

引用格式:

袁红春, 肖智豪. 伪异常引导的融合注意力和记忆增强的鱼群异常行为检测[J]. 湖南农业大学学报(自然科学版), 2025, 51(1): 123–130.

YUAN H C, XIAO Z H. Pseudo-anomaly-guided fish school abnormal behavior detection with fused attention and memory augmentation[J]. Journal of Hunan Agricultural University(Natural Sciences), 2025, 51(1): 123–130.

投稿网址: <http://xb.hunau.edu.cn>



# 伪异常引导的融合注意力和记忆增强的鱼群异常行为检测

袁红春, 肖智豪

(上海海洋大学信息学院, 上海 201306)

**摘要:** 现有的鱼群异常行为检测方法无法有效提取高级语义信息、特征学习不足, 且缺乏对异常样本的学习和提取关键特征的能力, 无法满足现有的大规模水产养殖需求。笔者结合深度学习技术, 提出了一种伪异常引导的融合注意力和记忆增强的鱼群异常行为检测方法: 通过在视频序列中随机选择跳跃的帧构建伪异常合成器生成伪异常样本, 增强对异常样本的感知能力; 提出选择性内核频率通道注意力(SKFCa)机制, 在选择性内核(SK)注意力的基础上引入频域信息, 以捕捉更丰富的输入信息; 通过瓶颈注意力(BAM)机制在通道和空间维度上抑制不相关的背景特征, 突出前景目标特征; 在2种注意力模块后面添加记忆增强模块, 将异常样本的编码特征替换为正常样本的编码特征, 扩大异常样本输出与输入的重构误差; 将记忆增强后的通道和空间维度上的关键特征和频域特征融合, 以全面提取高级语义信息。结果表明, 本研究所提方法在2种自制的鱼类数据集上检测效果都很好, 曲线下面积(AUC)分别达0.953和0.957, 且能实现对异常的精确定位。

**关键词:** 鱼群异常行为检测; 高级语义信息; 深度学习; 伪异常引导; 注意力机制; 记忆增强

中图分类号: S951.2; TP391.41

文献标志码: A

文章编号: 1007–1032(2025)01–0123–08

## Pseudo-anomaly-guided fish school abnormal behavior detection with fused attention and memory augmentation

YUAN Hongchun, XIAO Zhihao

(School of Information, Shanghai Ocean University, Shanghai 201306, China)

**Abstract:** Existing methods for detecting abnormal behavior in fish schools had difficulties to extract higher-level semantic information and learn features effectively, or identify key features of anomalies, making them unsuitable for large-scale aquaculture. To address this, we proposed a deep learning-based fish school abnormal behavior detection method combining pseudo-anomaly guidance, fused attention, and memory augmentation. First, a pseudo-anomaly synthesizer was developed to enhance anomaly perception by randomly skipping frames in video sequences to generate pseudo-anomalous samples. Next, the SKFCa attention mechanism integrated frequency domain information into the SK attention mechanism to capture richer input features, while the BAM attention mechanism suppressed irrelevant background features in channel and spatial dimensions to emphasize foreground targets. A memory-augmented module replaced with encoded anomaly features with normal samples, amplifying reconstruction errors for anomalies. Finally, memory-augmented key features and enriched frequency domain features were merged to extract comprehensive high-level semantic information. Experiments results on two self-made fish datasets demonstrated superior performance, achieving AUC values of 0.953 and 0.957 with precise anomaly localization.

**Keywords:** fish school abnormal behavior detection; high-level semantic information; deep learning; pseudo-anomaly-guided; attention mechanism; memory augmentation

收稿日期: 2023–10–11

修回日期: 2024–10–30

基金项目: 国家自然科学基金项目(32403031)

作者简介: 袁红春(1971—), 男, 江苏海门人, 博士, 教授, 主要从事人工智能应用等研究, [hcyuan@shou.edu.cn](mailto:hcyuan@shou.edu.cn)

中国是渔业大国,国家大力倡导绿色渔业、生态渔业、数字渔业和智慧渔业<sup>[1]</sup>,其中,对鱼群异常行为的监测实现智能化和科学化管理是智慧渔业<sup>[2]</sup>至关重要的一环。外部环境的变化带来的刺激会使鱼群产生一系列应激反应<sup>[3-4]</sup>,比如快速游动、方向混乱甚至死亡等,而对鱼群异常行为的实时监测能快速检测出鱼群的行为异常,有助于评估水体的质量,避免给渔业和养殖户造成巨大的经济损失<sup>[5]</sup>。传统的水产养殖通常利用人工检测鱼群的异常行为,存在时效性差、覆盖范围有限、成本效益低等问题,难以适应现代规模化养殖的需求。为了提升监测的信息化与智能化水平,越来越多的学者结合计算机视觉技术实现了对鱼群异常行为的检测<sup>[6-14]</sup>,在大幅提高检测效率的同时降低了投入的成本。

