

DOI:10.19651/j.cnki.emt.2209829

# 基于 EfficientNetV2-HDCA 模型水下鱼类 图像分类算法研究<sup>\*</sup>

龚瑞昆<sup>1</sup> 赵学智<sup>1</sup> 赵福生<sup>2</sup>

(1. 华北理工大学电气工程学院 唐山 063210; 2. 秦皇岛路田科技有限公司 秦皇岛 066010)

**摘要:** 针对现有的鱼类分类网络模型抗干扰能力差、耗费计算资源高、难以在野外部署等问题,该研究提出了一种基于改进 EfficientNetV2 模型的轻量化鱼类智能分类鉴定模型。该模型通过引入混合空洞卷积和坐标注意力模块改进主干网络 EfficientNetV2 的模型结构,增大感受野的同时,提高模型对目标细粒度特征的全局关注力,增强模型的抗干扰能力。训练后通过对比消融实验对模型进行评价,结果表明该研究提出的 EfficientNetV2-HDCA 模型在验证集上的准确率为 97.01%,相较于改进前准确率提升了 3.8 个百分点。改进后的 EfficientNetV2-HDCA 模型参数量为 22.06 MB,较改进前增加了 0.45 MB。为了直观的展示该研究提出的 EfficientNetV2-HDCA 模型的有效性,又通过了 Grad-CAM 热力实验,实验结果表明该模型较改进前可以更加全面的提取鱼类的关键部位特征,具有一定的抗干扰能力。

**关键词:** 湿地;水下图像分类;EfficientNetV2;混合空洞卷积;坐标注意力

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 510.4050

## Research on underwater fish image classification algorithm based on EfficientNetv2-HDCA model

Gong Ruikun<sup>1</sup> Zhao Xuezhi<sup>1</sup> Zhao Fusheng<sup>2</sup>

(1. College of Electrical Engineering, North China University of Science and Technology, Tangshan 063210, China;

2. Qinhuangdao Lutian Technology Co., Ltd., Qinhuangdao 066010, China)

**Abstract:** In view of the problems of the existing fish classification network models, such as poor anti-interference ability, high computational resource consumption, and difficulty in field deployment, this study proposed a lightweight fish intelligent classification and identification model based on the improved EfficientNetV2 model. By introducing Hybrid Dilated Convolution and Coordinate Attention modules, this model improves the model structure of EfficientNetV2, increases the receptive field, improves the global attention of the model to the fine-grained features of the target, and enhances the anti-interference ability of the model. After training, the model was evaluated by comparative ablation experiments, and the results showed that the accuracy of the EfficientNetV2-HDCA model proposed in this study on the verification set was 97.01%, which was 3.8 percentage points higher than that the accuracy before improvement. The number of parameters in the improved EfficientNetV2-HDCA model is 22.06 MB, which is 0.45 MB higher than that before improvement. In order to visually demonstrate the effectiveness of the EfficientNetV2-HDCA model proposed in this study, the Grad-CAM thermal experiment was also passed. The experimental results show that the model can extract the features of key parts of fish more comprehensively than before, and has a certain anti-interference ability.

**Keywords:** wetland; underwater image classification; EfficientNetV2; hybrid dilated convolution; coordinate attention

## 0 引言

近年来,随着人类现代化城市进程的推进,许多动植

物赖以生存的湿地环境逐渐遭到破坏,使得湿地生态系统的健康问题受到了广泛的社会关注。而水下鱼类物种分类和鉴定对于后续的湿地科学数据统计以及监测生态系统工

收稿日期:2022-05-04

\*基金项目:唐山市科技计划项目(20150212C)资助

作尤为重要<sup>[1]</sup>。

水下目标分类和检测是计算机视觉领域研究的热点问题,但是湿地水下环境复杂多变,水体中不仅含有水草等杂质,而且含有大量悬浮颗粒,造成水质混浊<sup>[2]</sup>,使用水下相机采集信息时往往因为不同波长的光在水下传播时颜色衰减程度不同,导致采集到的图片颜色失真、纹理特征模糊<sup>[3-5]</sup>、目标与背景对比度较低,使得水下图像识别成为一项非常具有挑战性的工作<sup>[6]</sup>。

