

doi: 10.6041/j.issn.1000-1298.2023.09.032

# 基于 SEEC - YOLO v5s 的散养蛋鸡日常行为识别与统计系统

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> 王连增<sup>6</sup> 宁炜<sup>7</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;  
7. 成都小巨人畜牧设备有限公司, 成都 611435)

**摘要:** 针对鸡只个体较小、个体间存在遮挡, 对蛋鸡日常行为识别造成干扰的问题, 提出了一种基于 SEEC - YOLO v5s 的蛋鸡日常行为识别方法。通过在 YOLO v5s 模型输出部分添加 SEAM 注意力模块、在特征融合部分引入显式视觉中心模块 (EVCBlock) 扩大了模型的感受野, 提高了模型对小个体遮挡情况下的目标识别能力, 提升了模型对蛋鸡站立、采食、饮水、探索、啄羽和梳羽 6 种行为的识别精度。提出了一种基于视频帧数与视频帧率比值计算蛋鸡日常行为持续时间的统计方法, 并对蛋鸡群体一天之中不同时间段及全天各行为变化规律进行了分析。将改进后的模型进行封装、打包, 设计了蛋鸡日常行为智能识别与统计系统。试验结果表明, SEEC - YOLO v5s 模型对 6 种行为识别的平均精度均值为 84.65%, 比 YOLO v5s 模型高 2.34 个百分点, 对比 Faster R - CNN、YOLO X - s、YOLO v4 - tiny 和 YOLO v7 - tiny 模型, 平均精度均值分别提高 4.30、3.06、7.11、2.99 个百分点。本文方法对蛋鸡的日常行为监测及健康状况分析提供了有效的支持, 为智慧养殖提供了借鉴。

**关键词:** 蛋鸡; 日常行为识别; SEAM 模块; EVCBlock 模块; YOLO v5s

中图分类号: TP391.4 文献标识码: A 文章编号: 1000-1298(2023)09-0316-13

OSID:



## Daily Behavior Recognition and Real - time Statistics System of Free - range Laying Hens Based on SEEC - YOLO v5s

YANG Duanli<sup>1,2</sup> WANG Yongsheng<sup>1,2</sup> CHEN Hui<sup>3,4</sup> SUN Erdong<sup>5</sup> WANG Lianzeng<sup>6</sup> NING Wei<sup>7</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 Layer Industry Technology Research Institute, Handan 056007, China

7. Chengdu Little Giant Animal Husbandry Equipment Co., Ltd., Chengdu 611435, China)

**Abstract:** The small size of the chickens and the shading of the chickens from each other are factors that make it difficult to identify the daily behaviour of laying hens. To address this problem, a method of daily behavior identification of laying hens based on SEEC - YOLO v5s was proposed. By adding a SEAM attention module (separated and enhancement attention module) to the output part of the YOLO v5s model and introducing an EVCBlock module (explicit visual center) to the feature fusion part, the perceptual field of the model was expanded, the recognition ability of the model for occluded targets was improved, and the recognition accuracy of the model for the six behaviors of standing, feeding, drinking, exploring, feather pecking and grooming of laying hens was improved. A statistical method was proposed to calculate the duration of daily behavior of laying hens based on the ratio of video frames to video frame rate, and various behavioral changes of laying hens at different times of the day and throughout the day

收稿日期: 2023-03-22 修回日期: 2023-06-12

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

were analyzed. The improved model was encapsulated and packaged to develop an intelligent identification and automatic statistics system for the daily behavior of laying hens. The test results showed that the mAP of SEEC - YOLO v5s model for six behaviors recognition was 84.65%, which was 2.34 percentage points higher than that of YOLO v5s model, and compared with that of Faster R - CNN, YOLO X - s, YOLO v4 - tiny and YOLO v7 - tiny models, the mAP was improved by 4.30 percentage points, 3.06 percentage points, 7.11 percentage points and 2.99 percentage points, respectively. The method can provide effective support for daily behavior monitoring and health condition analysis of laying hens, and provide a reference for smart farming.

**Key words:** laying hens; daily behavior recognition; SEAM module; EVCBlock module; YOLO v5s

## 0 引言

我国蛋鸡养殖业发展迅速, 目前已经成为鸡蛋产量最多的国家<sup>[1-2]</sup>。随着物质生活的提高, 人们对优质蛋白的市场需求也在不断扩大, 食品安全需要养殖业减抗、无抗生产<sup>[3]</sup>。健康养殖是实现无抗养殖的前提, 家禽的行为信息与其生理健康状况密切相关<sup>[4-5]</sup>。目前, 对蛋鸡健康状况的监测主要采用人工观察的方式, 此方法不仅需要大量的劳动力、效率低下, 而且易受主观因素影响。

近年来, 国内外学者在机器视觉技术识别动物行为研究领域开展了大量研究。李丽华等<sup>[6]</sup>通过 K-means 聚类算法实现了对本交笼种鸡的采食、饮水、打斗、交配和振翅行为的识别。RIDDLE 等<sup>[7]</sup>手动识别了图像中的蛋鸡站立、躺卧、栖息、拍打翅膀、沐浴灰尘等行为。劳凤丹等<sup>[8]</sup>通过对蛋鸡图像的分割、形态学处理提取参数、利用贝叶斯分类的方法, 实现了对单只蛋鸡的运动、饮水、采食、修饰、抖动、休息、拍翅膀、探索、举翅膀行为的识别。刘修林<sup>[9]</sup>利用最大类间方差法实现了复杂背景下的鸡体分割, 然后根据位置信息实现了啄食、饮水、运动、静止行为的识别。XIAO 等<sup>[10]</sup>通过改进活动轮廓模型, 分割出笼养鸡的图像技术, 提出了一种利用双目视觉系统获取行为信息的检测方法。ZHUANG 等<sup>[11]</sup>首先从复杂背景中提取家禽目标, 然后计算家禽骨架结构、建立特征向量, 对家禽是否处于啄食状态进行了分析, 同时利用支持向量机方法对家禽的健康状况进行了评估。上述文献在动物行为识别方面取得了相应的进展, 但这些研究方法均具有人工图像分割、手动提取参数或特征的特点, 分割效果依赖于人的主观经验, 无法保证分割精度的稳定性。

随着深度学习技术的发展, 越来越多的学者开始尝试将深度学习技术应用于动物行为识别。王凯<sup>[12]</sup>提出了改进 YOLO v3 模型 (TD - YOLO v3), 实现了对蛋鸡的采食、躺、站立、探索和修饰行为的检测。WANG 等<sup>[13]</sup>采用 YOLO v3 模型和迁移学习的方法, 实现了对笼内 20 只蛋鸡的交配、站立、喂

食、散步、打架和饮水 6 种行为的识别。MBELWA 等<sup>[14]</sup>通过改进的卷积神经网络 (CNN), 并采用迁移学习的方法, 通过对鸡粪便的识别, 实现了对患有疾病鸡的检测。ZHANG 等<sup>[15]</sup>通过改进的 ResNet 模型 (ResNet - FPN), 实现了对病鸡的检测。WANG 等<sup>[16]</sup>应用 RPN + ResNet 模型根据粪便种类, 实现对消化疾病的检测, 从而对鸡的健康状况进行预测。LIN 等<sup>[17]</sup>利用 Faster R - CNN 模型实现了鸡只运动和饮水行为的识别。不仅站立、采食、饮水、探索和梳羽行为能够反映蛋鸡的健康状况, 啄羽行为也能反映蛋鸡的健康状况<sup>[18]</sup>。上述文献在蛋鸡健康状态的行为识别中, 鸡舍背景简单且缺少对蛋鸡啄羽行为的关注。

利用深度学习技术识别蛋鸡行为, 具有网络模型自动提取行为特征、不需人工参与的特点, 不仅能够解决人工观察法耗费大量劳动力的弊端, 而且还能够解决图像处理法的分割效果依赖于人的主观性、分割精度不稳定的问题<sup>[19]</sup>。因此, 本研究基于深度学习技术, 选用 YOLO v5 模型, 通过引入 SEAM 注意力模块和显式视觉中心模块 (EVCBlock), 对 YOLO v5 模型进行优化, 实现遮挡情况下的小个体蛋鸡站立、采食、饮水、探索、啄羽和梳羽 6 种日常行为的自动识别, 提升模型的识别精度。在行为识别的基础上, 进一步对蛋鸡群体行为的变化规律进行统计分析。