罗毅等<sup>[6]</sup>结合直方图统计和 PCA 等技术实现了对行为数据的降维和特征提取,构建了 One-Class(单分类) SVM 模型对鱼类异常行为进行识别,但是该方法仅使用正常样本进行模型训练,缺乏对异常样本的学习。袁红春等<sup>[7]</sup>通过灰度共生矩阵得到 5 种鱼群纹理特征,采用 Lucas-Kanade 光流法计算鱼群的方向矢量,构建 LightGBM 模型,实现对鱼群异常行为的检测。ZHOU 等<sup>[8]</sup>结合深度学习技术,运用数据增强技术扩展数据集后,通过卷积神经网络模型训练,实现了鱼类进食强度的自动分级。朱瑞金等<sup>[9]</sup>提出了一种基于 LBP 特征的 BP 神经网络算法,将鱼群摄食和未摄食活动图像进行滤波处理以及 LBP 特征提取,再经过 BP 神经网络训练,实现了对鱼类摄食行为的分类识别。UBINA 等<sup>[10]</sup>提出了一种两阶段的鱼类摄食强度评估方法,首先使用光流神经网络生成光流帧,然后将其输入到 3D 卷积神经网络中,评估结果的准确率较高。WANG 等<sup>[11]</sup>提出了一种双流三维卷积神经网络,通过使用 3D 卷积神经网络和 FlowNet2 网络将时空特征和运动特征结合,实现了对鱼群行为的识别。文献<sup>[12-14]</sup>结合传统机器学习和深度学习技术,通过 YOLO 识别鱼类后采用跟踪算法追踪鱼类轨迹,然后通过轨迹相似度等算法进行鱼类异常轨迹的判别,能有效识别鱼类行为异常。

综上所述,现有的鱼群行为检测方法大多采用

了传统机器学习、深度学习以及两者结合的方法,虽然取得了一定的效果,但仍存在一些问题。对于传统机器学习方法来说,大多数是针对图片提取人工设计的手工特征,这样会导致提取的特征不充分,无法提取图片和视频数据的高级语义特征,且有的方法只使用正常样本进行模型训练,缺乏对异常样本的学习。对于深度学习方法来说,大多数方法以卷积神经网络(CNN)为基础,二维卷积通过局部连接与权值共享强化了空间特征提取,但其池化操作导致空间分辨率下降及目标细节丢失,且无法有效地对时序上下文进行建模,对动态行为的敏感性不足;三维卷积虽通过时序卷积扩展了时空建模能力,但因计算复杂度剧增和时空特征的耦合,降低了关键运动模式的判别性表征。对于传统机器学习和深度学习结合的方法来说,通过 YOLO 检测鱼类后还得结合跟踪算法计算轨迹进行判别等,使得过程复杂化,无法实现端到端的异常检测。

针对以上问题,笔者提出了一种伪异常引导的融合注意力和记忆增强的鱼群异常行为检测方法,以期在提高检测效率的同时实现对异常的定位。

## 1 伪异常引导的融合注意力和记忆增强的鱼群异常检测模型的建立

本研究中,提出一种基于重构的无监督异常检测方法,以基于 3D 卷积的自动编码器(3DconvAE)网络为基础模型,使用 3D 卷积提取特征,使用 3D BatchNorm 批量归一化并将 LeakyReLU 作为激活函数;此外,还添加伪异常合成模块(jump)、瓶颈注意力模块(BAM)、选择性内核频率通道注意力(SKFCa)模块和记忆增强模块(mem),整体框架图如图 1 所示。整体流程为:首先使用伪异常合成器以一定的概率  $p$  在正常样本的视频序列中随机选择跳跃的帧生成伪异常样本,剩下的以  $1-p$  的概率保留为正常样本;然后将这些正常样本和伪异常样本一起输入网络中,得到相应的重构输出;最后在训练时通过最小化正常样本输出与输入的重构损失,同时最大化伪异常样本输出与输入的重构损失来更新网络,从而限制网络强大的重构能力,进一步扩大正常样本和异常样本的差别。

