

基于改进 YOLO 11 的轻量化鹌鹑蛋裂纹在线无损检测系统

刘世伟^{1,2} 王志浩¹ 袁捷¹ 魏子源¹

(1. 华中农业大学工学院, 武汉 430070; 2. 农业农村部长江中下游农业装备重点实验室, 武汉 430070)

摘要: 针对鹌鹑蛋裂纹缺陷视觉无损检测效率低、准确性不足的问题, 本文提出一种基于改进 YOLO 11 的轻量化鹌鹑蛋裂纹在线无损检测系统。以 YOLO 11 为基线模型, 通过引入 C3k2_IDWC、SPPF_LSKA 及 EUCB_SCM 模块完成网络结构优化, 再经 LAMP 剪枝实现全局稀疏化, 并结合 BCKD 逻辑蒸馏与 CWD 特征蒸馏迁移判别知识, 构建兼具高精度与轻量化特性的 YOLO 11-Quail 模型。试验结果表明, 改进的 YOLO 11-Quail 模型平均精度均值达到 94.6%, 精确率和召回率均为 95.1%, 检测速度达 184.8 f/s, 参数量仅为 1.6×10^6 。在 Jetson Nano 部署测试中, 采用数字化结果矩阵判定跟踪算法实现多角度综合检测, 误检率降低至 8.33%, 检测时延为 68.59 ms, 较改进前处理速度提升 11.3%, 满足典型鹌鹑蛋裂纹在线无损检测需求。

关键词: 鹌鹑蛋; 无损检测; YOLO 11; 轻量化; 剪枝; 知识蒸馏

中图分类号: TS253.7

文献标识码: A

文章编号: 1000-1298(2026)10-0403-09

OSID:



Lightweight Quail Egg Crack Online Non-destructive Testing System Based on Improved YOLO 11

LIU Shiwei^{1,2} WANG Zhihao¹ YUAN Jie¹ WEI Ziyuan¹

(1. College of Engineering, Huazhong Agricultural University, Wuhan 430070, China

2. Key Laboratory of Agricultural Equipment in Mid-lower Yangtze River, Ministry of Agriculture and Rural Affairs, Wuhan 430070, China)

Abstract: Aiming to address the critical quality control challenge of detecting cracked quail eggs in egg processing, where manual and machine-assisted visual inspection are both inefficient and inaccurate, a high-performance, lightweight online non-destructive detection system was developed based on a comprehensively improved YOLO 11 deep learning architecture. YOLO 11n was selected as the baseline for its favorable balance of speed and accuracy, then systematically optimized for the specific task of identifying subtle cracks on variably patterned quail eggshells through two core phases: network architectural refinement and model compression. In the network refinement phase, the backbone network integrated the C3k2_IDWC module to capture multi-scale textural details and directional contextual information of fine cracks, while the neck network replaced the original SPPF module with SPPF_LSKA (to focus on crack regions via spatial attention) and standard upsampling with EUCB_SCM (to enhance cross-channel information interaction and feature fusion). For model compression, the enhanced network underwent global sparsification via the LAMP pruning algorithm to eliminate redundant parameters, followed by dual knowledge distillation combining BCKD (logit-level guidance) and CWD (feature-level imitation) to transfer knowledge from the high-performance teacher model to the compact student model, yielding YOLO 11-Quail. Experimental results on a dark-field backlighting dataset showed YOLO 11-Quail achieved 94.6% mAP, 95.1% precision and recall, 184.8 f/s inference speed, and only 1.6×10^6 parameters. Deployed on Jetson Nano with a multi-angle tracking algorithm, it delivered an 8.33% false detection rate, 0 missed detection rate, and 68.59 ms latency, satisfying the high-precision real-time demands of industrial production lines.

Key words: quail egg; non-destructive testing; YOLO 11; lightweight; pruning; knowledge distillation

收稿日期: 2025-12-02 修回日期: 2025-12-30

基金项目: 国家自然科学基金项目(52375542)、中央高校基本科研业务费专项资金项目(2662024SZ004)、教育部产学研合作协同育人基金项目(20243870B07)、湖北省自然科学基金项目(2023AFB903)和华中农业大学教育教学改革研究基金项目(2024046)

作者简介: 刘世伟(1990—),男,副教授,博士生导师,主要从事无损检测技术及理论研究, E-mail: liusw@hzaue.edu.cn

0 引言

我国鹌鹑蛋年产量约 1.5×10^6 t, 占全球总产量的 60% 以上^[1]。随着市场需求从鲜蛋向休闲零食、预制菜等深加工产品加速转变^[2], 鹌鹑蛋除鲜食外, 熟食类鹌鹑蛋在 C 端市场规模为 20 亿 ~ 30 亿元^[1], 这对鹌鹑蛋原料及成品品质一致性提出了更高要求。鹌鹑蛋个体小、蛋壳带斑, 传统人工检测劳动强度大、效率低且易漏检误判^[3], 制约产业智能化发展。

近年鹌鹑蛋无损检测研究多围绕新鲜度、几何参数及整体质量展开。NARUSHIN 等^[4]建立数学模型实现蛋体参数非侵入式计算; MASSAKI 等^[5]、LIMA 等^[6]分别借助热成像与近红外光谱结合算法评估蛋品新鲜度; YILDIZ 等^[7]通过机器学习预测蛋品质量, 准确率超 97%。然而, 针对鹌鹑蛋表面裂纹的在线无损检测仍为研究空白。

