

doi:10.6041/j.issn.1000-1298.2023.11.026

# 基于改进 YOLO v4 的笼养蛋鸭行为实时识别方法

谷月 王树才 严煜 衡一帆 龚东军 唐诗杰

(华中农业大学工学院, 武汉 430070)

**摘要:** 蛋鸭行为模式是判断笼养鸭养殖过程中健康状况及福利状态的重要指标,为了通过机器视觉实现识别蛋鸭多行为模式,提出了一种基于改进 YOLO v4 ( You only look once) 的目标检测算法,不同的行为模式为蛋鸭的养殖管理方案提供依据。本文算法通过更换主干特征提取网络 MobileNetV2,利用深度可分离卷积模块,在提升检测精度的同时降低模型参数量,有效提升检测速度。在预测输出部分引入无参数的注意力机制 SimAM 模块,进一步提升模型检测精度。通过使用本文算法对笼养蛋鸭行为验证集进行了检测,优化后模型平均精度均值达到 96.97%,图像处理帧率为 49.28 f/s,相比于原始网络模型,平均精度均值及处理速度分别提升 5.03% 和 88.24%。与常用目标检测网络进行效果对比,改进 YOLO v4 网络相较于 Faster R - CNN、YOLO v5、YOLOX 的检测平均精度均值分别提升 12.07%、30.6% 及 2.43%。将本文提出的改进 YOLO v4 网络进行试验研究,试验结果表明本文算法可以准确地对不同时段的笼养蛋鸭行为进行记录,根据蛋鸭表现出的不同行为模式来帮助识别蛋鸭的异常情况,如部分行为发生异常时长或在异常时段发生等,从而为蛋鸭的养殖管理提供有价值的指导,为实现鸭舍自动化、智能化管理提供技术支持。

**关键词:** 笼养蛋鸭; 目标检测; 性能优化; 行为识别; YOLO v4

中图分类号: S24; S83 文献标识码: A 文章编号: 1000-1298(2023)11-0266-11

OSID: 

## Method for Real-time Behavior Recognition of Cage-reared Laying Ducks Based on Improved YOLO v4

GU Yue WANG Shucai YAN Yu HENG Yifan GONG Dongjun TANG Shijie

(College of Engineering, Huazhong Agricultural University, Wuhan 430070, China)

**Abstract:** The laying duck behavior pattern is an important indicator for assessing the health and welfare status of ducks in cage farming. An object detection algorithm based on improved YOLO v4 (you only look once) was proposed to identify multiple behavior patterns in laying ducks by machine vision, and the different behavior patterns provided a basis for duck breeding management scheme. By replacing the backbone feature extraction network MobileNetV2 and using the depthwise separable convolution, this algorithm can improve the detection accuracy while reducing the number of model parameters and effectively improving the detection speed. The parameter-free attention mechanism SimAM module was introduced in the prediction output part to further improve the model detection accuracy. By using this algorithm to detect the cage-reared laying duck behavior validation set, the mAP value of the optimized model reached 96.97% and the image processing frame rate was 49.28 f/s, which improved the mAP and processing speed by 5.03% and 88.24%, respectively, compared with the original network model. Comparing the effect with commonly used object detection networks, the improved YOLO v4 network improved the mAP values by 12.07%, 30.6% and 2.43% compared with Faster R - CNN, YOLO v5 and YOLOX, respectively. The improved YOLO v4 network proposed was experimentally studied. The results showed that this algorithm can accurately record the behaviors of cage-reared ducks at different time periods, helping identify abnormal conditions of ducks according to the different behavior patterns exhibited by ducks, such as some behaviors occurring for abnormal periods of time or during abnormal

收稿日期: 2023-04-17 修回日期: 2023-07-03

基金项目: 中央高校基本科研业务费专项资金项目(2662020GXPY005)

作者简介: 谷月(1994—),女,博士生,主要从事深度学习和机器视觉研究,E-mail: yuegu@webmail.hzau.edu.cn

通信作者: 王树才(1966—),男,教授,博士生导师,主要从事农产品智能化检测技术与装备研究,E-mail: wsc01@mail.hzau.edu.cn

periods. The research result can provide valuable guidance for duck breeding management and enable technical support for implementing automated and intelligent management of duck houses.

**Key words:** cage-reared laying ducks; object detection; performance optimization; behavior recognition; YOLO v4

## 0 引言

随着人们生活水平的提高,禽肉和禽蛋等需求正在不断增加,笼养鸭技术因其高效、环保等特点得到快速发展。相比于传统的水塘放养和散养模式,笼养方式具有更多的优势<sup>[1-3]</sup>,如减少水体污染、提升土地和饲料利用率,以及蛋鸭可全年产蛋并避免蛋品破损和污染。然而,将蛋鸭放入舍内笼养虽然技术优势显著,但仍存在问题。由于工作人员的走动,蛋鸭会受到惊吓、情绪不稳定,导致打斗、踩踏、躲避等行为,甚至产生强烈应激反应,影响蛋鸭健康,增加死淘率<sup>[4-5]</sup>。

为了实现精准畜禽养殖(Precision livestock farming, PLF),养殖场常引入传感器、图像监控等设备对畜禽个体(群体)进行实时信息获取,从而优化畜禽的生产环境<sup>[6-8]</sup>。对于家禽养殖,通过传感器检测鸡的体温、体重等生命体征信息可以综合判断鸡的生产性能<sup>[9]</sup>,还可以应用可穿戴式加速度传感器远程监测种鸡的日常行为<sup>[10]</sup>。随着计算机处理速度的加快,监控设备应用到动物饲养管理中,通过相机捕捉蛋鸡的姿态,能够准确识别出蛋鸡的站立、采食、抓挠、打架等行为<sup>[11]</sup>。这些行为可以帮助判定鸡群的聚集、分散等行为,进而判断其热舒适度<sup>[12-15]</sup>。利用机器视觉及深度学习技术,根据鸡冠颜色或鸡的行为特征等信息可以判断健康状况<sup>[16-18]</sup>。

动物行为可以作为其对环境需求和福利状态的重要指标<sup>[19]</sup>,通过记录、观察维持行为<sup>[20]</sup>和异常行为<sup>[21]</sup>,协助制定科学的饲养管理制度,以满足动物饲养过程中所需的福利要求。目前,对于鸡的行为识别和健康检测的研究较为丰富,技术也更成熟。然而,水禽笼养方面的研究仍有不足,不舒适的生活状态会导致蛋鸭食欲下降、精神萎靡、生长缓慢,进而影响产能。提升笼养鸭的福利养殖水平可以提高生存率,特别是在大规模高密度饲养蛋鸭时,应该时刻关注蛋鸭的生存状态。本文应用机器视觉技术对笼养鸭的行为进行目标检测,可以在不接触蛋鸭的情况下,更加方便记录和研究水禽笼养后的生活习性,以期为蛋鸭笼养技术的推广提供理论支持,同时也为后续建立自动化、智能化鸭舍提供基础。

## 1 数据采集与预处理

### 1.1 试验环境与数据采集

本试验在湖北省某福利蛋鸭场中进行,试验蛋鸭养殖在4层H型层叠式鸭笼中,如图1所示,鸭笼尺寸为300 mm×450 mm×420 mm(长×宽×高),每笼饲养2只,4个鸭笼为一组,每层共计66组,鸭舍中有5排饲养架,共饲养约21 120只蛋鸭。



