

基于 YOLO v8 - ST 的叠层笼养肉鸡死鸡识别方法

王红英^{1,2} 杨慧琳¹ 郝宏运¹ 宋道一¹ 王粮局^{1,2} 孙宪法³

(1. 中国农业大学工学院, 北京 100083; 2. 农业装备技术全国重点实验室, 北京 100083;

3. 山东民和牧业股份有限公司, 烟台 264000)

摘要: 针对规模化商品肉鸡养殖场中死鸡自动检测问题, 构建了一种基于改进 YOLO v8 的检测模型。基于自建数据集, 提出 YOLO v8 - ST 模型, 在 C2f 模块中引入移位稀疏卷积 (Shift-wise Conv), 通过小核卷积模拟大核感受野以增强复杂场景下的特征提取能力; 同时引入 Power Transform (PT) 函数优化对齐度量中的 Overlap 计算, 以提升高质量预测框的学习能力。实验结果表明, YOLO v8 - ST 模型的精确率、召回率和平均精度分别达到 94.7%、92.8% 和 97.6%, 较基线分别提升 4.2、4.1、4.0 个百分点。针对模型复杂度较高的问题, 引入 LAMP 剪枝方法进行轻量化优化。在全局剪枝率为 33% 时, 模型平均精度仅下降了 2.0 个百分点, 而浮点计算量降低约 33.0%, 参数量与模型内存占用量 (9.1 MB) 分别减少 60.0% 和 57.0%。多相机实验结果表明: 单相机模型在同源数据上性能最优; 多相机数据融合可显著提升检测性能; 低照度相机在低照度环境下具有替代高价工业相机的潜力。

关键词: 叠层笼养肉鸡; 死鸡; YOLO v8; 模型剪枝; 低照度相机

中图分类号: S858.3; TP391.41

文献标识码: A

文章编号: 1000-1298(2026)15-0075-11

OSID:



Identification Method of Dead Broilers in Stacked Cages Based on YOLO v8 - ST

Wang Hongying^{1,2} Yang Huilin¹ Hao Hongyun¹ Song Daoyi¹ Wang Liangju^{1,2} Sun Xianfa³

(1. College of Engineering, China Agricultural University, Beijing 100083, China

2. State Key Laboratory of Agricultural Equipment Technology, Beijing 100083, China

3. Shandong Minhe Animal Husbandry Co., Ltd., Yantai 264000, China)

Abstract: A detection model based on the improved YOLO v8 was constructed to address the issue of automatic dead chicken detection in large-scale commercial broiler farms. Based on a self-built dataset, the YOLO v8 - ST model was proposed. In the C2f module, the shift-wise convolution was introduced to simulate large kernel receptive fields through small kernel convolutions, thereby enhancing the feature extraction capability in complex scenarios. Meanwhile, the Power Transform (PT) function was introduced to optimize the overlap calculation in the alignment metric, improving the learning ability of high-quality prediction boxes. Experimental results showed that the precision, recall, and average precision of the YOLO v8 - ST model reached 94.7%, 92.8%, and 97.6%, respectively, which were 4.2, 4.1, 4.0 percentage points higher than the baseline. To address the issue of high model complexity, the LAMP pruning method was introduced for lightweight optimization. When the global pruning rate was 33%, the average precision of the model was decreased by only 2.0 percentage points, while the floating-point operation count was reduced by approximately 33.0%, and the number of parameters and model size (9.1 MB) were reduced by 60.0% and 57.0%, respectively. The results of multi-camera experiments indicated that the single-camera model performed optimally on homologous data; multi-camera data fusion could significantly improve detection performance; and low-illumination cameras had the potential to replace expensive industrial cameras in low-illumination environments. The methods and conclusions proposed for dead chicken detection can provide theoretical references for the automatic inspection of dead chickens in broiler farms.

Key words: stacked cage rearing broiler; dead broiler; YOLO v8; model pruning; low-light camera

0 引言

白羽肉鸡是我国肉鸡的主要品种,属于“快大型”的肉用品种鸡,主要用于快餐、团餐等的需要^[1],主要采用笼养模式^[2]。死鸡巡检是白羽肉鸡养殖过程中的重要日常工作,死鸡若没有及时清理,极易成为病原传播源,对健康鸡群造成威胁。然而在商品白羽肉鸡养殖中,肉鸡养殖规模庞大,人工巡检不仅耗时费力且存在健康和安全风险。实现肉鸡死鸡的自动化检测对改善肉鸡养殖福利以及提升生产效益具有重要意义。

现有研究围绕家禽死亡识别已开展了一定探索。早期方法多基于传统图像处理技术,通过颜色分割^[3]、几何特征提取等手段实现死鸡判别,但鲁棒性较差。随着深度学习的发展,研究逐渐转向基于目标检测模型的方法,并结合巡检机器人实现自动化应用。李腾飞等^[4]基于规模化蛋鸡笼养模式,设计了一种蛋鸡健康行为检测机器人,但是该机器人识别效率受舍内光线影响较大。以平养肉鸡为研究对象,Liu 等^[5]开发了一种肉鸡死鸡清除装置,基于 YOLO v4 网络构建了肉鸡死鸡检测模型,模型对死鸡识别的准确率为 95.24%,但当死鸡的头部和脚部被遮挡时,易出现漏检。Xin 等^[6]搭建了基于轮式移动平台的肉鸡死鸡捡拾装置,构建了基于 YOLO v6 目标检测算法的肉鸡死鸡识别模型,测试结果表明,基于 YOLO v6 构建的死鸡识别模型的准确率为 86.1%,死鸡捡拾成功率为 81.3%,但模型对远距离的遮挡死鸡识别困难。此外,部分研究结合红外图像或多模态信息提升识别效果。姜来等^[7]以叠层笼养肉鸡为研究对象,开发了一套死鸡识别机器人系统,该系统通过 Otsu 算法提取鸡图像,图像去噪后通过红外图像判别笼内是否存在死鸡。Li 等^[8]开发了一种死亡肉鸡移除机器人系统,基于彩色图像和 YOLO v4 模型构建了肉鸡死鸡识别模型,探究不同光照条件下的模型识别准确率,结

