

基于深度迁移学习的垃圾分类研究

封皓元, 段 勇, 胥程琪

沈阳工业大学信息科学与工程学院, 辽宁 沈阳

收稿日期: 2023年6月19日; 录用日期: 2023年7月10日; 发布日期: 2023年7月21日

摘 要

针对垃圾分类人工检测环境差, 易出错, 难度大, 效率低的问题, 提出一种利用深度迁移学习对生活垃圾分类的方法。首先, 构建垃圾分类的图像数据集, 同时数据增强, 其次, 搭建深度卷积神经网络ResNeXt和MobileNetV2, 微调网络迁移参数以适应垃圾分类任务, 最后, 在基于深度迁移学习的卷积神经网络下, 探索了网络冻结层数和学习率对不同量级的网络结构造成的影响。结果表明, ResNeXt受到学习率的影响更强, MobileNetV2受到网络冻结层数的影响更多, 两者的最佳网络冻结层分别是50层和80层, 最佳学习率分别是0.0003和0.0001, 有效提升模型准确率, 实现了对多种常见垃圾的有效分类。

关键词

深度迁移学习, 卷积神经网络, 网络冻结, 学习率, 垃圾分类

Deep Transfer Learning-Based Waste Classification Research

Haoyuan Feng, Yong Duan, Chengqi Xu

School of Information Science and Engineering, Shenyang University of Technology, Shenyang Liaoning

Received: Jun. 19th, 2023; accepted: Jul. 10th, 2023; published: Jul. 21st, 2023

Abstract

To address the problems of poor manual detection environment, error-prone, difficulty and low efficiency of garbage classification, a method of domestic garbage classification using deep transfer learning is proposed. Firstly, image datasets for garbage classification are constructed while data augmentation, secondly, deep convolutional neural networks ResNeXt and MobileNetV2 are built to fine-tune the network transfer parameters to suit the garbage classification task, and finally, the effects of network freezing layers and learning rate on the network structure caused by different magnitudes are explored under the convolutional neural networks based on deep migra-

tion learning. The results show that ResNeXt is more strongly influenced by the learning rate and MobileNetV2 is more influenced by the number of network freeze layers, and the best network freeze layers for both are 50 and 80 layers, respectively, and the best learning rates are 0.0003 and 0.0001, respectively, which effectively improve the model accuracy and achieve the effective classification of many kinds of common garbage.

Keywords

Deep Transfer Learning, Convolutional Neural Network, Network Freezing, Learning Rate, Garbage Classification

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

伴随经济生活水平的不断提高,垃圾数量呈现爆炸式的增长,目前虽然提倡从源头开始分类,然而实际操作中依旧利用人工分拣海量的垃圾,工作环境差,分类效率低,社会的真实需求无法满足。近年来,人工智能迅速发展,有效推进了图像识别在计算机视觉领域的应用,针对垃圾分类的智能识别技术应运而生。

传统的垃圾分类以机器学习为主,利用特征工程对目标数据进行特征提取,寻找数据内部之间存在的关系和潜在的规律。黄浩然[1]等利用几何矩尺度不变性、平移等属性优势,利用7个Hu不变矩和多颜色空间特征,采取关键信息作为特征向量,通过构建一个相似性度量方法得到衡量标准以获取分类结果。申新杰[2]等采用AGAST二叉树角点域的算法,使用非极大值抑制法对角点进行处理,获得AGAST特征点,通过特征点匹配实现对特定垃圾的识别。潘丽[3]等采用BRISK特征提取算法实现对图像的监测,实现了高准确率的垃圾识别。李勇[4]利用灰色预测模型预测产生量,设计朴素贝叶斯分类器对数据训练,实现更高效的垃圾分类。黄兴华[5]等将局部二值模式(LBP)改进,再与Uniform LBP融合得到AD-LBP,将AD-LBP与梯度方向直方图算法对图像进行特征提取。

然而传统技术直接将数据输入模型,难以获取正确的规律,导致分类精度低,同时浪费人工成本和时间成本。伴随2012年AlexNet[6]的诞生,深度学习重新引起广泛的关注,许多学者将其应用到垃圾分类中。Wang H[7]利用VGG16卷积网络,嵌入Batch Normalization以加快收敛速度、保证垃圾的识别精度。Sultana[8]通过AlexNet进行多次实验,分别实现了对室内垃圾与室外垃圾的分类。迁移学习[9][10]同样被引入到网络模型中实现对废弃物的分类,以减少模型训练时间。Adedeji[11]等提出一种将ResNet与SVM相结合的方式对城区固体废物进行分类,通过ResNet提取图像特征,将特征放入SVM中进行训练以获得结果。陈牧图[12]等也讨论了深度学习相关方法并实现了对垃圾的自动化识别。高静[13]等设计一种基于Xception的轻量级模型,引入锯齿状扩张卷积且结合预热与余弦退火的方式控制学习率,实现了学习率的凸变化,加快了模型的收敛效率,提高识别的精度。