## 1 数据采集与预处理

### 1.1 数据采集

本试验于 2022 年 9 月 7—24 日在河北桃木疙瘩农业科技股份有限公司中庄养殖基地长 3 m、宽 2 m、柱高 1.2 m、顶高 2 m 的移动式鸡舍内饲养了 20 只健康状态良好的太行山蛋鸡, 鸡舍内部放置一个食槽、一个饮水桶和一个产蛋箱, 于每日 09:00 和 15:00 喂食、拾取鸡蛋。试验采用焦距为 2.8 mm、帧率为 25 f/s、分辨率为 2 560 像素 × 1 920 像素的海康威视 (DS - 2CD3T56FWDV2 - 15) 广角摄像头对蛋鸡每日 09:00—18:00 间的日常行为进行录制,

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 - K1/4P( D) ) 中。摄像头安装在鸡舍内部中间顶部,距地面 2 m,垂直向下拍摄<sup>[20]</sup>。采集环境如图 1 所示。



图 1 采集环境

Fig. 1 Acquisition environment

### 1.2 数据预处理

本文选择蛋鸡站立、采食、饮水、探索、啄羽和梳羽共 6 种与蛋鸡健康状况评估相关的行为作为研究对象,蛋鸡行为判定标准如表 1 所示,各行为例如图 2 所示。

表 1 蛋鸡行为判定标准

Tab. 1 Laying hens behavior determination criteria

行为种类	行为描述	标签
站立	鸡只腿部直立,支撑身体	stand
采食	鸡只在食槽前,头部探入食槽	eat
饮水	鸡只在饮水桶旁,头部探入饮水桶	drink
探索	鸡只处于站立状态下,头部低下	explore
啄羽	鸡只用喙啄其它鸡只	peck
梳羽	鸡只用喙梳理自己的羽毛	preening feather




图 2 各行为例图

Fig. 2 Example diagrams of each behavior

利用帧提取的方法每隔 30 帧提取 1 幅图像,随机选择不同时间下的图像作为蛋鸡日常行为识别数据集。数据集中图像的质量会显著影响模型的训练效果<sup>[21]</sup>,因此,需要对提取出的图像进行数据清洗,去除模糊图像。最后利用 LabelImg 工具对蛋鸡日

常行为识别数据集进行标注,制作成 Pascal VOC<sup>[22]</sup> 格式数据集,并按照 7:2:1 的比例划分为训练集、验证集和测试集。

为了避免模型过拟合,增强算法的鲁棒性<sup>[23]</sup>,本文采用离线增强方式,随机选择旋转、缩放、镜像的方式对训练集中的图像进行数据增强。数据增强后的样本如图 3 所示。




图 3 数据增强效果图

Fig. 3 Data enhancement effect diagrams

经过数据预处理后,蛋鸡日常行为识别数据集共包括 3 019 幅图像。如图 3 所示,同时对原图像进行了镜像、旋转和缩放操作,增加了图像的多样性。试验总体流程图如图 4 所示。

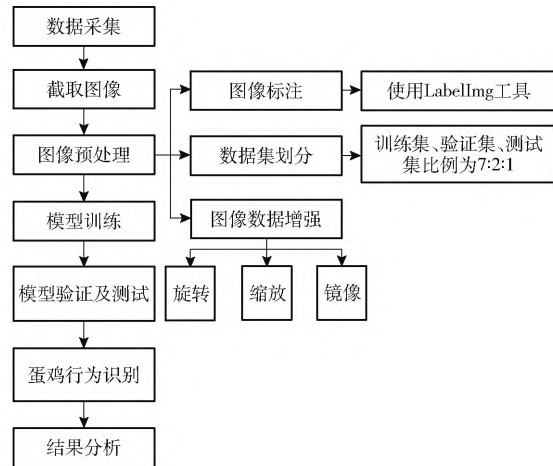


图 4 试验总体流程图

Fig. 4 General flow chart of experiment

如图 4 所示,整个试验首先进行数据采集,获得蛋鸡日常行为图像,其次对图像进行预处理操作,为模型训练做准备。经模型训练后,进行性能测试和结果分析。

## 2 蛋鸡日常行为识别方法

### 2.1 YOLO v5s 网络结构

YOLO v5 模型兼顾了推理速度和检测精度<sup>[24]</sup>,根据网络结构的深度和宽度的不同,将 YOLO v5 模型分为 YOLO v5n、YOLO v5s、YOLO v5m、YOLO v5l 和 YOLO v5x 共 5 个版本。为了选取合适的版本,使用本试验的蛋鸡日常行为识别数据集分别训练上述 5 个模型,利用测试集进行识别效果评估,不同版

本的 YOLO v5 模型检测精度对比如表 2 所示。

表 2 不同版本的 YOLO v5 模型检测精度对比  
Tab.2 Comparison of detection accuracy of different versions of YOLO v5 models

模型	精确率 / 召回率 / F1 值 / 平均精度		参数量		
	%	%		均值 / %	
YOLO v5n	70.82	70.02	70.42	72.06	$1.770 \times 10^6$
YOLO v5s	81.55	76.52	78.95	82.31	$7.030 \times 10^6$
YOLO v5m	81.18	79.52	80.34	82.89	$2.087 \times 10^7$
YOLO v5l	80.45	79.09	79.76	83.57	$4.614 \times 10^7$
YOLO v5x	80.64	80.74	80.69	84.14	$8.621 \times 10^7$

从表 2 可知 ,YOLO v5s 模型对蛋鸡日常行为

识别的精确率为 81.55% ,召回率为 76.52% ,F1 值为 78.95% ,平均精度均值为 82.31% ,参数量为  $7.03 \times 10^6$ 。与 YOLO v5n 模型相比 ,精确率、召回率、F1 值和平均精度均值分别提升 10.73、6.50、8.53、10.25 个百分点 ,参数量仅增加  $5.26 \times 10^6$  ,与 YOLO v5m、YOLO v5l 以及 YOLO v5x 模型相比 ,虽然平均精度均值降低了 0.58、1.26、1.83 个百分点 ,但是参数量分别减少  $1.384 \times 10^7$ 、 $3.911 \times 10^7$ 、 $7.918 \times 10^7$ 。综合模型检测精度和模型复杂度 ,本文选取 YOLO v5s 模型作为蛋鸡日常行为识别基本模型。YOLO v5s 模型结构如图 5 所示。

