

DOI:10.3969/j.issn.1007-9580.2024.05.010

开放科学(资源服务)标识码(OSID):

陈庭槿,黄耀波,陈炫辛,等.基于 Prune-YOLOv5s 的养殖鱼类缺氧风险评估方法[J].渔业现代化,2024,51(5):81-89.



基于 Prune-YOLOv5s 的养殖鱼类缺氧风险评估方法

陈庭槿¹,黄耀波¹,陈炫辛²,周纪军¹,刘英¹

(1 深圳大学物理与光电工程学院,广东 深圳 518061;

2 深圳大学教育学部,广东 深圳 518061)

摘要:为解决传统鱼类缺氧检测方法准确率不高、需耗费大量人力的问题,提出了一种基于 Prune-YOLOv5s 的养殖鱼类缺氧风险评估方法。该方法首先采集鱼类缺氧进行水面呼吸(Aquatic surface respiration, ASR)时的数据集,并训练 YOLOv5s 模型,然后用轻量化改进的 YOLOv5s 模型实时检测鱼类缺氧进行水面呼吸的行为,并引入鱼类 ASR 系数,设计鱼群缺氧评估模块实现鱼类缺氧风险评估。最后通过鱼类缺氧试验对改进前后 YOLOv5s 模型性能以及缺氧评估模块的准确率进行测试。结果显示:与原模型相比,Prune-YOLOv5s 模型的性能得到明显提升,其中综合性能最优的 65%_Prune_YOLOv5s 模型,模型大小缩小至原模型的 45.3%,在检测精度上提升 0.6%,在推理速度上提升 23.8%,在检测速度上提升 31.4%。鱼群缺氧评估模块在测试集中的准确率可达 97.4%,在鱼类缺氧试验周期中表现良好。研究表明,基于 Prune-YOLOv5s 的养殖鱼类缺氧风险评估方法能有效检测鱼类缺氧情况,准确给出风险提示,将在实际应用中具有较好的可行性。

关键词:鱼类缺氧;人工智能;深度学习;YOLOv5s;ASR 系数

中图分类号:TP 391;S 932.2

文献标志码:A

文章编号:1007-9580(2024)05-0081-009

中国是渔业大国,水产养殖业作为中国渔业的核心部分,其规模现已超 12 000 亿元^[1-2]。缺氧会对鱼类养殖造成诸多不良影响,包括摄食量下降、生长速度减缓、繁殖能力降低,甚至窒息死亡等^[3-6],可能造成巨大的经济损失,因此由缺氧而引起的养殖鱼类泛塘是养殖户最担心的问题之一。传统的鱼类缺氧检测是溶氧仪测试法和人工观察法,前者由于水体环境复杂,易受环境干扰,水体溶氧量可能存在较大差异,进而影响溶氧仪的测试精度;后者则需要人工多次监视,耗费人力大,同时主观判断存在较大误差,难以准确评估鱼类缺氧情况。

当鱼类处于缺氧状态时,鱼类群体会表现出某些特定行为以应对缺氧环境。Kramer 等^[7]对鱼类处于低氧条件下的行为进行分析,提出了群体活动变化、空气呼吸增加、栖息地变化以及水面

呼吸增加这 4 大缺氧行为。其中鱼类进行水面呼吸(aquatic surface respiration, ASR)是指鱼在水和空气的交界处,嘴部在水下张开,头部接触水面^[8-10],俗称“浮头”。当溶氧量降低到某一阈值后,进行 ASR 是大多数鱼类共有的群体性的行为,并且随着溶氧量的降低,鱼类的 ASR 持续时间也会增加^[11-13]。故通过鱼群中进行 ASR 的鱼比例以及 ASR 的持续时间这两个参量,即可有效衡量鱼类缺氧情况。根据国内外的相关研究,鱼类的低氧耐受性会随着鱼类体型大小、种类、生理状态的不同而不同^[14],并且温度、水质、光照等环境因素也会影响鱼类的缺氧情况,因此在一般情况下鱼类缺氧的溶氧量阈值通常是不同的。何伟等^[15]通过研究发现 10 °C 下鳊鱼的缺氧阈值约为 1.39 mg/L,并随着温度升高而下降;Gee 等^[10]对 26 种鱼进行研究,发现不同种类的鱼进行 ASR 的

收稿日期:2024-04-12

基金项目:深圳大学横向项目“基于深度学习的便携式水下成像及实时检测系统(横 KJ2023059)”;国家级大学生创新创业训练计划项目“普惠智慧渔业管理系统(202310590046)”

作者简介:陈庭槿(2001—),男,研究方向:深度学习。E-mail:1206235928@qq.com

通信作者:刘英(1978—),女,副研究员,研究方向:智能数据分析,水下探测与成像。E-mail:liuying-ipp@szu.edu.cn

溶氧量阈值是不同的;Mustafa等^[16]提出鲤鱼的缺氧范围在 1.8 ± 1.1 mg/L。因此,相比于只通过溶氧量数值的判断方法,通过检测鱼类在缺氧时共有的群体性行为来评估鱼类的缺氧情况会更加直接有效。

