

兔舍移动巡检机器人轻量化兔只计数方法

宋道一¹ 孟安祺¹ 杨慧琳¹ 沈阳¹ 李丛艳² 王红英¹ 王粮局¹ 秦应和³

(1. 中国农业大学工学院, 北京 100083; 2. 四川省畜牧科学研究院动物遗传育种四川省重点实验室, 成都 610066;
3. 中国农业大学动物科学技术学院, 北京 100193)

摘要: 针对集约化笼养兔场中兔只个体密集、遮挡严重以及移动巡检机器人机载计算资源受限的问题,提出一种适用于资源受限条件下的轻量化兔只自动计数方法。基于 NanoDet-Plus 框架,通过引入改进的 Ghost-Shuffle 单元构建轻量骨干网络、增强型轻量特征聚合网络以及 GeLU 激活函数,结合空间感知计数策略,实现了鲁棒的兔只自动计数。基于真实商用笼养兔舍环境采集的数据集,在相同实验条件下将所提出模型与多种典型轻量化目标检测模型进行对比实验,并在移动巡检机器人平台上进行部署验证。实验结果表明,RabbitDet 在参数量只有 7.3×10^5 和浮点计算量为 1.2×10^9 的情况下,实现了 75.7% 的平均精度均值和 98.83% 的计数准确率。与基线模型相比,参数量和计算开销分别下降了 36.0% 和 31.0%,同时计数准确率提升了 0.53 个百分点。在移动巡检机器人平台上的推理实验中,与对比的主流模型相比,该方法实现了计数准确度与推理效率之间的更优平衡。所提出的方法能够在计算资源受限条件下实现复杂遮挡笼养环境中兔只的稳定、精准计数。

关键词: 兔只; 计数; 移动巡检; 边缘计算; NanoDet-Plus

中图分类号: S81; TP391 文献标识码: A 文章编号: 1000-1298(2026)15-0125-12

OSID:



Lightweight Rabbit Counting Method for Mobile Inspection Robots in Rabbitries

Song Daoyi¹ Meng Anqi¹ Yang Huilin¹ Shen Yang¹ Li Congyan² Wang Hongying¹
Wang Liangju¹ Qin Yinghe³

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

2. Sichuan Provincial Key Laboratory of Animal Breeding and Genetics, Sichuan Animal Science Academy, Chengdu 610066, China

3. College of Animal Science and Technology, China Agricultural University, Beijing 100193, China)

Abstract: Aiming to address the challenges of high rabbit density and severe occlusion in intensive caged rabbit farms, as well as the limited onboard computational resources of mobile inspection robots, a lightweight automatic rabbit counting method suitable for resource-constrained conditions was proposed. Based on the NanoDet-Plus framework, robust automatic rabbit counting was achieved by introducing a lightweight backbone network constructed with improved Ghost-Shuffle units, an enhanced lightweight feature aggregation network, and the GeLU activation function, combined with a spatial-aware counting strategy. Based on a dataset collected in a real commercial caged rabbit house environment, comparative experiments were conducted between the proposed model and multiple typical lightweight object detection models under identical experimental conditions, and deployment verification was performed on a mobile inspection robot platform. Experimental results showed that RabbitDet achieved an mAP of 75.7% and a counting accuracy of 98.83% with only 7.3×10^5 parameters and 1.2×10^9 FLOPs. Compared with the baseline model, the parameter size and computational cost were reduced by 36.0% and 31.0%, respectively, while the counting accuracy was improved by 0.53 percentage points. In inference experiments on the mobile inspection robot platform, compared with the baseline models, the proposed method achieved a superior balance between counting accuracy and inference efficiency. The proposed method enabled stable and accurate counting of rabbits in caged environments with complex occlusion

收稿日期: 2026-03-09 修回日期: 2026-04-19

基金项目: 财政部和农业农村部:国家现代兔产业技术体系项目(CARS-43-D-3)

作者简介: 宋道一(2001—),男,博士生,主要从事基于计算机视觉的畜禽信息感知研究,E-mail: songdaoyi2001@163.com

通信作者: 秦应和(1965—),男,教授,主要从事家兔生产与智慧养殖研究,E-mail: qinyinghe@cau.edu.cn

under resource-constrained conditions, providing effective technical support for mobile inspection and inventory management in intensive rabbit farms.

Key words: rabbit; counting; mobile inspection; edge computing; NanoDet – Plus

0 引言

随着全球人口持续增长与居民生活水平普遍改善,肉类产品的消费需求正面临前所未有的压力。在此背景下,兔肉以其饲养周期短、饲料转化效率高的生产优势,日益受到消费者与产业界的重视^[1]。为提升养殖效率,现代兔场正加速向高密度、多层笼养的集约化养殖模式转型^[2]。在此背景下,依赖人工巡查的传统存栏清点方式效率低下、劳动强度大,且易引发动物应激反应并带来生物安全隐患^[3-4]。因此,具备非接触式监测能力的自动化巡检机器人逐渐成为集约化兔养殖环境中开展存栏管理与生产监测的有效技术途径。

随着深度学习技术的不断发展,目标检测模型已经广泛应用于畜禽养殖领域并表现出卓越的性能^[5-8]。近年来,研究者开始关注轻量化目标检测模型在畜禽养殖场景中的应用,以适应边缘计算设备的部署需求^[9-11]。总体来看,现有轻量化研究主要从骨干网络替换和网络结构优化两条技术路径展开。

在骨干网络替换方面,Guo 等^[12]将 YOLO v4 的主干网络替换为 GhostNet,实现了对鸽子清洁行为的检测,在保证检测精度的同时将模型参数量由 1.02×10^8 降至 1.97×10^7 ; Yang 等^[13]采用 MobileNet V3 替代改进 YOLO v7 的主干网络用于死鸡检测,使模型参数量和计算量分别降低 35.42% 和 63.73%。相关研究表明,通过引入轻量化骨干网络能够有效降低模型规模,为目标检测模型在嵌入式平台上的部署提供了可能。