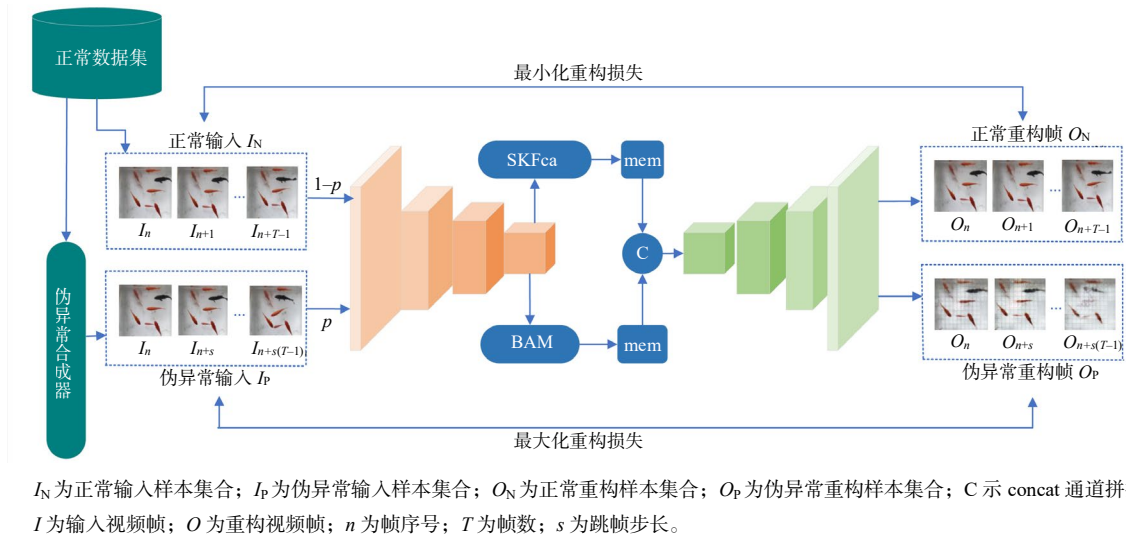


图 1 伪异常引导的融合注意力和记忆增强的鱼群异常检测模型整体框架

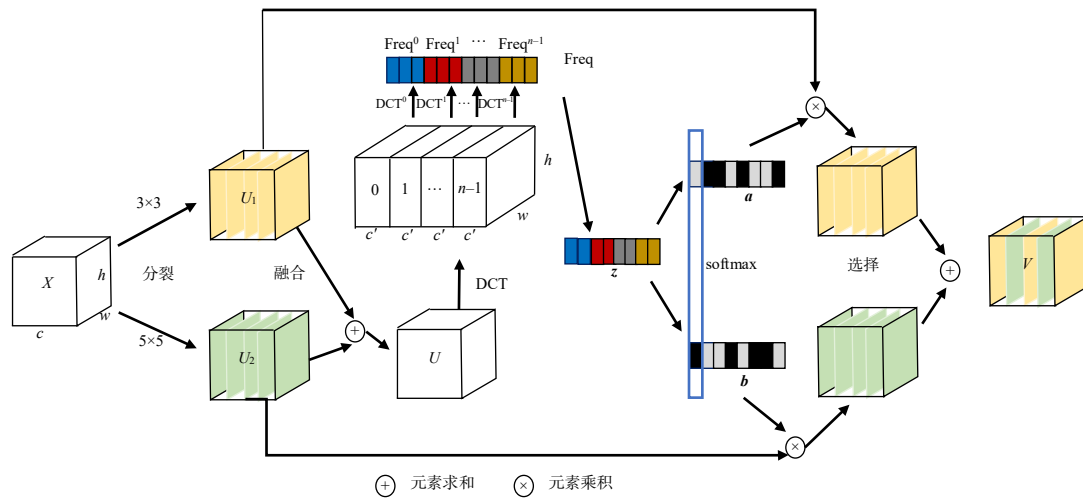
Fig.1 The overall framework of the pseudo-anomaly-guided fish school abnormal behavior detection with fused attention and memory augmentation model

1.1 伪异常合成器

现有的鱼群异常检测方法在训练过程中大多没有使用异常样本,在测试时往往无法有效地将异常样本与正常样本区分开来。本研究中,构建一个伪异常合成器<sup>[15]</sup>,在正常样本中通过随机选择跳跃的帧生成相应的伪异常样本以近似替代异常样本,且以  $p$  的概率参与网络的训练,通过最小化正常样本输出与输入的重构损失和最大化伪异常样本输出与输入的重构损失来限制网络强大的重构能力,从而进一步扩大正常样本和异常样本的差别,将异常样本和正常样本区分开来。

