

基于改进 MobileNetv3 的大米外观质量检测模型

陈明真^{1,2}

¹河南工业大学信息科学与工程学院, 河南郑州, 中国

²河南工业大学粮食信息处理与控制教育部重点实验室, 河南郑州, 中国

【摘要】针对大米外观检测中类间差异小、局部判别特征弱及模型部署资源有限的问题, 本文提出一种轻量级分类模型 RQM-MobileNetV3。该模型基于 MobileNetV3-Small, 引入轻量级多尺度特征增强模块以提升对米粒边缘、色差及糠粉分布的感知能力, 同时结合通道重标定注意力模块增强关键判别通道响应, 并在分类头中加入 Dropout 正则化以提升泛化性能。实验结果表明, RQM-MobileNetV3 在大米单粒图像分类任务中准确率达到 92.08%, 较原始 MobileNetV3 提升约 2.96 个百分点, 尤其显著改善了精碾米与适碾米等易混淆类别的分类效果。该模型在保持轻量化的同时有效提升了细粒度分类性能, 具备良好的实际应用潜力。

【关键词】大米外观检测; 深度学习; MobileNetv3; 细粒度分类; 轻量化模型

1. 引言

现代计算机视觉技术的发展为农业视觉质量检测提供了有效手段。传统的大米质量检测主要依赖人工视觉评估, 这种方法不仅效率低, 而且容易受人为因素影响[1]。随着卷积神经网络(CNN)的普及, 基于视觉的自动检测成为可能, 尤其是在大米外观识别等细粒度分类任务中, 深度学习表现出显著优势[2]。CNN 已被广泛应用于谷物种类判别、缺陷检测与病害识别等农业视觉任务, 显著优于传统图像处理方法。

针对谷物图像分析任务, 已有研究利用 CNN 提取纹理、颜色与几何形状特征, 实现对不同类别粮食的识别。例如, Wang 等综述指出, 卷积神经网络在作物表型检测中可有效处理复杂图像信息, 实现高精度分类与检测[3]。Zia 等人设计基于混合 CNN 聚类的方法, 对不同米类的损坏与断裂情况进行分级检测, 体现了深度学习在质量评估中的潜力[4]。

在细粒度大米分类任务中, 深度学习模型如 ResNet、VGG、EfficientNet 和 MobileNet 等被广泛实验与比较研究。例如, 对比研究显示高精度模型(如 EfficientNet)在大规模大米分类中取得接近 99.7% 的准确率, 而 MobileNet 则以较快的分类速度表现优异, 适合轻量级部署[5]。Razavi 等使用迁移学习的 ResNet 模型对不同水稻品种进行分类, 并通过数据预处理与特征学习实现高精度评估, 这表明深层模型在质量分析中具备强表达能力[6]。

轻量化网络结构(如 MobileNet 系列)因其计算效率高、参数量小, 在嵌入式设备和实时检测领域有广泛应用, 而其设计基于神经架构搜索和高效构建模块, 以达到在移动平台上的实时性能与高精度平衡[7]。

近年来, 注意力机制被引入 CNN 结构中, 以增强对关键局部区域的关注, 从而提升细粒度分类性能。例如, 聚合注意力模块结合通道注意力与空间注意力, 有效学习判别性特征以提高分类精度[8]。此外, 在细粒度图像分类任务中, 混合注意力模型也能自适应增强图像中重要区域的信息, 有助于提取更多判别性特征[9]。

基于以上研究背景, 本研究针对大米外观质量检测任务, 提出了基于改进 MobileNetv3 的轻量化模型, 并通过引入多尺度特征增强与通道重标定注意力机制来提升细粒度特征提取能力。本文通过与传统 CNN 和轻量网络进行对比, 验证了所提方法的有效性与适用性。

2. 基于 RQM-MobileNetv3 的大米检测模型

2.1 MobileNetv3 算法模型结构

MobileNetv3 是 Google 在 2019 年提出的一种轻量级卷积神经网络模型, 结合神经架构搜索(NAS)与深度可分离卷积结构, 在保证较高精度的同时显著降低计算复杂度[10]。MobileNetv3 分为 MobileNetv3-Small 和 MobileNetv3-Large 两种结构。考虑到本文研究对象为单粒大米图像, 图像背景相对简单, 目标结构较为集中, 因此选用 MobileNetv3-Small 作为基础模型开展改进研

