

基于改进 YOLO 11n 的轻量化金鲳鱼摄食强度检测模型

杨 洲^{1,2} 邱家鸿¹ 段洁利¹ 刘 清¹ 彭小红³ 杨仁友⁴

(1. 华南农业大学工程学院, 广州 510640; 2. 广东海洋大学机械工程学院, 湛江 524088;

3. 广东海洋大学数学与计算机学院, 湛江 524088; 4. 南方海洋科学与工程广东省实验室(湛江), 湛江 524000)

摘要: 在循环水养殖系统中,精准投喂对于提升饲料利用率、保障鱼类健康生长具有重要意义。过量投喂会造成资源浪费并诱发水体污染,而投喂不足则会影响鱼类生长效率。针对传统视觉检测模型参数量大、难以在边缘设备中高效部署的问题,以金鲳鱼为研究对象,提出了一种基于改进 YOLO 11n 的金鲳鱼摄食强度轻量化检测方法,实现金鲳鱼摄食强度的准确检测。提出的模型将传统的 YOLO 11n 模型中的卷积层替换为可变形卷积核模块(Arbitrary kernel convolution, AKConv),同时,在模型中融入可变形邻域注意力(Deformable neighborhood attention, DN-Attention),在降低模型计算成本的同时,提高了摄食个体数量的检测准确度。将检测模块输出的摄食个体数量与对应的时间帧作为循环神经网络 CNN-LSTM 模型的输入,通过无监督训练,将金鲳鱼的摄食强度分为:强、弱、无 3 个等级。试验结果证明,改进后的 YOLO 11n 检测模型,精确率达到 87.6%,召回率达到 81.5%,平均精度均值达到 88.1%,相较于传统 YOLO 11n 模型,本研究提出的模型在精确率、召回率和平均精度均值上分别提升了 3.5、3.6、2.4 个百分点。实现了检测精度与轻量化的有效平衡,可为智能投喂装备的边缘部署提供技术支撑。

关键词: 精准投喂; YOLO 11n; 摄食强度; 金鲳鱼

中图分类号: S951.2

文献标识码: A

文章编号: 1000-1298(2026)19-0044-10

OSID:



Lightweight Feeding Intensity Detection Model for *Trachinotus ovatus* Based on Improved YOLO 11n

Yang Zhou^{1,2} Qiu Jiahong¹ Duan Jieli¹ Liu Qing¹ Peng Xiaohong³ Yang Renyou⁴

(1. College of Engineering, South China Agricultural University, Guangzhou 510640, China

2. School of Mechanical Engineering, Guangdong Ocean University, Zhanjiang 524088, China

3. College of Mathematics and Computer Science, Guangdong Ocean University, Zhanjiang 524088, China

4. Guangdong Provincial Laboratory of Southern Marine Science and Engineering (Zhanjiang), Zhanjiang 524000, China)

Abstract: In recirculating aquaculture systems, precise control of feeding amounts is essential for optimizing feed utilization and promoting the healthy growth of fish. Overfeeding can result in resource waste and water pollution, while underfeeding can diminish fish growth efficiency. To address the challenges posed by large parameter sizes and the difficulty of efficient deployment on edge devices inherent in traditional visual inspection models, focusing on *Trachinotus ovatus*, a lightweight detection method for assessing feeding intensity was proposed based on an improved YOLO 11n model. The proposed model replaced the convolutional layers in the traditional YOLO 11n with deformable convolution kernel modules (arbitrary kernel convolution, AKConv) and incorporated deformable neighborhood attention (deformable neighborhood attention, DN-Attention). This integration not only reduced the model's computational cost but also enhanced the detection accuracy of number of individuals ingested being fed. The number of individuals ingested and the corresponding time frames were input into a recurrent neural network (CNN-LSTM) model. Through unsupervised training, the feeding intensity of *Trachinotus ovatus* was classified into three levels: strong, weak, and none. Experimental results demonstrated that the improved YOLO 11n detection model achieved an accuracy of 87.6%, a recall of

收稿日期: 2026-01-14 修回日期: 2026-01-26

基金项目: 国家重点研发计划项目(2023YFD2401702)、广东省现代化海洋牧场养殖环境监测预报预警体系研究与应用项目(第一批)

(粤农农[2024]206号)和湛江湾实验室人才团队引进科研项目(ZJW-2023-04)

作者简介: 杨洲(1972—),男,教授,博士,主要从事农业生产机械化与信息化研究,E-mail: yangzhou@scau.edu.cn

通信作者: 杨仁友(1980—),男,正高级工程师,博士,主要从事现代化海洋牧场智慧渔业研究,E-mail: youngrenyou@zjblab.com

81.5%, and an average precision of 88.1%. Compared with the traditional YOLO 11n model, the proposed model improved accuracy, recall, and average precision by 3.5, 3.6, and 2.4 percentage points, respectively. This approach effectively balanced detection accuracy and model lightness, providing technical support for the edge deployment of intelligent feeding equipment.

Key words: precise feeding; YOLO 11n; intake intensity; *Trachinotus ovatus*

0 引言

精准投喂是现代化水产养殖的重要环节之一,不仅关系到饲料转化效率与成本控制,还与鱼类的健康生长密切相关。投喂不足会抑制鱼类正常生长,而过量投喂则不仅造成饲料浪费,还会加速氮、磷等营养盐的累积,诱发水体富营养化,进而降低养殖环境的稳定性^[1]。因此,实现鱼类摄食行为的实时监测与分级,对推动智能投喂系统的实际应用具有重要意义^[2]。

金鲳鱼因其生长迅速、饲料利用效率高、抗逆性强等特点,已成为华南沿海地区主要的规模化养殖经济鱼类。在循环水养殖系统(RAS)中^[3],水体环境可控性强,为部署数字化监测设备提供了较好的条件,也为基于视觉的摄食行为识别提供了稳定的观测场景。在此背景下,利用机器视觉技术对鱼群摄食状态^[4]进行自动识别,通过实时监测鱼群摄食动态并实现按需投喂,已成为智能化水产养殖领域的重要研究方向。