图 1 试验场地图

Fig. 1 Scene map of experimental site

鸭笼相背设置,正反鸭笼之间有送水管,每个笼位有一个乳头状饮水器,如图2所示,水源全天供应。在鸭笼配置方面,鸭笼为内推式笼门,且前方安装有料槽,饲养方式为每天投喂饲料3次,分别在07:00、11:00及16:00。鸭笼的底面为倾斜状,倾角为6°,以保证所产鸭蛋能够自动滚动到传送带上,且不会因撞击而破碎,每天定时转动传送带,收集鸭蛋。

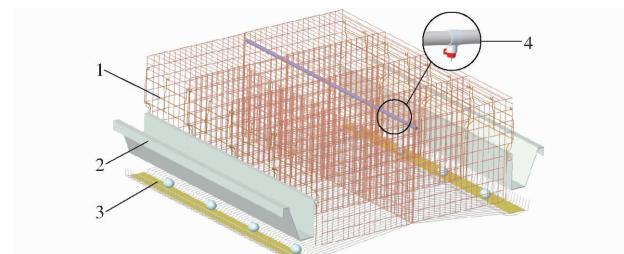


图 2 鸭笼外观示意图

Fig. 2 Schematic of duck cage appearance

1. 内推式笼门 2. 料槽 3. 鸭蛋传送带 4. 乳头状饮水器

为了采集蛋鸭日常的行为图像,需要在鸭舍中安装摄像装置,由于鸭舍中的照射光源为较昏暗的黄色白炽灯,因此选择采集图像的装置型号为DS-IPC-B4H-LFT,具有红外夜视功能以保证拍摄效果更清晰。拍摄位置距离笼网200~400 mm,布置镜头位于鸭笼中心线位置,并倾斜5°,如图3所示,采用录像的方式,记录200组共400只蛋鸭在笼中的生活行为,以确保该方法对不同蛋鸭的识别适应

性。拍摄时间为全天 24 h。

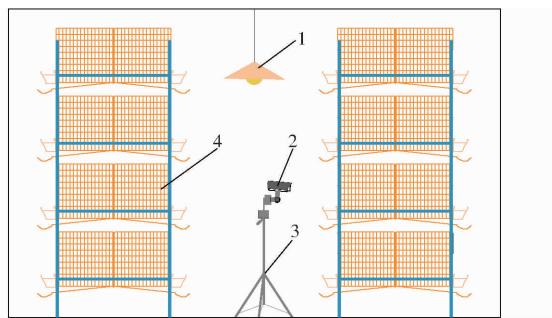


图 3 鸭舍及拍摄方式示意图

Fig. 3 Schematic of duck house and shooting method

1. 黄色白炽灯
2. 图像采集装置
3. 固定图像采集装置三脚架
4. 层叠式鸭笼

## 1.2 数据预处理

笼养鸭数据集共定义 5 类行为,分别是休息、采食、梳羽、踩踏和互啄。行为的评价标准如表 1 所示,为方便标记,将名称分别简化为 rest、feed、comb、trample 和 peck。每一类中均需包含长相不同、光照不同、摄像位置不同的蛋鸭。将视频中相应行为所需片段,应用 PotPlayer 软件每秒截取 30 幅图像,共生成训练集 3 661 幅,验证集 300 幅。使用 Make Sense 标注网页对图像中的 5 种行为进行标注,并将结果保存为 XML 格式。

为了提高模型的泛化能力,必须对原有数据集进行数据增强预处理,本文使用的数据增强处理方法包含马赛克增强、图像模糊处理、滤波、缩放、翻

转、色域变换等。对数据集随机洗牌,每幅图像中包含至少一种行为。

表 1 笼养鸭行为评判标准

Tab. 1 Evaluation criteria of cage-reared duck behavior

行为名称	评判标准	样本量
休息 (rest)	蛋鸭身体趴卧在笼中	1 044
采食 (feed)	从鸭喙靠近料槽到头伸进料槽进食	1 559
梳羽 (comb)	用鸭喙梳理自身羽毛	1 237
踩踏 (trample)	至少一只鸭掌踩踏到另一只身体	1 104
互啄 (peck)	蛋鸭用鸭喙啄咬另一只或互相啄咬	1 032

## 2 蛋鸭行为识别

### 2.1 YOLO v4 目标检测算法原理

本文利用 YOLO v4 网络对笼养蛋鸭的 5 种日常行为进行识别。YOLO v4 目标检测算法由 CSPDarknet53、SSP、PANet 网络组成,如图 4 所示。

CSPDarknet53 为主干网络 (Backbone), 提取图像的特征供后期网络使用<sup>[22]</sup>。CSPDarknet53 中卷积大小为  $3 \times 3$ , 对输入图像  $416 \times 416 \times 3$  的尺寸进行压缩, 并将通道数进行扩张, 最终得到 3 个特征层, 分别为  $52 \times 52 \times 256$ 、 $26 \times 26 \times 512$  及  $13 \times 13 \times 1024$ 。

SPP (Spatial pyramid pooling) 网络<sup>[23]</sup>作为颈部网络 (Neck) 用于增加网络的感受野, 该网络使用  $5 \times 5$ 、 $9 \times 9$  和  $13 \times 13$  的 3 种不同尺度的池化以获得更丰富的特征, 如图 5 中 3 种颜色的窗口, 对特征

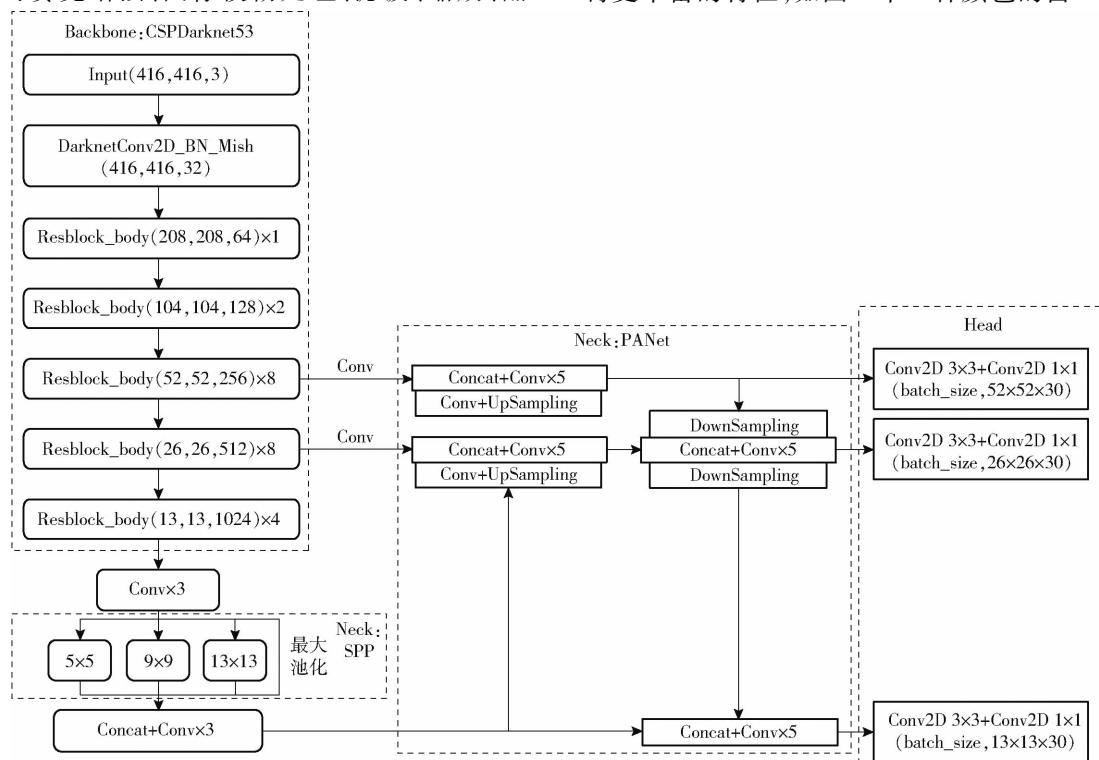


图 4 YOLO v4 网络结构图

Fig. 4 Structure diagram of YOLO v4 network

图进行池化,将分别得到的结果合并得到固定长度的输出。SPP 网络提高了模型处理图像的尺度不变性(Scale-invariance)和降低了过拟合(Over-fitting)。

