

# 基于改进 YOLO v6 - tiny 的蛋鸡啄羽行为识别与个体分类

杨断利<sup>1,2</sup> 王永胜<sup>1,2</sup> 陈辉<sup>3,4</sup> 孙二东<sup>5</sup> 曾丹<sup>6</sup>

(1. 河北农业大学信息科学与技术学院, 保定 071001; 2. 河北省农业大数据重点实验室, 保定 071001;

3. 河北农业大学动物科技学院, 保定 071001; 4. 农业农村部肉蛋鸡养殖设施工程重点实验室, 保定 071001;

5. 河北桃木疙瘩农业科技股份有限公司, 保定 074300; 6. 河北省蛋鸡产业技术研究院, 邯郸 056007)

**摘要:** 针对目前蛋鸡啄羽异常行为(包括啄和被啄)识别精度比较低的问题,提出了一种基于改进 YOLO v6 - tiny 模型进行啄羽异常行为识别的方法。该方法通过在 YOLO v6 - tiny 模型中引入 DenseBlock 结构并融入 CSP 结构的 SPP 模块(SPPCSPC)的方式,增强了 YOLO v6 - tiny 模型的特征提取能力,扩大了模型的感受野,提升了模型的检测精度。在识别出啄羽异常行为的基础上,对如何基于异常行为发生次数,进行蛋鸡个体分类进行了研究。提出了基于 YOLO v6 - tiny 模型进行蛋鸡个体识别,并将啄羽异常行为识别结果输入个体识别网络,进行蛋鸡个体分类的方法。同时,本文还分别对 2 种不同的养殖密度、一天当中 3 个不同的时间段,异常行为发生次数的变化规律进行了分析。实验结果表明,优化后的模型对啄和被啄异常行为的识别平均精度(AP)分别为 92.86% 和 92.93%,分别比 YOLO v6 - tiny 模型高 1.61、1.08 个百分点,比 Faster R - CNN 模型高 3.28、4.00 个百分点,比 YOLO v4 - tiny 模型高 6.15、6.63 个百分点,比 YOLO v5s 模型高 2.04、4.27 个百分点,比 YOLO v7 - tiny 模型高 5.39、3.92 个百分点。本文方法可以识别出啄和被啄羽异常行为,为蛋鸡异常行为的智能检测提供了技术支撑。

**关键词:** 蛋鸡; 啄羽; 异常行为识别; 个体分类; YOLO v6 - tiny

中图分类号: TP391.4; S24

文献标识码: A

文章编号: 1000-1298(2023)05-0268-10

OSID:



## Feather Pecking Abnormal Behavior Identification and Individual Classification Method of Laying Hens Based on Improved YOLO v6 - tiny

YANG Duanli<sup>1,2</sup> WANG Yongsheng<sup>1,2</sup> CHEN Hui<sup>3,4</sup> SUN Erdong<sup>5</sup> ZENG Dan<sup>6</sup>

(1. College of Information Science and Technology, Hebei Agricultural University, Baoding 071001, China

2. Hebei Key Laboratory of Agricultural Big Data, Baoding 071001, China

3. College of Animal Science and Technology, Hebei Agricultural University, Baoding 071001, China

4. Key Laboratory of Broiler and Layer Facilities Engineering, Ministry of Agriculture and Rural Affairs, Baoding 071001, China

5. Hebei Taomu Geda Agricultural Science and Technology Co., Ltd., Baoding 074300, China

6. Hebei Laying Industry Technology Research Institute, Handan 056007, China)

**Abstract:** To address the current problem of low accuracy in the recognition of feather pecking anomalies (including pecking and pecked) in laying hens, a method for feather pecking anomaly recognition was proposed based on an improved YOLO v6 - tiny model. By introducing the DenseBlock structure into the YOLO v6 - tiny model and incorporating the SPP module SPPCSPC into the CSP structure, the feature extraction capability of the YOLO v6 - tiny model was enhanced, the sensory field of the model was expanded, and the detection accuracy of the model was improved. Based on the identification of feather pecking anomalies, how to classify individual laying hens was investigated based on the number of anomalies. The method to identify individual laying hens based on the YOLO v6 - tiny model was proposed and identification results of feather pecking anomalies were input into the individual identification network to classify individual laying hens. At the same time, the change pattern of the number of anomalies at two different breeding densities and three different times of the day was also

收稿日期: 2022-12-21 修回日期: 2023-02-27

**基金项目:** 国家自然科学基金项目(32172779)、财政部和农业农村部:国家现代农业产业技术体系项目(CARS-40)和河北省科技研发平台建设专项(225676150H)

**作者简介:** 杨断利(1973—),女,副教授,主要从事机器视觉、智能检测与控制研究,E-mail: 502217591@qq.com

**通信作者:** 陈辉(1981—),女,教授,博士生导师,主要从事禽舍环境与工程研究,E-mail: 531613107@qq.com

analyzed. The experimental results showed that the average precision (AP) of the optimized model were 92.86% and 92.93% for pecking and pecked anomalies, respectively, which were 1.61 percentage points and 1.08 percentage points higher than that of the YOLO v6-tiny model, 3.28 percentage points and 4.00 percentage points higher than that of the Faster R-CNN model, 6.15 percentage points and 6.63 percentage points higher than that of the YOLO v4-tiny model, 2.04 percentage points and 4.27 percentage points higher than that of the YOLO v5s model, and 5.39 percentage points and 3.92 percentage points higher than that of the YOLO v7-tiny model. The method can identify the abnormalities of pecking and pecked feathers, which provided technical support for the intelligent detection of abnormal behavior of laying hens. The results of classifying individual laying hens based on pecking abnormalities provided a basis for preferential breeding of individual laying hens.

**Key words:** laying hens; feather pecking; abnormal behavior identification; individual classification; YOLO v6-tiny

## 0 引言

2021年我国在产的高产蛋鸡年均存栏量约 $1.107 \times 10^9$ 只,蛋鸡产业的高质量发展在全面实现乡村振兴和农业农村现代化建设中起着重要作用<sup>[1]</sup>。我国目前主要采用集约化蛋鸡饲养方式<sup>[2]</sup>,这种饲养方式饲养密度大,食物、空间资源竞争激烈,会导致啄羽异常现象的频繁发生,从而引发蛋鸡代谢紊乱、免疫抑制等生产性能问题<sup>[3-5]</sup>。鸡群一旦出现啄羽异常现象,啄羽现象会很快蔓延全群,严重时患病率可达80%以上,死亡率50%左右,严重影响养殖场经济效益和动物福利,同时也对疫病防控带来了巨大压力<sup>[6]</sup>。基于机器视觉的啄羽异常现象检测,可为及时发现异常现象,实现早期无接触疾病预警<sup>[7]</sup>奠定基础。有文献提出:蛋鸡可依据啄羽异常现象分为啄行为实施鸡、被啄鸡,既没有啄现象又没有被啄现象鸡,既有啄现象又有被啄现象鸡4种类型<sup>[8]</sup>,但目前还未见到有关这方面的进一步研究。