在网络结构优化方面,部分研究通过对检测头和特征融合结构进行精简以提升模型运行效率。Xiao 等^[14]针对鸭只行为检测任务对 YOLO v8 的检测头结构进行了简化,使模型体积减少 2.8×10^6 ; Wang 等^[15]通过对 YOLO v8 颈部网络进行轻量化重构以识别低产母鸡,计算量降低了约 1.5×10^9 ; Li 等^[16]通过在 YOLO v8n 中引入多种轻量化特征融合模块来检测鸡只,将参数量从 3.01×10^6 降低至 1.57×10^6 。这类方法在保持模型基本检测性能的同时,有效提升了推理效率。

虽然以上方法有效减少了模型参数量和计算复杂度,但通用的轻量化架构难以适用于复杂的场景。在兔养殖场景中,笼养环境下个体密集、遮挡严

重^[3],轻量模型特征表达能力的削弱易导致计数结果不稳定。因此,亟需一种在满足移动巡检机器人计算资源受限的硬件约束条件下,仍能够在高密度遮挡环境中保持较高检测鲁棒性的目标检测模型。

为解决上述问题,本文提出一种面向集约化笼养环境移动巡检应用的高效兔只检测模型 RabbitDet,该模型基于改进的 NanoDet – Plus 框架构建。针对边缘计算设备部署对模型规模和计算复杂度的严格约束,设计一种由改进 Ghost – Shuffle 单元组成的轻量化骨干网络;同时,引入增强型轻量化特征聚合网络,以提升严重个体遮挡条件下的特征表达能力。此外,网络中统一采用 GeLU 激活函数替换原始的激活函数,以增强模型训练稳定性并提高检测鲁棒性。基于商用兔舍中移动巡检机器人采集的真实场景数据,对所提出的 RabbitDet 模型进行验证,并与多种先进目标检测模型进行对比分析,为大规模笼养兔场移动巡检与存栏管理提供技术方案。

1 数据集制作

1.1 实验环境与图像采集

实验数据采集于河北省廊坊市国家兔产业智能养殖实验与示范基地(39.94°N,116.92°E)。实验兔舍采用标准化双层笼养结构,其中下层笼位空间相对较大,每个笼位通常饲养 3~7 只青年兔;上层笼位空间较为紧凑,每个笼位饲养 1~3 只青年兔。数据采集工作分别于 2025 年 8 月 20—21 日和 9 月 10—11 日开展。采集平台为搭载 Orbbec Femto Bolt 深度相机的移动巡检机器人,用于实际生产环境下的自动化巡检作业。

图像采集按照标准化巡检流程进行。巡检机器人以 0.1 m/s 的恒定速度沿预设轨迹行驶,首先调整机械臂至下层观测姿态,在行进过程中以固定时间间隔对下层笼位进行拍摄,确保目标笼位位于图像中心位置,直至完成该列笼位的巡检任务。随后,机器人调整机械臂至上层观测姿态,沿原路径返回并持续采集上层笼位图像,直至返回起点位置。采集过程如图 1a、1d 所示。由于上层笼位与机械臂之间的作业空间较为狭窄,单幅图像的相机视场通常同时覆盖相邻的两个笼位。基于实际物理视场特性并兼顾巡检效率,上层图像采集以“相邻双笼”为一个基本单元进行。

所有原始图像的分辨率为 1 280 像素 × 720 像



图 1 上下层兔笼图像采集与标注示意

Fig. 1 Illustration of image acquisition and annotation for upper- and lower-layer rabbit cages

素,均以 TIFF 格式存储。最终构建的数据集共包含 3 461 幅图像,其中上层笼位图像 1 739 幅,下层笼位图像 1 722 幅,样本示例如图 1b、1e 所示。

1.2 图像处理与数据集划分

由于拍摄视角的限制,原始上层兔笼图像中不可避免地包含部分下层笼位以及相邻笼列的背景干扰区域。为降低无关背景对模型训练的影响,对上层图像进行了统计分析。结果表明,上层目标笼位的有效区域主要集中在图像横向像素坐标 370 ~ 850 范围内。基于该统计结果,对所有上层图像实施感兴趣区域(Region of Interest, ROI)预处理,仅保留上述有效区域,以减少背景噪声并提高特征学习的针对性。

数据标注工作采用 LabelMe 软件完成。考虑到上、下层笼养结构及成像视角存在明显差异,分别制定了差异化的标注规则。对于下层图像,将画面中心对应的目标笼位区域标注为“center cage”;位于该区域内但不属于目标笼位的兔只标注为“cover”;其余兔只统一标注为“rabbit”。对于上层图像,在完成 ROI 预处理后,将画面中心对应的两个目标笼位内的兔只标注为“rabbit”,将位于目标笼位之外的兔只标注为“cover”。具体标注示例如图 1c、1f 所示。

在数据集划分阶段,为模拟实际巡检作业中连续采集的应用场景,并客观评估模型在真实环境下的检测与计数性能,从完整数据中选取连续采集的 5 列上层图像序列和 5 列下层图像序列作为测试集,每类图像各 205 幅,共 410 幅。其余图像随机划分为训练集和验证集,分别包含 2 518 幅和 533 幅图像。最终,所有标注数据统一转换为 MS COCO 标准格式,以满足后续模型训练与性能评估的需要。

2 兔只计数方法

2.1 RabbitDet 模型构建

2.1.1 RabbitDet 模型整体框架

RabbitDet 是基于 NanoDet - Plus 轻量检测框架改进而建成,其整体结构如图 2 所示。该模型在保持原有无锚框、单阶段检测优势的基础上,针对笼养环境中兔只密集分布、个体遮挡严重以及机器人端计算资源受限等问题,对骨干网络、特征融合结构及激活函数进行了系统性优化,以实现检测精度与计算效率之间的有效平衡。