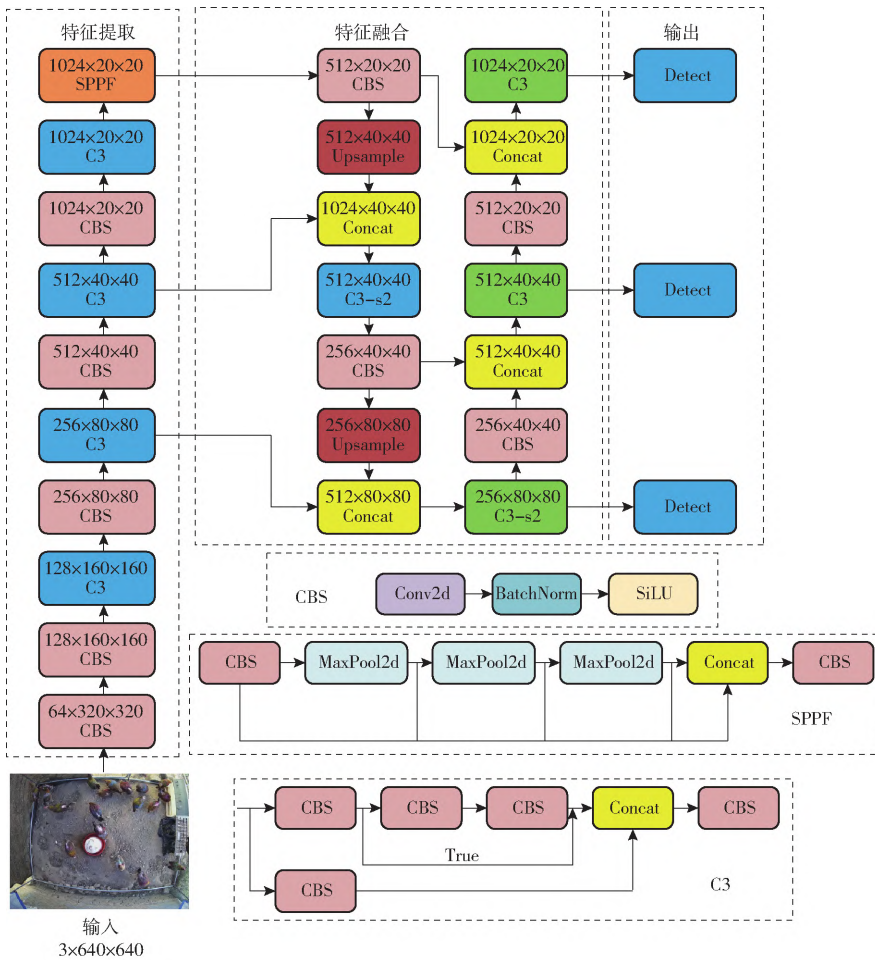


图 5 YOLO v5s 模型结构图

Fig.5 YOLO v5s model structure diagram

YOLO v5s 模型包括输入、特征提取、特征融合和输出 4 部分。输入部分用于向模型输入预先处理好的蛋鸡图像;特征提取部分采用了 CSPDarknet53 结构 ,用于提取目标的语义信息;特征融合部分使用了 PAN 结构 ,用于对特征提取部分提取到的特征进行处理<sup>[25]</sup> 融合不同尺度信息 ,增强特征的表达;输出部分共包括 3 个分支 ,特征图尺寸分别为 80 像素 × 80 像素、40 像素 × 40 像素和 20 像素 × 20 像素 ,分别用于识别小、中、大目标 ,并进行输出。

### 2.2 SEEC - YOLO v5s 蛋鸡日常行为识别模型

针对鸡只个体目标较小、蛋鸡之间重叠遮挡导致的有效特征不足、丢失、遗漏、行为识别效果不理想的问题 ,本文以 YOLO v5s 模型为基础 ,通过引入 SEAM 注意力模块和显式视觉中心模块 ,构建改进 YOLO v5s 模型 (SEEC - YOLO v5s) ,增强模型特征提取能力 ,提升行为识别精度。优化后的 SEEC - YOLO v5s 模型结构如图 6 所示。

在图 6 中的输出部分加入 SEAM 注意力模

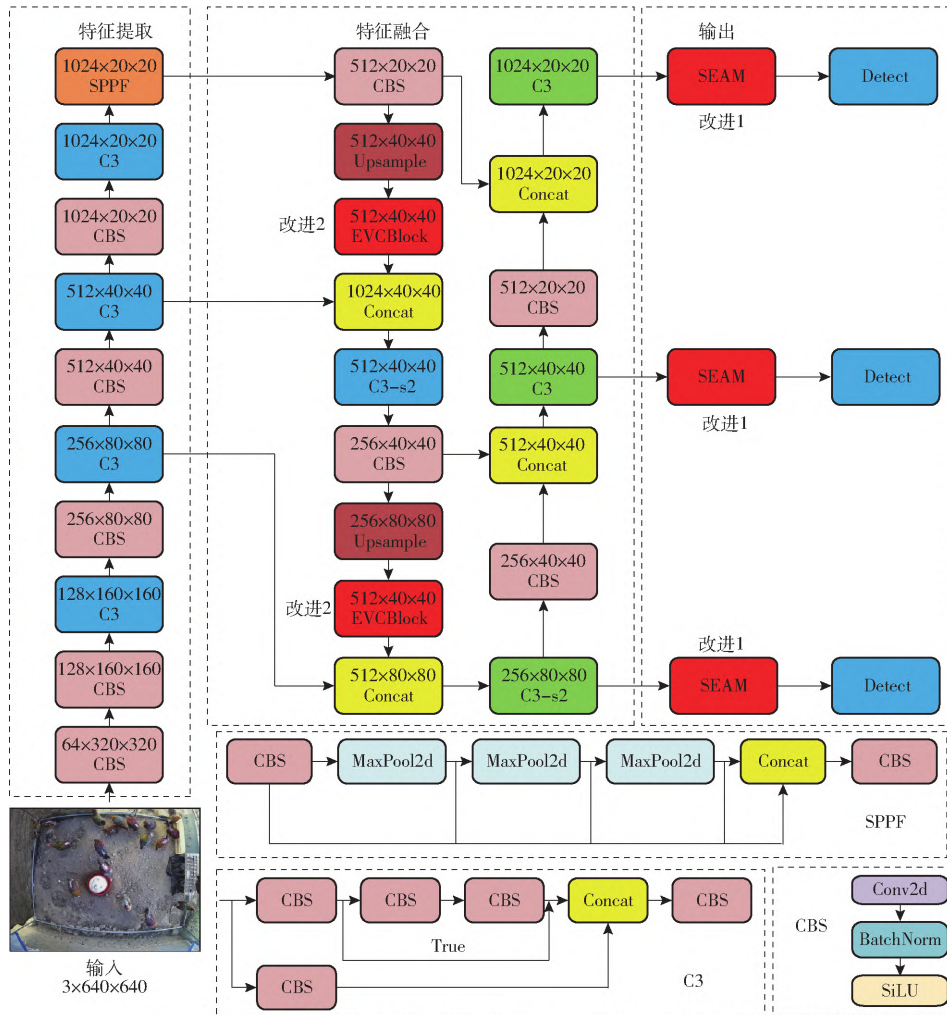


图6 SEEC-YOLO v5s 模型结构图

Fig. 6 SEEC-YOLO v5s model structure diagram

块<sup>[26]</sup> (图6中的改进1) 将特征融合部分的3个不同尺度输出层与输出部分的3个检测头进行连接, 解决蛋鸡之间因为遮挡导致的有效特征丢失问题。在特征融合部分的特征金字塔网络(FPN)结构中加入显式视觉中心模块(EVCBlock)<sup>[27]</sup> (图6中的改进2) 解决鸡只目标较小、有效特征不足、容易被遗漏的问题。

### 2.2.1 SEAM 注意力模块

蛋鸡个体间的遮挡会导致鸡体局部混叠、重要特征缺失<sup>[26]</sup>。利用SEAM模块, 将YOLO v5s模型特征融合部分的3个不同尺度输出层与输出部分的3个检测头进行连接, 可突出图像中的蛋鸡区域, 弱化背景区域, 实现多尺度下的蛋鸡日常行为检测。SEAM模块结构图如图7所示。

SEAM模块的第1部分是带有残差连接的深度可分离卷积。深度可分离卷积不仅能减少模型的参数量, 而且还可以利用逐通道运算, 学习多个不同通道的重要特征, 提升模型的特征提取能力。但是深度可分离卷积在学习不同通道的重要特征时, 由于

