

王伟杰, 曹嘉璇, 李阳, 等. 基于改进 MobileNetV2 的医疗废物智能分类研究[J]. 智能计算机与应用, 2025, 15(5): 1-9.
DOI:10.20169/j.issn.2095-2163.24121205

基于改进 MobileNetV2 的医疗废物智能分类研究

王伟杰¹, 曹嘉璇¹, 李阳¹, 邹北骥², 赵国英^{1,3,4}, 刘青萍^{1,3}

(1 湖南中医药大学 信息科学与工程学院, 长沙 410208; 2 中南大学 计算机学院, 长沙 410083; 3 湖南省科技厅智慧中医工程技术研究中心, 长沙 410699; 4 奥卢大学 机器视觉与信号分析中心, 奥卢 90570, 芬兰)

摘要: 随着医疗服务需求的增长, 医疗废物的产生量逐渐超出负荷, 当前医疗废物的分类与包装多以人工为主, 存在医护人员感染病毒风险高、工作效率低下等问题。针对上述问题, 本研究在 MobileNetV2 模型的基础上, 提出一种改进 MobileNetV2 的医疗废物智能分类模型 (MobileNetV2-MW)。通过改进瓶颈残差模块, 捕捉不同特征通道之间的关系, 提升模型对图像信息的特征提取能力; 同时, 引入一种多尺度特征融合模块, 增强模型对图像多尺度信息的适应能力, 避免模型过度关注某一特定尺度带来的不良影响。实验结果表明, MobileNetV2-MW 模型在医疗废物图像数据集上的分类准确率、精准率、召回率和 $F1 - Score$ 分别达到 95.38%、95.36%、95.33% 和 95.30%, 相比于 MobileNetV2 模型分别提升了 3.18%、3.05%、3.23% 和 3.21%, 在对比模型中分类效果优秀, 最后通过 t-SNE 可视化分析和泛化实验进一步验证了该模型的有效性, 为医疗废物智能分类研究提供了新的思路和方法。

关键词: 医疗废物智能分类; 图像处理; MobileNetV2; 特征提取; 多尺度特征融合; 深度学习

中图分类号: X799.5 文献标志码: A 文章编号: 2095-2163(2025)05-0001-09

Research on intelligent classification of medical waste based on an improved MobileNetV2 model

WANG Weijie¹, CAO Jiakuan¹, LI Yang¹, ZOU Beiji², ZHAO Guoying^{1,3,4}, LIU Qingping^{1,3}

(1 School of Informatics, Hunan University of Chinese Medicine, Changsha 410208, China;

2 School of Computer Science, Central South University, Changsha 410083, China; 3 AI TCM Lab Hunan,

Changsha 410699, China; 4 Center for Machine Vision and Signal Analysis, University of Oulu, Oulu 90570, Finland)

Abstract: With the increasing demand for healthcare services, the volume of medical waste generation has gradually exceeded capacity. Currently, the classification and packaging of medical waste primarily rely on manual operations, which pose high risks of viral infections for healthcare workers and result in low efficiency. To address these challenges, this study proposes an improved MobileNetV2-based intelligent classification model for medical waste (MobileNetV2-MW). By enhancing the bottleneck residual module, the model captures relationships between different feature channels, improving its feature extraction capability for image data. Furthermore, a multi-scale feature fusion module is introduced to enhance the model's adaptability to multi-scale image information, avoiding the adverse effects of overemphasizing specific scales. Experimental results show that the MobileNetV2-MW model achieves a classification accuracy, precision, recall, and $F1 - Score$ of 95.38%, 95.36%, 95.33%, and 95.30%, respectively, on the medical waste image dataset. These represent improvements of 3.18%, 3.05%, 3.23%, and 3.21% over the baseline MobileNetV2 model. The proposed model demonstrates superior classification performance compared to other models. Finally, t-SNE visualization analysis and generalization experiments further validate the effectiveness of the model, offering new insights and methods for intelligent medical waste classification research.

Key words: intelligent classification of medical waste; image processing; MobileNetV2; feature extraction; multi-scale feature fusion; deep learning

基金项目: 国家重大科技专项项目(2018AAA0102100); 国家自然科学基金青年基金(62402180); 湖南省自然科学基金青年基金(2024JJ6338); 湖南省普通高等学校教学改革研究项目(HNJG-20230527); 2023年湖南中医药大学研究生科研创新项目(2023CX134)。

作者简介: 王伟杰(2001—), 男, 硕士研究生, 主要研究方向: 医学图像处理, 深度学习; 赵国英(1977—), 女, 教授, 博士生导师, 主要研究方向: 计算机视觉, 机器学习, 情感智能。

通信作者: 刘青萍(1982—), 女, 博士, 教授, 主要研究方向: 中医辅助临床决策支持系统, 数据挖掘与知识发现, 人工智能。Email: liuliu@hnuocm.edu.cn。

