

田敏,牛智有,刘梅英.基于改进ShuffleNetV2的轻量化饲料原料种类识别模型[J].华中农业大学学报,2025,44(2):105-115.
DOI:10.13300/j.cnki.hnlkxb.2025.02.011

基于改进 ShuffleNetV2 的轻量化饲料原料种类识别模型

田敏,牛智有,刘梅英

华中农业大学工学院/农业农村部智慧养殖技术重点实验室,武汉 430070

摘要 针对目前配合饲料加工过程中生产饲料原料入仓环节人工识别粉碎程度、颜色和形状相近的入仓原料时存在种类识别困难的问题,基于轻量化卷积神经网络模型 ShuffleNetV2,提出一种识别精度更高、计算复杂度更小且适用于饲料原料图像种类识别的 ShuffleNetV2-EH 轻量化模型。首先在 ShuffleNetV2 网络模型结构中引入注意力机制 ECA(efficient channel attention),根据输入自适应调整通道权重,提升网络模型对饲料原料图像重要特征的感知能力;其次将 ReLU 替换为 HardSwish 激活函数,在不增加额外的权重和偏置参数的前提下,提升模型的识别准确率;最后在保证模型识别精度的基础上,对 ShuffleNetV2 网络模型结构进行调整,减少模型的参数量以及计算量。结果显示,ShuffleNetV2-EH 模型在 8 种饲料原料图像测试集上的识别准确率为 99.13%,与原 ShuffleNetV2 模型相比提升 1.38 百分点,其精确率、召回率和 F_1 分数分别提升 1.45、1.63 和 1.62 百分点,模型参数量和浮点运算量较之前分别减少 352 092 个和 45.27×10^6 ;且综合性能优于经典卷积神经网络模型 AlexNet、VggNet16、GoogLeNet 和 ResNet18。结果表明,改进后的 ShuffleNetV2 模型较好地平衡了模型的计算复杂度和识别精度,为入仓环节的饲料原料在线识别提供了算法基础。

关键词 饲料原料;种类识别;轻量化模型;ShuffleNetV2;注意力机制

中图分类号 S512.2;TP183 **文献标识码** A **文章编号** 1000-2421(2025)02-0105-11

配合饲料加工过程中,经过粉碎或不需要粉碎的饲料原料需要经旋转分配器通过溜管进入不同配 料仓,为了确保原料正确入仓,在入仓初期需要对饲 料原料进行种类识别,该环节对于饲料加工企业生 产出高质量且安全可靠的配合饲料具有重要意义^[1]。 传统的人仓原料种类识别由巡检工在旋转分配器下 方的溜管取样点人工取样并感官识别其种类^[2]。由 于入仓原料种类繁多,在区分粉碎程度、颜色和形 状相近的饲料原料时,即便是经验丰富的巡检工也 无法对入仓原料进行快速、准确地识别。因此,开展 饲料原料种类识别方法研究,利用自动化的饲料原料 种类识别检测技术代替人工识别,对于提高检测效 率、识别准确率以及确保饲料产品质量具有重要 意义。

传统机器学习为识别和分类任务提供了一种解 决方法,通过提取图像中的颜色^[3]、纹理^[4]、形状^[5]等

特征信息,利用 SVM^[6]、K 邻近^[7]和随机森林^[8]等分 类算法实现图像识别和分类任务。但传统机器学习 算法在特征提取等方面存在一定的局限性,高度依 赖人工设计的特征提取算法,同时提取的特征表达 能力有限^[9],在区分粉碎程度、颜色和形状接近的饲 料原料时,构建的种类识别模型泛化能力弱,难以实 际应用于入仓饲料原料的自动识别检测。

近年来,随着深度学习的发展,基于卷积神经网 络提出了 GoogLeNet^[10]、ResNet^[11]和 DenseNet^[12] 等系列图像分类模型,这些模型因其强大的特征提 取能力,在图像识别任务中得到广泛应用。在饲料 原料种类识别方面,牛智有等^[1]在 ResNet18 中引入 注意力机制增强模型对饲料原料图像中重要特征进 行提取,在 10 种饲料原料测试集上识别准确率达到 99.1%。在农作物病虫害识别方面,李恩霖等^[13]在 3 种玉米叶片病害图像数据集上评估了 5 种主流深度

收稿日期:2024-07-11

基金项目:国家自然科学基金项目(32072765)

田敏,E-mail:1683597935@qq.com

通信作者:刘梅英,E-mail:meiying_liu@mail.hzau.edu.cn

卷积神经网络模型的识别精度,其中DenseNet121模型的识别准确率最高,达到99.73%;Luo等^[14]针对复杂环境下苹果叶片病害特征显著性相对较弱等问题,提出了一种基于多尺度特征融合的ResNet50苹果病害分类模型,在测试集上的识别准确率达94.99%。上述卷积神经网络模型在图像识别任务中具有更高的识别精度,但存在模型计算复杂度高、对硬件资源需求较大等问题,因此部分研究工作者对轻量化卷积神经网络开展了研究。孙俊等^[15]通过嵌入坐标注意力机制和多尺度特征融合改进轻量级卷积神经网络模型MobileNetV2,使得在复杂背景下的田间农作物叶片病害识别准确率达到92.2%。彭红星等^[16]针对荔枝病虫害特点,基于ShuffleNetV2轻量级卷积神经网络提出了识别精度更高的荔枝病虫害识别模型SHTNet,在测试集上的识别准确率可达到84.9%。张鹏程等^[17]为提高柑橘害虫的识别精度,在MobileNetV2模型结构基础上嵌入注意力机制ECA,识别准确率达93.63%。其中,ShuffleNet系列模型能够快速准确地识别不同类别的差异,并且在轻量化和模型性能之间取得了良好平衡,对计算资源需求少且适用于高性能的应用场景,目前已被

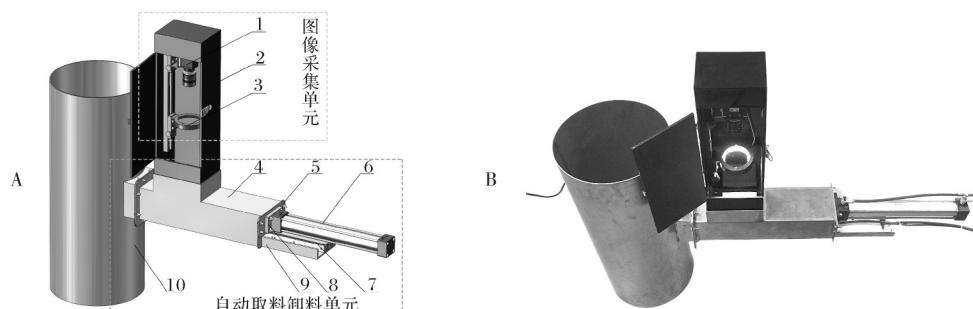
广泛应用于农作物病害识别、害虫检测等领域,但在饲料原料种类识别方面应用较少。

为实现对入仓饲料原料的快速识别,本研究在ShuffleNetV2轻量级卷积神经网络模型结构基础上,通过添加注意力机制ECA、将原模型中的ReLU替换为HardSwish激活函数以及对模型结构进行调整,提出一种识别精度更高、计算复杂度更小且适用于饲料原料图像种类识别的轻量化模型,旨在为入仓环节的饲料原料在线识别提供算法参考。