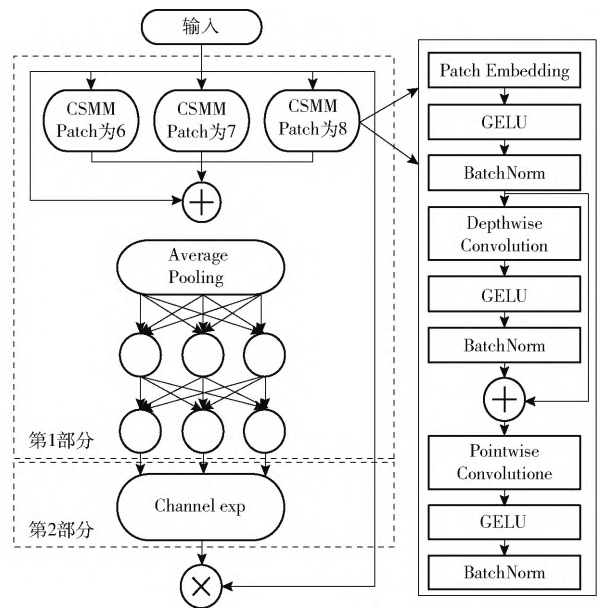


图7 SEAM 模块结构图

Fig. 7 SEAM module structure diagram

没有考虑通道之间的特征联系, 所以对不同通道的特征提取并不充分。因此, 为了弥补深度可分离卷积的不足, SEAM模块在不同深度可分离卷积的输

出后进行了逐点卷积操作,最后通过一个两层的全连接网络融合各通道的特征,实现了所有通道之间的连接。第 2 部分是将全连接层的输出结果通过指数函数进行处理,并将取值范围从 [0, 1] 扩大到 [1, e],使得上一步学习到的被遮挡蛋鸡的有效特征与无遮挡的有效特征相互联系,最后将 SEAM 模块的输出作为特征与原始特征相乘,使模型能够有效地

解决蛋鸡个体间遮挡带来的有效特征丢失的问题。

### 2.2.2 显式视觉中心模块

蛋鸡个体目标较小,有效特征不足且容易产生遗漏,致使模型识别精度较低。为了尽可能多地提取蛋鸡个体有效特征,本文在特征融合部分的 FPN 结构中加入了显式视觉中心模块 (EVCBlock)。EVCBlock 模块结构如图 8 所示。

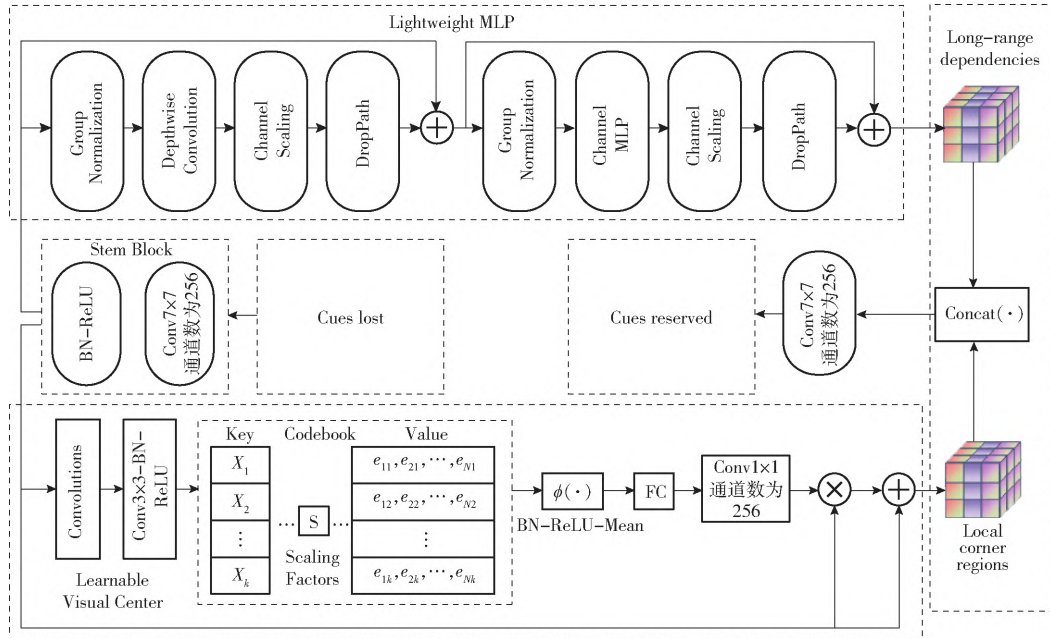


图 8 EVCBlock 模块结构图

Fig. 8 EVCBlock module structure diagram

EVCBlock 模块主要包括轻量级 MLP 和可学习的视觉中心机制,轻量级的 MLP 用来获取模型中 EVCBlock 模块上一层传入特征  $X_4$  的全局特征信息,可学习的视觉中心机制用于聚合模型中 EVCBlock 模块上一层传入特征  $X_4$  的局部区域特征信息。EVCBlock 模块将获得的全局特征信息和局部区域特征信息沿着通道维度进行拼接,生成最后的特征。由于 EVCBlock 模块学习的特征中不仅包括全局的特征信息,还包括局部区域的特征信息,特征信息较丰富,因此,能够解决蛋鸡个体目标较小、特征遗漏的问题。

EVCBlock 模块并未直接对模型中 EVCBlock 模块上一层的传入特征  $X_4$  进行操作,而是先将上一层的传入特征  $X_4$  通过 Stem 模块进行操作,然后再对经过 Stem 模块处理后的特征进行操作。

Stem 模块依次通过卷积核为  $7 \times 7$ 、输出通道数为 256 的卷积操作、批归一化 (Batch normalization) 操作,并使用 ReLU 作为激活函数。Stem 模块主要用于对模型中 EVCBlock 模块上一层的传入特征  $X_4$  进行特征平滑。

EVCBlock 模块的计算公式为

$$X = \text{Concat}(\text{MLP}(X_{in}); \text{LVC}(X_{in})) \quad (1)$$

$$\text{其中 } X_{in} = \sigma(\text{BN}(\text{Conv}_{7 \times 7}(X_4))) \quad (2)$$

式中  $X$ ——EVCBlock 模块的输出

$\text{Concat}()$ ——沿 channel 维度的特征图拼接操作

$\text{MLP}(X_{in})$ ——使用轻量级 MLP 的输出特征

$\text{LVC}(X_{in})$ ——使用可学习的视觉中心机制的输出特征

$X_{in}$ ——Stem 模块的输出

$\sigma()$ ——ReLU 激活函数

$\text{BN}()$ ——批归一化层操作

$\text{Conv}_{7 \times 7}$ ——卷积核为  $7 \times 7$ 、步幅为 1、输出通道数为 256 的卷积操作

### 2.3 试验参数设置

本研究所用的硬件配置和试验环境如表 3 所示。使用相同的蛋鸡日常行为数据集分别对 YOLO v5 的 5 个版本模型、Faster R - CNN、YOLO X - s、YOLO v4 - tiny、YOLO v7 - tiny 以及 SEEC - YOLO v5s 模型进行训练。试验所采用的超参数:输入图像尺寸为 640 像素  $\times$  640 像素,训练批量大小 (Batch size) 为 8,迭代周期 (Epoch) 为 100,线程数 (num

workers) 为 8, 初始学习率 (Initial learning rate) 为 0.01, 动量因子 (Momentum) 为 0.937, 优化器为随机梯度 (SGD), 利用最优权重对模型进行评价。

表3 硬件配置和试验环境

Tab.3 Hardware configuration and experimental environment

硬件	配置	试验环境
操作系统	Windows 10	Python 3.8
CPU	Intel Core i7-9700	PyTorch 1.9
GPU	Nvidia GeForce RTX3060	CUDA 11.1.74
RAM	16 GB	CUDNN 8.0.5

## 2.4 模型评估

本文利用精确率 (Precision,  $P$ )、召回率 (Recall,  $R$ )、平均精度 (Average precision, AP)、F1 值、平均精度均值 (Mean average precision, mAP) 和参数量对模型性能进行评估。

精确率表示正确检测出的目标与识别出的所有目标的比值, 召回率表示检测出为正类且真实类别也为正类的目标数量与真实类别为正类的所有目标总数的比值, 平均精度表示对每个类检测的结果, F1 值表示精确率和召回率的调和平均值, 平均精度均值表示对所有类别的检测结果。

## 2.5 蛋鸡日常行为持续时间统计方法

在日常生活中, 可以对蛋鸡群体进行各种行为的持续时间统计, 从而判断蛋鸡的生活习性, 并分析其健康状况, 为蛋鸡福利养殖提供借鉴<sup>[28]</sup>。

通过对帧速率计算公式的变换, 可以实现对蛋鸡日常行为持续时间的统计, 即利用 SEEC-YOLO v5s 模型对蛋鸡的日常活动视频进行识别, 并对各种行为的识别结果进行统计, 通过检测出的各行为视频帧数与视频帧率的比值, 获得各种日常行为的持续时间  $T$  (单位为 min)。