目前,常见的动物行为识别方法有人工观察法、图像处理法和基于机器视觉的方法。人工观察法耗时耗力且容易产生遗漏。劳凤丹等<sup>[9]</sup>、ZHUANG等<sup>[10]</sup>、LI等<sup>[11]</sup>通过图像分割、形态学处理等技术对单只蛋鸡常见行为、健康鸡和病鸡的姿态及群养肉鸡采食和饮水等常见行为的识别进行了研究。随着深度学习技术的发展,机器视觉技术因为具有不与监测动物直接接触、不会带来应激反应和疫病传染风险、成本较低且一旦网络训练完成后,不需人工参与就可获得高精度识别效果的优势,在动物行为识别领域得到了越来越多的研究。常用的行为识别模型主要有Faster R-CNN<sup>[12]</sup>、SSD<sup>[13]</sup>和YOLO系列<sup>[14-19]</sup>等,王凯<sup>[20]</sup>和WANG等<sup>[21]</sup>利用改进YOLO v3模型对蛋鸡的常见行为进行了检测,李娜<sup>[22]</sup>利用YOLO v4模型对蛋鸡采食、饮水、站立及啄羽等行为进行了识别。JIANG等<sup>[23]</sup>利用改进YOLO v4

模型对山羊行为进行了识别。GU等<sup>[24]</sup>利用YOLO v5模型进行了蛋鸭的常见行为识别。通过查阅文献资料发现,目前已有文献关于蛋鸡啄羽异常行为识别的精度较低。

本文以YOLO v6-tiny模型为基本模型,通过在主干网络中融入DenseBlock结构和CSP<sup>[25]</sup>结构的SPP模块(SPPCSPC)<sup>[26]</sup>,对YOLO v6-tiny基本模型进行优化,以期实现对蛋鸡啄羽行为的精准识别。

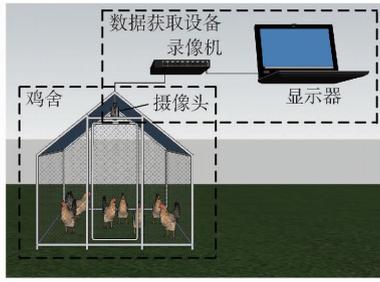
## 1 数据采集与预处理

### 1.1 数据采集

实验数据采集于2022年9月7日—10月12日,采集地点为河北桃木疙瘩农业科技股份有限公司中庄养殖基地。可移动鸡舍长3 m、宽2 m、顶高2 m,选取20只太行山蛋鸡,每只蛋鸡通过喷染不同颜色进行区分,为蛋鸡个体识别做准备。可移动鸡舍内部有一个食槽、一个饮水桶和一个产蛋箱,每天09:00和15:00喂食和收集鸡蛋。采用海康威视广角摄像头(DS-2CD3T56FWDV2-15型)进行录制,并通过网线将数据传输到容量为4TB的海康威视网络硬盘录像机(DS-7804N-K1/4PD型)中。摄像头安装在鸡舍内部中间最高点处,距地面2 m,垂直向下拍摄,采集系统示意图如图1a所示。摄像头焦距为2.8 mm,视频帧率为25 f/s,分辨率为2560像素×1920像素。实验期间,摄像头每天09:00—18:00采集蛋鸡的日常活动情况。为了分析蛋鸡密度变化对啄羽异常行为是否有影响,于2022年9月25日将移动鸡舍的长度由3 m调整为2.5 m,蛋鸡平均密度由3.3只/m<sup>2</sup>调整为4只/m<sup>2</sup>,每种密度各录制18 d,共获得36 d蛋鸡日常活动视频,现场采集环境如图1b所示。

### 1.2 数据预处理

观察采集到的蛋鸡日常活动视频,对具有啄羽异常行为(鸡只用喙啄其他鸡只的羽毛)<sup>[22]</sup>的片段



(a) 采集系统示意图



(b) 现场采集环境图

图1 实验采集示意图

Fig.1 Schematics of experimental collection

进行截取;对截取出的啄羽视频片段每隔 30 帧提取 1 幅图像,获取啄羽异常行为图像。由于数据集中图像的质量会影响模型的训练效果<sup>[27]</sup>,因此,对帧提取出的图像进行数据清洗,将模糊图像去除。利用 LabelImg 工具,对蛋鸡啄羽异常行为图像进行标注,制作蛋鸡啄羽异常行为识别数据集。利用 LabelImg 工具,对每只蛋鸡个体进行标注,制作单只蛋鸡个体识别数据集。蛋鸡啄羽异常行为识别数据集和蛋鸡个体识别数据集均为 Pascal VOC<sup>[28]</sup> 格式。

将两个数据集均按照 8:1:1 的比例划分为训练集、验证集和测试集。随机选择亮度变换、旋转、加噪、缩放以及镜像对训练集图像进行增强,提升算法的鲁棒性,数据集构建流程如图 2 所示。

数据预处理后,蛋鸡啄羽异常行为识别数据集共包括 4 008 幅图像,其中,啄羽异常行为标签

(peck) 4 310 个,被啄异常行为标签 (be pecked) 4 306 个。蛋鸡个体识别数据集共包括 1 700 幅图像,每只蛋鸡标签(标签名为 1~20)均为 1 700 个。

## 2 蛋鸡啄羽异常行为识别与个体分类

### 2.1 YOLO v6 - tiny 网络模型

YOLO v6 - tiny 网络结构整体可划分为 4 部分,分别为 Input、Backbone、Neck 和 Head。Input 用于向模型中输入图像,Backbone 对输入的图像进行特征提取,此部分主要采用 RepConv 卷积和 RepBlock 结构,RepBlock 结构如图 3 所示。Neck 是对 Backbone 学习到的不同尺寸特征进行融合操作,通过 Panet 结构,将提取的特征先通过上采样操作,实现特征融合,然后再通过下采样操作,对特征再次进行特征融合,所使用的卷积均为 RepBlock 结构,Head 进行分类回归操作,对结果进行输出。

YOLO v6 - tiny<sup>[29]</sup> 网络模型受到硬件感知神经网络设计思想的启发,通过引入 RepVGG 结构,设计了一种更高效的 Backbone 和 Neck;优化设计了更简洁有效的 Efficient Decoupled Head,在维持精度的同时,进一步降低了一般解耦头带来的额外延时开销;在训练策略上,采用了基于 Anchor-free 的无锚范式,同时运用了 SimOTA 标签分配策略和 SIoU<sup>[30]</sup> 边界框损失函数来进一步提升模型检测精度。

