

基于骨骼关键点的大鲵行为识别模型

杨欣垚 陈俊轶 田芳 孙楠清 谢模凯

(湖北民族大学智能科学与工程学院, 恩施 445600)

摘要: 针对大鲵夜间活动、生境偏好所导致野外行为数据难以实时精准获取的问题,提出一种基于改进 YOLO 11n-Pose 的关键点检测模型与 LSTM-BP 级联网络相结合的大鲵行为识别方法。首先构建包含 16 个关键点的大鲵骨架模型,为提升模型复杂环境下检测精度,提出多维度协同注意力模块(Multi-dimensional collaborative attention, MDCA),通过方向感知、通道增强和空间聚焦 3 个并行分支协同增强特征表示,同时引入 Wise-IoU 损失函数优化边界框回归质量,以及采用基于 L1 范数的通道剪枝技术压缩模型体积。在此基础上,提取关键点坐标、关节角度、相对距离和关键点数量等 42 维特征,形成行为识别的输入数据集,采用 LSTM-BP 神经网络实现大鲵行为分类,试验结果表明,改进的 YOLO 11n-LWM-Pose 模型召回率达 93.69%、精确率达 96.38%、mAP50 达 95.78%,帧率达 88.90 f/s,模型内存占用量仅为 6.35 MB。LSTM-BP 神经网络识别精确率达 96.3%,计算时间仅为 3.0 ms。该方法满足野外环境下大鲵行为的实时监测需求,为野生大鲵保护与行为学研究提供有效的技术支撑。

关键词: 中国大鲵;姿态估计;骨骼关键点;YOLO 11;行为识别

中图分类号: TP183; TP391.41 文献标识码: A 文章编号: 1000-1298(2026)14-0080-11 OSID: 

Skeletal Keypoint-based Behavioral Recognition Model for Chinese Giant Salamanders

Yang Xinyao Chen Junyi Tian Fang Sun Nanqing Xie Mokai

(College of Intelligent Systems Science and Engineering, Hubei Minzu University, Enshi 445600, China)

Abstract: Aiming to address the challenge of obtaining real-time, accurate behavioral data in the wild due to the Chinese giant salamander's nocturnal activity and habitat preferences, a behavioral recognition method that combined an improved YOLO 11n-Pose keypoint detection model with an LSTM-BP neural network was proposed. Firstly, a Chinese giant salamander skeleton model comprising 16 keypoints was constructed. To enhance the model's detection accuracy in complex environments, a multi-dimensional collaborative attention (MDCA) module was proposed, which collaboratively enhanced feature representations through three parallel branches: direction-aware, channel-enhanced, and spatially focused. Concurrently, a Wise-IoU loss function was introduced to optimize bounding box regression quality, and a channel pruning technique based on the L1 norm was adopted to reduce the model's size. Based on this, 42-dimensional features, including keypoint coordinates, joint angles, relative distances, and the number of keypoints were extracted to form the input dataset for behavior recognition. An LSTM-BP neural network was employed to classify giant salamander behaviors. Experimental results showed that the improved YOLO 11n-LWM-Pose model achieved a recall of 93.69%, a precision of 96.38%, an mAP50 of 95.78%, a frame rate of 88.90 f/s, and a memory footprint of only 6.35 MB. The LSTM-BP neural network achieved a recognition accuracy of 96.3% with a computation time of only 3.0 ms. This method met the requirements for real-time monitoring of Chinese giant salamander behavior in the wild, providing effective technical support for the conservation and behavioral research of wild Chinese giant salamanders.

Key words: Chinese giant salamander; pose estimation; skeletal landmarks; YOLO 11; behavior recognition

收稿日期: 2026-03-23 修回日期: 2026-03-30

基金项目: 中国高校产学研创新基金项目(2024WA064)、湖北省自然科学基金计划青年项目(2020CFB337)和湖北民族大学研究生创新项目(MYK2025023)

作者简介: 杨欣垚(2001—),男,硕士生,主要从事控制理论及图像处理技术研究,E-mail: xyy0138@163.com

通信作者: 陈俊轶(1992—),女,讲师,博士,主要从事加工检测及图像识别研究,E-mail: chenjunyi1224@163.com

0 引言

大鲵(*Andrias davidianus*)系中国二级重点保护野生动物^[1],其生存状况被视为区域生态系统完整性与健康度的重要生物指示剂。高效精准的监测技术是推进大鲵种群保护与恢复工作的先决条件^[2]。

随着计算机视觉与人工智能技术的不断发展,深度学习技术在动物行为识别等领域取得巨大进展^[3-7]。在畜禽与野生动物的行为识别与姿态估计中^[8-14],深度学习方法通过提取时空特征实现了高精度自动分析,生猪饮食行为识别准确率达 99.4%,肉鸡休息行为分类精度达 96.23%,野生动物 4 种行为识别精度达 96.8%。研究涵盖全卷积神经网络姿态估计、改进 OpenPose 骨骼关键点分类、YOLOX 攻击行为量化、DeepLabCut 多特征分类以及循环神经网络与自注意力机制相结合的时空建模等。

上述研究表明,深度学习在目标识别领域已取得显著成效,在动物行为识别方面已成为主流方法。其准确率通常高于传统机器学习算法,甚至优于人工判断水平。尤其在基于骨骼关键点的识别技术通过分析动物姿态序列,在保持数据紧凑性的同时,保留了丰富的互补特征信息,展现出显著技术优势^[15]。然而大鲵作为典型的夜行性水生动物,具有显著的夜行性与特定的微栖境偏好,如主河道沿岸及细小支流,导致在昏暗、复杂的光线环境下,传统调查方法存在监测盲区大、数据滞后与识别准确性低等诸多局限。这一现状严重制约了对其种群动态与行为生态的量化、实时化解析。

前期研究发现,尽管现有深度学习模型在其他场景下表现优异,但直接应用于大鲵检测时,受水下光折射和夜间低照度以及大鲵特殊体型等因素影响,识别性能明显下降。为此,本研究提出一种基于骨骼关键点的大鲵行为识别方法。该方法旨在为野外环境下大鲵行为全天候、无人化监测提供有效的技术支撑,以推动大鲵保护与行为生态学研究深入发展。

