

doi:10.6041/j.issn.1000-1298.2023.11.025

# 基于帧间深度特征差分的大西洋鲑鱼群活跃度分类模型

徐立鸿<sup>1</sup> 崔钰惠<sup>1</sup> 刘世晶<sup>2</sup> 韩厚伟<sup>3</sup>

(1. 同济大学电子与信息工程学院, 上海 201800;

2. 中国水产科学研究院渔业机械仪器研究所, 上海 200092;

3. 国信东方(烟台)循环水养殖科技有限公司, 烟台 264000)

**摘要:** 鱼群活跃度是鱼类健康福利养殖的特征性指标之一, 实现鱼群活跃度细粒度分类有利于更精细地描述鱼群健康状况、评估鱼群福利水平。基于工厂化循环水养殖系统, 本文建立了水下大西洋鲑鱼群活跃度细粒度分类视频数据集, 并提出一种基于帧间深度特征差分的鱼群活跃度分类模型, 通过引入残差连接的小型卷积神经网络提取视频帧的特征, 进而在相邻帧之间做差分运算和平方运算得到视频帧间特征, 最后将其输入基于外部注意力机制的分类网络 IFDNet 中得到视频类别。试验结果表明, 本文提出的 CNN – IFDNet 模型分类准确率达到 97.72%, F1 值达到 97.42%, 以较低的计算复杂度实现了对水下视频鱼群活跃度的三分类。相较于实验室环境, 基于真实养殖环境对鱼群活跃度所展开的算法研究实际应用性更强, 可以为精细化描述鱼群的活跃度、实现智能监测鱼类健康状况提供参考, 帮助养殖人员发现并排除导致鱼群活跃度异常的水质环境、病害等因素。

**关键词:** 鱼类健康福利养殖; 鱼群活跃度; 分类模型; 视频分类; 深度特征

中图分类号: S951.2 文献标识码: A 文章编号: 1000-1298(2023)11-0259-07

OSID: 

## Classification Model of Atlantic Salmon Activity Intensity Based on Deep Feature Differencing between Frames

XU Lihong<sup>1</sup> CUI Yuhui<sup>1</sup> LIU Shijing<sup>2</sup> HAN Houwei<sup>3</sup>

(1. College of Electronics and Information Engineering, Tongji University, Shanghai 201800, China

2. Fishery Machinery and Instrument Research Institute, Chinese Academy of Fishery Sciences, Shanghai 200092, China

3. Conson Oriental (Yantai) Recirculating Aquaculture Technology Co., Ltd., Yantai 264000, China)

**Abstract:** Fish activity intensity is one of the characteristic indicators of fish health and welfare farming. The fine-grained classification of fish activity intensity is beneficial to describe fish health status and assess fish welfare levels. The fine-grained classification of Atlantic salmon activity intensity where a small-scaled underwater video dataset was collected in the industrial recirculating aquaculture system was carried out. Firstly, the features of video frames were extracted through a small convolutional neural network with residual connections. Then the inter-frame features were obtained by performing differential and square operations between adjacent frames. Finally, the inter-frame features were inputted into the classification network IFDNet based on the external attention mechanism to obtain the video category. The experimental results showed that the classification accuracy of the CNN – IFDNet model proposed reached 97.72%, and the F1 score reached 97.42%. With low computational complexity, the three classification of the fish activity intensity video was realized. Compared with the laboratory environment, the algorithm research based on the real farming environment for fish activity intensity was more practical. The research result can provide a reference for elaborately describing the activity intensity of fish school and realizing intelligent monitoring of fish health status, which can help aquaculture workers discover abnormal conditions and investigate factors causing abnormal fish activity intensity, such as water quality environment and diseases.

**Key words:** aquaculture health and welfare; fish activity intensity; classification model; video classification; deep feature

收稿日期: 2023-03-29 修回日期: 2023-07-16

基金项目: 国家自然科学基金项目(61973337)

作者简介: 徐立鸿(1960—), 男, 教授, 博士生导师, 主要从事智能控制及水产养殖机器视觉技术研究, E-mail: xulihong@tongji.edu.cn