究。MobileNetv3-small 网络输入尺寸为 224×224 (像素)，通过多层深度可分离卷积与逐点卷积操作逐步提取图像特征，并通过全局平均池化得到特征向量，最终经过全连接层完成分类任务。其网络结构主要包含：深度可分离卷积[11]、SE 注意力模块[12]非线性激活函 (h-swish) 该模型在移动端和嵌入式设备中具有良好的应用前景。如图 1 为 MobileNetv3-Small 架构图：




图 1. MobileNetv3-Small 架构图

2.2 多尺度特征增强模块的添加(MSFE)

MobileNetv3 原始模型在浅层特征提取过程中感受野较小，对于细粒度特征的表达力有限。在大米外观质量分类任务中，不同类别之间差异主要体现在边缘形态、局部色差及表面纹理等细节信息上，容易出现特征

提取不充分的问题，从而影响分类精度。

为提高模型对细粒度特征的识别能力，在网络浅层引入多尺度特征增强模块 (MSFE)。该模块通过多分支结构对输入特征进行并行处理，分别采用不同尺度的卷积核提取特征信息，以增强模型对不同尺度信息的表达能力[13]。

具体而言，输入特征首先分别经过 1×1 卷积、 3×3 深度可分离卷积和 5×5 深度可分离卷积进行处理，其中 1×1 卷积用于通道压缩与信息整合， 3×3 卷积用于提取局部纹理特征， 5×5 卷积用于获取更大感受野下的结构信息[11]。各分支输出特征在通道维度进行拼接后，通过 1×1 卷积进行融合，从而得到增强后的特征表示。

同时，为避免特征信息在融合过程中丢失，引入残差连接结构，将输入特征与融合后的特征进行相加，提高网络的稳定性和表达能力[14]。通过该模块，可以有效提升模型对大米细粒度特征的提取能力，从而提高分类准确率。如下图 2 为 MSFE 框架图：

