

基于 NAF - YOLO v8 的集成运动模糊图像复原的奶牛体况评分方法

李景文^{1,2} 李璐璐^{1,2} 秦立峰^{1,2} 宋怀波^{1,2}

(1. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100;

2. 农业农村部农业物联网重点实验室, 陕西杨凌 712100)

摘要:为解决因运动导致图像模糊难以有效进行奶牛体况评分的问题,改进噪声自适应流网络(Noise adaptive flow network, NAFNet)模型对奶牛运动模糊图像进行复原,提出集成运动模糊图像复原的奶牛体况评分方法 NAF - YOLO v8。将 NAFNet 中通道注意力(Simple channel attention, SCA)模块更换为通道先验卷积注意力(Channel prior convolutional attention, CPCA)模块,在通道和空间维度上动态分配注意力权重,完成特征细化与增强,生成高质量奶牛体况特征图;将反向残差移动模块(Inverted residual mobile block, iRMB)嵌入 YOLO v8 模型 C2f 模块中,有助于捕获奶牛体况特征在空间上的联动关系,且保持了模型轻量级;将可分离大核注意力(Large separable kernel attention, LSKA)模块嵌入到空间金字塔池化融合(Spatial pyramid pooling fusion, SPPF)模块中,增加有效感受野,增强模型对全局特征的提取能力,实现奶牛体况评分。实验结果显示,NAF - YOLO v8 在奶牛运动模糊测试集上精确率、召回率和平均精度分别为 80.7%、75.3% 和 80.1%,相较于未进行图像复原模型,分别提高 8.2、4.7、8.0 个百分点,表明提出的 NAF - YOLO v8 方法有效减小了运动模糊对体况评分准确性的影响,降低了误检和漏检概率,提高了检测精度,为奶牛智能化管理提供了重要支持。

关键词: 奶牛; 体况评分; 运动模糊; 图像复原; 注意力机制

中图分类号: TP391.4

文献标识码: A

文章编号: 1000-1298(2026)08-0256-12

OSID:



Method for Dairy Cow Body Condition Scoring Based on Integrated Motion-blurred Image Restoration Using NAF - YOLO v8

LI Jingwen^{1,2} LI Lulu^{1,2} QIN Lifeng^{1,2} SONG Huaibo^{1,2}

(1. College of Mechanical and Electronic Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

2. Key Laboratory of Agricultural Internet of Things, Ministry of Agriculture and Rural Affairs, Yangling, Shaanxi 712100, China)

Abstract: Aiming to address the challenge of accurately assessing the body condition of dairy cows in environments with motion blur, an integrated method for body condition scoring that incorporated an improved noise adaptive flow network model was proposed for the restoration of motion-blurred images. The simple channel attention module in NAFNet was replaced with a channel prior convolutional attention module, which dynamically allocated attention weights in both channel and spatial dimensions, refining and enhancing features to generate high-quality body condition feature maps. Additionally, the inverted residual mobile block module was embedded within the C2f module of the YOLO v8 model, maintaining the model's lightweight nature while aiding in the extraction of spatial relationships among body condition features. Furthermore, the large separable kernel attention module was integrated into the spatial pyramid pooling fusion (SPPF) module to achieve a larger effective receptive field, enhancing the model's ability to extract global features for body condition scoring. It can effectively reduce the probability of false detection and missing detection, and improve the detection accuracy. The proposed NAF - YOLO v8 method achieved precision, recall, and mean average precision of 80.7%, 75.3%, and 80.1%, respectively, on the motion-blurred test set, representing improvements of 8.2, 4.7, and 8.0 percentage

收稿日期: 2024-12-29 修回日期: 2025-03-07

基金项目: 国家重点研发计划项目(2023YFD1301800)

作者简介: 李景文(2000—),女,硕士生,主要从事图像处理研究,E-mail: lijingwen@nwafu.edu.cn

通信作者: 秦立峰(1981—),男,副教授,博士,主要从事图像处理与模式识别研究,E-mail: fuser@nwafu.edu.cn

points compared with models without image restoration. This integrated approach effectively reduced the impact of motion blur on the accuracy of body condition scoring, providing significant support for the intelligent management of dairy cattle.