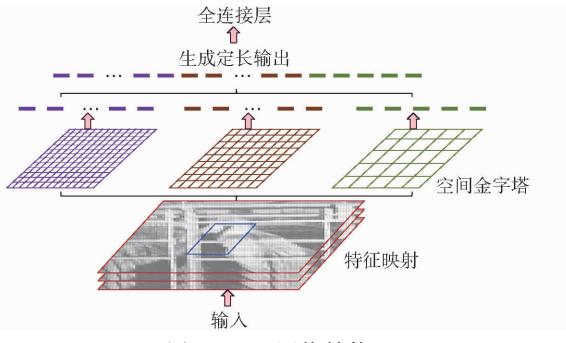


Fig. 5 Structure of SPP network

使用 PANet(Path aggregation network)能够准确地保留空间信息,该网络有助于正确定位像素点,以便于更好地利用提取的特征<sup>[24]</sup>。当图像经过神经网络的各个层时,特征的复杂度增加,同时图像的空间分辨率降低。PANet 使用自适应特征池化将相邻的层拼接相加进行预测,获得较好的预测结果。

Head 部分与 YOLO v3 网络相同,对通过以上步骤获取到的特征进行预测<sup>[25]</sup>,图 4 中的 Head 部分由  $3 \times 3$  的卷积进行特征整合,用  $1 \times 1$  的卷积将获取的特征转化成预测结果,最终完成目标检测。

## 2.2 YOLO v4 目标检测算法优化

### 2.2.1 MobileNetV2 网络引入

在 YOLO v4 提取特征过程中,由于结构的复杂导致权重参数较多,加重了计算负担,为了提高在实际应用中的运算速度,替换更为轻量级的 MobileNetV2<sup>[26]</sup>作为主干特征提取网络。

MobileNet 系列网络提出了深度可分离卷积(Depthwise separable convolution),与标准卷积(图 6)相比,深度可分离卷积参数量减小,进而降低计算量。标准卷积中,输入图像维数为  $M$ ,卷积核尺寸记为  $D_k$ ,输出宽度、高度及维度为  $D_w$ 、 $D_h$  及  $N$ ,则总参数量(Params)计算公式及运算量(Computation)为

$$P_{\text{params}} = D_k^2 MN \quad (1)$$

$$C_{\text{computation}} = D_k^2 MND_w D_h \quad (2)$$

式中  $P_{\text{params}}$  —— 总参数量  $C_{\text{computation}}$  —— 运算量

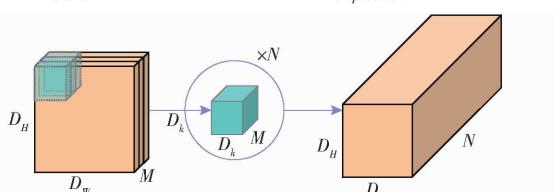


图 6 标准卷积模块

Fig. 6 Standard convolution block

图 7 为深度可分离卷积所需使用的参数,则总

参数量计算公式及运算量为

$$P_{\text{params}} = D_k^2 M + MN \quad (3)$$

$$C_{\text{computation}} = D_k^2 MD_w D_h + MND_w D_h \quad (4)$$

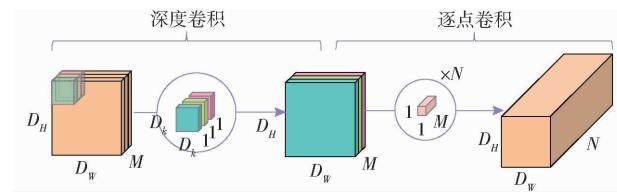


图 7 深度可分离卷积模块

Fig. 7 Depthwise separable convolution block

由此可计算出相较于普通卷积网络,深度可分离卷积的参数数量和运算量均下降为原来的  $(1/N + 1/D_k^2)$ ,模型运行速度可以大幅增加。

MobileNetV2 的瓶颈层(Bottleneck),不同于传统的残差模块(Residual block),如图 8a 所示,先通过  $1 \times 1$  卷积降通道,再通过  $3 \times 3$  和  $1 \times 1$  卷积恢复通道,并与输入相加。MobileNetV2 提出逆残差模块(Invresidual block),如图 8b 所示,通过  $1 \times 1$  卷积提升通道数的扩展层(Expansion convolution),再利用  $3 \times 3$  的深度可分离卷积方法(Depthwise convolution)减少计算量,最后用  $1 \times 1$  卷积降低通道数的投影层(Projection convolution)。具体方法如图 9 所示。

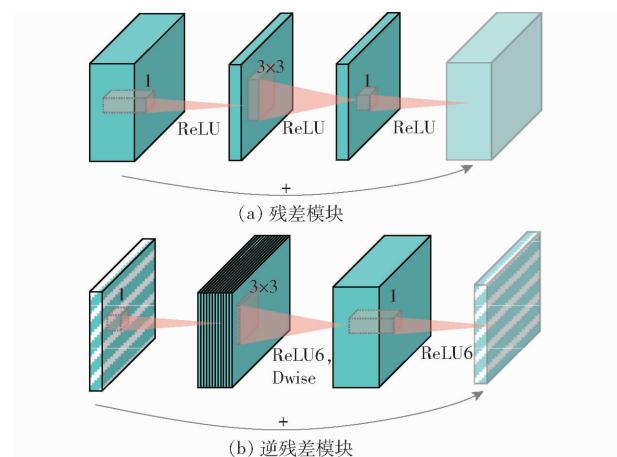


图 8 瓶颈层关键组件

Fig. 8 Critical components of bottleneck layer

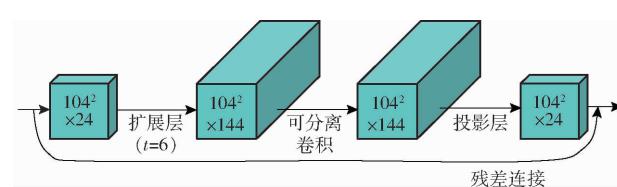


图 9 残差模块实例

Fig. 9 Example of inverted residual block

将部分 MobileNetV2 网络应用于 YOLO v4 目标检测网络的主干特征提取位置,网络结构如表 2 所示。

### 2.2.2 注意力机制引入

YOLO v4 目标检测算法的 Head 部分,输出 3 个

表 2 MobileNetV2 网络结构

Tab. 2 Structure of MobileNetV2

输入	操作	扩展因子 $t$	输出 $c$	重复 $n$	步长 $s$
$416^2 \times 3$	Conv2D		32	1	2
$208^2 \times 32$	bottleneck	1	16	1	1
$208^2 \times 16$	bottleneck	6	24	2	2
$104^2 \times 24$	bottleneck	6	32	3	2
$52^2 \times 32$	bottleneck	6	64	4	2
$26^2 \times 64$	bottleneck	6	96	3	1
$26^2 \times 96$	bottleneck	6	160	3	2
$13^2 \times 160$	bottleneck	6	320	1	1
$13^2 \times 320$	Conv2D	1 $\times$ 1	1 280	1	1