1 材料与方法

1.1 饲料原料自动取样识别装置

饲料原料自动取样识别装置结构如图1所示。该装置包括自动取料卸料单元和图像采集单元2部分,自动取料卸料单元由外壳、取料盒、卸料板、连接件等零部件组成,由空气压缩机提供动力,驱动标准气缸和双轴气缸活塞杆分别带动取料盒和卸料板相互配合完成取料与卸料动作。图像采集单元主要由工业相机、镜头、环形光源、滑块、直线导轨和暗箱等组成,负责采集正下方取料盒取料口中的饲料原料样品图像。



A:装置总体结构示意图 Overall structure diagram of the device; 1. 工业相机 Industrial cameras; 2. 暗箱 Camera obscura; 3. 环形光源 Ring light source; 4. 外壳 Shell; 5. 连接件 Connecting parts; 6. 标准气缸 Standard cylinder; 7. 双轴气缸 Dual-shaft cylinder; 8. 连接法兰 Connecting flange; 9. 取料盒 Take-up box; 10. 溜管 Chute pipe; B:装置实物图 Physical picture of the device.

图1 饲料原料自动取样识别装置

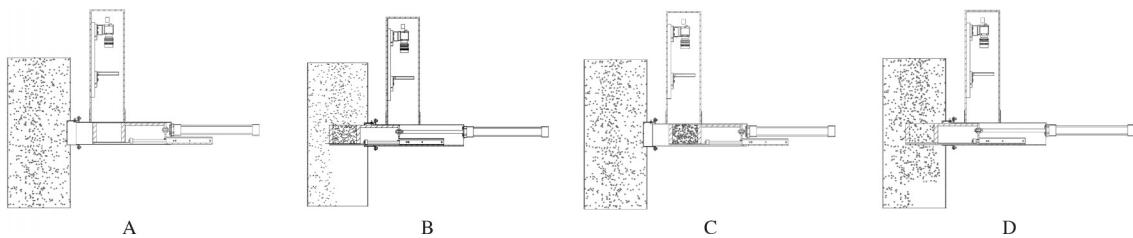
Fig.1 Automatic sampling and identification device for feedstuffs

饲料原料自动取样识别装置的工作流程为:自动取料卸料单元的标准气缸活塞杆推动取料盒进入溜管内采集饲料原料样品,并在规定的取料时间内完成样品采集,随后标准气缸活塞杆带动取料盒返回图像采集单元正下方;图像采集单元采集取料盒取料口中的饲料原料样品图像;完成图像采集后,标准气缸推动取料盒到达取料卸料位置,双轴气缸活塞杆带动取料口下方的卸料板,完成卸料动作,随后标准气缸和双轴气缸活塞杆复位,回到初始位置完成一次图像采集工作。装置工作状态示意图如图2

所示。装置的工作状态由现场核心控制器和远程中控室共同控制,通过采集经溜管进入配料仓的饲料原料图像,并将图像传输回中控室识别其种类,判断入仓原料是否正确落入对应的配料仓。

1.2 图像数据采集

采集不同饲料加工企业、不同产地、不同批次的玉米粉、面粉、膨化玉米、麸皮、鱼粉、小麦、豆粕和棉粕等8类大宗饲料原料样品384份,其中每类饲料原料48份。采用上述笔者所在课题组设计并加工的装置采集饲料原料图像,该装置由型号为ME2P-1230-



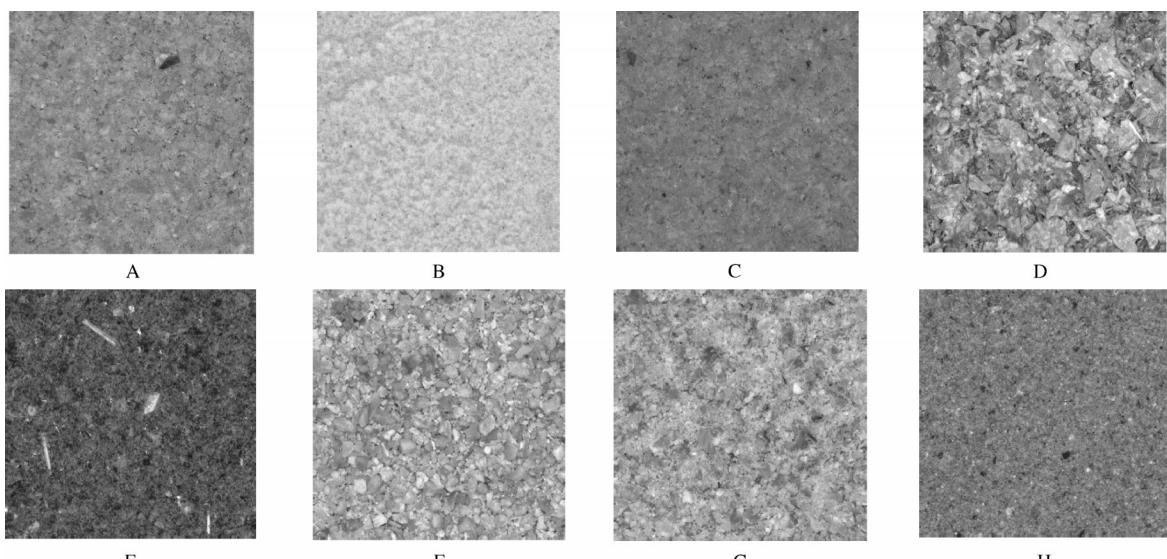
A: 初始状态 Initial state; B: 取料状态 Withdrawal condition; C: 图像采集状态 Image acquisition state; D: 卸料状态 Unloading status.

图2 装置工作状态示意图

Fig.2 Schematic diagram of device working status

23U3C 工业相机及镜头、环形光源、尺寸为 140 mm×106 mm×450 mm 的暗箱、直线导轨、滑块和计算机等组成。相机镜头和环形光源在暗箱内部垂直方向上距离饲料原料样品表面分别为 300、110 mm 的高度,通过设置合适的相机参数以及环形光源的

光照强度,确保采集的 8 种饲料原料在统一的设备参数设置下能够获得高质量的图像。试验共获取 8 000 张大小为 500 像素×500 像素的饲料原料图像,每种原料各有 1 000 张。采集的部分饲料原料图像如图 3 所示。



A: 玉米粉 Corn meal; B: 面粉 Flour; C: 膨化玉米 Expanded corn; D: 花生皮 Bran; E: 鱼粉 Fish meal; F: 豆粕 Soybean meal; G: 小麦 Wheat; H: 棉粕 Cottonseed meal.