深度学习技术凭借快速、准确的优势, 已被广泛应用于农产品无损检测中, 有效提升了农产品检测效率和精度。胡建超^[8]提出一种轻量级卷积神经网络 MobileNetV2, 使模型体积减小 31.0%, 综合识别率为 94.9%。汤文权等^[9]在皮蛋裂纹在线检测中, 提出了一种基于改进 YOLO v5 的皮蛋裂纹在线检测方法, 将裂纹检测准确率提升至 92% 以上, 参数量降低至 1.5×10^6 。赵祚喜等^[10]提出一种基于改进 YOLO v7 模型的破壳鸡蛋在线实时检测系统, 平均精度均值为 94.0%, 单幅图像检测时间为 13.1 ms。

以上研究为鹌鹑蛋裂纹无损检测提供了参考, 但当前基于深度学习的鹌鹑蛋在线检测研究存在以下问题: 相较于鸡蛋, 鹌鹑蛋因尺寸、表面状态差异导致其裂纹检测难度更高, 相关研究也较少; 现有方案既缺乏针对性翻转机构, 主流追踪算法也难以适配凸显微裂纹所需的暗场背光成像条件, 且很少完成边缘设备与产线部署验证。针对上述问题, 本文提出改进 YOLO 11 算法, 引入 C3k2_IDWC、SPPF_LSKA、EUCB_SCM 模块提升裂纹特征学习能力, 结合剪枝与双蒸馏策略实现高精度轻量化, 搭建三通道输送台并开发数字化结果矩阵判定跟踪算法, 最终将模型部署于 Jetson Nano 完成在线试验, 验证其在实际产线的可行性。

1 材料与方法

1.1 数据采集

在图 1 所示的三通道鹌鹑蛋检测装置上采集鹌鹑蛋表面图像, 检测装置主要由相机、暗箱、蛋辊和光源组成, 图像采集装置结构示意图如图 2 所示。



图 1 三通道鹌鹑蛋检测装置

Fig. 1 Three channel quail egg detection device




图 2 图像采集装置结构示意图

Fig. 2 Schematics of image acquisition device

1. 相机 2. 暗箱 3. 鹌鹑蛋 4. 蛋辊 5. 滚子 6. 光源

在数据采集部分, 鹌鹑蛋经人工定向摆放至定制三通道输送台入口, 输送台兼容自动上料设备, 其滚子可带动鹌鹑蛋前移并匀速自转, 保障蛋体表面全面扫描。成像系统采用激光传感器触发机制, 鹌鹑蛋运动至背光光源正下方时, 相机同步采集含 9 枚鹌鹑蛋的 3×3 阵列图像, 每枚蛋品在自转过程先后 3 次经过成像位置, 从而分别触发采集代表 3 个不同侧面图像 A、B、C。传感器端设置防误触时间窗, 避免蛋品振动、抖动等引发的连续误触发, 维持图像采集与蛋品运动的时序同步。

鹌鹑蛋自转使 A、B、C 三视角可覆盖大部分侧面, 但长轴顶、尾端因投影面积小存在检测盲区, 垂直自转轴分布的裂纹、旋转至蛋体轮廓边缘的裂纹, 在暗场背光成像下易因投影尺度小、对比度低或亮域面积压缩影响识别精度。为此, 在数据采集阶段纳入顶端裂纹、底端裂纹、边缘裂纹、星状裂纹、线状裂纹等困难样本, 增强模型对弱显性裂纹的鲁棒性, 如图 3 所示; 在线检测时融合三视角结果, 结合暗场背光成像清晰显现蛋体轮廓、高亮裂纹特征的优势, 降低局部盲区与不利角度导致的误检风险, 提升检测容错率与敏感度。

1.2 数据集构建

为提升模型鲁棒性, 针对鹌鹑蛋检测任务设计专门的数据增强策略。考虑到现场常见的设备反光、阴影波动等光照变化和电子噪声、粉尘干扰等场景噪声, 采取对应随机调整饱和度、添加噪声、翻转、放缩、平移和背景分离方式, 先划分数据集后对数据集进行扩充。数据增强后, 从原有 300 幅图像数据扩充到 1 500 幅图像数据, 图像分辨率为 1 920 像




图 3 鹌鹑蛋数据样例

Fig. 3 Quail egg data sample

素 $\times 1080$ 像素。数据集共包含 13 456 个标签,其中完好和裂纹鹌鹑蛋标签数量分别为 6 733 和 6 723,以比例 7:1.5:1.5 随机分为训练集、验证集和测试集。

1.3 改进 YOLO 11n 模型网络结构

在 YOLO 系列模型中,YOLO 11n 具有参数量少、推理速度快等优势^[11]。由于 YOLO 11n 模型轻量化设计,可在边缘设备上高效部署与运行,为实现鹌鹑蛋质量检测的智能化与自动化提供有效技术支撑,故本文以 YOLO 11n 为基准模型,提出改进的 YOLO - Quail,改进模型结构如图 4 所示,图中 Conv 为卷积模块,C3k2 为复合卷积模块,C2PSA 为特征提取模块,Concat 为特征连接模块,Detect 为检测头。