在整体流程上,输入图像首先经过轻量化骨干网络进行多尺度特征提取。与原 NanoDet - Plus 采用 ShuffleNet V2 作为骨干网络不同,RabbitDet 对其基础单元和下采样单元进行了结构重构,引入 Ghost - Shuffle(GS)模块,以减少冗余特征生成带来的参数和计算开销,同时保证通道间信息充分交互。

随后,多尺度特征被送入特征融合网络进行跨层信息聚合。RabbitDet 用轻量特征聚合(Lightweight feature aggregation, LFA)模块替代原 NanoDet - Plus 中的特征融合单元,构建 LFA 路径聚合网络(LFA PAN)。该结构通过自顶向下与自底向上的双向路径,实现不同尺度特征的充分交互与增强。

在预测阶段,融合后的特征直接输入检测头,完成目标类别预测与边界框回归,保持了 NanoDet - Plus 端到端、单阶段检测的高效特性。

同时,为增强网络的非线性表达能力并提高训练过程的稳定性,RabbitDet 在全网络范围内采用 Gaussian Error Linear Unit(GeLU)激活函数替代原有的 LeakyReLU 激活函数。




图2 RabbitDet 模型结构图

Fig. 2 Structure diagram of RabbitDet network

在训练策略方面,RabbitDet 继承了 NanoDet - Plus 中的分配引导模块 (Assign guidance module, AGM),利用辅助预测分支生成软标签,引导主检测头的样本分配与参数优化,从而缓解轻量模型在复杂场景下易出现的样本匹配不稳定问题。需要指出的是,AGM 仅在训练阶段引入,在模型推理阶段完全移除,不会对部署时的计算开销产生任何影响。

2.1.2 Ghost Shuffle 模块

NanoDet - Plus 的骨干网络以 ShuffleNet V2 为基础构建,其核心由基本单元和空间下采样单元组成,如图 3a 所示。ShuffleNet V2 以其较高的计算效率被广泛应用于轻量化视觉任务^[17],但其在通道融合阶段大量依赖 1 × 1 逐点卷积,在嵌入式和边缘计算场景中仍占据较高的参数比例和计算开销。同时,该类逐点卷积在实际应用中易产生特征冗余,不利于资源受限 CPU 平台上的高效部署。

针对上述问题,本文对 ShuffleNet V2 的基本单元和下采样单元进行了结构改进,将 Ghost 卷积引入其通道生成与融合过程,构建了 Ghost Shuffle (GS)模块。Ghost 卷积的核心思想是通过少量标准卷积生成内在特征,再利用计算代价较低的线性变换生成冗余特征,从而避免使用密集卷积直接生成全部特征通道^[18],其结构示意图如图 3b 所示。

在本文提出的 GS 模块中,原 ShuffleNet V2 单元中的 1 × 1 逐点卷积被 Ghost 卷积所替代,分别构建了改进的基本 GS 单元和空间下采样 GS 单元,如

图 3c 所示。然而,由于 Ghost 卷积输出的内在特征与线性变换得到的特征在通道分布上简单叠加,若直接送入后续网络层,将在下一次通道分裂操作中造成某一支仅包含浅层变换特征,而另一分支仅包含深层卷积特征,影响特征表达的有效性。

为此,本文在 GS 模块中结合通道洗牌 (Channel Shuffle) 机制,对 Ghost 卷积输出的特征进行重新排列与交叉混合,其结构如图 3d 所示。通过该操作,含有不同层次信息的特征得以充分交织,使后续并行分支能够同时接收到具有较强语义信息的内在特征和补充性的 Ghost 特征,从而保证在模型轻量化的同时,维持良好的全局信息流动性与语义连贯性。

Ghost 卷积与通道洗牌机制的协同设计,在显著降低模型参数量和浮点运算量的同时,有效缓解了特征冗余与信息失衡问题,使骨干网络在计算受限条件下仍具备较强的特征提取能力。该结构改进从代码实现层面对骨干网络进行了针对性优化,为移动巡检机器人在仅有 CPU 的计算条件下实现低时延、高稳定性的免只检测提供了基础支撑。

2.1.3 LFA 轻量特征聚合模块

在 NanoDet - Plus 中,特征融合网络基于 GhostPAN 构建,其核心单元为 Ghost Bottleneck,如图 4a 所示。该模块采用双分支并行结构,通过逐元素相加的方式融合来自不同感受野的特征。然而,在笼养免场环境中,免只个体密集分布、相互遮挡严重,目标边界信息往往呈现出局部弱化和碎片化特




图 3 ShuffleNet V2 的组成单元与改进的 GS 组成单元

Fig. 3 Structural diagrams of ShuffleNet V2 units and proposed GS units

征。在此情况下,采用逐元素相加的融合方式容易削弱高频空间信息,使具有不同语义侧重的特征被压缩为单一响应,进而导致目标轮廓模糊、相邻个体区分度降低,增加漏检和计数误差风险。针对上述问题,本文提出一种轻量特征聚合模块 LFA,其结构如图 4b 所示。与传统的加和式特征融合不同,LFA 模块采用通道级拼接的方式对多分支特征进行聚合,从而在不破坏原有特征分布的前提下,完整保留来自不同处理路径的空间与语义信息,使互补特征在通道维度上共存。

具体而言,输入特征首先通过 1×1 卷积进行通道压缩,以降低计算复杂度和参数规模。随后,压缩后的特征被划分为两个并行分支:其中一条分支采用恒等映射,直接保留原始特征信息;另一条分支则作为特征变换路径,引入深度可分离卷积 (Depthwise separable convolution, DS Conv) 以提取局部空间上下文信息,其结构如图 4c 所示。与标准卷




图 4 特征融合网络核心模块结构示意图

Fig. 4 Structural diagrams of core modules in feature fusion network

积同时进行空间与通道混合不同,深度可分离卷积将二者解耦,其中逐通道的空间卷积在不引入跨通道干扰的情况下对每个通道独立进行局部邻域建模,从而能够更充分地保留细粒度纹理与边缘响应。该分支使得局部结构在早期不会被通道混合过程过度平滑或稀释,能够为原始特征分支提供有益的局部补充信息,从而在一定程度上提升模型对细粒度空间模式的表达能力。