### 2.2 YOLO v6 - tiny 网络模型的改进

#### 2.2.1 DenseBlock 结构的引入

针对蛋鸡个体目标较小,在摄像头中的成像较小,且与摄像头的距离不同,成像尺度存在差异,YOLO v6 - tiny 模型对较小的图像及不同尺度的图像有效特征提取能力不足的问题,本文在 YOLO v6 - tiny 模型的 Backbone 部分,引入了具有更加密集连接机制的 DenseBlock<sup>[31]</sup> 模块,以提升模型的特征提

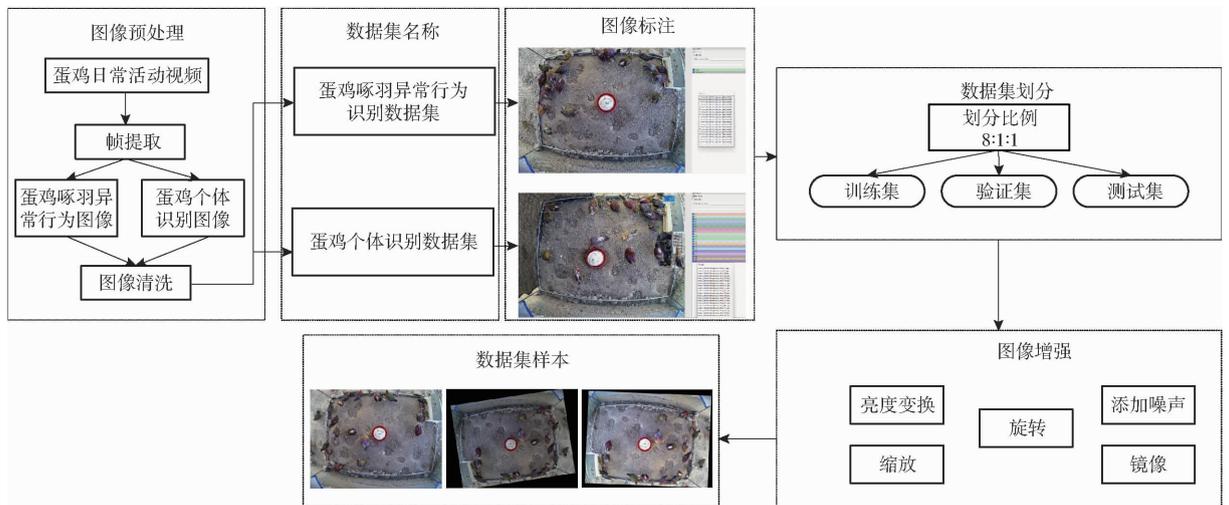


图2 数据集构建流程图

Fig.2 Flowchart of dataset construction

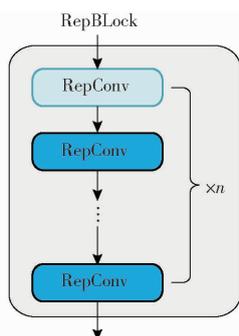


图 3 RepBlock 结构图

Fig. 3 RepBlock structure diagram

取能力, DenseBlock 模块的密集连接机制如图 4 所示。

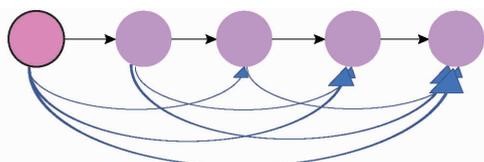


图 4 DenseBlock 结构图

Fig. 4 DenseBlock structure diagram

DenseBlock 模块的每一层都会接收前面所有层的输出作为额外的输入, 在 channel 维度上, DenseBlock 模块的每一层都会与前面所有层进行连接, 作为下一层的输入。对于一个  $L$  层的网络, DenseBlock 共包含  $L(L + 1)/2$  个连接。DenseBlock 模块将不同层的特征图进行 Concat 操作, 这种操作可以将蛋鸡个体不同尺度的成像进行特征重用, 提升了模型的识别效率和检测能力。

### 2.2.2 融入 SPPCSPC 结构的 YOLO v6 - tiny 网络模型

由于产蛋箱、食槽等物体会对蛋鸡个体产生不同程度的遮挡, 导致有效特征区域变小, 影响啄羽异常行为的识别效果。本文通过在 Backbone 部分引入 SPPCSPC 结构<sup>[26]</sup>优化 YOLO v6 - tiny 网络模型, 优化后的模型通过池化操作扩大感受野, 丰富了缺失区域的特征, 增强了模型对有效特征区域完好程度不同的图像的特征融合能力。

以 SPP 模块为基础, 借鉴 CSP 结构, 构成了 SPPCSPC 模块。SPPCSPC 模块结构如图 5 所示, 模块首先将 Backbone 中 RepBlock 模块提取的特征分

为 SPP 和常规卷积操作两部分。SPP 结构有 4 条分支, 分别对应池化核大小为 5、9、13、1 的 MaxPool 操作, 这 4 种不同大小的 MaxPool 操作, 使得 SPPCSPC 结构能够处理 4 种不同感受野对象, 可用于更好区分小目标和大目标。最后将这两部分合并在一起, 进行 Concat 操作, 从而使得模型减少一半的计算量, 模型速度更快、精度更高。引入 DenseBlock 和 SPPCSPC 的 YOLO v6 - tiny 结构图如图 6 所示。

### 2.3 蛋鸡啄羽异常行为识别及个体分类过程

啄羽异常行为识别及个体分类流程如图 7 所示, 蛋鸡个体分类过程实例如图 8 所示。首先利用改进 YOLO v6 - tiny 模型进行啄和被啄异常行为识别, 获得包含啄和被啄异常行为的原始图像。模型以矩形框的形式, 将原始图像中啄和被啄异常行为区域框出 (如图 8 中的第 2 幅图像所示)。模型识别并记录该框的坐标值 (上、下、左、右 4 个点坐标值), 依据坐标值, 模型自动对原始图像中啄和被啄的区域进行裁剪 (如图 8 中的第 3 幅图像所示)。将裁剪后的图像输入个体识别网络, 识别出发生了啄和被啄异常行为蛋鸡, 并统计每只蛋鸡发生啄和被啄异常行为的次数。

如果某蛋鸡既发生过啄又发生过被啄异常行为, 则将此蛋鸡归类为既是啄羽者又是被啄者类别, 表示为 A 类; 如果某蛋鸡仅发生过啄异常行为, 则将此蛋鸡归为啄类别, 表示为 B 类; 如果某蛋鸡只发生过被啄异常行为, 则将此蛋鸡归为被啄类别, 表示为 C 类; 如果某蛋鸡既未发生过啄又未发生过被啄异常行为, 则将此蛋鸡归类为中立者, 表示为 D 类。

### 2.4 实验参数设置

本研究所涉及的模型均在相同的设备上运行, 具体的配置和实验环境如表 1 所示。输入图像尺寸为 640 像素  $\times$  640 像素, 迭代次数 (Epoch) 设置为 200, 训练批量大小 (Batch size) 设置为 16, 线程数 (Num workers) 设置为 8, 模型训练过程中利用 COCO 数据集训练的权重作为预训练权重。实验中超参数设置如下: 初始学习率设置为 0.01, 采用余弦退火算法进行学习率衰减, 优化器为 SGD, 动量