## 3 结果与分析

### 3.1 不同模型识别结果分析

为了验证不同模型对蛋鸡日常行为识别的效果, 采用相同的蛋鸡日常行为识别数据集分别对 Faster R-CNN 模型、YOLO X-s 模型、YOLO v4-tiny 模型、YOLO v7-tiny 模型、YOLO v5s 模型以及本文模型 (SEEC-YOLO v5s) 进行训练, 利用精确率、召回率、F1 值、平均精度均值和参数量进行效果评估, 试验结果如表 4 所示。

从表 4 可以看出, SEEC-YOLO v5s 模型对蛋鸡日常行为识别的精确率、召回率、F1 值、平均精度均值以及参数量分别为 82.34%、81.30%、81.82%、

表4 不同模型识别结果对比

Tab.4 Comparison of recognition results of different models

模型	精确	召回	F1 值 / 平均精度		参数量
	率 / %	率 / %	%	均值 / %	
Faster R-CNN	64.80	82.72	72.33	80.35	$1.3679 \times 10^8$
YOLO X-s	75.74	82.54	78.99	81.59	$8.04 \times 10^6$
YOLO v4-tiny	73.22	73.65	73.43	77.54	$3.07 \times 10^6$
YOLO v7-tiny	76.73	79.09	77.89	81.66	$6.02 \times 10^6$
YOLO v5s	81.55	76.52	78.95	82.31	$7.03 \times 10^6$
SEEC-YOLO v5s	82.34	81.30	81.82	84.65	$1.279 \times 10^7$

84.65% 和  $1.279 \times 10^7$ 。在检测精度方面, 精确率、F1 值和平均精度均值比 Faster R-CNN 模型分别高 17.54%、9.49%、4.30 个百分点, 比 YOLO X-s 模型分别高 6.60%、2.83%、3.06 个百分点, 比 YOLO v4-tiny 模型分别高 5.61%、8.39%、7.11 个百分点, 比 YOLO v7-tiny 模型分别高 5.61%、3.93%、2.99 个百分点, 比 YOLO v5s 模型分别高 0.79%、2.87%、2.34 个百分点。SEEC-YOLO v5s 模型的召回率略低于 Faster R-CNN 模型和 YOLO X-s 模型, 与 YOLO v4-tiny 模型、YOLO v7-tiny 模型和 YOLO v5s 模型相比分别高 7.65%、2.21%、4.78 个百分点。在模型复杂度方面, SEEC-YOLO v5s 模型参数量与其他模型相近, 仅为 Faster R-CNN 模型参数量的 10.70%。因此, 从检测精度和模型复杂度两方面综合来看, SEEC-YOLO v5s 模型在蛋鸡日常行为检测方面更有优势。

蛋鸡不同日常行为识别结果反映出模型对目标特征的识别能力, 因此将本文模型 SEEC-YOLO v5s 分别与 Faster R-CNN、YOLO X-s、YOLO v4-tiny、YOLO v7-tiny 和 YOLO v5s 模型对每类蛋鸡日常行为识别的平均精度进行对比, 结果如表 5 所示。

表5 不同行为识别精度均值对比

Tab.5 Comparison of average precision of different behavioural recognition %

行为	Faster	YOLO	YOLO	YOLO	YOLO	SEEC-
	R-CNN	X-s	v4-tiny	v7-tiny	v5s	YOLO v5s
站立	83.88	87.03	85.57	86.74	87.77	86.56
采食	92.29	96.68	96.02	97.23	96.37	98.46
饮水	98.32	95.31	89.73	92.81	92.04	94.52
探索	70.30	71.13	63.96	68.58	73.82	77.33
啄羽	60.52	57.17	58.64	64.48	66.09	67.52
梳羽	76.79	82.20	71.29	80.12	77.75	83.50

从表 5 中可以看出, SEEC-YOLO v5s 模型对蛋鸡的采食行为的识别精度最高, 达到 98.46%, 对啄羽行为的识别精度最低, 仅为 67.52%, 分析

原因可能是啄羽行为在所有行为中属于少数异常行为,采集得到的数据集中啄羽行为占比只有 3.68%,因此基于深度学习算法对啄羽行为的识别精度普遍偏低,可通过长时间采集大量啄羽行为训练模型来提升啄羽行为的识别精度。SEEC - YOLO v5s 模型对采食、探索、啄羽和梳羽 4 种行为的识别精度均高于其他模型,SEEC - YOLO v5s 模型对 4 种行为的识别精度最少提高 1.23 个百分点,最高提高 13.37 个百分点。SEEC - YOLO v5s 模型对站立行为的识别精度比 YOLO X - s 和 YOLO v5s 模型低 0.47、1.21 个百分点,对饮水行为的识别精度比 Faster R - CNN 和 YOLO X - s 模型低 3.80、0.79 个百分点。总体而言,SEEC - YOLO v5s 模型对蛋鸡日常行为的识别具有一定的优势。

随机从本试验的蛋鸡日常行为识别数据集中选择 1 幅图像,分别利用 Faster R - CNN、YOLO X - s、YOLO v4 - tiny、YOLO v7 - tiny、YOLO v5s 和本文模型(SEEC - YOLO v5s) 对此图像进行识别,识别效果如图 9 所示。

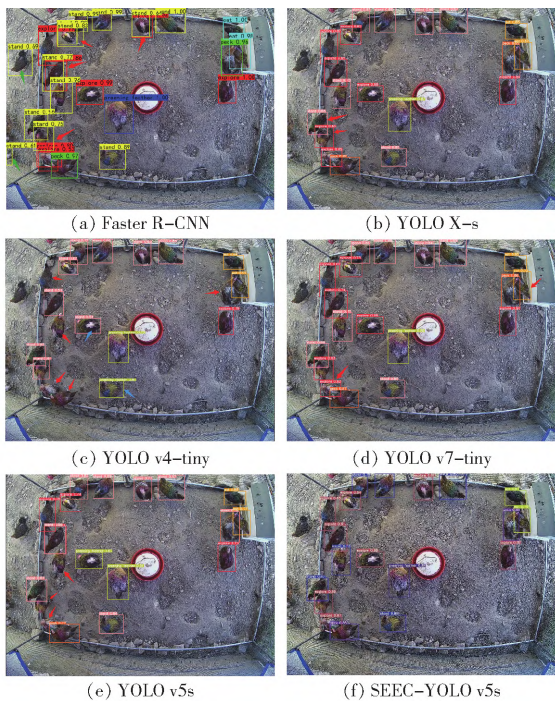


图 9 不同模型识别效果图

Fig. 9 Different model recognition effect diagram

通过对比发现,如图 9a 中的红色箭头所示, Faster R - CNN 模型误将 1 只蛋鸡行为识别为 2 种行为,如绿色箭头所示,也误识别出了鸡舍外部不属于本试验的蛋鸡。如图 9b 中红色箭头所示, YOLO X - s 模型虽然正确识别了蛋鸡的行为,但是与图 9f 本文模型相比,识别的置信度较低。如图 9c 中红色箭头所示, YOLO v4 - tiny 模型存在多处漏检行为,如蓝色箭头所示,误将探索和站立的蛋鸡识别为了站立和梳羽行为。如图 9d 中红色箭头所示,当蛋鸡被遮挡时, YOLO v7 - tiny 模型的目标置信度较 SEEC - YOLO v5s 模型更低;如图 9e 中红色箭头所示, YOLO v5s 模型对蛋鸡日常行为识别存在多处漏检行为;图 9f 中的 SEEC - YOLO v5s 模型能够准确识别出鸡舍内部每只蛋鸡的行为。