## 0 引言

水产养殖业中的鱼类健康福利养殖主要指的是为养殖鱼群提供良好的生存环境<sup>[1-2]</sup>,保障鱼不受环境胁迫(如有毒化学物质、溶解氧含量低、饥饿、养殖密度高、致病菌等),本质是保持鱼的生理和身体健康。提高养殖鱼类健康福利水平可以有效提升鱼生长率、饵料转化率及鱼肉品质,降低鱼病发病率,最大化水产养殖经济效益。多项研究表明鱼的活跃度可以作为鱼类健康福利养殖特征性指标之一<sup>[3-7]</sup>,鱼类受到环境胁迫时激素水平发生变化,产生回避反应、加速逃窜,而随着时间延长,鱼的生理机能受损,活跃度随之下降。鱼类处于高活跃或低活跃状态都意味着鱼类健康状况可能受到威胁,随着水产养殖规模不断扩大以及人工监控成本的上涨<sup>[8]</sup>,如何在工厂化养殖中实现智能监测鱼群活跃度、对活跃度异常情况进行预警,从而提醒养殖人员发现并排除导致鱼群活跃度异常的水质环境、病害等因素,具有重要研究意义和应用价值。

目前,基于机器视觉技术对鱼群活跃度分类的研究,可分为个体行为分析和群体行为分析两类<sup>[9]</sup>。个体行为分析是基于对鱼群中单鱼的检测和跟踪来建立运动轨迹<sup>[10]</sup>,并从目标质心和轨迹中提取一些运动特征参数,如速度<sup>[11-13]</sup>、转弯角度<sup>[14]</sup>、尾拍频率<sup>[15]</sup>、空间分布<sup>[16]</sup>,通过这些参数指标实现鱼群活跃度分类。然而,个体鱼的检测跟踪算法通常在高密度水产养殖环境中表现不佳,且计算成本较高。群体行为分析则是基于整体特征直接量化鱼群活跃度,无需识别和跟踪单个鱼类。LIU 等<sup>[17]</sup>基于背景减法和帧间差分法,计算了由鱼群运动引起的连续图像的差异强度,用以量化描述鱼类摄食活跃度。YU 等<sup>[18]</sup>基于角点检测和光流法得到图像的特征点和速度,提出一种模拟特征点选择方案,有效量化鱼群特殊行为的速度。

以上研究均在实验室环境下完成,而工厂化循环水养殖池具有养殖密度高、光环境差的特点,这些依赖于传统图像处理技术的方法很容易受到鱼群遮挡和图像噪声的影响,与之相比,深度学习模型<sup>[19]</sup>更有能力提取代表性特征。YANG 等<sup>[20]</sup>提出一种基于 EfficientNet-B2 的双注意力网络,以单帧图像的鱼群聚集状态反映鱼群摄食活跃度,但是忽略了时序信息。MÅLØY 等<sup>[21]</sup>通过双流循环神经网络实现了鱼类摄食视频的二分类,但是参数众多的深度 3D 残差网络不仅计算量大、不够经济,还对数据采集量有更高要求。ZHANG 等<sup>[22]</sup>利用变分自编码器(Variational auto-encoder, VAE)将视频帧映射到隐

空间,再训练 4 个多层全连接网络分别学习鱼群两种游泳行为的多元高斯均值向量和方差向量的状态转移矩阵,实现摄食行为二分类,准确率达到 97.5%,缺点是细粒度分类场景下需要训练的全连接网络太多,在小数据集上容易过拟合。

综上,针对工厂化循环水养殖系统(Recirculating aquaculture systems, RAS)场景下大西洋鲑鱼群特点,本文提出一种基于深度特征帧间差分的鱼群活跃度三分类模型,以通过较少的网络参数和计算量实现对视频的细粒度分类。本文根据现场环境设计水下视频采集方案并建立鱼群活跃度细粒度分类数据集。在该视频数据集上利用门控循环单元<sup>[23]</sup>(Gated recurrent unit, GRU)对时序依赖的捕捉能力,辅助训练引入残差连接的小型特征提取网络对视频帧的特征提取能力,基于特征提取层得到的深度特征帧间差值来训练包含外部注意力机制的分类网络 IFDNet,以实现对视频的细粒度分类。

## 1 材料与方法

### 1.1 试验材料与视频采集方案

本研究试验对象为大西洋鲑鱼(Salmo salar),该鱼种鱼群正常巡游时在循环养殖池中逆着水流呈顺时针或逆时针规律性成群游动,在水池中分布相对均匀,当鱼群活跃度发生变化时,鱼群游泳速度、摆尾频率和空间分布等行为参数相应地出现差异。试验数据采集于国信东方(烟台)循环水养殖科技有限公司的循环水养殖池,如图 1 所示,养殖池直径 6.8 m,池深 2.5 m,试验鱼平均体长 60 cm,体质量为 2.5~3 kg,养殖密度约为 7 尾/m<sup>3</sup>,养殖温度全年恒定在 14.5~15.5℃,水体溶解氧饱和度不低于 90%,氨氮含量小于 0.5 mg/L, pH 值保持在 7.3~7.4 的弱碱性范围内,盐度为 2.9%~3.0%,养殖车间提供 24 h 光照,轨道式智能投饵机自动执行鱼类养殖专家制定的定时定量投饵策略,每日投喂 5~6 次。