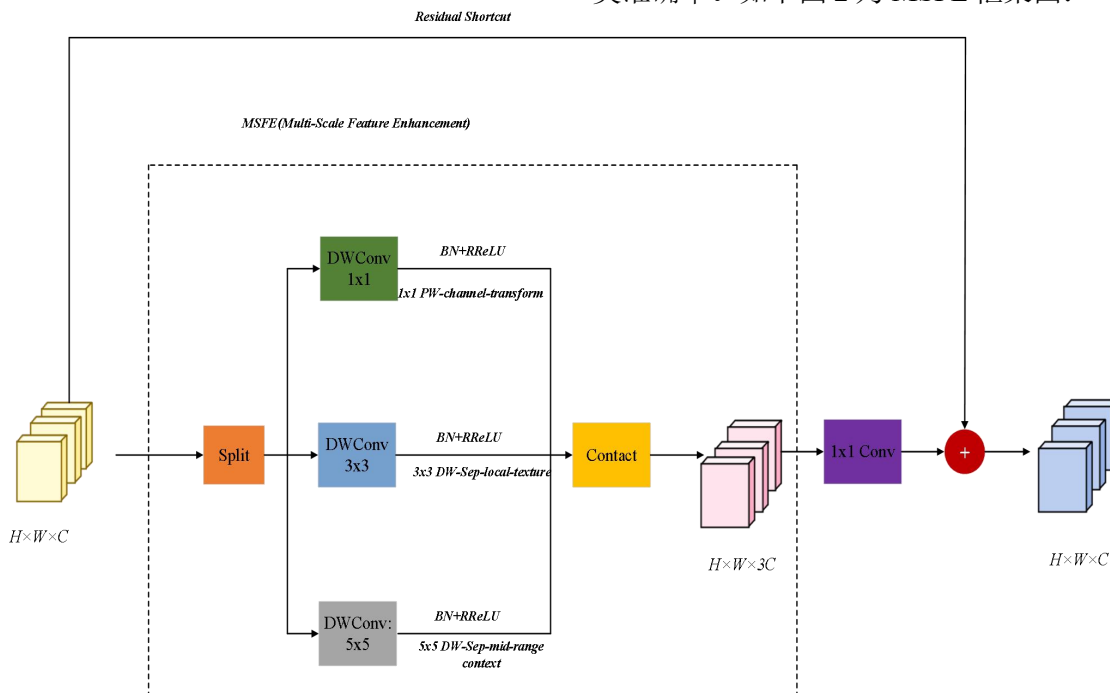


图 2. MSFE 框架图

2.3 CRA 注意力模块

虽然 MSFE 模块能够通过多尺度并行卷积结构增强网络对不同尺度局部特征的提取能力，不过，其在特征整合阶段仍面临一些限制。具体而言，MSFE 通过多分支卷积获取丰富的空间特征后，通常采用简单的拼接或线性融合方式对各分支特征进行整合，不同通道特征的重要性未被区分处理，因此在

特征融合后，关键信息与背景干扰在后续计算中权重一致[15]。

这种现象在大米外观品质检测任务中尤其明显。例如碎米断裂边缘、黄粒米局部色差以及适碾米与等外米之间的留皮纹理差异等关键判别信息通常只占据特征图中较少的通道响应，而背景区域的反光纹理、噪声信息或无关细节可能在多尺度特征提取过程中

被同时增强。如果缺乏有效的特征筛选机制，模型在进行特征融合时容易受到冗余信

息干扰，从而影响分类结果的稳定性与准确性。




图 3. CRA 注意力模块

已有研究表明，多尺度特征融合与注意力机制的结合能够有效提升模型对关键特征的表达能力，从而改善复杂场景下的识别性能[16]。

因此，在 MSFE 模块增强多尺度特征表达能力的基础上，仍需要一种能够对特征通道进行自适应选择的机制，以突出关键判别特征并抑制无关信息。基于这一考虑，本文进一步在 MobileNetv3 主干网络中引入通道重标定注意力模块（CRA），从而进一步提升模型性能[17]。如图 3 所示。通过对各通道特征响应进行动态权重调整，使网络能够更加关注对大米外观分类具有重要意义的特征信息，从而进一步提升模型的判别能力与分类性能。

2.4 分类头优化

由于大米某些类别之间的差异较小，模型在训练过程中容易学习到训练数据中的噪声特征，从而导致过拟合现象的产生，进而影响模型在测试集上的泛化能力。针对这一问题，本文在分类头部分引入 Dropout 正则化机制，以降低模型对特定特征的依赖程度，从而提升整体鲁棒性[18]。

Dropout 是一种经典的随机失活方法，其基本思想是在模型训练过程中以一定概率随机屏蔽部分神经元，使得网络在每次迭代中均以不同的结构进行学习，从而减少特征之间的共适应现象，提高模型的泛化能力[19]。具体而言，在前向传播过程中，Dropout 层会对神经元输出进行随机置零操作，而在测试阶段则通过权重缩放的方式恢复网络的整体输出分布。

已有研究表明，在深度学习模型中引入正则化策略能够有效抑制过拟合现象，提高模型在未知样本上的泛化能力，尤其在样本规模有限的情况下效果更加显著。此外，结合随机失活机制与网络结构优化方法，可以进一步增强模型对关键特征的学习能力，减少噪声干扰[20]。

因此，在本研究中，通过在全连接层后加入 Dropout 层，不仅增强了模型的泛化性能，同时也提高了模型在不同类别大米图像上的稳定分类能力。Dropout 的具体工作原理如图 4：




图 4. Dropout 的具体工作原理

3. 数据集的制作和模型训练

3.1 数据集的获取

为了实现大米颗粒的有效分离与图像采集，本文构建了简易图像采集系统。该系统主要由工业相机、光源及支撑结构组成。为保证采集过程的稳定性，采用固定高度为 800 mm 的刚性支架对相机进行固定，并通过底座加固方式减少外界振动对成像质量的影响。

在光源设计方面，考虑到自然光存在亮度不稳定及色温变化等问题，本文采用可控人工光源进行图像采集[21]。实验中选用双矩形 LED 光源（规格为 2×52 mm×10 mm），以保证图像亮度均匀，提高后续特征提取的稳定性。

在图像采集设备方面，选用海康威视 MV-CE100-30GC 彩色工业相机，该相机分辨率为 3840×748，能够清晰获取大米颗粒的细节信息。配套使用 MVL-HF1228M-6MP 工业镜头，以降低成像畸变并提升图像质量[22]。