以改进的 YOLO - Quail 模型为识别核心,衔接后续的判决算法。系统首先采集每枚鹌鹑蛋 3 幅背光图像 A、B、C 并输入模型;YOLO - Quail 模型对每帧图像进行实时推理,输出所有蛋品边界框及裂纹分类结果;检测结果随即被数字化矩阵算法(见 1.4 节)接收,若结果满足条件,系统即输出分拣指令。

1.3.1 C3k2_IDWC 模块

为增强模型在复杂纹理干扰下对裂纹细节的表征能力,在 YOLO 11 的 C3k2 模块基础上引入 InceptionNeXt 中的 InceptionDWConv2d 结构^[12],构建 C3k2_IDWC 模块。核心改进体现在对原始 Bottleneck 中 2 层标准卷积 Conv 进行替换,由 InceptionDWConv2d 实现。




图 4 YOLO - Quail 模型结构

Fig. 4 YOLO - Quail model structure

InceptionDWConv2d 模块通过 4 条并行路径整合不同尺度特征。其中,恒等映射路径(Identity)保留输入的细粒度特征,有助于梯度传播并防止细节丢失; 3×3 深度卷积分支提取局部邻域的纹理与模式; 1×11 与 11×1 非对称深度卷积分支分别专注于捕获水平与垂直方向上的延展上下文信息。这种多路径设计能够整合不同尺度、方向性特征。

与传统卷积模块 Conv 相比,InceptionDWConv2d 模块参数量和计算量均不再与 C^2 (C 为通道数)非线性相关,而是变为线性关系,这在大通道数网络中能显著降低模型复杂度。同时,通过与深度卷积 DWConv 公式对比可知,InceptionDWConv2d 模块通过引入多分支、非对称卷积核降低了项内系数数量,在保持强大特征提取能力的同时,进一步优化计算开销。

1.3.2 SPPF_LSKA 模块

在 YOLO 11n 模型中,SPPF (Spatial pyramid pooling-fast)模块通过多尺度池化操作扩展感受野并融合不同尺度的上下文信息,但特征融合过程为静态,缺乏对关键空间区域的自适应选择能力,难以在复杂背景下有效突出裂纹特征。针对鹌鹑蛋表面纹理复杂、裂纹细微等问题,在 SPPF 模块基础上引入大可分离核注意力 (Large-separable-kernel-attention, LSKA)^[13],构建改进的 SPPF_LSKA 模块,以提升模型在裂纹检测任务中鲁棒性与精确度。

SPPF_LSKA 首先沿用 SPPF 多尺度池化以扩展感受野并获取不同尺度的上下文特征;随后将池化融合后的特征输入 LSKA 模块,引入基于大核方向卷积的空间注意力,使网络能够自适应地关注裂纹

区域并抑制背景噪声。通过将多尺度上下文信息与方向性空间注意力相结合,SPPF_LSKA 模块既保持了 SPPF 结构的轻量化优势,又显著增强了模型在复杂纹理背景下对细微裂纹的感知能力。

1.3.3 EUCB_SCM 模块

在传统 YOLO 上采样过程,特征图经过简单的插值与卷积操作后往往导致高频细节丢失,不利于裂纹等细微目标检测。为应对鹌鹑蛋表面裂纹细微、纹理复杂干扰的问题,针对 YOLO 11 上采样结构进行针对性改进,引入基于 EMCAD 的 EUCB(Enhanced up-sampling convolution block)模块^[14]与 BHViT 中 SCM(Shift channel mix)模块^[15],设计一种混合模块 EUCB_SCM(Enhanced up-sampling convolution block with shift channel mix),以提升模型对鹌鹑蛋表面细微裂纹的检测能力,结构如图 5 所示。




图 5 EUCB_SCM 模块结构

Fig. 5 EUCB_SCM module structure

在通道混洗(Channel shuffle)机制中,输入特征首先被划分为多个通道组,每组通道内进行重排操作,通过跨组转置实现特征的重新组合。由于深度卷积(DWConv)每个输入通道只与自己对应的卷积核进行卷积,但该过程使原本独立的通道间产生信息交互,从而打破深度卷积带来的特征孤立问题。

通道位移混合(SCM)模块将特征通道分块并在水平与垂直方向做小幅循环位移,随后重组输出。通过改变同一空间位置处不同通道所代表的原始局部来源,从而为随后的逐点卷积提供更为多样的邻域信息组合路径。对于裂纹检测需要感知细长连续结构的任务,通道位移混合模块能够帮助模型更好地捕捉裂纹的延伸方向和整体轮廓,而且与原始 EUCB 模块相比,几乎不会额外增加计算成本。

1.3.4 LAMP 剪枝算法

模型剪枝作为一种主流的轻量化技术,核心思想是移除网络中冗余参数,在尽可能保持模型性能的同时,显著减少参数量与计算复杂度。为了使模型能够高效地在嵌入式设备上实时运行,采用 LAMP(Layer-adaptive magnitude pruning)^[16]剪枝算法。

LAMP 算法基本思想是在给定的全局稀疏度约束下,寻找一个权重子集,使得剪枝后对网络输出的扰动最小。LAMP 剪枝流程见文献[17]。LAMP 优势在于每层都会至少保留 1 个权重,即至少保留 1 个存活连接,有效地避免因盲目剪枝而导致的层崩溃现象发生^[18]。