近年来计算机视觉技术在鱼类检测中的应用日渐成熟。Fernandes等^[17]通过深度学习图像分割技术成功检测鱼的体质量;赵梦等^[18]提出了SK-YOLOv5模型实现对养殖鱼群的检测,其识别精度为98.86%;Zhao等^[19]提出了改进的动能模型以检测鱼群特殊行为,取得了良好的效果。尽管多数模型能取得较好效果,但模型的运行仍十分依赖于高性能计算机,在性能普通的设备上可能存在检测速度下降甚至无法运行等问题。对视频影像的鱼群实时检测来说,则要求模型检测速度快^[18]。另外计算机视觉技术在鱼类缺氧检测应用方面的相关研究也比较稀少,吴昊峰等^[20]针对工厂化养殖提出一种基于图像分类的鱼类缺氧状态判断方法并在试验中顺利测试成功,但该方法主要采用ASR持续时间进行判断,而并未将进行ASR的鱼类在鱼群中所占比例这一重要参量作为缺氧状态评估,存在一定缺陷。

本研究将提出基于Prune-YOLOv5s的养殖

鱼类缺氧风险评估方法,通过模型剪枝方法轻量化YOLOv5s模型,减小模型大小,提高模型的检测速度。最后通过鱼类缺氧试验测试该方法的实际效果,以期为鱼类缺氧的智能检测和自动控制提供技术参考。

1 材料与方法

1.1 设计方案

针对传统鱼类缺氧检测方法准确率不高、需耗费大量人力问题,本研究通过深度学习模型对鱼类缺氧进行检测。当缺氧时鱼类会呈现ASR的特殊动作形态,这与常见的水中游动形态不同,故采集并制作了鱼类缺氧时进行ASR的缺氧数据集。在实际应用场景中,要求模型能对养殖池进行实时检测,而普通设备无法匹配模型运行的性能要求,会导致运行卡顿或失败等问题。为了提高模型对设备的兼容性,采用通道剪枝方法轻量化YOLOv5s模型,在保持较高检测精度的同时,提高模型运行速度,减小内存占用。本研究利用计算机视觉技术检测鱼群的ASR情况,并由此计算鱼类ASR系数实现对鱼类缺氧风险的量化评估。图1为基于Prune-YOLOv5s的养殖鱼类缺氧风险评估方法的设计方案流程图。

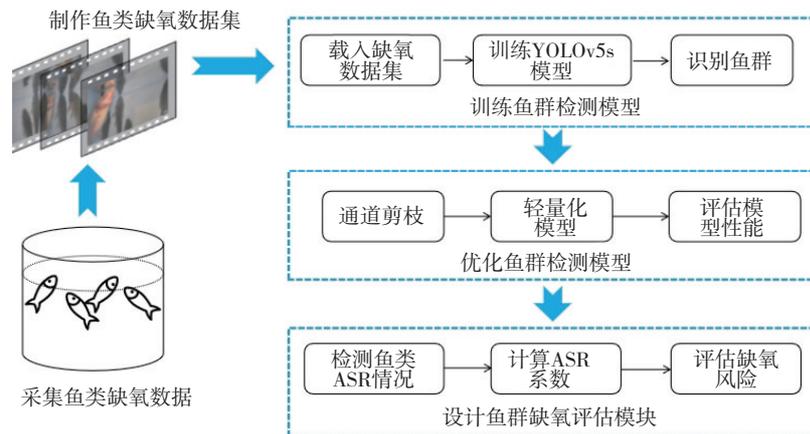


图1 设计方案流程图

Fig. 1 Design flowchart

1.2 数据集构建

搭建了鱼类缺氧测试系统,通过水下摄像机采集了缺氧条件下(溶氧量 ≤ 1.0 mg/L)^[21]的鱼类视频数据,大小为5.38 G。通过VMS软件将视频储存到计算机中。然后对视频数据进行抽帧,

并挑选3 954张质量较好图像数据,图像分辨率为 $1\ 920\times 1\ 080$ 。通过Labelimg软件,对图片中的缺氧鱼类进行标注,输出对应的txt标签文件,文件中包含标注框 x 、 y 坐标、标注框长和宽以及类别“fish”。最后通过Python程序对标签数据以及

图片进行批量操作,按 8:1:1 划分成训练集、验证集、测试集。

1.3 鱼群检测模型

1.3.1 模型评估指标

采用了检测精度 mAP (mean Average Precision)、模型大小 (model size)、推理速度 (inference speed) 以及检测速度对模型性能进行评估。mAP 是所有类别平均精确度的均值,是模型综合精度的度量。模型大小是模型文件的存储大小,能直接影响到模型在计算资源有限的设备上部署效率,越小的模型越便于在设备上部署。推理速度是模型对单个输入样本进行处理并输出结果所需的时间,处理时间越短,代表模型处理样本速度越快;而检测速度则是指模型处理视频的实际速度,通常采用模型每秒可处理的帧数 FPS (Frames Per Second) 来表示,FPS 越高代表模型处理视频速度越快,实时性越好。检测速度不仅受模型推理速度的影响,也受设备计算资源的影响。