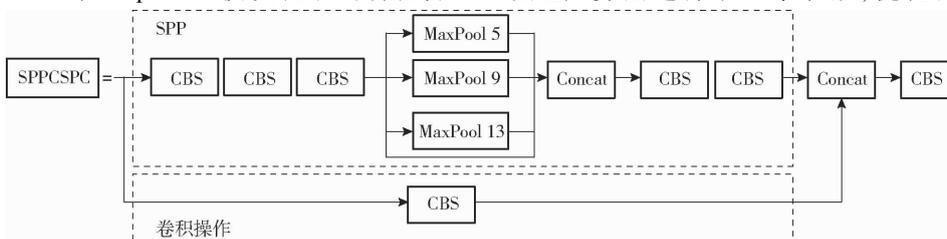


图 5 SPPCSPC 结构图

Fig. 5 SPPCSPC structure diagram

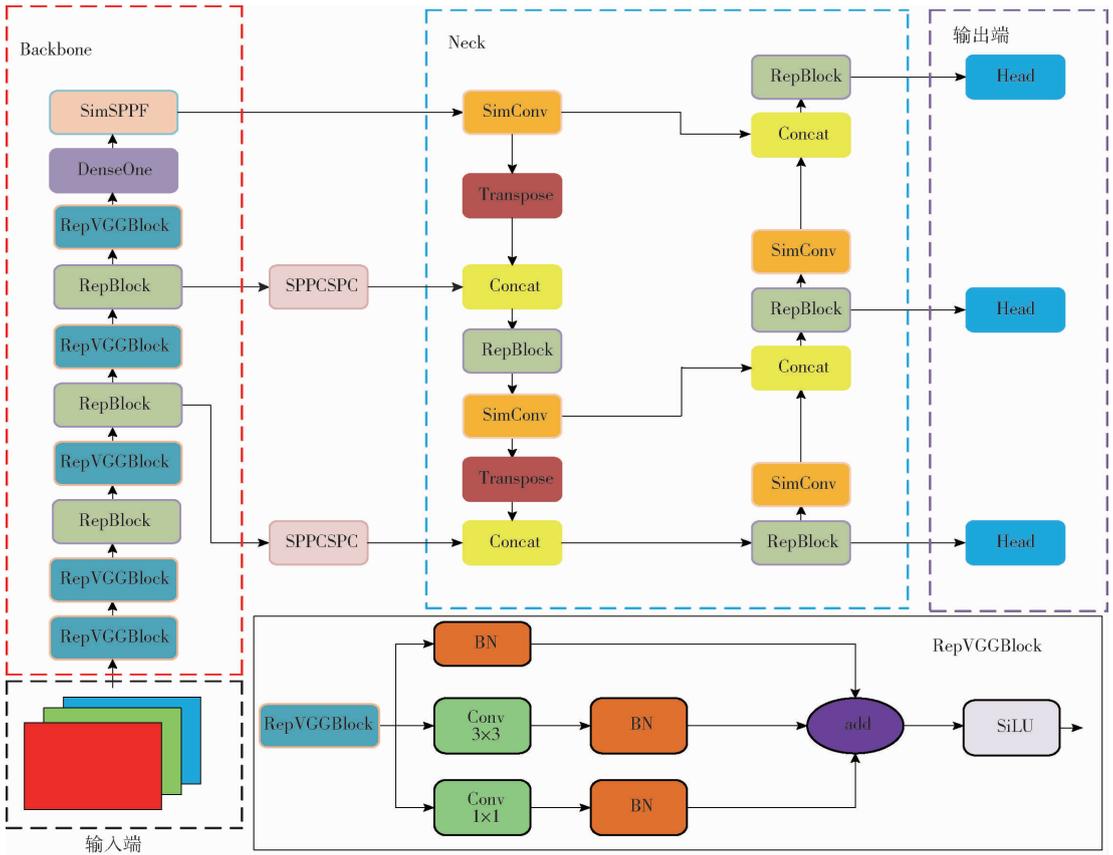


图6 改进YOLO v6-tiny结构图

Fig.6 Improved YOLO v6-tiny structure diagram

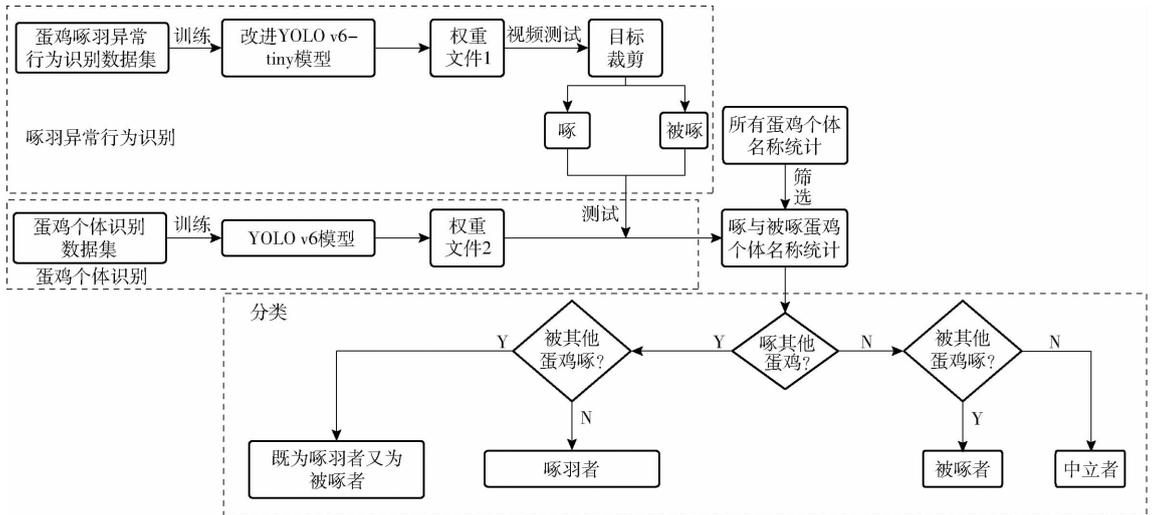


图7 蛋鸡啄羽异常行为识别及个体分类流程图

Fig.7 Flow chart of identification and individual classification of abnormal feather pecking phenomena of laying hens



图8 异常行为识别及个体分类过程实例图

Fig.8 Example diagram of anomaly recognition and individual classification process

(Momentum) 为 0.937。

## 2.5 模型评估

本研究利用精准率 (Precision,  $P$ ) 表示模型正确识别目标的比例, 召回率 (Recall,  $R$ ) 表示识别图像中目标的完全程度, 利用平均精度 (Average precision, AP) 表示每类目标识别的精度, F1 值为精准率和召回率的调和平均值, 利用平均精度均值 (Mean average precision, mAP) 表示所有类别的平均识别精度。本文中蛋鸡啄羽异常行为包括啄和被啄两类, 蛋鸡个体识别包括 20 类, 采用参数量、运算

