

王一非,袁涛,吴鹏飞.基于双重注意力机制的鱼类体表病理识别方法[J].华中农业大学学报,2025,44(2):73-82.
DOI:10.13300/j.cnki.hnlkxb.2025.02.008

基于双重注意力机制的鱼类体表病理识别方法

王一非^{1,2},袁涛¹,吴鹏飞^{1,2}

1. 华中农业大学信息学院,武汉 430070; 2. 农业农村部智慧养殖技术重点实验室,武汉 430070

摘要 为提高鱼类体表病理识别精确度及识别效率,解决当前识别过程中对人工依赖严重且识别准确性低等问题,根据4种发病率高且对鱼类危害大的鱼病构建鱼类体表病理数据集,基于Resnet-18模型进行改进优化,融合空间注意力和SE通道注意力双重注意力机制构建出高识别精度的DBA_Resnet-18模型,并基于该模型开发了鱼病实时智能识别可视化系统。改进后模型将SE通道注意力模块添加在网络中部,在网络尾部引入了空间注意力机制。测试结果显示,DBA_Resnet-18模型对鱼类体表病理分类准确率达到96.75%,相比于常见的模型Resnet-18、Resnet-34、Resnet-50、Resnet-101、Swin Transformer、VGG-16、VGG-19和AlexNet分别高出1.71、2.12、2.37、2.83、2.51、2.23、2.50和3.53个百分点。研究结果表明,本研究提出的模型及鱼病智能识别可视化系统能够对不同鱼类体表病理进行快速、精确的分类识别,实现了鱼病识别系统的智能化,可用于实际环境中诊断鱼类体表病理类型。

关键词 鱼类体表病理;深度学习;注意力机制;Resnet-18;鱼病智能识别

中图分类号 S941; TP391.41; TP18 **文献标识码** A **文章编号** 1000-2421(2025)02-0073-10

我国是鱼类养殖大国,我国渔业养殖规模大、需求高,预计在“十四五”期间,我国渔业总产量将稳定在6 000万~7 100万t^[1]。我国渔业养殖多采用粗放型人工养殖模式,这种模式主要以人力劳动为主,对养殖条件要求不高,但对自然资源、经济资源和人力资源造成了一定程度的浪费。在病理诊断方面,全球范围内常见的做法是传统的以个人经验为主导的方法^[2]。然而,这种方法的准确率取决于诊病者的经验,其精度较低且不稳定,容易受到环境、状态等因素的干扰,误判率大,阻碍了行业的发展。因此,开发鱼类体表病理智能识别系统十分必要。

在早期的鱼类体表病理智能诊断领域,主要采用专家系统方法,其发展可分为几个关键阶段。王成志等^[3]设计了一套鱼病诊疗专家系统,该系统模拟鱼病专家的推理和判断过程,完成鱼病的诊断与治疗。这代表了专家系统在鱼病诊断领域的初步应用。温继文等^[4]在总结专家诊断鱼病经验的基础上,结合鱼病知识特点,构建了基于UML的鱼病远程诊断推理系统。这一进步展示了信息化技术与传统经验相结合的可能性,为远程诊断提供了新思路。进

一步地,徐妙君等^[5]采用模糊kohonen聚类网络对鱼病典型案例进行聚类分析,并引入神经网络的分类能力实现鱼病的快速诊断,为提高诊断速度和准确性开辟了新路径。这类方法应用专家系统的思想尽管在一定程度上提高了鱼病识别的效率及信息化水平,但大多仍以人为诊断经验作为推理基础,使得诊断精度和效率受到限制^[6]。Lopes等^[7]提出应用人工神经网络诊断由原生动物和细菌引起的鱼类疾病,该模型的分类准确率高达97%。Mia等^[8]采用机器学习技术,设计了一种基于随机森林的鱼病识别算法,该算法对鱼类皮肤溃疡等疾病进行分类识别,准确率可达88.87%。近年来深度学习技术迅猛发展,卷积神经网络(CNN)在图像识别领域取得了重大进展,应用机器视觉方法识别鱼类体表病理成为鱼病识别的研究趋势。Malik等^[9]结合机器学习算法与图像处理技术,实现对患鱼类流行性溃疡综合征(EUS)鱼的形态学运算及病理特征提取,完成了对鱼类溃疡综合症的分类诊断,其分类准确率达到86%。这些研究不仅提高了诊断精度,也显示了深度学习技术在提取复杂病理特征方面的能力。此

收稿日期:2023-11-03

基金项目:国家重点研发计划项目(2022YFD1400400)

王一非, E-mail:857237460@qq.com

通信作者:吴鹏飞, E-mail:chriswpf@mail.hzau.edu.cn

外,Waleed等^[10]研究了基于卷积神经网络的鱼病检测与诊断系统,针对白点病(ichthyophthiriasis,Ich)等3种鱼类体表常见疾病取得了较好的检测结果。Yu等^[11]提出的基于鱼类皮肤病的目标检测算法模型,实现了对深海养殖环境中鱼类皮肤健康的实时监测。这些进展展示了深度学习和其他高级算法在实时监测和精确分类方面的优势。

然而,尽管上述研究在技术上取得了显著进步,但多以二分类模型研究为主,测试环境相对理想,且准确率水平仍有待提高。这表明鱼类体表病理诊断领域在提高诊断准确率和适应复杂环境方面仍有较大的发展空间。

本研究设计DBA_Resnet-18模型,以解决鱼类体表病理特征复杂、局部特征提取困难及识别背景复杂的问题。该模型基于Resnet-18^[12]架构,增加了空间注意力机制^[13]和SE通道注意力机制^[14],目的在于加强对鱼类体表病理特征的关键提取,从而提高模型捕捉输入信息相关性和依赖性的能力,并增强算法的鲁棒性。通过这种方法,本研究旨在提高鱼类体表疾病识别的精确度,并探索该方法在其他水生动物健康监测和疾病预防中的潜在应用。