收稿日期: 2024-12-12

哈尔滨工业大学主办 ◆ 学术研究与应用

0 引言

医疗废物(Medical Waste, MW)主要产生自医疗、保健、实验等活动,包括可能携带传染性病菌、病毒及化学污染物的废弃物,给人类生活带来极大危险^[1]。随着医疗卫生服务的不断发展,医疗废物的数量和危险性仍在增加。根据国家卫生健康委员2024年1~4月全国医疗服务数据,全国医疗卫生机构的诊疗人次已超过25亿,同比增长15.9%^[2],随之产生大量医疗废物。医疗废物的处理流程通常包括分类、分拣、包装、标识、临时存储和处置^[3],其中大量废物需要分类和包装以便妥善处理。医疗废物智能分类能有效减少废物分类中的人力成本,提高分类效率并降低医护人员受医疗废物中病毒二次感染的风险^[4],对于医疗卫生服务领域的可持续发展具有重要意义。如何实现医疗废物的智能分类是目前亟待解决的关键问题之一。

近年来,随着深度学习技术的快速崛起,卷积神经网络(Convolutional Neural Network, CNN)因为其强大的学习能力和多样的功能逐步被应用在计算机视觉^[5]、自然语言处理^[6]等领域。目前,在医疗废物智能分类领域,卷积神经网络的相关研究不断涌现。谈笑^[7]提出了一种基于BP神经网络的医疗废物分类模型,该模型能对医疗废物进行有效识别分类。Chen等学者^[8]设计了一种名为R3D+C2D的新型卷积神经网络模型,针对4种医疗废物的分类准确率达到79.99%。Cai等学者^[9]基于YOLO-ResNet18深度学习模型,设计了一种基于机器视觉的智能医疗废物分类系统,该系统医疗废物分类准确率达到90%。Mythili等学者^[10]提出了一种EnSegNet-DNN-TC模型,对来自垃圾图像数据集中不同类别的100张生物医学废物图像进行识别,准确率达到88%。Zhou等学者^[11]利用ResNeXt卷积神经网络和迁移学习,在3480张图像上成功实现了8种医疗废物的高准确率分类,最终准确率为97.2%。传统卷积神经网络的医疗废物智能分类方法已具有较高准确率,但通常需要大量数据、较大的计算量和较长的训练周期,在硬件资源有限的情况下难以满足深度学习的需求。此外,现有研究所使用数据集的医疗废物种类较少、样本特征丰富度较低,导致模型泛化能力较差。

针对上述问题,本研究提出了一种基于改进轻量级卷积神经网络MobileNetV2的医疗废物智能分类模型,称为MobileNetV2-MW。本研究的主要贡

献总结如下:

(1)运用网络爬虫技术创建了超过6000张图片的10类医疗废物图像数据集,可广泛应用于医疗废物图像研究。同时,对数据集进行数据增强,丰富样本特征,提高训练模型的泛化能力和鲁棒性。

(2)通过改进瓶颈残差模块,有效捕捉输入图像中不同特征通道之间的关系,提升对图像关键特征信息的动态感知能力。

(3)通过引入多尺度特征融合模块,避免模型过度关注某一单一尺度特征的潜在问题,提升模型对复杂场景的适应能力。

(4)基于医疗废物图像数据集开展实验研究,通过消融实验评估各个模块的有效性,并与先进的卷积神经网络模型进行对比实验,评估模型分类性能。为验证模型的鲁棒性与泛化能力,本研究还通过t-SNE可视化分析探索特征分布,并在2个不同类型的垃圾分类数据集上进行泛化实验。实验结果表明,本研究提出的模型在多个测试指标上均达到具有竞争力的性能,验证了模型的有效性,为医疗废物的智能分类研究提供了一种新的技术思路和方法。

1 数据集获取与预处理

1.1 数据集获取

本研究参照浙江大学第一附属医院2019年收集的医疗废物图像数据集^[11],选择口罩、棉签、药瓶、注射器、输液袋、纱布、手套、镊子和手术剪刀10种常用医疗废物进行分类研究。本研究运用网络爬虫技术^[12],成功实现了爬取医疗废物图像的任务。10类医疗废物的示例图像如图1所示。



图1 10类医疗废物的示例图像

Fig. 1 Example images of 10 categories of medical waste

1.2 数据集预处理

通过百度图片、360图片和谷歌图片三个网站平台爬取医疗废物图像,共收集到20000张医疗废物原始图像。通过人工筛选和整理,剔除存在类别不符、带有大量水印、模糊不清或者图像特征不明显

等问题的图像数据,最终得到 10 种医疗废物图像,共计 6 662 张。数据集分类和相应的样本数量具体见表 1。由表 1 可知,10 种医疗废物的图像样本数量基本平衡,其中输液器样本数量最多(687 张),口罩样本数量最少(657 张),均衡的样本数量分布有利于提高分类模型的稳定性和准确性^[13]。

表 1 数据集类别和相应的样本数量

Table 1 Dataset category and corresponding sample size

序号	医疗废物名	样本数量/张
1	口罩	657
2	棉签	659
3	药瓶	662
4	注射器	667
5	输液袋	666
6	输液器	687
7	纱布	663
8	手套	666
9	镊子	674
10	手术剪刀	661
总计		6 662

1.3 数据增强

本研究对数据集进行随机划分,按照 7 : 2 : 1 的比例划分为训练集、验证集和测试集^[14],并对训

练数据集进行了数据增强处理。具体处理过程如下:首先,通过缩放、旋转、剪切、平移、翻转、高斯噪声和拉伸变换 7 种方式对数据进行增强^[15],随机选择参数,应用于每张图像。其次,对增强后的数据进行筛选,对质量低和噪声过大的数据进行替换或删除。最后,获得样本特征丰富且样本数量分布均匀的医疗废物图像共 22 828 张。