综上所述, Faster R - CNN 模型对蛋鸡日常行为识别存在多处将 1 只蛋鸡误识别为 2 种行为的情况,表明 Faster R - CNN 模型对蛋鸡日常行为识别能力较差; YOLO X - s 和 YOLO v7 - tiny 模型在蛋鸡存在遮挡情况下置信度较低,表明 YOLO X - s 和 YOLO v7 - tiny 模型在遮挡情况下,对目标特征的学习能力较弱; YOLO v4 - tiny 和 YOLO v5s 模型存在多处漏检情况,表明 YOLO v4 - tiny 和 YOLO v5s 模型对较小目标的识别能力不足。因此,从检测精度、模型复杂度和识别效果 3 方面来看, SEEC - YOLO v5s 模型对蛋鸡日常行为识别的总体效果最好。

### 3.2 SEEC - YOLO v5s 模型消融试验

利用本文数据集,使用平均精度均值和各类别的平均精度指标,对 YOLO v5s、YOLO v5s + SEAM、YOLO v5s + EVCBlock 和 SEEC - YOLO v5s 模型,通过消融试验进行识别效果对比,进一步验证 SEEC - YOLO v5s 模型的性能,试验结果如表 6 所示。

通过表 6 可以发现, YOLO v5s + SEAM 模型和 YOLO v5s + EVCBlock 模型对蛋鸡 6 种行为识别的平均精度均值与 YOLO v5s 模型相比,分别提高 0.75、1.91 个百分点。其中, YOLO v5s + SEAM 模型对站立、采食、饮水和探索行为识别的平均精度较 YOLO v5s 模型分别提高 0.07、0.11、2.69、0.08 个

表 6 消融试验结果对比

Tab. 6 Comparison of ablation experiment results

模型	平均精度均值	平均精度					
		站立	采食	饮水	探索	啄羽	梳羽
YOLO v5s	82.31	87.77	96.37	92.04	73.82	66.09	77.75
YOLO v5s + SEAM	83.06	87.84	96.48	94.73	73.90	62.00	73.90
YOLO v5s + EVCBlock	84.22	89.44	97.34	96.56	73.62	67.38	81.35
SEEC - YOLO v5s	84.65	86.56	98.46	94.52	77.33	67.52	83.50

百分点;YOLO v5s + EVCBlock 模型对站立、采食、饮水、啄羽和梳羽行为识别的平均精度较 YOLO v5s 模型分别提高 1.67、0.97、4.52、1.29、3.60 个百分点,表明添加 SEAM 注意力模块和 EVCBlock 模块后均能对蛋鸡日常行为的识别有一定的促进作用。

与 YOLO v5s 模型相比,SEEC-YOLO v5s 模型对站立行为识别的平均精度有所降低,分析原因在于,蛋鸡个体间存在遮挡,在视觉上腿部呈现不明显,致使区分站立行为的有效特征变少,因此,对站立行为识别结果有所降低。对采食、饮水、探索、啄羽和梳羽行为识别结果均有所提升,表明 SEEC-YOLO v5s 模型对蛋鸡日常行为识别效果有明显提升。

Gard-CAM 可以将模型对蛋鸡行为特征的学习程度以热力图的方式显示<sup>[29-30]</sup>。特征图可视化也可以直接显示出模型对重要信息的学习能力。因此,为了进一步检验本文模型(SEEC-YOLO v5s)对蛋鸡日常行为识别的有效性,随机选择 1 幅图像,分别利用 YOLO v5s 模型和 SEEC-YOLO v5s 模型对输出部分的 3 种不同尺度的输出层进行特征图可视化和热力图显示,结果分别如图 10、11 所示。




图 10 特征图可视化结果对比

Fig. 10 Comparison of feature map visualization results

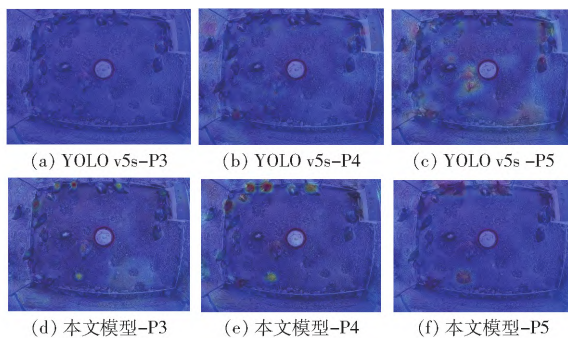


图 11 热力图效果对比

Fig. 11 Comparison of heat map effect

图 10a ~ 10c 为 YOLO v5s 模型在输出层 P3、P4、P5 的可视化结果,图 10d ~ 10f 为本文模型在输出层 P3、P4、P5 的可视化结果。通过对比两个模型在 P3 输出层的可视化结果发现,本文模型对蛋鸡小

目标特征的识别效果更明显,学习的特征更丰富,在输出层 P4、P5 中,本文模型的可视化效果也均优于 YOLO v5s 模型。

图 11a ~ 11c 为 YOLO v5s 模型在上述随机选择的图像上通过 Gard-CAM 对 P3、P4、P5 输出层进行热力图显示的结果,图 11d ~ 11f 为本文模型在上述随机选择的图像上通过 Gard-CAM 对输出层 P3、P4、P5 进行热力图显示的结果。通过对比两模型在输出层 P3 和 P4 的热力图发现,本文模型对蛋鸡目标区域的热力较高,对无关区域的热力较低,能够更好地学习蛋鸡日常行为特征。综上所述,从识别精度和特征图可视化以及热力图显示的效果分析,再一次证明了本文模型对蛋鸡日常行为识别的效果更优。

### 3.3 小个体蛋鸡不同遮挡情况下检测性能分析

为了验证本文模型对不同遮挡情况下小个体蛋鸡行为的检测性能,从测试集中随机选取 2 幅不同遮挡情况下的蛋鸡图像,并利用 YOLO v5s 和本文模型(SEEC-YOLO v5s)进行检测。结果如图 12 所示。




图 12 不同遮挡情况下检测效果

Fig. 12 Detection effects under different occlusion situations

对比图 12a、12b 中黄色圈所标注的蛋鸡检测结果可以发现,在无遮挡的情况下,YOLO v5s 模型将处于站立行为的蛋鸡误识别为站立和探索两种行为,而本文模型准确识别出了蛋鸡的站立行为。对比图 12a、12b 中蓝色圈所标注的蛋鸡检测结果可以发现,当蛋鸡只显示出了头部和尾部,身体部分被另一只蛋鸡严重遮挡时,YOLO v5s 模型虽然识别出了被遮挡蛋鸡的行为,但是对蛋鸡定位时只定位出了尾部,蛋鸡的头部被遗漏(如图 12a 中蓝色箭头处)影响最终的识别精度,本文模型不仅准确识别出了蛋鸡的行为,而且相较于 YOLO v5s 模型,对被严重遮挡的蛋鸡定位也更准确。

对比图 12c、12d 中粉色圈 1 所标注的蛋鸡检

测结果可以发现,当某只蛋鸡的尾部被其他蛋鸡轻微遮挡时,虽然 YOLO v5s 模型和本文模型均识别出了被遮挡蛋鸡的行为,但是 YOLO v5s 模型识别的置信度(0.85)低于本文模型的置信度(0.87);对比粉色圈 2 所标注的蛋鸡检测结果可以发现,当蛋鸡的腹部被完全遮挡时,YOLO v5s 模型出现了误识别现象,而本文模型准确识别出了蛋鸡所处的行为。

综上所述,在无遮挡、蛋鸡腹部或尾部被其他鸡只轻微遮挡或者是蛋鸡的身体被严重遮挡,只剩下头部和尾部情况下,本文模型均能够准确检测出蛋鸡的行为,而 YOLO v5 模型均出现了一定的误检现

象,表明本文模型在不同遮挡情况下对蛋鸡日常行为的检测效果更优。

### 3.4 不同时间段各行为变化规律分析

试验期间鸡群视频录制时间为每日 09:00—18:00,喂食时间为每日 09:00 和 15:00。为了分析鸡群各行为为不同时间段的变化规律,随机选取连续 4 d 的视频录像,并将每天录像每隔 30 min 划分 1 个时间段,共 18 个时间段。利用本文模型对划分后的蛋鸡视频录像进行识别,求得 4 d 内 18 个时间段的平均值,并按照 2.5 节所述的持续时间统计方法将识别出的帧数转换为持续时间并进行分析。结果如表 7 和图 13 所示。