果表明在 1 000 lx 光照条件下,模型对死鸡识别准确率最高,为 90.0%,实验过程表明模型对光照条件较敏感。总体来看,深度学习方法显著提升了检测精度,但在复杂环境下仍存在一定局限。现有研究仍存在以下不足:研究对象多集中于笼养蛋鸡或平养肉鸡,对叠层笼养肉鸡关注较少;模型在实际养殖环境中易受光照变化、目标遮挡等因素影响,导致识别性能下降^[9]。同时,肉鸡与蛋鸡在外观特征及生长周期上差异显著,且高密度养殖条件下个体间相似度高,增加了目标检测难度,使得现有方法难以直接迁移应用。因此,有必要针对叠层笼养肉鸡复杂环境开展更加鲁棒的死鸡检测方法研究。

基于此,本文以商品肉鸡养殖场为研究对象,采集实际生产环境中的死鸡图像数据,构建一种基于改进 YOLO v8 的死鸡检测模型。在主干网络中引入移位卷积以增强特征提取能力,提高对遮挡及小目标的识别效果;在标签分配策略中引入 Power Transform(PT)函数,以提升高质量检测框的学习能力,从而增强模型在光照不均及背景复杂条件下的检测稳定性;同时采用 LAMP 剪枝方法实现模型轻量化部署。对多源相机数据下的检测效果进行对比分析,以期为叠层笼养环境下肉鸡健康巡检机器人的研发提供技术参考。

1 数据集构建与检测模型建立

1.1 数据采集

实验数据采集于山东省烟台市民和股份有限公司的一家商品肉鸡养殖场。该养殖场采用叠层笼养的养殖方式,单栋鸡舍结构为 2 层 4 层叠,共 8 层鸡笼,单笼长 240 cm,宽 160 cm,高 45 cm,共计 1 632 套,每笼养殖罗斯 308 肉鸡约 70 只。鸡舍采用螺旋喂料的方式,使用乳头饮水器供水,笼具内部上方配备白炽灯(暖色光)用于提供照明,笼内照度在 5 ~ 20 lx 之间。图 1 显示了单套笼具的三维图与现场图像。



图 1 肉鸡舍笼具与采集现场

Fig. 1 Broiler chicken house cages and collection site

为提升数据集多样性,选用 Sony XCG - 240C 型工业相机、HK MV - CA023 - 10UC 型工业相机、华兴视讯 G1 型低照度相机及 RealSense L515 型相机,对 3 ~ 6 周龄肉鸡进行图像采集,覆盖第 1、2 层鸡笼。如表 1 所示,不同相机在分辨率、传感器性能及光照适应能力等方面存在差异,可有效模拟多设

备成像环境,从而提升模型鲁棒性与实际应用价值。图 1c 为采集现场。采集过程中,相机固定于三脚架上:第 1 层采集时,镜头中心距地 91 cm、距笼门约 17 cm,并以约 60°俯角拍摄;第 2 层采集时,镜头高度调整为 165 cm。图像采集由便携式计算机控制,通过调节相机位置、光圈及焦距,以适应低照度环境

表 1 相机参数

Tab.1 Camera parameters

参数	Sony XCG - 240C	HK MV - CA023 - 10UC	华兴视讯 G1	Intel RealSense L515
传感器型号	Sony IMX249	Sony IMX249	Sony IMX355	CMOS 彩色传感器
分辨率/(像素 × 像素)	1 920 × 1 200	1 920 × 1 200	1 920 × 1 080	1 920 × 1 080
帧率/(f·s ⁻¹)	41	40	60	30

并保证图像清晰度。

1.2 数据集构建与网络训练

剔除重复图像后,共计得到 2 520 幅肉鸡图像,使用 Labelimg 对图像中的肉鸡进行标注,其中死亡肉鸡被标注为“dead”类,其他肉鸡被统一标注为“broiler”类。按照 VOC 格式整理图像与标注数据,共计标注正常肉鸡样本 26 600 只,死亡肉鸡样本 2 350 只,按照 8:1:1 划分为训练集、验证集与测试集。本文实验平台为: Intel (R) Core (TM) i7 - 9700K 处理器,内存容量为 16 GB,GPU 为 NVIDIA GeForce RTX 3060 和 NVIDIA GeForce RTX 3070,操

作系统为 Ubuntu 20. 04,Cuda 版本为 11. 6。为了保持训练环境一致,所有模型均不使用预训练权重参与训练,输入图像大小设定为 640 像素 × 640 像素, batch size 设定为 4,共训练 300 个轮次,其他参数均保持为默认。

1.3 肉鸡死鸡检测模型构建与优化

1.3.1 YOLO v8 目标检测网络

YOLO v8 具有高精度与快速推理的优势,已在农业视觉领域得到广泛应用^[10]。其结构主要由主干网络 (Backbone)、颈部网络 (Neck) 和检测头 (Head) 组成,如图 2 所示。




图 2 YOLO v8 网络结构图

Fig. 2 Network structure diagram of YOLO v8

主干网络负责提取多尺度特征,包含标准卷积 (Conv)、C2f 和 SPPF 模块。其中,Conv 模块由卷积层、批量归一化层及激活函数层构成,是基本特征提取单元;C2f 模块融合 YOLO v5 的 C3 与 YOLO v7 的 E - ELAN 设计思想^[11],通过跨层连接与特征拼接增强特征表达能力;SPPF 模块通过连续最大池化