水上图像会受到水面反光和波纹的影响,同时



图 1 循环水养殖池

Fig. 1 Recirculating aquaculture pond

考虑到轨道式投饵机使得水上相机安装困难,本试验采用水下视频方案。在比较相机平视和斜俯视两种视角的视野范围后,本文选择更有利于反映鱼群集体行为的斜俯视视角,水下摄像机(GoPro HERO9型)固定在距水面 0.1 m 高度的池壁,拍摄俯角约 36°,视频采集方案如图 2 所示。视频在 08:00—22:00 录制,相机采集的 RGB 视频的分辨率和帧率分别为 1920 像素 × 1080 像素和 30 f/s。为了减少背景对分类器的干扰,剔除应急增氧气泡遮蔽期间的采集数据,并确保视频采集过程中的光照一致性。

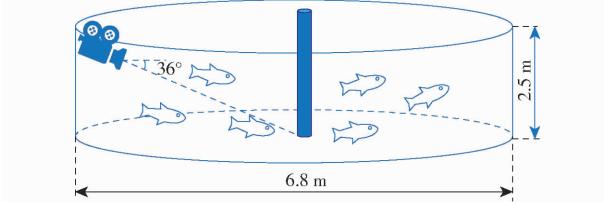


图 2 视频采集示意图

Fig. 2 Schematic of video capture

## 1.2 数据集制作

在原始长视频中观察到鱼群存在短暂冲刺行为(1~2 s),且鱼群在巡游、摄食、休息、受惊及其他异常行为中的活跃情况在短视频内均可较好体现,将数据集视频样本的时长设置为 3 s,在降低计算成本的同时,可以较好地反映当前时刻鱼群活跃度。

相较于其他鱼群行为参数,不同活跃度下鱼群游泳速度差异最显著且更易量化,利用基于 YOLO v7<sup>[24]</sup>与 StrongSORT<sup>[25]</sup>的多目标跟踪算法获得鱼的运动轨迹,从时间、空间、框长宽比、框尺寸变化、框质心及顶点移动距离等维度对轨迹进行降噪,减少在速度计算过程中鱼相互遮挡及姿态变化引入的误差。以目标检测框质心的运动代表整条鱼的运动,根据鱼在两帧之间像素位移与鱼体长的比例计算出实际位移,进而得出每条鱼每时刻的瞬时速度,最后取所有鱼所有时刻的平均值得出鱼群游泳速度(cm/s)。图 3 为 5 个原始长视频分割为时长 3 s 的若干视频样本后得到的游泳速度曲线,横坐标为按时间顺序排列的视频样本的编号,根据离群点和游速变化趋势快速找到鱼群活跃度可能异常的视频样本。

结合游泳速度和视频中鱼群行为将鱼群活跃度分为 3 个类别,设置游泳速度阈值,制定数据集样本分类标准,如表 1 所示。实际操作中,利用速度阈值从大量数据样本中筛选出高活跃和低活跃等小样本类,通过欠抽样减少中活跃类别的样本量。根据鱼群行为对上述样本进行人工筛选,本标注工作由 3 名研究人员同时展开,每一视频样本必须由 2 人及

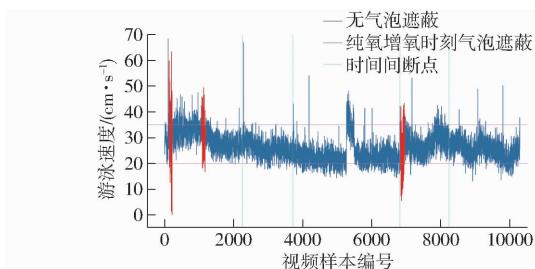


图 3 游泳速度

Fig. 3 Swimming speed

表 1 数据集样本分类标准

Tab. 1 Classification criteria for dataset

鱼群行为	游泳速度/(cm·s⁻¹)	数据集类别
鱼群逃窜、突然加速或乱游	35~70	高活跃状态
鱼群正常巡游	20~35	中活跃状态
鱼群游动缓慢	0~20	低活跃状态

以上确认为同一类别才可完成标注,否则视为模糊样本被剔除。

最终,鱼群活跃度细粒度分类数据集的单个样本长度为 3 s(90 帧),尺寸缩放至 240 像素 × 135 像素,共包含 1 972 个视频样本,其中高活跃、中活跃和低活跃类别分别包含 365、1 158、449 个样本,训练集、验证集和测试集按照 6:2:2 的比例划分,具体数量如表 2 所示。