目前,鱼群摄食行为的检测方法主要分为声学检测^[5]和视觉检测两类。声学方法^[6-7]可实现全天候、大范围的监测^[8],但声呐设备成本较高,且易受到悬浮物、气泡等水体杂质的干扰,从而限制其在中小规模养殖场中的推广应用。

随着深度学习的发展,基于卷积神经网络的检测方法逐渐成为主流^[9-13]。

在摄食行为量化方面,Liu 等^[14]提出鱼群摄食聚集系数(Flocking index of fish feeding behavior, FIFFB),通过单位面积内鱼体数量密度变化表征鱼群聚集程度;Zhou 等^[15]构建抢食强度指数(Snatch intensity of fish feeding behavior, SIFFB),基于鱼体运动速度及方向一致性量化摄食的激烈程度。这些指标为摄食行为的定量评估提供了理论基础,但其计算过程依赖于准确的鱼体检测与跟踪,因此对目标检测算法的精度和速度提出了更高要求。

近年来,YOLO 系列目标检测算法因其在速度与精度之间取得良好平衡,被广泛应用于水产养殖领域^[16]。尽管相关研究^[17-19]取得了进展,但金鲳鱼摄食行为的检测仍存在难以精准识别与难以量化等问题。

此外,现有视觉检测模型在循环水养殖系统的实时应用中仍面临两方面挑战:摄食过程中常伴随快速跃水、鱼体遮挡、光照变化及水花扰动等复杂视觉现象,易导致检测精度下降;主流深度检测模型参数量大、计算负荷高,难以在边缘设备上实现高帧率推理,限制了其在智能投喂装备中的实际部署。因此,构建兼具高精度与轻量化特性的摄食检测模型具有重要的研究与应用价值。

针对上述问题,本研究提出一种基于改进 YOLO 11n 的轻量化金鲳鱼摄食检测方法。通过引入可变形卷积 AKConv 提升模型对鱼体跃水等不规则姿态的空间表达能力,并融合可变形邻域注意力机制 DN-Attention,以增强对关键摄食区域的特征聚焦能力,在保证轻量化的同时兼顾高精度的要求。在此基础上,利用 CNN-LSTM 对检测序列进行时间维度特征建模,以实现金鲳鱼摄食行为的强、弱、无 3 级识别。

1 材料与方法

1.1 试验材料与环境

本研究以金鲳鱼为试验对象,试验在广东省湛江市坡头区南方海洋科学与工程广东省实验室(湛江)开展。养殖系统如图 1 所示,养殖池为直径 2.5 m、池高 1.7 m 的圆形池,试验期间水深维持在 1.5 m。试验鱼的单体质量为 (200 ± 10) g,养殖密度为 (13 ± 0.65) kg/m³。水质条件维持在适宜金鲳鱼生长的范围内,其中水温为 (26 ± 2) °C,pH 值为 7.5 ± 0.5 ,溶解氧质量浓度为 (6 ± 0.5) mg/L,蓝绿藻平均指数约为 7 mg/L,氧化还原电位(Oxidation-reduction potential, ORP)约为 270 mV。投喂采用浮性膨化饲料,每日投喂两次(10:00、16:00),单次投喂总量不超过 500 g。为保证试验鱼适应养殖环境,试验开始前在系统内暂养 15 d。

1.2 视频采集方案

由于本研究采用浮性饲料,金鲳鱼在摄食过程中会迅速上浮并常伴随跃出水面的抢食行为,形成明显的视觉特征。基于这一特性,本研究采用水面俯视的方式采集摄食过程影像。数据采集系统如图 2 所示。摄像机型号为海康威视 DS-IPC-B12HV3-LT,安装于水面斜上方约 1 m 处,采集分



图 1 养殖系统实物图

Fig.1 Physical diagram of aquaculture system

分辨率为 3 840 像素×2 160 像素的 RGB 图像,帧率为 60 f/s,图像格式为 JPEG。为提高摄食行为样本的多样性与覆盖性,视频采集分别在早晨、黄昏及不同光照条件下进行。

1.3 数据集预处理

从采集视频中截取 1 438 幅鱼群摄食图像作为




图 3 不同样本数据增强图像

Fig.3 Enhanced images of different sample data

摄食行为的分类特征如表 1 所示,并作为数据标注的依据。使用 LabelImg 软件对图像中处于摄食状态的金鲮鱼进行标注,其中金鲮鱼跃出水面摄食的行为被统一标注为“eating”。部分图像中可能同时出现多尾金鲮鱼跃出水面的情况,因此标注中会对应多个标注框,如图 4 所示。标注文件以*.txt 格式保存。最终构建了包含 6 400 个标注框的金鲮鱼摄食数据集,红色框为摄食,黄色框为无摄食。

表 1 鱼群摄食行为特点

Tab.1 Characteristics of fish school feeding behavior

摄食行为类别	摄食行为特点
摄食 (eating)	鱼体跃/露出水面,水面产生水花
无摄食	鱼体在水面以下,水面无水花




图 2 数据采集系统示意图

Fig.2 Data collection system diagram

1.循环过滤器 2.养殖池 3.金鲮鱼 4.摄像机 5.水质传感器 6.计算机

原始数据。考虑到光照变化、反射干扰及水花遮挡等因素可能影响检测性能,本研究采用随机亮度调整、饱和度扰动及随机椒盐噪声注入等图像增强方法扩展数据规模,如图 3 所示。增强后数据集数量增至 2 876 幅。随后,将扩充后的数据按 8:1:1 的比例划分为训练集、验证集和测试集。