图3 部分饲料原料样品图像

Fig.3 Images of some feed material samples

1.3 数据集划分和数据增强

将采集的每类饲料原料图像按照 7:2:1 随机划分为训练集、验证集和测试集。其中,训练集图像数量为 5 600 张,验证集图像数量为 1 600 张,测试集图像数量为 800 张。为丰富训练集数据的多样性,提高识别模型的鲁棒性和泛化能力,使用 Python 提供的 ImgAug 库以 50% 的概率对训练集原始图像进行水平翻转、垂直翻转、对比度调整和亮度调整,将训练集数据量扩充 2 倍。其中,对比度调整因子从 0.5~1.5 随机生成,强化模型对关键特征的学习;亮度调整因子从 0.75~1.25 随机生成,提高模型对于光照变化的适应性。经数据增强后的训练集图像数量为

16 800 张。

1.4 ShuffleNetV2 网络模型结构

ShuffleNetV2 以减少内存访问成本、避免过多使用分组卷积(group convolution)、减少模型整体碎片化程度、平衡网络的深度和宽度为设计准则^[18],引入通道混洗(channel shuffle)和深度可分离卷积(depth-wise separable convolution),配合模块化单元组成的网络结构,在保证模型精度的前提下,实现快速、高效的图像识别。

ShuffleNetV2 中的基础单元(basic block)和下采样单元(downsampling block)共同组成了模型的主体结构,将深度可分离卷积和通道混洗操作集成到模

块化的单元中,进一步降低了模型的计算复杂度。对于基础单元,如图4A所示,输入特征图经通道分割(channel split)操作在通道维度上分成2个分支,左分支不做任何处理,右分支将通道数只有原来一半的输入特征图进行逐点卷积和深度可分离卷积,随后通过拼接(concat)操作将2个分支的特征图进行拼接,得到输出和输入尺寸一致的特征图,经通道混洗将拼接后的特征图在通道维度上进行混洗,实现跨通道信息交流。对于下采样单元,如图4B所示,不使用通道分割操作直接分成2个分支,左分支对输入特征图进行深度可分离卷积,右分支同基础单元的右分支一致,但在深度卷积中使用步长为2的卷积核,经过拼接和通道混洗操作使输出特征图的通道数是输入特征图的2倍,特征图尺寸减半,以获取更抽象的特征。

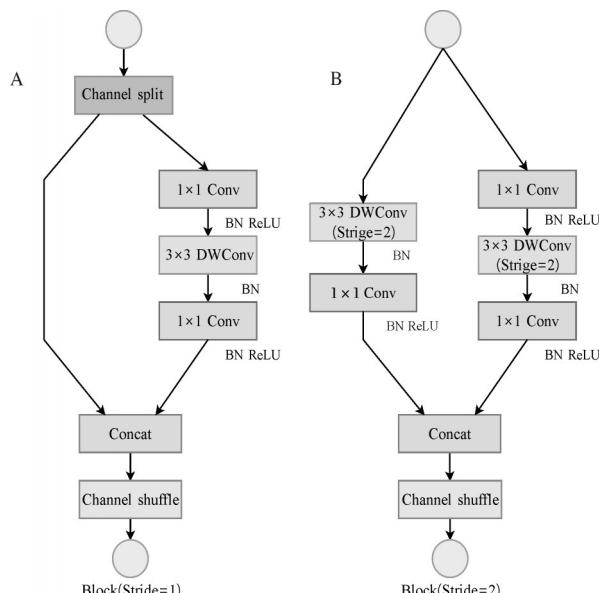


图4 ShuffleNetV2单元

Fig.4 ShuffleNetV2 unit

ShuffleNetV2网络模型结构如图5所示,输入3通道224像素×224像素的图像,经过标准卷积和最大池化层提取图像中的初级特征,接着进入由重复堆叠的基础单元和下采样单元组成的阶段(stage)中,其中基础单元用于相同尺寸特征图的特征提取,下采样单元则用于不同阶段中以减小特征图的尺寸,同时增加通道数,最后经过全局平均池化(global average pooling)和全连接层(fully connected layer)输出各类别预测概率。

1.5 基于改进的饲料原料种类识别模型 ShuffleNetV2-EH

根据本研究对饲料原料图像种类识别模型轻量

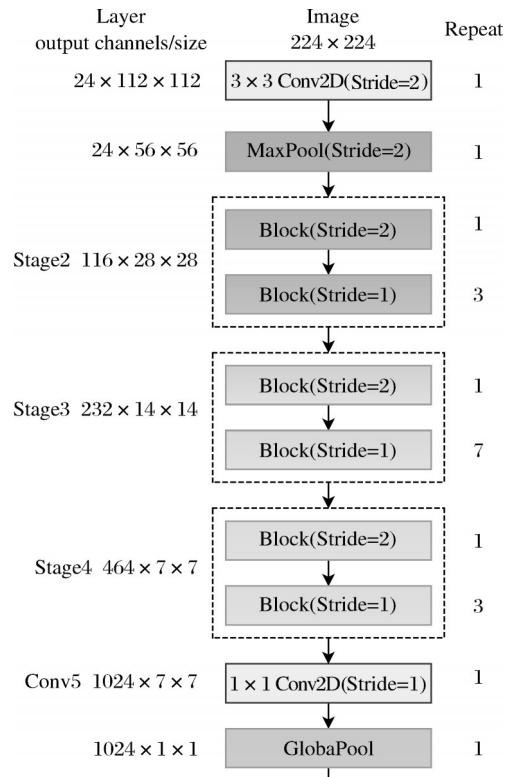


图5 ShuffleNetV2模型结构

Fig.5 ShuffleNetV2 model structure

化的实际使用需求,选择ShuffleNetV2系列中的1.0×版本作为改进模型的主干网络,在原ShuffleNetV2网络模型结构基础上,将ReLU激活函数替换为HardSwish激活函数,在基础单元和下采样单元中的 1×1 Conv后添加注意力机制ECA,同时将Stage2、3、4中基础单元重复堆叠的次数进行了调整,以降低模型的参数量和浮点运算量。基于以上改进措施提出一种识别精度更高、计算复杂度更小的饲料原料种类识别模型ShuffleNetV2-EH,网络模型整体结构如图6所示。

1)添加注意力机制ECA。注意力机制ECA凭借独特的轻量化结构设计,使得其不需要对ECA结构进行任何修改就可集成到现有的各种卷积神经网络,同时不需要手动调整特征图各通道权重,可根据输入特征图自适应调整通道权重,有效地提升网络模型对输入特征图重要特征的感知能力^[19],使模型从饲料原料图像中提取到更具代表性的特征。ECA结构示意图如图7所示。