1.3.5 知识蒸馏算法

模型剪枝在提升推理速度的同时,不可避免地会导致模型表征能力下降。为有效恢复剪枝后轻量模型在鹌鹑蛋裂纹检测精细任务上的性能,引入一种结合 BCKD(Bridging cross-task protocol inconsistency for distillation in dense object detection)逻辑蒸馏^[19]与 CWD(Channel-wise knowledge distillation for dense prediction)特征蒸馏^[20]的双蒸馏策略,旨在从高层语义和底层特征 2 个维度,将未剪枝教师模型的判别知识高效地迁移至剪枝后学生模型中,双知识蒸馏框架如图 6 所示。

逻辑蒸馏作用于模型的输出层,通过温度参数 $T(T > 1)$ 对教师模型和学生模型的原始逻辑输出进行软化。软化后的概率分布更加平滑,蕴含丰富的类间关系信息。教师模型通过软化后的逻辑输出,向学生模型传递该信息,从而提供高层语义指导。逻辑蒸馏损失 L_{BCKD} 通过计算 2 个软化分布间的 KL 散度(Kullback-leibler divergence)定义,计算式为

$$L_{\text{BCKD}} = T^2 D_{\text{KL}}(\sigma(Z_s/T) \parallel \sigma(Z_t/T)) \tag{1}$$

式中 Z_s ——学生逻辑输出
 Z_t ——教师逻辑输出
 σ ——Softmax 函数
 D_{KL} ——KL 散度

特征蒸馏与逻辑蒸馏互补,特征蒸馏直接作用于模型的中间特征层。对于鹌鹑蛋裂纹细微缺陷,深层特征图保留至关重要的空间结构信息,从而提供底层细节指导。提取教师模型与学生模型骨干网络末端的特征图 F_t 和 F_s ,因为剪枝操作通常会导致学生模型特征通道数减少,所以引入 1 个轻量的 1×1 卷积层对 F_s 进行通道维度对齐,得到 F'_s 。特征蒸馏损失 L_{CWD} 通过最小化二者概率化后分布的 KL 散度实现,计算式为

$$L_{\text{CWD}} = D_{\text{KL}}(\sigma(F'_s)\sigma(F_t)) \tag{2}$$

综合上述 2 种知识蒸馏方法的优势,将其协同




图 6 双知识蒸馏框架

Fig. 6 Knowledge distillation framework

整合。双知识蒸馏策略的总训练损失 L_{total} 由标准任务损失和 2 项蒸馏损失加权构成,即

$$L_{total} = L_{gt} + \alpha L_{BCKD} + \beta L_{CWD} \quad (3)$$

式中 L_{gt} ——学生模型预测标签与真实标签间的交叉熵损失,确保其不偏离基本的裂纹判别任务

α, β ——平衡 2 项蒸馏损失的加权超参数

1.4 鹌鹑蛋裂纹在线检测方法

为实现鹌鹑蛋在线裂纹检测的实时性与鲁棒性,设计一种数字化结果矩阵判定跟踪算法,将物理空间中鹌鹑蛋位置数字化为矩阵,通过对同一枚蛋品在连续运动过程、不同视角下的多次检测结果进行累积与判决,替代复杂的轨迹跟踪,显著降低计算复杂度。算法执行流程是一个顺序化的周期处理循环,步骤如下:

(1)状态矩阵生成:算法读取每一帧图像的检测结果。将每个检测框中心坐标与预设的 3×3 网格边界进行比对,确定所属的特定网格单元。随后,初始化 1 个所有元素为 0 的 3×3 矩阵。仅当某一网格单元内存在被分类为“裂纹”的检测目标时,才将该矩阵中对应位置元素更新为 1。此矩阵即为表征当前帧各位置裂纹检测状态的二值状态矩阵。

(2)累加矩阵更新与位移:从缓存读取上一周期的累加矩阵,对其执行向下位移操作:原第 2 行移至第 3 行,第 1 行移至第 2 行,第 3 行数据丢弃,新的第 1 行置 0。将位移后的矩阵与当前状态矩阵按位相加,结果作为新的累加矩阵存入缓存。

(3)阈值判定与输出:实时扫描更新后的累加矩阵,检查各元素值。若任一元素值等于 1,则立即生成对应网格位置的裂纹蛋判定指令,并发送至分拣控制系统。

(4)循环与重置:步骤(1) ~ (3)随图像采集周期同步循环执行。当蛋体完全移出检测区域或判定指令发出后,可对相关行或整个矩阵执行重置操作,以准备下一批次检测。

将空间定位与时序关联转换为确定的矩阵运算,避免了传统跟踪算法中特征匹配与数据关联开销,兼具高实时性与强鲁棒性,可满足边缘设备在线检测系统的工程约束。

1.5 评价指标

为更好地衡量鹌鹑蛋裂纹检测精度和实时性,选取精确率 (Precision, P)、召回率 (Recall, R)、每秒检测帧数 (Frames per second, FPS)、交并比为 0.5 时的平均精度均值 (mean Average Precision, mAP@50)、参数量、浮点运算量 (GFLOPs)、模型内存占用量 (Weight)、漏检率和误检率等作为评价指标。