图 4 数据集标注示意图

Fig.4 Schematic of dataset annotation

2 基于改进 YOLO 11n 的金鲮鱼摄食检测模型

2.1 YOLO 11n 模型

在 YOLO 系列模型中,YOLO 11n 以参数量小、

推理速度快等特点展现出显著优势^[16]。其网络结构如图 5 所示。YOLO 11n 在延续 YOLO v8 优秀性能的基础上,进一步针对小目标检测与推理效率进行了优化,在轻量化场景下具有较强竞争力。对于资源受限的计算平台(如边缘设备和移动终端),目标检测算法普遍面临如何在计算效率(轻量化)与检测性能(准确性)之间取得平衡的关键问题。YOLO 11n 的设计理念正是围绕这一需求,通过结构协同设计实现了在保持极低计算开销的同时尽可能提升检测性能。YOLO 11 系列首次引入 C3k2 等新型结构模块,用于弥补网络压缩带来的精度损失,并通过适当增加模型深度提升特征表达能力。基于此,YOLO 11n 在轻量化与精度之间取得了良好折中。然而,现有金鲳鱼摄食检测模型在目标识别精度、边缘设备推理延迟和能耗等方面仍存在不足。针对上述问题,本研究以 YOLO 11n 为基准模型,提出了改进的 AKD-YOLO 11n,用以提升金鲳鱼摄食检测在复杂场景下的精确性与实时部署能力。




图 5 YOLO 11n 结构图

Fig. 5 YOLO 11n architecture diagram

2.2 AKConv 模块

可变形卷积核模块 (Arbitrary kernel convolution, AKConv) 是一种改进的卷积操作,通过引入可变形卷积核并动态调整采样位置,使卷积运算具备更高的灵活性和适应性^[20]。AKConv 的结构示意图如图 6 所示。该模块首先通过一个标准卷积层从输入特征 X 中学习得到动态偏移量,并据此对采样位置进行自适应调整,从而增强特征提取能力。动态偏移公式为

$$\Delta P = \text{Conv}_{\text{offset}}(X) \quad (1)$$

式中,动态偏移张量 ΔP 的尺寸为 $(B, 2N, H_{\text{out}}, W_{\text{out}})$, N 表示卷积核中采样点的数量,对于输出特征图上的每个位置 (i, j) ,该张量为其对应的 N 个采样点分别学习生成一个二维偏移向量 $\Delta p^{(k)}(i, j) =$

$(\Delta p_x^{(k)}(i, j), \Delta p_y^{(k)}(i, j))$,从而实现对采样坐标的可学习形变。




图 6 AKConv 模块结构图

Fig. 6 Structure diagram of AKConv module

对于输出特征图上任意位置,其最终采样坐标由 3 部分组成:从输出位置映射回输入特征图的基准坐标;卷积核定义的初始静态偏移;网络学习得到的动态偏移张量。其坐标计算公式为

$$p_x^{(k)}(i, j) = j_s + p_{nx}^{(k)} + \Delta p_x^{(k)}(i, j) \quad (2)$$

$$p_y^{(k)}(i, j) = i_s + p_{ny}^{(k)} + \Delta p_y^{(k)}(i, j) \quad (3)$$

$$(k = 1, 2, \dots, N)$$

其中 (j_s, i_s) 为输出点 (i, j) 映射回输入图的基准坐标。 $(p_{nx}^{(k)}, p_{ny}^{(k)})$ 为第 k 个点的初始静态偏移。 $\Delta p_x^{(k)}(i, j)$ 、 $\Delta p_y^{(k)}(i, j)$ 为第 k 个点的动态学习偏移张量。

AKConv 允许构建不规则形状的卷积核,并通过动态调整采样点以捕捉输入特征的空间变化,这一机制区别于传统卷积所采用的固定采样网格,具备更高的结构灵活性。通过引入可学习的偏移量,AKConv 能够根据输入特征动态改变卷积的采样模式,从而提升模型对不同空间形态的适应能力。在保持轻量化计算特点的同时,该模块仍能够获得良好的特征表达能力。

2.3 DN-Attention 模块

可变形邻域注意力 (Deformable neighborhood attention, DN-Attention) 是一类高效且灵活的局部注意力机制^[21],其结构如图 7 所示。该模块基于可变形局部注意力 (Deformable local attention) 的思想,通过一个轻量化的深度可分离卷积网络预测每个查询点 (Query) 对应的邻域采样点偏移量 (Offset)。这一机制意味着注意力的采样位置不再受限于固定的规则网格,而是能够根据输入特征分布自适应调整感受野,将计算资源聚焦于局部信息更密集的区域。因此,在处理金鲳鱼摄食行为中姿态变化快、局部结构形变显著的场景时,该模块具有明显优势。其中,采样点的计算公式为

$$p_{\text{sample}} = p_{\text{ref}} + \Delta p' \quad (4)$$

式中 p_{ref} ——在规则卷积窗口中预定义的固定网

格坐标

$\Delta p'$ ——轻量卷积网络根据输入特征动态预测的偏移量

p_{sample} ——最终进行特征采样的点,不再是固定的网格,而是根据内容自适应调整过的位置,用于从输入特征中提取内容




图 7 DN-Attention 模块结构图

Fig. 7 Structure of DN-Attention module

定义区域重要性的局部邻域注意力公式为

$$Output_i = \sum_{j \in \text{Neighborhood}} \text{softmax} \left(\frac{q_i k_{i,j}}{\sqrt{d_h}} \right) v_{i,j} \quad (5)$$

式中 i ——当前查询 (Query) 的位置
 j —— i 的局部邻域内的某个位置
 $q_i, k_{i,j}, v_{i,j}$ ——查询向量、邻域内的键向量和值向量

定义了模块集成到深度网络中公式

$$y = x + \text{DNA}(\text{LayerNorm}(x)) \quad (6)$$

式中 x ——块的输入特征

$\text{LayerNorm}(x)$ 表示先对输入进行归一化,稳定训练。 $\text{DNA}(\text{LayerNorm}(x))$ 表示应用上述两个核心公式计算出的注意力结果。

本模块的核心思想是:首先,通过一个轻量级网络动态预测每个位置应关注的邻域采样点(式(4));随后,在该自适应的局部邻域内执行高效的局部注意力计算(式(5));最后,通过标准的残差结构融合特征,实现稳定特征传播(式(6))。整个过程实现了从动态采样到局部注意力到残差融合的完整建模链路,使得模块能够在保持较低计算成本的同时,具备强大的空间建模能力。

在位置编码设计方面,该模块集成了两种主流且有效的位置编码方式,以提高模型对空间结构和几何关系的感知能力:①相对位置偏置(Relative position bias, RPB),通过一个可学习的偏置矩阵,根据查询点与邻域采样点的相对位置为注意力得分添加偏置。RPB 能够显式建模空间关系,帮助网络