2 医疗废物智能分类模型构建

2.1 MobileNetV2-MW 网络模型

本研究提出改进的医疗废物智能分类模型 MobileNetV2-MW。该模型通过优化瓶颈残差模块和引入多尺度特征融合模块,在保持快速推理和低硬件需求的同时,有效提取医疗废物图像特征。模型结构如图 2 所示,主要包括 3 部分:特征提取网络、特征融合网络和分类网络。特征提取网络中,改进的瓶颈残差模块通过加权不同通道的信息,逐级生成特征图,增强了模型对通道间关系的感知能力。特征融合网络引入多尺度特征融合模块,通过多分支结构进行特征处理,提升感受野,从而全面提取医疗废物图像的多尺度特征。分类网络由一个自适应最大池化层和一个包含全连接层的分类器组成,用于提取全局特征并实现医疗废物图像的最终分类。

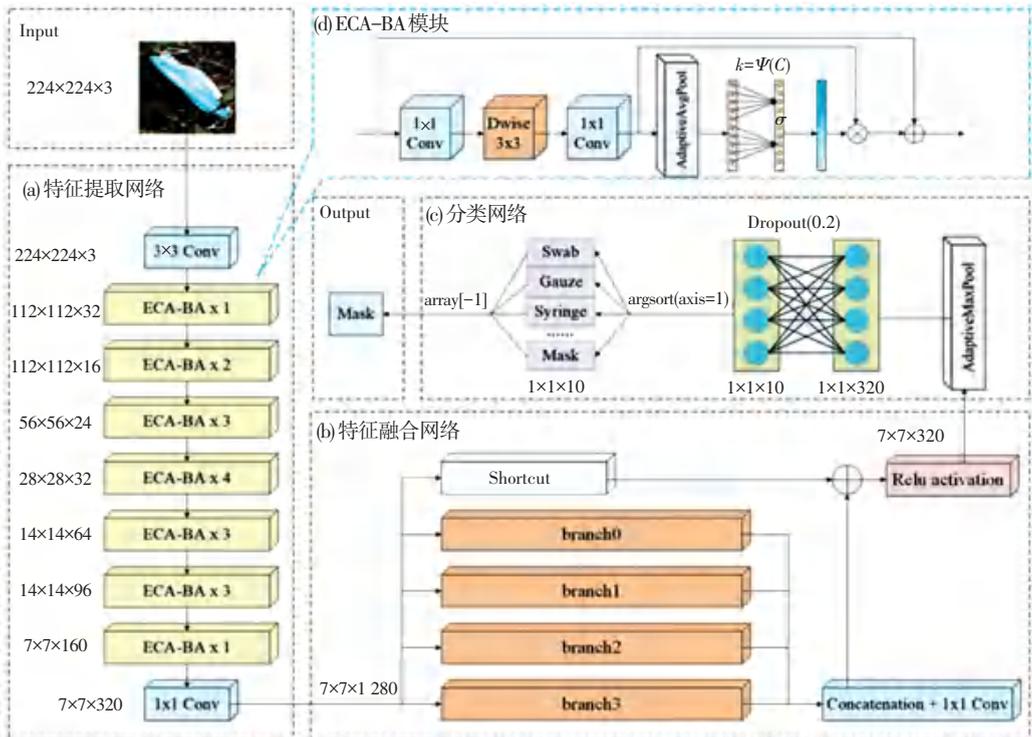


图 2 MobileNetV2-MW 网络结构图

Fig. 2 MobileNetV2-MW network architecture

2.2 ECA-BA 模块

在通道信息处理中,传统卷积神经网络通常对所有通道赋予相同的权重,缺乏对关键通道信息的动态感知能力,容易导致重要特征被稀释或无效特征被过度利用,限制了模型对复杂图像的描述能力^[16]。为此,本研究基于瓶颈残差模块提出了一种新的特征提取方法,ECA-BA 模块(Efficient Channel Attention - based block Aggregation module, ECA - BA)。通过自适应调整通道权重,动态突出包含关键信息的通道,抑制无关和冗余特征,有效提升网络对通道间关系的感知能力^[17]。ECA-BA 模块结构如图 2(d)所示。具体而言,输入特征图首先通过扩展比例调整生成隐含特征通道,经过逐层卷积操作提取深度特征:包括 1×1 卷积用于通道扩展、 3×3 深度卷积用于空间特征提取,以及线性 1×1 卷积用于通道压缩。随后,利用自适应全局池化计算通道间的权重关系,并通过一维卷积动态调整通道权重,增强模型对关键特征的感知能力。该模块在保持模型计算效率的同时,增强了分类模型对关键特征的提取能力。算法 1 描述具体流程。

算法 1 ECA-BA 模块

输入 特征图 x , 大小为 $C_{in} \times H \times W$

输出 特征图 y , 大小为 $C_{out} \times H \times W$

1. 获取输入特征图大小:

$batch_size, channels, height, width = x.shape$

2. 进行通道扩展:

$C_{mid} = channels \times expand_ratio$

$Y1 = ReLU6(BatchNorm(Conv2D(x, kernel_size = 1, out_channels = C_{mid}, stride = 1, padding = 0)))$

