doi:10.6041/j.issn.1000-1298.2026.23.034

基于 YOLO－SAVD 和 DeepSORT 的轻量型家禽呼吸健康监测方法

杨立伟[1,2]　于欣迪[1,2]　毕泽洋[1,2]　赵旭阳[1,2]　李　寒[1,2]　张　漫[1,2]

（1.中国农业大学智慧农业系统集成研究教育部重点实验室，北京 100083；
2.中国农业大学信息与电气工程学院，北京 100083）

摘要：家禽夜间呼吸行为识别是早期呼吸道疾病监测的关键，尽管呼吸困难是呼吸道疾病的显著早期症状，但在集约化养殖环境中，由于夜间光照不足、鸡只高密度聚集导致的严重遮挡以及传统人工监测方法效率低下、主观性强等因素，该症状难以被有效识别。针对这一难题，本文提出了一种基于 YOLO 11n 框架的轻量级目标检测模型——YOLO－SAVD，用于准确识别鸡头目标并检测是否为张口状态。YOLO－SAVD 系统集成了 4 个创新模块：引入 StarNet 的轻量级网络作为 YOLO 11 的骨干网络，显著降低模型的计算量、参数量和模型内存占用量；引入 ADown 来改进卷积模块，降低计算成本的同时提升检测精度；引入 Slim－Neck 中的 VoV－GSCSP 来改进网络的 Neck 结构，在降低模型计算量和参数量的同时提升模型的检测精度；引入一种超轻量级且高效的动态上采样器 DySample，增强在光照不足条件下模型的特征融合能力。实验结果显示，YOLO－SAVD 模型的召回率和平均精度分别为 94.7%、97.5%，模型计算量仅为 3.7×10^9，模型内存占用量仅为 3.8 MB，对比 YOLO 11 原模型计算量降低 41.2%，内存占用量降低 31.0%。与主流的 YOLO 模型相比，YOLO－SAVD 在同等资源约束下实现了优越的准确性和鲁棒性。将 YOLO－SAVD 与 DeepSORT 算法相结合，与未改进的 YOLO 11n 相比，MOTA、MOTP 和 IDF1 分别提升 0.5、0.3、2.2 个百分点，IDS 减少 19 次。此外，本文通过基于 PyQt 开发的的应用程序，将 YOLO－SAVD 模型与 DeepSORT 目标追踪算法进行集成部署，用于实时检测鸡的张口闭口行为，统计个体张口呼吸时长，并对异常呼吸个体（单次张口呼吸持续超过 10 s）自动报警。该系统在实际测试中运行稳定，有效实现了设计目标，为大规模家禽养殖提供了一种高效的呼吸健康监测解决方案。

关键词：家禽呼吸行为识别；深度学习；轻量化网络；YOLO－SAVD；DeepSORT

中图分类号：TP391　　**文献标识码**：A　　**文章编号**：1000-1298(2026)23-0360-10　　**OSID**：

Lightweight Poultry Respiratory Health Monitoring Method Based on YOLO－SAVD and DeepSORT

Yang Liwei[1,2]　Yu Xindi[1,2]　Bi Zeyang[1,2]　Zhao Xuyang[1,2]　Li Han[1,2]　Zhang Man[1,2]

(1. *Key Laboratory of Smart Agriculture System Integration*, *Ministry of Education*, *China Agricultural University*, *Beijing* 100083, *China*
2. *College of Information and Electrical Engineering*, *China Agricultural University*, *Beijing* 100083, *China*)

Abstract: Aiming at the problem that dyspnea, a significant early symptom of respiratory diseases in poultry, is difficult to detect in the current intensive breeding environment due to factors such as low light at night, high-density occlusion, and the inefficiency of manual monitoring, a lightweight object detection model named YOLO－SAVD was presented based on the YOLO 11n framework. The YOLO－SAVD system incorporated four innovative modules: StarNet, which significantly reduced computational complexity, parameter count, and model memory footprint; ADown, which enhanced the detection accuracy with less computational expense; VoV－GSCSP, which facilitated weight and computational expense reduction while improving model detection accuracy; DySample, which enhanced the feature fusion capability under lowlight conditions. It was demonstrated that the model of YOLO－SAVD achieved a recall of 94.7% and mAP@0.5 of 97.5%, while maintaining a compact size of 3.8 MB and 3.7×10^9

收稿日期：2025－07－29　修回日期：2025－09－09

基金项目：中国农业大学 2115 人才工程项目（1081－00109022）

作者简介：杨立伟（1981—），女，教授，博士，主要从事智慧农业研究，E-mail：yangliwei@cau.edu.cn

of computation. Compared with the baseline, the GFLOPs was decreased by 41.2%, and weights was decreased by 31.0%. Under identical resource constraints, YOLO－SAVD demonstrated superior accuracy and robustness compared with mainstream YOLO models. The integration of YOLO－SAVD with the DeepSORT algorithm demonstrated superior performance compared with the unmodified YOLO 11n, achieving improvements of 0.5, 0.3, and 2.2 percentage points in MOTA, MOTP, and IDF1 metrics respectively, while reducing the number of ID switches (IDS) by 19. Furthermore, it deployed the proposed YOLO－SAVD model alongside the DeepSORT tracking algorithm in a PyQt-based application for real-time monitoring of chicken open/closed-mouth states, calculating individual open-mouth duration and automatically alerting for abnormal respiratory chickens. The system operated stably in practical tests and effectively met the design objectives. The framework demonstrated promising potential as an efficient solution for large-scale poultry farming.

Key words: poultry respiratory behavior recognition; deep learning; lightweight network; YOLO－SAVD; DeepSORT

0　引言

中国作为畜禽养殖大国，其中鸡只的健康程度直接关乎生产效率和经济效益[1]。近年来，养殖场规模化、标准化的趋势逐渐增强，但随之而来的疾病防控难题也日益突出，例如热应激和呼吸系统疾病[2-3]。热应激会加剧鸡只呼吸系统负荷，诱发呼吸道疾病；而新城疫、传染性支气管炎等呼吸道疾病具有传染性强、致死率高的特点，二者均会导致鸡只出现呼吸困难症状[2,4]。这种行为在夜间排除了饮水、啄食等主动动作的干扰，成为表征早期呼吸困难的可靠生物标志。因此，通过对夜间鸡只张口呼吸行为的识别和时长统计，可以实现对呼吸道疾病的早期预警，而传统的监测方法主要靠人工判断，不仅效率低，也容易受主观因素影响[4]。近年来，随着深度学习技术的蓬勃发展，基于计算机视觉的目标识别与多目标跟踪方法逐步应用于畜禽养殖领域[5-7]，为家禽呼吸健康监测提供了新的技术途径。