1 设备及数据集构建

1.1 图像采集

图像采集工作于 2024 年 9 月—2025 年 12 月在湖北咸丰忠建河大鲵国家级自然保护区内进行,设备安装以及数据采集示意图如图 1 所示。本试验采集大鲵行为数据包括大鲵休息、游动、探头呼吸 3 类。将采集的图像进行数据清洗、去除模糊和相似度过高图像,优先保留行为特征显著

且涵盖不同个体、不同光照条件的代表性图像,确保数据质量和代表性。并对图像进行随机裁剪、缩放、镜像等数据增强处理,以增加图像多样性,提升模型泛化能力。




图 1 图像采集装置示意图

Fig. 1 Schematic of image acquisition device

1.2 数据集构建

1.2.1 大鲵骨骼关键点构建

大鲵骨骼关键点的设计遵循实践与理论相结合的原则。首先,通过查阅大鲵骨架相关文献资料,并结合公开的姿态数据集 MPII 人体姿态数据集^[16]、AP-10K 动物姿态数据集^[17]与 Animal Kingdom 动物数据集^[18]标注方法,初步确定关键点设置。依托湖北咸丰忠建河大鲵国家级自然保护区大鲵行为监测研究项目,在保护区内开展大鲵行为分析试验,充分征询保护区从事大鲵养育与救助的技术人员和人工养殖基地技术人员的指导意见,确保关键点贴合大鲵的实际生理结构与行为特征。同时,将关键点设计思路在省林业厅巡检时进行专题汇报,相关技术负责人表示该方法可应用,进一步确认关键点划分的科学性与合理性。最终确定了涵盖大鲵运动与静止全过程的 16 个骨骼关键点来全面捕捉大鲵的姿态特征,如图 2 中的骨架设计所示。

1.2.2 数据集划分与标注

完成骨架设计后,使用 X-Any Labeling 标注软件对数据集图像中大鲵进行关键点的精确标注,如图 2 所示。用矩形框对大鲵进行标注,标注标签为“Chinese giant salamander”,16 个关键点按照“R-eye”“L-eye”“Head”“Neck”“Spine”“Spine”“Ridge”“tail-tip”“R-F-shoulder”“R-F-flipper”“L-F-shoulder”“L-F-flipper”“R-P-shoulder”“R-P-flipper”“L-P-shoulder”“L-P-flipper”的顺序标注(即:右眼、左眼、头部、颈部、脊椎、脊椎、尾根、尾尖、左前肩、右前肩、左后肩、右后肩、左前掌、右前掌、左后掌、右后掌。),标注后得到包含大鲵目标标注框宽度、高度信息以及按关键点顺序排列的关键点坐标和可见度信息。关键点可见度信息以数值编码,0 表示关键点不可见,1 表示关键点被遮挡,2 表示关键点可见且无遮挡。以比例




图 2 数据集构建流程

Fig. 2 Data set construction process

7:2:1将数据集划分为训练集、测试集、验证集,数据集构建流程如图 2 所示。

2 大鲵关键点检测模型

2.1 大鲵关键点提取方法

在大鲵姿态估计中,关键点提取是实现精准行为识别的核心技术。通过提取大鲵关键点,可获取与行为密切相关的关节位置与姿态信息,从而有效提升行为识别的准确性。本研究监测的大鲵目标数量较少且分布相对分散,选用 YOLO 11n - Pose 方法进行 2D 姿态提取。该方法为单阶段姿态估计框架,兼顾检测精度与推理效率,能够更好地适应大鲵细长体型与复杂水下光照环境,为后续关键点特征构造与行为识别提供高质量坐标信息。

2.2 改进的 YOLO 11n - Pose 模型

YOLO 11n - Pose^[19] 具备预测关键点位置的能力。针对大鲵生存环境,从 3 个方面对模型进行改进:①在颈部每个 PANet 融合节点之后插入所设计的多维度协同注意力模块 (Multi-dimensional collaborative attention, MDCA)。②引入 Wise - IoU

(WIoU) 损失函数替换原 CIoU 损失。③采用基于 L1 范数的通道剪枝技术对模型进行轻量化。改进的模型为 YOLO 11n - LWM - Pose, 结构如图 3 所示。

2.2.1 MDCA 模块

针对大鲵细长体型及姿态多变的特点,设计一种多维度协同注意力模块。该模块通过方向感知、通道增强和空间聚焦 3 个并行分支,分别捕捉主轴结构连续性、校准特征重要性、突出局部关键区域,并利用可学习参数自适应融合各分支输出,生成判别力更强的特征表示。MDCA 轻量高效,显著提升了大鲵关键点检测的精度与鲁棒性。结构如图 4 所示。

设输入特征图为 $X \in \mathbf{R}^{C \times H \times W}$, MDCA 输出增强后的特征图 $Y \in \mathbf{R}^{C \times H \times W}$ 。计算流程为:方向感知分支生成方向注意力图, $A_{dir} \in \mathbf{R}^{C \times H \times W}$, 强化大鲵身体主轴(头尾方向)的结构信息;通道增强分支生成通道权重 $A_{ch} \in \mathbf{R}^{C \times 1 \times 1}$, 自适应校准各通道的重要性。空间聚焦分支生成空间注意力图 $A_{sp} \in \mathbf{R}^{1 \times H \times W}$, 突出局部关键区域(如四肢、头部);最后将 3 个分支的




图 3 YOLO 11n - LWM - Pose 网络结构

Fig. 3 YOLO 11n - LWM - Pose network architecture




图 4 MDCA 网络结构图

Fig. 4 MDCA network architecture diagram

输出融合为最终注意力图 M , 并与输入相乘得到输出 $Y = M \odot X$ 。

在方向感知分支捕捉沿垂直和水平方向的长程依赖, 强化大鲵身体结构的连续性。首先, 对输入 X 分别进行垂直方向和水平方向的全局平均池化, 即

$$z_h(h) = \frac{1}{W} \sum_{i=1}^W X(:, h, i) \in \mathbf{R}^{C \times H} \quad (1)$$

$$z_w(w) = \frac{1}{H} \sum_{j=1}^H X(:, j, w) \in \mathbf{R}^{C \times W} \quad (2)$$