自 2000 年以来,随着深度学习的不断发展,传统卷积神经网络(AlexNet<sup>[7]</sup>、VGGNet<sup>[8]</sup>、GoogLeNet<sup>[9]</sup>、ResNet<sup>[10]</sup>、ResNeXt<sup>[11]</sup>)等模型架构的不断完善,更多基于经典卷积神经网络的模型已成功应用于鱼类物种识别等相关计算机视觉任务当中。如;2018 年,Cui 等<sup>[12]</sup> 基于 AlexNet 模型增加 concat 层结构以实现输入特征融合,这种结构将分类精度从 93.58 提高到 94.32%。同年,Ma 等<sup>[13]</sup> 使用 6 个类别 3 600 张鱼类图像数据集训练 ResNet50 模型,达到 97.19% 的精确度。2019 年,Gómez-Ríos 等<sup>[14]</sup> 使用 ResNet50 模型对水下珊瑚纹理图像进行分类,并获得了超过 95.87% 的准确性。2020 年,杨春兰等<sup>[15]</sup> 通过改进 VGG16 模型的批量归一化层和激活函数在淡水鱼数据集上达到了 95.87% 的准确率。不仅如此,近些年来,随着轻量化卷积神经网络(MobileNet<sup>[16]</sup>、ShuffleNet<sup>[17]</sup>、EfficientNet<sup>[18]</sup>)的出现,越来越多的计算机视觉分类任务逐渐迁移到轻量化模型当中,如:2022 年,刘南杉等<sup>[19]</sup>引入空洞卷积和 Leaky-ReLU 激活函数对 MobileNet 模型进行优化,并基于该模型对垃圾进行分类达到了 88.0% 的准确率;同年,甘雨等<sup>[20]</sup> 在 EfficientNetV1 模型中引入 CA 注意力机制,对农作物害虫进行分类,相比于改进前准确率提升 4.01 个百分点等。轻量化卷积神经网络通过增加模型的复杂程度,达到了更少的模型参数量以及更高的分类精度,为移动端部署卷积神经网络带来了可能。

通过比较和分析文献,我们了解到现有的网络模型对鱼类的分类工作大致存在以下几种问题:一是随着分类数量的增加,会出下诸如类别之间的相似性(不同种类的鱼类图像的特征的差异相对不明显)的细粒度分类<sup>[21]</sup> 问题;二是在复杂的水下环境中存在各种外在因素对分类任务产生的扰动问题;三是传统的网络模型往往耗费的计算资源较大,只能停留在实验室阶段,难以在复杂野外环境中的模型部署问题。

针对这些问题,本研究使用 EfficientNetV2 模型作为主干网络进行改进,使用改进后的网络模型来实现对复杂水下环境的鱼类分类。具体而言,结合水下鱼类图像特点,在 EfficientNetV2 网络的基础上引入了混合空洞卷积(hybrid dilated convolution, HDC)和基于坐标的注意力(coordinate attention, CA)模块,增加模型对分类目标的全局注意力,减少外部环境信息对模型的干扰,并基于数据增强,迁移学习,以及 VGD 优化器等训练策略对网络模型

进行训练,以提高网络模型的泛化性能。

## 1 EfficientNetV2-HDCA 模型构建

### 1.1 EfficientNet-v2 模型

EfficientNet 模型是谷歌通过堆叠轻量翻转瓶颈卷积(mobile inverted bottleneck convolution, MBConv)并基于神经网络架构搜索技术(neural architecture search, NAS)研发出的一种新型轻量化网络,其将网络深度、通道数以及输入图像的分辨率这 3 个维度按一定比例系数进行设计,同时为了提升模型对图像中分类目标的关注力,每个 MBConv 模块中都嵌有 SE 模块。而 EfficientNetV2<sup>[22]</sup> 模型则在之前 EfficientNetV1 模型的基础上进一步改进了网络结构,优化目标联合搜索技术,并提出了改进的渐进学习方法,在提升准确率的同时,进一步提升了网络的训练速度。

### 1.2 EfficientNetV2 模型改进

由于湿地水下环境中的鱼类图像大多颜色较暗,鱼类和背景环境较为相似,且背景较为复杂,使得模型进行特征提取时会受到干扰元素的影响。为了便于在现代化鱼类检测体系种应用鱼类识别算法并能适应野外复杂的湿地环境,本研究选用 EfficientNetV2 网络作为主干。为了进一步提高网络模型在面对复杂背景下的特征提取能力,本研究在改模型的基础上使用混合空洞卷积(hybrid dilated convolution)进一步改进模型结构,与传统的空洞卷积<sup>[23]</sup> 相比,混合空洞卷积能够保证原有特征图细节不丢失的同时,进一步增大感受野<sup>[24]</sup>,进而获取更多的鱼类特征;在此基础上引入另一种高效的坐标注意力<sup>[25]</sup>(coordinate attention, CA)模块替代原网络中的激励-挤压(sequeeze and excitation, SE)模块,与原模块相比,该模块通过“协调注意”的方式将目标位置特征嵌入到通道注意中,这样做可以沿着一个空间的维度捕获长距离的依赖关系,同时又可以沿着另一个空间维度保留精确的位置信息,进而提升模型的全局关注能力;最终将改进后的模型命名为 EfficientNetV2-HDCA。