对于通道数为C,高宽分别为H和W的输入特征图,首先对其进行全局平均池化操作,将特征图尺寸由原来的 $H \times W$ 降为 1×1 ,获取特征图全局信息

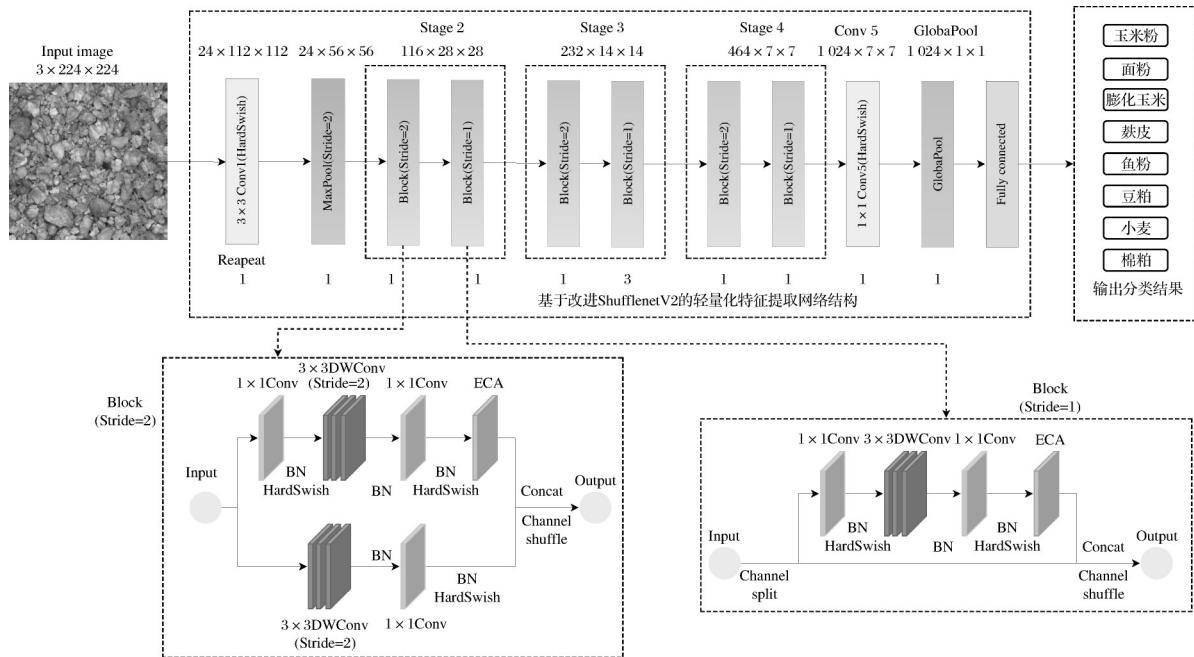


图 6 ShuffleNetV2-EH 网络模型结构

Fig.6 ShuffleNetV2-EH network model structure

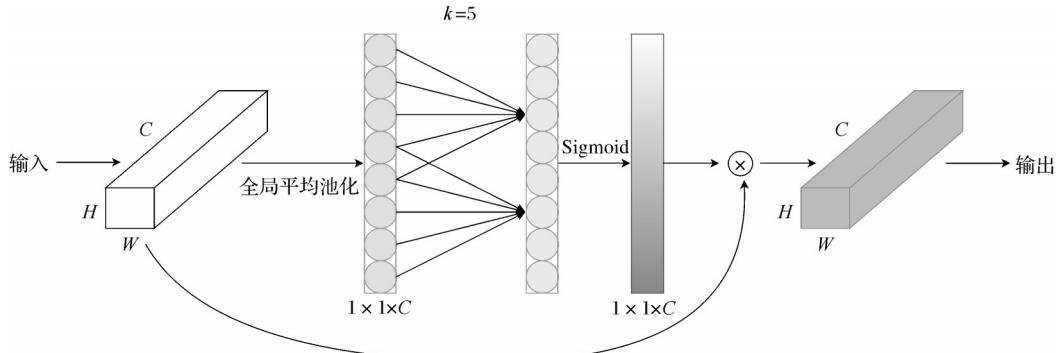


图 7 ECA 结构示意图

Fig.7 ECA structure diagram

以及各个通道的整体重要性,降低后续各通道权重的计算复杂度,随后将全局平均池化后的结果通过局部跨通道交互方法学习通道注意权重。为实现局部跨通道信息交互,需确定交互的范围(即一维卷积核的尺寸 k),而 k 和通道数 C 之间存在如公式(1)~(2)所示的映射关系。

$$C = \phi(k) = 2^{(\gamma \times k - b)} \quad (1)$$

$$k = \psi(C) = \left| \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right|_{\text{odd}} \quad (2)$$

式(1)~(2)中,通道数 C 通常设置为 2 的幂次,将线性函数 $\varphi(k) = \gamma \times k - b$ 引入到非线性函数中,根据通道数 C 自适应求得 1 个可能的解 k , γ 和 b 值一般分别设为 2 和 1,通过映射使通道拥有相应长度的相互作用,在此基础上使用一维卷积计算通道权重,并

由激活函数 Sigmoid 求得各通道权重值在 0~1 的分布,与原输入特征图相乘得到不同通道权重值下的输出特征图。

2) HardSwish 激活函数。原 ShuffleNetV2 中使用 ReLU 作为激活函数,其函数表达式如公式(3)所示,只需对输入进行判断是否大于 0,若大于 0 则输出该值,若小于等于 0 则输出 0。因此,在计算上相比于其他激活函数更加高效,能够保证网络模型的稀疏性,避免模型发生过拟合。但也存在当某个输入一直小于 0,导致该神经元一直未被激活(输出恒为 0),没有参与模型的整个训练过程中,从而损失了一部分学习能力。

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

式(3)中, $R_e(x)$ 表示 ReLU 激活函数, 为解决 ReLU 激活函数存在的“神经元坏死”问题, 使用 HardSwish 激活函数代替 ReLU。HardSwish 作为 Swish 激活函数的变体, 使用分段线性函数替换了 Sigmoid 激活函数, 降低了模型的计算成本, 优化了模型的性能和计算效率, 同时还保持了与 Swish 激活函数类似的缓解梯度消失和非单调性的优势^[20], 其表达式如式(4)所示, 其中, $H(x)$ 表示 Hardswish 激活函数。

$$H(x)=x \cdot \frac{R_e(x+3)}{6} = \begin{cases} x, & x \geq 3 \\ \frac{x \cdot (x+3)}{6}, & -3 < x < 3 \\ 0, & x \leq -3 \end{cases} \quad (4)$$

3) 模型结构调整。模型的深度(层的数量)和宽度(每层的通道数)是影响深度学习模型性能的2个主要因素, 在 ShuffleNetV2 网络模型结构中的阶段 Stage 2、3、4 中通过重复堆叠基础单元和下采样单元, 增加 Stage 中基础单元的重复次数从而加深网络深度, 使模型能够获取更深层和抽象的特征, 从而提高模型的识别精度。但增加基础单元的重复次数也面临模型计算量和参数量的增加, 以及模型在训练过程中产生过拟合的风险。根据本研究对识别模型的实际应用需求, 在不降低模型性能的前提下, 将 Stage 2、3、4 中步长为 1 的基础单元重复堆叠次数由原来的 3、7、3 次分别降为 1、3、1 次, 减少模型的计算量和参数量, 实现最佳的模型性能和计算效率的平衡。