1.6 试验环境

模型训练与测试使用的硬件配置: Intel Core i5 12500H CPU, NVIDIA RTX 3060 Laptop GPU, 6 GB 显存。软件配置: Pytorch 2.0.1 深度学习框架, CUDA 12.5.85, Python 3.9.23 编程语言,训练轮次为 100,批量大小为 4,图像输入分辨率为 640 像素 $\times$ 640 像素。此外,模型训练过程均未使用预训练权重文件。

2 结果与分析

2.1 消融试验

为验证 C3k2_IDWC、SPPF_LSKA 与 EUCB_SCM 各模块对裂纹检测性能的具体贡献,以 YOLO 11n 为基线模型开展消融试验,改进模型为 YOLO 11-ILE。在相同的试验环境和参数设定下进行消融试验,试验结果如表 1 所示。

表 1 消融试验结果

Tab.1 Results of ablation experiment

模型	精确率/%			召回率/%			mAP@ 50/ %	参数量	浮点运算 量	模型内存占 用量/MB
	正常	裂纹	所有	正常	裂纹	所有				
YOLO 11n	92.3	94.8	93.5	94.6	92.1	93.4	93.9	2.6×10^6	6.3×10^9	10.2
YOLO 11n + C3k2_IDWC	91.3	96.8	94.1	97.0	90.8	93.9	94.5	2.4×10^6	6.1×10^9	9.5
YOLO 11n + SPPF_LSKA	92.7	96.1	94.4	95.6	91.5	93.5	94.6	2.9×10^6	6.5×10^9	11.3
YOLO 11n + EUCB_SCM	93.2	94.7	94.0	95.1	93.3	94.2	94.3	2.7×10^6	6.8×10^9	10.6
YOLO 11n + C3k2_IDWC + SPPF_LSKA	94.1	95.4	94.8	95.5	94.0	94.7	94.9	2.7×10^6	6.3×10^9	10.6
YOLO 11n + C3k2_IDWC + SPPF_LSKA + EUCB_SCM(YOLO 11 - ILE)	95.4	94.9	95.1	94.8	95.3	95.0	95.3	2.8×10^6	6.7×10^9	10.9

单独引入 C3k2_IDWC 模块后,“正常”类别精确率从 92.3% 降至 91.3%,但“裂纹”类别精确率从 94.8% 升至 96.8%,在召回率方面,“正常”类别从 94.6% 提升至 97.0%,但“裂纹”类别从 92.1% 降至 90.8%,mAP@ 50 提升至 94.5%。InceptionDWConv2d 模块的引入显著降低了参数量和浮点运算量,实现了模型轻量化的同时提升了整体检测性能。其次,引入 SPPF_LSKA 模块则带来了不同的优化方向,“裂纹”类别精确率从 94.8% 上升至 96.1%,同时保持了各类别指标的均衡,整体 mAP@ 50 提升至 94.6%,同时模型复杂度因模块引入而略有增加。而引入 EUCB_SCM 模块效果最为均衡,在整体精确率、召回率上几乎均有提升,整体 mAP@ 50 也达到 94.3%。当 C3k2_IDWC 与 SPPF_LSKA 结合后,模型在“所有”类别上的精确率和召回率分别达到 94.8% 与 94.7%,mAP@ 50 进一步提升至 94.9%。最终,集成全部 3 个模块的完整模型 YOLO 11 - ILE,在“所有”类别上精确率与召回率分别达到 95.1% 与 95.0%,mAP@ 50 达到 95.3%,较原始模型分别提升 1.6、1.6、1.4 个百分点,参数量增加约 7.7%,浮点运算量增加约 6.3%,模型内存占用量增加约 6.9%。

2.2 可视化分析

为可视化模型决策所关注的图像区域,采用 Grad - CAM + + 技术生成热力图,相较于 Grad - CAM,在图像中存在多个同类物体时能更精准地定位目标,可视化结果如图 7 所示,颜色由蓝到红表示模型关注度从低到高变化。

由图 7 可知,在边缘、顶端、星状及线状等裂纹上,YOLO 11n 和 YOLO 12n 注意力较为分散,尤其对于边缘裂纹,模型易受蛋壳背景干扰且定位焦点不集中,而 YOLO 11n - ILE 热力图高亮区域能较为精准地定位裂纹区域。

2.3 模型剪枝与知识蒸馏

采用 LAMP 剪枝技术和全局剪枝策略对 YOLO 11 - ILE 模型进行压缩。与逐层为非全局剪枝不同,全局剪枝从整体视角评估并移除模型中所有层




图 7 可视化结果

Fig.7 Visualization results

内重要性最低的参数。该策略优势在于能够在整个网络范围内实现最优稀疏化,避免因某些层被过度剪枝而成为性能瓶颈,从而在相同剪枝率下,能获得比非全局剪枝更优的精度与效率权衡,如图 8 所示。由图 8 可知,在低剪枝率阶段,模型 mAP@ 50 仅轻微下降,表明此阶段移除的主要是冗余参数。而当剪枝率过大时,mAP@ 50 开始出现断崖式下跌。通过对不同剪枝率模型进行知识蒸馏后,当剪枝率设定为 28.6% 时,模型获得较大化压缩效益,而且较好地保留骨干特征提取能力。