### 1.3 改进后的 EfficientNetV2-HDCA 网络结构

与原模型相比,本研究具体改进如下:

1)在网络的第一个卷积层后以残差形式嵌入第一个 CA 模块,利用该模块的坐标注意力特性,增强网络的全局注意力,为通道中较为重要的特征赋予较高的权重,不重要的特征赋予较低的权重,使网络不会因为前期的卷积操作丢失过多有用的信息。

2)将原网络中的第一个重复堆叠两次的 Fused-MBConv 模块中大小为 3x3 的卷积核分别替换为膨胀因子分别为 2 和 3,卷积核大小为 3x3 的膨胀卷积核,与网络第一层构成扩张率(dilation rate)为[1,2,3]的混合卷积结构。通过此操作,可以在不增加计算量的同时,获得更大的感受野,使模型能够提取到更多的目标特征。

3)参考原网络结构,将模型浅层重复堆叠的 Fused-MBConv 结构中的 SE 注意力机制替换为 CA 坐标注意力机制;模型深层中重复堆叠的 MB-Conv 结构中的 SE 注意力机制替换成节点个数为原输入节点个数 0.25 倍的低权重的 CA 坐标注意力机制。

如图 1 所示,改进的 EfficientNetV2-HDCA 模型对鱼类的识别过程如下:将经过预处理后的图片首先通过由第

一个卷积层以及两个连续的空洞卷积模块共同构成的混合空洞卷积结构,随后经过两个重复堆叠次数为 4 (layer = 4) 的 Fused-MBConv 模块完成浅层网络的特征提取;然后通过重复堆叠次数分别为 6,9,15 的 3 个 MBConv 模块完成深层网络的特征提取,期间使用 CA 注意力模块调配特征权重,最后通过池化卷积全连接模块得到对鱼类的分类类别索引。

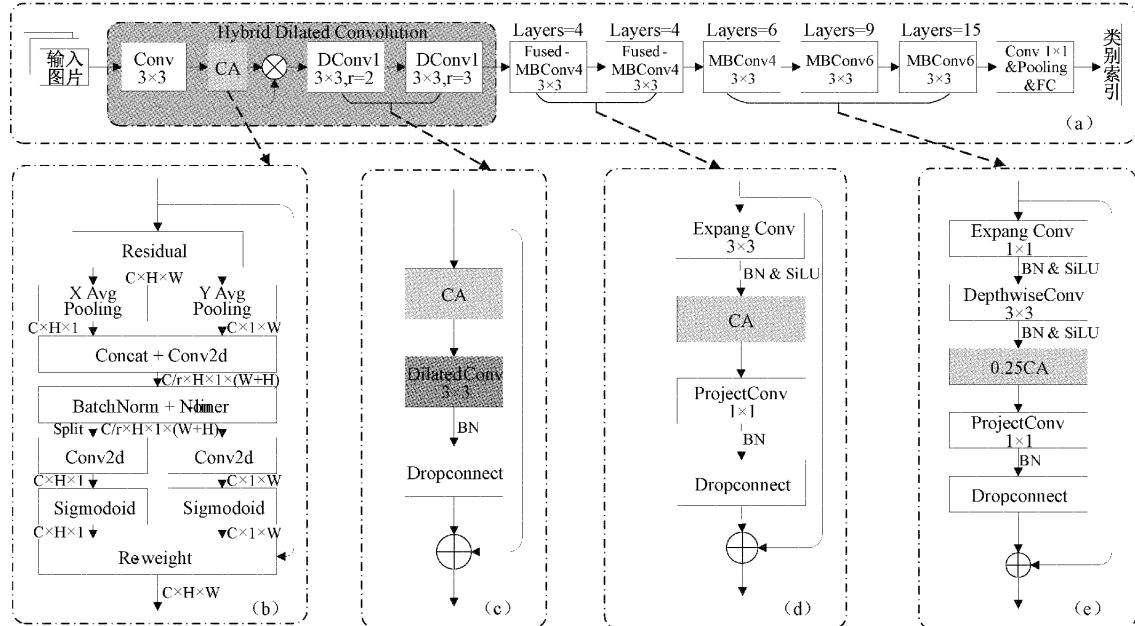


图 1 改进的 EfficientNetv2-HDCA 模型架构图

## 2 实验部署与评价标准

### 2.1 数据采集和数据集构建

本研究选取 7 种湿地中常见淡水鱼类:鲤鱼(Carp)、草鱼(Grass carp)、鳙鱼(Bighead carp)、鲈鱼(Perch)、鳊鱼(Bream)、罗非鱼(Tilapia)、鲶鱼(Catfish)作为研究对象。为了涵盖种