1.6 试验环境与参数配置

本研究所有模型训练都在同一试验环境下进行, 选择的计算机硬件搭载型号为 AMD Ryzen7-5800H 的 CPU, 内存容量为 16 GB, 以及 NVIDIA GeForce RTX 3060 显卡, 系统版本类型为 Windows 10(64位)专业版, 深度学习框架为 Pytorch2.0.0, CUDA 版本为 11.7, 在 PyCharm 软件工具中使用编程语言 Python3.9 对网络模型结构进行改进。在模型训练前进行参数配置, 使用随机梯度下降(SGD)优化器计算模型训练过程中的损失函数梯度, 动态更新调整网络模型权重, 损失函数选择交叉熵函数(cross entropy), 初始学习率为 0.01, 迭代次数为 40 次, 批大小为 32, 学习率优化策略为每经过 5 次迭代学习率衰减为原来的一半。

1.7 模型评价指标

为评价添加注意力机制 ECA、使用 HardSwish 激活函数、模型结构调整对模型性能提升的效果, 使

用精确率(percision, P)、召回率(recall, R)、 F_1 分数(F_1)、准确率(accuracy, A)评价训练后的模型在测试集上的表现效果。对应计算公式分别为:

$$P = \frac{T_p}{T_p + F_p} \times 100\% \quad (5)$$

$$R = \frac{T_p}{T_p + F_n} \times 100\% \quad (6)$$

$$F_1 = \frac{P \times R}{P + R} \times 100\% \quad (7)$$

$$A = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \times 100\% \quad (8)$$

式(5)~(8)中, T_p 表示模型在测试集上将真实类别预测为真实类别数量, T_n 表示模型在测试集上将非真实类别预测为非真实类别数量, F_p 表示模型在测试集上将非真实类别预测为真实类识数量, F_n 表示模型在测试集上将真实类别预测为非真实类识数量。为探究模型轻量化的效果, 使用参数量(parameters)反映模型存储的权重和偏置的总体情况, 体现模型的大小, 以及通过浮点运算量(FLOPs)反映模型的计算复杂度和对计算资源的需求情况。

2 结果与分析

2.1 引入不同注意力机制对模型性能的影响

添加注意力机制能使模型关注输入图像数据更重要的特征部分, 提升对输入图像数据重要部分的敏感程度。为探究添加注意力机制 ECA 后对模型性能提升的效果, 以及不同的注意力机制对模型性能的影响, 分别在模型中的相同位置添加 CBAM、SE 和 SimAM 注意力机制进行对比分析, 在相同的参数设置下进行训练, 记录模型在测试集上的准确率、精确率、召回率和 F_1 分数。不同注意力机制对模型性能的影响如表 1 所示。

由表 1 可知, 使用注意力机制 ECA 的模型准确率为 98.69%, 与原 ShuffleNetV2 相比提升 0.94 百分点, 精确率、召回率、 F_1 分数与原 ShuffleNetV2 相比也分别提升 0.97、1.14、1.10 百分点, 浮点运算量保持不变, 只增加了少量的参数量, 表明 ECA 轻量化的结构设计能够有效提升模型的性能。使用不同注意力机制对模型进行对比分析, 结果表明, 添加注意力机制 ECA 相比于 CBAM、SE、SimAM 的准确率和精确率分别提升 0.38、0.30、0.56 百分点以及 0.75、0.51、1.13 百分点, 在拥有最高识别准确率的同时, 模型的参数量和浮点运算量更具有优势。综上可知, 添加注意力机制能有效提高模型对于饲料原料图像种类识别的准确率, ECA 注意力机制相比于 CBAM、SE

表1 不同注意力机制对模型性能的影响

Table 1 The impact of different attention mechanisms on model performance

| 模型 Model | 准确率/% Accuracy | 精确率/% Percision | 召回率/% Recall | F_1 /% F_1 score | 参数量 Parameters | 浮点运算量 FLOPs |
|--------------------|-------------------|--------------------|-----------------|-------------------------|-------------------|----------------------|
| ShuffleNetV2 | 97.75 | 97.68 | 97.50 | 97.51 | 1 263 854 | 149.58×10^6 |
| ShuffleNetV2+CBAM | 98.31 | 97.90 | 97.84 | 97.85 | 1 305 806 | 150.11×10^6 |
| ShuffleNetV2+SE | 98.39 | 98.14 | 98.10 | 98.09 | 1 304 222 | 149.62×10^6 |
| ShuffleNetV2+SimAM | 98.13 | 97.52 | 97.50 | 97.46 | 1 263 854 | 149.58×10^6 |
| ShuffleNetV2+ECA | 98.69 | 98.65 | 98.64 | 98.61 | 1 263 918 | 149.58×10^6 |

和 SimAM, 独特的结构设计能有效地捕捉通道之间的依赖关系, 避免大幅度增加模型的参数量和浮点运算量, 有助于提升模型的识别准确率。

2.2 引入不同激活函数对模型性能的影响

为评估将原 ShuffleNetV2 模型中用 HardSwish 激活函数替换 ReLU 激活函数的效果, 与 ReLU6 和 SiLU 激活函数进行对比(表2)。结果显示, 在识别精度方面, 使用 HardSwish 激活函数的模型准确率为

98.45%, 相比于 ReLU、SiLU 和 ReLU6 激活函数分别提升 0.7、0.14、0.18 百分点, 精确率、召回率和 F_1 分数也略高于其他 3 种激活函数; 在计算复杂度方面, 在拥有相同参数量的情况下, 相比于使用 SiLU 和 ReLU6 激活函数, 使用 HardSwish 激活函数的模型的浮点运算量分别减少 10×10^6 和 1.48×10^6 , 与 ReLU 激活函数相比减少了 1.48×10^6 , 由此可看出使用 Hardswish 激活函数后的模型综合性能表现更好。

表2 不同激活函数对模型性能的影响

Table 2 The impact of different activation functions on model performance

| 激活函数 Activation function | 准确率/% Accuracy | 精确率/% Percision | 召回率/% Recall | F_1 分数/% F_1 score | 参数量 Parameters | 浮点运算量 FLOPs |
|-----------------------------|-------------------|--------------------|-----------------|---------------------------|-------------------|----------------------|
| ReLU | 97.75 | 97.68 | 97.50 | 97.51 | 1 263 854 | 149.58×10^6 |
| SiLU | 98.31 | 97.95 | 97.90 | 97.90 | 1 263 854 | 158.10×10^6 |
| ReLU6 | 98.27 | 97.76 | 97.54 | 97.55 | 1 263 854 | 149.58×10^6 |
| Hardswish | 98.45 | 98.35 | 98.30 | 98.30 | 1 263 854 | 148.10×10^6 |