两个分支的输出进行了通道拼接,原始特征分支与局部细节分支的特征在融合后具有不同的响应模式,直接使用可能导致信息冗余或重要特征被弱化。ECA 通过建模局部跨通道交互关系,在不显著增加计算开销的前提下,为每个通道分配自适应权重,从而强化对判别性特征的响应并抑制无关或噪声信息。该机制使模型能够根据输入内容动态调整对局部细节与全局语义的依赖程度,从而在不同视觉条件下获得更加稳健的特征表达,如图 4d 所示^[19]。

上述非破坏性特征融合方式与轻量化通道重标定机制的协同设计,使 LFA 模块在保持网络紧凑性的同时,显著提升了模型在高密度聚集和严重遮挡场景下的特征表达能力。该模块为后续构建轻量化路径聚合网络提供了支撑,使模型能够在无 GPU 支持的移动巡检机器人平台上实现鲁棒、实时的兔只检测与计数。

2.1.4 GeLU 激活函数

为增强网络的非线性表征能力并在目标密集、场景复杂条件下稳定梯度传播,本文在整个网络中采用 GeLU 激活函数替代原有的 LeakyReLU 激活函

数,其原理见图 5。与分段线性的 LeakyReLU 激活函数相比,GeLU 具有更加平滑且表达能力更强的非线性映射特性,有利于捕捉由个体遮挡和重叠引起的细微外观变化,从而提升模型在复杂养殖环境中的检测鲁棒性。




图 5 替换前后的激活函数
Fig.5 Comparison of activation functions before and after replacement

2.2 空间感知计数策略

针对双层笼养结构导致的视场差异问题,本文在目标检测结果的基础上提出一种空间感知计数策略。由于移动巡检机器人在作业过程中相邻采集视角之间不可避免地存在重叠,若采用简单的全局计数方式,易产生重复计数现象。为此,本文针对下层与上层兔笼图像分别设计了差异化的计数逻辑,如图 6 所示。



图 6 分层计数策略
Fig.6 Schematic illustrations of layer-adaptive counting strategy

对于上层兔笼图像,由于其视场通常完整覆盖相邻的两个笼位,且在预处理阶段已有效去除大部分背景干扰,图像中目标分布更加清晰。在此条件下,计数策略相对简化,仅对图像中检测到的 rabbit 类目标进行直接累加,并排除 cover 类检测结果,如

图 6a 所示。

对于下层兔笼图像,数据采集以单个目标笼位为中心,相邻笼位仅在图像边缘区域部分可见,空间覆盖不完整,存在较高的重复计数风险。因此,本文采用空间约束计数策略。具体而言,检测模型首先预测目标笼位的边界框以及图像中所有可见兔只实例;随后,仅保留其中心点落入目标笼位边界框内部的兔只检测结果参与计数,如图 6b 所示。在数据标注阶段,来自相邻笼位但部分进入目标笼位区域的兔只被统一标注为 cover 类,在模型推理过程中自动剔除,从而有效抑制相邻笼位干扰,避免重复计数。

通过引入空间约束与分层差异化计数规则,本文提出的空间感知计数策略有效缓解了由视角重叠和笼位相邻引起的重复计数问题,显著提升了多层笼养环境下自动化兔只存栏估计的准确性与鲁棒性。

3 实验结果与分析

3.1 实验环境

本文所有实验均在 Ubuntu 20.04 操作系统环境下完成,实验平台配置为 Intel(R) Xeon(R) Gold 6133 处理器和 NVIDIA GeForce RTX 3090 图形处理器。模型的开发与训练基于 Python 3.10 编程语言,采用 PyTorch 2.2.0 深度学习框架实现。模型训练前,所有输入图像分辨率统一调整至 640 像素 × 640 像素。

为保证不同目标检测模型对比结果的公平性,所有模型均在相同的超参数配置下进行训练。训练批量大小设置为 16,采用 AdamW 优化器进行 230 轮的迭代训练。初始学习率设定为 0.001,并在整个训练过程中采用 Cosine Annealing 策略进行动态调整。为保证训练后期的收敛稳定性,最小学习率限制为 5×10^{-5} 。

在部署性能评估阶段,重点对模型的推理速度及其在实际工程应用中的可行性进行验证。具体而言,将训练完成的模型部署于巡检机器人车载计算平台 ERAZER Mini PC D70,该平台搭载 AMD Ryzen 7 6800H 处理器,作为机器人系统的主要控制与感知单元。

3.2 评价指标

本文从目标检测性能和计数准确性两方面对所提出方法进行综合评价。在目标检测性能评价方面,采用计算机视觉领域通用的评价指标,包括在交并比 (Intersection over union, IoU) 阈值 0.50 ~ 0.95、步长为 0.05 条件下计算的平均精度 (AP50 - 95),

以及整体平均精度 (mean Average Precision, mAP)。此外,为评估模型的计算效率与工程应用潜力,进一步引入模型参数量、浮点运算量以及在 CPU 平台上的平均推理延迟时间作为衡量指标。其中,模型参数量表示网络中可训练参数的总数,浮点运算量用于衡量模型单次前向推理所需的计算复杂度。

在目标计数任务中,重点关注模型预测兔只数量与真实数量之间的一致性。因此,采用计数准确率作为评价指标。

表 1 消融实验结果
Tab.1 Results of ablation experiments

GS	LFA PAN	GeLU	AP50 - 95/%			mAP/%	计数准确率/%	参数量	浮点运算量
			center cage	rabbit	cover				
×	×	×	97.6	72.1	55.7	75.6	98.3	1.1×10^6	1.7×10^9
✓	×	×	98.2	73.0	56.8	76.0	98.5	7.9×10^5	1.3×10^9
✓	✓	×	98.3	72.7	58.0	76.3	98.6	7.3×10^5	1.2×10^9
✓	✓	✓	97.2	72.7	57.1	75.7	98.8	7.3×10^5	1.2×10^9