类、阴影、背景以及形态学的多样性,本研究中使用的图像是使用水下采集设备在不同的时间,从不同的湿地水下环境中捕获到的不同种类不同姿态的鱼类视频,经过逐帧提取而来,生成的图像经归一化处理(保持长宽比例不变,将图片长边经尺度变换为 980 dpi,短边部分以黑色背景填充),以像素分辨率为 980×980 的格式保存,部分鱼类图像如图 2 所示。

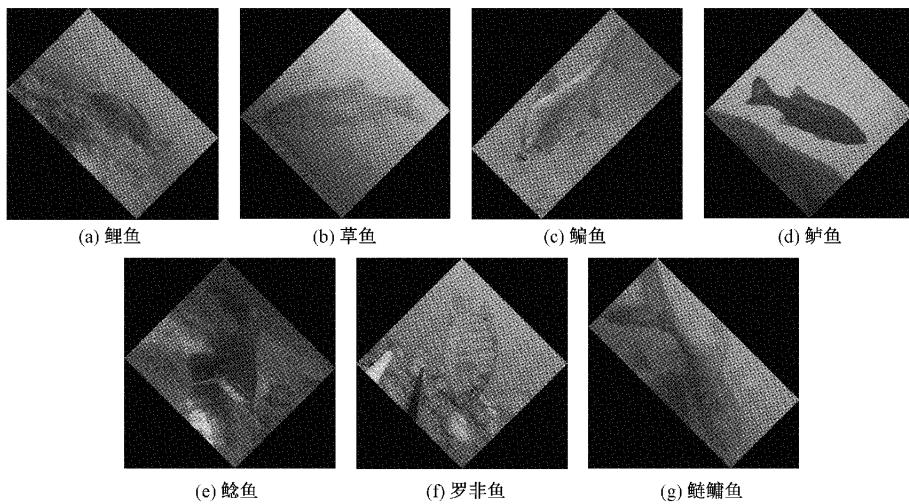


图 2 鱼类品种识别数据集中 7 种鱼类样品

经图片预处理后,共获得 3 780 张鱼类图像,这些实验图像用于构建鱼类分类鉴定数据集。如表 1 所示,该数据集共分为三部分:训练数据集(60% 的数据集,2 268 个样本),验证数据集(20% 的数据集,756 个样本)以及测试数据集(20% 的数据集,756 个样本);其中训练集用于训练过程中模型的拟合,验证集用于训练过程中调整模型的超参数来确定最佳模型,测试集用于对比评估最佳模型的性能。

**表 1 鱼类品种识别数据集数量**

数据集	鲤鱼	草鱼	鳊鱼	鲈鱼	鲶鱼	罗非鱼	鳙鱼
训练集	324	324	324	324	324	324	324
测试集	108	108	108	108	108	108	108
验证集	108	108	108	108	108	108	108

## 2.2 实验环境配置

本研究使用的所有模型均使用 pytorch 框架中的 Python 工具搭建,结果中所展示的混淆矩阵以及热力图均使用 Matplotlib 工具包所导出。卷积神经网络的训练以及测试工作部署在一台配备有 intel i7-8700k CPU 以及 NVIDIA GeForce GTX 1080ti 图形处理器的 PC 上。

## 2.3 数据集增强

为了进一步提升模型的鲁棒性,在训练集部分本研究采用 Pytorch 库中的数据增强技术来增加模型的泛化能力,使用的方法如下:

1)随机尺寸裁剪(random resized crop):将输入图像随机裁剪为不同的大小和宽高比,然后缩放所裁剪的图像为 300×300 像素。

2)转置(transpose):使用 50% 的概率将输入图像的 x、y 进行转置。

3)翻转(flip):使用 50% 的概率对输入图像进行水平或垂直翻转。

4)正则化(normalize):对输入图像按通道进行标准化,即先减去平均值,再减去标准差,通道顺序为 CHW (channel, height, width)。