1.2 SKFca模块

选择性内核(SK)<sup>[16]</sup>注意力使用全局平均池化(GAP)来获取每个通道的标量特征,会造成大量频率信息丢失,无法很好地捕捉丰富的输入模式信息;因此,在 SK 注意力的基础上,结合 FcaNet<sup>[17]</sup>,提出 SKFca 注意力,将 GAP 从空间域扩展到频域中,在网络中添加更多的频域信息,可更高效地压缩通道,更好地捕捉频率信息、增强重要频率特征并抑制噪声,从而提升网络在频域上的特征表达能力。SKFca 注意力机制由分裂、融合和选择 3 组操作构成,如图 2 所示。



$X$  为输入特征图;  $c$ 、 $w$  和  $h$  分别为通道数、宽度和高度;  $U_1$  和  $U_2$  为卷积后的特征图;  $U$  为  $U_1$  和  $U_2$  元素相加得到的特征图; DCT 为离散余弦变换;  $c'$  为划分后的小特征图的通道数;  $n$  为特征图的划分个数; Freq 表示将每个小特征图经过 DCT 后按通道拼接;  $z$  为特征向量;  $a$  和  $b$  为对应的权重向量; softmax 为激活函数;  $V$  为输出特征图。

图 2 SKFca 模块结构

Fig.2 The structure of SKFca module

1) 分裂。对输入的特征图  $X$  分别进行  $3 \times 3$  的卷积和  $5 \times 5$  的卷积, 得到相应的特征图  $U_1$  和  $U_2$ 。

2) 融合。对 2 个特征图  $U_1$  和  $U_2$  实现元素相加, 得到特征图  $U$ ,  $U$  中融合了多个感受野的信息。不同于 SK 的全局平均池化(GAP), 使用离散余弦变换(DCT)<sup>[17]</sup>来压缩通道, 以实现高质量的高数据压缩比; 为了更好地压缩通道并引入更多信息, 通过二维 DCT 提取多个频率分量, 并用多个频率分量压缩更多信息。将  $U$  沿通道划分为  $n$  个相同的部分, 对于每个部分, 使用相应的频率二维 DCT 进行处理, 之后通过通道拼接获得最终的多光谱向量, 最后通过一个全连接层进行通道降维, 生成了一个紧凑的特征向量  $z$ 。

3) 选择。对  $z$  在通道维度上应用 softmax 算子获得权重, 并与原来的特征图  $U_1$  和  $U_2$  进行元素相乘和相加得到最终的特征图  $V$ 。

### 1.3 BAM模块

本研究中, 使用 BAM<sup>[18]</sup>注意力机制, 融合通道注意力和空间注意力, 通过将两者并联的方式, 形成一种分层的注意力机制, 可以有效地抑制背景以及纹理等一些低级特征, 使模型更加聚焦于前景特征, 从而加强对高级语义信息的提取。

### 1.4 记忆增强模块

本研究中, 使用记忆增强模块<sup>[9]</sup>来存储正常行为的原型特征, 在训练时只使用正常样本最小化重构误差, 并对记忆模块的内容进行读取和更新。在测试阶段, 正常样本输出与输入的重构误差会保持在较小范围内, 对于异常样本, 由于经过了记忆模块的处理, 其原本的编码特征被替代为记忆模块里的正常行为的特征表示, 经过解码器后的输出与输入的重构误差显著增大, 从而增加了网络对正常样本和异常样本的区分能力。

### 1.5 特征融合模块

在 BAM 模块中由于使用了 GAP 压缩通道, 会造成一些信息的丢失, 导致经过记忆增强后的关键特征也会丢失部分信息, 而丰富的频域特征能弥补通道和空间中关键特征丢失的信息; 因此, 将两者通过 concat 方式进行特征融合, 能全面提取前景目标及关键特征, 即全面提取高级语义信息, 以实现

### 1.6 损失函数

在训练阶段, 为了得到与输入帧更相似的重构帧, 使用均方误差(MSE)损失函数减少重构帧与输入帧之间的距离, 通过计算重构帧和输入帧之间所有通道像素的差值, 保证图像空间中所有像素的相似性。对于正常样本, 通过 Adam 优化器最小化输入帧与其重构帧的 MSE 损失; 对于异常样本, 通过添加负号实现最大化输入帧与其重构帧的 MSE 损失。此外, 还添加交叉熵损失, 通过检索更少但更相关的内存项来表示特征, 从而在内存中学习更多信息的表示。