图 8 mAP@ 50、浮点运算量与剪枝率关系曲线

Fig.8 mAP@ 50, GFLOPs and pruning rate curves

在获得剪枝后的轻量学生模型基础上,进一步采用双知识蒸馏(BCKD + CWD)策略以恢复并提升性能。如表 2 所示,以较高性能的 YOLO 11 - ILE 作为教师模型,以较低计算成本剪枝后的 YOLO 11 - pruning 学生模型进行知识迁移。蒸馏后,学生模型准确率与召回率均由 94.1% 提升至 95.1%,核心指

表 2 知识蒸馏前后性能

Tab.2 Performance before and after knowledge distillation

模型	精确率/%	召回率/%	mAP@ 50/%	参数量	浮点运算量	模型内存占 用量/MB
YOLO 11n	93.5	93.4	93.9	2.6×10^6	6.3×10^9	10.2
YOLO 11 - ILE	95.1	95.0	95.3	2.8×10^6	6.7×10^9	10.9
YOLO 11 - pruning(蒸馏前)	94.1	94.1	94.2	1.6×10^6	4.8×10^9	6.6
YOLO 11 - Quail(蒸馏后)	95.1	95.1	94.6	1.6×10^6	4.8×10^9	6.6

标 mAP@ 50 也恢复至 94.6%。知识蒸馏后学生模型性能反超教师模型结论与 HINTON 等^[21] 观点一致,即知识蒸馏能使 学生模型从教师的软标签中学习 到类别间丰富的相似性关系,从而获得比原始教师模型更优的泛化能力。

最终, YOLO 11 - Quail 模型参数量为 1.6×10^6 ,浮点运算量为 4.8×10^9 ,模型内存占用量为 6.6 MB。相较于基准模型 YOLO 11n,参数量下降 38.5%,浮点运算量下降 23.8%,模型内存占用量减少 35.3%。检测精确率与召回率均达到 95.1%,较基准模型分别提升 1.6、1.7 个百分点,mAP@ 50 达到 94.6%,较基准模型提升 0.7 个百分点。另一

方面,相较于教师模型 YOLO 11 - ILE,轻量化 YOLO 11 - Quail 模型在参数量降低 42.9%、浮点运算量降低 28.4%、模型内存占用量减少 39.4%的同时,实现了与教师模型持平的准确率,且召回率略有超越,验证了网络剪枝与知识蒸馏联合优化策略的有效性。

2.4 不同模型性能试验

为验证 YOLO 11 - Quail 模型在鹌鹑蛋裂纹检测任务中的综合性能,将当前主流检测模型 Faster R - CNN、Deformable DETR、YOLO v5n、YOLO v8n、YOLO 11n、YOLO 12n 及 YOLO 13n 在相同试验条件下进行对比,结果如表 3 所示。

表 3 不同模型性能试验结果

Tab.3 Performance experimental results of different models

模型	mAP@ 50/%	召回率/%	参数量	浮点运算量	帧率/(f·s ⁻¹)
Faster R - CNN	93.6	80.3	4.175×10^7	2.130×10^{11}	13.0
Deformable DETR	91.9	84.1	4.010×10^7	1.976×10^{11}	9.3
YOLO v5n	92.6	90.1	2.500×10^6	7.100×10^9	178.6
YOLO v8n	92.3	91.6	3.010×10^6	8.100×10^9	175.4
YOLO 11n	93.9	93.4	2.580×10^6	6.300×10^9	173.8
YOLO 12n	93.8	93.1	2.510×10^6	5.800×10^9	175.4
YOLO 13n	93.2	92.7	2.450×10^6	6.200×10^9	166.7
YOLO 11 - ILE	95.3	95.1	2.800×10^6	6.700×10^9	172.4
YOLO 11 - Quail	94.6	95.2	1.600×10^6	4.800×10^9	184.8

以 Faster R - CNN 为代表的两阶段检测器在 mAP@ 50 方面表现优异,达到 93.6%,显示出较强的识别能力,但参数量、浮点运算量与模型内存占用量均显著偏高,导致推理速度较慢,帧率仅为 13.0 f/s。Deformable DETR 是基于 Transformer 的模型,虽在 mAP@ 50 上仍保持较高水平(91.9%),但模型复杂、计算资源消耗大,帧率为 9.3 f/s。相比之下,YOLO 系列模型在精度与效率间取得了良好平衡,mAP@ 50 均超过 92%,同时参数量、浮点运算量与模型内存占用量大幅降低,帧率普遍超过 170 f/s。在 mAP@ 50 方面,YOLO 11 - Quail 模型较 YOLO v5n 提升 2.0 个百分点,较 YOLO v8n 提升 2.3 个百分点,较 YOLO 11n 提升 0.7 个百分点,同时相较于 YOLO v12n 和 YOLO v13n 也分别提升 0.8、1.4 个百分点。在推理速度方面,YOLO 11 -

Quail 进一步提升至 184.8 f/s,较 YOLO v5n 提升约 3.5%,较 YOLO v8n 提升约 5.4%,较 YOLO 11n 提升约 6.3%,同时比 YOLO 12n 提升约 5.4%,比 YOLO 13n 提升约 10.9%,在所有参与对比的模型中表现最优。试验结果表明,YOLO 11 - Quail 模型在鹌鹑蛋裂纹识别任务中能够更好地兼顾检测精度与运算效率,满足实时检测需求。