平均值与标准差地取值如式(1)所示。

$$\text{mean} = [0.5, 0.5, 0.5]; \text{std} = [0.5, 0.5, 0.5] \quad (1)$$

经正则化公式如式(2)所示。

$$\text{image} = \frac{\text{image}-\text{mean}}{\text{std}} \quad (2)$$

## 2.4 实验细节

考虑到实验中使用到的数据集样本含量较少,鉴于迁移学习可以通过卷积层迁移不同图像之间含有共性的底层特征,提高训练效率<sup>[26]</sup>,本研究采用迁移学习策略进行训练。具体而言,使用 fish4knowledge<sup>[27]</sup>公开鱼类数据集在原 EfficientNetV2 网络上进行预训练,训练得到的模型参数迁移到本研究中改进的 EfficientNetV2-HDCA 模型

上作为初始训练权重进行训练。

在 EfficientNetV2-HDCA 模型的训练过程中,输入图像使用经由数据增强后的自建数据集图像,其中训练集图片尺寸大小为 300×300 像素,测试和验证集图像尺寸大小为 384×384 像素;损失函数选用交叉熵损失函数,并基于 VGD 优化器优化损失函数,初始学习率为 0.000 1,每批传入 8 张图片,迭代次数为 100 次。

## 2.5 评价标准

为了评估 EfficientNetV2-HDCA 模型的分类性能,本研究中采用混淆矩阵(Confusion Matrix)、准确率(Accuracy)、精确率(Precision)、召回率(Recall)、模型参数量(Parameters)、模型计算量(FLOPs)等几种量化指标对本研究的实验结果进行评价。具体如下:

混淆矩阵又称为可能性矩阵或错误矩阵,常用于图像分类精度的评价体系中。混淆矩阵的每一列元素代表了预测类别,每一列的元素总数表示预测为该类别的样本的数目;每一行元素代表了样本的真实标签类别,每一行元素总数表示该类别的样本的实际的数目;其中 True Positive(TP)、False Positive(FP)、True Negative (TN) 和 False Negative(FN) 分别代表真阳性、假阳性、真阴性、假阴性的样本数量。

准确率是指被正确预测的样本量占测试总样本量的百分比,计算公式如式(3)所示。

$$\text{Accuracy} = \frac{TP + TN}{TP + FN + FP + TN} \times 100\% \quad (3)$$

精确率,又称查准率,表示模型预测为正样本的结果中,真正是正样本所占的百分比。计算公式如式(4)所示。

$$\text{Precision} = \frac{TP}{TP + FP} \times 100\% \quad (4)$$

召回率,也叫查全率,是在实际为正样本中,被预测为正样本所占的百分比。计算公式如式(5)所示。

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% \quad (5)$$

模型参数量是该网络模型每一层参数量之和,用来衡量网络模型规模的大小。

模型运算量主要是指模型的每秒浮点运算数,主要是用来衡量网络模型的复杂程度。

## 3 结果和分析

### 3.1 EfficientNetV2-HDCA 模型稳定性分析

为了验证本研究提出的 EfficientNetV2-HDCA 模型性能的稳定性以及相关参数设定的合理性,将该模型采用 2.3 节中的实验设置进行训练,训练过程中的损失函数曲线如图 3 所示。从图中可以看出,在迭代过程中,模型在前 50 个 epoch 能够迅速且稳定的收敛;当迭代次数达到第 80 个 epoch 时,模型在验证集上的损失率开始趋于稳定,此时随着迭代次数的不断增加,损失率只有小幅度的震

荡,表明模型在此时已达到收敛状态,具有良好的分类鉴别能力。

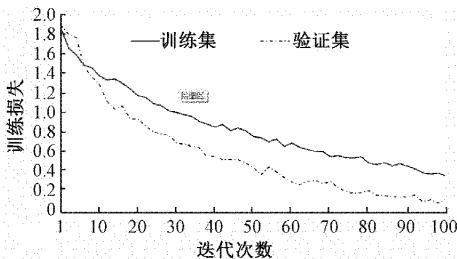


图 3 EfficientNetV2-HDCA 模型训练迭代损失

### 3.2 不同网络模型的识别效果比较

为了全面评估对原 EfficientNetV2 模型改进的合理性以及性能提升,本研究以准确率(ACC)、精确率(P)、模型运算量(FLOPs)和模型参数量(Parameters)作为评价指标,在验证数据集上将 EfficientNetV2 模型(EfficientNetV2)与仅使用混合空洞卷积模块改进的 EfficientNetV2 模型(EfficientNetV2-SE-HDC)、仅使用 CA 注意力模块替代 SE 模块改进的 EfficientNetV2 模型(EfficientNetV2-CA)、本研究中改良的 EfficientNetV2 模型(EfficientNetV2-HDCA),并以 RestNet50 模型作为参考进行了对比消融实验,实验结果如表 2 所示。