在以上学者的研究中,深度学习在图像分类的实际应用中普遍高于传统机器学习方法,通过卷积神经网络实现自动化的特征提取,摆脱了繁琐的特征工程,利用反向传播不断训练网络模型,使得模型分类准确率不断提升,超越了机器学习模型。在深度学习模型中ResNeXt[14]和MobileNetV2[15]正是图像分类任务中,两种不同量级、性能突出的模型。同时迁移学习实现了对已有知识的复用,加快了模型

训练的效率，利用微调与冻结的迁移方法，能够进一步提升模型分类的准确率。

基于此，本文研究了基于迁移学习的深度学习模型并应用于垃圾图片分类的问题。首先，构建垃圾分类数据集，分别采用位置和颜色两种不同维度的数据增强方式，提高模型的泛化能力，避免模型过拟合。其次，通过 ImageNet 数据集构建了 ResNeXt 与 MobileNetV2 两种预训练网络模型，微调模型的网络结构以适应垃圾分类任务，不断调整模型参数以提升图像分类准确率，最后采用迁移学习的冻结方法与调整学习率的方式，探究网络冻结层数和学习率在不同量级的网络结构中，对图像分类结果的影响，同时获取分类效果最佳的网络冻结层数和学习率。

2. 图像分类模型

2.1. ResNeXt

图像识别的基础是提取具有代表性的语义特征和细节特征，网络模型的深度和宽度决定着网络模型提取特征的性能。然而，伴随模型容量的不断增加，设计难度和计算开销在逐渐增大，网络深度和宽度带来的收益在逐渐降低，为此，本文采用 ResNeXt 深度学习模型作为垃圾图像分类模型之一以缓解收益降低的问题。

ResNeXt 模型的网络结构打破了深度和宽度对模型性能提升的局限，采用高度模块化的设计，改进了 ResNet 网络结构，通过融合 VGG 网络堆叠、ResNet 网络的残差模块以及 Inception 网络的拆分 - 变换 - 聚合的思想，其模型设计涵盖两个优点：1) 堆叠相同的拓扑结构，减少了超参数的自由选择，降低超参数对特殊数据集产生过拟合的风险。2) 将网络拆分成若干小模块，经过不同滤波器变换，沿通道维度以串联的方式聚合，实现减少计算开销，增强模型提取特征的性能。拆分 - 变换 - 聚合思想的公式如式 (1) 所示：

$$R(x) = x + \sum_{i=1}^C T_i(x) \quad (1)$$

其中， x 是输入向量、 T_i 是能把 x 投影到子空间进行变换的函数， C 是具有相同拓扑结构分支的数目，称为基数，可以取任意值，本文将 C 取值为 32，其 ResNeXt 基本模块如图 1 所示。图中 Path 是一个基数，代表一个 ResNeXt 模块，每一层的显示值由上到下分别表示为输入通道、滤波器大小和输出通道。

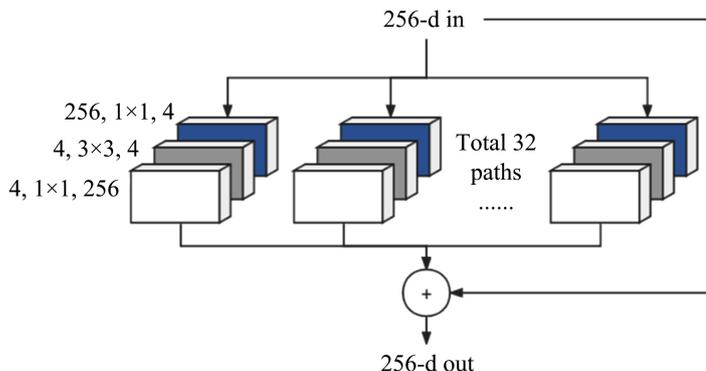


Figure 1. ResNeXt module (base $C = 32$)

图 1. ResNeXt 模块(基数 $C = 32$)

基数为网络模型引入一个度量，实验证明，基数的增加比深度或宽度更有效，有效减少模型对深度和宽度的依赖，模型提取特征的能力得到有效提升。

2.2. MobileNet-V2

MobileNetV2 深度学习模型是 MobileNetV1 基础上改进的轻量级网络结构，其保留原有 MobileNet 架构使用深度可分离卷积代替普通卷积的特性，同时利用逆向残差结构和线性瓶颈结构的特点提升模型的性能。因此，本文使用 MobileNetV2 作为验证分类结果的轻量级网络，同时探究轻量级网络在不同网络冻结层数及学习率下所受到的影响。

深度可分离卷积是由深度卷积和点卷积组合构成，深度卷积与普通卷积不同，而点卷积就是 1×1 的普通卷积，在输入特征图时，先利用深度卷积对输入图进行过滤，再通过点卷积对过滤特征线性组合，达到缩减模型参数量、减少计算量的目的。