尺度的检测结果,在输出结果之前加入了注意力机制,以增加 Head 部分对物体检测结果影响的权重。在本研究中,引入 SimAM 注意力机制<sup>[27]</sup>(图 10c),在维持原始网络参数的情况下为特征图推理增加注意力权重。通常,注意力机制分为通道注意力机制<sup>[28]</sup>(图 10a)、空间注意力机制<sup>[29]</sup>(图 10b)以及空间和通道相结合的注意力机制<sup>[30]</sup>。

SimAM 方法直接通过能量函数来计算 3 维注

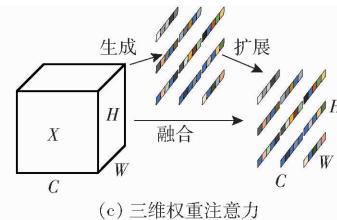
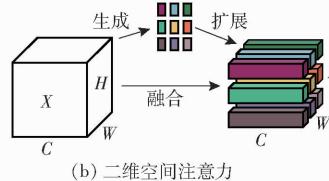
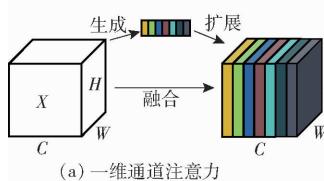


图 10 不同维度的注意力机制

Fig. 10 Attention mechanism of different dimensions

### 2.2.3 优化器选择

在反向传播过程中,为了让损失函数值尽快逼近全局最小,本文选用自适应学习率的优化器 Adam(Adaptive moment estimation)<sup>[31]</sup>,将梯度的一阶矩估计(First moment estimation)及二阶矩估计(Second moment estimation)共同利用,其中一阶矩估计为梯度的均值,代表模型更新方向,二阶矩估计为梯度中心化的方差,代表步长的控制,不依赖初始学习率的设置,可以自动控制学习率的步长和梯度方向,避免进入局部最优点。一阶矩估计  $m_t$  和二阶矩估计  $V_t$  分别为

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (7)$$

$$V_t = \beta_2 V_{t-1} + (1 - \beta_2) g_t^2 \quad (8)$$

式中  $\beta_1$ —一阶矩估计衰减率

$\beta_2$ —二阶矩估计衰减率

$g_t$ —梯度

Adam 参数的更新公式为

$$w_{t+1} = w_t - \alpha \frac{m_t}{\sqrt{V_t}} = w_t - \alpha \frac{\beta_1 m_{t-1} + (1 - \beta_1) g_t}{\sqrt{\beta_2 V_{t-1} + (1 - \beta_2) g_t^2}} \quad (9)$$

注意力权重。能量函数  $E$  的计算方法为

$$E = \frac{4(\sigma^2 + \lambda)}{(k - \mu)^2 + 2\sigma^2 + 2\lambda} \quad (5)$$

其中

$$\lambda = 1 \times 10^{-4}$$

$$\mu = \frac{1}{M} \sum_{i=1}^M x_i$$

$$\sigma^2 = \frac{1}{M} \sum_{i=1}^M (x_i - \mu)^2$$

式中  $\mu, \sigma^2$ —平均值、方差

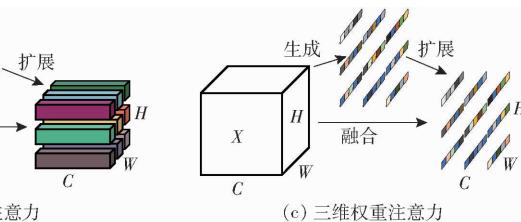
$k$ —通道内神经元数

$\lambda$ —常数

为了使特征的权重更加全局化,增强的输出特征  $\hat{X}$  为

$$\hat{X} = \text{sigmoid}\left(\frac{1}{E}\right) \odot X \quad (6)$$

其中,  $X$  是输入特征,  $\odot$  是点乘运算。较大的  $E$  意味着与周围神经元的区别更大,重要性更高,神经元的重要性为  $1/E$ ,特征矩阵由得到的神经元的重要性来增强。



式中  $\alpha$ —学习率  $w_t$ —更新前参数

相比于传统的 SGD(Stochastic gradient descent)优化器,应用 Adam 优化器时,训练集的损失曲线收敛更快,能够在较短时间内得到更优的训练效果,如图 11 所示。

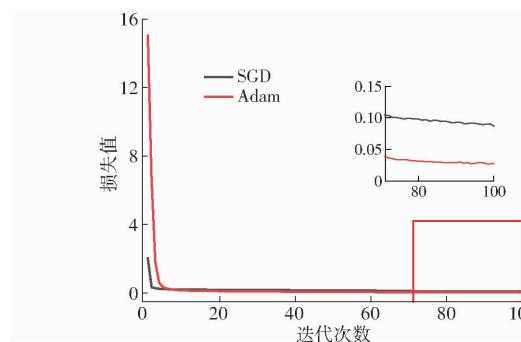


图 11 不同优化器训练收敛速度对比

Fig. 11 Comparison of convergence speed of different optimizer training

### 2.2.4 试验参数设置及迁移学习引入

在监督学习中,需要大量的标注数据才能获得更好的模型表现,而本文的数据样本有限,因此在深度学习训练前引入迁移学习,提高训练模型的准确

率。本文试验所提到的模型,均在训练中增加了 VOC 数据集的预训练权重。数据集训练共包含 100 个迭代轮次。前 50 轮次中批量大小(batch\_size)设置为 64, 学习率为 0.01, 从 50 到 100 轮次, batch\_size 减为 16, 学习率调整为 0.0001。针对笼养蛋鸭行为识别数据集, 迁移学习与非迁移学习的网络损失值变化曲线如图 12 所示。

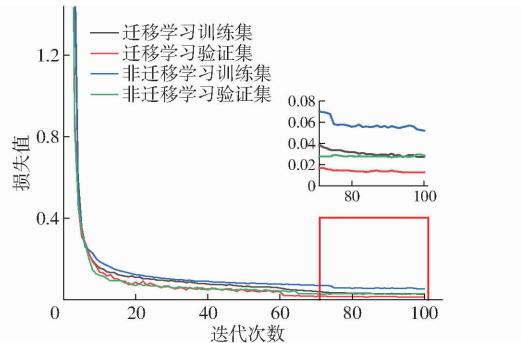


图 12 迁移学习与非迁移学习训练损失值曲线对比

Fig. 12 Comparison of training loss curves for transfer learning and non-transfer learning

由图 12 可知, 在笼养蛋鸭行为检测模型训练的初始阶段, 训练集和验证集的损失值曲线收敛很快, 其中引入 VOC 数据集预训练权重的网络训练损失值下降速度更快。随着训练的进行, 损失值曲线的斜率逐渐变慢, 整体损失曲线趋于收敛, 且引入迁移学习的训练集与验证集的损失值更小, 模型训练效果更好。

### 2.3 试验环境

试验基于深度学习框架 Pytorch 在 Dell T5810 塔式图形处理工作站上完成, 计算机系统为 Windows 10 专业版操作系统, 搭载 Intel 至强 3.70 GHz W-2145 处理器, 内存容量和显卡型号分别为 64 GB、2080Ti。

### 2.4 模型评价

为了评价改进 YOLO v4 模型对笼养蛋鸭行为的检测效果, 选取精确率(Precision)、召回率(Recall)、F1 值、平均精度(AP)、平均精度均值(mAP)、模型参数量以及识别帧率作为评价指标, 综合对比得到改进网络性能的优越性。

