干扰项会对水稻种子的正确分类识别产生负面影响。为使模型识别水稻种子时将更多的注意力聚焦到对识别起关键作用的特征上，在全局分支和局部分支中引入特征强化注意力模块，如图 6 所示。

为了进一步强化每个特征点的重要性，更为了避免在浅层引入该模块时导致过度关注非必要的特

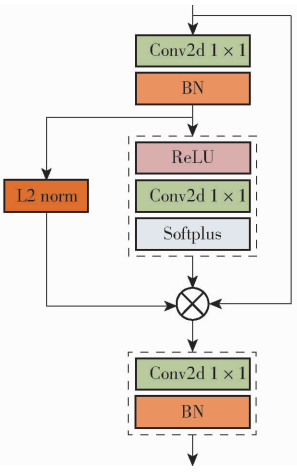

图 6 特征强化注意力模块

Fig. 6 Feature intensification attention module

征,对模型性能造成不利影响,选择在模型输出深度特征后再引入特征强化注意力模块。特征强化注意力模块将输入首先通过 1×1 卷积层和 BN 层进行特征提取和规范化处理,再通过 1×1 卷积层和 Softplus 操作生成权重矩阵;并将 BN 层的输出通过另一分支采用 L2 范数归一化操作,捕捉数据中更加普遍和稳定的特征,提高模型在新数据上的表现能力;最后将主次分支输出与原始输入相乘,再次通过 1×1卷积层和 BN 层规范化处理后输出。其中,对于一个 n 维向量 $\boldsymbol{v}=(x_1,x_2,\cdots,x_n)$,其 L2 范数定义为

$$\|\boldsymbol{v}\|_2=\sqrt{x_1^2+x_2^2+\cdots+x_n^2} \tag{1}$$

L2 范数归一化操作后,得到归一化向量 $\boldsymbol{v}'$可表示为

$$\boldsymbol{v}'=\left(\frac{x_1}{\|\boldsymbol{v}\|_2},\frac{x_2}{\|\boldsymbol{v}\|_2},\cdots,\frac{x_n}{\|\boldsymbol{v}\|_2}\right) \tag{2}$$

2.2 局部特征处理分支

局部特征处理分支主要由多通道卷积局部重采样模块(MCLRM)和特征强化注意力模块(FIAM)组成,负责处理主干网络第 3 个 Block 输出的深度特征。其整体结构如图 7 所示。

经典的图像识别网络仅靠全局的单一特征作为支撑,网络模型不足以提取到足够的细粒度特征来分类水稻种子,导致识别效果不佳,因此本文提出提取局部特征和全局特征进行融合,强化模型的表达能力。为了更加充分地提取深度局部特征,将主干网络第 3 个 Block 的输出传递给多通道卷积局部重采样模块(图 8)进一步提取和处理深度局部特征。具体来说,首先将输入分别通过 5 个卷积模块进行特征提取,使用 1×1、3×3 大小的卷积核,提取不同感受野大小的特征后使用 Concate 拼接,再通过 1×1 卷积层减少特征维度后输出。感受野计算式为