1.3.2 轻量化模型设计策略

YOLOv5s 是 YOLOv5 系列模型中网络深度最小、检测速度最快的模型^[22],对设备性能要求较低,在普通设备上能有良好的表现。

在提高模型检测效率、减小模型大小的轻量化研究中,主要分为直接设计小模型和对训练好的模型进行压缩的两大方向。为了获得总体性能更优的轻量化模型,在前期工作中,设计了基于深度可分离卷积轻量化改进的 MobileNetV2-YOLOv5s^[23],基于通道混洗轻量化改进的 ShuffleNetV2-YOLOv5s^[24] 以及基于通道剪枝轻量化改进的 Prune-YOLOv5s^[25],3 种不同的轻量化模型,并在一个包含 3 563 张分辨率为 640×512 鱼类图像的数据集中进行测试,测试结果如表 1 所示。

表 1 模型测试结果
Tab. 1 Model test results

目标检测模型	模型大小/MB	检测精度	FPS
YOLOv5s	13.7	95.8%	66
MobileNetV2-YOLOv5s	6.39	92.1%	50
ShuffleNetV2-YOLOv5s	2.32	92.7%	43
Prune-YOLOv5s	11.2	95.1%	72

测试结果表明,Prune-YOLOv5s 在检测精度和轻量化程度上得到了平衡,在基本不损失准确率的前提下,具有最快的检测速度。因此,在后续的工作中将 Prune-YOLOv5s 模型应用于鱼类缺氧方向评估,以提高实时性。

1.3.3 通道剪枝处理的 YOLOv5s 模型

网络剪枝^[26]作为结构化剪枝的主要方法之一,通过剪除冗余通道、重构输出特征图以及迭代优化等操作,在尽量保持模型精度的前提下减小模型大小,是一种常用的模型轻量化方法。本文对 YOLOv5s 模型进行通道剪枝,移除网络中冗余通道,提高模型的检测速度,减小模型对设备性能的依赖。

通道剪枝是通过在 BN (Batch Normalization, 批归一化) 层对缩放因子 γ 施加 L1 正则化,促使缩放因子趋近于零,当一个通道的缩放因子接近零则代表经过该通道卷积后的输出仍为零,那么该通道即被模型识别为冗余的通道^[27-28]。引入缩放因子稀疏化训练的损失函数如下:

$$L = \sum_{(x,y)} l(f(x,W),y) + \lambda \sum_{\gamma \in \Gamma} g(\gamma) \quad (1)$$

式中: L 为训练的损失函数, x 为输入的训练数据; y 为正确值; W 为权重参数; λ 为正则化系数,用于控制稀疏性的强度。

$$g(\gamma) = |\gamma| \quad (2)$$

式中: $g(\gamma)$ 代表对 γ 施加 L1 范数正则化,用于约束模型参数大小和稀疏性。

在识别到冗余的通道后,即可通过 BN 层的平移和缩放通道的功能,剪除掉冗余的通道。结合后的 BN 层输出如下:

$$\hat{z} = \frac{Z_{in} - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} \quad (3)$$

$$Z_{out} = \gamma \hat{z} + \beta \quad (4)$$

式中: Z_{in} 为 BN 层的输入, Z_{out} 为 BN 层的输出, μ_B 和 σ_B 分别为输入激活函数 B 的平均值和标准差值, β 为可训练参数。

剪枝后的模型会在验证集上评估其准确率,模型剪枝后通常伴随着准确率的暂时减低,那么则会对模型进行微调 (fine-tuning) 操作,对剪枝后的模型重新训练,以优化剩余通道的权重,提升模型性能。

通道剪枝原理如图 2 所示。

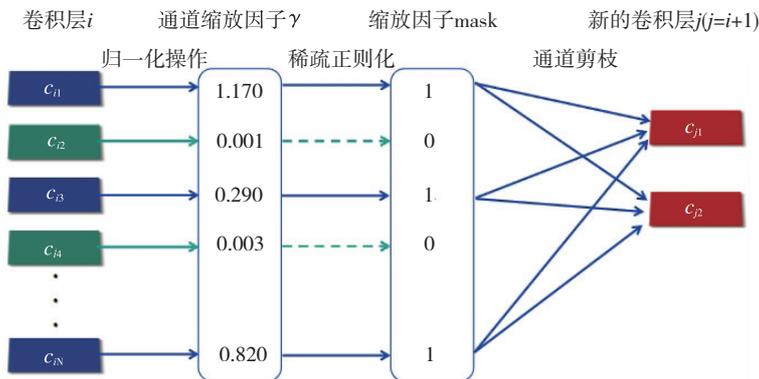


图 2 通道剪枝原理图

Fig. 2 Channel pruning schematic

1.4 鱼群缺氧评估模块

设计了相应的鱼群缺氧评估模块,通过鱼类 ASR 情况反映鱼类缺氧风险。在鱼类 ASR 试验上,多数学者采用过进行 ASR 的鱼类比例和 ASR 的持续时间这两个参数来评估鱼类的 ASR 情况^[29-31],进行 ASR 的鱼类比例越大、鱼类进行 ASR 的时间越长,代表鱼处于缺氧状态越严重,故通过这两个参数计算鱼类的 ASR 系数,并以此评估鱼类缺氧风险。公式如下:

$$F = \frac{\sum_{i=1}^n n_i}{N \cdot t} \tag{5}$$

式中: \$F\$ 为 ASR 系数,代表鱼类平均每秒进行 ASR 的比例; \$n\$ 为模型每秒检测到进行 ASR 的鱼类数目; \$N\$ 是鱼群总数,本研究主要针对工厂化养殖,养殖鱼群总数 \$N\$ 是可以事先得知或通过摄像头安装在适当位置预先采集得到; \$t\$ 为 ASR 系数计算的时间窗口。

算法逻辑图如图 3 所示。

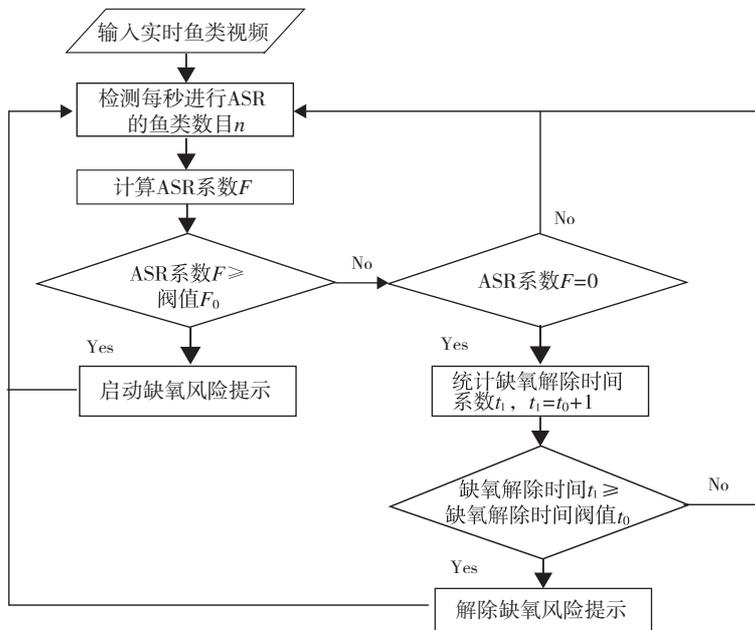


图 3 鱼群缺氧评估模块流程图

Fig. 3 Flow chart of fish hypoxia assessment module

首先通过鱼群检测模块对输入鱼类影像视频进行检测,获取每秒鱼类进行 ASR 的数目并以

此计算鱼类 ASR 系数,当 \$F\$ 大于等于设定的 ASR 缺氧系数阈值 \$F_0\$,说明鱼类缺氧风险高,程序在

视频中输出缺氧风险提示;在输出缺氧风险提示后,用户采取增氧措施使鱼摆脱缺氧状态,鱼类不再进行 ASR 即 $F=0$ 时,开始统计风险解除时间 t_1 ,当统计到 $t_1 \geq$ 风险解除时间阈值 t_0 时,解除缺氧风险提示。通过设置风险解除时间以确保鱼类真正恢复到正常状态,有效降低鱼类缺氧风险。模块会在视频中实时显示鱼类 ASR 系数,为用户评估鱼类缺氧风险提供便利。

2 测试方法

2.1 鱼类缺氧测试系统

鱼类缺氧测试系统由直径 47 cm、高 50 cm 的养殖池(水深约 40 cm),搭配 200 万像素的网络摄像机(哈克思特 HK90A),打氧机(AQ-2000F, 28 W),溶氧仪(AZ8403)和计算机组成,如图 4 所示。

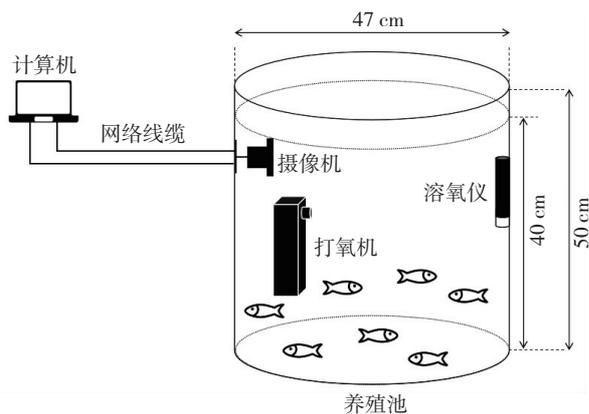


图 4 鱼类缺氧测试系统

Fig. 4 Fish hypoxia test system

摄像机固定在水平面下方,打氧机和溶氧仪固定在养殖池中部。计算机放置在养殖池附近的工作台,通过 5 m 长的网络线缆与摄像机相连,减少人类活动引起鱼类行为反常。使用软件(由哈克思特提供)进行视频采集。试验以禾花鱼为研究对象。养殖池养殖 10 条鱼(体质量约 43.3 g,体长约 13 cm)。试验前将鱼在养殖池中培养至少 4 周,可认为已经适应了饲养环境。