表 1 硬件配置和实验环境

Tab.1 Hardware configuration and experimental environment

硬件	配置	环境	版本
操作系统	Windows 10	Python	3.8
CPU	Intel Core i7 - 9700	PyTorch	1.9
GPU	Nvidia GeForce RTX3060	CUDA	11.3.58

表 2 各模型识别精度对比

Tab.2 Comparison of recognition accuracy of each model

模型	精确率		召回率		平均精度		F1 值		平均精度
	啄	被啄	啄	被啄	啄	被啄	啄	被啄	均值
Faster R - CNN	80.14	76.47	90.00	90.00	89.58	88.93	85.00	83.00	89.25
YOLO v4 - tiny	90.12	86.51	82.31	83.84	86.71	86.30	86.04	85.15	86.51
YOLO v5s	89.06	91.32	87.67	84.62	90.82	88.66	88.36	87.84	89.74
YOLO v7 - tiny	87.99	87.08	84.62	86.15	87.47	89.01	86.27	86.61	88.24
YOLO v6 - tiny	88.97	87.43	86.87	86.92	91.25	91.85	87.91	87.18	91.55
改进 YOLO v6 - tiny	90.45	92.56	88.46	86.12	92.86	92.93	89.45	89.23	92.90

表 3 各模型性能对比

Tab.3 Comparison of performance of each model

模型	参数量	运算量	模型内存	传输
			占用量/ MB	速率/ ( $f \cdot s^{-1}$ )
Faster R - CNN	$1.3671 \times 10^8$	$4.0174 \times 10^{10}$	108.00	11.90
YOLO v4 - tiny	$3.06 \times 10^6$	$6.310 \times 10^8$	5.95	52.63
YOLO v5s	$7.02 \times 10^6$	$1.577 \times 10^9$	13.70	125.00
YOLO v7 - tiny	$6.01 \times 10^6$	$1.303 \times 10^9$	11.70	81.30
YOLO v6 - tiny	$9.67 \times 10^6$	$2.482 \times 10^9$	20.50	120.48
改进 YOLO v6 - tiny	$8.05 \times 10^6$	$2.455 \times 10^9$	16.80	111.98

从表 2 可知, 改进前的 YOLO v6 - tiny 模型异常行为识别精确率明显高于 Faster R - CNN 模型和 YOLO v7 - tiny 模型, 略低于 YOLO v4 - tiny 模型和 YOLO v5s 模型。召回率和平均精度明显高于 YOLO v4 - tiny 模型、YOLO v5s 模型和 YOLO v7 - tiny 模型, 与 Faster R - CNN 模型相差不大, 平均精度均值高于 Faster R - CNN、YOLO v4 - tiny、YOLO v5s 和 YOLO v7 - tiny 模型。综合考虑, 本文选取

量、模型内存占用量和传输速率 (FPS) 对模型性能进行评价。

## 3 实验结果与分析

本文从验证改进模型的识别性能、YOLO v6 - tiny 模型对蛋鸡个体的识别效果、利用类别可能性对蛋鸡进行分类、不同时间段和不同密度下的蛋鸡啄羽异常变化规律 5 方面进行了实验结果分析。

### 3.1 蛋鸡啄羽异常行为识别结果分析

为了验证改进 YOLO v6 - tiny 模型的识别性能, 采用相同的啄羽异常行为识别数据集, 分别对 Faster R - CNN 模型、YOLO v4 - tiny 模型、YOLO v5s 模型、YOLO v7 - tiny 模型以及 YOLO v6 - tiny 模型进行训练, 并利用相同的测试集进行模型性能评估。各模型检测精度结果对比如表 2 所示, 模型性能对比如表 3 所示。

YOLO v6 - tiny 模型作为基本模型并进行优化, 进一步提升模型的识别性能。

在模型检测精度方面, 改进 YOLO v6 - tiny 模型对啄和被啄异常行为识别的精确率分别为 90.45% 和 92.56%, 召回率分别为 88.46% 和 86.12%, 平均精度分别为 92.86% 和 92.93%, F1 值分别为 89.45% 和 89.23%。平均精度分别高于 YOLO v6 - tiny 模型、Faster R - CNN 模型、YOLO v4 - tiny 模型、YOLO v5s 模型及 YOLO v7 - tiny 模型 1.61、1.08 个百分点, 3.28、4.00 个百分点, 6.15、6.63 个百分点, 2.04、4.27 个百分点, 5.39、3.92 个百分点。

从表 3 可知, 在模型复杂度方面, 改进 YOLO v6 - tiny 模型参数量为  $8.05 \times 10^6$ 、运算量为  $2.455 \times 10^9$ 、模型内存占用量为 16.80 MB, 分别为 YOLO v6 - tiny 模型的 83.25%、98.91% 和 81.95%。3 个指标明显低于 Faster R - CNN 模型, 略高于 YOLO v4 - tiny 模型、YOLO v5s 模型和 YOLO v7 - tiny 模型。

在模型运算速度方面,本文模型的传输速率为 111.98 f/s,略低于 YOLO v5s 和 YOLO v6-tiny 模型,较 Faster R-CNN、YOLO v4-tiny 和 YOLO v7-tiny 模型分别高 100.08、59.35、30.68 f/s。

综合而言,本文提出的改进 YOLO v6-tiny 模型性能优于其他模型。

为了进行直观的效果对比,在测试集中随机选取 1 幅图像,利用不同模型进行识别,结果如图 9 所示。

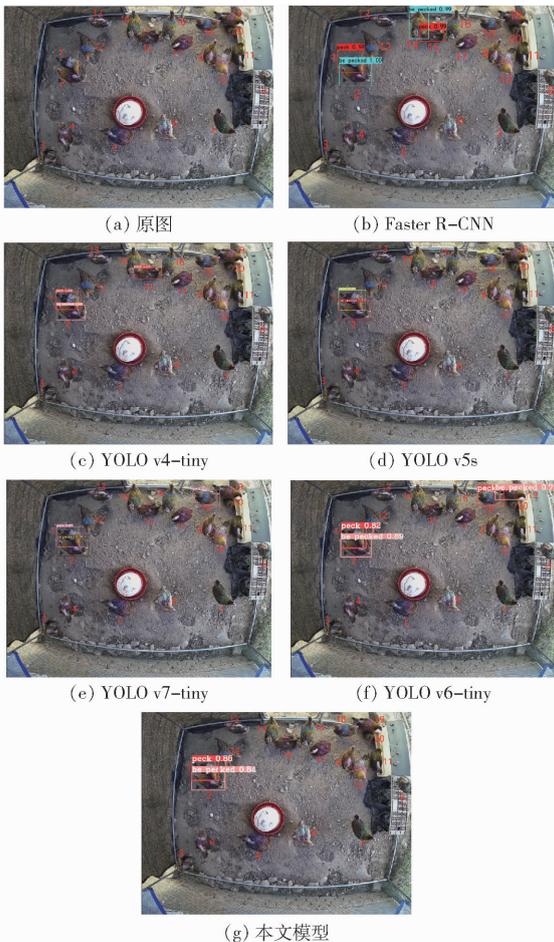


图 9 不同模型对蛋鸡啄羽异常行为识别效果  
Fig. 9 Effect of different model on recognition of abnormal feather pecking behavior of laying hens