近年来，基于计算机视觉和深度学习的家禽智能监测研究不断发展。早期的家禽行为识别主要采用传统机器学习方法。在家禽识别方面[8-11]和家禽疾病识别与追踪方面[4,12-15]，诸多学者开展了大量研究。现有方法已能够实现家禽行为、健康状态及个体轨迹的自动识别，提高了监测效率和识别精度，但在夜间低照度、高密度遮挡条件下的个体持续跟踪、张口时长统计及轻量化部署方面仍存在不足。

临床研究表明，健康鸡群单次张口呼吸通常短于 3 s 且频次低，而异常个体（如患呼吸系统疾病或热应激）则呈现高频次、单次长时间持续（大于 10 s）的张口呼吸模式[4]。因此，通过对夜间鸡只张口闭口呼吸行为的识别和张口时长的判断可以对鸡只的呼吸道疾病进行早期预警。因夜间光照条件受限，以及鸡只高密度聚集的遮挡，目前方法对鸡只行为识别的精确度和鲁棒性有待提高，且尚未有利用个体化追踪技术识别病鸡的研究报道。此外，大多数模型的计算量和参数量很大，难于满足嵌入式系统的实时推理需求[16]。

为了解决这些问题，本研究将 StarNet、Adown、VoVGSCSP、DySample 模块集成到 YOLO 11 框架中构建 YOLO－SAVD，在保持检测精度的同时有效降低模型复杂度，增强在光照不足场景下的检测鲁棒性。基于 PyQt、YOLO－SAVD 和 DeepSORT 目标追踪算法开发一个实时呼吸健康监测系统，实时检测鸡只张口闭口状态，为每个鸡只分配唯一 ID 号并持续跟踪，精确检测个体张口闭口行为并统计个体张口状态的持续时间，以期实现持续跟踪并对有异常呼吸行为的鸡只自动报警。

1　数据集采集与处理

本研究的图像数据采集自山东省威海市的一个商业化养鸡场。在 2024 年 8 月 10 日至 9 月 12 日期间，从 21:00 至次日 05:00，使用 DH－3 H3405－ADG 型相机捕获视频数据。设备参数设置如下：分辨率 2 560 像素 ×1 440 像素，帧率 24 f/s，存储格式为 MP4。图 1a 展示了图像采集的实际场景，捕捉不同笼子配置中鸡群的行为图像，包括单笼、双笼和四笼配置，如图 1b～1d 所示，旨在构建覆盖不同遮挡程度和群体规模场景的数据集，以增强模型的泛化能力。

本实验使用 Python 和 OpenCV 处理原始数据，为了避免 24 f/s 原始视频中的行为重复，用 OpenCV 对视频进行下采样，并将帧率降低到 1 f/s。经过筛选，获得了 7 682 幅有效图像，覆盖单笼、双笼和四笼鸡。使用分层随机抽样的方式以比例 9∶1将数据集分为两部分，其中 6 913 幅图像用于训练，769 幅图像用于验证和测试。验证和测试集在不同的拍摄日期进行抽样，以确保数据独立性。

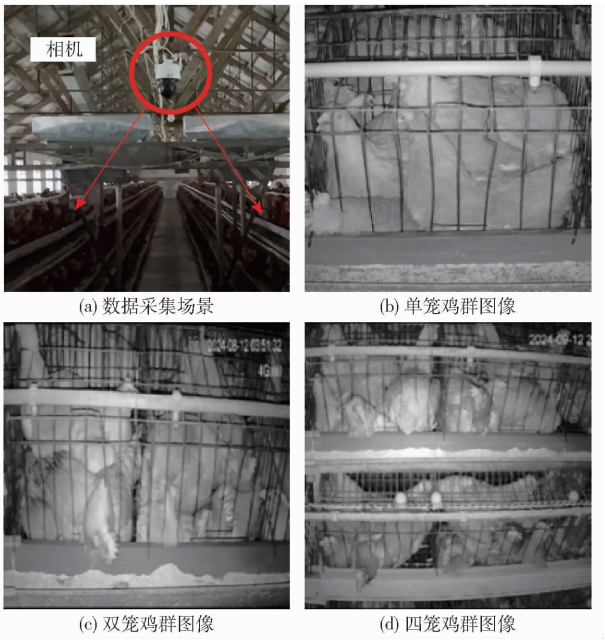

(a) 数据采集场景 (b) 单笼鸡群图像

(c) 双笼鸡群图像 (d) 四笼鸡群图像

图 1 实验环境与预处理图像

Fig. 1 Experimental environment and preprocessed image data

2 理论方法

2.1 基于 YOLO 11 的结构改进

2.1.1 YOLO－SAVD 模型结构

YOLO 11 作为 YOLO－SAVD 的基本框架，是 YOLO 系列中较为出色的版本之一，已逐步应用于智慧农业领域[17－19]。YOLO 11 包含输入(Input)、主干(Backbone)、颈部(Neck)、头部(Head)4 个模块，架构深化了特征融合：Backbone 采用改进 CSP 结构与高效注意力机制，减少冗余计算的同时强化关键特征提取，精准捕捉目标轮廓与细节；Neck 通过 FPN 与 PAN 协同，实现低维到高维特征充分交互，提升小目标及复杂背景下的检测鲁棒性；Head 采用无锚框解耦检测头，并结合任务对齐的样本分配策略与损失函数优化，提高目标定位精度。这些改进使其在智慧农业中，即便面对鸡只快速移动、羽毛纹理相似等干扰仍能稳定识别，为后续夜间光照、高密度场景优化提供基础，但仍需改进以解决夜间光照不足、鸡只密度高及嵌入式边缘部署问题。因此，本研究在 YOLO 11 模型的基础上，通过引入 StarNet 网络、ADown、VoVGSCSP 和 DySample 降低模型复杂度，实现模型轻量化，其结构如图 2 所示。

2.1.2 StarNet 模块

为满足嵌入式边缘设备部署需求，用 StarNet 替代原始主干网络，显著降低模型计算复杂度与内存占用，实现高效轻量化。StarNet 核心创新是星操作(Star operation)，通过元素级乘法实现双路特征融合，可在低维空间完成高维非线性映射；较传统依赖增加网络深度或加大计算开销的方案，星操作能在低计算成本下增强网络表征能力[20]。StarNet 将星操作整合至网络层间，计算资源受限条件下仍能保持较好的特征提取性能，其原始网络架构见图 3。其中，GAP/FC 为原始 StarNet 用于分类任务的分类头，本文将 StarNet 引入 YOLO 11 主干网络时去除该分类头，仅保留其特征提取部分；图中 d 表示特征通道维度，$4d$ 表示经全连接层扩展后的通道维度。

将 YOLO 11n Backbone 层中的主干网络替换为 StarNet_S1，同时保留 YOLO 11n 中的 SPPF 模块和 C2PSA 模块，目的是在减少计算量和参数量的同时，增强多尺度特征融合的能力，提高模型性能。