2.2 模型运行环境及参数配置

操作系统为 Windows 10 专业工作站版, GPU 为 NVIDIA GeForce RTX2080TI, CPU 为 Intel(R) Xeon(R) Gold512@2.20 GHz 2.19 GHz(双处理器),硬盘为 475DB NTFS(数量为 4),内存为 SK

128GB DIMM 2400MHz; GPU 加速计算架构为 CUDA 11.3,程序开发语言为 Python 3.6,深度学习框架为 Pytorch 1.7,加速神经网络库为 CuDNN8.2.0,计算机视觉库为 OpenCV 4.7.0;模型选用 YOLOv5s, Backbone 为 CSPDarknet53,学习率根据余弦退火算法确定, Batchsize 为 8, Epoch 数为 100。

2.3 测试步骤

在上述测试系统中,通过打氧机使水中溶氧量上升到正常值,再关闭打氧机让溶氧量自然下降,当溶氧量 ≤ 1.0 mg/L,即鱼类处于缺氧时,重新启动打氧机使溶氧量恢复正常水平。在此鱼类缺氧试验的过程中,启动摄像机实时记录鱼类活动的同时,通过溶氧仪记录对应时间下的溶氧量。重复多次操作并记录多个鱼类缺氧周期,最后将摄像机采集到的视频数据上传到计算机中,由模型进行检测试验。

3 结果与分析

3.1 Prune-YOLOv5s 模型

剪枝率的大小会影响模型性能,故采用相同的数据集分别训练 YOLOv5s 模型与不同剪枝率下的 Prune-YOLOv5s 模型以进行性能对比。同时通过检测同一鱼类视频评估各个模型的检测速度。试验结果如表 2 所示,其中以“剪枝率_Prune_YOLOv5s”代表对应剪枝率下的 Prune_YOLOv5s。

表 2 YOLOv5s 模型与不同剪枝率下的 Prune-YOLOv5s 模型性能对比

Tab. 2 Performance comparison between YOLOv5s model and Prune-YOLOv5s models under different pruning rates

模型	检测精度	模型大小 /MB	推理时间 /ms	FPS
YOLOv5s	95.7%	13.70	17.2	49.48
15%_Prune_YOLOv5s	96.1%	11.40	15.9	54.93
25%_Prune_YOLOv5s	96.5%	10.25	15.3	56.80
35%_Prune_YOLOv5s	96.7%	9.11	14.8	58.46
45%_Prune_YOLOv5s	96.1%	8.11	14.0	61.26
55%_Prune_YOLOv5s	96.4%	6.92	13.5	63.28
65%_Prune_YOLOv5s	96.3%	6.20	13.1	65.00

由试验结果可知,相比于 YOLOv5s 模型,剪

枝后的 YOLOv5s 模型在速度上获得了明显提升。并且随着剪枝率的上升, Prune-YOLOv5s 模型的推理速度及检测速度也随之上升, 推理速度最多提升了 23.8%, 达到 13.1 ms, 而检测速度最高提升了 31.4%, 达到 65.00 FPS。由于规模较小、复杂度低的简单数据集, 不需要过多的通道提取特征, 冗余的通道较多, 故而能使模型在尽量保持原有检测精度的前提下, 剪掉许多参数^[28], 因此剪枝后 YOLOv5s 模型大小明显减小, 在保持原有检测精度的前提下, 模型大小最高可被压缩至原模型的 45.3%。上述结果表明模型剪枝有效轻量化了 YOLOv5s 模型, 有利于模型在计算资源有限的设备上顺利运行。

在检测精度上, 模型剪枝后却有略微提升, mAP 提升了 0.4%~1.0%。这是因为数据集复杂度较低, 模型的检测精度在微调操作中不仅能很快恢复到原有精度, 甚至可能超越原有模型。

由于 65%_Prune_YOLOv5s 模型在具有较好的检测精度的同时, 其模型大小及检测速度表现最优, 故将用于后续研究中。

3.2 鱼群缺氧评估模块

基于上述测试系统, 展开了多次鱼类缺氧试验, 记录了在 2023 年 11 月—2024 年 2 月期间, 总时长为 88 h 的试验数据。当溶氧量 ≤ 1.0 mg/L 时, 鱼类会出现群体性 ASR 的情况, 表示处在缺氧状态。根据公式(5)分别计算缺氧和不缺氧状态下的鱼类 ASR 系数, 结果显示, 鱼类缺氧时 ASR 系数为 0.15~0.36, 不缺氧时的 ASR 系数为 0.00~0.09。由于测得缺氧的 ASR 系数最低为 0.15, 故将 ASR 缺氧系数阈值 F_0 设置为 0.15, 使程序能及时给出风险提示。在实际应用过程中可以把 F_0 值设低一些, 虽然可能会出现一些误报警, 但可以避免漏报情况。解除报警时间阈值 t_0 可以根据养殖池大小和打氧机的功率计算得到, 或根据经验来设置, 目的是通过打氧后确保溶氧量上升, 鱼群已摆脱缺氧状态, 解除报警时间阈值 t_0 设置为 7 min。采用测试集对缺氧评估模块进行测试, 测试集主要由 15 个鱼类缺氧视频以及 24 个鱼类不缺氧视频组成, 为了确认鱼类是稳定地处于某一状态下, 故每段测试视频时长均不低于 2 h。模块检测效果如表 3 所示。