3 设备端试验结果与分析

3.1 设备端试验环境

测试模型实际应用性能的嵌入式设备包括 1 台 Jetson Nano 开发板,搭载 64 位四核 ARM Cortex - A57 CPU,核心是 1 个 128 核的 NVIDIA Maxwell 架构 GPU,配备 4 GB LPDDR4 内存。运行环境包括 JetPack 4.6.1 操作系统,Ultralytics 8.3.9,PyTorch

1.7.0 深度学习框架,Python 3.8.20 编程语言。

3.2 模型部署

采用跨平台协同部署策略,模型训练已在 Windows 工作站完成,训练收敛后获得 pt 格式的模型权重,随后将其直接部署至 Jetson Nano 嵌入式开发板进行推理验证。在部署过程,未采用 ONNXRuntime 等模型加速框架,主要基于以下考虑:①模型转换与优化过程可能引入数值精度损失,影响裂纹识别准确率。②由于引入数字化结果矩阵判定跟踪算法,面向鹌鹑蛋在线检测场景的实际帧率需求较低,故在保证检测精度的前提下优先采用轻量化原生推理方案。

3.3 基于 Jetson Nano 的改进前后模型在线检测

在目标检测研究中,平均精度均值虽是评估模型性能的通用指标,但在工程场景中,系统可靠性更直接地取决于漏检率与误检率 2 项关键指标。为验证模型部署后性能,选取 72 枚鹌鹑蛋作为在线检测测试样本,其中完好鹌鹑蛋 36 枚,裂纹鹌鹑蛋 36 枚。通过试验对所提数字化结果矩阵判定跟踪算法在鹌鹑蛋裂纹检测任务中的有效性进行系统验证。

试验从漏检率、误检率和平均检测时延 3 方面进行评估。由表 4 可知,在漏检率与误检率方面,基线模型漏检数为 0 例,漏检率为 0,误检数为 5 例,误检率为 13.89%。相比之下,采用改进 YOLO 11-Quail 模型后,漏检数为 0 例,漏检率为 0,误检数 3 例,误检率降低至 8.33%,降低 5.56 个百分点。基

线模型平均检测时延为 77.30 ms,而改进后模型将其降低至 68.59 ms,处理速度提升约 11.3%,降低了系统的平均检测时延,且满足实际检测需求。

为将模型性能对标实际产线需求,结合具体产线设计参数进行分析。系统采用每 2 s 拍摄 1 幅图像(涵盖 9 枚蛋)的采集节拍,检测速度为 5 400 枚/h。因此,算法必须在 2s 内完成单图中全部 9 枚蛋的检测与判定,以满足生产的连续性要求。试验结果表明,部署于嵌入式平台的改进 YOLO 11-Quail 模型,单图平均检测时延仅为 68.59 ms,远低于 2 s 的产线节拍,可满足实时在线检测的工程需求。

4 结论

(1)搭建了三通道鹌鹑蛋检测装置,采集了多种形态鹌鹑蛋裂纹数据集,并通过随机调整饱和度、添加噪声、翻转、放缩、平移和背景分离方式对数据集进行扩充,避免因数据集样本量过少而导致模型过拟合,提高模型泛化性与鲁棒性。

(2)基于 YOLO 11n 网络,添加 C3k2_IDWC、SPPF_LSKA 和 EUCB-SCM 模块,并使用剪枝、知识蒸馏模型压缩技术,在降低模型参数量与计算量的同时,精确率、召回率、平均精度均值、帧率分别达到 95.1%、95.1%、94.6%与 184.8 f/s;与 Faster R-CNN、Deformable DETR、YOLO v5n、YOLO v8n、YOLO 12n、YOLO 13n 模型进行对比,展现出较高的检测精度与轻量化水平。

(3)改进模型在检测精度提升的基础上降低模型计算复杂度,并完成在 Jetson Nano 上实际部署。改进后模型较改进前裂纹鹌鹑蛋检测的误检率降低 5.56 个百分点,漏检率不变,处理速度提升约 11.3%,满足在线检测实时性需求,表明本文所提出的基于深度学习的轻量化鹌鹑蛋裂纹在线检测系统有效可行,具有较高应用价值。

表 4 模型改进前后在线检测精度

Tab.4 Online detection accuracy before and after model improvement

模型	漏检数	漏检率/%	误检数	误检率/%	平均检测时延/ms
YOLO 11n	0	0	5	13.89	77.30
YOLO 11-Quail	0	0	3	8.33	68.59

参 考 文 献

[1] 梅星星,谢文锋,韩占兵,等. 鹌鹑产业高质量发展:概况、态势、困境及建议[J]. 中国家禽,2025,47(4):96-104. MEI Xingxing, XIE Wenfeng, HAN Zhanbing, et al. High-quality development of quail industry: overview, trends, challenges and suggestions[J]. China Poultry, 2025, 47(4): 96-104. (in Chinese)

[2] 刘伟敏. 鹌鹑养殖现状及其机械化自控模式建设途径分析[J]. 河南农业,2021(14):55-56.