式中 $\delta(\cdot)$ ——ReLU 函数

再分别通过 1×1 卷积和 Sigmoid 函数生成方向权重, 即

$$g_h = \sigma(\text{Conv}_{1 \times 1}(f_h)) \in \mathbf{R}^{C \times H \times 1} \quad (3)$$

$$g_w = \sigma(\text{Conv}_{1 \times 1}(f_w)) \in \mathbf{R}^{C \times 1 \times W} \quad (4)$$

最后, 通过广播相加融合 2 个方向的权重, 得到方向注意力图, 即

$$A_{dir}(c, i, j) = g_h(c, i) + g_w(c, j) \in \mathbf{R}^{C \times H \times W} \quad (5)$$

在通道增强分支利用全局池化提取通道描述符, 并通过共享多层感知机 (Multi-layer perceptron, MLP) 生成通道权重。对输入 X 分别进行全局平均池化和全局最大池化

$$z_{avg} = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W X(:, i, j) \in \mathbf{R}^{C \times 1 \times 1} \quad (6)$$

$$z_{max} = \max_{i=1}^H \max_{j=1}^W X(:, i, j) \in \mathbf{R}^{C \times 1 \times 1} \quad (7)$$

将两者输入共享的多 MLP, 即

$$s_{avg} = W_2 \delta(W_1 z_{avg}) \in \mathbf{R}^{C \times 1 \times 1} \quad (8)$$

$$s_{max} = W_2 \delta(W_1 z_{max}) \in \mathbf{R}^{C \times 1 \times 1} \quad (9)$$

将两者相加后经 Sigmoid 激活, 得到通道权重, 即

$$A_{ch} = \sigma(s_{avg} + s_{max}) \in \mathbf{R}^{C \times 1 \times 1} \quad (10)$$

在空间聚焦分支, 通过 7×7 卷积和 Sigmoid 生成空间注意力, 即

$$A_{sp} = \sigma(\text{Conv}_{7 \times 7}([m_{avg}; m_{max}])) \quad (11)$$

2.2.2 WIoU 损失函数

由于保护区户外复杂环境下获取的大鲵图像背景复杂, 大鲵主体与背景极易类失衡, 在模型训练过程中高质量锚框远少于误差大的锚框, 质量差的样本会产生较大梯度从而影响模型优化方向, 结构如图 5 所示。




图 5 WIoU 结构

Fig. 5 WIoU architecture

为解决以上问题, 使用 WIoU 替换原损失函数, WIoU^[20] 提出动态非单调聚焦机制, 通过评估锚框质量, 结合动态调节的梯度增益策略。在强化高质量锚框学习效果的同时抑制有害梯度对低质量样本的过度优化, 提升模型鲁棒性。WIoUv1 构建基于注意力机制的边界框损失, 设预测框中心坐标 (x, y) , 对应真实框中心坐标投影 (x_0, y_0) , 两框最小外接矩形宽、高分别为 w_i, h_i , IoU 为交并比, w_i 和 h_i 若参与梯度计算, 会通过分母项 $(w_i^2 + h_i^2)^*$ 引发 2 个问题: ① 目标框尺寸较小时, 分母趋近于零, 导致梯度幅值急剧增大, 可能破坏模型参数稳定性。② W_i 和 H_i 本质上是目标框的几何属性。若允许其参与反向传播, 会产生与检测任务无关的干扰梯度, 导致扭曲参数更新方向。WIoUv1 计算公式为

$$L_{WIoUv1} = R_{WIoU} L_{IoU} \quad (12)$$

$$\text{其中 } R_{WIoU} = \exp\left(\frac{(x - x_0)^2 + (y - y_0)^2}{(w_i^2 + h_i^2)^*}\right) \quad (13)$$

$$L_{IoU} = 1 - IoU \quad (14)$$

式中 L_{wIoUv1} ——加权 IoU 损失函数第一版
 R_{wIoU} ——基于中心点距离加权因子
 L_{IoU} ——标准的 IoU 损失值

* 表示将 w_i 与 h_i 从计算图中分离,阻止参与梯度计算,使其变为不带梯度的常量,在前向计算时作为固定值参与计算,不参与反向传播,防止 R_{wIoU} 产生阻碍收敛的梯度。

2.2.3 基于 L1 范数通道剪枝

在大鲈行为识别任务中,实时监控和高效行为识别尤为重要。

针对上述问题,引入基于 L1 范数的通道剪枝技

术^[21],以有效减轻计算负担并提高推理速度,结构如图 6(其中 h_i 为高度, w_i 为宽度, x_i 为特征图, n_i 为输入通道)所示,针对输入通道为 n_i ,宽度和高度分别为 w_i 和 h_i 的特征图,使用 $n_i + 1$ 个过滤器进行卷积。每个过滤器的权重 L1 范数被用来衡量其在卷积操作中的贡献程度,通过对 L1 范数进行排序,识别并删除权重较小的卷积核及其对应的特征图。完成剪枝后,模型将进入再训练阶段,以恢复在关键点检测任务中的精度。通过优化模型能够有效减少计算负担,确保在资源受限的设备上高效运行,支持实时高效的大鲈行为监测与管理。




图 6 基于 L1 范数的剪枝过程
Fig. 6 Pruning process based on L1 norm

2.3 大鲈关键特征构造方法

在大鲈行为识别任务中,不同行为状态下的关节角度存在显著差异,在大鲈游动时,身体会保持笔直状态,大鲈头部和尾尖距离最远,四肢与躯干之间以及尾尖会在 $0^{\circ} \sim 90^{\circ}$ 之间上下或左右摆动。大鲈需要每 30 min 左右浮出水面获取空气,在大鲈换气时,头部与背部脊柱之间呈 $120^{\circ} \sim 180^{\circ}$ 夹角。在大鲈静止时,时常没有固定姿态,若大鲈身体关键点角度保持 10 s 以上没有变化便判定大鲈处于静止状态。构造的关键特征体系以关节角度为核心,同时辅以关键点相对位置及关键点识别个数信息,不同行为姿态示意图如图 7 所示。通过向量夹角计算各

关节角度,具体角度计算式为

$$\theta = \arccos \frac{(x_1 - x_2)(x_3 - x_2) + (y_2 - y_1)(y_3 - y_2)}{\sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \sqrt{(x_3 - x_2)^2 + (y_3 - y_2)^2}} \tag{15}$$