逆向残差结构借鉴了残差结构的思想，改变了传统残差结构先降低通道维度，再提取特征，最后扩大通道维度的顺序。通过先利用点卷积升维，再利用深度卷积提取特征，最后使用点卷积降维的顺序，解决由于模型参数量减少，导致提取特征信息不足的问题，保证了模型提取特征的性能。其基本模块如图 2 所示，图中 Conv 表示点卷积，Dwise 表示深度卷积，Relu6 表示激活函数，Linear 表示线性激活函数，此外，模块仅在步长为 1 时，才有残差结构，而步长为 2 时，直接使用串联结构。

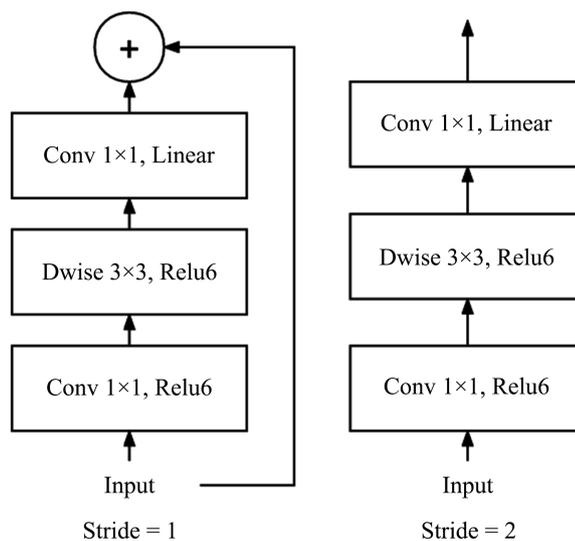


Figure 2. MobileNetV2 module
图 2. MobileNetV2 模块

线性瓶颈结构是将激活函数更换成 ReLu6，同时将最后一步点卷积的激活函数替换成线性激活函数，进一步保留更多的特征信息。

3. 基于深度迁移学习的分类模型

3.1. 深度迁移学习

迁移学习的思想是利用数据、任务、模型之间的相似性，将在旧领域学习到的知识转移到新领域，进而完成任务的学习过程。依据方法分类，迁移学习分成基于实例、特征、模型、关系的学习方法。

本文采用基于模型的迁移学习方法，通过共享模型的权重、偏置等网络参数训练模型，完成从现有数据集转移至垃圾数据集的分类任务，深度学习与迁移学习的结合可以有效减少模型的训练时间，加快模型的收敛速度，提高训练模型的效率。

3.2. 模型分类流程

本文提出的基于深度迁移学习的垃圾图像分类模型流程主要分成两个部分，一部分是对数据的数据增强处理，防止过拟合问题的产生，提升模型的泛化能力。另一部分是针对垃圾分类的任务，利用对预训练模型结构的修改与参数的引用以训练模型，提取图像的特征信息，实现垃圾分类。

本文数据增强采用多种处理方式，位置部分采用随机裁剪、水平/垂直翻转、随机旋转的处理方式，颜色部分采用调整色度、对比度以及饱和度的处理方式，图像数据增强示例如图 3 所示，为一次性快餐盒图像原图与其进行数据增强的 16 个处理结果的示例。

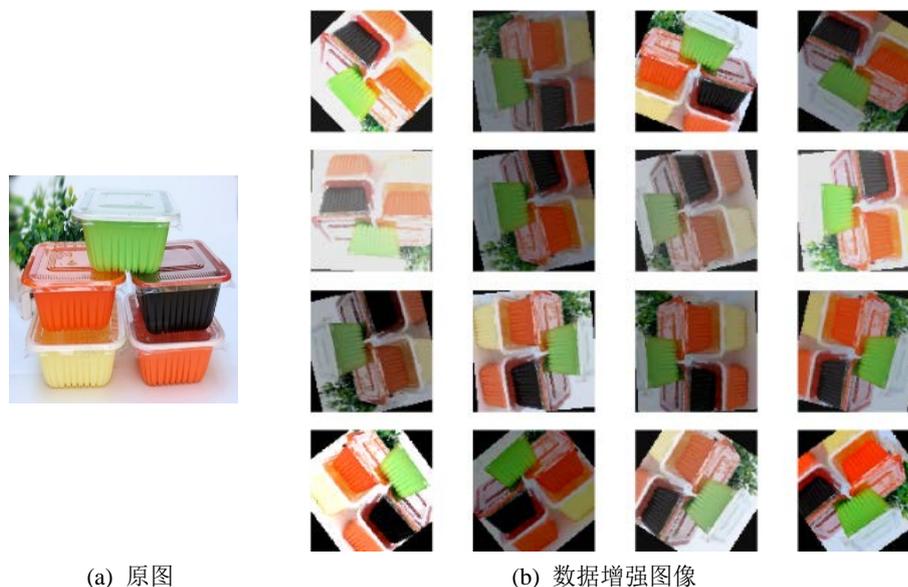


Figure 3. Data augmentation example
图 3. 数据增强示例

本文提出的算法主要分成两个部分，一部分是构建预训练模型，利用迁移学习的优势，将迁移参数代表的具体特征和抽象特征，提升模型的训练效率，另一部分是数据集的处理，采用多维度的处理方式进行数据增强，防止过拟合。最终，分别调整冻结层数和学习率，实现对垃圾图像的高准确率分类，基于深度迁移学习的详细分类流程如图 4 所示。