在原图中,蛋鸡 1 对蛋鸡 2 实施啄羽,1 为啄羽实施鸡,2 为被啄鸡,蛋鸡 3~20 均没有异常现象,但此时蛋鸡 15 的喙恰好出现在蛋鸡 14 的背部。可以看出,图 9b~9f 均出现了误识别,图 9b 误识别蛋鸡 14、15,图 9c 误识别蛋鸡 15,图 9d 和图 9e 误识别蛋鸡 18,图 9f 误识别蛋鸡 18 和蛋鸡 19,而本文模型没有误识别,再次验证了本文模型识别能力优于其他模型。

### 3.2 蛋鸡个体识别结果分析

利用制作的蛋鸡个体识别数据集对 YOLO v6-tiny 模型进行训练,利用测试集进行模型精度评估。

实验结果表明,在模型检测精度方面,蛋鸡个体识别模型识别精确率为 98.34%,召回率为 98.87%,F1 值为 98.59%,平均精度均值为 99.30%。在模型复杂度方面,模型参数量为  $9.67 \times 10^6$ ,运算量为  $2.482 \times 10^9$ ,模型内存占用量为 20.50 MB。在模型运算速度方面,模型对蛋鸡个体识别的传输速率为 56.34 f/s。综上所述,从模型检测精度、模型复杂度和模型运算速度 3 方面评估,YOLO v6-tiny 模型达到了对蛋鸡个体识别的要求,识别效果如图 10 所示。

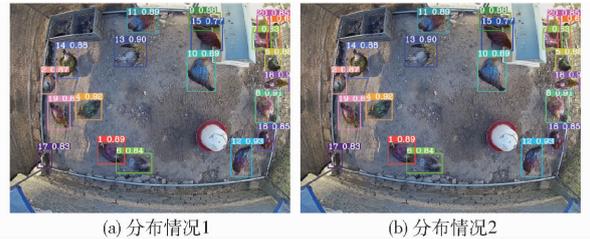


图 10 蛋鸡个体区分模型识别效果图

Fig. 10 Recognition effect of individual laying hens differentiation model

实验发现,YOLO v6-tiny 模型对图 10 右上角蛋鸡密集出现的部分,也能准确识别出蛋鸡个体,表明 YOLO v6-tiny 模型具有良好的识别性能。

### 3.3 蛋鸡个体分类结果分析

为了对蛋鸡个体进行分类,随机选取了 5 段时长为 17.75 min 的视频,利用改进 YOLO v6-tiny 模型对蛋鸡的啄和被啄异常行为进行识别,并将识别结果输入个体识别网络判断蛋鸡所属类别。蛋鸡啄和被啄异常行为识别结果如表 4 所示(表 4 中啄和被啄次数指的是视频中啄和被啄出现的帧数,平均值总次数为每只蛋鸡 5 段视频啄和被啄异常行为平均次数之和)。

从表 4 可以看到,20 只蛋鸡均出现啄和被啄异常行为,参照文献[8]的分类方法,这 20 只蛋鸡都应该被划分为 A 类,没有属于 B、C、D 类的蛋鸡。但从表 4 可以看出,每只蛋鸡异常行为发生的总次数差异较大,1 号蛋鸡总次数达到 1 918.8,而 2 号、5 号、6 号、7 号、9 号、10 号、17 号蛋鸡总次数只有 121.6、137.0、71.6、125.2、114.4、112.6、126.0 次,相较于 1 号蛋鸡而言,总次数非常少,这些蛋鸡更应该划归为 D 类。因此,简单的以发生或未发生异常行为对蛋鸡进行分类的方法过于绝对。

本文以 1 号蛋鸡为基准,用其它蛋鸡与 1 号蛋鸡总次数的比值作为权重,评判其他蛋鸡相对而言发生异常行为的可能性。例如 6 号蛋鸡,异常行为总次数仅有 71.6 次,相较于 1 号蛋鸡 1 918.8 次而言,权重只有 0.037,说明 6 号蛋鸡出现异常行为的

表 4 每只蛋鸡个体啄、被啄异常行为识别结果

Tab. 4 Results of identifying abnormalities of pecking and being pecked for each individual laying hen 次

蛋鸡序号	视频 1		视频 2		视频 3		视频 4		视频 5		平均值		总次数
	啄	被啄	啄	被啄	啄	被啄	啄	被啄	啄	被啄	啄	被啄	
1	694	1 088	849	1 145	424	809	1 306	2 303	273	703	709.2	1 209.6	1 918.8
2	78	86	100	39	38	17	155	64	21	10	78.4	43.2	121.6
3	305	219	145	133	51	59	1 410	866	267	192	435.6	293.8	729.4
4	350	230	410	256	106	78	523	249	151	315	308.0	225.6	533.6
5	82	51	43	38	103	24	185	59	85	15	99.6	37.4	137.0
6	34	15	22	30	35	26	46	68	80	2	43.4	28.2	71.6
7	57	66	25	32	11	11	95	175	111	43	59.8	65.4	125.2
8	168	218	117	192	166	126	367	190	156	101	194.8	165.4	360.2
9	67	69	17	19	68	14	183	111	17	7	70.4	44.0	114.4
10	49	29	22	29	26	16	126	116	104	46	65.4	47.2	112.6
11	158	68	72	39	76	50	161	144	167	71	126.8	74.4	201.2
12	471	484	318	487	619	682	787	774	384	277	515.8	540.8	1 056.6
13	214	137	71	65	40	72	268	175	93	58	137.2	101.4	238.6
14	559	455	479	450	409	311	1 602	1 239	325	325	674.8	556.0	1 230.8
15	324	334	351	208	64	155	462	538	131	145	266.4	276.0	542.4
16	447	223	281	146	104	132	892	953	275	293	399.8	349.4	749.2
17	56	79	44	50	32	44	110	117	35	63	55.4	70.6	126.0
18	178	202	83	152	77	87	309	296	57	83	140.8	164.0	304.8
19	311	436	234	285	80	163	285	577	32	101	188.4	312.4	500.8
20	82	82	103	79	84	27	197	181	151	40	123.4	81.8	205.2