式中 (x_1, y_1) 、 (x_2, y_2) 、 (x_3, y_3) ——3 个关键点坐标

大鲈常见姿态关键点信息如表 1 所示。为降低因关键点漏检或坐标定位不准带来的误差,设定如下判定规则,若构成某一角度的 3 个关键点中,至少有 2 个点的检测置信度低于阈值 0.5,则判定该角度数据不可靠,并将其赋值为 -1,以标记为无效值。




图 7 不同行为姿态示意图

Fig. 7 Diagrams of different postures and gestures

表 1 大鲵常见姿态关键信息

Tab.1 Key information on common postures of Chinese giant salamander

特征类型	特征名称	静止	游动	探头呼吸	权重
关节角度/(°)	头颈角	150	170	150	0.15
	左前肢角	120	45	110	0.10
	右前肢角	120	45	110	0.10
	左后肢角	110	45	100	0.10
	右后肢角	110	45	100	0.10
	尾部弯曲角	160	170	160	0.15
归一化值	头部-左前肢距离	0.30	0.25	0.40	0.08
	头部-右前肢距离	0.30	0.25	0.40	0.08
	头部-尾尖距离	0.85	1.00	0.80	0.09
关键点数量	有效关键点个数	13	13	13	0.05

为更完整地捕捉关节角度未能涵盖的姿态信息,选取 3 组关键点,“头部-右前蹠”“头部-左前蹠”以及“头部-颈部”,分别计算其欧氏距离。

2.4 基于 LSTM – BP 级联网络的分类方法

基于大鲵关键点检测与关节角度计算所获得的数据,利用关键点坐标、关节角度、关键点间相对位置及关键点识别数量 4 类特征,构建了包含 16 个关键点横纵坐标、6 个关节角度、3 对关键点间欧氏距离及 1 个关键点检出数量的 42 维特征参数。考虑

到大鲵行为具有显著的时序依赖性,单帧静态特征难以完整刻画行为的动态演变过程,因此引入时序模型 LSTM (Long short-term memory) 对连续视频帧的特征序列进行时序建模,再输入至 BP 神经网络 (Back propagation neural network) 进行最终分类^[22],两者形成级联网络的关系。

首先将监控设备采集的图像输入模型,利用改进的 YOLO 11n – LWM – Pose 模型进行姿态估计,提取大鲵的关键点坐标,为特征构造提供核心数据,基于关键点坐标构建关键特征向量,形成行为识别的输入数据集,再将连续 F 帧视频图像中提取的空间特征按时间顺序拼接,构造维度为 $F \times 42$ 的特征序列矩阵作为网络输入。随后,将该序列输入至 LSTM 层。LSTM 内部的门控机制能够有效抑制瞬时噪声的干扰并记忆长距离的历史状态,从而深度捕捉大鲵行为的时间上下文信息。经过时序处理后,LSTM 层输出最后一个时间步的隐藏状态向量 (Hidden state),该向量高度浓缩了设定时间窗口内的动态行为特征。最后,将该高维时序特征送入 BP 神经网络中最终实现大鲵行为的高精度分类。分类整体流程如图 8 所示。




图 8 基于 LSTM – BP 级联网络行为分类流程

Fig. 8 Flowchart of behavior classification based on a cascaded LSTM – BP network

3 结果与分析

3.1 试验环境及评价指标

基于 Autodl 算力平台,CPU 为 Intel (R) Core (TM) i9 – 13900K,GPU 为 NVIDIA GeForce RTX 4090,运行环境采用 PyTorch 2.0.1 与 Cuda 12.1。模型训练过程中,训练轮次为 1 000,初始学习率设置为 0.001,动量为 0.937。利用精确率 (Precision, P)、召回率 (Recall, R)、F1 分数、浮点运算量、mAP50、mAP50:95、模型内存占用量以及帧率对模型检测性能进行评估。

关键点精度评价采用目标关键点相似度 (Object keypoint similarity, OKS),OKS 用于衡量预测点坐标与真实点坐标之间的相似度,类似于目标

检测中的交并比 (IoU)。

3.2 不同注意力机制性能测试

为全面验证提出的 MDCA 模块的性能,与主流注意力模块 CA (Coordinate attention)^[23]、CBAM (Convolutional block attention module)^[24]、BAM (Bottleneck attention module)^[25]、DANet (Dual attention network)^[26]、GSoP (Global second-order pooling)^[27] 进行对比试验,结果如表 2 所示。

YOLO 11n – Pose + MDCA 的召回率、精确率、和帧率比 YOLO 11n – Pose + CA 分别提升 7.24、9.03 个百分点和 24.15 f/s,比 CBAM 分别提升 3.45、5.50 个百分点和 26.03 f/s,比 BAM 分别提升 6.02、10.44 个百分点和 23.02 f/s,比 DANet 分别提升 10.00、9.80 个百分点和 20.53 f/s,比 GSoP 分别提

表 2 不同注意力模块性能测试结果

Tab.2 Results of tests between different attention modules

模型	召回率/%	精确率/%	浮点运算量	帧率/(f·s ⁻¹)	模型内存占用量/MB
YOLO 11n-Pose+CA	85.14	86.73	2.835×10 ¹⁰	62.23	42.32
YOLO 11n-Pose+CBAM	88.93	90.26	3.560×10 ¹⁰	60.35	35.36
YOLO 11n-Pose+BAM	86.36	85.32	2.361×10 ¹⁰	63.36	78.36
YOLO 11n-Pose+DANet	82.38	85.96	3.537×10 ¹⁰	65.85	43.69
YOLO 11n-Pose+GSoP	82.21	83.88	4.736×10 ¹⁰	75.83	48.36
YOLO 11n-Pose+MDCA	92.38	95.76	7.800×10 ⁹	86.38	35.12

升 10.17、11.88 个百分点和 10.55 f/s。为直观验证 MDCA 模块对关键点检测性能的提升作用,采用基于梯度加权类激活映射方法 (Axiom-based gradcam, XGradCAM)对大鲵关键区域进行热力图可视化分析,如图 9 所示。