3. 执行深度可分离卷积:

$Y2 = BatchNorm(DepthwiseConv2D(Y1, kernel_size = 3, stride = stride, padding = 1, groups = C_{mid}))$

4. 通道压缩并应用线性投影:

$Y3 = BatchNorm(Conv2D(Y2, kernel_size = 1, out_channels = C_{out}, stride = 1, padding = 0))$

5. 生成通道权重:

$GlobalFeatures = AdaptiveAvgPool2D(Y3, output_size = (1, 1))$

$ChannelWeights = Sigmoid(Conv1D(GlobalFeatures, kernel_size = k_size, stride = 1, padding = (k_size - 1) // 2))$

6. 调整权重的尺寸以匹配输入特征图:

$Y4 = Y3 \times ChannelWeights$

7. 如果步幅为 1 且输入输出通道数相等,则进

行残差连接:

if $stride == 1$ and $channels == C_{out}$:

$y = x + Y4$

else:

$y = Y4$

8. 返回加权后的特征图 y :

return y

2.3 RFB-s 多尺度特征融合模块

医疗废物图像存在背景复杂、噪声较多等特性,传统方法难以有效区分目标特征与背景区域,特征提取效率和分类精度受到限制。同时,传统卷积神经网络依赖固定尺寸的卷积核处理图像特征,难以同时捕捉不同尺度上的细节信息^[18],尤其是对于医疗废物图像中尺寸、形状、颜色差异较大的情况,表现出一定局限性。为解决这一问题,本研究引入了 RFB-s 多尺度特征融合模块(Receptive Field Blocks with multi-scale feature fusion module, RFB - s)。RFB-s 模块的结构如图 3 所示。

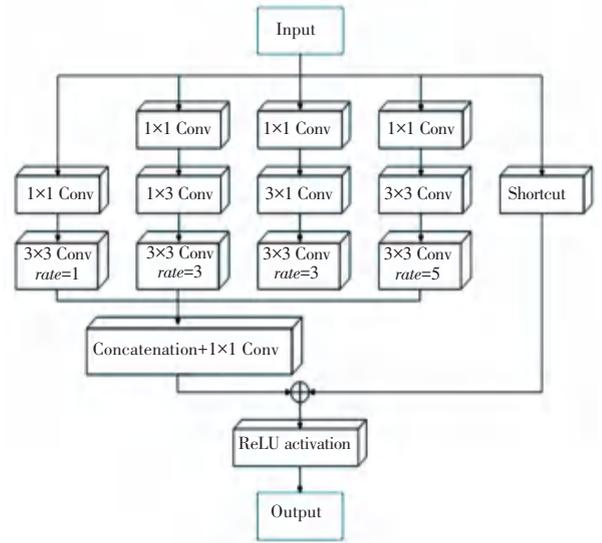


图 3 RFB-s 模块图

Fig. 3 RFB-s module diagram

该模块采用多分支设计,从左至右依次包括 branch0、branch1、branch2 和 branch3 四个分支,具体结构见图 2(b)。通过不同的卷积操作,每个分支实现对输入特征的多尺度感知,并捕捉不同方向和尺度的纹理及特征信息,从而增强特征表达能力。branch0 采用 1×1 卷积和 3×3 卷积 ($rate = 1$),用于提取局部的基础特征信息;branch1 和 branch2 在 1×1 卷积的基础上,分别引入水平方向(卷积核为 1×3)和垂直方向(卷积核为 3×1)的卷积操作,捕捉特定方向上的特征变化,并通过 3×3 卷积 ($rate = 3$)进一步提取细粒度的纹理信息。结合 1×1 卷积、 $3 \times$

3 卷积和空洞卷积 ($rate = 5$) 构建多步卷积结构。branch3 通过使用多种不同尺寸的卷积核,扩大感受野,捕捉全局特征与上下文信息,弥补其他分支在大尺度特征提取上的不足。4 个分支提取的特征在通道维度上进行拼接后,使用 1×1 卷积以融合不同尺度的特征信息。最终通过短连接机制 (Shortcut) 直接引入输入特征,确保网络的梯度流畅性并增强特征表达能力。具体地,分支内部的卷积操作和特征融合过程可用下式描述为:

$$Z_{ij} = Conv(Conv(X, W_{ij}), W_{ij}) \quad (1)$$

其中, Z_{ij} 表示第 i 个分支内第 j 次卷积操作的输出; $Conv$ 为卷积操作; X 为输入特征图; W_{ij} 为相应的卷积核。随后,将各卷积操作结果进行连续乘积,具体公式为:

$$P_i = \prod_{j=1}^3 Z_{ij} \quad (2)$$

其中, P_i 表示第 i 个分支内所有卷积操作结果的连续乘积。接着,将各分支的输出通过加权融合,并引入短连接以强化特征表达,表示形式见下式:

$$M = \sum_{i=0}^3 (P_i \cdot W_{linear} + Conv(X, W_{shortcut})) \quad (3)$$

其中, M 表示多分支加权融合并添加短连接后的输出; W_{linear} 表示特征融合的权重参数; $W_{shortcut}$ 表示短连接的权重参数。最后,应用 ReLU 激活函数对融合结果进行非线性变换,得到最终的输出特征图。