可能性非常低,6号蛋鸡归为D类(中立鸡)的可能性应该更高。计算出权重后,再计算每只蛋鸡相对于1号蛋鸡而言,属于B、C、D类的可能性。计算过程如下:对于2~20号蛋鸡,首先用每只蛋鸡啄、被啄异常行为平均次数与各蛋鸡异常行为平均总次数相除(表4最后3列),计算每只蛋鸡相对自己而言,啄、被啄异常行为所占比例。然后用求出的啄、被啄异常行为比例分别乘以权重,得到相较于1号蛋鸡而言,蛋鸡属于B类和C类的可能性。最后用1减去属于B类和C类的可能性,得到属于D类的概率,结果如表5所示。

以异常行为次数最多的1号蛋鸡和异常行为次数最少的6号蛋鸡为例,从表5可以看到,1号归为B类概率为36.96%,C类的概率为63.04%,因此1号蛋鸡更应该被归为C类,计算结果与表4中,1号蛋鸡被啄次数远高于啄次数,更应该归为被啄鸡(即C类)的结果一致。6号蛋鸡归为B类概率为2.26%,C类的概率为1.47%,D类的概率为96.27%,因此6号蛋鸡更应该被归为D类,计算结果与表4中6号蛋鸡仅有71.6次异常行为更应该归为中立鸡(即D类)的结果一致,利用表5可以得到其他鸡归为各类的可能性。本文提出利用可能性代替绝对分类的方法使分类结果更为合理。

分析20只蛋鸡的啄羽异常行为,可以看出明显具有啄羽异常行为的蛋鸡有3只,占比15%,啄羽

表 5 蛋鸡个体属于各类别的概率

Tab. 5 Likelihood of individual laying hens belonging to each category %

蛋鸡序号	啄	被啄	A类	B类	C类	D类
1	36.96	63.04	100	36.96	63.04	0
2	64.47	35.53	100	4.09	2.25	93.66
3	59.72	40.28	100	22.70	15.31	61.99
4	57.72	42.28	100	16.05	11.76	72.19
5	72.70	27.30	100	5.19	1.95	92.86
6	60.61	39.39	100	2.26	1.47	96.27
7	47.76	52.24	100	3.12	3.40	93.48
8	54.08	45.92	100	10.15	8.62	81.23
9	61.54	38.46	100	3.67	2.29	94.04
10	58.08	41.92	100	3.41	2.46	94.13
11	63.02	36.98	100	6.61	3.88	89.51
12	48.82	51.18	100	26.88	28.18	44.94
13	57.50	42.50	100	7.15	5.28	87.57
14	54.83	45.17	100	35.17	28.98	35.85
15	49.11	50.89	100	13.88	14.39	71.73
16	53.36	46.64	100	20.84	18.21	60.95
17	43.97	56.03	100	2.89	3.68	93.43
18	46.19	53.81	100	7.34	8.55	84.11
19	37.62	62.38	100	9.82	16.28	73.90
20	60.14	39.86	100	6.43	4.26	89.31

异常行为较少的蛋鸡有7只,占比35%,有啄羽异常行为,但不明显的有10只,占比50%。因此,养殖场辨识啄癖鸡,实现精准防控时,更应该关注啄羽

异常行为总次数较多的鸡只。

由于这些蛋鸡的饲养条件相同,不同个体异常行为发生总次数有差异,不仅证实了蛋鸡个体之间存在差异性,同时也为养殖户进行蛋鸡个体优选育种、质量评价和生产性能评测,提供了一项新的参考指标。

### 3.4 不同时间段蛋鸡啄羽异常行为分析

为了分析不同时间段蛋鸡啄羽异常行为的发生是否具有规律性,实验选取2022年9月15—19日(连续5 d)蛋鸡日常活动视频,将每天分为09:00—12:00、12:00—15:00、15:00—18:00共3个时间段。这段时间,实验场地前4 d最低平均温度基本恒定在11℃左右,最高温度基本恒定在27℃左右,第5天最低平均温度基本恒定在5℃左右,最高温度基本恒定在19℃左右,每天09:00和15:00喂食。利用改进YOLO v6-tiny模型对5 d的蛋鸡活动视频进行啄羽异常行为识别,并统计每个时间段的蛋鸡啄羽异常行为次数,次数变化规律如表6所示。

表6 每个时间段的蛋鸡啄羽异常行为次数统计

Tab.6 Statistics of number of abnormal feather pecking of hens in each time period 次

时间	09:00— 12:00	12:00— 15:00	15:00— 18:00	总计
第1天	14 161	19 633	9 431	43 225
第2天	13 187	15 768	10 449	39 404
第3天	15 025	17 123	11 138	43 286
第4天	13 479	16 581	7 664	37 724
第5天	10 834	11 895	10 356	33 085
平均值	13 337.2	16 200.0	9 807.6	39 344.8

通过对比发现,每天12:00—15:00啄异常行为发生次数均高于其他两个时间段,15:00—18:00时间段啄异常行为发生次数最少。12:00—15:00平均啄异常行为发生次数高于09:00—12:00、15:00—18:00时间段,分析其原因,主要是由于12:00—15:00温度最高,光照较强,对蛋鸡产生了一定的刺激,导致啄羽异常行为发生较其他两个时间段频繁。通过表6发现,这5 d 09:00—12:00、12:00—15:00和15:00—18:00啄异常行为平均发生次数为13 337.2、16 200.0、9 807.6次,前4 d的啄异常行为总次数在平均数40 909.7附近波动,但第5天啄异常行为总次数出现较大下降,分析其原因,主要与第5天气温较低有关。因此,在蛋鸡饲养期

间,应注意鸡舍的遮光和温度调整。

### 3.5 不同密度下蛋鸡啄羽异常行为分析

为了分析养殖密度对蛋鸡啄羽异常行为的影响,利用改进YOLO v6-tiny模型分别对2022年9月15—19日期间常规尺寸下(鸡舍长3 m、宽2 m、顶高2 m)09:00—18:00和2022年10月2—6日期间较小尺寸下(鸡舍长2.5 m、宽2 m、顶高2 m)09:00—18:00的蛋鸡日常活动视频进行啄羽异常行为识别,2个不同蛋鸡平均密度每天蛋鸡啄羽异常行为发生次数统计结果如表7所示。

表7 不同蛋鸡养殖密度每天蛋鸡啄羽异常行为发生次数统计

Tab.7 Statistics of number of abnormal feather pecking of hens per day at different breeding densities of laying hens 次

时间	低密度	高密度
第1天	43 225	44 938
第2天	39 404	55 375
第3天	43 286	49 358
第4天	37 724	43 986
第5天	33 085	44 264
平均值	39 344.8	47 584.2

通过对比可发现,低养殖密度下每天啄羽次数均低于高养殖密度的每天啄羽次数,平均相差8 239.4次,说明养殖密度对蛋鸡的啄羽产生一定的影响,因此,在蛋鸡饲养过程中应该合理控制饲养密度。

## 4 结束语

本文提出了一种基于改进YOLO v6-tiny模型对蛋鸡啄羽异常行为进行识别及依据啄羽异常行为对蛋鸡个体进行分类的方法。通过在主干网络中引入DenseBlock结构和融入CSP结构的SPP模块(SPPCSPC)的方法,提升了YOLO v6-tiny模型的特征提取能力,扩大了模型的感受野,提升了模型的检测精度。改进YOLO v6-tiny模型对啄和被啄异常行为识别平均精度达到92.86%和92.93%。提出了利用可能性代替绝对分类的蛋鸡个体分类方法,为养殖户进行蛋鸡个体优选育种、质量评价和生产性能评测提供了一项新的参考指标。同时分析了不同时间段和不同养殖密度下的蛋鸡啄羽异常行为变化规律,为养殖户优化蛋鸡养殖环境提供了参考。

## 参 考 文 献

- [1] 胡小然,唐志鹏.蛋鸡养殖业发展现状及应对措施[J].中国动物保健,2021,23(9):91-92.
- [2] HAO H, FANG P, DUAN E, et al. A dead broiler inspection system for large-scale breeding farms based on deep learning[J]. Agriculture, 2022, 12(8):1176.