图 9 热力图可视化结果

Fig.9 Visualization results of heatmaps

3.3 轻量化试验结果

为评估改进的模型轻量化效果,本研究采用 L1 范数、Slim (network slimming) 和 Lamp (layer-adaptive magnitude-based pruning)剪枝进行试验。L1 范数剪枝通过计算过滤器权重的 L1 范数,裁剪掉权重较小的卷积核及其对应的特征图。而 Slim 剪枝基于批归一化 (BN) 层中的缩放因子来判断通道的重要性。Lamp 剪枝通过计算每个连

接的 Lamp 分数,裁剪掉得分较低的连接。轻量化试验结果如表 3 所示。

表 3 轻量化试验结果

Tab.3 Results of lightweight experiment

模型	召回率/%	精确率/%	浮点运算量 FLOPs/G	模型内存 占用量/MB
MDCA	92.38	95.76	7.80	35.12
MDCA+Slim	91.36	91.30	7.20	16.32
MDCA+Lamp	90.32	90.16	7.25	15.36
MDCA+L1	92.39	95.80	7.50	7.28

3.4 消融试验结果

为验证提出的 MDCA 模块与其他 2 种改进方法的可靠性,在本数据集上进行消融试验,结果如表 4 所示,改进的网络 YOLO 11n-LWM-Pose 相较于仅加入 WIoU 损失函数的模型,召回率、精确率、mAP50、mAP50:95 和帧率分别高 7.37、8.82、9.48、5.06 个百分点和 35.67 f/s,模型内存占用量减少 19.21 MB。相较于仅加入 L1 剪枝的模型,分别高 4.73、6.85、5.87、4.28 个百分点和 23.54 f/s,模型内存占用量减少 0.78 MB。相较于仅加入 MDCA 注意力模块的模型,分别高 1.31、0.62、0.06、3.24 个百分点和 2.52 f/s,模型内存占用量减少 28.77 MB。相较于同时加入 MDCA 和 L1 的模型,分别高 1.30、

表 4 消融试验结果

Tab.4 Ablation experiment results

MDCA	L1	WIoU	召回率/%	精确率/%	mAP50/%	mAP50:95/%	帧率/(f·s ⁻¹)	模型内存占用量/MB
×	×	×	87.93	87.65	88.21	50.61	43.58	25.21
×	×	✓	86.32	87.56	86.30	54.53	53.23	25.56
×	✓	×	88.96	89.53	89.91	55.31	65.36	7.13
✓	×	×	92.38	95.76	95.72	56.35	86.38	35.12
✓	✓	×	92.39	95.80	95.69	57.86	88.69	7.28
✓	✓	✓	93.69	96.38	95.78	59.59	88.90	6.35

注:✓表示采用该方法,×表示未采用该方法。

0.58、0.09、1.73 个百分点和 0.21 f/s,模型内存占用量减少 0.93 MB。应用 3 种改进方法的模型相较于基础网络 YOLO 11n-Pose,分别高 5.76、

8.73、7.57、8.98 个百分点和 45.32 f/s,模型内存占用量减少 18.86 MB,达到 93.69%、96.38%、95.78%、59.59% 和 88.90 f/s,模型内

存占用量仅为 6.35 MB。

3.5 不同环境模型检测结果

为验证改进模型在复杂环境条件下的关键点检测性能,在正常光照、曝光及弱光照 3 种条件下,对比分析 YOLO 11n - Pose 模型与改进的 YOLO 11n - LWM - Pose 模型的检测效果。试验结果如图 10(其中黄色圈表示关键点预测偏移,红色圈表示关键点漏检,黑色圈表示误检)所示。




图 10 不同环境下检测效果

Fig. 10 Detection results in different environments

YOLO 11n - Pose 模型在不同光照条件下均存在显著缺陷,正常光照下,模型对水波纹等背景纹理敏感,在肢体交叉或颜色相近区域出现大量关键点漏检,尤其水体波纹处几乎无法检出,反映出模型缺乏细长体型目标的结构化感知能力,难以抑制背景噪声。曝光过度时,高光反射引入强噪声,模型易将光斑误判为目标,导致漏检与误检并存。弱光照下,图像信噪比降低,模型难以提取低对比度区域的关键点,对小体型大鲵几乎无法检出,并伴有误检和低质量锚框,缺乏全局与局部信息的联合建模。

针对上述问题,改进的 YOLO 11n - LWM - Pose 模型实现了性能提升。首先,多维度协同注意力模块通过方向感知、通道增强和空间聚焦 3 个并行分支,分别强化身体主轴的结构连续性、自适应校准关

键特征通道的重要性、精准聚焦四肢与头部等局部区域,从而在正常光照下有效抑制背景干扰,提高小区域关键点检出率。在曝光条件下,空间聚焦分支能够从高光区域恢复局部细节,避免关键点丢失。在弱光照环境下,方向感知与通道增强分支协同作用,增强低对比度边缘的特征表达,稳定捕获小目标关键点。其次,引入 Wise - IoU 损失函数替代 CIoU,利用动态非单调聚焦机制根据锚框质量自适应调整梯度增益,在复杂光照下抑制低质量样本的有害梯度,优化边界框回归质量,减少误检并提升定位精度;WIoU 通过分离几何因子梯度计算,避免目标框尺寸变化对参数更新的干扰,增强光照鲁棒性。最后,基于 L1 范数的通道剪枝移除权重较小的冗余卷积核,在保持精度的前提下将模型内存占用量从 35.12 MB 压缩至 6.35 MB,推理帧率达到 88.90 f/s,实现轻量化优化。

3.6 不同模型检测结果

为验证构建的 YOLO 11n - LWM - Pose 模型性能,与其他主流识别模型 SimCC^[28-29]、HRNet^[30]、HigherHRNet^[31]、YOLO v8n - Pose^[32-34] 与 YOLO v10n - Pose^[35-36] 关键点检测算法进行同一数据集试验,结果如表 5 所示。由表 5 可知,本研究提出的 YOLO 11n - LWM - Pose 模型在各指标上均显著优于主流关键点检测模型。相较于 SimCC 模型,召回率、精确率、mAP50、mAP50:95 和帧率分别高 6.13、12.78、10.66、11.23 个百分点和 41.77 f/s,模型内存占用量减少 49.28 MB。相较于 HRNet 模型,分别高 7.34、13.69、9.61、11.90 个百分点和 36.74 f/s,模型内存占用量减少 35.81 MB。相较于 HigherHRNet 模型,分别高 8.56、9.51、7.22、13.01 个百分点和 39.22 f/s,模型内存占用量减少 40.03 MB。相较于 YOLO v8n - Pose 模型,分别高 5.04、9.93、6.15、4.38 个百分点和 19.48 f/s,模型内存占用量减少 19.34 MB。相较于 YOLO v10n - Pose 模型,分别高 2.43、3.70、4.10、3.23 个百分点和 23.62 f/s,模型内存占用量减少 11.93 MB。