3 实验与结果分析

3.1 实验设置

本研究采用 Pytorch2.0.1 框架对模型进行搭建。硬件环境如下:15 vCPU Intel (R) Xeon (R) Platinum 8358P CPU@2.60 GHz 处理器, Nvidia A40 GPU (48 GB)。软件环境如下: Pycharm 2023.1、Anaconda2023.3、Python3.8、CUDA11.7。超参数设置如下:批处理大小 (batch size) 为 32,学习率 ($learning\ rate$) 为 $10e-4$,迭代次数 ($epoch$) 为 200。

3.2 评价指标

研究采用模型大小 ($Model\ size$)、模型参数量

($Params$) 和浮点运算总量 ($FLOPs$) 作为衡量模型复杂度和计算性能的指标。同时,使用准确率 ($Accuracy$)、精准率 ($Precision$)、召回率 ($Recall$)、 $F1 - Score$ 作为评价模型分类性能的指标^[19]。4 类指标公式具体如下:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

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

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (7)$$

其中, TP 表示模型预测为正的正样本数; TN 表示模型预测为负的负样本数; FP 表示模型预测为负的正样本数; FN 表示模型预测为正的负样本数。

3.3 消融实验

本研究在构建的医疗废物图像数据集上,测试 MobileNetV2-MW 模型的性能。通过消融实验对改进点逐个进行测试,对比各项评价指标来验证各个改进点的有效性。消融实验结果见表 2,最优指标加粗表示。由表 2 实验结果可知, MobileNetV2 模型在采用 ECA-BA 模块后, $Accuracy$ 由 92.20% 提升至 93.95%, $Precision$ 、 $Recall$ 和 $F1 - Score$ 也分别提高了 1.79%、1.79% 和 1.82%,表明 ECA-BA 模块能够有效提升网络的特征提取能力,进而提高模型的分​​类准确率。 MobileNetV2 模型在引入 RFB-s 多尺度特征融合模块后, $Accuracy$ 、 $Precision$ 、 $Recall$ 和 $F1 - Score$ 分别提升了 1.43%、1.46%、1.47% 和 1.51%。表明 RFB-s 模块可以通过优化模型的感知能力和多尺度特征提取能力,提高模型的分​​类准确率。 MobileNetV2-MW 模型融合了 ECA-BA 模块与 RFB-s 多尺度特征融合模块,相比于原始的 MobileNetV2 模型, $Accuracy$ 提升了 3.18%。由此可知,基于原始的 MobileNetV2 网络模型,通过融合 ECA-BA 模块和 RFB-s 模块,可以取得更好的分类效果。

表 2 消融实验结果

Table 2 Ablation results

模型	$Accuracy$	$Precision$	$Recall$	$F1 - Score$	%
MobileNetV2	92.20	92.31	92.10	92.09	
MobileNetV2+ECA-BA	93.95	94.10	93.89	93.91	
MobileNetV2+RFB-s	93.63	93.77	93.57	93.60	
MobileNetV2-MW(本文)	95.38	95.36	95.33	95.30	

3.4 对比实验

为验证改进后模型的分类效果,本研究选取了 LeNet、AlexNet、ResNet50、以及近年来表现良好的轻量级模型 MobileNetV2、MobileNetV3、ShuffleNetV2、ConvNeXt 进行对比实验,数据集采用相同的医疗废物图像数据集,实验设置均相同。经过 200 次迭代后,对比实验结果见表 3。本研究提出的 MobileNetV2-MW 与其他模型相比, *Accuracy*、

Precision、*Recall*、*F1 - Score* 结果均为最高,比 LeNet、AlexNet、ResNet50、MobileNetV3、ShuffleNetV2、ConvNeXt 分别提高了 25.95%、11.46%、0.48%、2.23%、5.41%、21.02%。同时 *Model size*、*Params* 比 LeNet、AlexNet、ResNet50、MobileNetV3、ConvNeXt 更低,与轻量级卷积神经网络 MobileNetV2、ShuffleNetV2 相比在医疗废物智能分类任务上具有较高性能。

表 3 对比实验结果

Table 3 Comparison of experimental results

模型	<i>Accuracy</i> /%	<i>Precision</i> /%	<i>Recall</i> /%	<i>F1 - Score</i> /%	<i>Model size</i> /MB	<i>Params</i> /M	<i>FLOPs</i> /M
LeNet ^[20]	69.43	70.73	69.17	68.78	41.24	10.81	173.98
AlexNet ^[21]	83.92	83.84	83.79	83.64	55.66	14.59	274.03
ResNet50 ^[22]	94.90	94.99	94.83	94.85	87.72	22.99	4 207.48
MobileNetV2	92.20	92.31	92.10	92.09	8.53	2.24	319.06
MobileNetV3 ^[23]	93.15	93.52	93.09	93.07	16.08	4.21	229.36
ShuffleNetV2 ^[24]	89.97	90.30	89.90	89.89	4.82	1.26	146.28
ConvNeXt ^[25]	74.36	74.17	74.12	73.92	334.06	87.52	15 340.87
MobileNetV2-MW(本文)	95.38	95.36	95.33	95.30	9.55	2.50	332.70