1) 将 ImageNet 数据集作为源域数据，使其训练参数加载到 ResNeXt 和 MobileNetV2 的预训练模型中，以便提升模型训练的效率，以预训练模型为基准，通过去除原有结构中末尾的全连接层，添加全新的全连接层以适应 20 分类的垃圾分类任务，使模型能够在迁移学习的微调方式中，实现对模型训练参数的调整。

2) 将垃圾数据集作为目标域数据，将 64% 划分成训练集、16% 划分成验证集、20% 划分成测试集，实现对模型的有效训练。同时采用数据预处理中的数据标准化平衡特征所占用的权重，提高模型的决策效率。

3) 通过对原始样本参数的操作，重新生成全新的、独特的样本，以此获取同等价值的样本，实现数据增强。采用位置与颜色两种维度的数据增强方式，对训练集和验证集进行处理，采用随机裁剪、水平/垂直翻转、随机旋转以及调整色度、对比度以及饱和度的方式，提高模型的泛化能力，防止模型在训练时发生过拟合。

4) 在 ResNeXt 和 MobileNetV2 模型训练前, 分别调整网络冻结层数和学习率, 调整冻结层数, 是为了通过固定前几层的模型参数, 合理的运用模型在 ImageNet 训练中产生的具体特征和抽象特征, 提高模型在图像分类中的能力, 探究不同量级的网络模型在不同冻结层数下的垃圾图像分类效果。调整学习率, 是为了使模型在合适的学习率, 目标函数在适当的时间收敛到局部最小值, 提升训练效率, 探究不同量级的网络模型在不同学习率下的垃圾图像分类效果。

5) 将数据增强后的训练集和验证集数据输入到网络模型中进行训练, 再通过测试集验证模型的分类结果, 实现垃圾图像的分类。

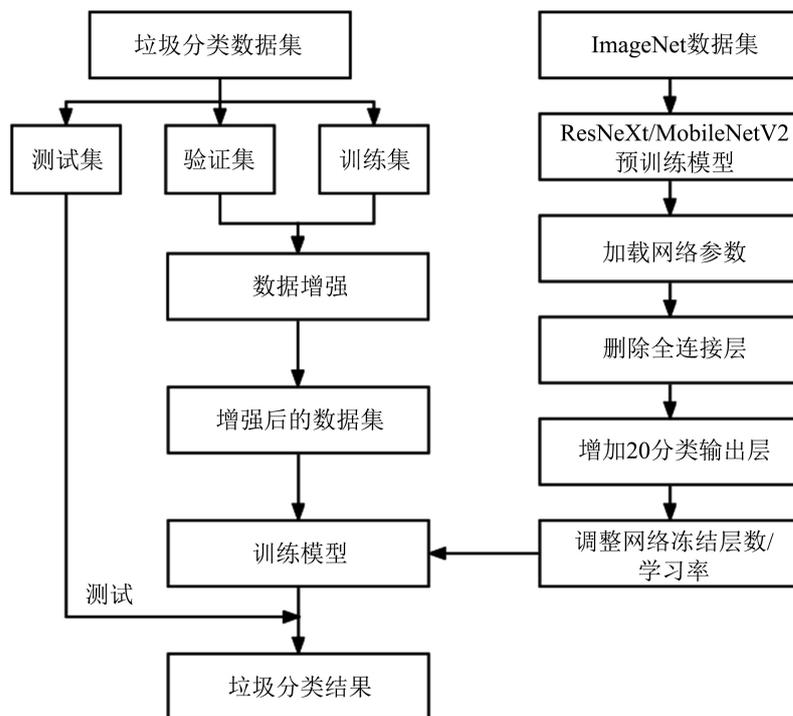


Figure 4. Garbage classification flow chart based on deep transfer learning

图 4. 基于深度迁移学习的垃圾分类流程图

4. 实验结果与分析

4.1. 数据集简介

本文实验的垃圾数据集源自华为云, 其中包含可回收垃圾、厨余垃圾、有害垃圾以及其他垃圾四大垃圾类别图像, 从中筛选出 20 小类, 每个类别随机分配 300~350 张图像, 共计 6581 张图像作为实验数据, 表 1 为具体分类及图像数量。

Table 1. Garbage classification dataset image classification statistics

表 1. 垃圾分类数据集图像分类统计

图像种类	数量	图像种类	数量
一次性快餐盒	322	茶叶渣	331
污损塑料	336	菜叶菜根	338

Continued

烟蒂	335	鱼骨	335
破碎花盆碟碗	319	充电宝	312
竹筷	323	包	336
剩饭剩菜	330	塑料玩具	323
水果果皮	335	塑料衣架	346
插头电线	326	毛绒玩具	345
砧板	319	金属食品罐	340
食用油桶	315	过期药物	316