表 2 各类模型消融对比试验结果

Model	ACC/	P/	FLOPs	Parameters
	%	%	(B)	(M)
ResNet50	89.8	89.9	1.96	26
EfficientNetV2	93.3	93.5	8.8	21.61
EfficientNetV2-HDC	95.2	95.4	8.8	21.61
EfficientNetV2-CA	94.1	94.2	8.9	22.06
EfficientNetV2-HDCA	97.1	97.1	8.9	22.06

从表 2 可以清楚地看出,与经典模型 RestNet50 相比,轻量化的 EfficientNetV2 模型增加了模型的复杂程度,使其拥有更低的模型参数量以及更高分类性能,在准确率上和精确率上分别提升了 3.5 和 3.6 个百分点。说明选用 EfficientNetV2 模型作为本研究的基干模型用于鱼类的分类鉴别工作是合理的。通过对比 EfficientNetV2、EfficientNetV2-HDC、EfficientNetV2-CA、EfficientNetV2-HDCA 四个模型,我们发现仅使用空洞卷积或 CA 注意力机制分别改进原 EfficientNetV2 网络,在不改变网络复杂程度的同时,模型参数量仅有少量的上升,分类性能相较于原 EfficientNetV2 模型在准确率上分别提升了 1.9 和 0.8 个百分点;在精确率上分别提升了 1.9 和 0.7 个百分点;同时引入两种改进策略后,在准确率和精确率上分别上升了 3.8 和 3.6 个百分点,说明本研究对原 EfficientNetV2 模型的改进策略是有效的。综上所述,本

研究中改进的 EfficientNetV2-HDCA 模型具有分类精度高、模型参数轻量化、方便迁移和部署等特点。基于此特点本研究下一步的研究方案尝试将模型迁移到移动端进行部署,以面对在复杂的野外环境中对鱼类的分类鉴别工作。

### 3.3 使用 EfficientNetV2-HDCA 模型进行鱼类鉴定结果的数据分析

在本节中,使用 3.4 节中配置的实验参数对本研究提出 EfficientNetV2-HDCA 进行训练,并使用自建数据集中验证集部分的图像来验证模型的鱼类识别性能,图 4 显示了该模型用于识别验证数据集中鱼类各类型的混淆矩阵。从混淆矩阵中可以看出,鱼类物种识别的误认主要来自于鲶鱼(Catfish),通过观察数据集我们发现,主要来自于以下两点原因:(1)数据集中鲶鱼普遍体态较长,经过数据增强的中心裁剪后造成部分身体缺失,可能造成网络的误判;(2)水下的弱光环境截取的部分不同姿态的鲶鱼可能由于角度原因致网络误判。

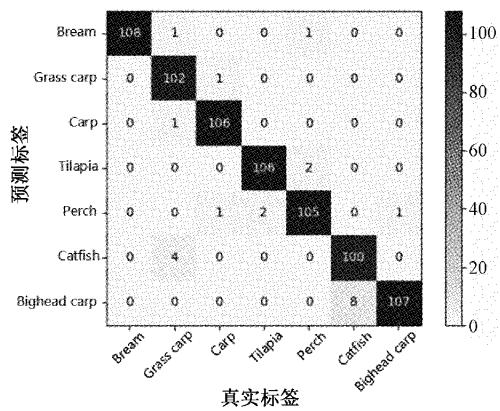


图 4 EfficientNetV2-HDCA 模型在验证集上的混淆矩阵

为了进一步展示对该模型定量评估结果,本研究使用 3.4 节中的评价标准对图 4 的混淆矩阵进行计算分析,计算结果如表 3 所示,通过分析表中数据进行分析后得出,改进后的 EfficientNetV2-HDCA 对于验证集中各类鱼类图像具有显著的识别效果。从单一鱼类识别结果来看,该模型对 7 种鱼类的识别准确率(Accuracy)高于 98.4%,精确率(precision)高于 93%,召回率(recall)高于 92.6%。针对单一鱼类的识别结果表明,该模型可以较为准确的识别测试数据集中的各类鱼类物种。从整体鱼类识别结果来看,我们发现该模型对测试数据集识别的整体准确率为 97.02%,说明 EfficientNet-v2-CA 模型对于数据集中存在的几种鱼类具有稳定的识别能力。

### 3.4 使用 EfficientNetV2-HDCA 模型进行鱼类鉴定结果的可视化分析

为了对比本研究改进前后模型对鱼类特征的关注能力的变化,本节采用 Grad-CAM<sup>[28]</sup> 技术,对验证集中的鱼类进行了注意力热图分析实验,部分实验结果如图 5 所示。