在数据采集过程中，选取精碾米、适碾米、等外米、碎米及黄粒米五类大米作为研

究对象[23]。如下图为五类大米样品图。

首先采集混合样本图像，每类样品选取 100 g 进行拍摄，共获得 60 张混合图像。随后对样品进行人工分类，并分别补充采集单粒大米图像，每类 15 张。

最终获得混合样本与单粒样本图像共计




图 5.大米样品图

3.2 数据预处理

由于原始采集的大米图像包含背景信息复杂、颗粒分布不均以及样本数量有限等问题，难以直接用于深度学习模型训练，因此需要对数据进行预处理与扩充，以提高模型的训练效果和泛化能力。

首先，对原始图像进行单粒分割处理。针对混合样本图像，通过图像裁剪与区域分割方法提取单粒大米图像，以减少背景干扰，使模型更加关注大米本身的形态特征。同时，对分割后的图像进行尺寸统一处理，将所有样本缩放至 224×224 像素，以满足模型输入要求[24]。

其次，为解决数据量不足的问题，对数据集进行数据增强处理。通过对原始图像进行随机旋转、水平翻转、亮度调整及对比度变换等操作，生成多样化样本，从而提升模型对不同环境条件的适应能力。数据增强不仅增加了样本数量，还有效提高了模型对不同姿态及光照条件下大米图像的鲁棒性[25]。

此外，为加快模型收敛速度并提高训练稳定性，对输入图像进行归一化处理，将像素值映射至统一范围，从而减少不同图像之间的数值差异。

通过上述预处理操作，构建了结构规

范、分布均衡的数据集，为后续模型训练与性能评估提供了可靠的数据基础。

3.3 实验环境与参数配置

表 1.实验软硬件设置

硬件环境	配置说明	软件环境	配置说明
CPU	Intel(R) Core i7 3.81 GHz	系统环境	Windows 10
显卡	NVIDIA RTX 3060	编程环境	Python 3.9.10

表 2.训练参数设置

训练参数	数值	训练参数	数值
输入图像尺寸	224×224	初始学习率	0.01
批处理大小	16	训练轮次	100

在进行大米外观图像生成的场景下，输入分辨率的设定对细粒度判别特征的有效呈现具有直接影响。以本文所涉及的五类大米为例：精碾米与适碾米之间的等级差异体现在糠粉分布密度与表面反光程度的细微变化，等外米的外观异常主要表现为局部色斑与轮廓缺损，碎米的关键特征集中在断口边缘的不规则几何形态，黄粒米则以籽粒整体色度偏黄为核心判别依据。实验所采用的软硬件环境及网络训练参数如表 1 所示，设备配置参数见表 2。

3.4 评价指标

对于本文的大米外观质量检测任务而言，不同类别之间存在明显的细粒度差异，尤其是适碾米与等外米在局部纹理和留皮程度上的差异较小，因此仅使用单一准确率指标难以全面揭示模型在各类别上的实际识别效果，有必要结合精确率与召回率对模型进行多角度分析[26]。

在多分类任务中，通常需要基于混淆矩阵分别统计各类别的真阳性、假阳性和假阴性，同时，对各类别的识别结果计算精确率和召回率，以更全面地评估模型的分类能力[27]。

除分类精度指标外，本文还将模型推理时间作为评价模型实际应用价值的重要指标。推理时间反映模型对输入样本完成一次前向预测所需的时间开销，能够在一定程度上表征模型在实际检测场景中的运行效率。对于面向粮食质量检测的轻量级模型而言，较高的分类精度固然重要，但若模型推理速度过慢，则难以满足现场检测、在线筛查或嵌入式部署等应用需求[28]。

MobileNetV3 本身即是面向高、低资源使用场景设计的轻量化网络，因此在本文实验中引入推理时间指标，有助于从精度和效率两个方面综合评价改进模型的性能表现[29]。

其中 TP 表示正确预测为目标类别的样本数量，TN 表示正确判定为非目标类别的样本数量，FP 表示错误分类为目标类别的样本数量，FN 表示真实属于目标类别但未被正确识别的样本数量。在后续实验中，本文将结合整体准确率、各类别精确率与召回率以及模型推理时间，对改进模型与对比模型的性能进行系统分析。