- [3] 刘宏伟. 浅谈我国蛋鸡业发展状况[J]. 畜牧兽医科技信息, 2021(10):173.
- [4] 张鑫, 牛召珊, 宋存鑫. 蛋鸡青年鸡质量评价指标及饲喂关键点[J]. 养殖与饲料, 2021, 20(9):64-65.
- [5] BAO J, XIE Q. Artificial intelligence in animal farming: a systematic literature review[J]. Journal of Cleaner Production, 2022, 331: 129956.
- [6] CRONIN G M, GLATZ P C. Causes of feather pecking and subsequent welfare issues for the laying hen; a review[J]. Animal Production Science, 2020, 61(10):990-1005.
- [7] 沈明霞, 刘龙申, 闫丽, 等. 畜禽养殖个体信息监测技术研究进展[J]. 农业机械学报, 2014, 45(10):245-251. SHEN Mingxia, LIU Longshen, YAN Li, et al. Review of monitoring technology for animal individual in animal husbandry[J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(10):245-251. (in Chinese)
- [8] DAIGLE C L, RODENBURG T B, BOLHUIS J E, et al. Individual consistency of feather pecking behavior in laying hens; once a feather pecker always a feather pecker[J]. Frontiers in Veterinary Science, 2015, 2(10):3386.
- [9] 劳凤丹, 滕光辉, 李军, 等. 机器视觉识别单只蛋鸡行为的方法[J]. 农业工程学报, 2012, 28(24):157-163. LAO Fengdan, TENG Guanghui, LI Jun, et al. Behavior recognition method for individual laying hen based on computer vision[J]. Transactions of the CSAE, 2012, 28(24):157-163. (in Chinese)
- [10] ZHUANG X, ZHANG T. Detection of sick broilers by digital image processing and deep learning[J]. Biosystems Engineering, 2019, 179:106-116.
- [11] LI G, ZHAO Y, PURSWELL J L, et al. Analysis of feeding and drinking behaviors of group-reared broilers via image processing[J]. Computers and Electronics in Agriculture, 2020, 175: 105596.
- [12] 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, 2016, 39(6):1137-1149.
- [13] 刘慧, 张礼帅, 沈跃, 等. 基于改进 SSD 的果园行人实时检测方法[J]. 农业机械学报, 2019, 50(4):29-35, 101. LIU Hui, ZHANG Lishuai, SHEN Yue, et al. Real-time pedestrian detection in orchard based on improved SSD[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(4):29-35, 101. (in Chinese)
- [14] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [15] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2017: 6517-6525.
- [16] REDMON J, FARHADI A. YOLO v3: an incremental improvement[J]. arXiv preprint, arXiv:1804.02767, 2018.
- [17] BOCHKOVSKIY A, WANG C Y, LIAO H. YOLO v4: optimal speed and accuracy of object detection[J]. arXiv preprint, arXiv:2004.10934, 2020.
- [18] 司永胜, 肖坚星, 刘刚, 等. 基于 MSRCP 与改进 YOLO v4 的躺卧奶牛个体识别方法[J]. 农业机械学报, 2023, 54(1):243-250, 262. SI Yongsheng, XIAO Jianxing, LIU Gang, et al. Individual identification method of lying cows based on MSRCP and improved YOLO v4 model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(1):243-250, 262. (in Chinese)
- [19] 薛鸿翔, 沈明霞, 刘龙申, 等. 基于改进 YOLO v5s 的经产母猪发情检测方法研究[J]. 农业机械学报, 2023, 54(1):263-270. XUE Hongxiang, SHEN Mingxia, LIU Longshen, et al. Estrus detection method of parturient sows based on improved YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(1):263-270. (in Chinese)
- [20] 王凯. 基于深度学习的蛋鸡行为检测方法研究与系统开发[D]. 杭州:浙江农林大学, 2019. WANG Kai. Detection method research and system development of laying hen behavior based on deep learning[D]. Hangzhou: Zhejiang A&F University, 2019. (in Chinese)
- [21] WANG J, WANG N, LI L, et al. Real-time behavior detection and judgment of egg breeders based on YOLO v3[J]. Neural Computing and Applications, 2020, 32(10):5471-5481.
- [22] 李娜. 舍饲散养模式下鸡只行为分析与监测关键技术研究[D]. 保定:河北农业大学, 2021. LI Na. Key technology research of behavior analysis and monitoring of chickens in free-range feeding mode[D]. Baoding: Hebei Agricultural University, 2021. (in Chinese)
- [23] JIANG M, RAO Y, ZHANG J, et al. Automatic behavior recognition of group-housed goats using deep learning[J]. Computers and Electronics in Agriculture, 2020, 177: 105706.
- [24] GU Y, WANG S, YAN Y, et al. Identification and analysis of emergency behavior of cage-reared laying ducks based on YOLO v5[J]. Agriculture, 2022, 12(4):485.
- [25] WANG C Y, LIAO H Y M, WU Y H, et al. CSPNet: a new backbone that can enhance learning capability of CNN[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020: 390-391.
- [26] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLO v7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[J]. arXiv preprint, arXiv:2207.02696, 2022.
- [27] LI S, LI K, QIAO Y, et al. A multi-scale cucumber disease detection method in natural scenes based on YOLO v5[J]. Computers and Electronics in Agriculture, 2022, 202: 107363.
- [28] EVERYINGHAM M, GOOL L V, CHRISTOPHE K L, et al. The pascal visual object classes (VOC) challenge[J]. International Journal of Computer Vision, 2010, 88: 303-308.
- [29] LI C, LI L, JIANG H, et al. YOLO v6: a single-stage object detection framework for industrial applications[J]. arXiv preprint, arXiv:2209.02976, 2022.
- [30] GEVORGYAN Z. Siou loss: more powerful learning for bounding box regression[J]. arXiv preprint, arXiv:2205.12740, 2022.
- [31] HUANG G, LIU Z, VAN DER M L, et al. Densely connected convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4700-4708.