表 2 数据集信息

Tab. 2 Dataset information

类别	训练集	验证集	测试集
高活跃	219	73	73
中活跃	694	232	232
低活跃	269	90	90
总计	1 182	395	395

## 2 基于帧间深度特征差分的鱼群活跃度分类模型 CNN-IFDNet 构建

### 2.1 特征提取网络

卷积层的若干卷积核与输入进行卷积计算可以提取不同特征,卷积层、激活层和池化层的组合多次堆叠可以从低层提取图像低级特征过渡到高层提取图像高级特征,包含 2 层卷积层的小型 CNN 网络如图 4a 所示。通过堆叠卷积层增加网络深度可以提高模型性能,但也可能出现过拟合、梯度消失、网络退化等问题,为解决上述问题,残差连接将输入和输入的非线性变换叠加作为输出,信息在浅层网络和深层网络之间的前后向传递更畅通,网络性能提升且更易训练。因此,以引入残差连接的 5 层卷积神经网络作为特征提取网络,用于提取视频帧的深度特征,结构如图 4b 所示。

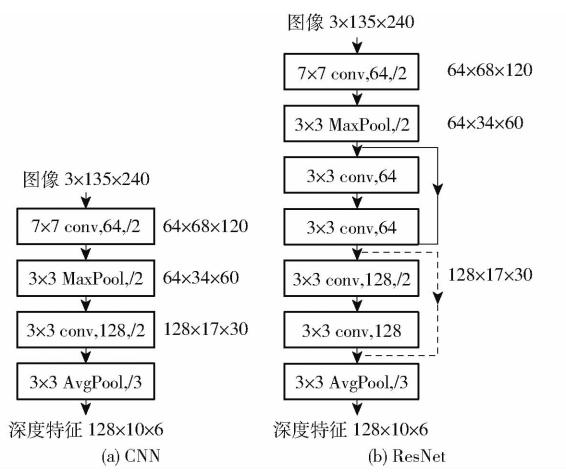


图 4 特征提取网络结构示意图

Fig. 4 Structure diagram of feature extraction network

为使特征提取网络提取的视频帧特征的帧间差值更易用于完成视频分类任务,在数据集上训练卷积神经网络-门控循环单元(CNN - GRU)的视频分类模型,利用GRU的时序依赖捕获能力,辅助训练特征提取网络对静态图像中有效特征的提取能力。门控递归单元GRU是循环神经网络的一种,主要由重置门和更新门组成,可以有效捕捉视频的长短期时序依赖关系。将特征提取网络提取的视频帧静态特征输入到双层单向GRU网络(节点数256)中得到时序特征,最后通过全连接层得到分类结果,模型整体结构如图5所示(图中 $cl_1$ 、 $cl_2$ 、 $cl_3$ 分别表示鱼群处于高活跃、中活跃和低活跃状态)。以视频分类表现最好的CNN - GRU模型的网络参数作为特征提取网络最优参数。

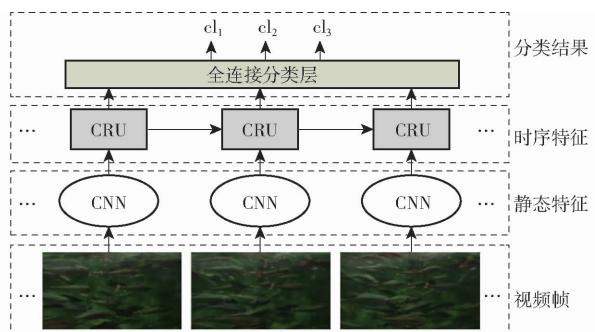


图 5 CNN - GRU 模型示意图

Fig. 5 Structure diagram of CNN - GRU

## 2.2 外部注意力模块

图像中大量像素仅与少量其他像素密切相关,基于该思想,外部注意力模块<sup>[26]</sup>(External attention, EA)利用2个外部的、小型的且可共享的记忆单元替代了存在冗余计算的自注意力机制,将计算复杂度降到和像素数目线性相关,其示意图如图6所示(图中 $F_{in}$ 和 $F_{out}$ 分别表示输入、输出特征; $Q$ 、 $M_k$ 和 $M_v$ 为外部注意力机制的查询矩阵、键矩阵和值矩阵),其中查询矩阵可以省略,键矩阵和值矩阵均使