4. 实验结果

4.1 改进模型分类结果分析


由于本文提出的 RQM-MobileNetv3 模型是在 MobileNetv3-Small 基础上，通过引入 MSFE 模块、CRA 注意力机制及 Dropout 正则化进行改进，为验证其有效性，对改进前后模型进行对比实验分析。

在相同实验环境与数据集条件下，对 MobileNetv3 与 RQM-MobileNetv3 模型进行训练与测试。实验结果表明，改进模型在大米外观质量分类任务中表现出更优的识别性能。RQM-MobileNetv3 在准确率、精确率和召回率方面分别达到 92.08%、92.44% 和 92.57%，相比原始 MobileNetv3 分别提升约 2.96%、2.70% 和 2.56%。

进一步分析发现，改进模型在精碾米与适碾米等易混淆类别上的识别能力明显增强。这主要得益于多尺度特征增强模块对局部细节信息的提取能力，以及注意力机制对关键特征通道的强化作用。

4.2 分类结果可视化分析

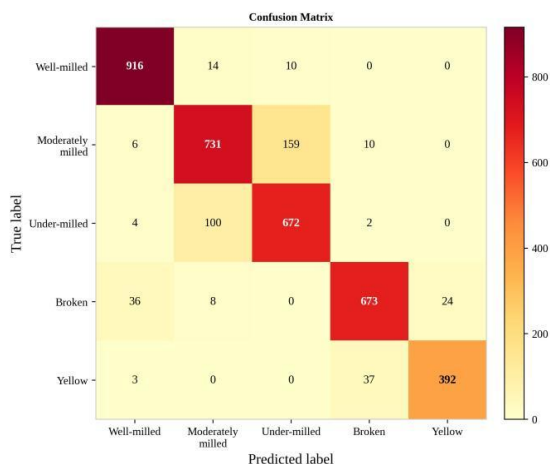
为了更直观地分析改进前后模型的性能，本文进一步绘制 MobileNetv3 与 RQM-MobileNetv3 的 ROC 曲线和混淆矩阵，如图 6 和图 7 所示。从图 6 可以看出，RQM-MobileNetv3 的 ROC 曲线整体更加接近左上角，表明其具有更强的分类判别能力；从图 7 所示混淆矩阵可以看出，原始 MobileNetv3 在适碾米与等外米之间存在较明显的类别混淆，而改进后的 RQM-MobileNetv3 在这两类样本上的误分现象有所减少，说明本文所提出的改进模块能够有效增强模型对留皮纹理、局部色差和边缘特征的感知能力，提高相似类别之间的区分效果。



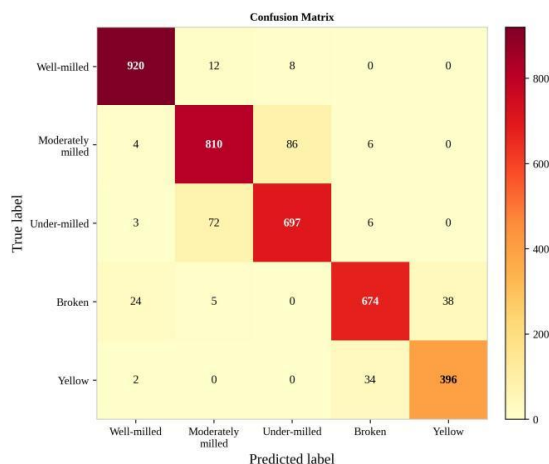
a) MobileNetV3 ROC 曲线

b) RQM-MobileNetV3 ROC 曲线

图 6. MobileNetV3 与 RQM-MobileNetV3 的 ROC 曲线对比图



a) MobileNetv3 混淆矩阵



b) RQM-MobileNetv3 混淆矩阵

图 7. MobileNetv3 与 RQM-MobileNetv3 的混淆矩阵对比图

4.3 对比实验

为了进一步验证本文所提出 RQM-MobileNetv3 模型在大米外观质量检测任务中的性能优势，本文选取多种经典深度学习分类模型进行对比实验，包括 ResNet34、VGG16、EfficientNet-B1、ShuffleNetV2、InceptionV3 以及原始 MobileNetv3。所有模型均使用相同的训练、验证和测试数据集进行训练与评估，并在一致的实验环境下设置相同的训练参数和评估指标。