图1 鱼类体表病理图像

Fig.1 Pathological images of fish surface

1.2 Resnet-18模型结构

在深度学习的发展进程中,深度神经网络常面临梯度消失、梯度爆炸等问题,这限制了网络的深度和性能。为了解决这一问题,有研究者提出了ResNet(残差网络)^[12]模型,其中ResNet-18是一种轻量且性能优良的网络架构,如图2所示。ResNet-18主要采用残差块(residual block)作为其核心组成部分。一个基本的残差块包含2个 3×3 的卷积层,每个卷积层后接一个批量归一化层和ReLU激活函数。残差块采用跳跃连接(skip connection),直接将输入连接到输出,形成残差网络结构,其结构如图3

1 材料与方法

1.1 数据采集及数据集制作

本研究以疾病出现频率及鱼类患病概率较高、对鱼类危害性较大且人工识别难度大的4种鱼类体表疾病白点病(Ich)、赤皮病(erythrodermatitis)、打印病(stigmatisis)和竖鳞病(lepidorthosis)作为分类的研究对象,进行数据采集。该数据集由互联网搜索鱼病图片数据制作而成,经过数据清洗及图像填充后得到共7 166张图片。其中白点病图片数量为1 954张,赤皮病数量为2 004张,打印病数量为2 004张,竖鳞病数量为1 204张。4种鱼类体表病理典型图像如图1所示,数据集中图像背景环境更贴近于真实场景,鱼病的性状表征相对较清晰,可以还原模拟真实生活环境中鱼类患病状态,进一步提升模型在真实场景中的实用性和可靠性。

在保证充足的训练数据和均衡的验证数据前提下,本研究按照7:3的比例随机将数据集中所有图像划分为训练集和测试集。为增强模型的泛化能力以及避免训练过程中出现过拟合问题,对训练集使用镜像翻转、随机裁剪、随机旋转图像角度、横纵平移、随机改变图片亮度、对比度、锐化值等方法完成训练数据扩充。

所示。通过这种方式,梯度可以直接通过网络向后传播,有效缓解了梯度消失问题,从而可以训练更深的网络。

1.3 空间注意力机制

空间注意力机制主要关注输入特征图的每个空间位置的重要性权重。通过计算输入特征图在通道维度上的加权和或其他运算,生成一个空间注意力图,该图强调了原特征图中更为重要的空间位置,指导后续层更加关注这些区域^[15],如图4所示。

具体来说,给定一个特征图 F ,空间注意力机制产生一个同等空间尺寸的注意力图 M ,将 M 与原始

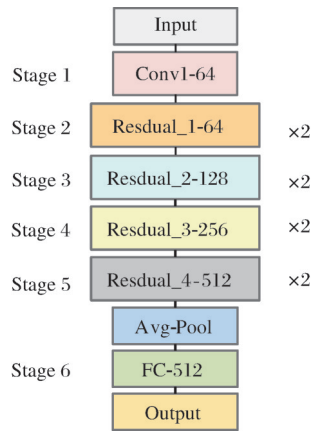


图2 Resnet-18网络结构示意图

Fig.2 Resnet-18 network structure diagram




图3 残差网络结构示意图

Fig.3 Schematic diagram of residual network structure
特征图 F 通过广播机制进行元素相乘,得到加权后的特征图,其计算公式如下:

$$M = \sigma(g(F)) \quad (1)$$

$$F' = M \odot F \quad (2)$$

式(1)、式(2)中, σ 表示 Sigmoid 激活函数, $g(F)$ 表示从输入特征图 F 到空间注意力图 M 的映射函数,由 F 在通道维度 C 上进行平均池化来实现, M 和 F 完成矩阵元素相乘操作后得到最终的特征图。




图4 空间注意力机制示意图

Fig.4 Spatial attention mechanism illustration

1.4 SE 通道注意力模块

卷积神经网络(CNN)通常更倾向于捕获全局的、显著的特征^[16],因此在自动关注和提取鱼类局部病理特征方面难以达到较好的效果。SE(squeeze-

and-excitation)注意力机制提出了一种独特的通道重新校准方法,旨在显式地建模特征通道间的依赖关系,并进行动态调整,如图5所示。




图5 SE通道注意力模块示意图

Fig.5 SE channel attention module illustration

这种通道注意力通过评估每个通道的信息内容和重要性,为与目标病理状态密切相关的特征通道分配更高的权重^[17],同时减弱或抑制那些与识别任务关联度较低的通道,从而能够更好地捕获和强调与鱼病理特征相关性更强的信息。其计算公式如下:

$$s = \sigma(W_2 \delta(W_1 z)) \quad (3)$$

$$\tilde{F} = s_c \cdot F_{ijc} \forall i, j, c \quad (4)$$

公式(3)、式(4)中, σ 代表 Sigmoid 激活函数, δ 为 ReLU 激活函数, W_1 和 W_2 是 2 个全连接层的权重, SE 注意力机制首先执行全局平均池化操作以产生通道描述子 z ,随后通道描述子通过 2 个全连接层进行变换,产生通道注意力权重 s ,通道注意力权重和原始输入特征相乘得到重新校准后的特征图。

1.5 DBA_Resnet-18 鱼类体表病理识别模型

本研究选择 DBA_Resnet-18 作为鱼病识别问题的解决方案是基于对病鱼识别特定需求的深入理解和对现有模型能力的全面评估。鱼病识别任务的核心挑战在于病理特征的细微差异识别和复杂环境下的稳定性。首先,针对病鱼体表病理特征的微妙性和多样性, DBA_Resnet-18 模型利用深度残差网络架构有效捕获这些细微特征。这种架构的高精确度和敏感性为精确识别提供了坚实的基础,即使它们在视觉上非常接近,模型也能够辨识出各种微小的病理变化。其次,考虑到鱼类图像数据中常见的背景变化,如水质和光照条件的变化, DBA_Resnet-18 模型通过融合空间注意力和通道注意力机制,增强了对关键区域与次要背景的区分能力。这种双重注意力机制提升了模型在不同环境下的适应性和稳健性,使模型能够在多变的背景条件下保持高效的识别性能。空间注意力机制通过计算特征图的平均和最大响应,生成空间权重图,该权重图强调图像中的关键空间位置,当与原始特征图