更好地理解局部几何结构。②条件位置编码(Conditional positional encoding, CPE),利用深度可分离卷积(记为 rpe_table)对 Query 特征进行动态处理,生成内容相关的局部增强编码(Local enhancement, LEPE),即 residual_lepe。该方法属于内容自适应的位置编码,能够根据特征内容动态调整位置表征,进一步增强局部建模能力。

基于上述设计,DN-Attention 具备更高的灵活性和表现力。其可变形机制赋予模型动态、内容自适应的感受野,相比传统固定网格采样的注意力机制,更能够捕捉关键局部结构,尤其适用于在金鲳鱼摄食行为识别等需要精确定位的任务场景中。

此外,该模块将注意力计算限制在局部邻域,使其计算复杂度相对于图像大小呈线性增长,而非全局注意力的平方关系。同时,结合高效的网格采样与滑窗展开策略,该模块在保持较高表达能力的同时,兼具良好的计算效率。其设计融合了卷积网络的归纳偏置(如局部性与平移不变性)和注意力机制的动态加权能力,并引入先进的位置编码方案,实现了性能、效率与效果之间的平衡,在各类视觉任务中展现出优越的性能。

2.4 改进 YOLO 11n 模型

金鲳鱼在摄食过程中受水花、反光及光照变化等影响,其环境 RGB 特性波动较大。通过图像预处理可显著增强模型的鲁棒性,同时引入 AKConv 卷积结构能够提升模型对多尺度摄食特征的适应能力。为了兼顾金鲳鱼摄食检测任务对模型预测精度^[22]、计算量和参数量^[23]的要求,本研究构建了基于 AKD-YOLO 11n 的改进检测模型,结构图如图 8 所示,主要包括以下 3 项改进:①在主干网络




图 8 改进的 YOLO 11n 结构图

Fig. 8 Architecture of modified YOLO 11n

(Backbone) 中引入了 AKConv 下采样模块,AKConv 的核心特性在于其卷积核形状与大小可学习,使其在空间采样上具有高度灵活性。该模块能够根据输入特征自动调整感受野形态,从而提升模型对不规则鱼体跃水姿态的建模能力,并在参数增长效率、几何适应性和特征表达能力方面均优于传统卷积。

②引入了可变形邻域注意力 (DN - Attention),与传统固定方形窗口的注意力机制不同,DN - Attention 能够动态调整采样点位置,优先聚焦图像中信息密集区域。在计算过程中,DN - Attention 将可变形卷积与自注意力机制相结合:前者通过轻量化卷积网络预测采样点偏移,实现灵活的可形变特征采样;后者在确定采样位置后,根据采样点间的相关性权重进行加权聚合。两者协同作用,可实现更加精准、高效的局部特征提取,使模型在复杂光照变化和鱼体遮挡条件下仍具备较强的特征表达能力。

③采用结合“邻域注意力 + 可形变采样”的局部自注意力结构。DN - Attention 仅在 $k \times k$ 局部邻域内执行注意力计算,其计算复杂度随窗口规模呈线性增长,有利于在高分辨率输入条件下保持可计算性。此外,DN - Attention 还支持可形变偏移采样、下采样注意力与空洞感受野等机制,分别通过在连续坐标上进行学习式采样、降低邻域计算密度以及扩大有效感受野来提升几何对齐能力、减少计算开销并增强对长程结构特征的捕获能力。

上述设计使得模型在中高层特征提取阶段能够同时获得“广视野、低成本”的注意力表示,并通过可形变偏移进一步强化几何结构的对齐能力及复杂形态特征的建模能力。

由表 2 可以看出,YOLO 11n 虽然在帧率方面略低于 YOLO v8n 和 YOLO v10n,但在精确率、召回率、mAP0.5、参数量以及内存占用量等指标上均表现出较为明显的优势。因此,本研究选择 YOLO 11n 作为基础模型,并在其结构上引入注意力模块和轻量化 AKConv 模块,对主干网络 (Backbone) 进行改

3 结果与分析

3.1 试验硬件环境

本研究的模型训练与测试在以下平台上完成:硬件环境包括 Intel Xeon W - 2235 处理器和 NVIDIA GeForce RTX A4500 显卡 (20 GB 显存)。软件环境采用 Python 3.8、PyTorch 1.13.1 深度学习框架和 CUDA 11.6。模型训练阶段的主要超参数设置如下:输入图像尺寸为 3 840 像素 $\times$ 2 160 像素,batch size 为 16,训练轮数为 100,初始学习率设定为 0.01,其余参数保持默认配置。上述软硬件条件能够满足模型训练需求,并保证结果的稳定性与可复现性。

3.2 评估指标

为系统评估目标检测模型的性能,本研究选取精确率、召回率以及平均精度均值 (Mean average precision,mAP,阈值为 0.5) 作为检测精度指标。同时,采用参数量、浮点运算量和模型内存占用量来衡量模型的复杂度与可部署性。模型的实时推理能力则通过帧率进行评估。上述指标体系兼顾检测准确性、轻量化程度和实时性能,为全面评价改进后的 YOLO 11n 模型提供了依据^[24]。

3.3 不同目标检测算法对比试验

为验证改进模型的有效性,本研究选取 Faster R - CNN^[25]、YOLO v5n、YOLO v8n、YOLO v9t、YOLO v10n、YOLO 11n、YOLO 12n 及 AKD - YOLO 11n^[26] 共 8 种主流检测模型进行对比试验。表 2 展示了各模型在精确率、召回率、mAP、参数量、内存占用量以及帧率等指标上的性能表现。

表 2 不同目标检测算法性能						
Tab.2 Performance comparison of different object detection algorithms						
模型	精确率/%	召回率/%	mAP0.5/%	参数量	内存占用量/MB	帧率/(f·s ⁻¹)
Faster R - CNN	75.6	84.1	84.2	4.18×10^7	158.0	28.3
YOLO v5n	83.8	74.8	83.4	2.53×10^6	5.2	142.9
YOLO v8n	79.6	81.0	83.9	3.04×10^6	6.2	133.3
YOLO v9t	82.1	77.0	82.6	2.03×10^6	4.4	112.4
YOLO v10n	79.1	77.0	83.1	2.74×10^6	5.7	158.7
YOLO 11n	84.1	77.9	85.7	2.60×10^6	5.4	126.6
YOLO 12n	79.6	81.3	85.0	2.54×10^6	5.5	122.0
AKD - YOLO 11n	87.6	81.5	88.1	3.72×10^6	7.7	117.6