表 3 EfficientNetV2-HDCA 的量化评估结果

种类	TP	TN	FP	FN	ACC(%)	P(%)	R(%)	特异性(%)	整体 ACC(%)
鳊鱼	108	646	2	0	99.7	98.2	100	99.7	
草鱼	102	647	1	6	99	99	94.4	99.8	
鲤鱼	106	647	1	2	99.6	99.1	98.1	99.8	
罗非鱼	106	646	2	2	99.4	98.1	98.1	99.7	97.1
鲈鱼	105	644	4	3	99	96.3	97.2	99.4	
鲶鱼	100	644	4	8	98.4	96.2	92.6	99.4	
鳙鱼	107	640	8	1	98.8	93	99.1	98.8	

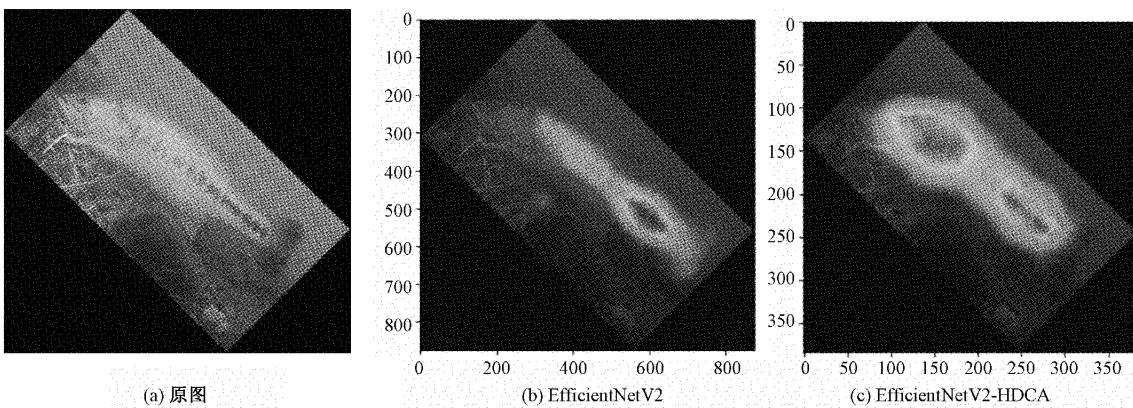


图 5 不同模型的鱼类图像关注热力图

通过对图 5 中改进前后模型关注区域热力图能够直观的看出,对于同一张待识别鱼类的原始图片,在改进前,模型虽然也能够关注到目标主体,但是关注范围还不够精准,模型只关注到了鱼类的部分纹理特征,而且容易受到目标所处环境的影响,关注到了一些无用的复杂背景信息;而改进后,模型不仅关注到了目标的纹理特征,进一步关注了目标的轮廓特征,受到目标所处环境的影响较小,不易被复杂背景所干扰。这表明经过改进后的模型可以更加全面的提取鱼类的关键特征,而且具有一定的抗背景干扰能力,能够有效的提高在复杂环境中对鱼类分类鉴别工作的准确率以及鲁棒性。

#### 4 结 论

普遍湿地的水下环境较为复杂,湿地中水下鱼类的物种分类鉴定对于湿地的保护以及科学数据统计工作具有重要意义。本研究利用自建的水下复杂环境鱼类数据集,并基于深度学习的计算机视觉技术对数据集中包含的 7 类典型湿地鱼类进行了分类鉴定工作,在此过程中,本研究提出了一个鱼类分类鉴定模型 EfficientNetV2-HDCA。该模型对于数据集中的鱼类识别准确率为 97.1%,与本文提到的经典模型 RestNet50 相比,拥有更少的模型参数量,以及更高的准确率和精确度;并通过可视化分析实验进行辅助验证,该模型对于鱼类的纹理和轮廓特征能够做到全面关注,而且不容易受到复杂环境的影响,能够胜任水下

环境下鱼类的分类鉴定工作。本研究为进一步开展野外环境中的鱼类分类和鉴别工作奠定了基础。在未来的研究中,我们尝试进一步扩充原有的自建数据集,在宽度上,加入更多不同种类的湿地常见鱼类图像;在深度上,增加同种鱼类在复杂环境下的多种姿态图像,以期模型能够学习到更加丰富的姿态特征。同时对本文提出的 EfficientNetV2-HDCA 模型进一步优化,并以此为基干网络,构建实时鱼类目标识别检测系统,部署在移动终端上,用以完成在野外环境下鱼类识别检测工作。