相乘时改进后的模型更加关注于鱼类体表上局部病理特征从而增强模型的识别能力。SE通道注意力机制强化了模型特征通道的分析能力,保证模型在计算过程中更加关注那些对于鱼类体表病理识别更重要的通道,进一步提升了模型在细微病理特征区分上的准确性。这在处理视觉上相似但病理学上不同的病鱼样本时尤为重要,有效避免了对病理特征的误识别^[18]。

DBA_Resnet-18模型在第三和第四阶段残差块运算之后加入了SE通道注意力机制,上述位置引入SE通道注意力机制有效提升了模型关键特征提取的能力,强化了与鱼体表病理相关通道的重要性,维持了病理特征的多样性。相较于在模型尾部引入SE通道注意力机制,将SE置于模型的中间位置可以有效避免计算成本的增加,从而提高了模型的计算效率和整体性能^[19]。改进后的Resnet-18模型在最后一个残差块计算完成后、进入全连接层之前,加入了空间注意力机制。这一新增机制有助于减少信息损失,并确保模型在进行最终分类决策时,能够关注到经过注意力机制筛选后的关键病理区域。在全连接层之前引入空间注意力机制,显著提升了模型的决

策能力和分类准确率。

DBA_Resnet-18模型整体结构如图6所示,鱼类体表病理图片在输入层被统一调整为224像素×224像素的RGB三通道格式,经过特征提取网络第一阶段的二维卷积及最大池化层后,得到尺寸56×56×64的特征图。随后特征图进入第二阶段,该阶段由2个64通道的残差块组成。在第三阶段特征图首先通过1个残差块,其通道数从64增加到128,然后再经过另一个128通道的残差块,随后,特征图被传递给SE通道注意力模块。第四阶段和第三阶段类似,但是通道数在此阶段从128增加到256,在2个256通道的残差块之后,特征图再次被传递给通道注意力模块。第五阶段特征图首先通过一个残差块,其通道数从256增加到512,然后再经过另一个512通道的残差块。完成5个阶段后,特征图尺寸变为7×7×512,经过空间注意力模块、全局平均池化、展平操作后进入全连接层,全连接层的输出由Softmax函数处理后计算得到鱼类体表病理图片的特征值。根据这些特征值,模型预测每种鱼病的概率并将最高概率的鱼病种类作为预测结果返回到输出层,从而实现鱼类体表病理的分类识别。

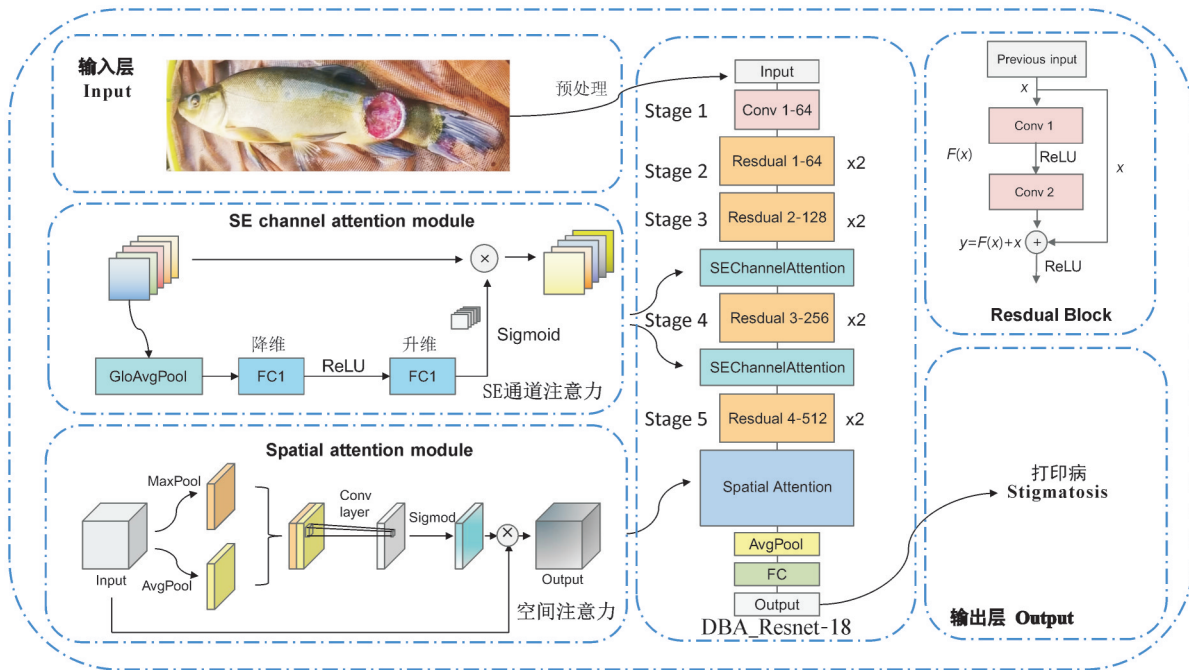


图6 鱼类体表病理识别模型结构图

Fig.6 Fish surface pathology recognition model architecture diagram

1.6 损失函数选择

本研究选择交叉损失熵(cross entropy loss,公式中以 L 表示)作为改进Resnet-18模型的损失函数,其

在网络训练时优化更快,梯度更大,处理分类问题时效果更好。其表达式如下:

$$L = -\frac{1}{M} \sum_i^M \sum_j^N p_{ij} \log q_{ij} \quad (5)$$

式(5)中, M 表示样本总数, N 表示类别数, q_{ij} 表示预测值中第 i 个样本类别为 j 的概率分布值, p_{ij} 表示实际值中第 i 个样本类别为 j 的概率分布值。