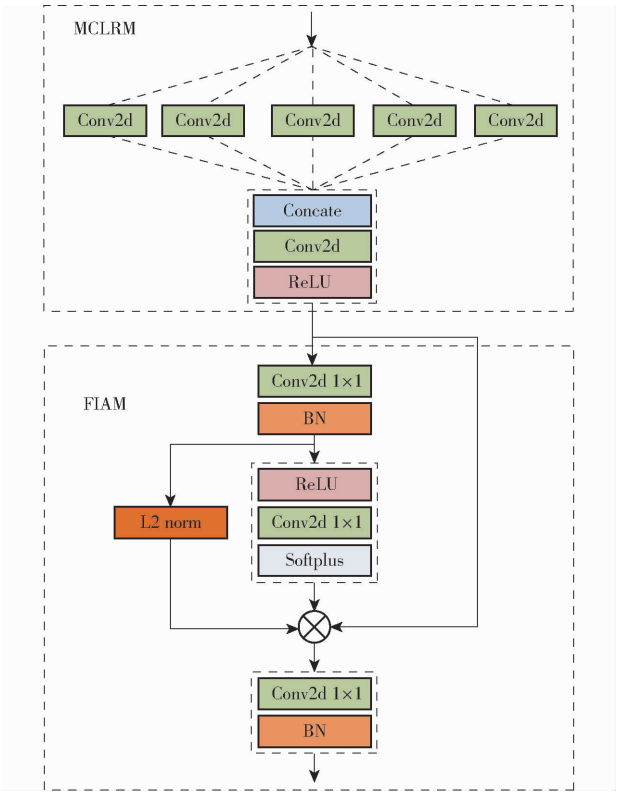

图 7 局部特征处理分支结构图

Fig. 7 Local features deal with branching structure diagram

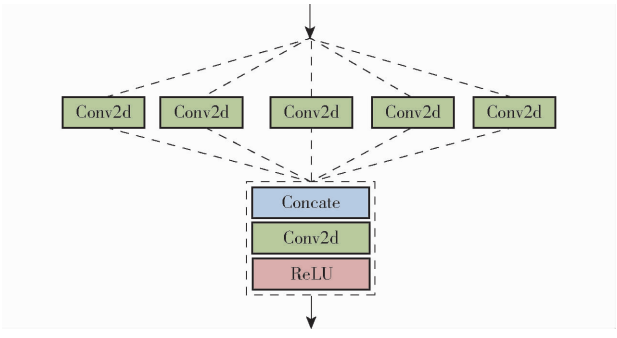

图 8 多通道卷积局部重采样模块

Fig. 8 Multi-channel convolutional local resampling module

$$F(i)=F(i-1)+(K_{\text{size}}-1)\prod_{j=1}^{i-1}d_{\text{stride}_j} \tag{3}$$

式中 $F(i)$——第 i 层感受野

K_{size}——卷积核尺寸

d_{stride_j}——第 j 层步幅

2.3 特征融合(Fusion)

为了强化特征输出,将输出的全局特征和局部特征相加后对输出的全局特征进行映射,再进行特征融合后将输出传递至全连接层。其中,特征相加、映射和融合过程公式为

$$f_{\text{Plus}}=f_G+f_L \tag{4}$$

$$f_{\text{Projection}}=\frac{f_{\text{Plus}}f_G}{|f_G|^2}f_G \tag{5}$$

$$f_{\text{Fusion}} = f_{\text{Plus}} - f_{\text{Projection}} \tag{6}$$

式中　f_G——全局特征　　f_L——局部特征

f_{Plus}——特征相加　　$f_{\text{Projection}}$——特征映射

f_{Fusion}——特征融合

2.4　CosFace 损失

为了更好地增大特征空间中类别之间的边界，最大化类间方差和最小化类内方差，采用 CosFace 损失来约束网络进行分类训练。CosFace 损失 L 公式为

$$L = \frac{1}{N}\sum_{i} -\ln\frac{e^{s(\cos(\theta_{y_i,i})-m)}}{e^{s(\cos(\theta_{y_i,i})-m)} + \sum_{j\neq y_i} e^{s\cos(\theta_j,i)}} \tag{7}$$

式中　s——缩放因子

m——边际距离(margin)

N——样本数量

3　实验与结果分析

3.1　实验设置

为了公平公正性，所有的模型均使用相同的微调参数进行训练。微调参数如表 1 所示。

表 1　微调参数

Tab. 1　Fine tuning parameters

参数	数值/类型
批大小	32
训练轮次	100
优化器	AdamW
学习率	0.000 5
L2 正则化系数	0.05
输入图像大小	224×224

3.2　评价指标

采用总体准确率(Overall accuracy，OA)、精确率(Precision，P)、召回率(Recall，R)和 F1 分数(F1-score，F)来评价模型性能。为了使实验数据能够有效地反映真实情况，网络模型均进行 5 次训练，上述评价指标取这 5 次训练的最优值。共使用 2 160 幅测试集图像来验证模型效果(每类各 60 幅)。