注:✓表示采用该改进模块,×表示不采用该改进模块。

由表 1 可知,与基准模型 NanoDet - Plus 相比,引入 GS 单元的模型参数量与计算复杂度均显著降低,同时目标检测性能和计数精度均得到稳定提升。其中,mAP 由 75.6% 提升至 76.0%,计数准确率由 98.3% 提升至 98.5%。

在此基础上,进一步引入所提出的 LFA PAN 轻量化特征聚合网络后,模型参数量和浮点运算量分别降低至 7.3×10^5 和 1.2×10^9 。在该配置下,模型获得了最高的检测性能,mAP 达到 76.3%,同时计数准确率进一步提高。

最后,将网络中的 LeakyReLU 激活函数替换为 GeLU 函数后,mAP 指标出现小幅波动,但计数准确率提升至最高。值得注意的是,该性能提升并未引

鉴于不同目标检测模型的置信度分布存在差异,采用固定置信度阈值难以全面反映各模型的最优性能。为此,在验证集上采用网格搜索策略,对置信度阈值与非极大值抑制的 IoU 阈值进行联合优化。其中,参数搜索范围设定为 0.1 ~ 0.7,步长为 0.05。最终选取各模型在验证集上表现最优的参数组合,并将其应用于测试集。

3.3 消融实验结果

为定量评估各改进模块对模型性能的贡献,开展了一系列消融实验,相关结果见表 1。

入额外的计算开销,表明 GeLU 激活函数在复杂遮挡场景下有助于提升计数稳定性。

3.4 不同模型对比实验

为全面评估模型性能,将所提出的 RabbitDet 与多种具有代表性的轻量化目标检测模型进行了对比实验。对比模型包括主流的 YOLO 系列轻量化基线模型^[20](YOLO v5n 和 YOLO 11n)、结构优化型轻量化检测模型^[21](YOLO v6 - Lite),以及以边缘设备推理速度为优先目标的超轻量化模型^[22](FemtoDet 和 FastestDet)。所有模型均在相同的自建数据集上进行训练与测试,并采用一致的实验设置,以保证对比结果的公平性和可重复性。对不同目标检测模型在兔只计数任务中的性能进行了系统对比,相关结果见表 2。

表 2 不同模型对比实验结果
Tab.2 Comparative experiments of different models

模型	AP50 - 95/%			mAP/%	计数准确率/%	参数量	浮点运算量
	center cage	rabbit	cover				
YOLO v5n	95.4	74.8	59.7	76.6	98.3	2.22×10^6	5.38×10^9
YOLO 11n	98.2	75.8	62.2	78.8	98.3	2.58×10^6	6.30×10^9
YOLO v6 - Lite	92.9	70.7	54.0	72.6	97.0	1.06×10^6	3.31×10^9
FemtoDet	83.0	56.8	37.3	59.2	95.6	7.00×10^4	2.00×10^8
FastestDet	83.3	62.0	37.7	61.0	92.5	2.40×10^5	4.30×10^8
RabbitDet	97.2	72.7	57.1	75.7	98.8	7.30×10^5	1.20×10^9

就通用目标检测指标 mAP 而言,YOLO 11n 取得了最高的检测精度,为 78.8%。然而,该性能提升以显著增加的计算开销为代价,其浮点计算量和参数量分别达到 6.30×10^9 和 2.58×10^6 ,是所有对比模型中

计算负担最大的模型。相比之下,RabbitDet 在 mAP 仅下降 3.1 个百分点的情况下,将计算复杂度降低了约 81%,模型参数量减少了约 71%,在检测精度与计算效率之间实现了更为合理的平衡。

针对实际应用中更为关键的兔只存栏计数任务,计数准确率是衡量模型实用性的核心指标。由表 2 可知,RabbitDet 取得了最高的计数准确率,为 98.8%,不仅优于 YOLO v5n,也超过了整体检测精度更高的 YOLO 11n,表明 RabbitDet 在复杂遮挡和密集场景下具备更强的计数一致性与鲁棒性。

此外还可以观察到,FemtoDet 和 FastestDet 等超轻量化模型虽然参数规模极小,但其在各类别上的检测性能均出现了明显下降,难以满足精确计数的实际需求。相比之下,RabbitDet 在仅适度增加模型复杂度的前提下,相对于上述超轻量化基线模型实现了超过 14% 的 mAP 提升,体现了其在检测精度、计数性能与计算效率之间的综合优势。

表 2 的结果揭示了通用目标检测评价指标与领域特定计数可靠性之间的显著差异。尽管 YOLO 11n 在 mAP 指标上取得了最优性能,但其优势并未转化为最高的计数准确率。可能的原因是 mAP 指标高度依赖于预测框与真实框之间的重叠精度。YOLO 11n 拥有更大的参数量和网络结构,其深层网络能够捕捉更细微的几何特征,从而在边界框回归上表现更准,因此获得了更高的 mAP。但其对局部纹理的过度拟合导致了严重的重框现象,从而降低了整体的计数准确率。

此外,所有对比模型均由 PyTorch 权重文件转换为 ONNX 格式,并进一步部署为 NCNN 模型,运行于巡检机器人的车载计算平台。在实际机器人作业过程中,计算资源需要同时分配给 SLAM、定位与路径规划等关键任务。为避免多任务并行导致的资源竞争,目标检测模块通常需要在低线程甚至单线程 CPU 约束条件下运行。基于此,本文在单线程执行模式下,对各模型在机器人 CPU 平台上的平均推理时延进行了测试与评估。