1.7 实验环境及模型训练参数配置

本研究所采用操作系统为 Windows 10, 使用 Python 3.8.13 作为系统整体编写语言, 深度学习模型框架为 Pytorch 1.11.0, CUDA 版本为 11.3.1, CUDNN 版本为 8.0。改进后基于双重注意力机制的 Resnet-18 模型所使用的服务器硬件配置如下: 处理器为 Intel(R) Xeon(R) Platinum 8124M CPU, 主频为 3.00 GHz, 内存为 128 GB, 显卡为 NVIDIA GeForce RTX 3090(24 GB)。

在模型训练前, 统一将图片输入尺寸调整为 224 像素 \times 224 像素, 初始学习率设置为 0.000 1, 使用 Adam^[20] 作为模型训练过程中的优化器, 提升模型的收敛速度, 优化调整训练过程中的梯度数据, 权重衰减系数设置为 0.01。为提升模型泛化能力及避免过拟合采用了 L2 正则化方式, 设定训练迭代(epoch)为 100, 单次训练样本 Batch size 设置为 32。

1.8 评价指标

本研究采用精确率(precision, P)、召回率(recall, R)、 F_1 分数(F_1 -score, F_1)和准确率(accuracy, A)等指标衡量模型性能, 各个评价指标的取值区间为 $[0, 1]$ 。

$$P = \frac{T_p}{T_p + F_p} \quad (6)$$

$$R = \frac{T_p}{T_p + F_N} \quad (7)$$

$$F_1 = \frac{2 \times T_p}{2 \times T_p + F_p + F_N} \quad (8)$$

$$A = \frac{T_p + T_N}{T_p + T_N + F_p + F_N} \quad (9)$$

T_p 表示实际为正类并且被模型预测为正类的实例, F_p 表示实际为负类但模型错误地将其预测为正类的实例, T_N 表示实际为负类并且被模型正确预测为负类的实例, F_N 表示实际是正类但模型错误预测为负类的实例。

2 结果与分析

2.1 消融实验

为了证明空间注意力机制和 SE 通道注意力机制特征融合的有效性和准确性, 本研究选择了 3 种不同配置的网络以及我们提出的 DBA_Resnet-18 网络进行消融实验。这些配置分别为基础 Resnet-18(ba-

sic Resnet-18)、带空间注意力的 Resnet-18(Resnet-18 with spatial attention) 和带 SE 通道注意力的 Resnet-18(Resnet-18 with SE channel attention)。表 1 给出了消融实验的 4 种网络消融模块对比, 4 类鱼病图像分类的精确率、召回率、 F_1 分数和准确率的结果对比如表 2 所示。

表 1 4 种网络消融模块对比

Table 1 Comparison of four network ablation modules

网络类型 Network type	Resnet-18	空间注意力机制 Spatial attention mechanism	SE 通道注意力 机制 SE channel atten- tion mechanism
基础 Resnet-18 Basic Resnet-18	✓		
带空间注意力的 Resnet-18 Resnet-18 with spatial attention	✓	✓	
带 SE 通道注意力的 Resnet-18 Resnet-18 with SE channel attention	✓		✓
DBA_Resnet-18	✓	✓	✓

表 2 鱼病图像分类结果对比

Table 2 Comparison of fish disease image
classification results

网络类型 Network type	精确率 Precision	召回率 Recall	F_1 分数 F_1 -score	准确率 Accuracy
基础 Resnet-18 Basic Resnet-18	95.66	95.48	95.57	95.04
带空间注意力的 Resnet-18 Resnet-18 with spatial attention	95.83	95.31	95.55	95.32
带 SE 通道注意力的 Resnet-18 Resnet-18 with SE channel attention	96.21	95.98	96.12	95.87
DBA_Resnet-18	96.91	96.83	96.87	96.75

本研究对比了 4 种不同的网络架构在鱼病图像识别任务上的性能。这 4 种网络包括基础的 ResNet-18 模型以及通过增加不同注意力机制改进的模型, 即加入空间注意力机制的 Resnet-18 with spatial attention, 加入 SE 通道注意力机制的 Resnet-18 with SE channel attention, 以及同时融合空间注意力和 SE 通道注意力机制的 DBA_Resnet-18。本研究评估了这些网络在精确率、召回率、 F_1 分数和准确率 4 个指标上的表现。试验结果显示, 基础的 ResNet-18 模型(Basic Resnet-18)在鱼病图像识别任务上已经具有

较高的性能,达到了95.66%的精确率、95.48%的召回率、95.57%的 F_1 分数和95.04%的准确率。当引入空间注意力机制(Resnet-18 with spatial attention)和SE通道注意力机制(Resnet-18 with SE channel attention)时,模型性能略有提升。具体而言,Resnet-18 with spatial attention的精确率提升到95.83%,召回率为95.31%, F_1 分数为95.55%,准确率为95.32%;而Resnet-18 with SE channel attention在这些指标上的表现分别为96.21%、95.98%、96.12%和95.87%。最引人注目的是,当同时融合空间注意力和SE通道注意力机制(DBA_Resnet-18)时,模型在所有评估指标上均获得了最佳表现。具体来说,DBA_Resnet-18达到了96.91%的精确率、96.83%的召回率、96.87%的 F_1 分数以及96.75%的准确率。这一结果表明,融合空间注意力和SE通道注意力机制能够显著提升鱼病图像识别的性能。