3.3　改进模型实验结果

在混淆矩阵中，主对角线上的值表示正确分类的实例数量，而非主对角线上的值表示错误分类的实例数量。提出模型混淆矩阵和基础模型混淆矩阵如图 9、10 所示。

由模型混淆矩阵可以看出，本文提出模型的分类识别效果相对基础模型有明显提升，水稻种子分

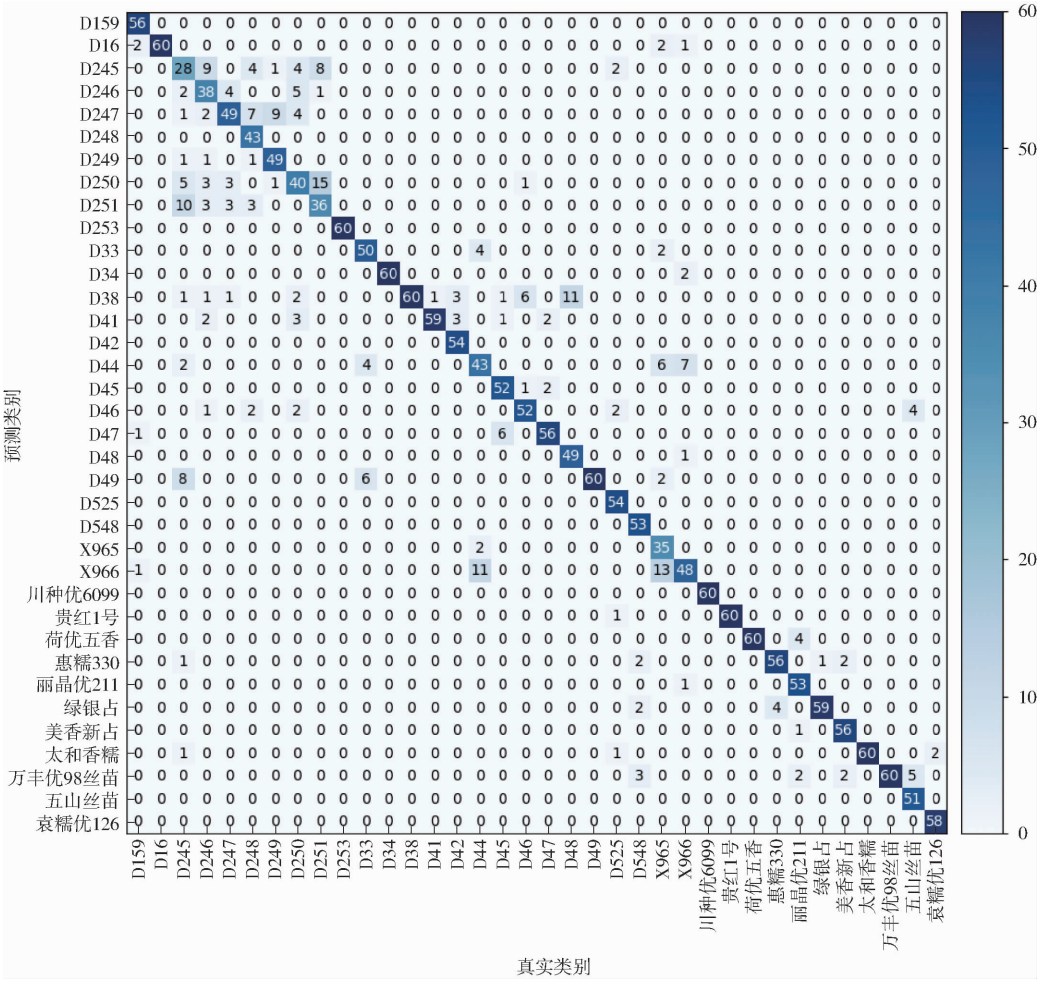

图 9　ConvNeXt－DFLRF 混淆矩阵

Fig. 9　ConvNeXt－DFLRF confusion matrix

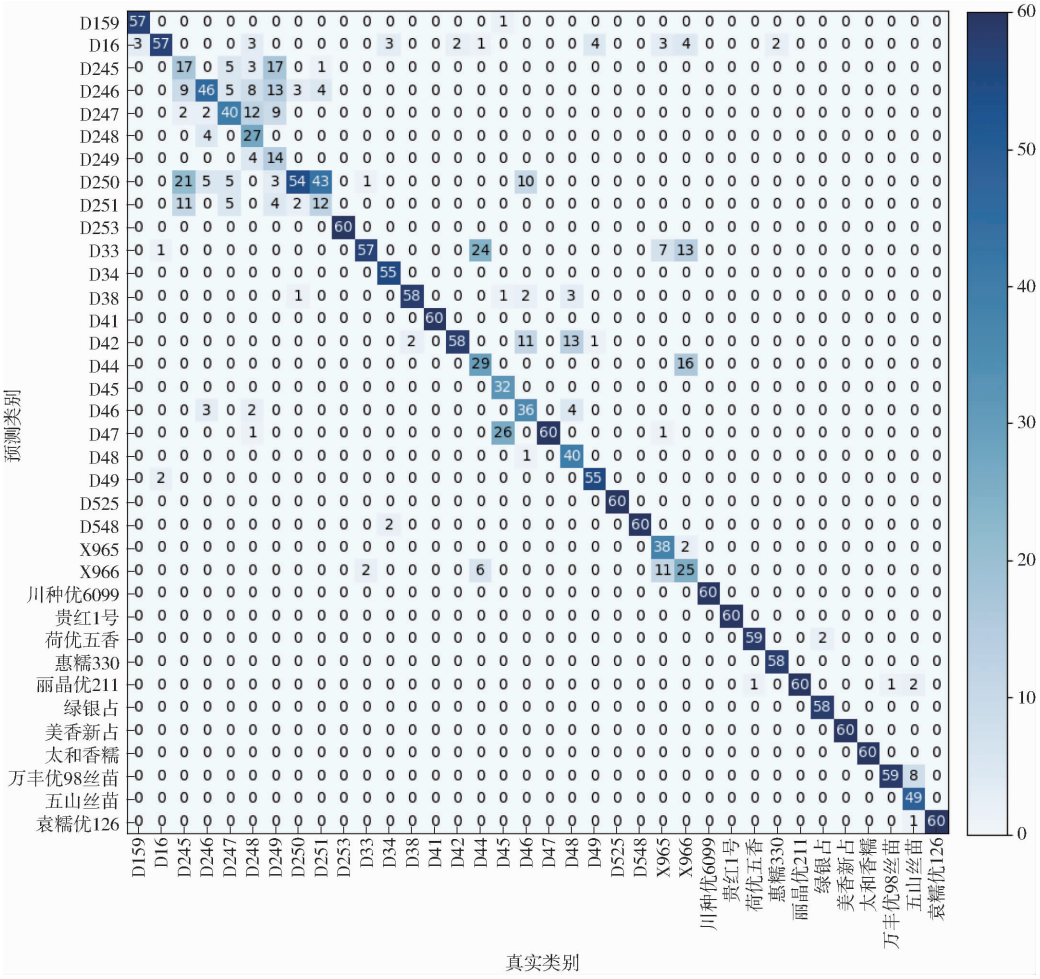

图 10 ConvNeXt 混淆矩阵

Fig. 10 ConvNeXt confusion matrix

类识别结果更加向混淆矩阵的主对角线靠齐;具体而言,品种 D245、D248、D249、D251、D44、D45、D46 和 X966 的召回率得到了明显提升。然而,相比基础模型,改进模型对某些水稻种类的识别率有所下降,相对较明显的有 D246 和 D250,从混淆矩阵中可以看出,新模型主要将 D246 错误识别为 D245,D250 错误识别为 D245、D246 和 D247,但数量较少。总体来说,新模型在整体性能上优于基础模型,能够很好地处理外观特征近似的水稻种子分类问题,且对具有相对较大特征区别的水稻种子分类能力基本不变,效果得到了较大提升。