实现多尺度感受野信息融合。特征融合网络采用 FPN 与 PAN 结构,通过自上而下与自下而上的路径传递,实现高层语义信息与低层空间信息的融合,从而提升模型对多尺度及小目标的检测能力。

1.3.2 移位卷积

C2f 模块通过部分特征跨层连接和瓶颈卷积堆

叠实现特征复用,在有效减少参数量的同时加快了网络收敛速度。然而,3×3 卷积虽然减少了参数量,但在复杂场景(如多尺度、遮挡或密集目标)下其感受野和特征融合能力受限。Ding 等^[12]研究表明大核卷积能够有效扩大网络的感受野,从而提升模型对复杂特征的理解能力,但与此同时,大核卷积会不可避免地增加模型的计算量。移位卷积(Shift-wise Conv)是由 Li 等^[13]提出的卷积操作,旨在通过重参数化小卷积核结构达到大卷积核有效扩大网络感受野的效果,同时保持硬件友好性和计算效率。其核心思想是利用“移位操作”(shift operation)和“稀疏化”(sparsity)来扩展卷积核的感受野,建立长距离依赖关系,同时相对同样大小感受野的大核卷积能够保持更好的计算效率。

图 3a 显示 Shift-wise Conv 首先将大卷积核分解为多个小卷积核,并对其卷积结果施加空间位移,以模拟大核卷积的感受野;同时,通过沿特征维度的位移操作扩展感受区域,并支持通过裁剪部分位移分支实现动态特征建模,如图 3b 所示。此外,通过构建稀疏组卷积结构并移除冗余连接,在保持通道规模不变的前提下降低计算复杂度,实现结构高效化,如图 3c 所示。




图 3 Shift-wise Conv 结构组成及整体示意图
Fig. 3 Composition and overall schematic of Shift-wise Conv structure

在此基础上,本文在主干网络中引入了 Shift-wise Conv 模块,并使用重参数化操作分离模块的训

练与推理结构,构建了包含重参数化的 Shift-wise Conv 模块 SW Conv。如图 4 所示,使用 SW bottleneck 模块来替换 C2f 模块中的残差块结构,构建了 C2f_shift 替换主干网络中所有的 C2f 模块。通过使用小卷积核来模拟大核卷积的效果,扩大主干网络的感受野,从而提升主干网络的全局上下文建模能力,以及密集预测任务的性能。




图 4 C2f_shift 模块
Fig. 4 C2f_shift module

1.3.3 Power Transform 函数

任务对齐学习是 TOOD 网络中提出的一种改进的正负样本分配策略。该方法通过重新设计样本分配机制和引入任务对齐损失函数,使检测中的分类任务与回归任务在优化过程中实现显式对齐,从而使两者预测的最优框更加一致。其中,样本分配机制通过抑制低对齐度预测框的分类得分,同时提升高对齐预测框的分类效果,并以对齐指数来评估预测框的对齐程度,实现预测框的动态优化。在 YOLO v8 中,对齐指数通过预测框与真实框交并比(o)与预测框分类得分(s)进行加权求和计算得出。

在 RTMDet^[14]中,使用 IoU 的对数作为回归成本以达到放大低 IoU 值匹配成本的效果,以解决广义 IoU 作为匹配代价时难以区分高低质量匹配的问题,使不同真实-预测标签对的匹配质量更具区分性。回归成本 C_{reg} 的计算公式为

$$C_{reg} = -\lg(IoU) \tag{1}$$

为了加强不同真实-预测标签对的匹配质量和损失权重的区分性,参考 RTMDet 使用 IoU 的对数放大回归成本的思路,引入了 Power Transform (PT) 函数对预测框与真实框交并比进行优化。促使网络在训练过程中加强对高质量预测框的关注,并抑制低质量预测框带来的干扰。优化后的交并比函数 O_{PT} 计算公式为

$$O_{PT} = \begin{cases} o^2 & (o < T) \\ o^{0.5} & (o \geq T) \end{cases} \tag{2}$$

式中 T ——设定的 o 阈值

图 5 显示了在阈值 $T = 0.5$ 的条件下,使用 Power Transform 优化后的 O_{PT} 函数。图中绿色直线表示原始交并比函数 o ,蓝色与红色曲线分别代表优化后的 O_{PT} 函数。当输入 $x < 0.5$ 时,使用 Power

Transform优化的 O_{PT} 函数会降低函数的输出值 y , 从而达到进一步抑制低对齐度预测框的作用; 而当 $x > 0.5$ 时, Power Transform 函数会放大 y 的值, 从而达到增强高对齐度预测框的效果。在 x 接近阈值 T 时, 这种抑制或增强效应越显著。在任务对齐学习中, 模型会降低低精度预测框的影响, 同时强化高精度预测框的学习, 使得模型学习更多的高质量预测框样本。




图 5 O_{PT} 函数曲线

Fig. 5 Visualization of O_{PT} function

1.3.4 模型部署测试

Lee 等^[15]提出了一种基于层自适应幅度的模型剪枝方法 (Layer-adaptive magnitude-based pruning, LAMP)。LAMP 将层级别的权重幅度剪枝扩展到全局剪枝, 通过最小化模型输出的 L2 范数失真来动态分配各层稀疏度, 优先对模型整体影响最小的连接进行剪枝, 并提出了一种基于权重张量贡献的评分方法来判定需要剪枝的通道。定义权重张量 $\mathbf{w}$ 的第 u 个索引权重的 lamp 分数 s 计算公式为

$$s(u; \mathbf{w}) = \frac{(\mathbf{w}_{[u]})^2}{\sum_{v > u} (\mathbf{w}_{[v]})^2} \quad (3)$$