2.2 不同神经网络模型对比

本研究选择DBA_Resnet-18、Resnet-18、Resnet-34、Resnet-50、Resnet-101、Swin Transformer、VGG-16、VGG-19、AlexNet等9种网络模型^[21-23],对鱼类体表病理数据集进行训练和测试,测试集精确率、召回率、 F_1 分数和准确率结果如表3所示。DBA_Resnet-18模型针对鱼类体表病理的识别准确率达到了96.75%,相比于常见的卷积神经网络模型Resnet-18、Resnet-34、Resnet-50、Resnet-101、Swin Transformer、VGG-16、VGG-19和AlexNet分别高出1.71、2.12、2.37、2.83、2.51、2.23、2.50和3.53百分点。在鱼类体表病理数据集上,与未改进的Resnet-18网络模型相比,DBA_Resnet-18网络的精确率、召回率、 F_1 分数和准确率分别提升了1.25、1.35、1.30和1.71百分点。DBA_Resnet-18网络在鱼类体表病理数据集上的各项评价指标及分类能力均超过了Resnet-34、Resnet-50、Resnet-101、Swin Transformer、VGG-16和VGG-19等模型。试验结果证明,在原始Resnet-18模型的基础上引入空间注意力与SE通道注意力结合的双重注意力机制能有效提升模型在鱼类体表病理数据集上的特征提取能力及泛化能力,显著提升了模型的识别准确率及分类能力。

2.3 不同鱼病识别结果对比

基于双重注意力机制的DBA_Resnet-18模型对白点病、赤皮病、打印病和竖鳞病4种鱼类体表疾病的识别结果如表4所示。

表3 不同模型的种类识别结果对比

模型 Model	精确率 Precision	召回率 Recall	F_1 分数 F_1 -score	准确率 Accuracy
AlexNet	93.35	93.12	93.23	93.22
VGG-16	94.56	94.40	94.48	94.52
VGG-19	94.30	94.01	94.15	94.25
Resnet-18	95.66	95.48	95.57	95.04
Resnet-34	94.52	94.89	94.71	94.63
Resnet-50	94.06	94.31	94.19	94.38
Resnet-101	93.86	93.95	93.84	93.92
Swin Transformer	94.31	93.93	94.10	94.24
DBA_Resnet-18	96.91	96.83	96.87	96.75

表4 4种鱼类体表病理识别结果对比

鱼病种类 Types of fish diseases	精确率 Precision	召回率 Recall	F_1 分数 F_1 -score
白点病 Ichthyophthiriasis	99.13	96.76	97.93
赤皮病 Erythrodermatitis	94.08	97.67	95.85
打印病 Stigmatisis	96.63	95.35	95.98
竖鳞病 Lepidorthosis	97.78	97.51	97.65

由表4所示的数据可见,DBA_Resnet-18模型在识别白点病和竖鳞病时表现出了卓越的性能,其精确率和召回率均显著高于其他病症。相对地,尽管打印病在鱼类体表上的视觉表现十分显著,该模型在识别此疾病时的性能却相对较低,可能是由于其图像处理上的复杂性相对较高,尤其是在病理特征方面。具体来说,打印病的特征可能与正常鱼鳞的自然变异以及赤皮病的某些视觉特征相混淆,这导致DBA_Resnet-18模型在特征提取和分类过程中出现误判。这种误判不仅降低了对打印病的识别准确性,也可能影响整体的识别性能。

2.4 模型输出特征可视化

为进一步说明DBA_Resnet-18模型中卷积层工作原理及对鱼类体表病理特征提取的合理性,分析模型决策过程,本研究利用Grad-CAM^[24](gradient-weighted class activation mapping)方法对模型进行了特征可视化分析。根据图6中DBA_Resnet-18模型的网络结构,分别对卷积块1和残差块2、3、4、5的最后一个卷积层进行输出特征可视化并对输入图片与激活映射图进行叠加,更加直观地反映网络特征权重的集中区域,如图7所示。

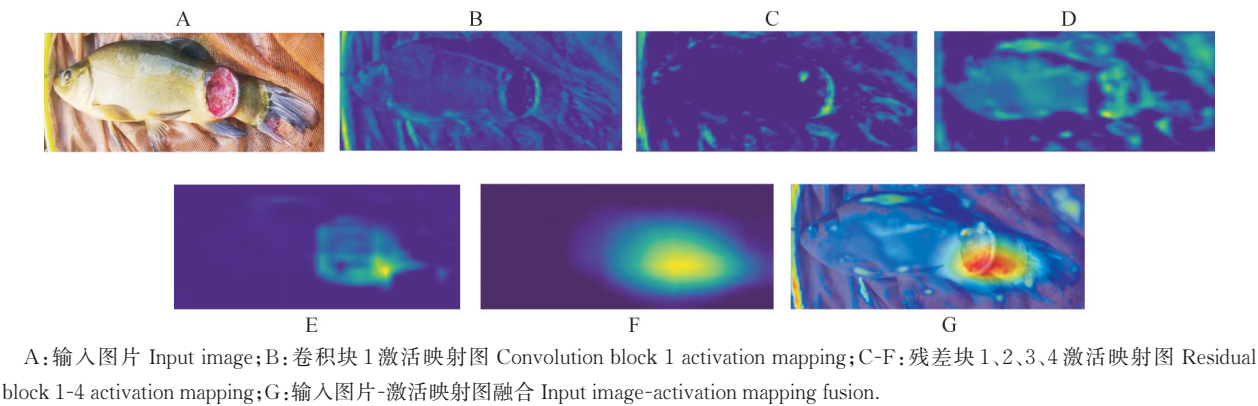


图 7 DBA_Resnet-18 激活映射图
Fig.7 DBA_Resnet-18 activation mapping

图 7A 展示了一个原始的输入图像,其中鱼体上的病理变化为模型预测的依据。图 7B-F 展示了该图片经过 5 个不同的层的激活热力图,图 7B 中模型广泛地关注了大部分的体表区域,到了图 7D,热力图关注的区域明显减少,特征区域开始集中于鱼的体表病理明显的位置,图 7E 和 7F 的结果显示,模型关注区域集中在鱼体表病理所在位置,通过图 7G 的融合图可以看到鱼体表上明显的红色热力区域与其病理现象的位置高度一致,表明模型高度关注这部分来做出准确的分类决策。图 7 的结果表明,模型在输入图片中的关注焦点显著地集中在鱼体表面的病理变化区域,这些区域恰好是鱼类体表病理特征的关键部位,进而说明 DBA_Resnet-18 模型能准确地识别和定位病理特征,并且模型不仅仅是进行浅层的特征匹配,而是能够深入捕获到病理现象背后的复杂模式,从而证实了 DBA_Resnet-18 模型在捕获和定位鱼类体表病理特征的能力,为其在实际应用中的可行性提供了有力的证据。