4.2. 实验设置

本文实验对训练数据与测试数据按照 8:2 的比例随机划分以用来训练模型。针对两种不同量级的网络结构,探究在不同网络冻结层数和学习率的设置下,对于分类结果的影响,具体参数设置如表 2 所示,对 ResNeXt 和 MobileNetV2 分别设置网络冻结层数为 20 到 150,学习率分别设置 0.001、0.003、0.005、0.0001、0.0003、0.0005。

Table 2. Parameter settings of network freezing layers and learning rate

表 2. 网络冻结层数与学习率的参数设置

网络模型	冻结层数	学习率
ResNeXt、MobileNetV2	20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150	0.001, 0.003, 0.005, 0.0001, 0.0003, 0.0005

衡量指标是判断实验结果的重要依据,根据指标的结果,能够实时监测实验进行的程度,本文采用准确率作为实验的衡量标准,其公式如式(2)所示。

$$\text{Accuracy} = \frac{1}{N} \sum_{i=1}^N I(y_i = f(x_i)) \quad (2)$$

其中,Accuracy 表示准确率, N 是样本总数量, y_i 是实际结果, $f(x_i)$ 是预测结果, I 是条件判断函数。对训练集、验证集以及测试集进行计算,将训练集和验证集的结果作为判断模型训练程度以及是否发生过拟合问题的实验依据,测试集的结果用来判断模型的分类能力,本文中表格内的准确率指测试集的准确率结果。

4.3. 网络冻结层数的分类影响

ResNeXt 模型的网络冻结层数对垃圾分类结果的影响如表 3 所示。

根据表 3 可知,ResNeXt 在冻结层数不同时,对分类结果有着不同的影响,并且依据网络冻结层数越多,训练时间越短的趋势以及分类准确率,显示当网络冻结层数为 50 层时,分类效果最佳,说明此时 ResNeXt 模型针对当前数据集所提取的特征最具代表性,模型效果最佳的训练变化曲线如图 5 所示。

Table 3. ResNeXt network freezing layer results
表 3. ResNeXt 网络冻结层数结果

冻结层数	准确率/%	冻结层数	准确率/%
20	91.96	90	91.10
30	92.35	100	90.48
40	92.12	110	91.41
50	92.35	120	91.18
60	92.12	130	90.09
70	91.57	140	89.78
80	91.88	150	87.20

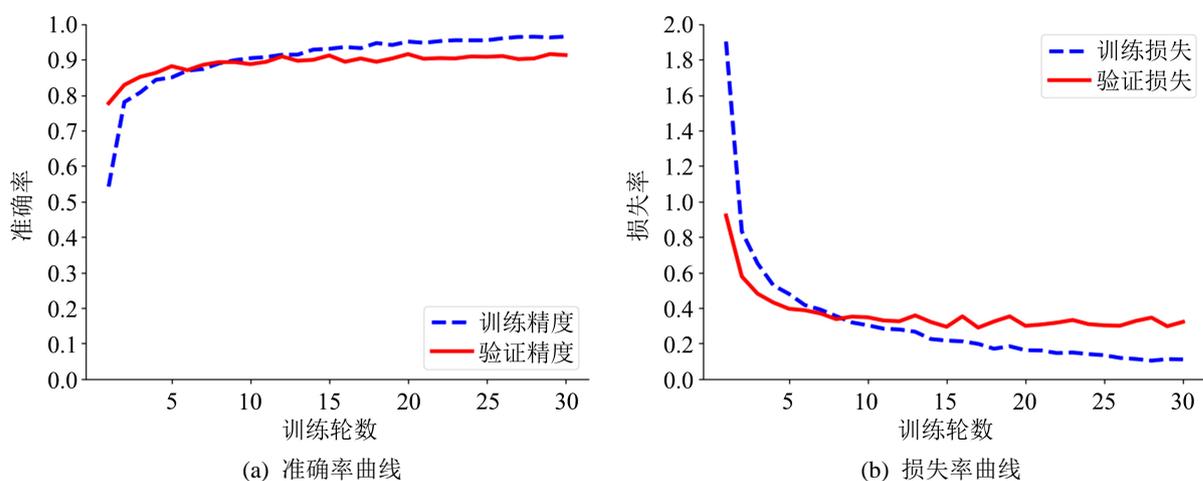


Figure 5. Change curve of ResNeXt training model
图 5. ResNeXt 训练模型的变化曲线

MobileNetV2 轻量级模型的网络冻结层数对垃圾分类结果的影响如表 4 所示。

Table 4. MobileNetV2 network freezing layer results
表 4. MobileNetV2 网络冻结层数结果

冻结层数	准确率/%	冻结层数	准确率/%
20	89.54	90	89.23
30	89.23	100	89.15
40	89.31	110	86.66
50	89.15	120	87.75
60	88.76	130	87.28
70	88.92	140	87.12
80	89.70	150	82.29