用线性层实现。

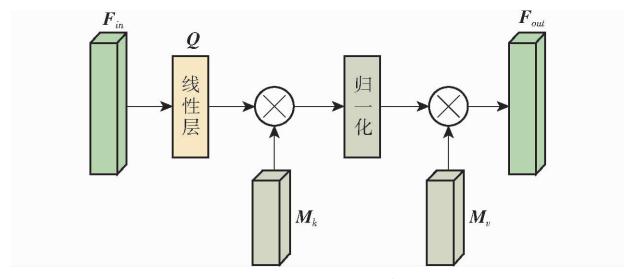


图 6 EA 模块示意图

Fig. 6 Structure diagram of EA block

特征图在空间维度上展平为一维特征向量,特征与键矩阵相乘计算相似性权重,经归一化处理后,相似性权重与值矩阵相乘得到注意力结果,数学描述为

$$\mathbf{A} = G(\mathbf{F}_{in} \mathbf{M}_k^T) \quad (1)$$

$$\mathbf{F}_{out} = \mathbf{A} \mathbf{M}_v \quad (2)$$

式中  $\mathbf{A}$ ——注意力矩阵

$G$ ——归一化函数,包含Softmax函数和L1范数归一化

自注意力机制使用同等操作处理每个样本,忽略样本间的潜在关系,EA模块只需使用2个级联的线性层作为外部、可共享、可学习的记忆单元,即可隐式地考虑所有数据样本之间的相关性,结合2个归一化层共同突出重要特征。

## 2.3 基于帧间深度特征差分的分类网络 IFDNet

帧间深度特征差分指的是对特征提取网络提取的两帧相邻视频帧特征取差值,在多维空间下常用欧氏距离度量两点间距离,取帧特征差值的平方作为帧间深度特征,则每个帧数为 $n$ 的视频样本可得到一个包含 $n-1$ 个帧间深度特征的视频帧间特征样本。本文提出了仅含4个线性层的基于帧间深度特征差分的分类网络(Inter-frame depth feature difference network, IFDNet),对视频帧间特征样本进行分类,模型整体结构如图7所示(图中 $\mathbf{F}_{ifd}$ 表示视频帧间特征;  $T$ 和 $C$ 分别表示特征时序长度和通道数;  $H$ 、 $W$ 和 $S$ 为特征空间域的高、宽和面积)。

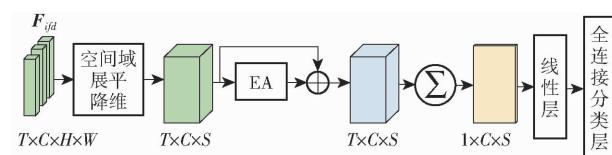


图 7 IFDNet 结构示意图

Fig. 7 Structure diagram of IFDNet

将 $\mathbf{F}_{ifd}$ 在空间维度上展平降维后输入EA模块,特征通过代表键矩阵的线性层映射到注意力矩阵,依次经过Softmax函数和L1范数归一化处理后,通过代表值矩阵的线性层映射为新特征,EA模块的输

人、输出叠加后, 经过 Leaky ReLU 激活函数得到突出重要信息后的视频帧间特征  $F_{EA}$ 。将  $F_{EA}$  在时间域维度上直接叠加作为视频的时序特征, 在空间域维度上利用线性层降维, 最后通过全连接层得到分类结果。

IFDNet 网络的 4 个线性层参数设置如表 3 所示, EA 模块计算复杂度为  $O(dCS)$ , 其中  $O$  表示成正比,  $d$  表示注意力矩阵通道数(即第 1 层线性层的输出维度)。

表 3 线性层参数

Tab. 3 Parameters of linear layers

指标	第 1 层	第 2 层	第 3 层	第 4 层
输入维度	128	32	60	256
输出维度	32	128	2	3
激活函数		ReLU	Softmax	

### 3 结果与分析

#### 3.1 特征提取层与分类网络设计

在鱼群活跃度细粒度分类数据集上训练视频分类模型, 该数据集存在样本分布不均衡的问题, 高活跃度和低活跃度样本数量远小于中活跃度类别, 在训练模型时, 对损失函数赋权重 3.2、1.0、2.5。

本文的特征提取网络是基于 CNN–GRU 模型训练得到的, CNN–GRU 模型分类性能直接关系着特征提取的有效性。表 4 为不同特征提取网络下 CNN–GRU 的性能比较, 3 种特征提取网络的输出特征尺寸均为  $90 \times 128 \times 6 \times 10$ , GRU 网络均为双层单向。两层 CNN 和 ResNet5 的网络结构如图 4 所示, ResNet9 的网络结构是 ResNet18 的第 1 层卷积加前两组残差块。相较于两层 CNN 网络, ResNet5 增加网络深度并使用残差连接, 准确率提升 4.05 个百分点, 相较于 ResNet5, ResNet9 网络深度增加仅使准确率提升 0.12 个百分点, 精准度提升 0.58 个百分点, 但参数量和计算量成倍增加。为降低计算成本, 本文以 ResNet5 作为特征提取网络。