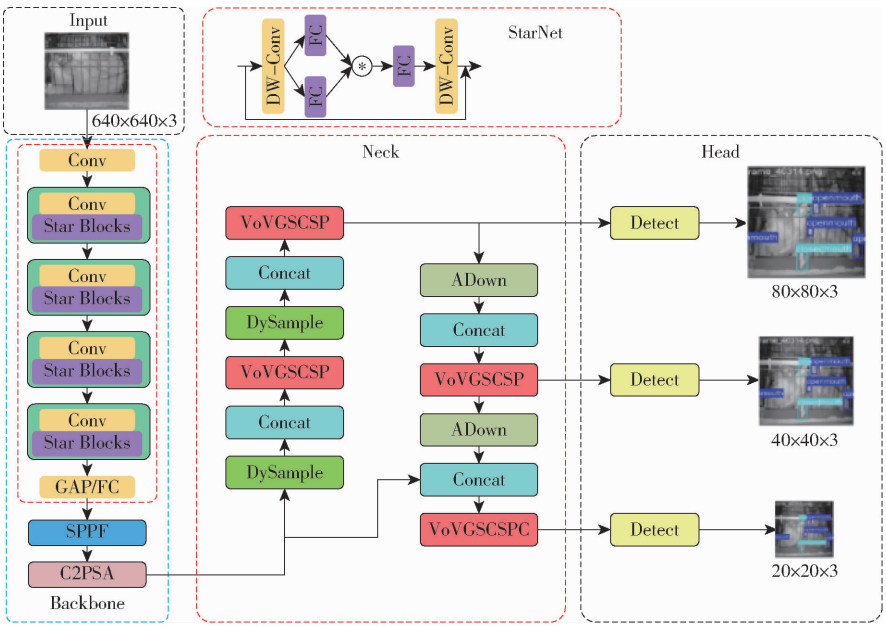

图 2 YOLO－SAVD 模型结构图

Fig. 2 Structural design of YOLO－SAVD model

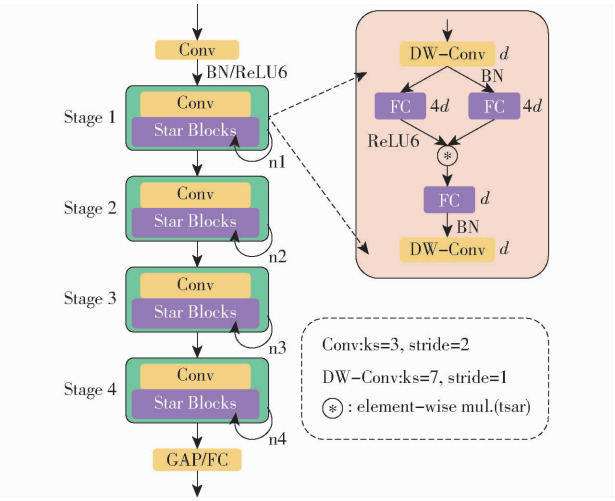

图 3　StarNet 结构示意图

Fig. 3　StarNet structure diagram

2.1.3　ADown 模块

为优化 YOLO 11 的嵌入式部署效率，用 ADown（Asymmetric downsampling）模块替代其 Neck 层标准卷积下采样层，在降低模型计算量、参数量的同时提升检测精度。传统卷积降维时存在特征丢失与计算冗余，尤其在禽群监测等密集目标场景中会影响小目标检测；而 ADown 通过非对称分组卷积与动态特征重组，降低分辨率时可显著提升特征保留能力，且满足轻量化需求[21]。ADown 的网络架构见图 4。

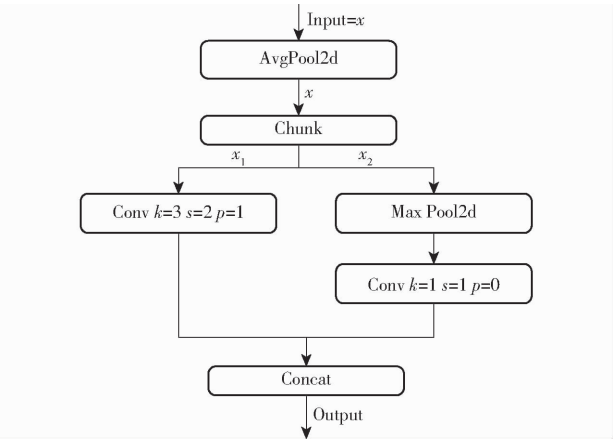

图 4　ADown 结构示意图

Fig. 4　ADown architecture overview

2.1.4　VoVGSCSP 模块

为在保证计算精度的同时降低模型计算成本，引入 Slim－Neck 结构的 VoVGSCSP 模块，替代 YOLO 11 Neck 层的核心 C3K2 模块。C3K2 虽能实现基础特征融合，但存在计算效率低、特征融合能力有限、硬件适配性差的局限；而 VoVGSCSP 作为 Slim－Neck 关键组件，创新点为分组空间-通道混合注意力机制、优化跨阶段连接及硬件友好设计，可在保证精度的同时降低计算要求、简化 Neck 结构、提升推理速度，更适配嵌入式边缘设备部署[22]。图 5 为 VoVGSCSP 模块的网络架构，它的主要由 GSConv（图 5a）、GSbottleneck（图 5b）组成。

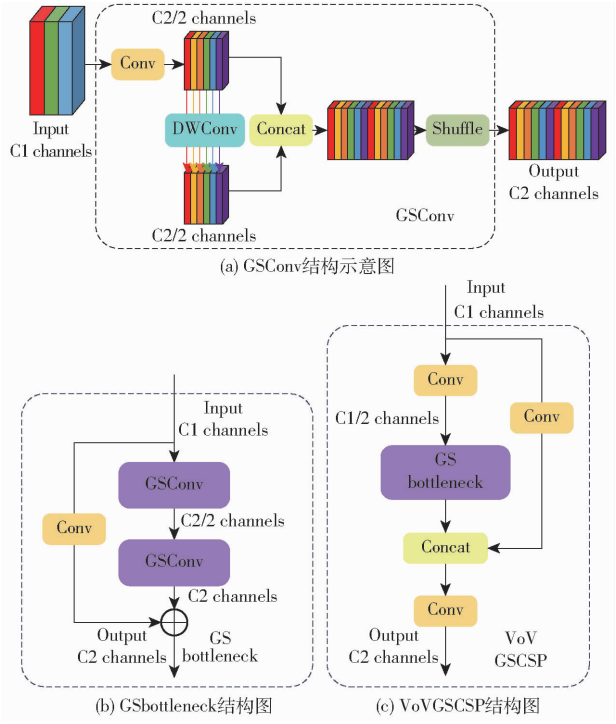

图 5　VoVGSCSP 以及组成部分结构示意图

Fig. 5　VoVGSCSP and its component structure diagram

2.1.5　DySample 模块

Neck 层采样操作对多尺度特征融合质量起决定性作用。YOLO 11 原架构的双线性插值上采样（UpSample）存在特征适应能力有限、多尺度兼容性不足、计算效率低的问题，尤其低光照下，固定采样模式难区分有效特征与噪声，易致细节模糊、边缘失真。为此，引入轻量有效的动态上采样器 DySample，核心是用动态点采样替代传统基于内核的动态卷积，图 6 显示了 DySample 的工作过程。DySample 的核心优势是通过轻量级线性层从输入特征图动态生成空间偏移量，使采样点依特征重要性自适应调整位置。为实现网络轻量化设计，采用网格采样结合线性映射的特征聚合方案，计算表达式为