表 3 模块在测试集中的检测效果

测试集	测试集数量	模型准确预测数量	检测准确率
缺氧	15	15	100.0%
不缺氧	24	23	95.8%
总计	39	38	97.4%

试验结果显示, 模块均能在鱼类缺氧时准确发出风险提示, 仅一次在不缺氧时错误发出提示, 检测准确率为 97.4%。同时为了进一步验证模型的实际应用效果, 试验模拟并记录了鱼类从常氧到缺氧, 再通过打氧机让溶氧量恢复到常氧的周期, 并由模块对该试验周期进行检测, 检测效果如图 5、图 6 所示。图 5 为鱼群缺氧评估模块的效果图, 其中图 5a 展示了在未缺氧时没有鱼类进行 ASR, ASR 系数为 0, 不输出风险提示的情况, 而图 5b 展示了在缺氧时, 鱼类进行 ASR 且 ASR 系数超过 F_0 , 输出风险提示的情况。图 6 为试验周期中溶氧量、ASR 系数、风险提示的实测曲线, 其中用 1 和 0 分别表示是否发出风险提示。



图 5 模块检测效果图

Fig. 5 Model testing effect diagram

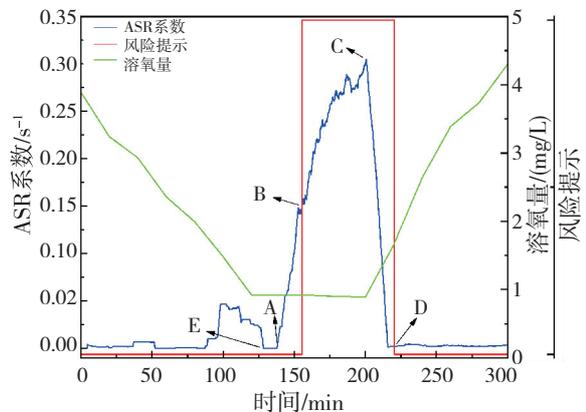


图 6 溶氧量、ASR 系数、风险提示实测曲线

Fig. 6 Measured curves of dissolved oxygen, ASR coefficient and risk warning

试验结果显示, 模块预测结果与实际试验情

况基本吻合。溶氧量降低至 1.0 mg/L 后,鱼群因缺氧而逐渐开始进行 ASR(图 6 的 A 点处),随着处于缺氧状态的时间增加,ASR 持续时间增加, F 也随之增大,并在测试周期的 155 min 时(图 6 的 B 点处) $F > F_0$,说明鱼类已经出现群体性较长时间缺氧,存在较为严重的缺氧风险,则出现缺氧风险提示。在确认鱼类已处于缺氧状态后,在 200 min 时(图 6 的 C 点处)启动打氧机增氧,鱼类不再进行 ASR, F 逐渐降低至 0,并当在 F 保持一定时间 t_0 后,于 220 min 取消缺氧风险提示(图 6 的 D 点处);其中, t_0 的作用是为鱼类在缺氧和不缺氧状态的转换过程中提供一定的缓冲时间,降低鱼类缺氧风险。

虽然该评估模块能较好地实现对鱼类缺氧风险评估,但仍有一定误差存在。这是由于鱼类在使用 ASR 这一行为上具有一定的灵活性^[7,32]。这样的灵活性主要体现在:一方面,在未达到低氧前,鱼类可能受水质、温度、低氧耐受性等因素^[32-33]的影响,而短暂进行 ASR,这也使得在正常溶氧量水平下,ASR 系数的数值存在小范围的浮动。另一方面,鱼类可根据低氧程度调节进行 ASR 的时间比例^[32],并且光照变化、环境噪声等环境因素容易使鱼类受惊吓^[34],故导致在低氧条件下鱼类可能存在部分时间段不进行 ASR,这也解释了在试验中 128~138 min 这段时间内没有鱼类进行 ASR。

4 结论

本研究提出了一种基于 Prune-YOLOv5s 的养殖鱼类缺氧风险评估方法,采用深度学习模型检测鱼类 ASR 情况,并引入 ASR 系数实现对鱼类缺氧风险评估。借助鱼类缺氧试验对该方法进行测试,结果表明:相比于 YOLOv5s 模型,Prune-YOLOv5s 模型在模型大小、推理速度、检测速度以及检测精度上均得到提升,其中 65%_Prune_YOLOv5s 模型综合表现最优,其模型大小缩小至原模型的 45.3%,推理速度提升 23.8%,检测速度提升 31.4%,检测精度也提升了 0.6%。在鱼类缺氧测试集中,鱼群缺氧评估模块可以准确检测鱼类缺氧情况并发出风险提示,检测准确率为 97.4%,并且在模拟的试验周期中具有良好表现。本研究的重点在于提出基于计算机视觉的鱼类缺