## 3 结果与分析

为验证改进模型对蛋鸭行为的识别效果, 与常用目标检测网络对比识别性能, 对不同时间段蛋鸭行为规律进行分析, 进而验证改进目标检测网络在实际生产中的应用效果。

### 3.1 不同目标检测网络性能对比试验

随着深度学习技术的快速发展, 目标检测的方法多种多样, 但对于不同的识别对象, 不同算法的表

现各不相同。为探究优化后的笼养蛋鸭行为识别模型较其他常用识别算法的优劣性, 训练常用目标检测网络包括 Faster R-CNN、YOLO v4、YOLO v5 及 YOLOX, 与本文改进 YOLO v4 对蛋鸭行为识别效果、性能作进一步对比分析。以上算法的训练超参数与 YOLO v4 模型保持一致, 利用分别得到的最优模型针对验证集数据集进行测试, 对 5 种行为的识别精确率、召回率、F1 值和平均精度如图 13 及图 14 所示, 得到相应的参数量、mAP 以及图像处理速度见表 3 及图 15, 用以综合评判各方法的识别效果。

	梳羽	86.98	88.21	87.59	91.75
Faster R - CNN	采食	53.06	83.87	65.00	91.36
	互啄	55.10	87.10	67.50	69.79
	休息	77.84	92.64	84.59	93.51
	踩踏	52.04	87.93	65.38	86.24
YOLO v4	梳羽	81.01	98.58	88.94	97.29
	采食	87.84	90.32	89.07	95.29
	互啄	64.58	100	78.48	98.75
	休息	84.69	78.75	82.15	79.42
YOLO v5	踩踏	79.17	98.28	87.69	90.91
	梳羽	76.52	89.15	82.35	80.86
	采食	76.60	58.06	66.06	51.22
	互啄	100	87.10	93.10	49.96
YOLOX	休息	88.76	92.02	90.36	95.09
	踩踏	88.89	96.55	92.56	94.12
	梳羽	85.91	89.15	87.50	95.29
	采食	91.70	93.55	92.61	98.37
改进 YOLO v4	互啄	84.38	87.10	85.71	88.75
	休息	91.04	93.56	92.28	92.27
	踩踏	96.55	96.55	96.55	98.68
	梳羽	92.52	93.40	92.96	97.81
	采食	91.27	92.74	92.00	97.12
	互啄	88.24	96.77	92.31	94.26
	休息	96.10	90.80	93.38	96.75
	踩踏	98.15	91.38	94.64	98.91
模型	行为	精确率/%	召回率/%	F1 值/%	平均精度/%
		%	%	%	%

图 13 不同目标检测网络识别精确率、召回率、F1 值和平均精度结果色阶

Fig. 13 Color-coded result of recognition precision, recall, F1-score and AP results for different object detection networks

图 13 中通过绿、黄、红不同颜色过渡来表示数值大小, 数值越大显示颜色越偏向绿色, 数值越小则越偏向红色, 中间值为黄色, 依此即可直观观测每个模型的检测结果。改进 YOLO v4 网络色阶均在黄色和绿色之间, 对 5 种行为识别的精确率只有互啄行为略低于其他行为识别效果, 召回率全部大于 90%, 综合精确率与召回率表现的 F1 值均为绿色区域, 相比于其他网络对蛋鸭行为检测效果更优越, 平

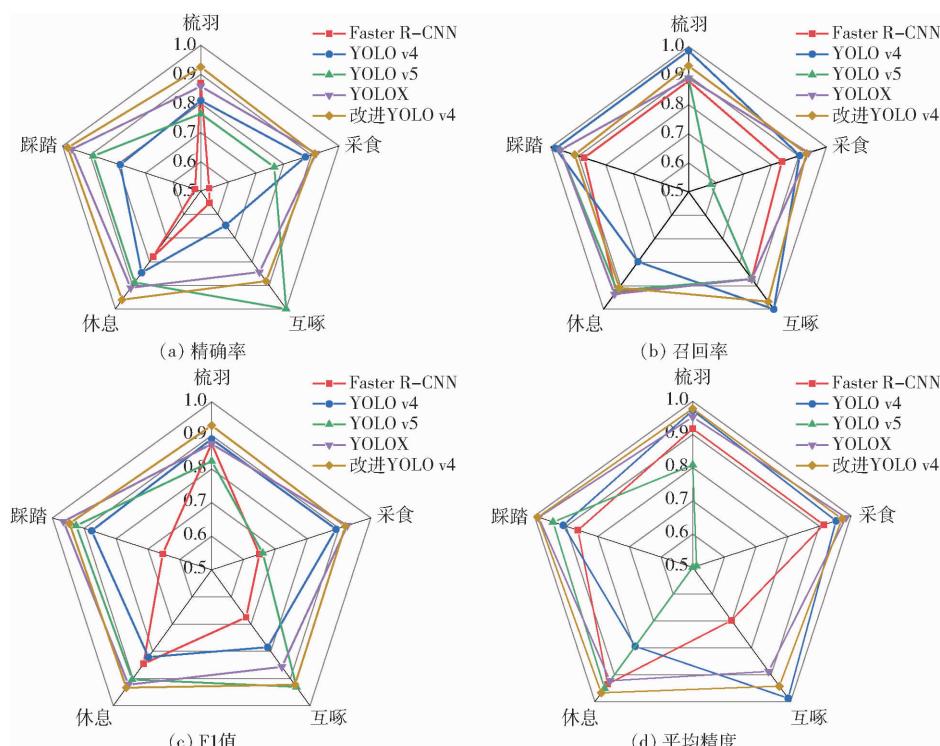


图 14 不同目标检测网络识别结果雷达图

Fig. 14 Radar plots of recognition results for different object detection networks

表 3 不同目标检测网络性能对比结果

Tab. 3 Performance comparison results of different object detection networks

模型	参数量	mAP/%	帧率/(f·s <sup>-1</sup> )
Faster R - CNN	$1.26 \times 10^8$	86.53	14.71
YOLO v4	$5.22 \times 10^7$	92.33	26.18
YOLO v5	$7.06 \times 10^6$	74.25	40.49
YOLOX	$8.94 \times 10^6$	94.67	52.01
改进 YOLO v4	$1.08 \times 10^7$	96.97	49.28

均精度更高。

如图 14 所示,应用不同网络识别蛋鸭行为的模型评价用雷达图表示,每个雷达图包含 5 个特征点,即 5 种行为,2 个相邻轴相差 0.1 个单位,每种颜色围成的五边形越靠近中心表示精确率、召回率、F1 值或平均精度越低。改进 YOLO v4 网络在 4 个评价指标的雷达图中均趋近于正五边形,即模型对 5 种行为的识别效果较平均,且数值接近 1;其他模型的雷达图所围形状不规则,且数值靠近雷达图中心,表示该模型对部分行为识别准确度差。

由表 3 可以得到,不同网络所产生的参数量不同、检测速度不同,综合平均检测精度指标,优化后模型的平均精度均值达到 96.97%,较 YOLO v4 网络提升 5.03%,相比于 Faster R - CNN、YOLO v5、YOLOX 网络,分别提升 12.07%、30.6% 及 2.43%,图像处理帧率为 49.28 f/s,检测速度较 YOLO v4 网络提升 88.24%,本文模型参数量较少、更轻量化,

在保持较高检测精度时,可以满足在养殖场内实时监控的需求,可为鸭舍自动化、智能化管理提供技术支持。

### 3.2 改进 YOLO v4 网络对笼养鸭行为识别结果

应用 Faster R - CNN、YOLO v4、YOLO v5、YOLOX 及改进 YOLO v4 网络对部分鸭舍采集图像进行识别效果对比,得到的结果如图 15 所示。