依据表 4 所知, MobileNetV2 轻量级网络在冻结不同层数后同样受到了不同程度的影响, 其最佳冻结层数为 80 层, 可以判断此时网络权重所提取的特征与数据集的潜在模式最为相近, 模型最佳的训练曲线如图 6 所示。

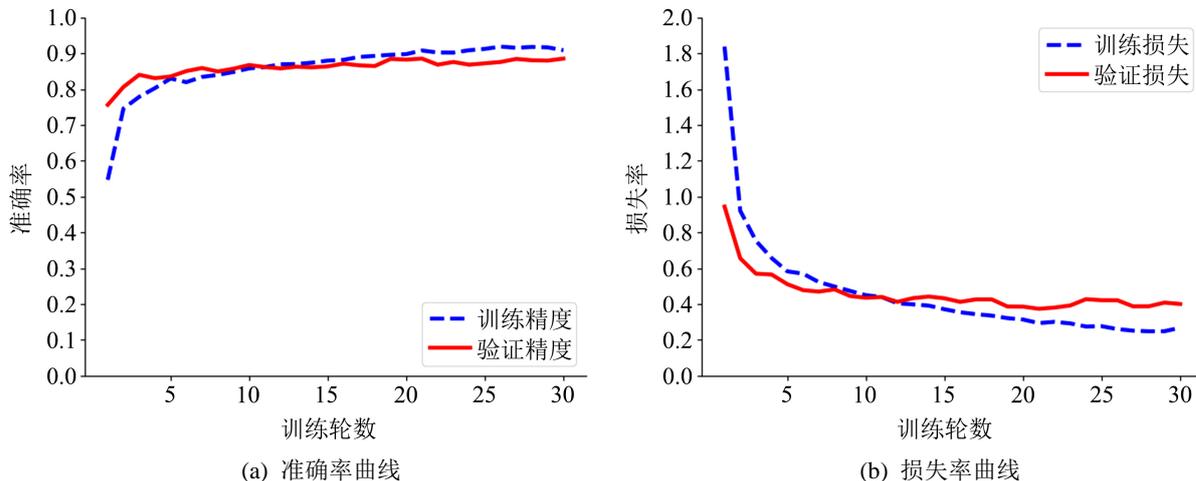


Figure 6. Change curve of MobileNetV2 training model

图 6. MobileNetV2 训练模型的变化曲线

ResNeXt 网络与冻结效果最差的分类结果相差 5.15%, MobileNetV2 轻量级网络与冻结效果最差的分类结果相差 7.41%, 说明网络冻结层数对 MobileNetV2 轻量级网络影响更大, 对 ResNeXt 网络影响更小。

4.4. 学习率的分类影响

ResNeXt 和 MobileNetV2 分别选用效果最佳的网络冻结层数进行实验, 分别冻结 50 层和 80 层, 实验结果如表 5 所示。

Table 5. ResNeXt and MobileNetV2 different learning rate results

表 5. ResNeXt 与 MobileNetV2 不同学习率结果

模型	学习率	准确率/%	模型	学习率	准确率/%
ResNeXt	0.001	91.41	MobileNetV2	0.001	88.29
	0.003	88.76		0.003	86.42
	0.005	83.93		0.005	84.55
	0.0001	92.35		0.0001	89.71
	0.0003	93.21		0.0003	88.06
	0.0005	92.48		0.0005	88.76

当 ResNeXt 冻结层数为 50 层, 学习率为 0.0003 时, 准确率最高, 通过混淆矩阵可以直观地展现模型在各个类别上的表现以及难以区分的类别, ResNeXt 混淆矩阵如图 7 所示, 其中, 横坐标为真实标签, 纵坐标为模型预测结果, 矩阵对角线表示模型分类的正确结果, 其余部分表示分类的误差。图 7 表明,

模型对于充电宝的分类误差相对较大, 然而整体分类准确率普遍达到 90% 以上, 验证了本文算法的有效性。

对比表 5 可知, ResNeXt 的最佳学习率为 0.0003, 最差的学习率为 0.005, 两者相差 8.57%, MobileNetV2 轻量级网络最佳学习率为 0.0001, 最差的学习率为 0.005, 两者相差 5.15%, 并且在学习率为 0.005 的同等条件下, 准确率高于 ResNeXt 的分类结果, 说明学习率对 ResNeXt 网络的影响程度更大, 对 MobileNetV2 轻量级网络的影响程度更小。