2.5 模型复杂度比较

AlexNet、VGG 系列 (VGG-16、VGG-19)、ResNet 系列 (ResNet-18、ResNet-34、ResNet-50、ResNet-101)、Swin Transformer 以及 DBA_ResNet-18 模型的复杂度比较结果如表 5 所示。DBA_ResNet-18 浮点运算数为 1.832 4 亿次,略高于 ResNet-18 的 1.822 3 亿次,低于 Swin Transformer、ResNet-34、ResNet-50、ResNet-101、VGG-16 和 VGG-19 这 7 种模型。除 AlexNet 和 ResNet-18 以外,DBA_ResNet-18 的训练时间及推理时间均处于较低水平,在实际应用中具有可行性。AlexNet 的训练时间、推理时间耗时最短,浮点运算数最小,表明其结构相对简单,但结合表 3 可知其准确率较低无法

满足复杂应用场景中的识别需求。综合浮点运算数、训练时间和推理时间 3 类指标,DBA_ResNet-18 模型的复杂度均保持在较低水平且拥有较高的准确率,适合在实际鱼类体表病理识别场景中部署。

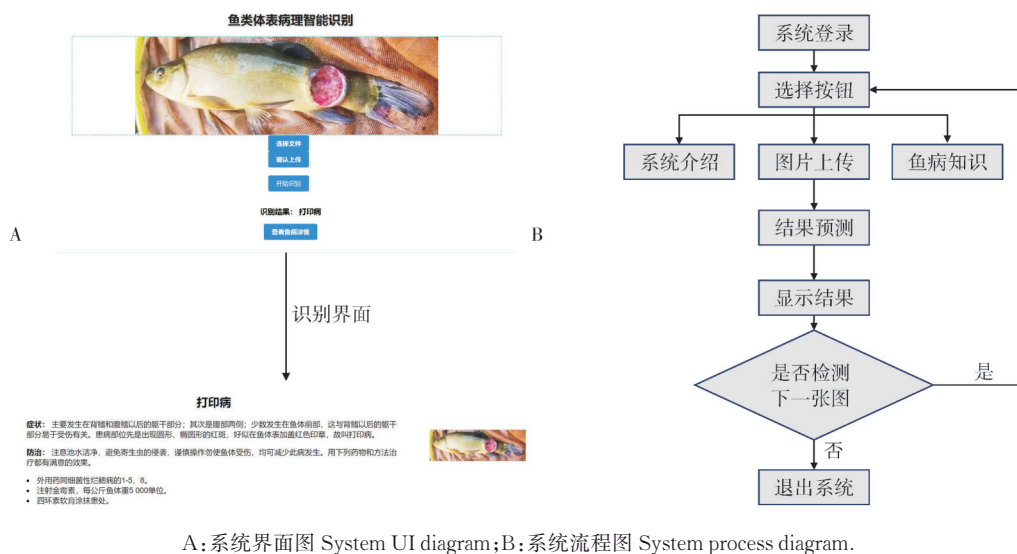
表 5 模型复杂度比较结果
Table 5 Model complexity comparison results

模型 Model	训练时间/s Training time	推理时间/ms Inference time	浮点运算数/亿次 FLOPs
AlexNet	58.815 6	0.934 8	0.757 1
VGG-16	158.828 7	2.301 4	15.502 6
VGG-19	178.752 0	2.900 1	19.703 2
Resnet-18	80.224 9	1.277 4	1.822 3
Resnet-34	119.943 2	1.832 8	3.684 2
Resnet-50	147.562 7	2.261 0	4.143 1
Resnet-101	178.764 1	2.824 9	7.862 9
Swin Transformer	218.512 2	3.570 1	8.784 5
DBA_Resnet-18	87.176 4	1.582 6	1.832 4

2.6 鱼类体表病理智能识别可视化系统开发

本研究开发了一款基于 Flask 框架的鱼类体表病理智能识别可视化系统,Flask 作为一种轻量级的 Web 应用程序框架,使得此系统具有易于部署和扩展的特点。该系统核心是基于双重注意力机制的 DBA_Resnet-18 模型,专门针对鱼类体表病理特征进行了训练和优化。系统主要分为系统登录、图像上传、结果预测和诊断分析 4 个模块。

如图 8 所示,用户可以通过简洁的界面上传待识别的鱼类体表图像。一旦图像被上传,后端的深度学习模型会即刻开始识别处理,精确地锁定可能存在的病理迹象,诊断的结果会在 Web 前端进行实时呈现。同时,系统还为用户提供了与所识别病症相关的辅助信息,以便于他们进一步了解诊断结果并有针对性地进行病害防治。



A:系统界面图 System UI diagram;B:系统流程图 System process diagram.