式中, $\mathbf{w}$ 为卷积层或全连接层的权重张量, u, v 为权重张量的索引, 其中分母是当前权重及其最大权重的平方和, 用于归一化权重的幅度。

LAMP 剪枝方法首先逐层计算所有卷积层和全连接层的 lamp 分数, 接着按照 lamp 分数从小到大对权重进行排序, 形成全局分数池。根据目标稀疏度, 在全局分数池中选择对应的分位数作为阈值, 将低于 lamp 分数阈值的权重置为零, 直到达到目标稀疏度, 并在每层中至少保留一个权重连接来保证网络的连通性。每次剪枝后验证模型在验证集上的精度损失, 若损失超过预设阈值, 则回退剪枝比例并重新调整, 重复直至达到目标稀疏度且精度损失在可接受范围。其流程如图 6 所示。

1.3.5 评价指标

在目标检测任务中, 为全面评估模型性能, 需从检测精度、模型复杂度及运行效率等多个维度进行综合评价。本文选取精确率 (Precision)、召回率




图 6 模型剪枝流程图

Fig. 6 Model pruning flowchart

(Recall)、平均精度 (Average precision, AP)、平均精度均值 (Mean average precision, mAP)、模型参数量、浮点计算量及推理速度 (Frames per second, FPS) 作为评价指标。

2 结果与分析

2.1 消融实验

为了验证改进后模型效果, 设计消融实验, 用于对比不同改进对模型性能的影响。如表 2 所示, 当仅在网络中加入 C2f_shift 后, 模型的精确率和平均精度均提升 1.3 个百分点, 参数量和召回率略有下降, 但浮点计算量增加了约 14%, 推理速度下降到 124.2 f/s。引入 C2f_shift 模块能够提升模型的精度, 但额外的模块增加了模型复杂度, 降低了推理速度。当仅使用 PT 函数进行模型优化时, 模型的精确率、召回率和平均精度分别提升了 2.2、1.0、2.1 个百分点, 参数量、浮点计算量和推理速度基本保持不变。对于模型召回率提升这一现象, 主要是由于 PT 函数通过对 IoU 进行非线性变换, 增强了高质量预测框的梯度贡献, 从而提高了预测框与真实框之间的匹配质量, 使部分原本定位不足的预测框能够满足评价阈值要求, 从而减少漏检并提升召回率。综上, 引入 PT 函数进行网络优化, 能够提升模型性能, 而不会增加模型的结构复杂度和推理开销。当

表 2 消融实验结果

Tab.2 Results of ablation experiment

模型	精确率/%	召回率/%	平均精度/%	参数量	浮点计算量	推理速度/(f·s ⁻¹)
YOLO v8	90.5	88.7	93.6	1.11 × 10 ⁷	2.86 × 10 ¹⁰	139.2
YOLO v8 + C2f_shift	91.8	87.1	94.9	1.10 × 10 ⁷	3.27 × 10 ¹⁰	124.2
YOLO v8 + PT0.5	92.7	89.7	95.7	1.11 × 10 ⁷	2.86 × 10 ¹⁰	139.3
YOLO v8 + C2f_shift + PT0.5	94.7	92.8	97.6	1.10 × 10 ⁷	3.27 × 10 ¹⁰	124.7

同时加入 C2f_shift 和 PT 函数优化时,模型的精确率、召回率、平均精度分别提升了 4.2、4.1、4.0 个百分点,参数量和浮点计算量主要受 C2f_shift 模块影响而增加,推理速度下降了约 14.5 f/s。

表 3 显示了改进前后模型在各类别上的检测性能。改进模型在正常肉鸡类别上的召回率和平均精度均值分别提升 3.0、0.4 个百分点,但精确率略有下降。相较于死鸡类别,其性能提升幅度较小,主要由于正常肉鸡样本数量更多、特征更复杂,且包含较多遮挡与小目标情况,增加了检测难度。

表 3 改进前后模型性能

Tab.3 Model performance before and after improvement %

模型	类别	精确率	召回率	平均精度均值
YOLO v8	all	89.9	86.2	93.2
	broiler	89.3	83.7	92.9
	dead	90.5	88.7	93.6
YOLO v8 - ST	all	91.4	89.8	95.4
	broiler	88.1	86.7	93.3
	dead	94.7	92.8	97.6

需要指出的是,本研究数据集中死鸡样本数量相对较少,整体规模有限,类别分布存在不平衡现象。该问题易使模型偏向多数类特征学习,从而影响少数类检测性能。为此,引入移位卷积(Shift-wise Conv)与 PT 函数,以增强特征表达并优化目标匹配。由表 3 可知,在类别不平衡条件下,改进模型在死鸡类别上的性能显著提升,精确率、召回率和平均精度均值分别由 90.5%、88.7% 和 93.6% 提升至 94.7%、92.8% 和 97.6%。同时,整体平均精度均值由 93.2% 提升至 95.4%,表明该方法在提升少数类检测能力的同时,保持了良好的整体性能与稳定性。未来将通过扩展数据规模及丰富多场景样本,进一步提升模型的泛化能力。

2.2 检测结果可视化分析

图 7 展示了 YOLO v8 与 YOLO v8 - ST 在不同相机图像上的检测效果。对比可见,YOLO v8 - ST 在远距离小目标及低照度场景下具有更优表现,能够有效识别暗处死鸡目标。同时,在遮挡严重或背景复杂条件下,原始 YOLO v8 易出现漏检、误检及