表 7 蛋鸡各行为的持续时间统计

Tab.7 Statistics on duration of each behavior of laying hens

时间段编号	时间段	站立	采食	饮水	探索	啄羽	梳羽
1	09:00—09:30	234.01	107.06	6.65	133.21	5.51	88.60
2	09:30—10:00	222.11	114.64	8.60	137.45	6.15	85.72
3	10:00—10:30	224.93	103.13	9.63	146.95	5.77	85.28
4	10:30—11:00	242.99	100.92	7.39	142.76	5.61	74.25
5	11:00—11:30	260.04	92.72	8.37	130.72	4.70	74.84
6	11:30—12:00	275.80	92.50	8.29	127.30	5.23	65.09
7	12:00—12:30	270.51	92.50	7.95	128.13	4.73	61.55
8	12:30—13:00	284.04	80.85	5.97	139.85	6.07	50.51
9	13:00—13:30	261.87	64.78	7.62	149.46	7.63	53.97
10	13:30—14:00	273.76	53.99	4.87	138.97	6.23	56.86
11	14:00—14:30	278.84	69.19	5.95	142.96	6.16	55.05
12	14:30—15:00	251.47	95.17	4.88	145.86	5.71	63.79
13	15:00—15:30	295.37	101.48	3.53	114.20	8.08	45.35
14	15:30—16:00	233.69	138.33	7.22	123.31	5.44	68.53
15	16:00—16:30	218.28	123.66	8.29	148.90	4.58	73.40
16	16:30—17:00	240.12	97.62	6.77	153.31	5.92	74.53
17	17:00—17:30	224.61	97.13	5.73	154.50	5.07	88.64
18	17:30—18:00	229.97	94.81	8.47	167.26	6.23	75.30




图 13 不同时间段蛋鸡各行为持续时间

Fig. 13 Duration of each behavior of laying hens at different time periods

观察表 7 和图 13 发现,蛋鸡的饮水、探索和啄羽行为在各时间段持续时间基本保持稳定。站立行为在 11:00—15:30 时间段持续时间高于其他时间

段,推测可能与温度有关,温度较高的时间段,站立行为持续时间较其他时间段会更长。采食行为在 11:00—15:00 和 16:30—18:00 期间持续时间明显低于其他时间段。梳羽行为在 11:30—16:00 区间内持续时间明显较低。统计结果为依据行为规律判断蛋鸡健康状态奠定了基础。

### 3.5 全天内蛋鸡日常行为持续时间变化规律分析

为了分析每天 09:00—18:00 期间蛋鸡 6 种日常行为之间的变化规律,利用本文模型对选取的连续 4 d 视频录像进行行为识别,利用 2.5 节提出的持续时间统计方法分别对每天蛋鸡 6 种行为持续时间进行统计,结果如表 8 所示,全天内各行为持续时间对比如图 14 所示。

通过观察图 14 可知,在这 4 d 中,每天每种蛋

表8 全天候蛋鸡日常行为发生时间  
Tab.8 Occurrence time of daily behaviors of laying hens throughout day

时间	站立	采食	饮水	探索	啄羽	梳羽
第1天/min	4 455.95	2 022.64	178.71	2 537.83	112.38	1 112.33
第2天/min	4 750.49	1 874.32	111.33	2 285.12	110.62	1 138.56
第3天/min	4 260.77	1 876.31	126.91	2 619.49	101.37	1 178.05
第4天/min	4 670.97	1 121.78	89.62	2 677.09	95.63	1 544.18
持续时间平均值/min	4 534.55	1 723.76	126.64	2 529.88	105.00	1 243.28
占整天活动时间的比值/%	44.18	16.80	1.23	24.65	1.02	12.11




图14 全天候内各行为持续时间对比  
Fig.14 Comparison of behaviors throughout day

鸡日常行为持续时间基本保持相同,站立、采食、饮水、探索、啄羽和梳羽6种行为持续的平均时间分别为4 534.55、1 723.76、126.64、2 529.88、105.00、1 243.28 min,占蛋鸡整天活动时间的比值分别为44.18%、16.80%、1.23%、24.65%、1.02%、12.11%。一天当中,站立行为持续时间最长,饮水和啄羽行为持续时间最短。站立行为持续时间比其它5种行为持续时间分别长2 810.78、4 407.90、2 004.66、4 429.55、3 291.27 min。通过对比可知,在一天当中,蛋鸡大部分时间会处于站立和探索状态,这两种行为占每天活动时间的68.83%,上述统计结果为通过统计蛋鸡各行为持续时间评估蛋鸡健康状况提供了数据依据。

#### 4 蛋鸡日常行为识别与统计系统设计

蛋鸡的健康状态影响着养殖户的经济效益,为了便于观察蛋鸡行为,本试验利用PyQt5对SEEC-YOLO v5s模型进行封装、打包,制作了蛋鸡日常行为识别与显示系统,实现了对蛋鸡行为的自动监测。

##### 4.1 总体设计及各部分功能

蛋鸡日常行为识别与统计系统的总体框架如图15所示,主要包括数据获取、蛋鸡日常行为识别、参数设置和显示。

数据获取部分是用于选择数据获取的主要渠道,包括本地文件获取和摄像头调用2种方式。蛋鸡日常行为识别部分通过调用训练好的模型,对数

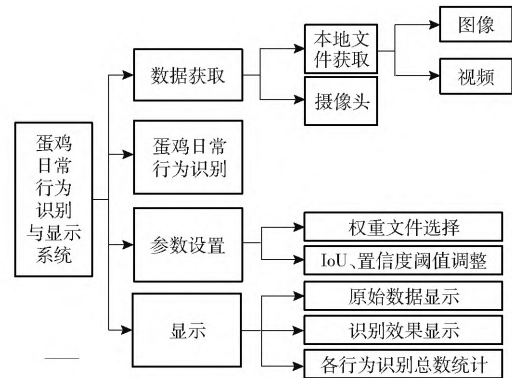


图15 蛋鸡日常行为识别与显示系统总体框架图  
Fig.15 General framework of daily behavior identification and display system of laying hens

据获取部分送入的数据进行识别,并对当前帧图像中识别出的各行为总持续时间进行统计;参数设置部分包括权重文件选择、IoU阈值、置信度阈值调整;显示部分是对原始数据、识别效果和当前帧图像中识别出的各行为持续时间的显示。

##### 4.2 操作方法及效果显示

如图16所示,用户进入蛋鸡日常行为识别与显示系统主界面后,在数据获取部分选择获取识别数据的方式,在参数设置部分选择训练好的权重文件,并对置信度阈值和NMS阈值进行调整,通过点击播放按钮启动蛋鸡日常行为识别,识别效果会显示在显示部分,识别效果如图17所示。




图16 系统主界面

Fig.16 Main interface of system

如图17所示,当完成对蛋鸡日常行为识别后,会在系统页面最左端,“结果显示”下方显示出识别出的各种行为鸡只个数。此幅图像识别结果为:探




图 17 识别效果图

Fig. 17 Recognition effect diagram

索行为有 7 只蛋鸡, 站立行为有 7 只蛋鸡, 啄羽行为有 2 只蛋鸡, 采食行为有 2 只蛋鸡, 梳羽行为有 1 只蛋鸡。

## 5 结论

(1) 提出了一种基于 SEEC - YOLO v5s 的蛋鸡日常行为识别方法。通过在 YOLO v5s 模型的输出部分引入 SEAM 结构, 突出了图像中的蛋鸡区域, 弱化了背景区域, 改善了 YOLO v5s 模型对遮挡目标识别精度较低的问题, 通过在特征融合部分加入

EVCBlock 模块, 解决了蛋鸡目标较小, 特征易被遗漏的问题。本文改进的 SEEC - YOLO v5s 模型对蛋鸡 6 种日常行为识别的平均精度均值为 84.65%, 其中对采食行为识别的平均精度达到 98.46%。对比 YOLO v5s、Faster R - CNN、YOLO X - s、YOLO v4 - tiny 和 YOLO v7 - tiny 模型, 6 种行为的平均精度均值分别提高 2.34、4.30、3.06、7.11、2.99 个百分点。