[3] 柴学文,贡继尚,许桥,等. 江西省蛋鹌鹑产业发展现状及对策[J]. 中国畜禽种业,2025,21(8):90-98. CHAI Xuewen, GONG Jishang, XU Qiao, et al. The current status and countermeasures of egg-type quail industry development in Jiangxi Province[J]. The Chinese Livestock and Poultry Breeding, 2025, 21(8): 90-98. (in Chinese)

[4] NARUSHIN G V, VOLKOVA A N, VETOKH N A, et al. ‘Eggology’ and mathematics of a quail egg: an innovative non-destructive technology for evaluating egg parameters in Japanese quail[J]. Food and Bioproducts Processing,2024,146:49-57.

[5] MASSAKI V N, TOFAEL A. Fast and non-destructive quail egg freshness assessment using a thermal camera and deep learning-based air cell detection algorithms for the revalidation of the expiration date of eggs[J]. Sensors,2022,22(20):7703.

[6] LIMA Y B, GRUZ-TIRADO J P, FERNANDES D B. Fast online estimation of quail eggs freshness using portable NIR spectrometer and machine learning[J]. Food Control,2022,131: 108418

[7] YILDIZ B I, ESKIOĞLU K, ÖZDEMİR D, et al. Predicting quail egg quality using machine learning algorithms[J]. Brazilian

Journal of Poultry Science, 2025, 27(1): 2024 – 2037.

[8] 胡建超. 基于 Android 的鸡蛋缺陷无损检测系统设计[D]. 武汉: 华中农业大学, 2022.
HU Jianchao. Design of egg defect nondestructive testing system based on Android [D]. Wuhan: Huazhong Agricultural University, 2022. (in Chinese)

[9] 汤文权, 陈灼廷, 王东桥, 等. 基于改进 YOLO v5 的皮蛋裂纹在线检测方法[J]. 农业机械学报, 2024, 55(2): 384 – 392.
TANG Wenquan, CHEN Zhuoting, WANG Dongqiao, et al. Crack detection method for preserved eggs based on improved YOLO v5 for online inspection[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(2): 384 – 392. (in Chinese)

[10] 赵祚喜, 魏洪飞, 黄渊, 等. 基于改进 YOLOv7 的破壳鸡蛋在线实时检测系统[J]. 农业工程学报, 2023, 39(20): 255 – 265.
ZHAO Zuoxi, WEI Hongfei, HUANG Yuan, et al. Online real-time detection system for cracked eggs using improved YOLOv7 [J]. Transactions of the CSAE, 2023, 39(20): 255 – 265. (in Chinese)

[11] KHANAM R, HUSSAIN M. YOLOv11: an overview of the key architectural enhancements[J]. arXiv Preprint arXiv:2410.17725, 2024.

[12] YU W, ZHOU P, YAN S, et al. Inceptionnext: when inception meets convnext [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 5672 – 5683.

[13] WAI K L, LAI-MAN P, UR A Y R. Large separable kernel attention: rethinking the large kernel attention design in CNN[J]. Expert Systems with Applications, 2024, 236: 121352.

[14] RAHMAN M M, MUNIR M, MARCULESCU R. Emcad: efficient multi-scale convolutional attention decoding for medical image segmentation [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 11769 – 11779.

[15] GAO T, ZHANG Y, ZHANG Z, et al. BHViT: binarized hybrid vision transformer[C] // Proceedings of the Computer Vision and Pattern Recognition Conference, 2025: 3563 – 3572.

[16] LEE J, PARK S, MO S, et al. Layer-adaptive sparsity for the magnitude-based pruning[J]. arXiv Preprint arXiv:2010.07611, 2020.

[17] 吴田, 刘佳, 梁书嘉, 等. 基于多尺度特征优化与轻量化剪枝的 YOLOv8 – seg 绝缘子缺陷检测方法[J/OL]. 南方电网技术, 1 – 14 [2025 – 11 – 22]. <https://link.cnki.net/urlid/44.1643.TK.20250826.0935.004>.
WU Tian, LIU Jia, LIANG Shujia, et al. YOLOv8 – seg insulator defect detection method based on multi-scale feature optimization and lightweight pruning[J/OL]. Southern Power System Technology, 1 – 14 [2025 – 11 – 22]. <https://link.cnki.net/urlid/44.1643.TK.20250826.0935.004>. (in Chinese)

[18] 吴明轩, 李远祿, 王键翔. 融合剪枝和知识蒸馏的水下生物检测[J]. 计算机系统应用, 2025, 34(7): 140 – 151.
WU Mingxuan, LI Yuanlu, WANG Jianxiang. Underwater organism detection incorporating pruning and knowledge distillation [J]. Computer Systems & Applications, 2025, 34(7): 140 – 151. (in Chinese)

[19] WANG Q, LIU L, YU W, et al. BCKD: block-correlation knowledge distillation[C] // 2023 IEEE International Conference on Image Processing (ICIP). IEEE, 2023: 3225 – 3229.

[20] SHU C, LIU Y, GAO J, et al. Channel-wise knowledge distillation for dense prediction[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 5311 – 5320.

[21] HINTON E G, VINYALS O, DEAN J. Distilling the knowledge in a neural network[J]. arXiv Preprint arXiv:1503.02531, 2015.

[22] 贾咪咪. 基于机器视觉的禽蛋外部缺陷检测[D]. 杭州: 浙江工业大学, 2017.
JIA Mimi. Detection of external defects in eggs based on machine vision[D]. Hangzhou: Zhejiang University of Technology, 2017. (in Chinese)