图8 鱼类体表病理智能识别可视化系统图

Fig.8 Intelligent visualization system for fish surface pathology recognition

3 讨论

本研究提出了一种基于双重注意力机制 Resnet-18 模型的鱼类体表病理识别方法,以鱼类体表白点病、赤皮病、打印病和竖鳞病 4 种疾病作为研究对象,收集了 7 166 张鱼病图片并构建出鱼类体表病理数据集。以 Pytorch 为深度学习框架,在原始 Resnet-18 网络模型的基础上引入了空间注意力和 SE 通道注意力结合的双重注意力机制,构建了 DBA_Resnet-18 模型并基于该模型开发了一套鱼类体表病理智能识别可视化系统。在本研究中 DBA_Resnet-18 模型在鱼病测试集上的分类准确率达到 96.75%, F_1 分数相比于 Resnet-18、Resnet-34、Resnet-50、Resnet-101、Swin Transformer、VGG-16、VGG-19 和 AlexNet 8 种模型分别提高了 1.30、2.16、2.68、3.03、2.77、2.39、2.72 和 3.64 百分点,取得了显著的提升。在精确率、召回率和 F_1 分数方面的表现也都优于上述 8 种模型。通过使用 Grad-CAM 方法进行特征可视化,揭示了 DBA_Resnet-18 模型的决策机制,激活映射图结果展示了模型在分类鱼类体表病理疾病时所关注的关键区域明确对应于鱼的体表病理现象,证明了模型在确定病理特征时的准确性。DBA_Resnet-18 浮点运算数、训练时间和推理时间分别为 1.832 4 亿次、87.176 4 s 和 1.582 6 s 略高于 Resnet-18,表明 DBA_Resnet-18 模型在不大量增加模型复杂度的前提下能有效提升对鱼类体表病理的特征提

取及识别能力。在实际应用中,将此模型整合入基于 Flask 框架的实时鱼病诊断系统,为人工鱼病诊断中成本高、效率低和判断准确性变化大的问题提供了可行的解决方案^[25-26]。上述结果表明本研究提出的方法可以满足鱼类体表病理智能分类识别的精度要求,DBA_Resnet-18 模型具有较强的鲁棒性和泛化能力,构建的鱼类体表病理智能识别可视化系统提升了模型在实际使用过程中的实用性及准确性,保证了识别结果的时效性及稳定性,有效解决了人工识别鱼病过程中成本高、效率低和判别水平不稳定等问题。

未来工作可探索将其他类型的注意力机制,及基于 Transformer 的模型整合到系统中,从而进一步提高处理序列图像数据或视频输入的能力。此外,在后续的研究中计划采取一系列措施以增强模型在打印病识别上的性能。首先,考虑在训练数据集中增加打印病样本的数量和多样性,这将有助于模型更好地学习和识别打印病的独特特征。同时,从提升模型整体泛化能力考虑,增加其他鱼种类和数量也至关重要。目前使用的数据集在鱼种和疾病类型上有限,通过扩展数据集以包括更多种类的鱼和更广泛的体表疾病状态,可以显著增强模型的泛化能力。引入来自不同地理位置的鱼类样本和各种病理阶段的数据,将有助于模型学习更全面的特征表示,使其能够适应更广泛的应用场景,为水产业的智能化发展带来实质性的益处。

参考文献 References

- [1] 鲁泉,陈新军.改革开放40年来中国渔业产业发展及十四五产量预测[J].上海海洋大学学报,2021,30(2):339-347.LU Q, CHEN X J. Development of Chinese fishery industry in 40 years of reform and opening up and production forecast in the 14th Five-Year Plan[J]. Journal of Shanghai Ocean University, 2021, 30(2): 339-347 (in Chinese with English abstract).
- [2] 杨运义. 鱼病诊断流程与常见鱼病诊断技术[J]. 渔业致富指南, 2017(2): 56-57. YANG Y Y. Fish disease diagnosis process and common fish disease diagnosis technology[J]. Fishery guide to be rich, 2017(2): 56-57 (in Chinese).
- [3] 王成志,黄少涛,纪荣兴. 鱼病诊疗专家系统:“鱼医生”[J]. 集美大学学报(自然科学版), 1997, 2(3): 35-41. WANG C Z, HUANG S T, JI R X. FISH DOCTOR: an expert system for diagnosing and treating the fish disease[J]. Journal of Jimei University (natural science), 1997, 2(3): 35-41 (in Chinese with English abstract).
- [4] 温继文,李道亮,陈梅生,等. 基于UML的鱼病远程监测预警与诊断系统[J]. 农业工程学报, 2008, 24(S2): 166-171. WEN J W, LI D L, CHEN M S, et al. Remote monitoring, early warning and diagnosis system of fish diseases based on UML[J]. Transactions of the CSAE, 2008, 24(S2): 166-171 (in Chinese with English abstract).
- [5] 徐妙君,吴远红. 基于粗糙集和神经网络结合的鱼病诊断方法[J]. 计算机工程与设计, 2009, 30(7): 1738-1741. XU M J, WU Y H. Fish diseases diagnosis based on rough set and neural network [J]. Computer engineering and design, 2009, 30(7): 1738-1741 (in Chinese with English abstract).
- [6] LI D L, LI X, WANG Q, et al. Advanced techniques for the intelligent diagnosis of fish diseases: a review[J/OL]. Animals: an open access journal from MDPI, 2022, 12(21): 2938 [2023-11-03]. <https://doi.org/10.3390/ani12212938>.
- [7] LOPES J N S, GONÇALVES A N A, FUJIMOTO R Y, et al. Diagnosis of fish diseases using artificial neural networks[J]. International journal of computer science issues (IJCSI), 2011, 8(6): 68-74.
- [8] MIA M J, MAHMUD R B, SADAD M S, et al. An in-depth automated approach for fish disease recognition[J]. Journal of King Saud University: computer and information sciences, 2022, 34(9): 7174-7183.
- [9] MALIK S, KUMAR T, SAHOO A K. Image processing techniques for identification of fish disease[C]//2017 IEEE 2nd international conference on signal and image processing (IC-SIP). Singapore: IEEE, 2017: 55-59.
- [10] WALEED A, MEDHAT H, ESMAIL M, et al. Automatic recognition of fish diseases in fish farms[C]//2019 14th international conference on computer engineering and systems (ICES). Cairo, Egypt: IEEE, 2019: 201-206.
- [11] YU G Y, ZHANG J B, CHEN A, et al. Detection and identification of fish skin health status referring to four common diseases based on improved YOLOv4 model [J/OL]. Fishes, 2023, 8(4): 186 [2023-11-03]. <https://doi.org/10.3390/fishes8040186>.
- [12] 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). Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [13] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C]//European conference on computer vision (ECCV). Cham: Springer, 2018: 3-19.
- [14] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF conference on computer vision and pattern recognition (CVPR). Salt Lake City, UT, USA: IEEE, 2018: 7132-7141.
- [15] XU K, BA J L, KIROS R, et al. Show, attend and tell: neural image caption generation with visual attention [C]//International conference on machine learning (ICML). Lille, France: IMLS, 2015: 2048-2057.
- [16] 刘世晶,刘阳春,钱程,等. 基于CycleGAN和注意力增强迁移学习的小样本鱼类识别[J]. 农业机械学报, 2023, 54(S1): 296-302. LIU S J, LIU Y C, QIAN C, et al. Recognition of small sample cultured fish based on improved CycleGAN and attention enhanced transfer learning[J]. Transactions of the CSAM, 2023, 54(S1): 296-302 (in Chinese with English abstract).
- [17] TAN M, LE Q. Efficientnet: rethinking model scaling for convolutional neural networks [C]//International conference on machine learning (ICML). Long Beach: IMLS, 2019: 6105-6114.
- [18] 任治洲,梁琨,王泽宇,等. 结合改进CBAM和MobileNetV2算法对小麦病斑粒分类[J]. 南京农业大学学报, 2024, 47(3): 583-591. REN Z Z, LIANG K, WANG Z Y, et al. Combining improved CBAM and MobileNet V2 algorithms for classifying diseased wheat kernels[J]. Journal of Nanjing Agricultural University, 2024, 47(3): 583-591 (in Chinese with English abstract).
- [19] 涂万,于红,张鹏,等. 基于通道非降维与空间协调注意力的改进YOLOv8养殖鱼群检测[J]. 大连海洋大学学报, 2023, 38(4): 717-725. TU W, YU H, ZHANG P, et al. Farmed fish detection by improved YOLOv8 based on channel non-degradation with spatially coordinated attention[J]. Journal of Dalian Ocean University, 2023, 38(4): 717-725 (in Chinese with English abstract).
- [20] KINGMA P D, BA J. Adam: a method for stochastic optimization. [DB/OL]. arXiv, 2014: 1412.6980 [2023-11-03]. <http://arxiv.org/abs/1412.6980>.
- [21] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [DB/OL]. arXiv, 2014: 1409.1556 [2023-11-03]. <https://doi.org/10.48550/>