YOLO 11n - LWM - Pose 的召回率、精确率、

表 5 不同模型性能测试结果

Tab. 5 Performance test results for different models

模型	召回率/%	精确率/%	mAP50/%	mAP50:95/%	帧率/(f·s ⁻¹)	模型内存占用量/MB
SimCC	87.56	83.60	85.12	48.36	47.13	55.63
HRNet	86.35	82.69	86.17	47.69	52.16	42.16
HigherHRNet	85.13	86.87	88.56	46.58	49.68	46.38
YOLO v8n - Pose	88.65	86.45	89.63	55.21	69.42	25.69
YOLO v10n - Pose	91.26	92.68	91.68	56.36	65.28	18.28
YOLO 11n - LWM - Pose	93.69	96.38	95.78	59.59	88.90	6.35

mAP50、mAP50: 95 和 帧率 分别 达到 93.69%、96.38%、95.78%、59.59% 和 88.90 f/s,模型内存占用量仅为 6.35 MB,充分验证改进方法在大鲵关键点检测任务中的鲁棒性和稳健性。

3.7 行为识别模型性能测试结果

利用改进的 YOLO 11n-LWM-Pose 模型提取大鲵 16 个关键点坐标,并基于空间分布关系计算关节角度、相对距离及关键点个数,通过该方法,构建了包含约 4 000 条样本的特征参数数据集,每条样本由 42 维特征组成,包括 32 个关键点坐标、6 个关节角度、3 组相对距离和有效关键点计数,所有数据以 CSV 格式保存。为捕捉行为的时序动态特征,将连续 F 帧的 42 维特征拼接为 $F \times 42$ 的特征序列矩阵,输入 LSTM-BP 级联网络。其中,LSTM 层捕捉时序上下文信息,将时间窗口内的动态特征浓缩为隐藏状态向量,BP 神经网络完成分类决策。

为全面评估 LSTM-BP 级联网络性能,采用 k 折交叉验证方法,将数据集划分为 5 个子集,每次选择其中 1 个子集作为验证集,其余 4 个子集作为训练集,重复 5 次后取平均值作为最终评价指标。在相同数据集与特征输入条件下,测试了 K 最近邻 (K-nearest neighbors, KNN)^[37]、决策树 (Decision tree, DT)^[38] 和 极限梯度提升 (eXtreme gradient boosting, XGBoost)^[39] 等主流分类模型,测试结果如表 6 所示。

表 6 行为识别模型性能测试结果

Tab.6 Performance test results for behavior recognition models

模型	精确率/%	召回率/%	F1 分数/%	计算时间/ms
KNN	89.2	87.6	88.4	3.8
DT	90.3	88.9	89.6	2.9
XGBoost	93.5	92.1	92.8	6.2
LSTM-BP	96.3	95.9	96.1	3.0

由表 6 可知,LSTM-BP 级联网络在大鲵休息、游动和探头呼吸 3 种行为类别的识别任务中表现优于 K 近邻算法、决策树和 XGBoost 模型。其中,LSTM-BP 级联网络的 F1 分数相较于 KNN 和 DT,分别提高 7.70、6.50 个百分点。XGBoost 作为集成学习模型虽也取得了较好的分类效果,但计算时间较长,而 LSTM-BP 级联网络在识别精确率、F1 分数分别达到 96.3%、96.1% 的同时,计算时间仅为 3.0 ms,显著低于 XGBoost。综合考虑分类精度与计算效率,LSTM-BP 级联网络在本研究任务中实现了更优的性能平衡,更适用于大鲵行为的实时识别需求。

4 结论

(1) 针对大鲵细长体型和户外复杂环境的特点,构建了包含 16 个关键点的骨架模型,并基于 YOLO 11n-Pose 进行改进,设计多维度协同注意力模块 MDCA,通过方向感知、通道增强和空间聚焦 3 个并行分支协同增强特征表示,引入 Wise-IoU 损失函数优化边界框回归质量,采用基于 L1 范数的通道剪枝技术压缩模型体积。改进的 YOLO 11n-LWM-Pose 模型召回率 93.69%、精确率 96.38%、mAP50 达 95.78%,帧率 88.90 f/s,模型内存占用量仅为 6.35 MB,为行为识别提供了高精度的关键点坐标信息。

(2) YOLO 11n-LWM-Pose 负责空间姿态提取,LSTM 负责时序动态建模,BP 神经网络负责分类决策,在 YOLO 11n-LWM-Pose 提取的关键点基础上,构建 42 维特征向量,将连续 F 帧特征拼接为 $F \times 42$ 特征序列输入 LSTM 层。LSTM 通过门控机制过滤环境干扰、捕捉行为时序信息,输出浓缩动态特征的隐藏状态向量。将该向量送入 BP 神经网络,实现大鲵行为的高精度分类。试验结果表明,LSTM-BP 级联网络识别精确率达 96.3%,计算时间为 3.0 ms。

参 考 文 献

[1] James E M W, Oscar V, Jasmine L, et al. Protect the last of the wild[J]. Nature, 2018, 563: 27-30.

[2] 曹剑寒,邓智勇,蒋万胜,等. 湖南张家界大鲵国家级自然保护区鱼类多样性研究[J/OL]. 水生生态学杂志,2025-10-16. <https://link.cnki.net/doi/10.15928/j.1674-3075.20250504001>.

[3] 王敏,李鹏琪,钟光谱,等. 湖北省国家重点保护野生动物名录初探[J]. 湖北林业科技,2021,50(3):43-52.

Wang Min, Li Pengqi, Zhong Guangpu, et al. Preliminary exploration of Chinese key protected wild animals list in Hubei Province[J]. Hubei Forestry Science and Technology, 2021, 50(3):43-52. (in Chinese)

[4] 田芳,杨欣垚,孙楠清,等. 基于改进 YOLO 11n-EWL 的大鲵检测模型研究[J]. 农业机械学报,2025,56(10):110-118.