2.3 消融实验结果

为充分了解添加注意力机制 ECA、将 ReLU 替换为 HardSwish 激活函数、模型结构调整对于模型整体性能的影响, 开展消融实验, 逐个添加或移除上述

改进措施, 对各种配置下的模型进行训练, 展示所有改进措施共同作用下的综合效果并提供全面的评估, 判断以上改进措施是否配合得当, 以及能否共同提升模型的整体性能, 消融实验结果如表3所示。

表3 改进 ShuffleNetV2 模型的消融实验结果

Table 3 Improved ablation test results of ShuffleNetV2 mode

| 编号 No. | 注意力机制 ECA | 激活函数 HardSwish | 结构调整 Adjustment | 准确率/% Accuracy | 精确率/% Percision | 召回率/% Recall | F_1 分数/% F_1 score | 参数量 Parameters | 浮点运算量 FLOPs |
|--------|-----------|----------------|-----------------|----------------|-----------------|--------------|------------------------|----------------|----------------------|
| 1 | × | × | × | 97.75 | 97.68 | 97.50 | 97.51 | 1 263 854 | 149.58×10^6 |
| 2 | √ | × | × | 98.69 | 98.65 | 98.64 | 98.61 | 1 263 918 | 149.58×10^6 |
| 3 | × | √ | × | 98.45 | 98.35 | 98.30 | 98.30 | 1 263 854 | 148.10×10^6 |
| 4 | √ | √ | × | 99.26 | 99.25 | 99.25 | 99.24 | 1 263 918 | 148.10×10^6 |
| 5 | √ | × | √ | 98.15 | 98.20 | 98.15 | 98.15 | 911 826 | 103.91×10^6 |
| 6 | × | √ | √ | 96.25 | 96.10 | 95.80 | 95.79 | 911 794 | 102.83×10^6 |
| 7 | √ | √ | √ | 99.13 | 99.13 | 99.13 | 99.13 | 911 826 | 102.83×10^6 |

注: “×”表示在对应的改进模型试验编号中不添加该项改进措施, “√”表示在对应的改进模型试验编号中添加该项改进措施。Note: “×” means that the improvement measure is not added to the corresponding improvement model test number, and “√” means that the improvement measure is added to the corresponding improvement model test number.

由表3可知, 在编号1至3的实验条件下, 单独添加注意力机制 ECA 和将 ReLU 替换为 HardSwish 激活函数都能提升模型的识别精度, 在测试集上识别

准确率分别增加 0.94 和 0.7 百分点。在编号为4的试验条件下, 组合添加注意力机制 ECA 和将 ReLU 替换为 HardSwish 激活函数, 模型的识别效果最显著,

识别准确率达到99.26%，相比于原ShuffleNetV2模型，在只增加了少量参数情况下，浮点运算量减少 1.48×10^6 。在编号为5和6的试验条件下，即通过在编号为2和3的模型改进条件中调整模型结构，通过对比分析可知，结构调整对模型添加Hard-Swish激活函数的影响要比引入注意力机制ECA大，模型的准确率分别为98.15%和96.25%，较原来分别减少2.2和0.54百分点，尽管降低了模型的识别精度，但模型的参数量和浮点运算量得到了大幅减少。在编号7的实验条件下，添加所有改进措施后模型的准确率为99.13%、精确率为99.13%、召回率为99.13%、 F_1 分数为99.13%，相比于原ShuffleNetV2模型分别增加1.38、1.45、1.63和1.62个百分点，相比于编号4实验条件下的模型，准确率只降低0.13百分点。

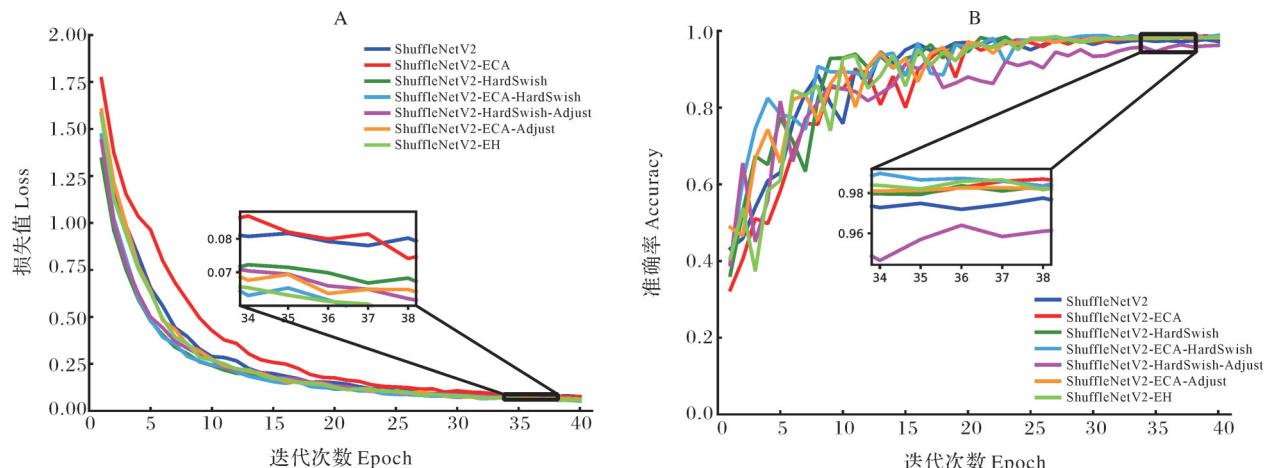


图8 不同改进模型在训练集上的损失值(A)和在验证集上的准确率(B)

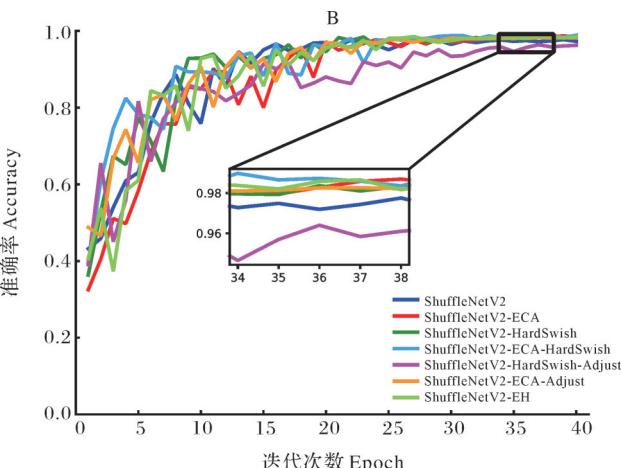
Fig.8 Loss values of different improved models on the training set(A) and accuracy of different improved models on the validation set(B)