$$x' = \text{grid_sample}(x, S) \tag{1}$$

$$O = \text{linear}(x) \tag{2}$$

$$S = g + O \tag{3}$$

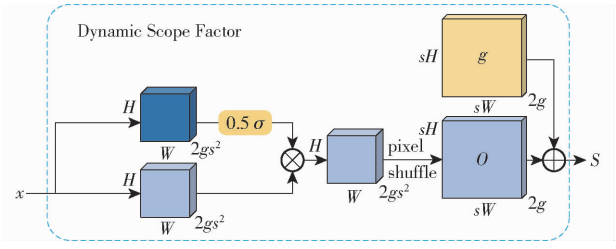

图 6　DySample 工作过程示意图

Fig. 6　DySample process schematic

式中 x——原始输入特征

S——网格采样尺度

x'——网格下采样特征

grid_sample(·)——网格采样函数

linear(·)——线性全连接层

O——通道调制特征

g——空间卷积特征

S——最终融合特征

该结构通过空间降采样 + 通道自适应变换压缩模型开销,可有效提升网络推理速度[23]。修改后的 Neck 模块标注于图 2 橙色虚线框内。

2.2 基于 DeepSORT 的家禽跟踪算法

2.2.1 多目标跟踪算法

DeepSORT 是 SORT[24]的改进版,适用于实时多目标跟踪(MOT)。它通过引入级联匹配和轨迹确认机制,有效缓解了目标遮挡与形变下的 ID 丢失问题,提升了跟踪稳定性,已广泛应用于行人、车辆跟踪及智能监控等领域[25]。其核心流程如下:

(1)运动状态建模

采用卡尔曼滤波(Kalman filter)预测目标在下一帧中的边界框位置与速度。状态向量定义为 $\boldsymbol{x} = [u, v, \gamma, h, \dot{u}, \dot{v}, \dot{\gamma}, \dot{h}]$,其中 (u, v) 为目标中心点坐标,γ 为宽高比,h 为高度,$\dot{u}$、$\dot{v}$、$\dot{\gamma}$、$\dot{h}$ 为对应变量的速度分量。预测阶段通过线性运动模型更新状态,公式为

$$\boldsymbol{X}_{k|k-1} = \boldsymbol{F}_k \boldsymbol{X}_{k-1|k-1} \tag{4}$$

$$\boldsymbol{P}_{K|K-1} = \boldsymbol{F}_{k|k-1} \boldsymbol{P}_{k|k-1} \boldsymbol{F}_k^{\mathrm{T}} + \boldsymbol{Q}_k \tag{5}$$

式中 $\boldsymbol{F}_k$——状态转移矩阵

$\boldsymbol{P}_K$——协方差矩阵

$\boldsymbol{Q}_k$——过程噪声

$\boldsymbol{X}_{k|k-1}$——k 时刻状态的先验估计值

(2)数据关联优化

使用匈牙利算法(Hungarian algorithm)完成检测框与预测轨迹的匹配,代价矩阵 $\boldsymbol{C}_{ij}$ 综合了运动相似性(马氏距离 $\boldsymbol{d}^{(1)}$)和外观相似性(余弦距离 $\boldsymbol{d}^{(2)}$),计算式为

$$\boldsymbol{C}_{ij} = \lambda \boldsymbol{d}^{(1)}(i,j) + (1-\lambda)\boldsymbol{d}^{(2)}(i,j) \tag{6}$$

(3)外观特征增强

DeepSORT 通过预训练的 ReID 网络提取目标外观特征(128 维向量),构建特征库 $F = \{f_1, f_2, \cdots, f_N\}$,弥补 SORT 仅依赖运动信息的不足。

(4)级联匹配策略

为缓解频繁遮挡导致的 ID 切换,算法优先匹配最近出现过的轨迹。计算前后两帧目标之间的匹配程度(利用匈牙利算法和级联匹配),为每个追踪到的目标分配 ID。

2.2.2 YOLO - SAVD 与 DeepSORT 算法融合

规模化养殖中,鸡只品种统一、形态相似易致多目标跟踪身份混淆。为实现家禽呼吸健康检测与个体化跟踪,本研究结合 YOLO - SAVD 与 DeepSORT 进行目标检测:YOLO - SAVD 检测视频帧鸡头区域(输出边界框),识别张口/闭口状态及置信度,为 DeepSORT 提供输入。跟踪处理:DeepSORT 先通过卡尔曼滤波(公式(4)、(5))依据前帧轨迹预测当前目标位置及边界框;再融合运动状态关联(计算检测框与预测框 IoU 或马氏距离初步匹配)与外观特征匹配(轻量级 ReID 网络提取鸡头 128 维特征,与轨迹特征库计算余弦距离),构建融合马氏距离 $\boldsymbol{d}^{(1)}$、余弦距离 $\boldsymbol{d}^{(2)}$ 的代价矩阵 $\boldsymbol{C}_{ij}$(公式(6)),经“级联匹配(优先近期轨迹) + 匈牙利算法”分配 ID 或初始化新轨迹,减少遮挡、光照变化导致的身份切换(IDS),保障 ID 稳定与行为统计准确。循环与报警:系统循环执行“检测-预测-特征提取-数据关联”,结合 YOLO - SAVD 张口状态与 DeepSORT 个体 ID 记录张口时长,若单个个体持续张口超 10 s 则判定异常并报警,系统工作流程见图 7。

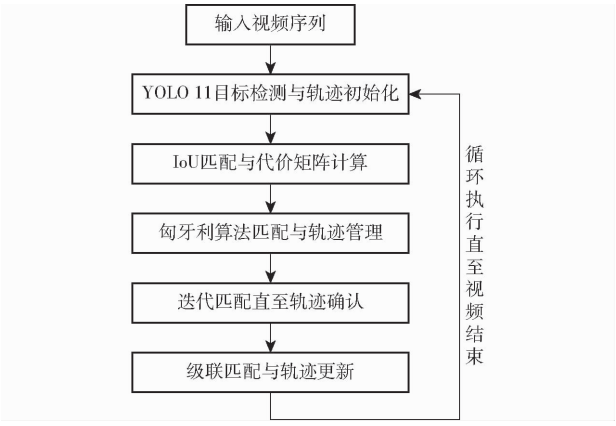

图 7 基于 YOLO - SAVD 与 DeepSORT 的目标跟踪流程图

Fig. 7 Workflow diagram of object tracking based on YOLO - SAVD and DeepSORT

3 实验与结果分析

3.1 实验平台

本实验模型均在 CPU 为 i9 - 14900HX,GPU 为 NVIDIA GeForce RTX 4060 的平台上进行,CUDA 版本为 12.6,Python 版本为 3.13.0,所使用网络在 PyTorch 深度学习框架下编写,PyTorch 版本为 2.6.0。另外,利用 LabelImg 软件对数据集的鸡头进行标注,包括张口和闭口 2 种标签。此外,本实验设置输入图像尺寸固定为 640 像素 × 640 像素,轮次数为 300,批量大小设置为 16。