定位不准等问题,而改进模型显著减少了上述现象,并整体提升了检测置信度。该结果表明,引入 PT 函数有助于优化预测框质量,从而提升模型在复杂环境中的检测性能。

为进一步验证 Shift-wise Conv 对感受野的影响,提取两种模型主干网络第 4、6、8 层特征图进行可视化分析,如图 8 所示(图例表示影响强度)。结果显示,随着网络加深,感受野逐渐扩大;相比之下,YOLO v8 - ST 的感受野分布更广,表明引入 Shift-wise Conv 能够有效增强全局上下文建模能力。

综上,Shift-wise Conv 从特征提取层面提升模型对密集遮挡场景的感知能力,而 PT 函数从损失优化角度增强预测框与真实目标的匹配质量。两者协同作用,使模型在叠层笼养复杂环境下实现更高的检测精度,并有效降低漏检与误检。

在实际生产中,肉鸡死亡后呈现腹部上翻、鸡爪僵直的形态特征,鸡胸部颜色由粉红色逐渐变为红棕色、黑色,羽毛暗淡、凌乱或紧贴在肉鸡体表^[16-17],与正常肉鸡具有明显的外观差异。彩色相机将光信号转化成电信号,捕捉物体的彩色图像,从而反映物体的形态、纹理、颜色等特征。对比图 7 中不同相机图像的测试结果,所有图像均能够反映出死亡肉鸡的姿态、纹理特征,而颜色特征却因不同相机的性能而存在视觉差异,这意味着不同相机图像构建的死鸡模型可能存在通用性差异。例如,Sony XCG-240C 型工业相机采集图像颜色偏黄对比度较高,其构建的检测模型能够更好提取图像特征;HK MV-CA023-10UC 型工业相机整体亮度偏暗且存在过曝欠曝,构建的模型检测效果可能较差;华兴视讯 G1 低照度相机图像与 RealSense L515 型相机采集图像最清晰,过曝现象少,但颜色差异并不明显,可能在一定程度上影响模型鲁棒性。

2.3 与不同模型检测结果对比

为评估改进模型性能,将其与目前主流目标检测模型在同一数据集上进行对比,实验结果如表 4 所示。由表 4 可看出,YOLO v8 - ST 模型获得了最高的平均精度和召回率,分别为 97.6% 与 92.8%,基于 YOLO v10 构建的模型获得了最高的推理速




图 7 改进前后网络检测效果对比

Fig. 7 Comparison of network detection performance before and after improvement




图 8 不同层的感受野

Fig. 8 Receptive fields of different layers

度,为 165.3 f/s,基于 YOLO 11 构建的模型精确率最高,为 95.3%。相比之下,YOLO v8 - ST 的计算量有所增加,推理速度略有下降。总体来看,YOLO v8 - ST 在召回率和平均精度上均优于其他模型,表现出更强的综合检测能力。尽管其精确率略低于 YOLO 11,但差异较小,同时显著提升了召回率,有效减少了漏检情况。综合各项指标,YOLO v8 - ST

模型性能最优。

2.4 模型剪枝

基于 CNN 的目标检测模型通常存在精度与复杂度正相关的特点,即参数量增加虽可提升性能,但会带来计算开销增大与推理速度下降等问题。尽管 YOLO v8 - ST 在死鸡检测精度上取得提升,但其较高的参数量与计算量不利于实际部署。为此,采用

表 4 不同网络模型性能对比

Tab.4 Performance comparison of different network models

模型	精确率/%	召回率/%	平均精度/%	参数量	浮点计算量	推理速度/(f·s ⁻¹)
YOLO v8	90.5	88.7	93.6	1.11 × 10 ⁷	2.86 × 10 ¹⁰	139.2
YOLO v8-ST	94.7	92.8	97.6	1.10 × 10 ⁷	3.27 × 10 ¹⁰	124.7
YOLO v9 ^[18]	91.4	90.7	94.9	7.2 × 10 ⁶	2.67 × 10 ¹⁰	143.2
YOLO v10 ^[19]	93.2	85.4	93.7	7.2 × 10 ⁶	2.14 × 10 ¹⁰	165.3
YOLO 11 ^[20]	95.3	87.1	94.4	9.4 × 10 ⁶	2.13 × 10 ¹⁰	154.0
YOLO 12 ^[21]	91.4	88.1	93.6	9.2 × 10 ⁶	2.12 × 10 ¹⁰	143.3
YOLO 26 ^[22]	92.9	88.1	94.0	9.5 × 10 ⁶	2.05 × 10 ¹⁰	161.0

模型剪枝对其进行轻量化优化。

表 5 给出了基于 LAMP 剪枝的实验结果(剪枝率为被剪掉的浮点计算量与剪枝前模型浮点计算量的比例。全局剪枝为对模型中所有卷积权重张量的 lamp 分数值设定统一阈值对模型进行剪枝,而局部剪枝策略为对每个卷积中的权重张量设定一个 lamp 分数值阈值进行剪枝)。在全局剪枝策略下,当剪枝率为 33% 时模型性能最优,此时死鸡类别的精确率、召回率和平均精度分别为 93.1%、90.7%

和 95.6%,平均精度较原模型仅下降约 2.0 个百分点,同时浮点计算量降低约 33%,参数量减少 60%,模型内存占用量压缩至 9.1 MB,减少 57%。说明在适度剪枝条件下,可在较小精度损失的前提下显著降低模型复杂度。随着剪枝率进一步增大,模型参数与计算量持续下降,但关键特征信息损失加剧,导致性能明显退化。相比之下,全局剪枝在压缩参数量与模型规模方面更具优势,而局部剪枝在精度保持方面表现更优。