2.4 不同模型性能对比分析

为进一步分析本研究改进的ShuffleNetV2-EH网络模型的综合性能，与经典卷积神经网络模型AlexNet、VggNet16、GoogLeNet、ResNet18以及未改

进的ShuffleNetV2进行对比，在相同的模型训练环境下对模型进行训练，记录训练完的模型大小、参数量和浮点运算量，以及在测试集上识别单张饲料原料图像的平均时间，试验结果如表4所示。

为保证消融实验结果的可靠性，所有改进模型都在相同的训练环境下进行训练，模型在编号1至7的实验条件下，在训练集上的损失值下降曲线以及验证集上的准确率曲线见图8。从图8可看出，经过40个迭代次数的训练，不同试验条件下的改进模型的损失值和准确率趋于平稳，表明模型已得到充分训练，本研究改进的ShuffleNetV2-EH模型与其他改进模型相比，在训练过程中的损失值曲线能够较早的稳定在损失值最低处，准确率曲线能够较早的稳定在准确率最高处附近。



由表4可知，ShuffleNetV2-EH网络模型相比于AlexNet、VggNet16、GoogLeNet和ResNet18准确率

分别提高8.27、4.48、3.46、0.78个百分点，精确率提高9.84、5.92、3.43、0.86个百分点，召回率提高12.58、

5.23、3.78、0.88 百分点, F_1 分数提高 13.00、5.24、3.77、0.89 百分点, 进一步验证了 ShuffleNetV2-EH 网络模型在饲料原料图像种类识别任务中的表现效果更好。且在参数量和浮点运算量上要比 AlexNet、VggNet16、GoogLeNet、ResNet18 小很多, ShuffleNetV2-EH 模型大小上只有 3.58 MB, 对于部署模型的设备计算资源需求低。在测试集上的识别单张饲料原料图像的平均时间为 8 ms, 相比于上述经典卷积神经网络模型分别减少 13、81、9、16 ms, 能够满足实时在线识别饲料原料种类的需求, 并且较好地平衡了模型的计算复杂度和识别精度, 在饲料原料种类识别任务上的表现要优于其他模型。

2.5 混淆矩阵

混淆矩阵可以用来可视化地展示分类模型的性能, 是评判模型结果的重要指标之一^[21]。使用改进的 ShuffleNetV2-EH 饲料原料种类识别模型在测试集上进行测试, 识别结果如图 9 所示。横坐标表示模型预测类别, 纵坐标表示预测图像的真实类别, 测试集共有 800 张饲料原料图像, 每一类别有 100 张。从识别结果上来看, 有 2 张膨化玉米图像被错误的预测为玉米粉, 有 3 张玉米粉图像被错误的预测为膨化玉米, 有 2 张豆粕图像被错误的预测为麸皮, 其他 5 种饲料原料图像能够被模型正确识别, 得到模型在测试集上的准确率为 99.13%、精确率为 99.13%、召回率为 99.13%、 F_1 分数为 99.13%。将识别错误的图像和数据集中被错误识别成该类别的图像进行对比如

分析, 发现从部分玉米粉和膨化玉米样品中采集的图像很相似, 原因是, 其一是经过膨化处理并进一步加工成细粉的膨化玉米的粒度和颗粒大小与玉米粉相近; 其二是膨化过程会因高温使膨化玉米的颜色发生改变, 且由于玉米本身颜色的变化范围较大, 从不同饲料厂采集不同批次的同种原料之间存在颜色差异, 导致模型难以完全区分玉米粉和膨化玉米; 同理, 发现将豆粕错误预测为麸皮的图像在粉碎程度、颜色、形状上较为相似, 导致模型难以完全将豆粕和麸皮进行区分。

3 讨论

针对人工识别粉碎程度、颜色和形状相近的入仓饲料原料较困难等问题, 本研究对 ShuffleNetV2 网络模型进行了改进, 构建了适用于饲料原料种类识别的 ShuffleNetV2-EH 轻量化模型。

本研究在 ShuffleNetV2 网络模型结构基础上添加注意力机制 ECA, 增强了模型对饲料原料图像重要特征的感知能力; 将 ReLU 替换为 HardSwish 激活函数, 有效提升模型的识别准确率; 对模型结构进行调整, 在保证模型识别精度的基础上减少了模型的参数量以及浮点运算量。

通过消融实验进一步证明本研究提出的改进措施对于提高模型识别准确率, 以及降低模型的参数量和浮点运算量具有明显的促进作用, 与原 ShuffleNetV2 模型相比, ShuffleNetV2-EH 模型的准确率提升 1.38 百分点, 与经典卷积神经网络模型进行对比, 改进模型具有更高的识别精度、更少的参数内存以及更快的识别速度。

本研究构建的饲料原料种类识别模型较好地平衡了模型的计算复杂度和识别精度, 能够实现快速识别饲料原料种类的要求, 下一步考虑采集其他饲料原料图像, 扩充饲料原料图库, 探究该模型在其他饲料原料上的识别效果。

参考文献 References

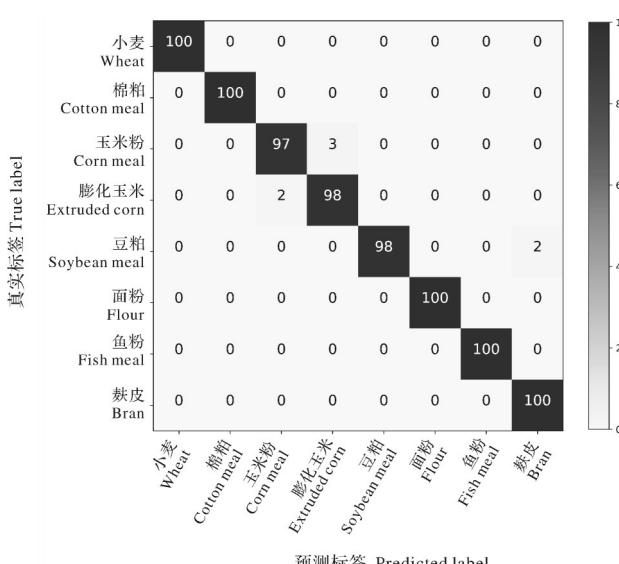


图 9 饲料原料种类识别模型的混淆矩阵

Fig.9 Confusion matrix of feed ingredient type identification model

- [1] 牛智有, 于重洋, 吴志陶, 等. 基于改进 ResNet18 模型的饲料原料种类识别方法[J]. 农业机械学报, 2023, 54(2):378-385. NIU Z Y, YU C Y, WU Z T, et al. Identification of feed raw material type based on improved ResNet18 model[J]. Transactions of the CSAM, 2023, 54 (2) : 378-385 (in Chinese with English abstract).
- [2] 张伟健, 牛智有, 刘静, 等. 粉碎机筛网破损在线自动识别装置设计与试验[J]. 农业工程学报, 2021, 37 (2) : 61-70.