3.2　评价指标

本研究采用精确率(P)、召回率(R)、平均精度均值(mAP)评估 YOLO－SAVD 在禽类喙部状态检测的性能[19]。高 P、R 值表明模型能更准确区分张口/闭口状态，有效降低漏检率；mAP 提供全面评估，其中 mAP@0.5 反映宽松 IoU 阈值下的检测性能，mAP@0.5:0.95 评估不同定位精度要求下的鲁棒性。针对部署效率，分析模型内存占用量、浮点计算量(GFLOPs)、参数量。这些指标对商业化家禽养殖的嵌入式系统至关重要，各指标综合证明模型是否适用于实际农业应用场景。

对于结合 DeepSORT 算法的多目标跟踪任务，引入以下评价指标，以评估跟踪算法在鸡群密集、光照不足场景下的性能：

(1)多目标跟踪准确率(Multiple object tracking accuracy，MOTA)用于综合评价跟踪过程中的漏检、误检和身份切换情况，其定义为

$$A_{\mathrm{MOTA}}=\left[1-\frac{\sum_{t}^{t}\left(F_{Nt}+F_{Pt}+N_{\mathrm{IDSW}t}\right)}{\sum_{t}G_{Tt}}\right]\times 100\% \tag{7}$$

式中　A_{MOTA}——多目标跟踪准确率

F_{Nt}——时间 t 处的遗漏检测数量

F_{Pt}——时间 t 处的不正确检测数量

$N_{\mathrm{IDSW}t}$——时间 t 处的身份切换数量

G_{Tt}——时间 t 处的地面实况对象数量

A_{MOTA}越大，表明跟踪算法的整体准确性越高。

(2)多目标跟踪精度(Multiple object tracking precision，MOTP)测量跟踪器在估计物体位置时的精度，其定义为

$$P_{\mathrm{MOTP}}=\frac{\sum_{t,i}D_{t,i}}{\sum_{t}C_{t}}\times 100\% \tag{8}$$

式中　P_{MOTP}——多目标跟踪精度

$D_{t,i}$——时间 t 时对象 i 的地面真实位置与预测位置之间的欧几里得距离

C_{t}——时间 t 时正确匹配(True positive 关联)的对象检测的数量

P_{MOTP}越大，表明预测框与真实框的重合程度越高，目标定位越准确。

(3)身份 F1 值(Identification F1 score，IDF1)：衡量所有帧上正确识别对象的精确度和召回率之间的平衡。其定义为

$$N_{\mathrm{IDF1}}=\frac{2N_{\mathrm{IDTP}}}{2N_{\mathrm{IDTP}}+N_{\mathrm{IDFP}}+N_{\mathrm{IDFN}}}\times 100\% \tag{9}$$

式中　N_{IDF1}——身份 F1 值

N_{IDTP}——正确匹配的身份数量

N_{IDFP}——错误匹配的身份数量

N_{IDFN}——未正确匹配的身份数量

N_{IDF1}越大，表明算法保持目标身份一致性的能力越强。

(4)身份切换次数(Identity switches，IDS)：跟踪过程中同一目标被分配不同 ID 的总次数，数值越低表示跟踪的连贯性越好，尤其在鸡只相互遮挡或光照变化时，IDS 的减少能有效保证个体呼吸行为统计的连续性。

3.3　YOLO－SAVD 算法实验

3.3.1　消融实验

YOLO－SAVD 集成了 StarNet、ADown、VoVGSCSP 和 DySample 4 个重要模块，在保证检测准确性的同时，显著降低了模型复杂度，包括计算量、参数量和模型内存占用量。为了评估各模块的贡献度，本研究通过消融实验对各个模块进行了独立评估，实验结果详见表 1。

表 1　消融实验结果

Tab.1　Ablation test results

模型	精确率/%	召回率/%	mAP@0.5/%	浮点运算量	参数量	内存占用量/MB
YOLO 11	93.4	94.6	97.6	6.3×10^{9}	2.6×10^{6}	5.5
YOLO 11＋StarNet	92.1	93.6	97.1	4.3×10^{9}	1.8×10^{6}	4.0
YOLO 11＋StarNet＋ADown	91.2	93.3	96.6	4.2×10^{9}	1.7×10^{6}	3.8
YOLO 11＋StarNet＋ADown＋VoVGSCSP	92.2	93.2	96.9	3.7×10^{9}	1.7×10^{6}	3.8
YOLO 11＋StarNet＋ADown＋VoVGSCSP＋DySample(YOLO－SAVD)	93.5	94.7	97.5	3.7×10^{9}	1.7×10^{6}	3.8

由表 1 可知，在原始 YOLO 11 模型上将主干网络替换为 StarNet 模块，并将卷积替换为 ADown 模块后，模型参数量从 2.6×10^{6} 降至 1.7×10^{6}(减少 34.6%)，浮点运算量由 6.3×10^{9} 降至 4.2×10^{9}(减少 33.3%)，模型内存占用量由 5.5 MB 降至 3.8 MB(减少 30.9%)，显著降低了模型复杂度。但轻量化设计对特征提取能力产生了一定的影响，其中 P、R 和 mAP@0.5 均略有下降。在引入 VoVGSCSP 模块后，浮点运算量显著降低至 3.7×10^{9}(降低 41.2%)，参数量稳定在 1.7×10^{6}，模型内存占用量

保持 3.8 MB,其分组空间–通道混合注意力机制、优化的跨阶段连接提高了模型的特征融合能力,在前 2 个模块基础上精确率提升 1.0 个百分点,mAP@0.5 提升 0.3 个百分点,在一定程度上弥补了前 2 个模块轻量化带来的损失。最终引入 DySample 模块,该模块显著提升了在光照不足条件下的特征融合能力,使得模型的精确率在此前基础上提升 1.3 个百分点,召回率提升 1.5 个百分点,mAP@0.5 提升 0.6 个百分点,同时浮点运算量、参数量和模型内存占用量保持不变。

当整合所有 4 个模块后,模型展现出最强的协同效应:与基线相比,浮点运算量降低 41.2%(降至 3.7×10^9),参数量减少 35.0%(降至 1.7×10^6),模型内存占用量减少 31.0%(降至 3.8 MB),同时精确率和召回率均提升 0.1 个百分点(分别达到 93.5% 和 94.7%)。尽管 mAP@0.5 略下降 0.1 个百分点,但这一降幅在实际场景中可忽略不计,且该配置实现了更优的全局鲁棒性——这是大规模家禽养殖的关键需求。