Tian Fang, Yang Xinyao, Sun Nanqing, et al. Giant salamander detection model based on improved YOLO 11n-EWL[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(10):110-118. (in Chinese)

[5] 张铮,鲁祥,胡庆松. 基于图像增强与 GC-YOLO v5s 的水下环境河蟹识别轻量化模型研究[J]. 农业机械学报,2024, 55(11):124-131,374.

Zhang Zheng, Lu Xiang, Hu Qingsong. Lightweight model for river crab detection based on image enhancement and improved YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11):124-131,374. (in Chinese)

- [6] Sun N, Lu D, Yang X, et al. Study on the localization technology for giant salamanders using passive UHF RFID and incomplete D – Tr measurement data[J]. *Sensors*, 2025, 26(1): 106.
- [7] 李道亮,李万超,杜壮壮. 基于音视频信息融合与 Self – Attention – DSC – CNN6 网络的鲈鱼摄食强度分类方法[J]. *农业机械学报* 2025,56(1):16 – 24.
Li Daoliang, Li Wanchao, Du Zhuangzhuang. Classification method of feeding intensity of sea bass based on Self – Attention – DSC – CNN6 and multi-modal fusion[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2025,56(1):16 – 24. (in Chinese)
- [8] Psota E T, Mittek M, Perez L C, et al. Multi-pig part detection and association with a fully-convolutional network[J]. *Sensors*, 2019, 19(4): 852.
- [9] Alameer A, Kyriazakis I, Dalton H A, et al. Automatic recognition of feeding and foraging behaviour in pigs using deep learning [J]. *Biosystems Engineering*, 2020, 197: 91 – 104.
- [10] 李光昌, 刘飞飞, 李嘉豪. 基于改进 OpenPose 算法的猪只行为识别方法[J]. *河南农业大学学报*, 2022, 56(3): 460 – 470.
Li Guangchang, Liu Feifei, Li Jiahao. Pig behavior recognition method based on improved OpenPose algorithm[J]. *Journal of Henan Agricultural University*, 2022, 56(3): 460 – 470. (in Chinese)
- [11] 李艳文, 李菊霞, 纳腾满, 等. 基于 YOLOX – NGS 的群养猪只攻击行为识别[J]. *农业工程学报*, 2023, 39(24): 177 – 184.
Li Yanwen, Li Juxia, Na Tengxiao, et al. Recognizing attack behavior of herd pigs using improved YOLOX[J]. *Transactions of the CSAE*, 2023, 39(24): 177 – 184. (in Chinese)
- [12] Fang C, Zhang T, Zheng H, et al. Pose estimation and behavior classification of broiler chickens based on deep neural networks[J]. *Computers and Electronics in Agriculture*, 2021, 180: 105863.
- [13] Feng L Q, Zhao Y Q, Sun Y C, et al. Action recognition using a spatial-temporal network for wild felines[J]. *Animals*, 2021, 11(2): 485.
- [14] Deng S C, Tang G Z, Mei L. Wild mammal behavior recognition based on gated transformer network[C] // 2022 International Conference on Cyber-Physical Social Intelligence (ICCSI). IEEE, 2022: 739 – 743.
- [15] Duan H D, Wang J Q, Chen K, et al. PYSKL: towards good practices for skeleton action recognition[C] // Proceedings of the 30th ACM International Conference on Multimedia. ACM, 2022: 7351 – 7354.
- [16] Zhang T, Li Q, Wen J, et al. Enhancement and optimisation of human pose estimation with multi-scale spatial attention and adversarial data augmentation[J]. *Information Fusion*, 2024, 111: 102522.
- [17] Yu H, Xu Y, Zhang J, et al. Ap – 10k: a benchmark for animal pose estimation in the wild[PP/OL]. V1. arXiv (2021 – 08 – 26)[2026 – 04 – 10]. <https://doi.org/10.48550/arXiv.2108.12617>.
- [18] Ng X L, Ong K E, Zheng Q, et al. Animal kingdom: a large and diverse dataset for animal behavior understanding[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 19023 – 19034.
- [19] Yuan C, Zhao Z, Huang X, et al. Phalaenopsis flower stem length measurement method based on keypoint detection[J]. *Measurement*, 2026, 271: 120865.
- [20] Dong X, Zhang L, Xu C, et al. Detection of pine wilt disease infected pine trees using YOLO v5 optimized by attention mechanisms and loss functions[J]. *Ecological Indicators*, 2024, 168: 112764.
- [21] 李凯,李文力,韩昌佩. 基于 L1 范数优化模型的遥感图像条纹去除方法[J]. *红外与毫米波学报*, 2021, 40(2): 272 – 283.
Li Kai, Li Wenli, Han Changpei. The method based on L1 norm optimization model for stripe noise removal of remote sensing image[J]. *Journal of Infrared and Millimeter Waves*, 2021, 40(2): 272 – 283. (in Chinese)
- [22] Ji H, Zhang X, Wang T, et al. Oil spill area prediction model of submarine pipeline based on BP neural network and convolutional neural network[J]. *Process Safety and Environmental Protection*, 2025, 199: 107264.
- [23] Zhang Z, Zhao Q, Li X, et al. CA – YOLO: cross attention empowered YOLO for biomimetic localization[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2026, 36(1): 175 – 189.
- [24] 李宏伟, 高际涛, 陈家升, 等. 基于改进 YOLO 13n 模型与边缘计算的芒果识别方法研究[J]. *农业机械学报*, 2026, 57(5): 159 – 166, 176.
Li Hongwei, Gao Jitao, Chen Jiasheng, et al. Mango recognition method using improved YOLO 13n model and edge computing [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2026, 57(5): 159 – 166, 176. (in Chinese)
- [25] Zia A, Mahum R, Ahmad N, et al. Eye diseases detection using deep learning with BAM attention module[J]. *Multimedia Tools and Applications*, 2024, 83(20): 59061 – 59084.
- [26] Ma J, Zhang H. HDR – DANet: single HDR image reconstruction via dual attention[J]. *Multimedia Systems*, 2025, 31(1): 37.
- [27] 赵韦婷, 刘紫旭, 何曼曼, 等. 基于多模态双线性池化机制的蘑菇类别识别模型[J]. *农业工程学报*, 2025, 41(20): 185 – 192.
Zhao Weiting, Liu Zixu, He Manman, et al. Mushroom category recognition model based on multimodal bilinear pooling mechanism[J]. *Transactions of the CSAE*, 2025, 41(20): 185 – 192. (in Chinese)
- [29] Wang Y, Yuan X, Wei B, et al. Performance evaluation of a state-of-the-art keypoint detection method for precision livestock farming[J]. *Computers and Electronics in Agriculture*, 2026, 240: 111230.
- [30] Liu M, Chen W, Cheng J, et al. Y – HRNet: research on multi-category cherry tomato instance segmentation model based on improved YOLOv7 and HRNet fusion[J]. *Computers and Electronics in Agriculture*, 2024, 227: 109531.