进,构建 AKD - YOLO 11n 模型。

由表 2 数据进一步分析可知,改进后的 AKD - YOLO 11n 模型在实现轻量化的同时,有效提升了检测精度,虽然轻量化不是对比模型中最优秀的,但本研究的模型在精确率和 mAP0.5 指标上均取得了最优结果。其中,召回率相较于 Faster R - CNN 降

低了 2.6 个百分点,但本研究的模型在参数量方面,远低于 Faster R - CNN 模型,这种结果是可以接受的。

AKConv 模块的核心操作是基于动态调整的采样点进行特征重采样,采样点的位置由学习得到的偏移量决定,使卷积运算能够以更加灵活的方式完成,同时减少冗余计算。结合可根据特征自适应调整感受野的 DN - Attention 注意力机制,AKD - YOLO 11n 在检测精度方面较 YOLO 11n 有显著提升。其中,与 Faster R - CNN、YOLO v5n、YOLO v8n、YOLO v9t、YOLO v10n、YOLO 11n 和 YOLO 12n 相比,AKD - YOLO 11n 的精确率分别提高了 12.0、3.8、8.0、5.5、8.5、3.5、8.0 个百分点;mAP0.5 分别提升了 3.9、4.7、4.2、5.5、5.0、2.4、3.1 个百分点。

从综合性能雷达图(图 9)可以直观地看出,改进 YOLO 11n 模型在精确率、召回率、mAP0.5、参数量、内存占用量和帧率等指标上呈现更加均衡的特性,其雷达图形区域最为饱满,说明模型在各项性能指标间达成了较好的平衡。虽然 AKD - YOLO 11n 的参数量略高于 YOLO v8n 和 YOLO v10n,但在检测精度提升与轻量化设计之间实现了合理权衡,更适合用于金鲳鱼摄食行为检测这一场景。




图 9 各模型对比雷达图
Fig. 9 Model comparison on radar chart

为了更直观地对比 YOLO 11n 与 AKD - YOLO 11n 在检测金鲳鱼摄食行为时的关注区域分布及漏检情况,本研究采用基于目标检测结果的高斯核密度估计(Gaussian kernel density estimation,GKDE)生成热力图,通过叠加机制累积多个目标的影响,生成高关注度为红色、低关注度为蓝色的高斯分布热力图。对两种模型的可视化结果进行分析,如图 10 所示。由图 10b 与图 10c 可以看出,两种模型均对金鲳鱼摄食区域保持较高关注度,热力图较好地覆盖了金鲳鱼跃水摄食的位置,但 YOLO 11n 存在部分目标漏检(图中红色圆圈标注区域),而 AKD - YOLO 11n 在这些区域的响应更为明显,表明改进

模型在复杂水面环境下对金鲳鱼摄食行为的检测能力更强。




图 10 可视化热力图对比
Fig. 10 Comparison of heatmaps

3.4 注意力机制检测性能对比试验

为研究引入 DN - Attention 注意力机制的合理性和必要性,本文选取 CBAM (Convolutional block attention module)^[27]、SE (squeeze-and-excitation)^[28] 以及 SEAM (Separated and enhancement attention module)^[29] 3 种代表性注意力机制进行对比试验。各注意力模块均嵌入 YOLO 11n 网络结构中的同一位置,并在相同数据集与试验条件下进行测试,试验结果如表 3 所示。

表 3 不同注意力机制的模型性能对比
Tab. 3 Performance comparison of models with different attention mechanisms

模型	精确率/ %	召回率/ %	mAP0.5/ %	内存占用 量/MB
YOLO 11n	84.1	77.9	85.7	5.4
CBAM - YOLO 11n	81.8	74.2	85.0	6.7
SE - YOLO 11n	82.5	74.7	84.4	6.7
SEAM - YOLO 11n	83.8	75.3	85.3	6.8
AKD - YOLO 11n	87.6	81.5	88.1	7.7

由表 3 可知,相较于基线 YOLO 11n 模型,引入 DN - Attention 模块 AKD - YOLO 11n 模型的精确率提升至 87.6%,较基线提高了 3.5 个百分点;召回率提升至 81.5%;mAP0.5 则达到 88.1%。而引入 CBAM、SE 和 SEAM 后,模型的精确率较基线分别下降了 2.3、1.6、0.3 个百分点,表现出不同程度的性能退化。

结合金鲳鱼摄食检测场景可进一步分析:CBAM 同时考虑通道注意力与空间注意力,能够增强局部特征,但对鱼体之间的长距离依赖关系建模不足,在鱼体重叠较严重的复杂环境中难以有效区分目标,影响检测性能;SE 注意力仅作用于通道维度,对空间位置信息的利用有限,难以准确定位金鲳鱼摄食特征区域;SEAM 虽在一定程度上增强了特征表示能力,但在复杂水面环境及极端遮挡条件下,仍可能无法稳定提取有效目标特征。

相比之下,DN - Attention 通过可变形的局部注意力机制,将注意力计算限制在可学习的局部邻域中,不仅具备较高的定位精度,而且具备高效的计算

架构,在速度、综合精度和定位精度之间实现了良好平衡。其对关键区域的准确聚焦能力为后续精准投喂控制提供了可靠基础。

3.5 消融试验

为定量分析 AKConv 模块与 DN - Attention 注意力模块对整体性能的贡献,本研究在 YOLO 11n 基础上设计了多组消融试验,具体包括:仅加入 AKConv、仅加入 DN - Attention,以及同时加入 AKConv 与 DN - Attention 共 3 种情况,对比结果见表 4。