### 1.7 异常分数

由于峰值信噪比(PSNR)比重构损失能更好地评估图像质量, 因此, 在测试阶段, 选用 PSNR 来进行异常分数的计算。具体来说, 将测试视频中所有帧的 PSNR 归一化到  $[0, 1]$  的范围, 然后取相反数得到最终的异常分数, 这样使得异常分数大的项对应于异常帧, 异常分数小的项对应于正常帧。

## 2 验证试验与结果分析

### 2.1 试验数据集

试验数据集分为红鲫鱼数据集和斑马鱼数据集, 均由上海海洋大学人工智能鱼实验室制作而成。红鲫鱼数据集的训练集只包括正常视频片段, 共 2 762 张图像, 测试集包括正常视频片段和异常视频片段, 共 2 027 张图像。斑马鱼数据集的训练集也只包括正常视频片段, 共 2 642 张图像, 测试集同样包括正常视频片段和异常视频片段, 共 2 210 张图像。

### 2.2 评价指标

采用常见的帧级受试者工作特征曲线(ROC)的曲线下面积(AUC)作为评价指标。

### 2.3 试验环境和参数设置

采用 Pytorch 深度学习框架, 服务器为 Ubuntu16.04.4 LTS 系统, GPU 显卡为 NVIDIA GeForce RTX 3090。训练时, 先将输入帧都调整为 256 像素  $\times$  256 像素, 运用 Adam 优化器对参数进行调整, 批次大小 batchsize 设置为 4, 学习率设置为 0.000 1, 总训练轮数 epoch 设置为 60, 均方误差损

失权重设置为 1, 交叉熵损失权重设置为 0.000 2, 记忆项的个数  $M$  设置为 2 000, 红鲫鱼数据集中生成伪异常样本的概率  $p$  设置为 0.02, 斑马鱼数据集中  $p$  设置为 0.04, 随机从 2~5 中抽取一个数作为跳帧的步长, 以增强模型对异常的感知。

## 2.4 消融试验

为了验证本研究所提方法各个模块的有效性, 通过逐一添加 jump 模块、SKFca 模块、BAM 模块和 mem 模块来进行消融试验, 在红鲫鱼数据集和斑马鱼数据集上取得的结果如表 1 所示。

表 1 红鲫鱼数据集和斑马鱼数据集上的消融试验结果


Table 1 Ablation experiments result on the red crucian carp and the zebrafish datasets

使用的模块	AUC	
	红鲫鱼	斑马鱼
3DconvAE	0.812	0.817
3DconvAE+jump	0.880	0.887
3DconvAE+jump+BAM	0.909	0.924
3DconvAE+jump+SKFca	0.915	0.920
3DconvAE+jump+BAM+mem	0.924	0.936
3DconvAE+jump+SKFca+mem	0.928	0.942
3DconvAE+jump+BAM+SKFca+mem	0.953	0.957

由表 1 可知: 在红鲫鱼和斑马鱼数据集中, 只使用 3DconvAE 网络的效果一般, 在添加了伪异常

合成模块后, AUC 分别提高了 0.068 和 0.070, 说明生成的伪异常样本能近似替代异常样本, 增强了模型对异常样本的感知能力并扩大了异常样本和正常样本的误差, 从而提高了模型检测异常的能力; 在基于伪异常合成的基础上, 分别添加 BAM 和 SKFca 模块, AUC 分别提高了 0.029 和 0.035(红鲫鱼)、0.037 和 0.033(斑马鱼), 表明添加这 2 种注意力模块均增强了模型对于关键特征的提取能力并提高了检测效果; 然后, 在添加了注意力模块后再添加记忆增强模块, AUC 分别提高了 0.015 和 0.013(红鲫鱼)、0.012 和 0.022(斑马鱼), 表明将异常样本的编码特征替换为正常样本的编码特征后, 能有效地增强对异常样本和正常样本的区分能力; 最后, 将 2 种注意力模块经过记忆增强并进行特征融合形成本研究中的最终方法, AUC 再度提升了 0.029 和 0.025(红鲫鱼)、0.021 和 0.015(斑马鱼), 表明通过特征融合能提高模型在通道维度和空间维度上对关键信息和频率信息的感知能力, 从而全面提高检测效果。


为了更直观地展示模型各模块的检测效果, 选取红鲫鱼测试集第 1 637 帧和斑马鱼测试集第 1 305 帧图像分别运用不同模型进行试验, 得到重构误差热力图分别见图 3、图 4。