YOLO v4 网络检测效果较准确,但在图 15c 的第 2 行中忽略了其中一只休息的蛋鸭;YOLO v5 网络的识别效果最差,特别是互啄行为和采食行为存在较多漏检,进而对应图 14b 的召回率较低;YOLOX 网络同样存在对休息行为的漏检现象;而 Faster R - CNN 网络虽然没有漏检现象,但识别框并不准确,没有完整框选出蛋鸭行为。改进后 YOLO v4 目标检测网络的检测定位更精准,置信度更高,即对笼养鸭的行为识别更准确。

### 3.3 不同时段蛋鸭行为分析

为了分析不同时段蛋鸭行为发生的规律,试验随机选取 6 d 日常活动视频进行分析,每日从 01:00 开始,每间隔 2 h 左右捕捉视频 10 min,记录行为发生时间总和(每秒视频分成 30 f,通过每种行为发生帧数,记录行为发生总时间),如表 4 及图 16 所示。表 4 中每个空白格中填入 6 d 某时段某行为的持续时间,并以“|”分割。利用改进 YOLO v4 网络对 72 段视频进行蛋鸭行为识别,分析蛋鸭行为规律如下:每天 19:00 到次日 05:00 为蛋鸭陆续休息时间,此

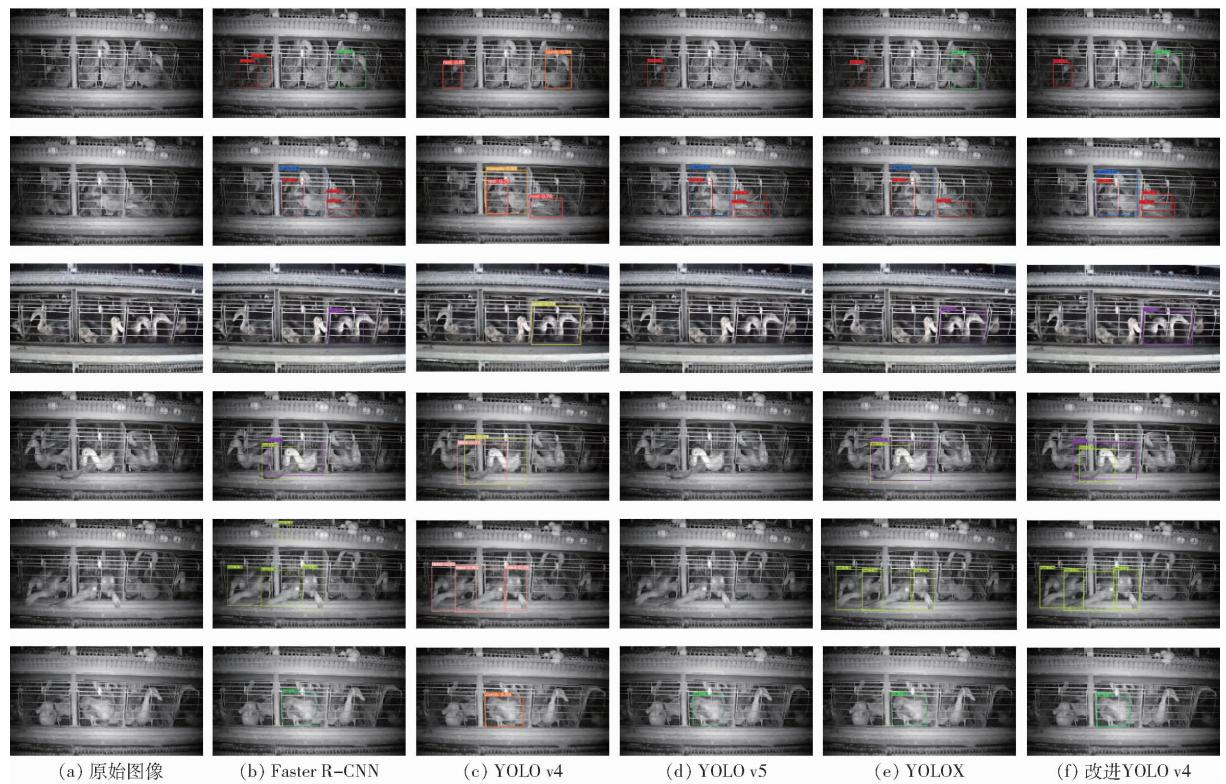


图 15 不同目标检测网络对笼养鸭行为识别结果

Fig. 15 Recognition results of cage-reared duck behavior based on different object detection networks

表 4 不同时段蛋鸭行为发生时长

Tab. 4 Duration of cage-reared duck behavior during different time periods

s

时段	休息	采食	梳羽	踩踏	互啄
01:00—01:10	2010 1400 6071	0 0 0	3 0 18	0 3 2	5 0 0
	1800 1530 12200	0 0 0	72 0 0	0 0 17	0 0 0
03:00—03:10	1521 2410 18671	3 0 0	184 12 0	8 0 21	3 0 0
	2128 1830 2151	0 0 0	0 16 0	0 0 0	0 8 0
05:00—05:10	0 0 87	1217 862 1402	20 34 3	0 0 0	12 0 3
	409 600 0	874 908 1107	69 21 5	2 0 0	0 2 0
07:00—07:10	966 59 613	2425 1921 1943	7 88 56	0 57 0	24 0 11
	184 0 600	2070 2269 2178	50 40 95	0 0 0	3 0 5
09:00—09:10	1135 1006 602	0 0 6	148 412 69	174 0 129	5 10 24
	0 392 0	0 3 0	7 23 358	0 21 15	0 14 0
11:00—11:10	600 0 102	2467 3008 1860	0 10 357	12 0 24	5 0 0
	84 0 0	2800 2320 1989	350 0 36	0 2 0	3 0 0
13:00—13:10	1843 1807 1520	0 4 0	42 0 105	0 0 0	0 2 0
	2071 2400 1200	12 0 0	86 0 315	6 12 0	0 0 2
15:00—15:10	1200 1625 1845	62 0 58	54 86 24	17 11 0	5 0 8
	1828 1130 720	0 0 689	308 89 203	0 0 5	10 6 17
17:00—17:10	2214 1800 1570	24 57 4	12 485 393	0 0 2	24 15 0
	2104 1748 1856	21 146 234	247 58 368	0 14 26	0 0 8
19:00—19:10	0 1547 433	0 0 0	257 16 62	14 2 0	0 0 3
	600 1740 1800	0 0 0	87 175 142	0 0 0	0 0 0
21:00—21:10	1950 1740 1800	0 0 0	12 0 0	0 0 5	0 0 0
	2710 3600 1920	0 0 0	3 0 0	0 0 0	0 0 13
23:00—23:10	2004 2455 3168	0 0 0	2 0 0	0 2 0	0 0 0
	2295 1932 2580	0 0 0	8 0 0	0 0 13	0 17 0