- arXiv.1409.1556.
- [22] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. *Communications of the acm*, 2017, 60(6):84-90.
- [23] LIU Z, LIN Y T, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows [C]//2021 IEEE/CVF international conference on computer vision (ICCV). Montreal, QC, Canada: IEEE, 2021:9992-10002.
- [24] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization [J]. *International journal of computer vision*, 2020, 128(2):336-359.
- [25] 张俊龙, 曾国荪, 覃如符. 基于深度学习的海底观测视频中鱼类的识别方法 [J]. *计算机应用*, 2019, 39(2):376-381. ZHANG J L, ZENG G S, QIN R F. Fish recognition method for submarine observation video based on deep learning [J]. *Journal of computer applications*, 2019, 39(2):376-381 (in Chinese with English abstract).
- [26] 陈英义, 龚川洋, 刘炜琦, 等. 基于FTVGG16卷积神经网络的鱼类识别方法 [J]. *农业机械学报*, 2019, 50(5):223-231. CHEN Y Y, GONG C Y, LIU Y Q, et al. Fish identification method based on FTVGG16 convolutional neural network [J]. *Transactions of the CSAM*, 2019, 50(5):223-231 (in Chinese with English abstract).

A method of identifying fish surface pathology based on dual attention mechanism

WANG Yifei^{1,2}, YUAN Tao¹, WU Pengfei^{1,2}

1. College of Informatics, Huazhong Agricultural University, Wuhan 430070, China;

2. Key Laboratory of Smart Farming for Agricultural Animals, Ministry of Agriculture and Rural Affairs, Wuhan 430070, China

Abstract The dataset of fish surface pathology was constructed based on four types of fish diseases with high rate of incidence and great harm to fish to improve the accuracy and efficiency of identifying fish surface pathology and solve the problems of heavy reliance on manual labor and low accuracy of identification in the process of identification at present. An improved and optimized DBA_Resnet-18 model with high accuracy of identification based on the Resnet-18 model was constructed by integrating spatial attention and SE channel attention dual attention mechanism. A real-time intelligent visualization system for identifying fish diseases was developed based on this model as well. The improved model incorporates SE channel attention module in the middle of the network and introduces spatial attention mechanism at the end of the network. The results of testing showed that the accuracy of the DBA_Resnet-18 model in classifying fish surface pathology reached 96.75%, which was 1.71, 2.12, 2.37, 2.83, 2.51, 2.23, 2.50, and 3.53 percent points higher than that of the commonly used models including Resnet-18, Resnet-34, Resnet-50, Resnet-101, Swin Transformer, VGG-16, VGG-19, and AlexNet, respectively. It is indicated that the proposed model and the developed intelligent visualization system for identifying fish diseases can quickly and accurately classify and identify different fish surface pathologies, realizing the intelligence of the system for identifying fish diseases, which can be used to diagnose the types of fish surface pathology in practical environments.

Keywords fish surface pathology; deep learning; attention mechanism; Resnet-18; intelligent identification of fish diseases

(责任编辑:边书京)