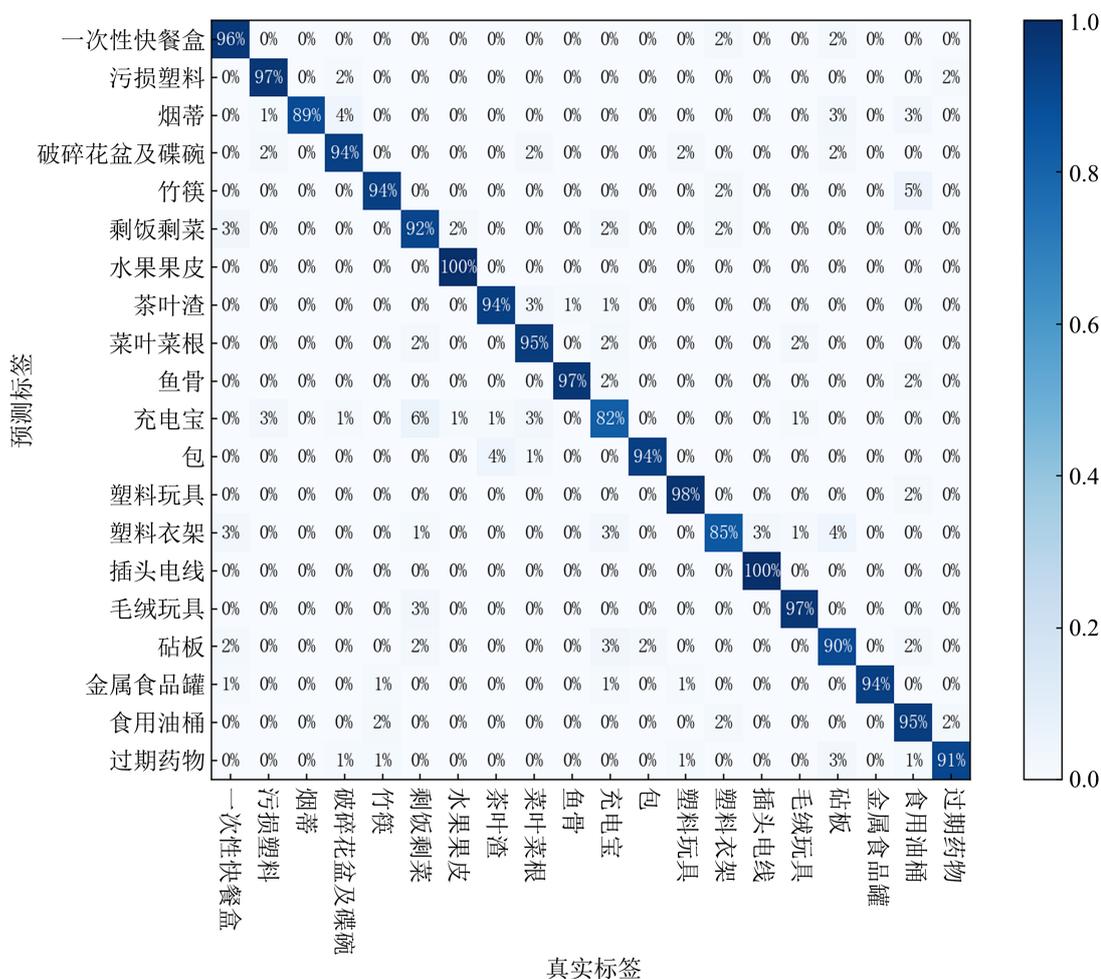


Figure 7. ResNeXt confusion matrix

图 7. ResNeXt 混淆矩阵

4.5. 实验对比

由于数据集的数量和种类不同于其他实验, 因此, 为了验证算法的有效性, 本文自行构建了 VGGNet 和 Xception 网络模型与文本使用的 ResNeXt 和 MobileNetV2 进行比较, 实现垃圾图像的分类, 以便直观体现模型的分类优势, 具体实验结果如图 8 所示。

通过图 8 对比得出, ResNeXt 算法获得了 93.21% 的识别准确率, 是四种模型中分类准确率最高的, 相较于 AlexNet, 其分类准确率相差了 10.38%, 因此, 从 ResNeXt 模型的角度分析, 一方面, 直观地展现出本文算法的有效性, 另一方面也侧面体现出模型选择的科学性与合理性。MobileNetV2 虽然不是第

二高的分类准确率，但是作为轻量级网络模型，其分类结果能够接近常规体量 Xception 模型，准确率仅相差 0.3%，为此，从 MobileNetV2 模型的角度分析，进一步说明，通过调整网络冻结层数与学习率，模型的性能能够得到有效提升。