表 4 不同特征提取网络下 CNN–GRU 的性能

Tab. 4 Model performance under different feature extraction networks

特征提取 网络	准确率/ %	精准度/ %	召回率/ %	F1 值/ %	参数量
两层 CNN	92.66	91.14	92.43	91.43	$3.34 \times 10^5$
ResNet5	96.71	95.09	96.88	95.92	$1.21 \times 10^6$
ResNet9	96.83	95.67	96.80	96.20	$2.63 \times 10^6$

表 5 为不同 GRU 层次下 CNN–GRU 的性能比

较, 特征提取网络均为 ResNet5, GRU 网络均为单向, 隐藏层 Dropout 值为 0.5, 节点数为 256。单层 GRU 网络的分类准确率达到 93.67%, 精准度仅为 90.23%, 性能劣于多层 GRU, 双层 GRU 网络性能表现最佳, 准确率达到 96.71%, 进一步增加网络层数, 三层 GRU 网络因训练难度提高, 准确率下降 0.25 个百分点。最终选择双层单向 GRU 辅助训练特征提取网络, 多次训练 CNN–GRU 模型, 选取最优视频分类结果对应的特征提取网络参数, 作为特征提取模型最优参数。

表 5 不同 GRU 层次下模型性能

Tab. 5 Model performance under different layers of GRU networks

模型	准确率	精准度	召回率	F1 值	%
单层 GRU 网络	93.67	90.23	95.05	92.03	
双层 GRU 网络	96.71	95.09	96.88	95.92	
三层 GRU 网络	96.46	95.06	96.37	95.68	

用训练好的特征提取网络处理视频数据集, 得到视频帧间特征数据集, 用于 IFDNet 网络的训练。表 6 为不同超参数下 IFDNet 网络性能比较。注意力矩阵的通道数  $d$  直接影响 IFDNet 网络结构, 对比试验结果可知, 在本文数据集上  $d = 32$  时模型性能最佳, 相较于  $d = 16$  和  $d = 64$ , 准确率分别提升 1.01、0.5 个百分点。修正线性单元 ReLU 是最常用且有效的激活函数之一, 当输入值为负值时, 输出为零, 带泄露修正线性单元 Leaky ReLU 是 ReLU 激活函数的变体, 当输入值为负值时, 输出为输入值乘一个较小的数(设为 0.2), 减少出现静默神经元, 丢失特征信息, 相较于使用 ReLU 作为 EA 模块的激活函数, 使用 Leaky ReLU 激活函数的准确率提升 0.76 个百分点。在空间域维度上利用线性层降维时引入 Dropout 随机删除神经元, 可以防止过拟合, 提升模型训练效果, 相较于不使用 Dropout, Dropout 值设为 0.3 时精准度提升 2.03 个百分点。

表 6 不同超参数下 IFDNet 网络性能

Tab. 6 Model performance under different hyper-parameters of IFDNet

超参数	准确率	精准度	召回率	F1 值	%
$d = 16$	96.71	95.29	97.11	96.12	
$d = 64$	97.22	96.60	97.05	96.81	
ReLU (EA 模块激活函数)	96.96	95.79	97.19	96.46	
无 Dropout(线性层)	96.71	95.29	96.81	95.98	
Dropout 为 0.1(线性层)	96.33	95.27	96.22	95.73	
$d = 32$ , Leaky ReLU, Dropout 为 0.3	97.72	97.32	97.54	97.42	

IFDNet 最佳模型的分类准确率达到 97.72% ,

精准度、召回率、F1 值等均在 97% 以上,取得了较好的分类结果。

本研究算法 CNN-IFDNet 在超参数  $d = 32$ 、Dropout 为 0.3 和 EA 模块激活函数为 Leaky ReLU 时高活跃、中活跃和低活跃类别的精准度、召回率和 F1 值如表 7 所示,3 个类别的 F1 值分别为 95.89%、98.06% 和 98.32%,均在 95% 以上,说明该算法能够很好地完成鱼群活跃度的细粒度分类。查看分类错误的视频样本,鱼群基本属于相邻活跃度间的过渡状态,高活跃类别的视频画面情况较复杂、多样,分类性能稍差于其他类别。

表 7 本研究算法性能

Tab. 7 Performances of proposed algorithm %

类别	精准度	召回率	F1 值
高活跃	95.89	95.89	95.89
中活跃	98.28	97.85	98.06
低活跃	97.78	98.88	98.32

### 3.2 其他鱼群活跃度分类算法性能对比分析

表 8 为不同算法的分类性能和复杂度性能的对比结果,单帧 CNN 的视频分类算法是采用卷积神经网络实现单帧图像分类的算法<sup>[27-28]</sup>,后续通过相对多数投票法由视频内每帧图像的类别预测视频类别。表 8 中所有算法运行环境均为 Windows 10 Intel Core i7-12700 CPU @ 2.10 GHz,运行内存 32 GB,运行时间是指算法处理单个 90 帧视频样本所用时间。