3.4 消融实验

为验证采用深度特征局部重采样的有效性,对同一水稻种子数据集开展消融实验,进行对比分析。实验结果如表 2 所示。

从表 2 可以看出,相比于 ConvNeXt 模型,消融模型 1 总体准确率提升 0.32 个百分点,证明采用特征强化注意力模块的有效性,其中 ConvNeXt 模型和消融模型 1 热力图如图 11、12 所示,可以观察到,消融模型 1 相对于 ConvNeXt 模型对图像关注的范围相对更大,水稻种子的特征信息得到了更多的关注;

表 2 消融模型实验结果对比

Tab. 2 Comparison of experimental results of ablation models

模型/方法	FIAM	MCLRM	Fusion	CosFace	OA/%
ConvNeXt					81.02
消融模型 1	√				81.34
消融模型 2	√	√		√	85.74
ConvNeXt-DFLRF	√	√	√	√	86.90

注:“√”表示使用该方法。

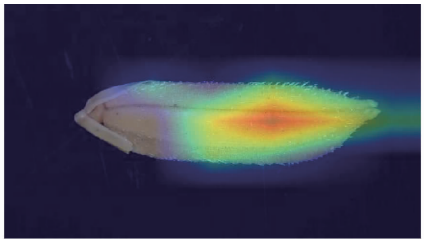

图 11 ConvNeXt 模型热力图

Fig. 11 ConvNeXt model heatmap

相比于消融模型 1,消融模型 2 总体准确率提升 4.40 个百分点,说明采用多通道卷积局部重采样模块和 CosFace 损失,使得模型更加聚焦细节特征和增加类间特征差距,使模型表达特征的能力进一步提升;相比于消融模型2,ConvNeXt-DFLRF模型总

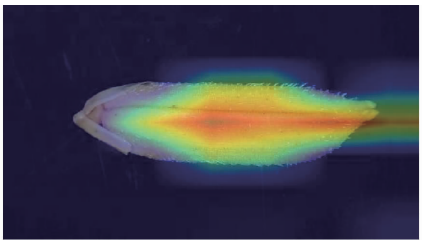

图 12　消融模型 1 热力图

Fig. 12　Ablation model 1 heatmap

体准确率提升 1.16 个百分点，得益于特征融合强化了全局特征和局部特征之间的联系，使模型整合和表达特征能力得到了增强。

3.5　不同模型实验结果对比

选用 InceptionResNetV2 和 EfficientNetV2[28] 等具有代表性的图像分类模型与提出模型和基础模型 ConvNeXt 进行水稻种子分类测试结果对比，各模型实验结果如表 3 所示。