[31] Li Y, Jia S, Li Q. BalanceHRNet: an effective network for bottom-up human pose estimation[J]. Neural Networks, 2023, 161: 297 – 305.

[32] 袁红春,李春桥. 基于改进可变形卷积的 FDC – YOLO v8 水下生物目标检测方法研究[J]. 农业机械学报,2024, 55(11):140 – 146.

Yuan Hongchun, Li Chunqiao. Research on FDC – YOLO v8 underwater biological object detection method improved by deformable convolution[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 140 – 146. (in Chinese)

[33] 罗斌,李家超,周亚男,等. 基于改进 YOLO v8 的轻量化稻瘟病孢子检测方法[J]. 农业机械学报,2024,55(11):32 – 38.

Luo Bin, Li Jiachao, Zhou Ya'nan, et al. Lightweight rice blast spores detection method based on improved YOLO v8[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 32 – 38. (in Chinese)

[34] 杨断利,齐俊林,陈辉,等. 基于改进 YOLO v8n 模型的散养蛋鸡个体行为识别方法与差异分析[J]. 农业机械学报, 2024, 55(11): 112 – 123.

Yang Duanli, Qi Junlin, Chen Hui, et al. Individual behavioral identification and differential analysis of free-range laying hens based on improved YOLO v8n model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 112 – 123. (in Chinese)

[35] 徐浩哲,王元兴. 改进 YOLO v10n 的无人机航拍图像检测算法[J]. 计算机科学与应用, 2025, 15(1): 230 – 238.

Xu Haozhe, Wang Yuanxing. Algorithm for aerial image detection of unmanned aerial vehicles based on improved YOLO v10n [J]. Computer Science and Application, 2025, 15(1): 230 – 238. (in Chinese)

[36] Chen R, Zhou H, Xie H, et al. YOLO – CE: an underwater low-visibility environment target detection algorithm based on YOLO 11[J]. The Journal of Supercomputing, 2025, 81(5): 1 – 24.

[37] 徐洁,杨长茂,陈建平,等. 基于多流形的单样本人脸模糊分类算法[J]. 计算机工程与设计, 2025, 46(3): 719 – 725.

Xu Jie, Yang Changmao, Chen Jianping, et al. Multi-manifold based fuzzy classificational gorithm for single face image problem [J]. Computer Engineering and Design, 2025, 46(3): 719 – 725. (in Chinese)

[38] Lim-Apo F A, Oliveira F, Hamacher S. Decision tree enhancer (DTE): improving decision trees with optimization[J]. Knowledge-Based Systems, 2026, 339: 115597.

[39] Xu W, Zhu H, Zheng Y, et al. ELXGB: an efficient and privacy-preserving XGBoost for vertical federated learning[J]. IEEE Transactions on Services Computing, 2024, 17(3): 878 – 892.



(上接第 12 页)

[72] Huang S, Wang Y, Xia J. Which riverine water quality parameters can be predicted by meteorologically-driven deep learning? [J]. Science of the Total Environment, 2024, 946: 174357.

[73] Nunno F D, Race M, Granata F. A nonlinear autoregressive exogenous(NARX) model to predict nitrate concentration in rivers [J]. Environmental Science and Pollution Research, 2022, 29(27): 40623 – 40642.

[74] Chen S, Huang J, Wang P, et al. A coupled model to improve river water quality prediction towards addressing non-stationarity and data limitation[J]. Water Research: a Journal of the International Water Association, 2024, 248: 120895.

[75] Meng H, Song J, Huang L, et al. Water quality prediction method based on OVMD and spatio-temporal dependence[J]. Technical Gazette/Tehnički Vjesnik, 2024, 31(1): 286 – 295.

[76] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [C] // Proceedings of the 31st International Conference on Neural Information Processing System, 2017: 6000 – 6010.

[77] Wu R, Painumkal J T, Volk J M, et al. Parameter estimation of nonlinear nitrate prediction model using genetic algorithm [C] // IEEE Congress on Evolutionary Computation (CEC), SPAIN, 2017: 1358 – 2069.

[78] Manzar M S, Benaafi M, Costache R, et al. New generation neurocomputing learning coupled with a hybrid neuro-fuzzy model for quantifying water quality index variable: a case study from Saudi Arabia[J]. Ecological Informatics, 2022, 70: 101696.

[79] Pham Q B, Mohammadpour R, Linh N T T, et al. Application of soft computing to predict water quality in wetland[J]. Environmental Science and Pollution Research, 2021, 28(1): 185 – 200.

[80] Lü J, Du L, Lin H, et al. Enhancing effluent quality prediction in wastewater treatment plants through the integration of factor analysis and machine learning[J]. Bioresource Technology, 2024, 393: 130008.

[81] 李道亮,赵晔,杜壮壮. 农业领域多模态融合技术方法与应用研究进展[J]. 农业机械学报, 2025, 56(1): 1 – 15.

Li Daoliang, Zhao Ye, Du Zhuangzhuang. Advances in multi-modal fusion techniques and applications in agricultural field [J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(1): 1 – 15. (in Chinese)

[82] 马若飞,杜岳峰,郭大方,等. 农场数字孪生技术发展现状与展望[J]. 农业机械学报, 2025, 56(9): 257 – 277.

Ma Ruofei, Du Yuefeng, Guo Dafang, et al. Development status and prospect of digital twin farm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(9): 257 – 277. (in Chinese)