进一步地,为综合衡量模型的运行效率与计数可靠性,构建了“推理时延-错检率”对比分析,如图 7 所示。其中,横轴表示单帧处理时延,其数值越小表示推理速度越快;纵轴表示总错检率,其定义为漏检数与错检数之和与兔只真实总数的比值,其数值越小表示计数精度越高。由图可见,RabbitDet 在所有对比模型中最接近左下区域,表明其在推理时延与计数误差之间实现了较优的平衡。尽管 YOLO 11n 具备相对更高的检测精度,但其在 CPU 平台上的推理时延最高,较 RabbitDet 增加一倍以上,因此位于图中的右下区域。相较之下,FastestDet 和 FemtoDet 在 CPU 上的推理时延极低,单帧约为 20 ms,但其计数误差显著偏大,整体性能分布于图中的左上区域。




图 7 推理时延-错检率图

Fig. 7 Inference latency – false positive rate plot

相比之下,RabbitDet 在单线程 CPU 条件下表现出更加均衡的“推理延迟-错检率”特性,其推理时延稳定保持在约 60 ms 的同时,仍能维持较低的计数误差。得益于整体轻量化的网络设计,该模型在不显著占用系统计算资源的前提下,实现了稳定的实时运行性能。上述结果表明,RabbitDet 更适合部署于低成本边缘计算设备和移动农业机器人平台,在实际应用中能够更好地满足可靠性和持续运行的工程需求。

3.5 可视化结果与分析

3.5.1 模型各组成模块影响分析

消融实验结果表明,所提出的各改进模块从不同层面提升了 RabbitDet 在密集遮挡场景下的检测与计数性能,分别针对效率、特征表达鲁棒性以及计数可靠性等关键问题发挥作用。

首先,引入的 GS 模块主要从效率角度对模型进行优化,有效降低了 ShuffleNet V2 主干网络中的参数冗余。在笼养兔密集分布的场景中,传统 1×1 卷积容易产生高度相关的特征通道,导致计算资源利用效率降低。GS 模块通过低成本线性变换生成补充特征图,在保持特征多样性的同时显著减少了参数量和计算开销。如图 8a(红色圆圈标出了发生计数错误的区域,相关区域进行了放大显示。为便于观察模型的检测结果,不同目标的边界框采用不同颜色进行标注)所示,相较于基线模型,该改进明显抑制了过度检测现象,表明模型获得了更加紧凑且具有判别力的特征表示。

其次,LFA PAN 在提升模型对严重遮挡场景的鲁棒性方面起到了关键作用。不同于原有基于逐元素相加的特征融合方式,本文提出的基于通道拼接的轻量特征聚合策略能够完整保留来自不同感受野的互补信息,并结合 ECA 通道注意力机制对关键特征进行自适应重标定,从而增强拥挤区域中的判别能力。如图 8b 所示,LFA PAN 使模型能够有效区



图 8 不同消融阶段检测结果的可视化对比

Fig. 8 Visual comparisons of detection results across different ablation stages

分高度重叠的个体,显著降低了漏检与错检现象。

最后,采用 GeLU 激活函数进一步使模型行为更契合精确计数这一核心目标。相较于具有分段线性硬截断特性的 Leaky ReLU,GeLU 的连续可微与平滑非线性特征为分类分支引入了隐式空间正则化,在分类分支上能够有效抑制局部信息的过度激活,从而修正错检,提升了计数稳健性。通过对图 8c 的分析发现,GeLU 有效抑制了局部特征的异常激活,将模型的注意力从不稳定的局部纹理转向了目标的全局语义,降低了冗余检测,提升了最终的计数准确率。虽然在参数量仅为 7.3×10^5 的轻量化架构中,GeLU 的平滑梯度流对回归分支的极致定位精度产生了一定的软化效应,导致 mAP 指标在高 IoU 阈值下出现微小波动,但其对目标实体存在性的准确判定确保了存栏统计的可靠性。因此,该改进使模型在牺牲极少定位指标的前提下,更加侧重于计数准确性,这对于实际机器人计数盘点应用具有更高的工程价值。

3.5.2 与其他模型的可视化结果对比

通过统计模型的计数结果发现不同模型的计数误差来源存在明显差异。RabbitDet、YOLO v5n 与

YOLO 11n 在漏检率方面表现接近,但 YOLO v5n 和 YOLO 11n 在密集聚集场景中表现出显著更高的误检率。这表明,通用 SOTA 模型较强的特征提取能力在拥挤环境下反而容易导致目标碎片化问题。YOLO v5n 和 YOLO 11n 的深层网络结构对局部形态细节高度敏感,当兔体在遮挡作用下出现视觉上的不连续时,模型往往将分离的身体局部误判为多个独立个体,即使经过非极大值抑制,仍会为同一目标生成冗余检测框,从而引发重检现象。

为进一步验证上述分析,本文在图 9(红色方框标出了发生计数错误的区域,相关区域进行了放大显示。为便于观察模型的检测结果,不同目标的边界框采用不同颜色进行标注)中给出了典型失效案例的可视化结果。对比结果表明,在兔只高度聚集、相互遮挡严重的场景下,YOLO 11n 和 YOLO v5n 往往会对同一聚集目标生成多个重叠检测框;而 RabbitDet 由于采用了更加轻量化的网络结构,其提取的特征更偏向于粗粒度、整体性的语义表示。通过优先关注目标的整体形态而非局部细节,RabbitDet 能够将被遮挡的身体部分视为一个完整个体,从而有效避免冗余预测,显著提升计数一致性与可靠性。




图 9 不同模型的可视化结果对比

Fig.9 Visual comparisons of detection results of different models

4 讨论

对现有基于深度学习的畜禽数量统计方法进行对比分析,结果如表 3 所示。在计算负载方面, Geffen 等^[23]、赵春江等^[24]以及 Wu 等^[25]提出的方

法均基于视频序列进行计数。视频级输入能够提供更加丰富的时空信息,在理论上有助于缓解遮挡与重叠带来的计数歧义。然而,这类方法通常需要进行多帧特征提取,并引入跨帧关联或目标跟踪等额外处理流程,从而显著增加了模型的计算复杂度和