3.3.2 不同模型对比实验

表 2 给出了本研究提出的 YOLO–SAVD 模型与几个主流的 YOLO 模型的详细比较结果。结果显示 YOLO–SAVD 的召回率达 94.7%,为所有模型中最高,mAP@0.5 为 97.5%,虽略低于部分模型但差距可忽略,同时其浮点运算量仅 3.7×10^9,参数量 1.7×10^6,模型内存占用量 3.8 MB,较 YOLO 11 浮点运算量降低 41.2%、内存占用量减少 31.0%,远优于其他模型的轻量化表现,帧率 312.5 f/s,虽略低于 YOLO 11,但远高于 YOLO v8、YOLO v9 等模型,完全满足实时监测需求,表明 YOLO–SAVD 在检测精度、轻量化性能与实时性间实现更优平衡,特别适用于集约化家禽养殖中计算资源有限、环境复杂的场景,为大规模家禽呼吸健康监测提供了高效解决方案。图 8 展示了各模型的检测结果对比,其中第 1 排和第 4 排为单笼和四笼配置下各模型的检测结果,各模型结果均优异;第 2 排和第 3 排为双笼配置下的检测结果,其中红色边界框标注误检目标,黄色边界框标记漏检目标。图 8 展示的各模型检测结果直观呈现出 YOLO–SAVD 在夜间光照不足、鸡群密集的养殖场景中,漏检和误检数量显著少于其他模型,尤其在捕捉家禽张口呼吸等细微行为时表现更稳

表 2 对比实验结果

Tab. 2 Comparison experiment with mainstream models

模型	精确率/%	召回率/%	mAP@0.5/%	浮点运算量	参数量	内存占用量/MB	帧率/(f·s^{-1})
YOLO v8	93.5	94.0	97.7	6.8×10^9	2.7×10^6	5.7	178.6
YOLO v9	93.7	94.2	97.8	6.7×10^9	1.8×10^6	5.6	153.8
YOLO v10	93.2	94.1	97.6	8.4×10^9	2.7×10^6	5.8	212.3
YOLO 11	93.4	94.6	97.6	6.3×10^9	2.6×10^6	5.5	333.3
YOLO 12	93.1	94.3	97.4	6.6×10^9	2.5×10^6	5.2	263.2
YOLO–SAVD	93.5	94.7	97.5	3.7×10^9	1.7×10^6	3.8	312.5

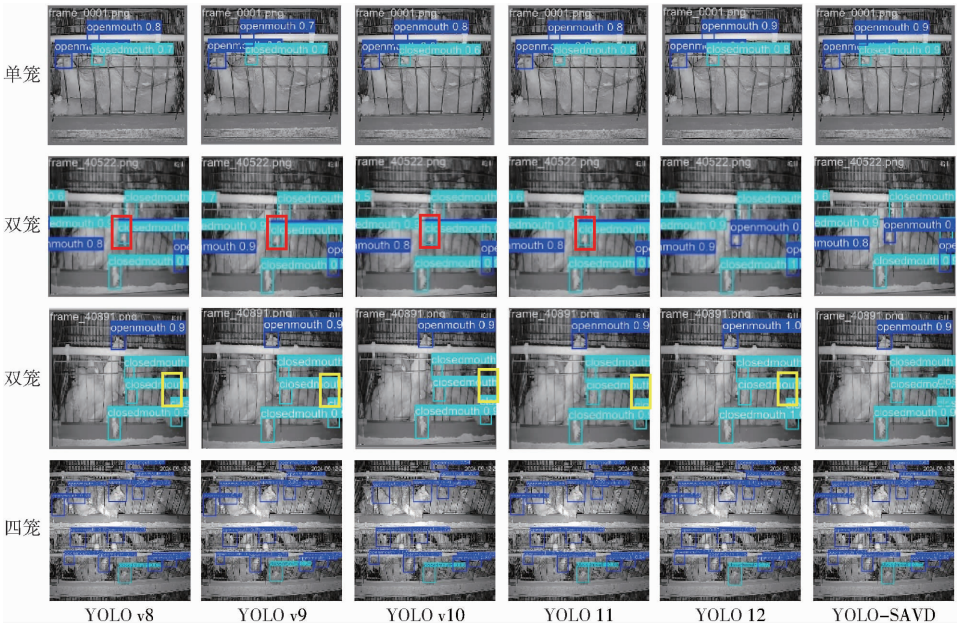

图 8 各模型检测结果

Fig. 8 Detection results of various models

定，进一步验证了其通过集成 StarNet、ADown、VoVGSCSP 和 DySample 模块所带来的优越性能，即在保证高精度检测的同时，增强了复杂环境下的鲁棒性。

3.4　YOLO－SAVD＋DeepSORT 实验与分析

为验证 YOLO－SAVD 与 DeepSORT 结合后的跟踪性能，本实验聚焦家禽夜间呼吸健康监测的核心场景，即鸡群密集、光照不足的养殖环境，重点评估算法对鸡只个体呼吸行为张口/闭口状态）的持续追踪能力及异常行为预警的可靠性。

跟踪实验选取与实际养殖环境高度匹配的夜间鸡群视频片段（帧率 1 f/s，分辨率 2 560 像素×1 440 像素），涵盖鸡只移动、相互遮挡、笼子栏杆遮挡等典型场景。这些场景与移动监测设备在养殖现场的实际工作环境一致，可有效验证算法在复杂条件下的跟踪稳定性。

将 YOLO－SAVD 作为 DeepSORT 的检测器，与原 YOLO 11n＋DeepSORT 算法进行对比，评估指标包括 MOTA、MOTP、IDF1 及 IDS。

实验结果如表 3 所示，改进后算法的关键指标均优于原模型：MOTA 提升 0.5 个百分点，MOTP 提升 0.3 个百分点，IDF1 提升 2.2 个百分点，验证了算法对鸡只个体身份识别的稳定性；IDS 减少 19 次，降低了因遮挡或光照变化导致的身份误切换，确保了对单一个体呼吸行为的持续追踪。尽管帧率略低于原 YOLO 11n＋DeepSORT，但在跟踪精度和身份一致性上的优势更符合养殖场景对个体行为持续监测的需求。

表 3　实验结果对比

Tab. 3　Comparison experiment

模型	MOTA/%	MOTP/%	IDF1/%	IDS
YOLO 11n＋DeepSORT	79.8	93.1	85.6	217
YOLO－SAVD＋DeepSORT	80.3	93.4	87.8	198

为直观展示算法性能，将关键场景的跟踪结果可视化。图 9 为 YOLO－SAVD＋DeepSORT 的跟踪效果：在双笼场景中，ID 为 4 和 5 的鸡只遮挡后再出现时，ID 保持不变，且张口/闭口状态的标注持续，确保异常呼吸时间统计的准确性。