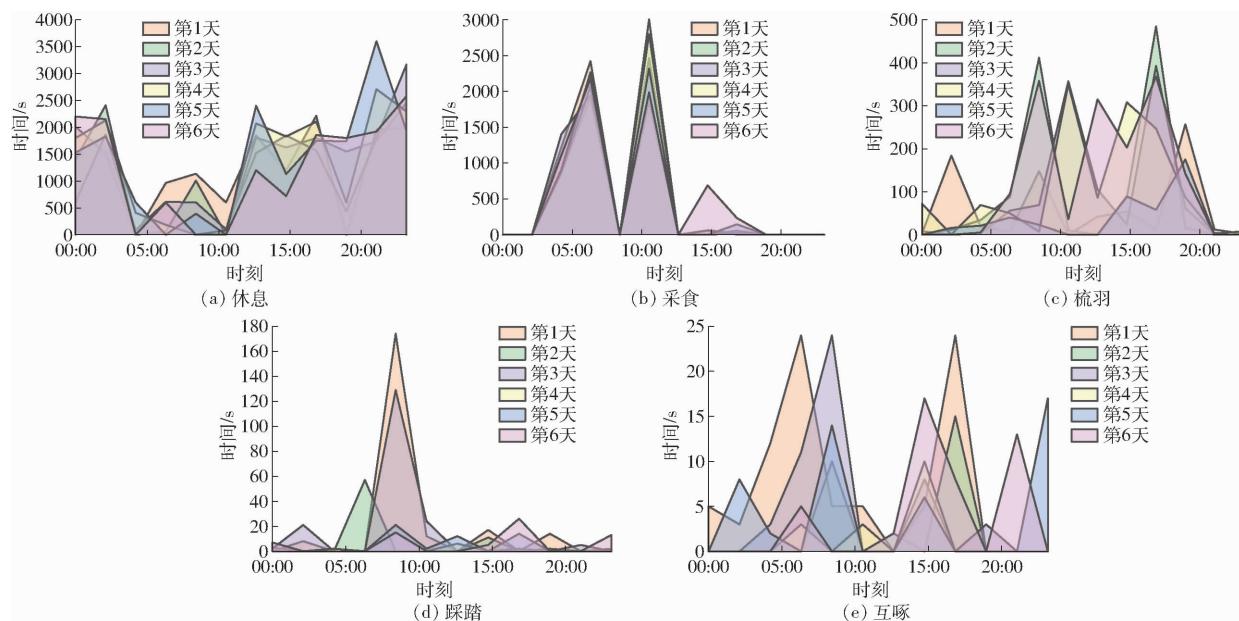


图 16 不同行为在各时段发生时长面积图

Fig. 16 Area charts of duration of different behaviors in different periods

时鸭舍相对安静,蛋鸭较少发生踩踏、互啄及采食行为,偶尔存在清醒的蛋鸭有梳羽行为;05:00 苏醒后开始采食,梳羽行为时间也略有增多;每天 07:00—11:00 为投放饲料时间,蛋鸭会集中采食,然后会进行梳羽行为,保持羽毛的干燥及整洁;上午工作人员会对鸭舍进行巡检及清扫工作,蛋鸭由于胆小敏感,会产生恐惧情绪,在狭小空间躲避过程中,以及抢占地盘过程中,易发生踩踏及互啄现象;11:30—13:00 为员工休息时间,此时间段内禽舍较安静,蛋鸭有较长时间在休息;下午同样有员工进鸭舍工作,鸭舍环境又会变得较吵闹、混乱,同样会有踩踏及互啄行为发生;傍晚时分,蛋鸭情绪渐渐平静,一部分梳理羽毛,防止羽毛潮湿和污染,一部分蛋鸭进入休息状态。

图 16 为不同的蛋鸭行为在各时段发生时长面积图,可以反映蛋鸭行为发生规律,如图 16a 所示,蛋鸭在夜间及中午有大段睡眠时间,在上午通常有较少休息行为;上午及下午鸭舍环境较混乱,梳羽、踩踏及互啄行为常发生,如图 16c、16d、16e 所示;蛋鸭进食时间比较集中,通常在睡觉苏醒后及投喂后,在图 16b 中采食行为时间分配也有较强的一致性。通过 6 d 对蛋鸭生活习惯的观察,可以了解蛋鸭每天的行为规律,进而有助于判断蛋鸭健康状况,帮助优化环境和管理,通过监测发掘蛋鸭的行为发生的异常频次或时长,可以为它们提供更适宜的饲料、光照和温度,以促进蛋鸭的生产力和保持蛋鸭健康成长,为蛋鸭福利养殖提供科学依据。

### 3.4 讨论

笼养蛋鸭舍内背景环境复杂、光照条件不均匀、

目标存在遮挡等因素均会对笼养鸭的行为检测准确度产生影响<sup>[32]</sup>,本文旨在利用改进 YOLO v4 目标检测算法识别笼养蛋鸭的休息、采食、梳羽、踩踏、互啄行为。通过试验验证,本文算法对于识别蛋鸭行为具有较高的准确率和鲁棒性。

本文采用具有红外夜视功能的设备对蛋鸭行为信息进行采集,以便在不同时间段和光照强度状态下观察和分析蛋鸭更丰富的行为<sup>[8]</sup>。相较于传统的图像处理方法,本研究采用基于深度学习的目标检测算法,能够更好地捕捉蛋鸭行为的丰富特征,从而实现更高的识别准确率。更换主干特征提取网络的 YOLO v4 算法,具备更快的运算速度和更低的计算成本,从而可以实现对笼养蛋鸭行为的实时识别。

但本研究也存在一些局限性。本文的试验数据集较小,无法完全涵盖所有蛋鸭行为的变化和特征,后续研究可以进一步扩大数据集。并且,对于蛋鸭的其他行为识别研究,仍需要进一步扩展。未来的研究中,会挖掘更多的蛋鸭行为数据,并将识别模型部署在禽舍机器人上,进一步将家禽行为监测和识别技术应用到实际的养殖场中,保障家禽健康和提高生产效率。

## 4 结束语

提出了一种改进 YOLO v4 的目标检测模型,用于通过红外夜视设备捕捉图像识别笼养蛋鸭行为。更换主干特征提取网络为 MobileNetV2,通过深度可分离卷积模块,降低模型参数量,有效提升检测速度。同时,模型引入 SimAM 注意力机制,该机制不增加额外的参数,通过优化能量函数发现神经元的

重要性,进而推导出特征图的三维注意力权重。本研究提出的改进 YOLO v4 模型可以在较短时间内收敛模型损失曲线,同时提高检测精度和速度。试验结果表明,优化后模型的平均精度均值达到 96.97%,较 YOLO v4 网络提升 5.03%,图像处理帧

率为 49.28 f/s,检测速度提升 88.24%。应用改进目标检测网络记录不同时段蛋鸭行为发生时长,并依此分析了每日蛋鸭行为的规律及原因。这为鸭舍养殖过程中蛋鸭产生异常状况的识别提供了借鉴。