表 3　各模型实验结果对比

Tab. 3　Comparison of experimental results of each model　%

水稻种子类别	ConvNeXt－DFLRF			ConvNeXt			InceptionResNetV2			EfficientNetV2		
	P	*R*	*F*	*P*	*R*	*F*	*P*	*R*	*F*	*P*	*R*	*F*
D159	100	93.3	96.5	98.3	95.0	96.6	100	98.3	99.1	96.6	93.3	94.9
D16	92.3	100	96.0	69.5	95.0	80.3	98.3	98.3	98.3	100	96.7	98.3
D245	50.0	46.7	48.3	39.5	28.3	33.0	33.3	26.7	29.6	56.8	35.0	43.3
D246	76.0	63.3	69.1	52.3	76.7	62.2	65.9	45.0	53.5	43.1	51.7	47.0
D247	68.1	81.7	74.3	61.5	66.7	64.0	35.8	73.3	48.1	51.1	75.0	60.8
D248	100	71.7	83.5	87.1	45.0	59.3	71.7	63.3	67.2	65.9	48.3	55.7
D249	94.2	81.7	87.5	77.8	23.3	35.9	100	35.0	51.9	78.6	55.0	64.7
D250	58.8	66.7	62.5	38.0	90.0	53.4	41.5	56.7	47.9	52.0	65.0	57.8
D251	65.5	60.0	62.6	35.3	20.0	25.5	47.6	33.3	39.2	41.5	36.7	39.0
D253	100	100	100	100	100	100	100	73.3	84.6	94.8	91.7	93.2
D33	89.3	83.3	86.2	55.9	95.0	70.4	73.5	60.0	66.1	71.1	98.3	82.5
D34	96.8	100	98.4	100	91.7	95.7	100	93.3	96.5	96.8	100	98.4
D38	69.0	100	81.7	89.2	96.7	92.8	74.6	83.3	78.7	94.8	91.7	93.2
D41	84.3	98.3	90.8	100	100	100	100	100	100	100	100	100
D42	100	90.0	94.7	68.2	96.7	80.0	78.9	93.3	85.5	86.8	98.3	92.2
D44	69.4	71.7	70.5	64.4	48.3	55.2	35.3	30.0	32.4	54.5	60.0	57.1
D45	94.5	86.7	90.4	100	53.3	69.5	81.5	73.3	77.2	88.9	66.7	76.2
D46	82.5	86.7	84.5	80.0	60.0	68.6	63.6	70.0	66.6	76.8	71.7	74.2
D47	88.9	93.3	91.0	68.2	100	81.1	76.1	85.0	80.3	74.7	93.3	83.0
D48	98.0	81.7	89.1	97.6	66.7	79.2	80.3	81.7	81.0	83.6	93.3	88.2
D49	78.9	100	88.2	96.5	91.7	94.0	96.3	86.7	91.2	94.8	91.7	93.2
D525	100	90.0	94.7	100	100	100	100	88.3	93.8	100	98.3	99.1
D548	100	88.3	93.8	96.8	100	98.4	96.4	90.0	93.1	98.4	100	99.2
X965	94.6	58.3	72.1	95.0	63.3	76.0	48.9	71.7	58.1	92.5	61.7	74.0
X966	65.8	80.0	72.2	56.8	41.7	48.1	46.3	41.7	43.9	55.2	53.3	54.2
川种优 6099	100	100	100	100	100	100	93.8	100	96.8	100	100	100
贵红 1 号	98.4	100	99.2	100	100	100	100	95.0	97.4	100	100	100
荷优五香	93.8	100	96.8	96.7	98.3	97.5	100	100	100	100	100	100
惠糯 330	90.3	93.3	91.8	100	96.7	98.3	96.6	95.0	95.8	100	98.3	99.1
丽晶优 211	98.1	88.3	92.9	93.8	100	96.8	100	96.7	98.3	100	100	100
绿银占	90.8	98.3	94.4	100	96.7	98.3	94.7	90.0	92.3	100	100	100
美香新占	98.2	93.3	95.7	100	100	100	96.8	100	98.4	100	100	100
太和香糯	93.8	100	96.8	100	100	100	77.9	100	87.6	100	100	100
万丰优 98 丝苗	83.3	100	90.9	88.1	98.3	92.9	92.2	98.3	95.2	98.4	100	99.2
五山丝苗	100	85.0	91.9	100	81.7	89.9	98.1	86.7	92.0	100	98.3	99.1
袁糯优 126	100	96.7	98.3	98.4	100	99.2	85.5	98.3	91.5	100	100	100
OA		86.90			81.02			78.10			83.98	

从表 3 可以看出，新模型 ConvNeXt－DFLRF 精确率、召回率和 F1 分数 3 个评价指标优于其他对比模型。具体来说：ConvNeXt－DFLRF 的 *P*、*R*、*F* 分别实现 19、19、18 个最优值，ConvNeXt 的 *P*、*R*、*F* 分别

实现 14、13、9 个最优值，InceptionResNetV2 的 P、R、F 分别实现 9、7、4 个最优值，EfficientNetV2 的 P、R、F 分别实现 16、17、16 个最优值；相对来说，新模型总体指标优于各对比模型。

可以观察到，新模型的评价指标最优值主要集中在种间特征近似的种类上，说明它在处理外观特征相似度高的水稻种子分类时效果较好；而对于种间特征区别相对较大的水稻种子，各模型的评价指标差距不大。新模型的总体准确率达到 86.90%，相较于其他模型提升 2.92 ~ 8.8 个百分点，这表明新模型在整体性能上有较明显的优势。通过各类水稻种子的召回率可以看出，新模型的召回率明显优于各对比模型，并且较于基础模型，较多种类水稻种子的召回率得到了明显提升。这进一步说明了新模型对水稻种子分类识别的有效性和优越性。