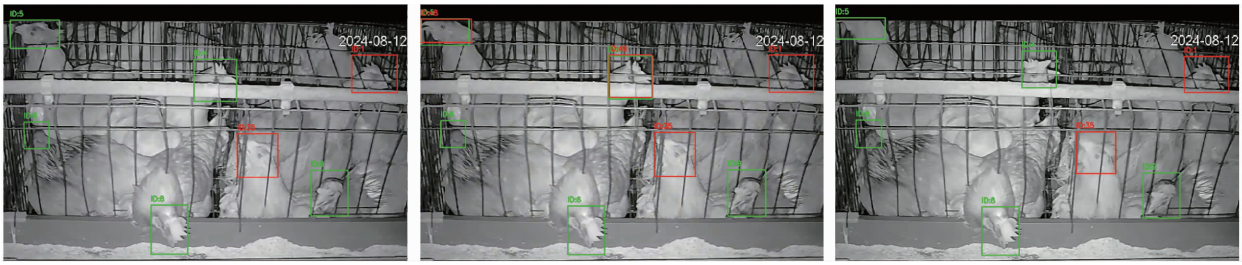

图 9　YOLO－SAVD 与 DeepSORT 的追踪效果

Fig. 9　Tracking performance of YOLO－SAVD＋DeepSORT

3.5　轻量化模型部署

本研究将 YOLO－SAVD 模型（best.pt 权重文件）与 DeepSORT 多目标跟踪算法协同集成至 PyQt5 开发框架，构建了“家禽夜间呼吸健康监测的轻量级实时检测系统”。

该系统主要技术特征包括：支持批量数据处理与检测结果可视化，以图表动态展示鸡群张口/闭口状态占比（图 10）；基于卡尔曼滤波、匈牙利匹配实现跨帧目标关联，通过 DeepSORT 为鸡只分配唯一 ID，实现个体识别追踪；结合高精度行为识别与量化分析，完成实时呼吸健康监测及风险预警。

本监测系统的实时性主要体现在算法处理效率、系统架构设计与功能响应时效 3 个层面：①核心 YOLO－SAVD 模型帧率达 312.5 f/s（见表 2）。②PyQt 框架采用多线程设计，分离视频捕获、检测跟踪、界面及报警模块并行执行，降低延迟。③功能响应及时，每帧同步更新张口状态与计时，依据

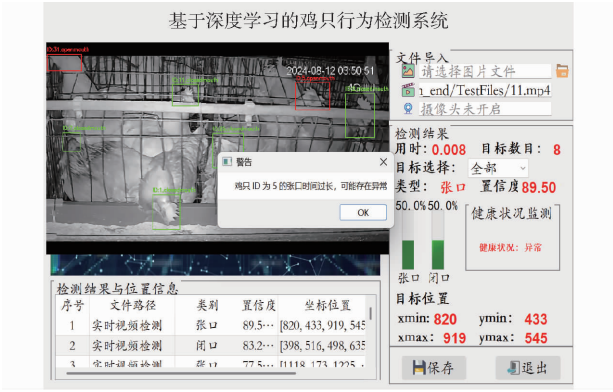

图 10　轻量化的夜间家禽呼吸健康监测系统界面

Fig. 10　Lightweight real-time detection system for poultry respiratory health monitoring at night

DeepSORT 的个体 ID 判断张口时长，超 10 s 阈值即触发异常报警。

该端到端流程可均在秒级完成“视频输入、行为识别、状态统计、风险预警”，满足大规模养殖场实时监测需求，能保证准确度，及时预警风险，降低人力成本与经济损失。

3.6 系统运行验证

为验证“家禽夜间呼吸健康监测的轻量级实时检测系统”的实际运行有效性及设计目标达成情况,在山东省威海市某商业化养鸡场的实际养殖环境中开展了系统测试。从山东省威海市某鸡舍采集的实际视频中挑选了5段具有代表性的30 s视频片段(分辨率2 560像素×1 440像素,帧率1 f/s)进行测试,这些视频不仅分别覆盖了单笼、双笼和四笼配置,并且包含不同程度的光照变化、鸡只遮挡和运动状态,以模拟实际监测中可能遇到的多类场景。结果显示系统在处理5段视频时均保持流畅运行,无卡顿、崩溃或数据丢失现象,平均CPU占用率为26%,GPU占用率为38%,整体视频处理帧率维持在310 f/s左右,接近实验室性能上限(312.5 f/s),表明系统具备良好的实时处理能力和资源调度效率,适合嵌入式设备长期部署。

为验证模型在资源受限环境下的部署能力,本研究使用一段统一的双笼鸡群视频(30 s,1 f/s)将YOLO-SAVD与原YOLO 11n模型进行对比测试,结果见表4。测试结果表明,YOLO-SAVD凭借其轻量化设计,在系统设备上同样表现出显著优势:CPU和GPU占用率分别降低了近50%和33%,同时处理帧率提升了27%,内存占用量减少31%。这证明了YOLO-SAVD更适用于在计算资源和能耗均受限的嵌入式设备或边缘计算节点上进行长期、稳定的部署。状态识别准确性方面,系统在5段视频中共处理150帧图像,结果如表5所示。识别张口状态实例412个,闭口状态实例1 256个。经人工核对,张口状态识别平均准确率为94.1%,闭口状态为95.7%,综合漏检率为5.3%,与YOLO-SAVD模型在验证集上的表现(召回率为94.7%,mAP@0.5为97.5%)高度吻合。

表4 模型性能测试结果

Tab.4 Performance comparison of different models

模型	CPU占用率/%	GPU占用率%	帧率/(f·s^{-1})	内存占用量/MB
YOLO 11	35	48	22	5.5
YOLO-SAVD	18	32	28	3.8

表5 视频识别准确性测试结果

Tab.5 Video recognition accuracy test results

序号	张口个数	张口识别准确率/%	闭口个数	闭口识别准确率/%	综合漏检率/%
1	72	95.0	210	96.5	4.8
2	75	94.5	215	96.0	5.0
3	82	94.0	250	95.8	5.2
4	88	93.5	285	95.0	5.5
5	95	93.5	296	95.2	5.8
平均值	82.4	94.1	251.2	95.7	5.3

系统基于DeepSORT为鸡只分配唯一ID,以保证个体呼吸行为统计的连续性。在频繁遮挡场景中共发生6次身份切换,主要出现在严重遮挡或快速移动情况下,表明系统具有较好的跟踪稳定性。系统共触发3次持续张口报警,其中2次经人工回放确认对应异常呼吸行为,1次由啄食动作引起误报,报警响应时间均小于1 s。

PyQt界面运行流畅,可实时显示检测框、个体ID、状态占比及报警日志。综合测试结果表明,该系统能够较稳定地完成个体跟踪、呼吸状态统计和异常预警,可为养殖场家禽呼吸健康监测提供技术支持。