3.5 混淆矩阵对比

本研究利用混淆矩阵图评估模型分类效果^[26],混淆矩阵中行标签表示预测的真实类别,列标签表示模型推理类别,对角线上的值代表 *TP* 值,对角线数据颜色越蓝、数字越大,则代表正确分类数据结果越好,分类性能越好。MobileNetV2-MW 混淆矩阵改进对比如图 4 所示。由图 4 可知,针对 MobileNetV2 模型,10 类医疗废物中,第 6 类医疗废物(输液器)的对角线数据 *TP* 值最高、颜色最深,表明其分类效果最好;第 5 类医疗废物(输液袋)的对角线数据 *TP* 值最低、颜色最浅,表明其分类结果最低。第 5 类医疗废物(输液袋)主要被错分类成了第 4 类医疗废物(注射器),其错误识别的主要原因是输液袋和注射器在颜色和材质上有一定的重叠,

两者可能都使用透明或半透明的塑料,这使得在图像中两者的外观非常相似。使用 MobileNetV2-MW 模型后这种现象得到一定改善。本研究构造的 MobileNetV2-MW 模型通过优化瓶颈残差模块结构,并结合多尺度特征融合模块,与原模型 MobileNetV2 相比,在 10 种医疗废物类别分类任务中分类性能得到了提升,特别是针对第 1 类(口罩)、第 4 类(注射器)、第 5 类(输液袋)、第 7 类(纱布)和第 10 类(手术剪刀)。MobileNetV2-MW 模型的平均分类准确率为 95.38%,体现了该模型用于医疗废物智能分类的准确性和可靠性。从以上混淆矩阵结果对比中可以看出,本研究提出的 MobileNetV2-MW 模型在医疗废物分类识别上具有一定优势。

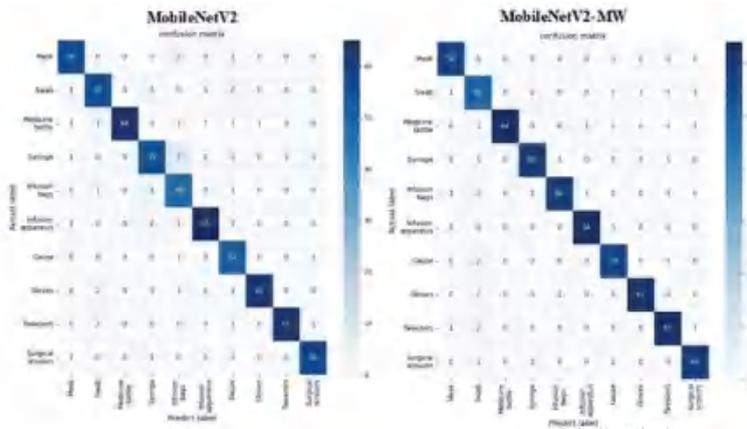


图 4 MobileNetV2-MW 混淆矩阵改进对比

Fig. 4 Comparison of improvements in MobileNetV2-MW confusion matrices

3.6 t-SNE 可视化分析

为了更直观地展示分类效果,本研究采取 t-SNE 方法对高维数据进行降维表达,将数据分布规律进行可视化展示^[27]。通过对各模型最后一层全连接层进行测试集语义特征提取,得到的二维平面效果如图 5 所示。由图 5 可知:LeNet 模型测试集的准确率为 69.43% 和 AlexNet 模型测试集的准确率为 83.92%,各类数据呈现混乱无序,没有形成清晰的簇结构。在 ShuffleNetV2 和 ConvNeXt 模型的二

维映射中,虽然形成了一部分簇结构,但各簇之间交叉过多,模型对各类医疗废物种类的特征区分并不理想。与之相比,ResNet50、MobileNetV2 和 MobileNetV3 的二维语义特征映射效果显著提升,但 MobileNetV2-MW 模型中各类医疗废物之间的特征间隔更为明显,且特征聚类更为集中。通过 t-SNE 可视化对比分析可知,MobileNetV2-MW 模型在各类医疗废物的分类中表现最佳,具有出色的分类效果,进一步验证了该模型的可靠性。