虽然 EfficientNetV2 的各评价指标与新模型接近，但能观察到，EfficientNetV2 的评价指标最优值主要集中在惠糯 330、丽晶优 211、绿银占、美香新占、五山丝苗和袁糯优 126 等特征区别相对较大的水稻种子上，且结合实验数据可以看出，EfficientNetV2 和 ConvNeXt - DFLRF 模型对这些品种识别结果的差距相对不大。然而，当面对需要识别多种类且特征近似的水稻种子时，如 D245、D246、D247、D248、D249、D250 和 D251 等，EfficientNetV2 的召回率和整体性能弱于新模型。因此，识别含有近似特征的多种类水稻种子时，新模型最优。

4 结论

（1）基于 ConvNeXt 设计了一种新的多种类水稻种子分类识别模型 ConvNeXt - DFLRF，对 36 种不同的水稻种子进行分类。在该模型中，使用 ConvNeXt 作为骨干网络提取特征，去除其全局平均池化层及以后结构，使用 MCLRM 和 FIAM 构造全新的局部特征和全局特征采集分支，将输出的局部特征和全局特征进行融合，增强模型表达特征的能力，引入 CosFace 损失，放大类间差异，提升网络区分不同种类水稻种子的能力；并在训练时采用数据增强技术，增加训练数据集的多样性，提高模型泛化能力，缓解过拟合问题。

（2）实验结果表明，新模型总体准确率达到 86.90%，较基础模型（81.02%）提高 5.88 个百分点，此外，较多种类的水稻种子识别率进一步提升，明显优于基础模型。为了充分证明提出模型的有效性和优越性，进行了消融实验，并与 InceptionResNetV2 和 EfficientNetV2 等模型进行了比较：新模型总体准确率均优于消融模型和对比模型，最高提升 8.8 个百分点，整体识别效果最优。因此，本文提出的新模型能够有效地对 36 种水稻种子进行分类，效果提升较明显，为科学研究乃至日常水稻种子交易提供了一种准确、便捷、高效、低成本的水稻种子辅助分类方法。

参 考 文 献

[1] MUTHAYYA S, SUGIMOTO J D, MONTGOMERY S, et al. An overview of global rice production, supply, trade, and consumption[J]. Annals of the New York Academy of Sciences, 2014, 1324(1): 7 - 14.

[2] BIN RAHMAN A N M R, ZHANG J. Trends in rice research: 2030 and beyond[J]. Food and Energy Security, 2023, 12(2): e390.

[3] SU Q, WU W, WANG H, et al. Fast discrimination of varieties of corn based on near infrared spectra and biomimetic pattern recognition[J]. Spectroscopy and Spectral Analysis, 2009, 29(9): 2413 - 2416.

[4] YU Y, YU H, GUO L, et al. Accuracy and stability improvement in detecting Wuchang rice adulteration by piece-wise multiplicative scatter correction in the hyperspectral imaging system[J]. Analytical Methods, 2018, 10(26): 3224 - 3231.

[5] MAHAJAN S, DAS A, SARDANA H K. Image acquisition techniques for assessment of legume quality[J]. Trends in Food Science & Technology, 2015, 42(2): 116 - 133.

[6] WENG S, TANG P, YUAN H, et al. Hyperspectral imaging for accurate determination of rice variety using a deep learning network with multi-feature fusion[J]. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 2020, 234: 118237.

[7] LIN P, LI X L, CHEN Y M, et al. A deep convolutional neural network architecture for boosting image discrimination accuracy of rice species[J]. Food and Bioprocess Technology, 2018, 11: 765 - 773.

[8] KIRATIRATANAPRUK K, TEMNIRANRAT P, SINTHUPINYO W, et al. Development of paddy rice seed classification process using machine learning techniques for automatic grading machine[J]. Journal of Sensors, 2020, 2020(1): 7041310.