4 结论

(1)本研究提出轻量化夜间家禽呼吸监测模型YOLO-SAVD。其精确率、召回率和mAP@0.5分别为93.5%、94.7%和97.5%,浮点运算量和内存占用量为3.7×10^9和3.8 MB,较YOLO 11分别降低41.2%和30.9%。结合DeepSORT后,MOTA、MOTP和IDF1分别达到80.3%、93.4%和87.8%,IDS减少19次。

(2)基于DeepSORT和PyQt开发了实时监测系统,可实现张口状态识别、个体跟踪、时长统计和异常预警。实际测试中,张口和闭口识别准确率分别为94.1%和95.7%,综合漏检率为5.3%,报警响应时间小于1 s。

参 考 文 献

[1] 朱宁. 蛋鸡产业2024年发展形势及值得关注的问题[J]. 中国禽业导刊, 2024, 41(7): 27-30.
Zhu Ning. Development trends and issues of concern in the layer industry for 2024[J]. China Poultry Industry Guide, 2024, 41(7): 27-30. (in Chinese)

[2] Yeh Y H, Chen B L, Hsieh K Y, et al. Designing an autonomous robot for monitoring open-mouth behavior of chickens in commercial chicken farms[J]. Journal of the ASABE, 2025, 68(1): 25-36.

[3] Bakar M A A A, Ker P J, Tang S G H, et al. A hybrid chromaticity-morphological machine learning model to overcome the limit of detecting Newcastle disease in experimentally infected chicken within 36 h[J]. Computers and Electronics in Agriculture, 2025, 234: 110248.

[4] 陈佳, 丁奇安, 刘龙申, 等. 基于YOLO v5与短时跟踪的鸡只呼吸道疾病早期检测[J]. 农业机械学报, 2023, 54(1):

271－279.
Chen Jia, Ding Qi'an, Liu Longshen, et al. Early detection of chicken respiratory diseases based on YOLO v5 and short-term tracking[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(1): 271－279. (in Chinese)

[5] Manoj S, Rakshith S, Kanchana V. Identification of cattle breed using the convolutional neural network[C]// 2021 3rd International Conference on Signal Processing and Communication (ICPSC). Coimbatore, India: IEEE, 2021: 503－507.

[6] 陈晨. 基于计算机视觉和深度学习的群养猪行为识别与分类算法研究[D]. 镇江：江苏大学, 2020.
Chen Chen. Research on behavior recognition and classification algorithms for group-housed pigs based on computer vision and deep learning[D]. Zhenjiang: Jiangsu University, 2020. (in Chinese)

[7] 葛雯, 姜添元. 改进 YOLO 与 DeepSORT 检测跟踪算法的研究[J]. 计算机仿真, 2022, 39(5): 186－190.
Ge Wen, Jiang Tianyuan. Research on improved YOLO and DeepSORT detection and tracking algorithm[J]. Computer Simulation, 2022, 39(5): 186－190. (in Chinese)

[8] 陈晨, 卢筱磊, 陈柚青, 等. 基于改进 YOLO 11s－Broiler 的复杂环境下笼养鸡全生长周期行为识别模型[J]. 云南农业大学学报(自然科学), 2025, 40(3): 44－56.
Chen Chen, Lu Xiaolei, Chen Youqing, et al. A behavior recognition model for the full cycle of caged chickens in complex environments based on improved YOLO 11s－Broiler[J]. Journal of Yunnan Agricultural University (Natural Science), 2025, 40(3): 44－56. (in Chinese)

[9] Wang Y, Cuan K, Pei W, et al. A two-stage deep learning approach for identifying low-yield hens in stacked cage systems[J]. Computers and Electronics in Agriculture, 2025, 231: 109958.

[10] Fang C, Zhang T, Zheng H, et al. Pose estimation and behavior classification of broiler chickens based on deep neural networks[J]. Computers and Electronics in Agriculture, 2021, 180: 105863.

[11] Li G, Zhao Y, Porter Z, et al. Automated measurement of broiler stretching behaviors under four stocking densities via faster region-based convolutional neural network[J]. Animal, 2021, 15(1): 100059.

[12] Zhuang X, Zhang T. Detection of sick broilers by digital image processing and deep learning[J]. Biosystems Engineering, 2019, 179: 106－116.

[13] 李亚硕, 毛文华, 胡小安, 等. 基于机器视觉识别鸡冠颜色的病鸡检测方法[J]. 机器人技术与应用, 2014(5): 23－25.
Li Yashuo, Mao Wenhua, Hu Xiaoan, et al. Sick chicken detection with chicken crown color based on machine vision[J]. Robot Technique and Application, 2014(5): 23－25. (in Chinese)

[14] 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)

[15] Yang X, Bist R, Paneru B, et al. Monitoring activity index and behaviors of cage-free hens with advanced deep learning technologies[J]. Poultry Science, 2024, 103(11): 104193.

[16] Wu D, Cui D, Zhou M, et al. Information perception in modern poultry farming: a review[J]. Computers and Electronics in Agriculture, 2022, 199: 107131.

[17] Khanam R, Hussain M. YOLO v11: an overview of the key architectural enhancements[PP/OL]. V1. arXiv (2024－10－23)[2026－07－31]. https://arxiv.org/abs/2410.17725. DOI:10.48550/arXiv.2410.17725.

[18] Qin J, Chen Z, Zhang Y, et al. YOLO－CT: a method based on improved YOLO v8n－Pose for detecting multi-species mature cherry tomatoes and locating picking points in complex environments[J]. Measurement, 2025, 254: 117954.

[19] Lin T Y, Maire M, Belongie S, et al. Microsoft COCO: common objects in context[C]// Computer Vision－ECCV 2014. Cham: Springer, 2014: 740－755.

[20] Ma X, Dai X, Bai Y, et al. Rewrite the Stars[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE, 2024: 5694－5703.

[21] Wang C Y, Yeh I H, Liao H Y M. YOLO v9: learning what you want to learn using programmable gradient information[C]// Computer Vision-ECCV 2024. Cham: Springer, 2024: 1－21.

[22] Li H, Li J, Wei H, et al. Slim-neck by GSConv: a lightweight-design for real-time detector architectures[J]. Journal of Real-Time Image Processing, 2024, 21(3): 62.

[23] Liu W, Lu H, Fu H, et al. Learning to upsample by learning to sample[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision. Paris, France: IEEE, 2023: 6027－6037.

[24] Bewley A, Ge Z, Ott L, et al. Simple online and realtime tracking[C]// 2016 IEEE International Conference on Image Processing. Phoenix, USA: IEEE, 2016: 3464－3468.

[25] Wojke N, Bewley A, Paulus D. Simple online and realtime tracking with a deep association metric[C]// 2017 IEEE International Conference on Image Processing. Beijing, China: IEEE, 2017: 3645－3649.