(2) 提出了一种基于视频帧数与视频帧率比值计算蛋鸡日常行为持续时间的统计方法, 并分析了一天当中不同时间段下的蛋鸡群体各行为和一整天内蛋鸡 6 种日常行为的变化规律。试验结果表明: 每天每种日常行为持续时间基本保持相同, 6 种行为平均时间占蛋鸡整天活动时间的 44.18%、16.80%、1.23%、24.65%、1.02% 和 12.11%。一天当中, 站立行为持续时间最长, 饮水和啄羽行为持续时间最短; 蛋鸡站立和探索行为占每天活动时间的 68.83%。利用 PyQt5 对本文模型进行了封装、打包, 制作了蛋鸡日常行为识别与统计系统, 为蛋鸡的日常行为监测和健康状况评估提供了技术手段。

## 参 考 文 献

- [1] 程欢, 孙志华, 白文娟, 等. 2019 年以来我国蛋鸡产业发展形势分析及建议 [J]. 中国畜牧杂志, 2022, 58(12): 295 - 299.
- [2] 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.
- [3] 李保明, 王阳, 郑炜超, 等. 中国规模化养鸡环境控制关键技术与设施设备研究进展 [J]. 农业工程学报, 2020, 36(16): 212 - 221.  
LI Baoming, WANG Yang, ZHENG Weichao, et al. Research progress in environmental control key technologies, facilities and equipment for laying hen production in China [J]. Transactions of the CSAE, 2020, 36(16): 212 - 221. (in Chinese)
- [4] 李保明. 畜禽养殖数字化技术装备 [J]. 兽医导刊, 2019(15): 9.
- [5] 许译丹, 谢秋菊, 刘洪贵, 等. 家禽精细养殖过程中的监测方法研究进展 [J]. 家畜生态学报, 2019, 40(2): 80 - 85.  
XU Yidan, XIE Qiuju, LIU Honggui, et al. Research progress on monitoring methods for fine farming of poultry [J]. Journal of Domestic Animal Ecology, 2019, 40(2): 80 - 85. (in Chinese)
- [6] 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)
- [7] RIDDLE E R, ALI A B A, CAMPBELL D L M, et al. Space use by 4 strains of laying hens to perch, wing flap, dust bathe, stand and lie down [J]. PLoS ONE, 2018, 13(1): e0190532.
- [8] 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)
- [9] 刘修林. 基于视觉技术的蛋鸡信息监测方法与应用研究 [D]. 太原: 中北大学, 2018.  
LIU Xiulin. Study on methods and applications of layer chicken information monitoring based on visual technology [D]. Taiyuan: North University of China, 2018. (in Chinese)
- [10] XIAO L, DING K, GAO Y, et al. Behavior-induced health condition monitoring of caged chickens using binocular vision [J]. Computers and Electronics in Agriculture, 2019, 156: 254 - 262.
- [11] ZHUANG Xiaolin, BI Minna, GUO Jilei, et al. Development of an early warning algorithm to detect sick broilers [J]. Computers and Electronics in Agriculture, 2018, 144: 102 - 113.
- [12] 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)
- [13] 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.
- [14] MBELWA H , MACHUVE D , MBELWA J. Deep convolutional neural network for chicken diseases detection [J]. *International Journal of Advanced Computer Science and Applications ( IJACSA )* , 2021 , 12( 2) : 759 – 765.
- [15] ZHANG H , CHEN C. Design of sick chicken automatic detection system based on improved residual network [C] // 2020 IEEE 4th Information Technology , Networking , Electronic and Automation Control Conference ( ITNEC ) . IEEE , 2020: 2480 – 2485.
- [16] WANG J , SHEN M , LIU L , et al. Recognition and classification of broiler droppings based on deep convolutional neural network [J]. *Journal of Sensors* , 2019 ( 2019) : 1 – 10.
- [17] LIN C Y , HSIEH K W , TSAI Y C , et al. Automatic monitoring of chicken movement and drinking time using convolutional neural networks [J]. *Transactions of the ASABE* , 2020 , 63( 6) : 2029 – 2038.
- [18] BAO J , XIE Q. Artificial intelligence in animal farming: a systematic literature review [J]. *Journal of Cleaner Production* , 2022 , 331: 129956
- [19] 杨断利 , 王永胜 , 陈辉 , 等. 基于改进 YOLO v6 – tiny 的蛋鸡啄羽行为识别与个体分类 [J]. *农业机械学报* 2023 , 54( 5) : 268 – 277.  
YANG Duanli , WANG Yongsheng , CHEN Hui , et al. Feather pecking abnormal behavior identification and individual classification method of laying hens based on improved YOLO v6 – tiny [J]. *Transactions of the Chinese Society for Agricultural Machinery* 2023 , 54( 5) : 268 – 277. ( in Chinese)
- [20] 赵守耀. 蛋鸡行为识别与健康评估系统研究 [D]. 太原: 中北大学 2022.  
ZHAO Shouyao. Study on behavior recognition and health assessment system of laying hens [D]. Taiyuan: North University of China 2022. ( in Chinese)
- [21] 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.
- [22] 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.
- [23] 刘莫尘 , 高甜甜 , 马宗旭 , 等. 基于 MSRCR – YOLO v4 – tiny 的田间玉米杂草检测模型 [J]. *农业机械学报* 2022 , 53( 2) : 246 – 255 , 335.  
LIU Mochen , GAO Tiantian , MA Zongxu , et al. Target detection model of corn weeds in field environment based on MSRCR algorithm and YOLO v4 – tiny [J]. *Transactions of the Chinese Society for Agricultural Machinery* 2022 , 53( 2) : 246 – 255 , 335. ( in Chinese)
- [24] 白强 , 高荣华 , 赵春江 , 等. 基于改进 YOLO v5s 网络的奶牛多尺度行为识别方法 [J]. *农业工程学报* 2022 , 38( 12) : 163 – 172.  
BAI Qiang , GAO Ronghua , ZHAO Chunjiang , et al. Multi-scale behavior recognition method for dairy cows based on improved YOLO v5s network [J]. *Transactions of the CSAE* , 2022 , 38( 12) : 163 – 172. ( in Chinese)
- [25] TAN M , PANG R , LE Q V. Efficientdet: scalable and efficient object detection [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition , 2020: 10781 – 10790.
- [26] YU Z , HUANG H , CHEN W , et al. YOLO – FaceV2: a scale and occlusion aware face detector [J]. *arXiv preprint* , arXiv: 2208.02019 , 2022.
- [27] QUAN Y , ZHANG D , ZHANG L , et al. Centralized feature pyramid for object detection [J]. *arXiv preprint* , arXiv: 2210.02093 , 2022.
- [28] 王月明 , 杜妍茹 , 陈甜甜 , 等. 基于 YOLO v5s 网络模型的牛只日常行为识别与统计研究 [J]. *黑龙江畜牧兽医* 2022 ( 14) : 48 – 51 , 56 , 137 – 139.  
WANG Yueming , DU Yanru , CHEN Tiantian , et al. Identification and statistical study of cattle daily behavior based on YOLO v5s network model [J]. *Heilongjiang Animal Husbandry and Veterinary* , 2022( 14) : 48 – 51 , 56 , 137 – 139. ( in Chinese)
- [29] SELVARAJU R , COGSWELL M , DAS A , et al. Grad-cam: visual explanations from deep networks via gradient-based localization [C] // Proceedings of the IEEE International Conference on Computer Vision , 2017: 618 – 626.
- [30] 夏焯 , 雷晓晖 , 祁雁楠 , 等. 基于改进 Ghost – YOLO v5s – BiFPN 算法检测梨树花序 [J]. *智慧农业( 中英文)* 2022 , 4( 3) : 108 – 119.  
XIA Ye , LEI Xiaohui , QI Yannan , et al. Detection of pear inflorescence based on improved Ghost – YOLO v5s – BiFPN algorithm [J]. *Smart Agriculture* , 2022 , 4( 3) : 108 – 119. ( in Chinese)