表 3 展示了各模型在大米外观质量检测任务中的实验表现。从表中可以看出，本文提出的 RQM-MobileNetv3 在准确率、精确率和召回率方面均取得了最优结果，分别达到 92.08%、92.44% 和 92.57%。相比原始 MobileNetv3，模型准确率提升了 2.96%，说明本文引入的 MSFE、CRA 及 Dropout 等改进策略能够有效提升模型对大米细粒度外观差异的表征能力。与 ShuffleNetV2 和 InceptionV3 等轻量级网络相比，RQM-MobileNetv3 在分类性能上同样具有明显优势，表明改进模型在细粒度类别区分任务中具有更好的适应性。

表 3. 各模型实验对比结果

Model	Acc(%)	P(%)	R(%)	Time(s)
ResNet34	90.73	91.22	91.46	48
VGG16	91.65	92.10	92.34	63
EfficientNet-B1	88.74	89.15	89.47	36
ShuffleNetV2	88.21	88.67	88.93	27
InceptionV3	88.56	89.03	89.21	34
MobileNetv3	89.12	89.74	90.01	30
RQM-MobileNetv3	92.08	92.44	92.57	36

4.4 消融实验

在实验环节中，为评估所提出改进模块

对模型表现的实际影响，本文先将原始 MobileNetv3 设为基准模型，然后在此基础上逐步加入改进模块进行性能测试与对比分析。首先在 MobileNetv3 网络中加入轻量级多尺度特征增强模块 (MSFE)，得到模型 MobileNetv3_M；随后在此基础上进一步引入通道重标定注意力模块，得到模型 MobileNetv3_M_C；最后在分类头中加入 Dropout 正则化策略，形成最终改进模型 RQM-MobileNetv3。

表 4 给出了 MobileNetv3 模型的消融实验结果。实验结果表明，随着改进模块的逐步引入，模型分类效果呈现出稳定的提升趋势。其中，仅加入 MSFE 模块时，模型准确率由原始 MobileNetv3 的 89.12% 提升至 90.47%，这表明，多尺度特征提取模块能够显著提升模型对大米局部细节特征的识别与表征能力；在进一步加入 CRA 注意力模块后，模型准确率提升至 91.36%，表明通道重标定机制能够强化关键判别特征通道，从而提升模型分类能力；当在分类头加入 Dropout 正则化后，模型最终准确率达到 92.08%，相比原始 MobileNetv3 提升约 2.96%。尽管模型的推理时间有所增加，但整体运算效率依然保持在较高水平。

表 4. RQM-MobileNetv3 消融实验结果

MSFE	CRA	Dropout	Acc(%)	P(%)	R(%)	Time(s)
×	×	×	89.12	89.74	90.01	30
√	×	×	90.47	90.95	91.10	32
√	√	×	91.36	91.82	92.03	34
√	√	√	92.08	92.44	92.57	36

5. 结论

本文设计了一种针对大米外观检测任务优化的轻量级分类网络改进型 RQM-

MobileNetv3。该模型在 MobileNetv3-Small 的基础上,通过引入轻量级多尺度特征增强模块,有效提升了对米粒边缘、局部色差、糠粉分布及表面纹理等关键细节特征的感知能力;同时加入通道重标定注意力模块,增强了模型对重要判别通道的关注,从而在细粒度类别判别中进一步降低混淆率。同时,通过在分类头中引入 Dropout 正则化与优化设计,模型在样本量有限的情况下过拟合现象得到缓解,从而增强了整体泛化能力与训练稳定性。

RQM-MobileNetv3 模型不仅保持了原有 MobileNetv3-Small 的轻量化优势和快速推理能力,而且在准确率、精确率和召回率等指标上均有明显提升,特别是在精碾米与适碾米等易混淆类别上表现出更高的区分能力。消融实验进一步验证了各改进模块对整体性能的贡献,说明多尺度特征增强模块、通道重标定注意力模块以及 Dropout 正则化策略的协同作用对于细粒度特征提取与分类精度提升具有重要意义。