氧风险评估方法,并通过测试验证其可行性。将摄像头安装于水下检测鱼群,这一做法提高了检测的准确性,却也限制了摄像头的可视范围。面对较大的养殖池,虽然可以通过增设摄像头来实现全面监控,但这会增加经济成本。为了解决这一矛盾,未来的工作中将为模型融入目标追踪算法,通过捕捉水面鱼类的行为轨迹来评估鱼类缺氧风险或健康状况,以提升该方法的实用性。

□

参考文献

- [1] 农业农村部渔业渔政管理局,全国水产技术推广总站,中国水产学会. 中国渔业统计年鉴[M]. 北京:中国农业出版社,2024.
- [2] 莽琦,徐钢春,朱健,等. 中国水产养殖发展现状与前景展望[J]. 渔业现代化,2022,49(2):1-9.
- [3] WU S S, ZHOU S B, RANDALL J D, et al. Aquatic hypoxia is an endocrine disruptor and impairs fish reproduction [J]. Environmental Science Technology, 2003, 37(6):1137-1141.
- [4] SHANG E H, WU R S. Aquatic hypoxia is a teratogen and affects fish embryonic development [J]. Environmental science technology, 2004, 38(18):4763-4767.
- [5] 徐贺,陈秀梅,王桂芹,等. 低氧胁迫在水产养殖中的研究进展[J]. 饲料工业,2016,37(2):33-37.
- [6] ABDEL-TAWWAB M, HAGRAS A, ELBAGHDADY H, et al. Dissolved oxygen level and stocking density effects on growth, feed utilization, physiology, and innate immunity of Nile tilapia, *Oreochromis niloticus* [J]. Journal of Applied Aquaculture, 2014, 26(4):340-355.
- [7] KRAMER D L. Dissolved oxygen and fish behavior [J]. Environmental Biology of Fishes, 1987, 18(2):81-92.
- [8] URBINA A M, FORSTER E M, GLOVER N C. Leap of faith: Voluntary emersion behaviour and physiological adaptations to aerial exposure in a non-aestivating freshwater fish in response to aquatic hypoxia [J]. Physiology Behavior, 2011, 103(2):240-247.
- [9] SLOMAN K A, WOOD C M, SCOTT G R, et al. Tribute to R. G. Boutilier: the effect of size on the physiological and behavioural responses of oscar, *Astronotus ocellatus*, to hypoxia [J]. The Journal of experimental biology, 2006, 209(7):1197-1205.
- [10] GEE J H, TALLMAN R F, SMART H J. Reactions of some great plains fishes to progressive hypoxia [J]. Canadian Journal of Zoology, 1978, 56(9):1962-1966.
- [11] RICHARDS J G. Physiological, behavioral and biochemical adaptations of intertidal fishes to hypoxia [J]. The Journal of experimental biology, 2011, 214(2):191-199.
- [12] KRAMER D L, MEHEGAN J P. Aquatic surface respiration, an adaptive response to hypoxia in the guppy, *Poecilia reticulata* (Pisces, Poeciliidae) [J]. Environmental Biology of Fishes,