## 参 考 文 献

- [1] 陈开丰. 不同笼养条件下山麻鸭生产性能和生理状态比较分析[D]. 南昌: 江西农业大学, 2019.  
CHEN Kaifeng. Comparison of production performance and physiological status in Shan Partridge Duck under different cage conditions[D]. Nanchang: Jiangxi Agricultural University, 2019. (in Chinese)
- [2] 吴艳, 皮劲松, 李成凤, 等. 夏季四层层叠式笼养鸭舍环境参数测定与分析[J]. 中国家禽, 2019, 41(11): 32–36.  
WU Yan, PI Jinsong, LI Chengfeng, et al. Mensuration and analysis of environmental quality of layer house with four overlap cages in summer[J]. China Poultry, 2019, 41(11): 32–36. (in Chinese)
- [3] 匡伟, 鄒正林, 伍冠锁, 等. 蛋鸭笼养技术实践与研究进展[J]. 家禽科学, 2020(5): 54–56.  
KUANG Wei, XU Zhenglin, WU Guansuo, et al. Practice and improvement of cage rearing technique for laying duck [J]. Poultry Science, 2020(5): 54–56. (in Chinese)
- [4] 尉传坤. 蛋鸭笼养舍内环境因子分布及其与生产性能关系的研究[D]. 南京: 南京农业大学, 2017.  
WEI Chuankun. Study on the production performance of caged layer ducks in relation to in house environmental factors[D]. Nanjing: Nanjing Agricultural University, 2017. (in Chinese)
- [5] BERCKMANS D. General introduction to precision livestock farming[J]. Animal Frontiers, 2017, 7(1): 6–11.
- [6] 张宏鸣, 周利香, 李永恒, 等. 基于改进 MobileFaceNet 的羊脸识别方法研究[J]. 农业机械学报, 2022, 53(5): 267–274.  
ZHANG Hongming, ZHOU Lixiang, LI Yongheng, et al. Sheep face recognition method based on improved MobileFaceNet[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(5): 267–274. (in Chinese)
- [7] 刘龙申, 舒翠霓, 李波, 等. 基于 EfficientDet 的围产期母猪姿态识别[J]. 农业机械学报, 2022, 53(4): 271–279.  
LIU Longshen, SHU Cuini, LI Bo, et al. Recognition of perinatal sows' posture based on EfficientDet algorithm [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(4): 271–279. (in Chinese)
- [8] GU Yue, WANG Shuai, YAN Yu, et al. Identification and analysis of emergency behavior of cage-reared laying ducks based on YOLO v5[J]. Agriculture, 2022, 12(4): 485.
- [9] FANG P, WANG H Y, CHEN X, et al. A review on identifying and monitoring technology for individual hen information[C]// ASABE Annual International Meeting, 2017.
- [10] 李丽华, 刘志伟, 赵学谦, 等. 基于加速度传感器的本交笼种鸡个体行为监测与识别[J]. 农业机械学报, 2019, 50(12): 247–254.  
LI Lihua, LIU Zhiwei, ZHAO Xueqian, et al. Monitoring and identification of natural mating cage breeding chickens individual behavior based on acceleration sensor[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(12): 247–254. (in Chinese)
- [11] 李娜, 任昊宇, 任振辉. 基于深度学习的群养鸡只行为监测方法研究[J]. 河北农业大学学报, 2021, 44(2): 117–121.  
LI Na, REN Haoyu, REN Zhenhui. Research of behavior monitoring method of flock hens based on deep learning[J]. Journal of Hebei Agricultural University, 2021, 44(2): 117–121. (in Chinese)
- [12] ZANINELLI M, REDAElli V, LUZI F, et al. Development of a machine vision method for the monitoring of laying hens and detection of multiple nest occupations[J]. Sensors, 2018, 18(2): 132.
- [13] VICTOR B, NATAN B, ILAN H, et al. Automatic broiler temperature measuring by thermal camera [J]. Biosystems Engineering, 2020, 199: 127–134.
- [14] LI Guoming, HUI Xue, LIN Fei, et al. Developing and evaluating poultry preening behavior detectors via mask region-based convolutional neural network[J]. Molecules, 2020, 10(10): 1762.
- [15] 肖林芳. 基于双目视觉的笼养蛋鸡饮水采食行为感知方法研究[D]. 杭州: 浙江大学, 2018.  
XIAO Linfang. Study on eating and drinking behaviors perception of caged chicken based on binocular vision[D]. Hangzhou: Zhejiang University, 2018. (in Chinese)
- [16] 毕敏娜, 张铁民, 庄晓霖, 等. 基于鸡头特征的病鸡识别方法研究[J]. 农业机械学报, 2018, 49(1): 51–57.  
BI Minna, ZHANG Tiemin, ZHUANG Xiaolin, et al. Recognition method of sick yellow feather chicken based on head features[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(1): 51–57. (in Chinese)
- [17] 丁琛琛, 倪金鑫, 陈永欢, 等. 基于深度学习的病鸡识别系统开发[J]. 工业控制计算机, 2021, 34(1): 48–50.  
DING Chenchen, NI Jinxin, CHEN Yonghuan, et al. Development of sick chicken recognition based on deep learning[J]. Industrial Control Computer, 2021, 34(1): 48–50. (in Chinese)
- [18] LIU Hungwei, CHEN Chiahung, TSAI Yaochuan, et al. Identifying images of dead chickens with a chicken removal system

- integrated with a deep learning algorithm [J]. Sensors, 2021, 21(11): 3579.
- [19] 张亚婷,席磊,赵芙蓉.旱养对种鸭行为的影响观察[J].中国家禽,2017,39(13):67-69.  
ZHANG Yating, XI Lei, ZHAO Furong. Observation on the effect of dry-feeding on breeding duck behavior [J]. China Poultry, 2017, 39(13): 67 - 69. (in Chinese)
- [20] WOOD K A, LACEY R, ROSE P E. Assessing trade-offs in avian behaviour using remotely collected data from a webcam [J]. PLOS ONE, 2022, 17(7): e0271257.
- [21] RELIC R, SOSSIDOU E, DEDOUSI A, et al. Behavioral and health problems of poultry related to rearing systems [J]. Ankara Universitesi Veteriner Fakultesi Dergisi, 2019, 66: 423 - 428.
- [22] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLO v4: optimal speed and accuracy of object detection [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2020.
- [23] HE K, ZHANG X Y, REN S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 37(9): 1904 - 1916.
- [24] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation [J]. Computer Vision and Pattern Recognition, 2018, 35(3): 8759 - 8768.
- [25] REDMON J, FARHADI A. YOLO v3: an incremental improvement [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2018.
- [26] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: inverted residuals and linear bottlenecks [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2018.
- [27] YANG L X, ZHANG R Y, LI L, et al. SimAM: a simple, parameter-free attention module for convolutional neural networks [C] // International Conference on Machine Learning, PMLR, 2021: 11863 - 11874.
- [28] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2019.
- [29] ZHU X Z, CHENG D Z, ZHANG Z, et al. An empirical study of spatial attention mechanisms in deep networks [C] // IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 6688 - 6697.
- [30] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C] // European Conference on Computer Vision (ECCV), 2018: 3 - 19.
- [31] DIEDERIK K, JIMMY B. Adam: a method for stochastic optimization [C] // The 3rd International Conference for Learning Representations, 2015.
- [32] GAI R, CHEN N, YUAN H. A detection algorithm for cherry fruits based on the improved YOLO - v4 model [J]. Neural Computing and Applications, 2023, 35: 13895 - 13906.

(上接第 224 页)

- [22] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad - CAM: visual explanations from deep networks via gradient-based localization [C] // IEEE International Conference on Computer Vision. IEEE, 2017.
- [23] MA N, ZHANG X, ZHENG H T, et al. ShuffleNet V2: practical guidelines for efficient cnn architecture design [C] // 15th European Conference on Computer Vision (ECCV), 2018: 122 - 138.
- [24] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J/OL]. Advances in Neural Information Processing Systems, 2012: 1097 - 1105. [https://papers.nips.cc/paper\\_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b - Paper.pdf](https://papers.nips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf).
- [25] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [EB/OL]. [2014 - 12 - 19]. <https://arxiv.org/abs/1409.1556>.
- [26] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770 - 778.
- [27] 姜红花,杨祥海,丁睿柔,等.基于改进 ResNet18 的苹果叶部病害多分类算法研究 [J].农业机械学报,2023,54(4):295 - 303.  
JIANG Honghua, YANG Xianghai, DING Ruirou, et al. Identification of apple leaf diseases based on improved ResNet18 [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(4):295 - 303. (in Chinese)
- [28] 彭红星,何慧君,高宗梅,等.基于改进 ShuffleNetV2 模型的荔枝病虫害识别方法 [J].农业机械学报,2022,53(12):290 - 300.  
PENG Hongxing, HE Huijun, GAO Zongmei, et al. Litchi diseases and insect pests identification method based on improved ShuffleNetV2 [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(12):290 - 300. (in Chinese)