(a)~(g)分别使用了 3DconvAE、3DconvAE+jump、3DconvAE+jump+BAM、3DconvAE+jump+SKFca、3DconvAE+jump+BAM+mem、3DconvAE+jump+SKFca+mem、3DconvAE+jump+BAM+SKFca+mem 模块的模型的结果。

图 3 红鲫鱼测试集第 1 637 帧图像的重构误差热力图

Fig.3 Reconstruction error heatmaps of frame 1 637 in the red crucian carp test set



(a)~(g)分别使用了 3DconvAE、3DconvAE+jump、3DconvAE+jump+BAM、3DconvAE+jump+SKFca、3DconvAE+jump+BAM+mem、3DconvAE+jump+SKFca+mem、3DconvAE+jump+BAM+SKFca+mem 模块的模型的结果。

图 4 斑马鱼测试集第 1 305 帧图像的重构误差热力图

Fig.4 Reconstruction error heatmaps of frame 1 305 in the zebrafish test set

从图 3 和图 4 可知: 在 2 种鱼类数据集中, 只使用 3DconvAE 网络的效果并不太明显, 在添加了伪异常合成模块之后, 可以看出异常部分的

颜色较为明亮, 表明异常部分的重构误差较大, 即检测到了鱼群的异常行为, 但是会有一定程度的漏检, 而且颜色并不算突出; 在伪异常合成的



基础上分别添加了 BAM 模块和 SKFca 模块后,可以看出这 2 种模块都能有效地抑制鱼缸和水流等背景信息,使得模型更加聚焦在异常行为的鱼身上,并且能突出异常鱼的整块区域,在一定程度上实现了对异常的定位,但是定位并不是很精确;再分别添加记忆增强模块后,可以看到 BAM 模块和 SKFca 模块定位的准确率有了一定的提高,但是仍然不够精确;最后,将 2 种注意力经过记忆增强后实现特征融合,可以看到该方法对异常定位的准确率有了一定的提高,且对于定位的范围基本围绕在异常鱼的整块鱼身区域,从而实现了更加准确而精细的异常定位。

## 2.5 对比试验

为验证本研究所提方法的性能,将其与现有的几种流行的视频异常检测方法进行比较,包括基于重构的方法(MemAE<sup>[19]</sup>、MNAD(重构)<sup>[20]</sup>),基于预测的方法(FFP<sup>[21]</sup>、MNAD(预测)<sup>[20]</sup>)及结合重构和预测的方法(IPR<sup>[22]</sup>、TransAnomaly<sup>[23]</sup>),结果如表 2 所示。

由表 2 可知,在这几种检测方法中,本研究所提方法在红鲫鱼数据集和斑马鱼数据集上都取得

了最好的效果,AUC 分别为 0.953 和 0.957,与现有的检测效果较好的方法(TransAnomaly)相比分别提高了 0.034 和 0.045,证明了本研究所提方法的有效性。

表 2 红鲫鱼数据集和斑马鱼数据集上不同视频异常检测方法的 AUC

Table 2 The AUC of different video anomaly detection methods on the red crucian carp and the zebrafish datasets

方法	AUC	
	红鲫鱼	斑马鱼
FFP	0.891	0.884
IPR	0.913	0.890
MemAE	0.850	0.866
MNAD(重构)	0.853	0.873
MNAD(预测)	0.895	0.888
TransAnomaly	0.919	0.912
本研究所提方法	0.953	0.957