表 8 不同算法性能对比

Tab. 8 Experiment results of different algorithms

参数	CNN-IFDNet	CNN-GRU	单帧 CNN
准确率/%	97.72	96.71	85.61
精准度/%	97.32	95.09	81.82
召回率/%	97.54	96.88	85.93
F1 值/%	97.42	95.92	82.18
参数量	$1.28 \times 10^6$	$2.66 \times 10^7$	$5.81 \times 10^5$
运行时间/s	0.327	0.332	0.126

根据表 8 可知,单帧 CNN 算法的视频分类准确

率、F1 值均在 80% 以上,能够起到有效分类,但是仅学习单帧图像特征,没有学习视频时序特征,分类性能明显劣于其他两种算法;本文所提出的 CNN-IFDNet 模型在测试集上准确率达到 97.72%,F1 值达到 97.42%,与 CNN-GRU 模型相比,准确率提升 1.01 个百分点,精准度提升 2.23 个百分点,各项指标都有明显提升,同时,IFDNet 参数量远小于 GRU(特征提取网络内存占用量为 1 245 kB,IFDNet 仅为 39 kB,GRU 为 25 360 kB),且运行时间也更短。

### 4 结论

(1) 基于专家经验和目标跟踪得到的鱼群平均游速,搭建了循环水养殖池水下大西洋鲑鱼群活跃度三分类视频数据集,为训练视频分类模型提供数据支撑。

(2) 设计了引入残差连接的小型特征提取网络,并利用 GRU 网络的时序依赖捕获能力对其优化训练,使特征提取网络提取的视频帧深度特征的帧间差值具有更适于后续视频分类的时序意义,有利于提取到在不同活跃度样本间有足够区分度的帧间深度特征差值。

(3) 构建了基于帧间深度特征差分的分类网络 IFDNet,利用外部注意力机制捕捉不同样本间的潜在联系,将突出重要特征后的视频所有帧间特征直接叠加作为后续分类的视频特征,结构简单,参数量少,网络训练更容易,最终在测试集上准确率达到 97.72%,在所需计算资源大幅度降低的情况下,分类效果优于 CNN-GRU 模型。

(4) CNN-IFDNet 模型实现了循环水养殖池水下大西洋鲑鱼群活跃度的三分类,能够较为精细地描述鱼群的活跃状态,对鱼群健康状况异常情况进行预警:当鱼群处于高活跃状态时,如果此时并没有投饵或应急供氧情况,判定为鱼群健康状况异常;当鱼群处于低活跃状态时,如果此时并非鱼群休息时间,判定为鱼群健康状况异常。

### 参考文献

- [1] TONI M, MANCIOCCO A, ANGIULLI E, et al. Review: assessing fish welfare in research and aquaculture, with a focus on European directives[J]. Animal: an International Journal of Animal Bioscience, 2019, 13(1): 161-170.
- [2] 李贤,刘鹰.水产养殖中鱼类福利学研究进展[J].渔业现代化, 2014, 41(1): 40-45.  
LI Xian, LIU Ying. Current research advances on fish welfare in aquaculture[J]. Fishery Modernization, 2014, 41(1): 40-45. (in Chinese)
- [3] TIERNEY K B. Chemical avoidance responses of fishes[J]. Aquatic Toxicology, 2016, 174(1): 228-241.
- [4] OPPEDAL F, DEMPSTER T, STIEN L H, et al. Environmental drivers of Atlantic salmon behaviour in sea-cages: a review [J]. Aquaculture (Amsterdam), 2011, 311(1): 1-18.
- [5] KALANANTHAN T, FOLKEDAL O, GOMES A S, et al. Impact of long-term fasting on the stomach-hypothalamus appetite regulating genes in Atlantic salmon postsmolts[J]. Aquaculture, 2022, 563: 738917.