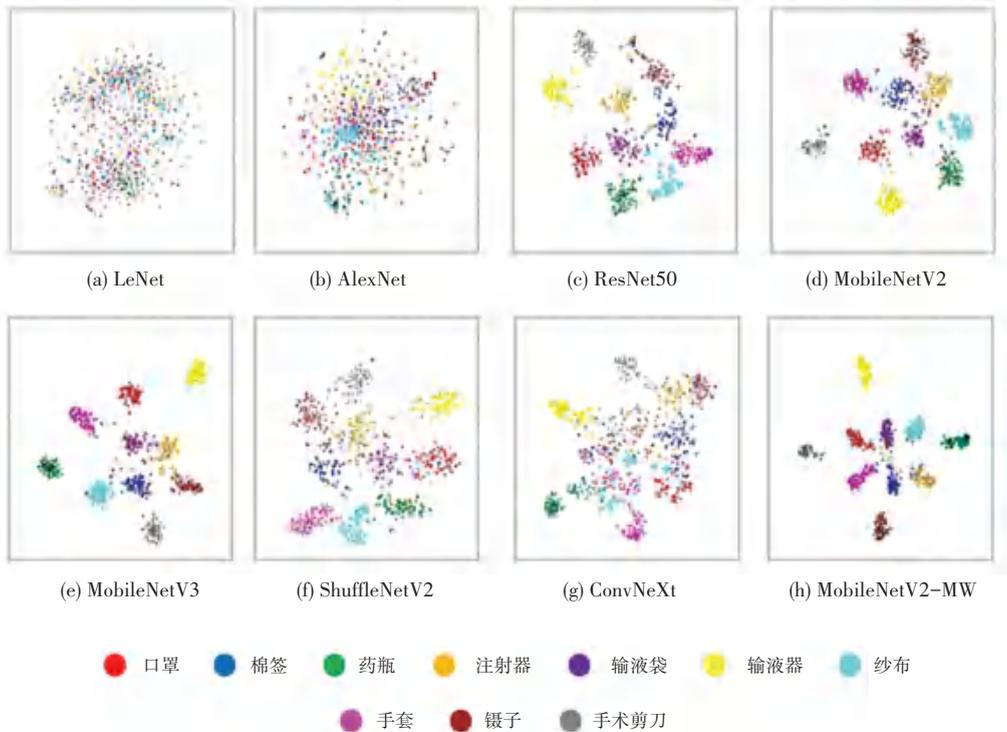


图 5 各模型 t-SNE 可视化结果

Fig. 5 Visualization results of t-SNE for each model

3.7 泛化实验

本研究对垃圾分类领域的 2 个公共数据集进行泛化实验,以测试所提出的 MobileNetV2-MW 模型的稳定性和鲁棒性。Drinking Waste 数据集由伦敦大学提供,包含 4 种不同的饮料废弃物类别:铝罐、玻璃瓶、PET(塑料)瓶和 HDPE(塑料)牛奶瓶,包含 4 820 张图像。Waste Classification data 数据集主要分为有机和可回收两个类别,包含 25 077 张图像。

在实验中,在 2 个数据集上重新进行训练和测试,实验设置不变,按照 7 : 2 : 1 的比例将数据集随机划分为训练集、验证集和测试集。表 4 展示了不同网络模型在 2 个数据集上的性能测试结果。针对

Drinking Waste 数据集,MobileNetV2-MW 取得了最佳性能,其准确率为 92.92%,精确率、召回率和 F1 - Score 均较其他模型更高。而在 Waste Classification data 数据集上,ResNet50 和 MobileNetV2-MW 表现最佳,其准确率分别达到了 83.25% 和 83.57%,超过了其他模型。ResNet50 在准确率、精确率、召回率和 F1 - Score 等指标上均稍逊于 MobileNetV2-MW。综合而言,MobileNetV2-MW 在 2 个数据集上均表现出色,显示出较高的分类性能,展现了模型出色的泛化能力和鲁棒性,为该研究提供了可靠的实验结果支持。

表4 不同网络模型在2个数据集上的性能测试

Table 4 Test performance of different network models on 2 datasets

%

Dataset	Model	Accuracy	Precision	Recall	F1 - Score
Drinking Waste ^[28]	LeNet	56.25	56.17	55.24	55.50
	AlexNet	83.96	83.98	83.85	83.89
	ResNet50	91.46	91.98	91.19	91.46
	MobileNetV2	90.62	90.80	90.35	90.51
	MobileNetV3	91.67	92.29	91.48	91.69
	ShuffleNetV2	86.04	86.19	85.75	85.94
	ConvNeXt	42.50	42.23	40.07	39.66
	MobileNetV2-MW(本文)	92.92	92.79	92.60	92.68
Waste Classification data ^[29]	LeNet	77.64	78.88	76.08	76.47
	AlexNet	80.06	81.70	78.51	79.00
	ResNet50	83.25	84.73	81.91	82.47
	MobileNetV2	80.58	81.85	79.19	79.67
	MobileNetV3	81.89	83.92	80.32	80.89
	ShuffleNetV2	81.70	82.18	80.72	81.10
	ConvNeXt	80.50	80.83	79.55	79.89
	MobileNetV2-MW(本文)	83.57	85.05	82.25	82.81

4 结束语

本研究提出一种基于改进 MobileNetV2 的医疗废物智能分类模型 MobileNetV2-MW。通过改进瓶颈残差模块,捕捉不同通道之间的关系,解决特征提取过程中容易忽视或过度依赖某些特征通道的问题,从而提高分类准确率。此外,引入 RFB-s 多尺度特征融合模块,捕捉医疗废物在不同尺度上的细节和特征,避免模型过度关注某一特定尺度,从而增强模型的泛化能力。MobileNetV2-MW 模型提高了医疗废物分类任务的准确性,同时具有较小的参数量与内存占有量,并在 t-SNE 可视化分析和泛化实验中展现出模型良好的泛化能力与鲁棒性。研究采用了数据增强技术扩充数据集,但仍存在数据量不足和数据质量不高的问题,限制了算法模型的泛化能力和准确性。因此,未来的研究可以继续提升数据集的质量和多样性,以及将模型应用于实际医疗废物分类系统中并进行更广泛的验证。

参考文献

[1] 马艳芳,刘畅,黄思雨,等. 考虑运营风险的医疗废物回收选址多目标鲁棒优化研究[J]. 计算机工程与应用, 2025, 61(1): 341-351.