## 2.6 定性分析

为进一步证明本研究所提方法的有效性,在红鲫鱼和斑马鱼测试集中随机选取了一段测试样本集,包括了一些正常帧和异常帧,绘制它们的帧级异常分数曲线,如图 5 所示。

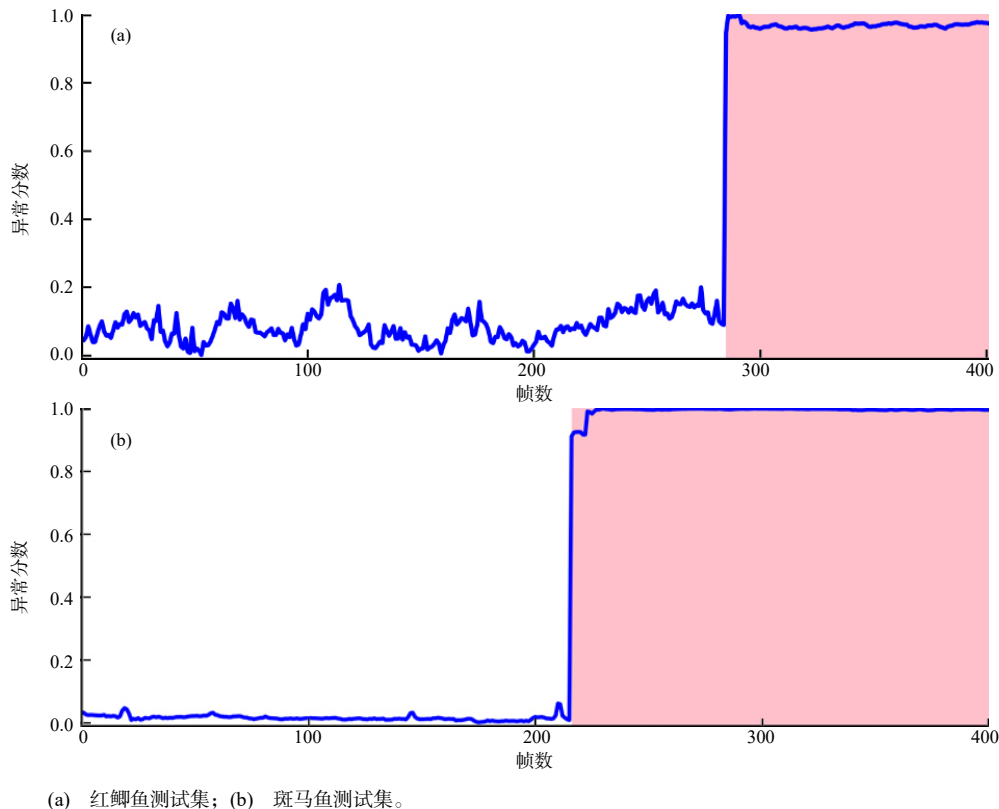



图 5 红鲫鱼测试集和斑马鱼测试集的异常分数

Fig.5 The anomaly scores on the red crucian carp and the zebrafish test sets

从图 5 可知, 初始阶段 2 类鱼群数据集的异常分数较低, 对应了鱼群的正常行为; 一段时间后, 通过向鱼缸中加入次氯酸钠溶液, 鱼群受到刺激后出现了明显的异常游动现象, 此时图中的异常分数突然增加, 并且在之后保持较高的异常分数, 对应了鱼群的异常行为, 说明本研究所提方法能有效检

测并区分鱼群的正常行为和异常行为。


为了更直观地展示模型的检测效果, 从红鲫鱼和斑马鱼测试集中随机挑选了一些帧, 包括正常帧和异常帧, 获得重构误差热力图, 分别如图 6 和图 7 所示。



(a) 正常帧图像 1; (b) 正常帧图像 2; (c) 异常帧图像 1; (d) 异常帧图像 2。

图 6 红鲫鱼测试集的重构误差热力图

Fig.6 The reconstruction error heatmaps of the red crucian carp test set



(a) 正常帧图像 1; (b) 正常帧图像 2; (c) 异常帧图像 1; (d) 异常帧图像 2。

图 7 斑马鱼测试集的重构误差热力图

Fig.7 The reconstruction error heatmaps of the zebrafish test set

从图 6 和图 7 可知, 2 种鱼群数据集的正常帧的颜色比较暗, 说明其输出与输入的重构误差较小; 异常帧的颜色明亮, 特别是在鱼身的整块区域特别明亮, 说明其输出与输入的重构误差大。由此可知, 本研究所提方法实现了准确而精细的异常定位, 很好地检测并区分了鱼群的正常和异常行为。

### 3 结论

本研究中, 笔者针对现有方法无法有效提取高级语义信息、缺乏对异常样本的学习和提取关键特征能力等问题, 提出了一种伪异常引导的融合注意力和记忆增强的鱼群异常行为检测方法, 通过在视频序列中随机选择跳跃的帧构建伪异常合成器, 以增强对异常样本的感知能力; SKFca 模块在 SK 注意力的基础上添加了频域信息, 以捕捉更丰富的输入信息; BAM 模块在通道和空间维度上抑制了不相关的背景特征, 以突出前景目标特征; 记忆模块将异常样本的编码特征替换为正常样本的编码特

征, 扩大了异常样本输出与输入的重构误差; 最后, 将记忆增强后的通道和空间的关键特征与丰富的频域特征融合, 以全面提取前景目标以及关键特征等高级语义信息, 再将其用解码器解码, 实现了端到端的异常检测, 提高了检测效率。本研究所提方法在 2 种鱼类数据集上取得了很好的结果, 检测红鲫鱼和斑马鱼数据集的 AUC 分别为 0.953、0.957, 且实现了对异常的定位。