#### 参考文献

- [1] OGUNLANA S O, OLABODE O, OLUWADARE S A A, et al. Fish classification using support vector machine[J]. African Journal of Computing & ICT, 2015, 8(2): 75-82.
- [2] PATTENGILL-SEMMENS C V, SEMMENS B X. Conservation and management applications of the reef volunteer fish monitoring program [ M ]//Coastal Monitoring Through Partnerships. Springer, Dordrecht, 2003: 43-50.
- [3] 姚钦舟,庄苏峰,屠大维,等.水下透视投影图像非线性畸变校正方法[J].仪器仪表学报, 2020, 41(2): 176-183.
- [4] 刘翠翠.基于综合特征和多层感知器的图像分类[J].电子测量技术, 2019, 42(8): 74-77.
- [5] 韩辰希,刘惠义,商国中.视觉显著性纹理—色彩特征

- 融合的图像目标分类[J]. 电子测量技术, 2017, 40(11):94-98.
- [6] BOOM B J, HUANG P X, BEYAN C, et al. Long-term underwater camera surveillance for monitoring and analysis of fish populations[J]. VAIB12, 2012.
- [7] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012, 25.
- [8] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Computer Science, 2014.
- [9] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1-9.
- [10] 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.
- [11] XIE S, GIRSHICK R, DOLLÁR P, et al. Aggregated residual transformations for deep neural networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1492-1500.
- [12] CUI J, WEI B, WANG C, et al. Texture and shape information fusion of convolutional neural network for plankton image classification [C]//2018 OCEANS-MTS/IEEE Kobe Techno-Oceans (OTO), IEEE, 2018: 1-5.
- [13] MA Y, ZHANG P, TANG Y. Research on fish image classification based on transfer learning and convolutional neural network model [C]//2018 14th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD), IEEE, 2018: 850-855.
- [14] GÓMEZ-RÍOS A, TABIK S, LUENGO J, et al. Towards highly accurate coral texture images classification using deep convolutional neural networks and data augmentation [J]. Expert Systems with Applications, 2019, 118: 315-328.
- [15] 杨春兰,薛大为. 基于卷积神经网络的淡水鱼分类识别[J]. 西南民族大学学报(自然科学版), 2020, 46(6): 611-618.
- [16] ANDREW G, MENG LONG Z. Efficient convolutional neural networks for mobile vision applications[J]. 2017.
- [17] ZHANG X, ZHOU X, LIN M, et al. Shufflenet: An extremely efficient convolutional neural network for mobile devices [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 6848-6856.
- [18] TAN M, LE Q. Efficientnet: Rethinking model scaling for convolutional neural networks [C]//International Conference on Machine Learning, PMLR, 2019: 6105-6114.
- [19] 刘南彬,裴云强,蒋皓,等. 基于VD-MobileNet网络的WebAR生活垃圾分类信息可视化方法[J/OL]. 图学学报, 1-11.
- [20] 甘雨,郭庆文,王春桃,等. 基于改进EfficientNet模型的作物害虫识别[J]. 农业工程学报, 2022, 38(1): 203-211.
- [21] 李思瑶,刘宇红,张荣芬. 多尺度特征融合的细粒度图像分类[J]. 激光与光电子学进展, 2020, 57(12): 91-97.
- [22] TAN M, LE Q. Efficientnetv2: Smaller models and faster training [C]//International Conference on Machine Learning. PMLR, 2021: 10096-10106.
- [23] LIU J, LI C, LIANG F, et al. Inception convolution with efficient dilation search[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 11486-11495.
- [24] WANG P, CHEN P, YUAN Y, et al. Understanding convolution for semantic segmentation [C]//2018 IEEE Winter Conference on Applications of Computer Vision(WACV), IEEE, 2018: 1451-1460.
- [25] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713-13722.
- [26] SHORTEN C, KHOSHGOFTAAR T M. A survey on image data augmentation for deep learning [J]. Journal of Big Data, 2019, 6(1): 1-48.
- [27] BOOM B J. Fish4Knowledge Database Structure, Creating and Sharing Scientific Data [M]//Fish4Knowledge: Collecting and Analyzing Massive Coral Reef Fish Video Data. Springer, Cham, 2016: 73-82.
- [28] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-cam: Visual explanations from deep networks via gradient-based localization [C]//Proceedings of the IEEE International Conference on Computer Vision, 2017: 618-626.

### 作者简介

龚瑞昆,博士,教授,硕士生导师,主要从事检测技术及智能装置等方面的研究工作。

E-mail:grk@ncst.edu.cn

赵福生,助理工程师,主要从事智能控制与应用等方面的研究工作。

E-mail:fu7209@163.com

赵学智(通信作者),硕士研究生,主要从事计算机视觉应用及图像处理方面的研究。

E-mail:444537344@qq.com