- 1981,6(3):299-313.
- [13]李洁. 限制溶解氧供应对褐牙鲈幼鱼生长的影响及其机制的实验研究[D]. 青岛:中国海洋大学,2012.
- [14]COLT J, ORWICZ K, BOUCK G. Water quality considerations and criteria for high-density fish culture with supplemental oxygen[M]. Bethesda, MD: American Fisheries Society, 1991: 372-385.
- [15]何伟. 温度对几种鲤科鱼类低氧耐受及生化反应的影响[D]. 重庆:重庆师范大学,2014.
- [16]MUSTAFA S A, AL-SUBIAI S N, DAVIES S J, et al. Hypoxia-induced oxidative DNA damage links with higher level biological effects including specific growth rate in common carp, *Cyprinus carpio* L[J]. *Ecotoxicology*, 2011, 20(6):1455-1466.
- [17]FERNANDES A F A, TURRA E M, ALVARENGA R R D, et al. Deep learning image segmentation for extraction of fish body measurements and prediction of body weight and carcass traits in Nile tilapia[J]. *Computers and Electronics in Agriculture*, 2020, 170:105274.
- [18]赵梦,于红,李海清,等. 融合 SKNet 与 YOLOv5 深度学习的养殖鱼群检测[J]. *大连海洋大学学报*, 2022, 37(2):312-319.
- [19]ZHAO J, GU Z, SHI M, et al. Spatial behavioral characteristics and statistics-based kinetic energy modeling in special behaviors detection of a shoal of fish in a recirculating aquaculture system[J]. *Computers and Electronics in Agriculture*, 2016, 127:271-280.
- [20]吴昊峰. 基于多源数据模型的工厂化循环水产养殖精准曝气策略[D]. 重庆:重庆工商大学,2022.
- [21]刘玉兰,刘娟,韩世涛,等. 鱼塘浮头预报方法研究[J]. *宁夏农林科技*, 2011, 52(9):107-109.
- [22]赵新龙,顾臻奇,李军. 基于 YOLOv5s 和改进 SORT 算法的黑水虻幼虫计数方法[J]. *农业机械学报*, 2023, 54(7):339-346.
- [23]SANDLER M, HOWARD A, ZHU M, et al. Mobile Net V2: Inverted Residuals and Linear Bottlenecks [C]//IEEE. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA: IEEE/CVF, 2018:4510-4520.
- [24]SU J, YANG M, TANG X. Integration of Shuffle Net V2 and YOLOv5s Networks for a Lightweight Object Detection Model of Electric Bikes within Elevators [J]. *Electronics*, 2024, 13(2):394-410.
- [25]周纪军. 基于深度学习的便携式鱼类实时检测系统的研究与实现[D]. 深圳:深圳大学,2023.
- [26]HE Y, ZHANG X, SUN J. Channel pruning for accelerating very deep neural networks [C]//IEEE. Proceedings of the IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017:1398-1406.
- [27]LAI Z, MO D, WONG W K, et al. Robust discriminant regression for feature extraction [J]. *IEEE transactions on cybernetics*, 2017, 48(8):2472-2484.
- [28]LIU Z, LI J, SHEN Z, HUANG G, et al. Learning efficient convolutional networks through network slimming [C]//IEEE. Proceedings of the IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017:2736-2744.
- [29]SHINGLES A, MCKENZIE D J, CLAIREAUX G, et al. Reflex cardioventilatory responses to hypoxia in the flathead gray mullet (*Mugil cephalus*) and their behavioral modulation by perceived threat of predation and water turbidity [J]. *Physiological & Biochemical Zoology* Pbz, 2005, 78(5):744-755.
- [30]余欣欣. 低氧对团头鲂鳃形态结构、细胞凋亡及相关基因表达的影响[D]. 上海:上海海洋大学,2023.
- [31]王嘉伟. 大菱鲆低氧耐受能力及生理指标变化研究[D]. 上海:上海海洋大学,2022.
- [32]JEAN-MICHEL W, KRAMER D L. Effects of hypoxia and surface access on growth, mortality, and behavior of juvenile guppies, *Poecilia reticulata* [J]. *Canadian Journal of Fisheries and Aquatic Sciences*, 1983, 40(7):836-844.
- [33]徐建瑜. 基于计算机视觉的急性应激条件下尼罗罗非鱼的行为研究[D]. 杭州:浙江大学,2005.
- [34]郭志文. 深秋到来华中地区昼夜温差大, 泛塘事件频发引发的几点思考[J]. *当代水产*, 2018, 43(11):96-97.

Anoxic risk assessment method for cultured fish based on Prune-YOLOv5s

CHEN Tingjin¹, HUANG Yaobo¹, CHEN Xuanxin², ZHOUJijun¹, LIU Ying¹

(1 College of Physics and Optoelectronic Engineering, Shenzhen University, Shenzhen 518061, Guangdong, China;

2 Faculty of Education, Shenzhen University, Shenzhen 518061, Guangdong, China)

Abstract: To address the issue of the traditional fish hypoxia detection methods, which have low accuracy and require a lot of labor, a Prune-YOLOv5s-based hypoxia risk assessment method for farmed fish is proposed. This paper introduces a hypoxia risk assessment method for cultured fish based on the Prune-YOLOv5s algorithm. This method first collects data on aquatic surface respiration (ASR) performed by fish under hypoxic conditions to create a data set for fish hypoxia. The dataset is then utilized to train the YOLOv5s model. Then, the lightweight and improved YOLOv5s model was used to monitor the behavior of fish surface respiration during hypoxia in real-time. The introduction of the ASR coefficient allows for quantifying ASR instances in fish, which indicates hypoxia risk. The fish hypoxia assessment module is designed to evaluate the risk of hypoxia. The improved performance of the YOLOv5s model before and after modifications and the accuracy of the fish hypoxia assessment module are tested through the fish hypoxia experiment. The test results show that compared with the YOLOv5s model, the detection accuracy, model size, inference speed, and detection speed of the PruneYOLOv5s model have been significantly improved. Among them, the detection accuracy of the 65% PruneYOLOv5s model, which has the best comprehensive performance, has been increased by 0.6% compared with the original model. The size of the model is reduced to 45.3% of the original model. The inference speed is improved by 23.8%, and the detection speed is enhanced by 31.4%. The fish hypoxia assessment method achieves 97.4% accuracy in the test set of 39 test videos and performs well in the hypoxia cycle experiment. The research indicates that the Prune-YOLOv5s-based hypoxia risk assessment method for cultured fish can effectively detect hypoxic conditions and provide accurate risk alerts, showing high feasibility for practical application.

Key words: fish hypoxia; artificial intelligence; deep learning; YOLOv5s; ASR coefficient