[9] SHARMA A, SATISH D, SHARMA S, et al. iRSVPred: a web server for artificial intelligence based prediction of major basmati paddy seed varieties[J]. Frontiers in Plant Science, 2020, 10: 1791.

[10] PANMUANG M, RODMORN C, PINITKAN S. Image processing for classification of rice varieties with deep convolutional neural networks[C]// 2021 16th International Joint Symposium on Artificial Intelligence and Natural Language Processing (iSAI - NLP). IEEE, 2021: 1 - 6.

[11] KOKLU M, CINAR I, TASPINAR Y S. Classification of rice varieties with deep learning methods[J]. Computers and

Electronics in Agriculture, 2021, 187: 106285.

[12] GILANIE G, NASIR N, BAJWA U I, et al. RiceNet: convolutional neural networks-based model to classify Pakistani grown rice seed types[J]. Multimedia Systems, 2021, 27: 867 – 875.

[13] 杨红云,黄琼,孙爱珍,等. 基于卷积神经网络和支持向量机的水稻种子图像分类识别[J]. 中国粮油学报,2021,36(12):144 – 150.
YANG Hongyun, HUANG Qiong, SUN Aizhen, et al. Rice seed image classification and recognition based on CNN_SVM[J]. Journal of the Chinese Cereals and Oils Association, 2021,36(12):144 – 150. (in Chinese)

[14] DIN N M U, ASSAD A, DAR R A, et al. RiceNet: a deep convolutional neural network approach for classification of rice varieties[J]. Expert Systems with Applications, 2024, 235: 121214.

[15] QIAN Y, XU Q, YANG Y, et al. Classification of rice seed variety using point cloud data combined with deep learning[J]. International Journal of Agricultural and Biological Engineering, 2021, 14(5): 206 – 212.

[16] HE X, CAI Q, ZOU X, et al. Multi-modal late fusion rice seed variety classification based on an improved voting method[J]. Agriculture, 2023, 13(3): 597.

[17] CHATNUNTAWECH I, TANTISANTISOM K, KHANCHAITIT P, et al. Rice classification using spatio-spectral deep convolutional neural network[J]. arXiv Preprint, arXiv:1805.11491, 2018.

[18] TANG X, ZHAO W, GUO J, et al. Recognition of plasma-treated rice based on 3D deep residual network with attention mechanism[J]. Mathematics, 2023, 11(7): 1686.

[19] JIN B, ZHANG C, JIA L, et al. Identification of rice seed varieties based on near-infrared hyperspectral imaging technology combined with deep learning[J]. ACS Omega, 2022, 7(6): 4735 – 4749.

[20] 叶文超,罗水洋,李金豪,等. 近红外光谱与图像融合的杂交水稻种子分类方法研究[J]. 光谱学与光谱分析,2023,43(9):2935 – 2941.
YE Wenchao, LUO Shuiyang, LI Jinhao, et al. Research on classification method of hybrid rice seeds based on the fusion of near-infrared spectra and images[J]. Spectrosc. Spectr. Anal., 2023, 43(9): 2935 – 2941. (in Chinese)

[21] HE K, ZHANG X, REN S, et al. Identity mappings in deep residual networks[C]// Computer Vision-ECCV 2016: 14th European Conference, 2016: 630 – 645.

[22] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv Preprint, arXiv:1409.1556, 2014.

[23] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 2818 – 2826.

[24] LIU Z, MAO H, WU C Y, et al. A convnet for the 2020s[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 11976 – 11986.

[25] WANG H, WANG Y, ZHOU Z, et al. Cosface: large margin cosine loss for deep face recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 5265 – 5274.

[26] MENG X, YUAN Y, TENG G, et al. Deep learning for fine-grained classification of jujube fruit in the natural environment [J]. Journal of Food Measurement and Characterization, 2021, 15(5): 4150 – 4165.

[27] HE J, CHEN J N, LIU S, et al. TransFG: a transformer architecture for fine-grained recognition[C]// Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(1): 852 – 860.

[28] TAN M, LE Q. Efficientnetv2: smaller models and faster training[C]// International Conference on Machine Learning. PMLR, 2021: 10096 – 10106.