### 参考文献:

- [1] 周文英, 史文崇. 机器学习在渔业研究中的应用进展与展望[J]. 渔业研究, 2022, 44(4): 407-414.
- [2] 于宁, 徐涛, 王庆龙, 等. 智慧渔业发展现状与对策研究[J]. 中国渔业经济, 2021, 39(1): 13-21.
- [3] 侯晓娇. 基于计算机视觉的鱼群行为检测与结构特征研究[D]. 太原: 太原科技大学, 2014.
- [4] 曹誉尹. 计算机视觉在观测量化鱼类行为中的研究[J]. 农业与技术, 2022, 42(17): 121-124.
- [5] 关辉, 许璐蕾. 基于机器视觉的鱼群异常行为监测技

- 术研究[J]. 信息技术与信息化, 2020(5): 97-99.
- [6] 罗毅, 王伟, 刘勇, 等. 基于 One-Class SVM 的青鳉鱼异常行为识别方法[J]. 河北工业科技, 2022, 39(3): 230-236.
- [7] 袁红春, 王丹, 陈冠奇, 等. 基于 LightGBM 模型的鱼类异常行为检测[J]. 渔业现代化, 2020, 47(1): 47-55.
- [8] ZHOU C, XU D M, CHEN L, et al. Evaluation of fish feeding intensity in aquaculture using a convolutional neural network and machine vision[J]. *Aquaculture*, 2019, 507: 457-465.
- [9] 朱瑞金, 张涛, 扎西顿珠. 基于 LBP 特征的 BP 神经网络鱼群摄食行为检测研究[J]. 黑龙江科学, 2021, 12(18): 5-8.
- [10] UBINA N, CHENG S C, CHANG C C, et al. Evaluating fish feeding intensity in aquaculture with convolutional neural networks[J]. *Aquacultural Engineering*, 2021, 94: 102178.
- [11] WANG G X, MUHAMMAD A, LIU C, et al. Automatic recognition of fish behavior with a fusion of RGB and optical flow data based on deep learning[J]. *Animals*, 2021, 11(10): 2774.
- [12] ANAS O, WAGEEH Y, MOHAMED H E, et al. Detecting abnormal fish behavior using motion trajectories in ubiquitous environments[J]. *Procedia Computer Science*, 2020, 175: 141-148.
- [13] 傅梁著. 基于视觉感知技术的鱼类行为辨别方法研究[D]. 大连: 大连理工大学, 2022.
- [14] 李星辉. 基于轨迹提取的鱼类异常行为监测[D]. 杭州: 浙江大学, 2021.
- [15] ASTRID M, ZAHEER M Z, LEE S I. Synthetic temporal anomaly guided end-to-end video anomaly detection[C]//2021 IEEE/CVF International Conference on Computer Vision Workshops(ICCVW). Montreal, Canada: IEEE, 2021: 207-214.
- [16] LI X, WANG W H, HU X L, et al. Selective kernel networks[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Long Beach, USA: IEEE, 2019: 510-519.
- [17] QIN Z Q, ZHANG P Y, WU F, et al. FcaNet: frequency channel attention networks[C]//2021 IEEE/CVF International Conference on Computer Vision(ICCV). Montreal, Canada: IEEE, 2021: 763-772.
- [18] PARK J, WOO S, LEE J Y, et al. Bam: bottleneck attention module[EB/OL]. (2018-07-18). <https://arxiv.org/abs/1807.06514v1>.
- [19] GONG D, LIU L Q, LE V, et al. Memorizing normality to detect anomaly: memory-augmented deep autoencoder for unsupervised anomaly detection[C]//2019 IEEE/CVF International Conference on Computer Vision(ICCV). Seoul, Republic of Korea: IEEE, 2019: 1705-1714.
- [20] PARK H, NOH J, HAM B. Learning memory-guided normality for anomaly detection[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, USA: IEEE, 2020: 14360-14369.
- [21] LIU W, LUO W X, LIAN D Z, et al. Future frame prediction for anomaly detection: a new baseline[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018: 6536-6545.
- [22] TANG Y, ZHAO L, ZHANG S S, et al. Integrating prediction and reconstruction for anomaly detection[J]. *Pattern Recognition Letters*, 2020, 129: 123-130.
- [23] YUAN H C, CAI Z Y, ZHOU H, et al. TransAnomaly: video anomaly detection using video vision transformer[J]. *IEEE Access*, 2021, 9: 123977-123986.

责任编辑: 邹慧玲  
英文编辑: 柳正