表 3 与已有研究性能比较结果

Tab.3 Comparison results of performance with previous studies

目标对象	模型	输入数据	计数逻辑	计数准确率/%	参数量	部署方式	文献序号
蛋鸡	Faster R - CNN	视频序列	基于 IoU 的跨帧匹配以避免重复计数	89.60	大	高性能 GPU	[23]
蛋鸡	改进 YOLO v7 - tiny	视频序列	依赖实体二维码实现笼位划分	96.70	5.60×10^6	NVIDIA Jetson AGX Xavier 边缘设备	[24]
蛋鸡	改进 YOLO v8s	视频序列	基于阈值的连续帧检查策略	90.90	8.27×10^6	NVIDIA Jetson AGX Orin 工控机	[25]
兔	改进 NanoDet - Plus	单帧图像	无物理标记,纯视觉计数	98.83	7.30×10^5	仅 CPU(无 GPU 加速)	

系统实现成本。

相比之下,RabbitDet 采用基于单帧图像的检测与计数策略。实验结果表明,在当前肉兔养殖巡检应用场景下,即使不引入显式的时序建模,仅依赖单帧图像中的空间特征信息,仍能够实现较高的计数准确率。这表明 RabbitDet 在性能与计算效率之间取得了较为合理的平衡:在满足日常巡检精度需求的同时,有效避免了视频处理带来的高计算开销,使其更适合同部署于计算资源受限的移动巡检机器人平台。

在部署成本方面,赵春江等^[24]和 Wu 等^[25]提出的方法通常依赖 NVIDIA Jetson AGX 等高性能边缘计算设备,以保证系统的实时性要求;而

RabbitDet 的设计目标是能够在无 GPU 加速条件下,稳定运行于通用 CPU 计算平台。该特性使得巡检系统可在大规模养殖场中以较低硬件门槛进行推广应用,无需配置昂贵的专用计算设备,从而显著降低系统初期部署成本和后期运维复杂度,具有更高的工程实用价值。

尽管 RabbitDet 在计数精度与计算效率之间取得了较好平衡,但仍存在一定不足。首先,本文采用固定输入分辨率 640 像素 × 640 像素,虽然保证了对目标特征的充分提取,但在算力极度受限的纯 CPU 边缘端,探讨输入分辨率与推理时延之间的关系,实现任务驱动的最优尺度推理,是下一步优化的

重点。其次,本数据集尚未覆盖哺乳期幼兔。幼兔体型极小且具有更强的集群堆叠行为,其外表特征与青年、成年兔存在显著的形态学差异。未能验证模型在肉兔全年龄段下的泛化能力是本研究的局限之一。最后,受限于数据来源的单一性,模型对不同材质笼具、不同毛色品种以及复杂光影干扰的鲁棒性仍待检验。未来将通过引入多地域、多尺度及全龄段的异构数据,利用领域自适应等技术进一步强化模型的泛化能力,以期实现该算法在智慧养殖领域的跨场景推广。

5 结论

(1)针对集约化笼养环境下兔只存栏自动计数过程中个体密集遮挡严重以及移动巡检机器人计算资源受限等问题,基于 NanoDet-Plus 框架提出了一种轻量化兔只检测模型 RabbitDet。通过在模型结

构中引入 GS 模块、轻量特征聚合网络 LFA PAN 及 GeLU 激活策略,有效提升了模型在复杂遮挡场景下的检测与计数性能。

(2)改进后的 RabbitDet 模型在保证低计算复杂度的前提下实现了较高的计数精度,其 mAP、计数准确率、参数量和浮点运算量分别为 75.7%、98.8%、 7.3×10^5 和 1.2×10^9 。

(3)与主流轻量化检测模型相比,RabbitDet 在显著降低模型规模和计算开销的同时,保持了稳定的检测性能,在计数精度与推理效率之间实现了更优平衡。

(4)在移动巡检机器人单线程 CPU 条件下的部署实验表明,RabbitDet 平均推理时延稳定在约 60 ms,能够在计算资源受限的情况下实现可靠运行,验证了其在移动机器人 CPU 平台上的工程可行性和实时性。

参 考 文 献

[1] 郭钰,徐琳娜,陈雅莉. 浅谈肉兔高效养殖技术[J]. 甘肃畜牧兽医,2023,53(2):109-112.

[2] 武拉平,秦应和. 2025 年中国兔产业特点和 2026 年发展趋势展望[J]. 中国畜牧杂志,2026,62(3):403-408.

[3] Song D, Chen Z, Peng Y, et al. INL-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.

[4] Li M, Zhao Z, Wu J, et al. Y-BGD: broiler counting based on multi-object tracking[J]. Computers and Electronics in Agriculture, 2022,202:107347.

[5] Li J, Yang Y, Yao Y, et al. A dynamic yak heifer pose estimation model based on keypoint detection for complex environmental monitoring[J]. Journal of Dairy Science, 2025, 108(12): 13704-13719.

[6] 曾志雄,黄迎辉,林锴,等. 基于 GSD-YOLO 的复杂场景仔猪检测和计数方法[J]. 农业机械学报,2025,56(6):247-257.

Zeng Zhixiong, Huang Yinghui, Lin Kai, et al. Advanced piglet detection and counting in complex scenarios using GSD-YOLO architecture[J]. Transactions of the Chinese Society for Agricultural Machinery,2025,56(6):247-257. (in Chinese)

[7] 李道亮,赵聪慧,朱弘烨,等. 基于深度学习的鱼类生物量估算研究进展[J]. 农业机械学报,2026,57(2):121-133.

Li Daoliang, Zhao Conghui, Zhu Hongye, et al. Recent advances in fish biomass estimation based on deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery,2026,57(2):121-133. (in Chinese)

[8] 刘晓阳,王文良,郑欣宇,等. 面向池塘养殖的水下海参原位计数无人船系统设计与试验[J]. 农业机械学报,2025,56(10):82-93.