表 5 模型剪枝效果对比

Tab.5 Comparison of model pruning effects

模型	精确率/%	召回率/%	平均精度/%	参数量	浮点计算量	模型内存占用量/MB
原始	94.7	92.8	97.6	1.10 × 10 ⁷	3.27 × 10 ¹⁰	21.2
lamp-33%-True	93.1	90.7	95.6	4.4 × 10 ⁶	2.16 × 10 ¹⁰	9.1
lamp-50%-True	90.9	82.0	90.6	3.0 × 10 ⁶	1.62 × 10 ¹⁰	6.3
lamp-60%-True	94.0	85.1	91.7	2.4 × 10 ⁶	1.31 × 10 ¹⁰	5.0
lamp-66%-True	88.7	80.6	87.3	2.0 × 10 ⁶	1.08 × 10 ¹⁰	4.2
lamp-33%-False	92.5	88.5	92.7	6.6 × 10 ⁶	2.17 × 10 ¹⁰	13.5
lamp-50%-False	91.6	88.1	93.5	4.4 × 10 ⁶	1.63 × 10 ¹⁰	9.1
lamp-60%-False	91.7	85.1	92.2	3.1 × 10 ⁶	1.30 × 10 ¹⁰	6.4
lamp-66%-False	91.0	83.1	91.2	2.3 × 10 ⁶	1.09 × 10 ¹⁰	4.8

注: 33%、50%、60%、66% 分别表示模型的剪枝率,True 或 False 表示是否使用全局剪枝。

2.5 肉鸡死鸡识别算法部署

将剪枝后的模型部署在边缘计算设备进行性能测试分析。设备为 Jetson Xavier NX 开发套件,简称 Jetson NX。其功率与尺寸的优势、支持深度学习推理的功能,十分适合工业部署与应用。将模型使用 TensorRT 部署在 Jetson NX 上,20 W 满功率运行下,得到模型的推理速度为 36.2 f/s,模型内存占用量为 4.8 MB,满足实时检测的需求(大于相机帧率 30 f/s)。当使用模型量化方法将模型的浮点(FP16)运算转化为整型(INT8)运算时,模型的推理速度可以进一步提高到 49.6 f/s,模型内存占用量缩减为 3.9 MB。

2.6 不同相机图像检测效果对比

遮挡和低照度是家禽健康监测中普遍存在的问题^[23-24]。针对遮挡问题,现有研究者主要从数据

(扩充数据集)、模型(强化特征提取)、图像获取(调整视角)3 个方面来缓解遮挡对检测的负面影响^[25]。本文在模型侧通过提高网络多尺度特征提取能力,改善了对部分遮挡死鸡的检测效果。在数据侧使用多相机图像构建数据集,增强了模型的鲁棒性。

在低照度环境下,现有方法多通过补光或采用高灵敏度工业相机缓解光照不足问题。然而,补光易引发家禽应激反应,而高性能相机则增加成本与部署复杂度。相比之下,低照度相机在灵敏度、成本与功耗之间取得较好平衡,具有替代高端工业相机的潜力。基于此,本文对 4 种成像设备构建的检测模型性能进行了系统对比。

2.6.1 单相机图像模型测试结果

针对不同成像设备,分别从华兴视讯 G1(520

幅)、HK MV-CA023-10UC(610 幅)、Sony XCG-240C(622 幅)及 RealSense L515(768 幅)图像中随机抽取各 100 幅构建测试集,其余数据经增强扩展至 2 100 幅用于训练与验证。基于各相机数据分别构建死鸡检测模型,并在对应测试集上进行评估。表 6 结果亦符合前文对不同相机图像构建模型检测效果的分析。HK MV-CA023-10UC 型工业相机亮度较低且过曝欠曝,故构建的模型误检、漏检最多,Sony XCG-240C 型工业相机存在局部过曝、欠曝,但对比度高,模型参数能更好提取该类图像的特征,构建的模型误检、漏检最少,华兴视讯 G1 型低照度相机图像与 RealSense L515 型相机采集图像较清晰,但对比度较低,颜色差异不明显,故检测效果处于两者之间。

该结果初步表明,在单一成像条件下,亮度合适且对比度较高的相机效果较好。另外,从错误总数(漏检+误检)可看出低照度相机图像的检测效果与高端工业相机相当。

表 6 单相机图像模型测试结果

Tab.6 Test results of single camera image mode 只

图像采集设备	漏检数	误检数	总计	死鸡总数
华兴视讯 G1	13	4	17	94
HK MV-CA023-10UC	28	2	30	90
Sony XCG-240C	11	1	12	103
RealSense L515	14	3	17	93

2.6.2 单相机图像模型交叉测试结果对比

图 9 给出了基于 4 种相机数据构建模型的交叉测试结果。结果表明,各模型在同源数据上表现最优,而在异源数据上性能明显下降。说明单一相机数据训练的模型主要依赖图像的颜色与纹理等低-中层特征,对成像条件变化较为敏感,导致跨设备泛化能力不足。这也表明,在当前数据规模与模型容量下,死鸡检测任务尚未上升到“语义不变”的高维表征。

2.6.3 混合多相机图像模型测试结果对比

将 4 组测试集合并为包含 400 幅图像的混合测试集,并从剩余样本中均衡抽取 1 730 幅图像构建多相机训练集。基于该数据训练的模型在混合测试集上的结果如表 7 所示。相比单相机模型,多相机数据显著提升了检测性能:漏检明显减少,误检略有增加,且不同相机间性能差异显著缩小。对比表 6 可知,混合多相机图像模型在测试集上的测试效果优于单相机图像数据构建的模型。不同相机采集的数据等价于一种“自然的数据增强”,有效提升了模型的泛化能力。这与 Brown 等^[26]研究中同一模型在不同相机采集数据上推理结果差异超过 10%,但