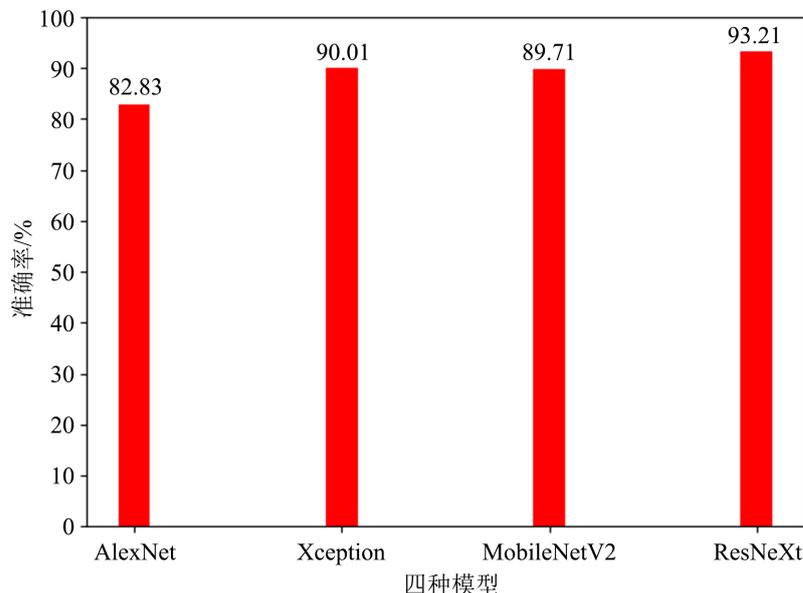


Figure 8. Comparative experiment of four models
图 8. 四种模型的对比试验

5. 结论

本文构建了基于深度迁移学习的垃圾分类模型，通过创建垃圾图像数据集，对数据采取多种数据增强处理，防止图像数量导致的过拟合，建立 ResNeXt 和 MobileNetV2 预训练网络模型，微调模型以适应垃圾分类的任务，实现了对多种常见垃圾的有效分类。通过混淆矩阵直观地表现出模型对于各个垃圾类别的分类能力，验证了本文算法的有效性，同时探究了网络冻结层数和学习率在不同量级的网络结构，对分类结果的影响。实验结果表明，网络冻结层数和学习率都能对不同量级的网络结构产生不同程度的影响，通过适当的调整，可以获得性能更好的模型，横向对比实验结果可知，MobileNetV2 轻量级网络受到网络冻结层数的影响则更多，而 ResNeXt 网络受到学习率的影响更强。

参考文献

- [1] 黄浩然. 基于 Hu 不变矩的垃圾分类和识别[J]. 自动化应用, 2020(8): 74-76.
- [2] 申新杰, 兰浩, 曾渝. 基于 AGAST 角点域特征的垃圾识别算法[J]. 电脑知识与技术, 2020, 16(20): 183-186.
- [3] 潘丽, 贾冕茜. 基于机器学习的智能垃圾分类系统设计[J]. 西昌学院学报(自然科学版), 2022, 36(2): 74-77, 124.
- [4] 李勇, 郑唯加. 基于朴素贝叶斯分类器的垃圾分类系统[J]. 辽宁工业大学学报(自然科学版), 2021, 41(1): 49-52.
- [5] 黄兴华, 叶军一, 熊杰. 基于纹理特征融合的道路垃圾图像识别及提取[J]. 计算机工程与设计, 2019, 40(11): 3212-3218, 3305.
- [6] Krizhevsky, A., Sutskever, I. and Hinton, G.E. (2012) Imagenet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, **25**, 1097-1105.
- [7] Wang, H. (2020) Garbage Recognition and Classification System Based on Convolutional Neural Network VGG16. *2020 3rd International Conference on Advanced Electronic Materials, Computers and Software Engineering (AEMCSE)*, Shenzhen, 24-26 April 2020, 252-255. <https://doi.org/10.1109/AEMCSE50948.2020.00061>

-
- [8] Sultana, R., Adams, R.D., Yan, Y., *et al.* (2020) Trash and Recycled Material Identification Using Convolutional Neural Networks (CNN). 2020 *SoutheastCon*, Raleigh, 28-29 March 2020, 1-8. <https://doi.org/10.1109/SoutheastCon44009.2020.9249739>
- [9] 贺朝辉, 曾鹏程. 基于深度学习的生活垃圾分类[J]. 电脑知识与技术, 2022, 18(3): 99-100.
- [10] Endah, S.N. and Shiddiq, I.N. (2020) Xception Architecture Transfer Learning for Garbage Classification. 2020 *4th International Conference on Informatics and Computational Sciences (ICICoS)*, Semarang, 10-11 November 2020, 1-4.
- [11] Adedeji, O. and Wang, Z. (2019) Intelligent Waste Classification System Using Deep Learning Convolutional Neural Network. *Procedia Manufacturing*, **35**, 607-612. <https://doi.org/10.1016/j.promfg.2019.05.086>
- [12] 陈牧图, 谭睿, 石垒垒, 等. 基于深度学习的智能垃圾分类系统设计[J]. 电子测试, 2022(17): 12-14, 18.
- [13] 高静, 段中兴, 何宇超. 多尺度特征融合的轻量型垃圾分类方法[J]. 小型微型计算机系统, 2023, 44(2): 376-382. <https://doi.org/10.20009/j.cnki.21-1106/TP.2021-0480>
- [14] Xie, S., Girshick, R., Dollár, P., Tu, Z.W. and He, K.M. (2017) Aggregated Residual Transformations for Deep Neural Networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 21-26 July 2017, 5987-5995. <https://doi.org/10.1109/CVPR.2017.634>
- [15] Sandler, M., Howard, A., Zhu, M., *et al.* (2018) Mobilenetv2: Inverted Residuals and Linear Bottlenecks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 4510-4520. <https://doi.org/10.1109/CVPR.2018.00474>