表 4 消融试验测试结果对比
Tab.4 Comparison of ablation study results

模型	精确率/ %	召回率/ %	mAP0.5/ %	参数量	帧率/ (f·s ⁻¹)
YOLO 11n	84.1	77.9	85.7	2.6×10^6	126.6
YOLO 11n + AKConv	85.2	78.3	86.3	2.4×10^6	135.1
YOLO 11n + DN - Attention	85.9	78.8	87.7	3.7×10^6	117.6
YOLO 11n + AKConv + DN - Attention	87.6	81.5	88.1	3.7×10^6	117.6

从表 4 可以看出,当仅引入 AKConv 模块时,模型的精确率由 84.1% 提升至 85.2%,增加 1.1 个百分点;召回率由 77.9% 提升至 78.3%,增加 0.4 个百分点;mAP0.5 从 85.7% 提升至 86.3%,增加 0.6 个百分点。同时,模型参数量由 2.6×10^6 降低至 2.4×10^6 ,帧率提升至 135.1 f/s。说明 AKConv 通过灵活的采样方式与减少冗余计算降低了模型计算复杂度,并利用动态采样模式提升了对不同输入特征的适应性。仅引入 DN - Attention 注意力模块时,精确率、召回率与 mAP0.5 分别提升至 85.9%、78.8% 和 87.7%,相比基线 YOLO 11n 分别提高了 1.8、0.9、2.0 个百分点。DN - Attention 能够根据输入特征自动学习并关注图像中信息量最丰富的区域,而不受限于固定方形窗口,对识别不规则形状或姿态各异的金鲳鱼具有显著优势。该模块利用分组卷积或深度可分离卷积等结构,在保持较好轻量化特性的同时,通过动态采样更好地捕捉几何形变与关键特征。同时引入 AKConv 与 DN - Attention 时,YOLO 11n + AKConv + DNAttnBlock (即 AKD - YOLO 11n)模型的精确率、召回率与 mAP0.5 分别提升至 87.6%、81.5% 和 88.1%,较基线模型分别提高 3.5、3.6、2.4 个百分点,目标检测能力显著优于其他组合方案,漏检与误检情况明显减少,验证了两种改进模块的叠加具有协同增益效果。与此同时,模型参数量由 2.6×10^6 增加至 3.7×10^6 ,帧率

为 117.6 f/s,相比基线略有下降,但在检测性能显著提升的前提下,这一开销处于可接受范围内,是模型性能与模型规模权衡后的合理结果。

3.6 应用分析

为进一步验证 AKD - YOLO 11n 模型在实际养殖环境中的应用效果,本研究选取一段时长为 3.45 min、文件大小约 499 MB 的金鲳鱼摄食视频作为测试对象。视频原始帧率为 60 f/s,为兼顾检测效率与时序信息保留,从每秒视频帧中均匀抽取 20 f 进行检测。将各抽取帧中检测到的标注框数量及其对应时间戳输出为 CSV 文件,构建“标注框数量-时间戳”序列,如图 11 所示。




图 11 标注框数量与时间戳轴线图
Fig.11 Line chart showing number of bounding boxes over time

图 11 中,黑色箭头标记为投喂时间点,其中第 1 次为养殖专家进行少量试投喂,第 2 次为正常投喂。从图中可以看出,在第 1 个摄食阶段(红色框范围),标注框数量出现显著峰值振荡,这是由于第 1 次少量投喂后,鱼群迅速聚集至水面,呈现明显的强摄食状态,但由于饲料量有限,该状态持续时间较短,随后进入弱摄食状态(灰色框范围)。在第 2 次正常投喂开始后,鱼群摄食状态由弱摄食迅速转变为强摄食,并维持较长时间。随着投喂过程接近尾声和饲料逐步被消耗,鱼群摄食状态由强摄食逐渐衰减为弱摄食,最终过渡为无摄食状态(绿色框范围)。上述分析表明,通过检测摄食时跃出水面的金鲳鱼数量变化,可以较好地反映鱼群摄食状态的变化规律。图 11 中黑色箭头为投喂起始时间点,红色框为强摄食,灰色框为弱摄食,绿色框为弱摄食。

在此基础上,对多段摄食视频进行目标检测,将各视频每一帧检测到的标注框数量及对应时间戳统一输出为 . csv 文件,共获得 86 940 组数据。将数据按 7:2:1 的比例划分为训练集、验证集和测试集,输入 CNN - LSTM 自编码器进行无监督训练,通过编码-聚类-解码机制学习摄食行为的潜在时序特征。模型在学习到的潜在特征空间中应用 K - means 聚类算法($k = 3$)自动发现摄食行为的内在模式,并根据各聚类簇内标注框数量的均值排序,自动映射为无摄食、弱摄食和强摄食 3 种状态。聚类质量评估

结果显示,轮廓系数达到 0.131 3,戴维斯-鲍丁指数为 2.160 0,卡林斯基-哈拉巴斯指数为 5 199.41,表明该聚类结构具有良好的紧凑性与可分离性,满足工程应用需求。

为验证所提出模型在实际应用环境中的推理效率与可行性,本研究将 AKD - YOLO 11n 模型部署在移动端设备 Lenovo Legion R7000P ARH7 (NVIDIA GeForce RTX 3050 Ti Laptop GPU,运行内存4 GB)上进行测试。为简化系统搭建,选用浙江格池园林用品有限公司生产的 CFF - 206 型投喂设备,对其原有电路进行改装,仅保留机械结构部分,由移动端设备作为上位机,通过串口与 STM32 单片机进行通信,下位机控制直流电机完成投喂动作。STM32 具有实时响应能力强、成本低、PWM 精准控制与硬件驱动能力强等优点,且具备丰富的硬件接口,便于后续功能扩展。

系统实物图如图 12 所示。通过移动端上位机根据模型输出的强摄食、弱摄食和无摄食状态分别向下位机发送指令,STM32 控制电机实现高速旋转、低速旋转或停止,从而完成相应的投喂动作。试验结果表明,改进模型在移动端平台上的平均检测帧率可达到 45 f/s,能够满足金鲟鱼摄食检测装备轻量化部署与实时控制的需求,为金鲟鱼自动化投喂和饲料节约提供了有效技术支撑。