图 9 多模型交叉测试结果

Fig. 9 Cross-test results of multiple models

混合多相机数据训练后性能显著提升的结论一致。这表明在复杂畜禽舍的检测任务中,可以引入成像多样性来改善模型的检测精度。

表 7 混合多相机图像模型结果对比

Tab.7 Comparison of results of mixed multiple

camera image models			只
图像采集设备	漏检数	误检数	错误总数
华兴视讯 G1	6	7	13
HK MV-CA023-10UC	12	0	12
Sony XCG-240C	3	5	8
RealSense L515	4	7	11

进一步分析表 7 可见,不同相机条件仍对检测结果产生影响,HK MV-CA023-10UC 因亮度不足导致漏检较多,而华兴视讯 G1 与 RealSense L515 因对比度较低易引发类别混淆,误检相对较高。这表明模型在跨设备条件下仍依赖颜色与纹理特征,性能存在一定波动。但总体而言,各相机数据下错误数量均保持较低水平,表明模型具备一定的跨设备适应能力。未来将通过扩展多源数据并结合颜色归一化、域泛化等方法,进一步提升模型在复杂成像条件下的鲁棒性与泛化性能。

综上,在低照度环境下,低照度相机在肉鸡死鸡检测任务中可获得与工业相机相当的检测精度。结合图 7 分析,G1 低照度相机在保证成像清晰度的同时,有效抑制了工业相机常见的过曝与欠曝问题,并避免了 RealSense L515 存在的色偏与细节模糊现象,表现出良好的成像稳定性与应用潜力。

3 结论

(1) 针对叠层笼养肉鸡环境中遮挡严重、低照度及光照不均问题,提出了一种改进 YOLO v8 的死鸡检测模型(YOLO v8-ST)。通过在主干网络中引入移位卷积增强特征提取能力,并结合 Power Transform 函数优化标签分配策略,提高模型对遮

挡、小目标及复杂光照条件的适应性。实验结果表明,模型精确率、召回率和平均精度分别达到 94.7%、92.8% 和 97.6%,较原模型分别提升 4.2、4.1、4.0 个百分点。

(2)基于 LAMP 剪枝策略对模型进行轻量化优化。在全局剪枝率为 33% 时,模型在保持较高检测性能(平均精度为 95.6%)的同时,浮点计算量降低约 33%,参数量减少 60%,模型内存占用量由 21.2 MB 压缩至 9.1 MB。进一步结合 TensorRT 在 Jetson NX 平台部署后,推理速度达到 36.2 f/s,模型内存占用量降至 4.8 MB,满足实际应用需求。

(3)单相机数据训练的模型在同源数据上性能最优,而在异源数据上表现下降,表明模型对成像条件变化敏感,跨设备泛化能力有限。因此,在实际应用中需尽量保证训练与应用数据的一致性。

(4)多相机数据混合训练可显著提升模型性能,减少漏检并增强跨设备适应能力,说明数据多样性对提升模型泛化能力具有重要作用。

(5)在低照度养殖环境中,低照度相机可获得与高灵敏度工业相机相当的检测性能,且在成像稳定性、成本及部署便捷性方面具有优势,具备良好的应用潜力。

参 考 文 献

[1] 中国畜牧兽医信息网. 突围:中国白羽肉鸡自主育种记[EB/OL]. [2026-04-16]. https://www.nahsorg.cn/dt/xwlb/202201/t20220106_395345.htm.

[2] 中华人民共和国农业农村部. 肉鸡立体养殖技术指导意见[EB/OL]. [2026-02-07]. https://www.moa.gov.cn/gk/nszd_1/2023/202307/t20230703_6431379.htm.

[3] 瞿子淇. 无人养鸡场死鸡检测方法研究[D]. 长春:吉林大学, 2019.
Qu Ziqi. Research on the detection method of dead chickens in unmanned chicken farms[D]. Changchun: Jilin University, 2019. (in Chinese)

[4] 李腾飞. 笼养蛋鸡健康行为监测机器人系统研究[D]. 北京:中国农业大学, 2016.
Li Tengfei. Study on caged layer health behavior monitoring robot system[D]. Beijing: China Agricultural University, 2016. (in Chinese)

[5] Liu H W, Chen C H, Tsai Y C, et al. Identifying images of dead chickens with a chicken removal system integrated with a deep learning algorithm[J]. Sensors, 2021, 21(11):3579.

[6] Xin C, Li H, Li Y, et al. Research on an identification and grasping device for dead yellow-feather broilers in flat houses based on deep learning[J]. Agriculture, 2024, 14(9):1614.

[7] 姜来, 王文娣, 霍晓静, 等. 死鸡识别机器人系统设计与试验[J]. 中国农机化学报, 2023, 44(8): 81-87.
Jiang Lai, Wang Wendi, Huo Xiaojing, et al. Design and experiment of a robot system for identifying dead chickens[J]. Journal of Chinese Agricultural Mechanization, 2023, 44(8): 81-87. (in Chinese)

[8] Li G, Chesser G D, Purswell J L, et al. Design and development of a broiler mortality removal robot[J]. Applied Engineering in Agriculture, 2022, 38(6):853-863.

[9] 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.

[10] 梁秀英, 贾学镇, 何磊, 等. 基于 YOLO v8n-seg 和改进 Strongsort 的多目标小鼠跟踪方法[J]. 农业机械学报, 2024, 55(2):295-305, 345.
Liang Xiuying, Jia Xuezhen, He Lei, et al. Multi-target mouse tracking method based on YOLO v8n-seg and improved Strongsort[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(2):295-305, 345. (in Chinese)

[11] 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[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.