- [6] KRISTIANSEN T S, FERNÖ A, HOLM J C, et al. Swimming behaviour as an indicator of low growth rate and impaired welfare in Atlantic halibut (*Hippoglossus hippoglossus* L.) reared at three stocking densities[J]. Aquaculture, 2004, 230(1): 137–151.
- [7] HAMED S B, MARIA J, TACHIBANA L, et al. Fish pathogen bacteria: adhesion, parameters influencing virulence and interaction with host cells[J]. Fish & Shellfish Immunology, 2018, 80: 550–562.
- [8] 朱建新, 刘慧, 程海华, 等. 工厂化循环水养殖技术研究与产业化发展[J]. 中国水产, 2022(10): 41–49.
- [9] YANG Ling, LIU Yeqi, YU Huihui, et al. Computer vision models in intelligent aquaculture with emphasis on fish detection and behavior analysis: a review[J]. Arch. Comput. Methods Eng., 2021, 28(4): 2785–2816.
- [10] MEI Yupeng, SUN Boyang, LI Daoliang, et al. Recent advances of target tracking applications in aquaculture with emphasis on fish[J]. Computers and Electronics in Agriculture, 2022, 201: 107335.
- [11] XU Jianyu, LIU Ying, CUI Shaorong, et al. Behavioral responses of tilapia (*Oreochromis niloticus*) to acute fluctuations in dissolved oxygen levels as monitored by computer vision[J]. Aquacultural Engineering, 2006, 35(3): 207–217.
- [12] PAPADAKIS V M, PAPADAKIS I E, LAMPRIANIDOU F, et al. A computer-vision system and methodology for the analysis of fish behavior[J]. Aquacultural Engineering, 2012, 46(1): 53–59.
- [13] PINKIEWICZ T H, WILLIAMS R N, PURSER G J. A computer vision system to analyse the swimming behaviour of farmed fish in commercial aquaculture facilities: a case study using cage-held Atlantic salmon[J]. Aquacultural Engineering, 2011, 45(1): 20–27.
- [14] WU Yao, WANG Xiaochan, ZHANG Xiaolei, et al. Locomotor posture and swimming-intensity quantification in starvation-stress behavior detection of individual fish[J]. Computers and Electronics in Agriculture, 2022, 202: 107399.
- [15] XIAO Gang, FENG Min, CHENG Zhenbo, et al. Water quality monitoring using abnormal tail-beat frequency of crucian carp [J]. Ecotoxicology and Environmental Safety, 2015, 111: 185–191.
- [16] ZHOU Chao, ZHANG Baihai, LIN Kai, et al. Near-infrared imaging to quantify the feeding behavior of fish in aquaculture [J]. Computers and Electronics in Agriculture, 2017, 135: 233–241.
- [17] LIU Ziyi, LI Xian, FAN Liangzhong, et al. Measuring feeding activity of fish in RAS using computer vision[J]. Aquacultural Engineering, 2014, 60: 20–27.
- [18] YU Xiaoning, WANG Yaqian, AN Dong, et al. Identification methodology of special behaviors for fish school based on spatial behavior characteristics[J]. Computers & Electronics in Agriculture, 2021, 185: 106169.
- [19] LECUN Y, YOSHUA B, GEOFFREY H. Deep learning[J]. Nature, 2015, 521:436–444.
- [20] YANG Ling, YU Huihui, CHENG Yuelan, et al. A dual attention network based on EfficientNet-B2 for short-term fish school feeding behavior analysis in aquaculture[J]. Computers & Electronics in Agriculture, 2021, 187: 106316.
- [21] MÅLØY H, AAMODT A, MISIMI E. A spatio-temporal recurrent network for salmon feeding action recognition from underwater videos in aquaculture[J]. Computers & Electronics in Agriculture, 2019, 167: 105087.
- [22] ZHANG Jialin, CEN Feng, XU Lihong. A classification algorithm of fish feeding behavior for automatic bait feeding control [J]. Journal of Physics: Conference Series, 2020, 1626(1): 012096.
- [23] CHO K, MERRIENBOER B V, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[J/OL]. arXiv e-prints, 2014. <https://arxiv.org/abs/1406.1078v3>.
- [24] WANG C Y, BOCHKOVSKIY A, LIAO H. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[J/OL]. [2022-09-28]. <https://arxiv.org/abs/2207.02696v1>.
- [25] DU Yunhao, ZHAO Zhicheng, SONG Yang, et al. StrongSORT: make DeepSORT great again[J]. IEEE Transactions on Multimedia, 2023, 1109(10): 1–14.
- [26] GUO Menghao, LIU Zhengning, MU Taijiang, et al. Beyond self-attention: external attention using two linear layers for visual tasks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(5): 5436–5447.
- [27] ZHOU Chao, XU Daming, CHEN Lan, et al. Evaluation of fish feeding intensity in aquaculture using a convolutional neural network and machine vision[J]. Aquaculture, 2019, 507: 457–465.
- [28] 徐立鸿, 黄薪, 刘世晶. 基于改进 LRCN 的鱼群摄食强度分类模型[J]. 农业机械学报, 2022, 53(10): 236–241.  
XU Lihong, HUANG Xin, LIU Shijing. Recognition of fish feeding intensity based on improved LRCN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(10): 236–241. (in Chinese)