- ZHANG W J, NIU Z Y, LIU J, et al. Design and experiments of online automatic identification device for screen breakage of hammer mill [J]. Transactions of the CSAE, 2021, 37(2): 61-70(in Chinese with English abstract).
- [3] CHAUDHARY P, CHAUDHARI A K, GODARA S. Color transform based approach for disease spot detection on plant leaf [J]. International journal of computer science and telecommunications, 2012, 3(6): 65-70.
- [4] 刘立波,周国民.基于多层感知神经网络的水稻叶瘟病识别方法[J].农业工程学报,2009,25(13):213-217.LIU L B, ZHOU G M. Identification method of rice leaf blast using multilayer perception neural network [J]. Transactions of the CSAE, 2009, 25 (13) : 213-217(in Chinese with English abstract).
- [5] 王献锋,张善文,王震,等.基于叶片图像和环境信息的黄瓜病害识别方法[J].农业工程学报,2014,30(14):148-153. WANG X F, ZHANG S W, WANG Z, et al. Recognition of cucumber diseases based on leaf image and environmental information [J]. Transactions of the CSAE, 2014, 30 (14) : 148-153(in Chinese with English abstract).
- [6] PATLE A, CHOUHAN D S. SVM kernel functions for classification [C]//2013 International Conference on Advances in Technology and Engineering (ICATE), January 23-25, 2013, Mumbai.Mumbai:IEEE,2013:1-9.
- [7] ZHANG S C, LI X L, ZONG M, et al. Efficient kNN classification with different numbers of nearest neighbors [J]. IEEE transactions on neural networks and learning systems, 2018, 29 (5): 1774-1785.
- [8] GOVARDHAN M, VEENA M B. Diagnosis of tomato plant diseases using random forest [C]//2019 Global Conference for Advancement in Technology (GCAT), October 18-20, 2019, Bangalore, India.Bangalore;IEEE, 2019:1-5.
- [9] KHALID S, KHALIL T, NASREEN S. A survey of feature selection and feature extraction techniques in machine learning [C]//2014 Science and Information Conference, August 27-29, 2014, London, UK.London:IEEE, 2014:372-378.
- [10] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA.Boston:IEEE, 2015:1-9.
- [11] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. Las Vegas: IEEE, 2016: 770-778.
- [12] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI.Honolulu: IEEE, 2017: 4700-4708.
- [13] 李恩霖,谢秋菊,苏中滨,等.基于深度学习的玉米叶片病斑识别方法研究[J].智慧农业导刊,2021,1(10):1-10.LI E L, XIE Q J, SU Z B, et al. Research on corn disease identification method based on deep learning [J]. Journal of smart agriculture, 2021, 1(10): 1-10(in Chinese with English abstract).
- [14] LUO Y Q, SUN J, SHEN J F, et al. Apple leaf disease recognition and sub-class categorization based on improved multi-scale feature fusion network [J]. IEEE access, 2021, 9: 95517-95527.
- [15] 孙俊,朱伟栋,罗元秋,等.基于改进 MobileNet-V2 的田间农作物叶片病害识别[J].农业工程学报, 2021, 37(22) : 161-169. SUN J, ZHU W D, LUO Y Q, et al. Recognizing the diseases of crop leaves in fields using improved MobileNet-V2 [J]. Transactions of the CSAE, 2021, 37(22) : 161-169(in Chinese with English abstract).
- [16] 彭红星,何慧君,高宗梅,等.基于改进 ShuffleNetV2 模型的荔枝病虫害识别方法[J].农业机械学报,2022,53(12):290-300. PENG H X, HE H J, GAO Z M, et al. Litchi diseases and insect pests identification method based on improved ShuffleNetV2 [J]. Transactions of the CSAM, 2022, 53(12) : 290-300(in Chinese with English abstract).
- [17] 张鹏程,余勇华,陈传武,等.基于改进 MobileNetV2 的柑橘害虫分类识别方法[J].华中农业大学学报,2023,42(3): 161-168. ZHANG P C, YU Y H, CHEN C W, et al. A classification and recognition method for citrus insect pests based on improved MobileNetV2 [J]. Journal of Huazhong Agricultural University, 2023, 42(3) : 161-168(in Chinese with English abstract).
- [18] MA N N, ZHANG X Y, ZHENG H T, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design [M]//Anon. Lecture notes in computer science. Cham: Springer International Publishing, 2018: 122-138.
- [19] WANG Q L, WU B G, ZHU P F, et al. ECA-net: efficient channel attention for deep convolutional neural networks [C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. Seattle: IEEE, 2020: 11534-11542.
- [20] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3 [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea.Seoul: IEEE, 2019: 1314-1324.
- [21] BANAN A, NASIRI A, TAHERI-GARAVAND A. Deep learning-based appearance features extraction for automated carp species identification [J/OL]. Aquacultural engineering, 2020, 89: 102053 [2024-07-11]. <https://doi.org/10.1016/j.aquaeng.2020.102053>.

A lightweight model for identifying types of feed raw material based on improved ShuffleNetV2

TIAN Min, NIU Zhiyou, LIU Meiyang

College of Engineering/Ministry of Agriculture and Rural Affairs Key Laboratory of Smart Farming for Agricultural Animals, Huazhong Agricultural University, Wuhan 430070, China

Abstract A lightweight model of ShuffleNetV2-EH with higher accuracy of identification, lower complexity of computation, and suitable for identifying the types of feed raw material based on the light-weight convolutional neural network model ShuffleNetV2 to achieve rapid identification of warehousing feed raw materials and solve the difficulties in manually identifying the types of feed raw materials with similar crushing degree, color, and shape in currently processing and producing the combined feed raw materials. Firstly, the efficient channel attention (ECA) mechanism was introduced into the structure of ShuffleNetV2 network model, which adaptively adjusts channel weights based on input to enhance the ability of network model to percept important features in images of feed raw materials. Secondly, ReLU was replaced with HardSwish activation function to improve the recognition accuracy of the model without adding additional weights and parameters of bias. Finally, the structure of ShuffleNetV2 network model was adjusted to reduce the number of parameters and the complexity of computation in the model on the basis of ensuring the recognition accuracy of model. The results showed that the recognition accuracy of ShuffleNetV2-EH model on image sets from 8 types of feed raw materials was 99.13%, 1.38% higher than that of the original ShuffleNetV2 model. Its accuracy, recall, and F_1 score increased by 1.45%, 1.63%, and 1.62%, respectively. The number of model parameters and floating-point operations decreased by 352 092 and 45.27×10^6 , compared to that of the original model. The overall performance was superior to classical convolutional neural network models including AlexNet, VggNet16, GoogLeNet, and ResNet18. It is indicated that the improved ShuffleNetV2 model well balances the complexity of computation and the recognition accuracy of the model, providing an algorithm foundation for online identification of feed raw materials in the warehousing process.

Keywords feeds; type identification; lightweight model; ShuffleNetV2; efficient channel attention (ECA)

(责任编辑:陆文昌)