4 结论

(1)通过引入 AKConv 模块动态调整采样位置,明显增强模型对鱼体跃水等非刚性形变的适




图 12 投喂机作业图

Fig. 12 Feeding machine at work

应性,DN - Attention 模块则以可变形局部注意力强化关键区域聚焦并抑制反光、水花等噪声。两模块协同作用,在保持轻量化结构的同时显著提升检测性能。

(2)与原 YOLO 11n 相比,改进后的模型在精确率、召回率和 mAP0.5 上分别提升了 3.5、3.6、2.4 个百分点,实现了精度的稳定提升,同时模型规模仍符合轻量化部署要求。进一步结合逐帧检测序列与 CNN - LSTM,可以将摄食行为划分为强、弱、无 3 个等级,为摄食行为的分级提供了可靠依据。

(3)工程验证表明,AKD - YOLO 11n 能够在 Lenovo Legion R7000P 上以约 45 f/s 的速度运行,并可与 STM32 配合实现实时投喂控制,具有良好的实践可行性。整体来看,本研究在“轻量化 + 高精度”的双重需求下提供了一种可实际落地的技术路线,对金鲟鱼智能投喂系统以及其他鱼类摄食监测任务均具有参考价值。

参 考 文 献

[1] 麻志宏,赵天昊,陈雨泽,等. 智慧渔业无人养殖工厂数智技术体系研究综述[J]. 农业机械学报,2025,56(10):1 - 19.
Ma Zhihong, Zhao Tianhao, Chen Yuze, et al. Towards smart fishery: application status and prospects of digital-intelligent technology system in unmanned aquaculture factories[J]. Transactions of the Chinese Society for Agricultural Machinery,2025, 56(10):1 - 19. (in Chinese)

[2] 岳冬冬,吴反修,李欣童,等. 我国水产养殖业生产效率评估及其对渔业统计的启示[J]. 渔业信息与战略,2021, 36(2):79 - 87.
Yue Dongdong, Wu Fanxiu, Li Xintong, et al. Evaluation of production efficiency of aquaculture industry in China and its implications for fishery statistics[J]. Fishery Information and Strategy, 2021, 36(2):79 - 87. (in Chinese)

[3] 李耀国,周刚,周诚,等. 大口黑鲈工厂化循环水苗种培育和池塘成鱼养殖的水质处理效率分析[J]. 渔业研究,2026, 48(2):190 - 199.

[4] 赵建,朱松明,叶章颖,等. 循环水养殖游泳型鱼类摄食活动强度评估方法研究[J]. 农业机械学报,2016,47(8): 288 - 293.
Zhao Jian, Zhu Songming, Ye Zhangying, et al. Assessing method for feeding activity of swimming fishes in RAS[J]. Transactions of the Chinese Society for Agricultural Machinery,2016,47(8):288 - 293. (in Chinese)

[5] Barraza-Guardado R H, Martínez-Córdova L R, Enríquez-Ocaña L F, et al. Effect of shrimp farm effluent on water and sediment quality parameters off the coast of Sonora, Mexico[J]. Ciencias Marinas, 2015, 40(4):221 - 235.

[6] Masaló I, Reig L, Oca J. Study of fish swimming activity using acoustical Doppler velocimetry (ADV) techniques[J]. Aquacultural Engineering, 2008, 38(1):43 - 51.

[7] 胡家祯,孙佳龙,黄小华,等. 基于高频水平机械扫描式声呐图像的海水网箱养殖卵形鲳鲹数量估算方法[J]. 南方水

- 产科学, 2024, 20(5): 113 – 125.
- Hu Jiazhen, Sun Jialong, Huang Xiaohua, et al. A method for estimating quantity of *Trachinotus ovatus* in marine cage aquaculture based on high-frequency horizontal mechanical scanning sonar image[J]. South China Fisheries Science, 2024, 20(5): 113 – 125. (in Chinese)
- [8] 仇丽阳. 基于声呐图像鱼类智能投喂技术研究[D]. 杭州: 浙江大学, 2022.
- Qiu Liyang. Research on intelligent fish feeding technology based on sonar images[D]. Hangzhou: Zhejiang University, 2022. (in Chinese)
- [9] 俞国燕, 钱利文, 刘峰春, 等. 基于双目相机和深度学习的鱼类摄食强度分析方法[J]. 农业机械学报, 2025, 56(3): 403 – 413, 424.
- Yu Guoyan, Qian Liwen, Liu Haochun, et al. Design and experimentation of fish feeding intensity system based on binocular cameras and deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 403 – 413, 424. (in Chinese)
- [10] 张铮, 沈彦兵, 张泽扬. 基于运动特征提取和 2D 卷积的鱼类摄食行为识别研究[J]. 农业机械学报, 2024, 55(6): 246 – 253.
- Zhang Zheng, Shen Yanbing, Zhang Zeyang. Recognition of feeding behavior of fish based on motion feature extraction and 2D convolution[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(6): 246 – 253. (in Chinese)
- [11] 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)
- [12] 徐立鸿, 黄志尊, 龙伟, 等. 基于 MobileViT – CBAM – BiLSTM 的开放式养殖环境鱼群摄食强度分类模型[J]. 农业机械学报, 2024, 55(11): 147 – 153.
- Xu Lihong, Huang Zhizun, Long Wei, et al. Classification model of fish feeding intensity based on MobileViT – CBAM – BiLSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 147 – 153. (in Chinese)
- [13] 徐立鸿, 崔钰惠, 刘世晶, 等. 基于帧间深度特征差分的大西洋鲑鱼群活跃度分类模型[J]. 农业机械学报, 2023, 54(11): 259 – 265.
- Xu Lihong, Cui Yuhui, Liu Shijing, et al. Classification model of Atlantic salmon activity intensity based on deep feature differencing between frames[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 259 – 265. (in Chinese)
- [14] Liu Z, Li X, Fan L, et al. Measuring feeding activity of fish in RAS using computer vision[J]. Aquacultural Engineering, 2014, 60: 20 – 27.
- [15] Zhou C, Zhang B, Lin K, et al. Near-infrared imaging to quantify the feeding behavior of fish in aquaculture[J]. Computers and Electronics in Agriculture, 2017, 135: 233 – 241.
- [16] Khanam R, Hussain M. YOLO 11: an overview of the key architectural enhancements[PP/OL]. V1. arXiv(2024 – 10 – 23) [2025 – 11 – 19]. <https://arxiv.org/abs/2410.17725>.
- [17] 徐文凯, 郎平, 李道亮. 多目标鱼类实例分割 LIS – YOLO 轻量化模型研究[J]. 农业机械学报, 2025, 56(10): 94 – 101, 139.
- Xu Wenkai, Lang Ping, Li Daoliang. Lightweight LIS – YOLO model for multi-target fish instance segmentation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(10): 94 – 101, 139. (in Chinese)
- [18] 刘星宇, 王芳, 任力生. 基于改进 YOLO 11n 的低光照图像增强下夜间肉牛行为识别方法[J]. 农业工程学报, 2025, 41(19): 176 – 184.
- Liu Xingyu, Wang Fang, Ren Lisheng. Nighttime beef cattle behavior recognition method based on improved YOLO 11n under low-light image enhancement[J]. Transactions of the CSAE, 2025, 41(19): 176 – 184. (in Chinese)
- [19] 郑荣才, 谭鼎文, 徐青, 等. 基于改进 YOLO v7 的鲑鱼检测模型轻量化研究[J]. 农业机械学报, 2024, 55(11): 132 – 139.
- Zheng Rongcai, Tan Dingwen, Xu Qing, et al. Lightweight salmon detection model based on improved YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 132 – 139. (in Chinese)
- [20] Zhang X, Song Y Z, Song T T, et al. AKConv: convolutional kernel with arbitrary sampled shapes and arbitrary number of parameters[PP/OL]. V3. arXiv(2024 – 07 – 22) [2026 – 07 – 16]. <https://doi.org/10.48550/arXiv.2311.11587>.
- [21] Wu G, Jiang J, Jiang K, et al. DSwinIR: rethinking window-based attention for image restoration[PP/OL]. V3. arXiv(2025 – 12 – 28) [2026 – 01 – 16]. <https://arxiv.org/abs/2504.04869>.
- [22] Ouyang D, He S, Zhang G, et al. Efficient multi-scale attention module with cross-spatial learning[C]//ICASSP 2023—2023 IEEE International Conference on Acoustics, Speech and Signal Processing. Rhodes Island: IEEE, 2023: 1 – 5.
- [23] Liu S, Qi L, Qin H, et al. Path aggregation network for instance segmentation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 8759 – 8768.