综上所述,本文的研究成果为大米外观质量的自动化检测提供了一个高效且便于实际应用的解决方案,也为其他细粒度农产品视觉识别任务提供了可借鉴的模型设计思路与方法参考。

参考文献

- [1]Wang Y H, Su W H. Convolutional neural networks in computer vision for grain crop phenotyping: A review[J]. *Agronomy*, 2022, 12(11): 2659.
- [2]Chen J, Zhang X, Liu Y. Intelligent rice quality assessment using hybrid CNN-clustering approach[J]. *Discover Applied Sciences*, 2025.
- [3]Razavi M, Mavaddati S, et al. Rice classification and quality detection using transferred ResNet deep model[J]. *Simulation Modelling Practice and Theory*, 2024.
- [4]A comparative study of deep learning architectures for rice grain classification[J]. *Journal of Agriculture and Food Research*, 2023.
- [5]Latif G, et al. Detection of rice plant diseases using an improved CNN model[J]. *Plants*, 2022, 11(17): 2230.
- [6]Howard A, Sandler M, Chen B, et al. Searching for MobileNetV3[J/OL].
- [7]Wang X, Shi J, et al. Aggregate attention module for fine-grained image classification[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2023, 14: 8335-8345.
- [8]Lu W, et al. Fine-grained image classification method based on hybrid attention module[J]. *Frontiers in Neurorobotics*, 2024, 18: 1391791.
- [9]Howard A, Sandler M, Chen B, et al. Searching for MobileNetV3[C]//*Proceedings of the IEEE International Conference on Computer Vision*. 2019: 1314-1324.
- [10]Chollet F. Xception: Deep learning with depthwise separable Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 1251-1258.
- [11]Hu J, Shen L, Sun G. Squeeze-and-Excitation networks[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2018: 7132-7141.
- [12]Lin T Y, Dollár P, Girshick R, et al. Feature Pyramid Networks for Object Detection[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017: 2117-2125.
- [13]He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016: 770-778.
- [14]张睿, 李允臣, 王家宝, 等.多尺度特征融合的双模态目标检测方法[J]. *计算机工程与应用*, 2024, 60 (17) : 233-242.
- [15]王桥, 胡春燕, 李菲菲.基于深度迁移学习与多尺度特征融合的场景识别方法[J]. *电子科技*, 2023, 36 (11) : 19-27.
- [16]付均尚, 田莹.采用多信息残差融合和多尺度特征表达的水下目标检测[J]. *计算机工程与应用*, 2025, 61 (11) : 272-283.
- [17]Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: A simple way to prevent neural networks from overfitting[J]. *Journal of Machine Learning Research*, 2014, 15(1): 1929-1958.
- [18]Goodfellow I, Bengio Y, Courville A. *Deep Learning*[M]. Cambridge: Mit Press, 2016.
- [19]刘建伟, 刘媛, 罗雄麟.深度学习研究进展[J]. *计算机应用研究*, 2014, 31 (7) : 1921-1930.
- [20]Krogh A, Hertz J A. A simple weight decay can improve generalization[J]. *Advances in Neural*

- Information Processing Systems, 1992, 4: 950-957.
- [21]Gonzalez R C, Woods R E. Digital Image Processing[M]. 3rd ed. New Jersey: Prentice Hall, 2008.
- [22]Kumar A, Vats A, Kumar A. Classification and morphology detection of rice grains using machine vision[C]//International Conference on Smart Computing. Springer, 2024: 45-56.
- [23]Gagliardi G, Corti A, Catalano G, et al. Computer vision and machine learning analysis of commercial rice grains[J]. Sensors, 2021, 21(19): 6354.
- [24]Sonka M, Hlavac V, Boyle R. Image Processing, Analysis, and Machine Vision[M]. 4th ed. Boston: Cengage Learning, 2014.
- [25]Shorten C, Khoshg of Taar T m. A survey on Image Data Augmentation for Deep Learning[J]. Journal of Big Data, 2019, 6(1): 60.
- [26]李航.统计学习方法[M].北京：清华大学出版社，2019.
- [27]周志华.机器学习[M].北京：清华大学出版社，2016.
- [28]刘建伟，刘媛，罗雄麟.深度学习研究进展[J].计算机应用研究，2014，31（7）：1921-1930.
- [29]张军，王晓华.轻量级卷积神经网络研究综述[J].计算机工程与应用，2021，57（5）：1-9.