Liu Xiaoyang, Wang Wenliang, Zheng Xinyu, et al. Design and testing of unmanned boat system for in-situ counting of sea cucumbers in pond aquaculture[J]. Transactions of the Chinese Society for Agricultural Machinery,2025,56(10):82-93. (in Chinese)

[9] Guo Y, Aggrey S E, Yang X, et al. Detecting broiler chickens on litter floor with the YOLO v5-CBAM deep learning model[J]. Artificial Intelligence in Agriculture, 2023, 9: 36-45.

[10] Wu R, He P, He Y, et al. Egg production monitoring in commercial laying cages via the StrongSort-EGG tracking-by-detection model[J]. Computers and Electronics in Agriculture, 2024, 227: 109508.

[11] Zhang G, Wang C, Xiao D. A novel daily behavior recognition model for cage-reared ducks by improving SPPF and C3 of YOLO v5s[J]. Computers and Electronics in Agriculture, 2024, 227: 109580.

[12] Guo J, He G, Deng H, et al. Pigeon cleaning behavior detection algorithm based on light-weight network[J]. Computers and Electronics in Agriculture, 2022, 199: 107032.

[13] Yang J, Zhang T, Fang C, et al. A detection method for dead caged hens based on improved YOLO v7[J]. Computers and Electronics in Agriculture, 2024, 226: 109388.

[14] Xiao D, Wang H, Liu Y, et al. DHWS-YOLO: a duck flock daily behavior recognition model adaptable to bright and dark conditions[J]. Computers and Electronics in Agriculture, 2024, 225: 109281.

[15] 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.

[16] Li X, Cai M, Liu Z, et al. A lightweight model based on knowledge distillation for free-range chickens detection in complex

commercial farming environments[J]. Artificial Intelligence in Agriculture, 2026, 16(1): 266 – 283.

[17] Man, Zhang X, Zheng H T, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design[C] // Proceedings of the European Conference on Computer Vision (ECCV). Cham: Springer, 2018: 116 – 131.

[18] Han K, Wang Y, Tian Q, et al. GhostNet: more features from cheap operations[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020: 1577 – 1586.

[19] Wang Q, Wu B, Zhu P, et al. ECA – Net: efficient channel attention for deep convolutional neural networks[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020: 11531 – 11539.

[20] Khanam R, Hussain M. YOLO 11: an overview of the key architectural enhancements[EB/OL]. (2024 – 10 – 24) [2026 – 03 – 08]. <https://arxiv.org/abs/2410.17725>.

[21] Li C, Li L, Jiang H, et al. YOLO v6: a single-stage object detection framework for industrial applications[EB/OL]. (2022 – 09 – 06) [2026 – 03 – 08]. <https://arxiv.org/abs/2209.02976>.

[22] Tu P, Xie X, Ai G, et al. FemtoDet: an object detection baseline for energy versus performance tradeoffs[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). IEEE, 2023: 13272 – 13281.

[23] Geffen O, Yitzhaky Y, Barchilon N, et al. A machine vision system to detect and count laying hens in battery cages[J]. Animal, 2020, 14(12): 2628 – 2634.

[24] 赵春江,梁雪文,于合龙,等. 基于改进 YOLO v7 的笼养鸡/蛋自动识别与计数方法[J]. 农业机械学报, 2023,54(7): 300 – 312.

Zhao Chunjiang, Liang Xuewen, Yu Helong, et al. Automatic identification and counting method of caged hens and eggs based on improved YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54(7): 300 – 312. (in Chinese)

[25] Wu Z, Yang J, Zhang H, et al. Enhanced methodology and experimental research for caged chicken counting based on YOLO v8[J]. Animals, 2025, 15(6): 853.

~~~~~

(上接第 102 页)

[22] 唐徐华,林君,杨海明,等. 不同家禽蛋壳结构及其成分研究[J]. 福建农业学报,2022,37(2):156 – 163.

Tang Xuhua,Lin Jun,Yang Haiming,et al. Shell structure and composition of poultry eggs[J]. Fujian Journal of Agricultural Sciences,2022,37(2):156 – 163. (in Chinese)

[23] 张云伟,张健涛,张海,等. 基于近红外光谱与 Transformer 的烟叶感官指标预测方法[J]. 农业机械学报,2026,57(1): 386 – 396.

Zhang Yunwei, Zhang Jiantao, Zhang Hai, et al. Prediction method of tobacco sensory indicators based on near infrared spectroscopy and transformer[J]. Transactions of the Chinese Society for Agricultural Machinery,2026,57(1):386 – 396. (in Chinese)

[24] Norgaard L,Saudland A,Wagner J,et al. Interval partial least-squares regression(iPLS): a comparative chemometric study with an example from near-infrared spectroscopy[J]. Applied Spectroscopy,2000,54(3):413 – 419.

[25] Leardi R,Nørgaard L. Sequential application of backward interval partial least squares and genetic algorithms for the selection of relevant spectral regions[J]. Journal of Chemometrics,2004,18(11):486 – 497.

[26] Ahmed M W, Sprigler A, Emmert J L, et al. Non-destructive detection of pre-incubated chicken egg fertility using hyperspectral imaging and machine learning[J]. Smart Agricultural Technology,2025,10:100857.

[27] 宋科,潘磊庆,杨崇龙,等. 受精种蛋理化指标与光谱信息的响应关系[J]. 南京农业大学学报,2023,46(6):1187 – 1195.

Song Ke,Pan Leiqing,Yang Chonglong,et al. The response of physical and chemical indicators of fertilized breeder eggs based on spectral information[J]. Journal of Nanjing Agricultural University,2023,46(6):1187 – 1195. (in Chinese)

[28] Gielen R M A M,De Jong L P,Kerkvliet H M M. Electrooptical blood-spot detection in intact eggs[J]. IEEE Transactions on Instrumentation and Measurement,1979,28(3):177 – 183.