[29] 邢洁洁,张锐,吴鹏,等.海南热区砖红壤颗粒离散元仿真模型参数标定[J].农业工程学报,2020,36(5):158-166.
Xing Jiejie, Zhang Rui, Wu Peng, et al. Parameter calibration of discrete element simulation model for laterite particles in Hainan hot region[J]. Transactions of the CSAE, 2020, 36(5): 158-166. (in Chinese)

[30] 王宪良,钟晓康,耿元乐,等.基于离散元非线性弹塑性接触模型的免耕土壤参数标定[J].农业工程学报,2021,37(23):100-107.
Wang Xianliang, Zhong Xiaokang, Geng Yuanle, et al. Construction and parameter calibration of nonlinear elastoplastic discrete element model for no-tillage soil[J]. Transactions of the CSAE, 2021, 37(23): 100-107. (in Chinese)

[31] Mohammadi M, Karparvarfard S H, Razavizadeh N, et al. Simulation of interaction between soil and rotary tiller to predict the power consumption and investigation of surface soil mixing[J]. Soil and Tillage Research, 2025, 252: 106626.

[32] Li W, Li W, Cheng J, et al. Optimization design and experiment of ginger rhizome separation device based on edem-recurdyn software[J]. Smart Agricultural Technology, 2025, 12: 101382.

[33] 张佳喜,郑亚鹏,张虎,等.液压驱动链式农田捡石机设计与试验[J].农业机械学报,2026,57(5):206-218.
Zhang Jiaxi, Zheng Yapeng, Zhang Hu, et al. Design and experiment of hydraulic driven chain type field stone picker[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(5): 206-218. (in Chinese)

[34] 中国农业机械化科学研究院.农业机械设计手册:上册[M].北京:中国农业科学技术出版社,2007.

[35] 王法安,倪畅,张兆国,等.三七收获机挖掘铲减阻特性分析与试验[J].农业机械学报,2024,55(7):179-190,199.
Wang Fa'an, Ni Chang, Zhang Zhaoguo, et al. Analysis and experiment of drag reduction characteristics of excavating blade for ginseng harvester[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(7): 179-190, 199. (in Chinese)

[36] 付善灿,王显明,常敬梓,等.基于离散元法的滩涂埋栖贝类仿生挖掘铲设计与试验[J].农业机械学报,2026,57(11):134-145.
Fu Shancan, Wang Xianming, Chang Jingzi, et al. Design and experiment of bionic digging shovel for tidal flat burrowing shellfish based on discrete element method[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(11): 134-145. (in Chinese)

[37] Tagar A A, Adamowski J, Memon M S, et al. Soil fragmentation and aggregate stability as affected by conventional tillage implements and relations with fractal dimensions[J]. Soil and Tillage Research, 2020, 197: 104494.

~~~~~

(上接第 53 页)

[24] 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)

[25] Ren S, He K, Girshick R, et al. Faster R- CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.

[26] 朱明,汪荣,万鹏,等.基于 YOLO v8- DBCS 的循环水养殖环境下大口黑鲈异常体表特征检测[J].华中农业大学学报,2026,45(2):269-279.  
Zhu Ming, Wang Rong, Wan Peng, et al. Detecting characteristics of abnormal body surface in *Micropterus salmoides* under recirculating aquaculture systems based on YOLO v8- DBCS[J]. Journal of Huazhong Agricultural University, 2026, 45(2): 269-279. (in Chinese)

[27] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[C]// Computer Vision-ECCV 2018. Cham: Springer, 2018: 3-19.

[28] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 7132-7141.

[29] Yu Z, Huang H, Chen W, et al. YOLO- FaceV2: a scale and occlusion aware face detector[J]. Pattern Recognition, 2024, 155: 110714.