[2] 曹成霖,曹文文,孟飞跃,等. 增权赋能视域下基层医疗卫生服务质量持续改进及实现路径研究[J]. 中国全科医学, 2024, 27(1): 9-14.

[3] 魏诗晴,涂敏,赖晓全,等. 我国各类医疗机构部分医疗废物分类处置现状[J]. 中国感染控制杂志, 2021, 20(9): 782-787.

[4] 罗叶辉. 上海市公立医院垃圾分类政策执行问题研究[D]. 上海: 华东师范大学, 2023.

[5] 袁浩天,朱正铭,宋燕,等. 基于卷积神经网络的甲状腺癌超声图像分类[J]. 智能计算机与应用, 2024, 14(8): 169-173.

[6] LIU J, LI K, ZHU A, et al. Application of deep learning-based natural language processing in multilingual sentiment analysis[J]. Mediterranean Journal of Basic and Applied Sciences (MJBAS), 2024, 8(2): 243-260.

[7] 谈笑. 基于 BP 神经网络的医疗废物识别与分类研究[J]. 电子设计工程, 2019, 27(24): 6-10.

[8] CHEN Junbo, MAO J, THIEL C, et al. iWaste: Video-based medical waste detection and classification[C]// Proceedings of the 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). Piscataway, NJ: IEEE, 2020: 5794-5797.

[9] CAI Z, BIAN T, BAI C, et al. Intelligent medical waste detection and classification system based on machine vision [C]// International Conference on Image, Signal Processing, and Pattern Recognition (ISPP 2023). San Francisco, CA: SPIE, 2023, 12707: 163-170.

[10] MYTHILI T, ANBARASI A. Enhanced segmentation network with deep learning for Biomedical wasteclassification[J]. Indian Journal of Science and Technology, 2021, 14(2): 141-153.

[11] ZHOU Haiying, YU Xiangyu, ALHASKAWI A, et al. A deep learning approach for medical waste classification[J]. Scientific Reports, 2022, 12(1): 2159.

[12] 兰坤,吴琼,耿艳兵. 基于 Python 的社交网站用户行为数据采集方法[J]. 智能计算机与应用, 2024, 14(6): 219-223.

[13] ABBAS M, ARSLANM, BHATTY R A, et al. Enhanced skin disease diagnosis through convolutional neural networks and data

- augmentation techniques[J]. *Journal of Computing & Biomedical Informatics*, 2024,7(1): 87-106.
- [14] SHI L, LIU W. Adversarial self-training improves robustness and generalization for gradual domain adaptation [J]. *Advances in Neural Information Processing Systems*, 2023, 36: 20241715985093.
- [15] PANG R, NING J, YANG Y, et al. Detection of road risk sources based on multi-scale lightweight networks [J]. *Sensors*, 2024,24(17): 5577.
- [16] 贾兆红,张袁源,王海涛,等. 基于 Res2Net 和双线性注意力的番茄病害时期识别方法[J]. *农业机械学报*, 2022,53(7):259-266.
- [17] 尹兆珂,缪炳荣,张盈,等. 一种融合特征与卷积神经网络的车轮缺陷识别方法[J]. *噪声与振动控制*, 2024,44(6):149-155.
- [18] 曹嘉璇,王家琪,邹北骥,等. 基于多分组协调注意力卷积的缺血性脑卒中病灶分割方法[J]. *智能计算机与应用*, 2025,15(4):9-16.
- [19] HASAN M D A, BHARGAV T, SANDEEP V, et al. Image classification using convolutional neural networks [J]. *International Journal of Mechanical Engineering Research and Technology*, 2024, 16(2): 173-181.
- [20] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [21] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [J]. *Communications of the ACM*, 2017,60(6): 84-90.
- [22] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway, NJ:IEEE, 2016: 770-778.
- [23] HOWARD A, SANDLER M, CHU G, et al. Searching for Mobilenetv3 [C]//*Proceedings of the IEEE/CVF International Conference on Computer Vision*. Piscataway, NJ:IEEE, 2019: 1314-1324.
- [24] MA Ningning, ZHANG Xiangyu, ZHENG Haitao, et al. Shufflenet v2: Practical guidelines for efficient cnn architecture design [C]//*Proceedings of the European Conference on Computer Vision (ECCV)*. Cham:Springer, 2018: 116-131.
- [25] LIU Z, MAO H, WU C Y, et al. Aconvnet for the 2020s [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Piscataway, NJ:IEEE, 2022: 11976-11986.
- [26] XIANG S, ZHANG L, CHEN Y, et al. A defect detection method for grading rings of transmission lines based on improved YOLOv8 [J]. *Energies*, 2024, 17(19): 4767.
- [27] 郑皓文,汪凯,程源,等. 基于并行特征提取的轴承故障诊断方法[J]. *噪声与振动控制*, 2024,44(6):185-190.
- [28] MAJCHROWSKA S, MIKOŁAJCZYK A, FERLIN M, et al. Deep learning - based waste detection in natural and urban environments [J]. *Waste Management*, 2022, 138: 274-284.
- [29] MAO W L, CHEN Weichun, WANG C T, et al. Recycling waste classification using optimized convolutional neural network [J]. *Resources, Conservation and Recycling*, 2021, 164: 105132.