[12] Ding X, Zhang Y, Ge Y, et al. Unireplknet: a universal perception large-kernel convnet for audio video pointcloud ti me-series and image recognition[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024:5513-5524.

[13] Li D, Li L, Chen Z, et al. Shift-ConvNets: small convolutional kernel with large kernel effects[C]//Proceedings of the IEEE/CUF Conference on Computer Vision and Pattern Recognition. IEEE, 2025:25281-25291.

[14] Lyu C, Zhang W, Huang H, et al. Rtmddet: an empirical study of designing real-time object detectors[PP/OL]. V2. arXiv (2022-12-16)[2026-06-24]. <https://doi.org/abs/2212.07784>.

[15] Lee J, Park S, Mo S, et al. Layer-adaptive sparsity for the magnitude-based pruning[PP/OL]. V2. arXiv(2021-05-09)[2026-06-24]. <https://arXiv.org/abs/2010.07611>.

[16] 郝宏运, 姜伟, 罗升, 等. 基于彩色与热红外图像信息融合的肉鸡死鸡识别方法[J]. 农业机械学报, 2025, 56(1):47-55, 64.
Hao Hongyun, Jiang Wei, Luo Sheng, et al. Identification method of dead broilers based on the fusionof color and thermal infrared image Information[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(1):47-55, 64. (in

Chinese)

[17] Ma W, Wang X, Yang S X, et al. Autonomous inspection robot for dead laying hens in caged layer house[J]. Computers and Electronics in Agriculture, 2024, 227:109595.

[18] Yaseen M. What is YOLO v9; an in-depth exploration of the internal features of the next-generation object detector[PP/OL]. V1. arXiv(2024 - 09 - 12) [2026 - 06 - 24]. <https://arXiv.org/abs/2409.07813>.

[19] Wang A, Chen H, Liu L, et al. YOLO v10: real-time end-to-end object detection[J]. Advances in Neural Information Processing Systems, 2025, 37:107984 - 108011.

[20] Khanam R, Hussain M. YOLO v11: an overview of the key architectural enhancements[PP/OL]. V2. arXiv(2024 - 10 - 23) [2026 - 06 - 24]. <https://arXiv.org/abs/2410.17725>.

[21] Tian Y, Ye Q, Doermann D S. YOLO v12: attention-centric real-time object detectors[J]. Advances in Neural Information Processing Systems, 2026, 38: 78433 - 78457.

[22] Sapkota R, Cheppally R H, Sharda A, et al. YOLO26: key architectural enhancements and performance benchmarking for real-time object detection[PP/OL]. V5. arXiv(2026 - 03 - 16) [2026 - 06 - 24]. <https://arXiv.org/abs/2509.25164>.

[23] 杨断利, 齐俊林, 陈辉, 等. 基于改进 YOLO v8n 模型的散养蛋鸡个体行为识别方法与差异分析[J]. 农业机械学报, 2024, 55(11):112 - 123.

Yang Duanli, Qi Junlin, Chen Hui, et al. Individual behavior recognition method and difference analysis of free-range laying hens based on the improved YOLO v8n model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11):112 - 123. (in Chinese)

[24] Song D, Chen Z, Peng Y, et al. JNL - SlowFast: an end-to-end approach for dead rabbits classification using short cage inspection videos in commercial farms[J]. Computers and Electronics in Agriculture, 2025, 240:111190.

[25] 杨断利, 王永胜, 陈辉, 等. 基于 SEEC - YOLO v5s 的散养蛋鸡日常行为识别与统计系统[J]. 农业机械学报, 2023, 54(9):316 - 328.

Yang Duanli, Wang Yongsheng, Chen Hui, et al. Daily behavior recognition and statistics system for free-range laying hens based on SEEC - YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(9):316 - 328. (in Chinese)

[26] Brown J, Nguyen A, Raj N. Effect of camera choice on image-classification inference[J]. Applied Sciences, 2024, 15(1): 246.

(上接第 63 页)

[12] Zheng C, Zhu X, Yang X, et al. Automatic recognition of lactating sow postures from depth images by deep learning detector [J]. Computers and Electronics in Agriculture, 2018, 147:51 - 63.

[13] Yu H, Xu Y, Zhang J, et al. AP - 10K: a benchmark for animal pose estimation in the wild[PP/OL]. V2. arXiv(2021 - 11 - 01) [2026 - 04 - 07]. <https://doi.org/10.48550/arXiv.2108.12617>.

[14] Wang J, Sun K, Cheng T, et al. Deep high-resolution representation learning for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(10):3349 - 3364.

[15] Jaegle A, Gimeno F, Brock A, et al. Perceiver: general perception with iterative attention[C] // Proceedings of the 38th International Conference on Machine Learning (PMLR), 2021:4651 - 4664.

[16] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016:770 - 778.

[17] Li Y, Yang S, Liu P, et al. SimCC: a simple coordinate classification perspective for human pose estimation[PP/OL]. V3. arXiv(2022 - 07 - 05) [2026 - 04 - 07]. <https://doi.org/10.48550/arXiv.2107.03332>.

[18] Tan M, Le Q V. EfficientNetV2: smaller models and faster training[C] // International Conference on Machine Learning (ICML), 2021:10086 - 10096.

[19] Wang C Y, Mark Liao H Y, Wu Y H, et al. CSPNet: a new backbone that can enhance learning capability of CNN[C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2020:1571 - 1580.

[20] Howard A, Sandler M, Chen B, et al. Searching for MobileNetV3 [C] // 2019 IEEE/CVF International Conference on Computer Vision (ICCV), 2019:1314 - 1324.

[21] Liu Z, Lin Y, Cao Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C] // 2021 IEEE/CVF International Conference on Computer Vision (ICCV), 2021:9992 - 10002.