Key words: dairy cow; body condition score; motion blur; image restoration; attention mechanism

0 引言

奶牛体况与产奶效率、饲料利用率、繁殖表现及健康状态关联紧密,在我国奶牛规模化和集约化养殖迅速发展的背景下,奶牛体况的自动化监测已成为智能化养殖领域的研究热点^[1-4]。通过在挤奶厅入口等奶牛行进通道上架设摄像头,获取奶牛视频图像,可实现自动化奶牛体况评分。然而,在养殖场,由于受到养殖人员驱赶,导致图像发生运动模糊^[5],出现拖影变形、纹理细节丢失、骨骼特征不清晰等问题,严重影响对奶牛体况的精准评分^[6-9]。因此,实现对奶牛运动模糊图像的高质量复原,提升目标检测网络对奶牛体况准确评估能力是亟需解决的技术问题。

在奶牛体况自动评分方法上,深度学习方法取得了显著效果。HUANG 等^[10]通过改进 SSD 模型检测奶牛尾部的体况特征,进行奶牛体况评分;采用该方法对图像质量与环境光照条件要求较高,且无法较好解决奶牛运动模糊问题。ÇEVİK^[11]使用 RCNN 分割出奶牛尾部区域,再采用基于 AlexNet 的图像分类模型得到体况评分结果;然而由于受到奶牛姿势、遮挡以及图像质量的影响,评分稳定性较低。ZHAO 等^[12]提出了一种基于点云和凸壳特征的 EfficientNet 体况评分模型,通过构建三维结构特征图实现对特征的有效提取,虽精确率达到 91.21%,但点云特征计算成本高,且评分准确率会因点云重建精确性的降低而下降。

上述深度学习模型虽能在一定条件下较准确地捕获奶牛体况特征,但均未能解决实际场景下较普遍出现的奶牛图像运动模糊问题。图像运动模糊一般被认为是清晰图像依据模糊核进行卷积操作后得到运动模糊图像的过程,而对应的逆过程被称为运动模糊图像复原^[13]。由于在实际应用中对图像内各像素点的模糊核估算是确定的,传统去模糊方法的泛用性不高、复原效果不稳定。伴随着神经网络与深度学习技术的不断发展,其被广泛应用于图像复原领域。KUPYN 等^[14]采用生成对抗网络 (GAN) 架构实现高质量的图像复原。Deblurgan 通过引入生成器和判别器的对抗训练机制,将 GAN 应用于运动模糊图像的恢复,利用 U-Net 结构有效捕捉多尺度特征,从而生成清晰的图像。其损失函数

结合了感知损失和对抗损失,使得生成的图像在视觉上更接近真实图像,并显著提高了去模糊效果。在此基础上,Deblurganv2^[15]进一步优化了网络结构,采用了更深层次的网络和多尺度特征提取策略,提升了生成图像的质量和速度。与 Deblurgan 系列模型依赖对抗训练和多尺度特征提取不同,Restormer^[16]基于 Transformer 架构采用了一种基于多头注意力机制和前馈网络的新型设计,以实现更高效的全局特征建模能力。NAFNet^[17]结合轻量化的通道注意力机制,提升了复原效果,为图像复原任务提供了更加高效的解决方案。然而,在处理奶牛运动模糊图像时,轻量化的注意力模块难以有效捕捉图像局部高频与低频特征之间的关联,导致复原结果在模糊严重的区域存在显著的细节缺失或模糊残留现象,影响奶牛体况检测精度。

针对上述问题,本文提出一种集成运动模糊图像复原的奶牛体况评分方法。针对奶牛运动模糊图像存在图像细节可视性差,现有模型特征提取能力不足问题,使用改进 NAFNet 模型进行运动模糊图像复原,修复图像骨骼肌肉纹理细节,恢复体况特征,以提高待检测体况图像质量,提升模型对模糊图像的特征提取能力。改进 YOLO v8 网络,将反向残差移动模块 (iRMB) 嵌入 YOLO v8s 模型的 C2f 模块中,将可分离大核注意力模块 (LSKA) 嵌入空间金字塔池化融合模块 (SPPF) 中,以实现更大的有效感受野,增强模型对全局特征的提取能力,完成奶牛体况评分,降低误检和漏检概率,提高检测精度。

1 数据集制备与实验平台搭建

1.1 数据集制备

1.1.1 数据来源

数据采集时间为 2021 年 12 月—2022 年 3 月与 2023 年 7—9 月,分别采集于宁夏回族自治区吴忠市吴忠牛乳 (宁夏奶牛) 标准化核心生产基地与陕西省咸阳市杨陵区源泰良种奶牛繁育中心 (图 1)。




图 1 挤奶厅监控场景
Fig. 1 Milking parlor monitoring scenario

实验对象为“荷斯坦”奶牛,共 400 头。所有实验视频均采集自奶牛养殖场搭建的远程监控设备。摄像机分别安装在挤奶厅入口约 2.1 m 和 2.3 m 高处,摄像机斜向下俯视拍摄,能够拍摄到奶牛整个背部区域与臀部区域。摄像头为 DS-2CD3T46(F)(D) WDV3-I3 型,分辨率为 2 560 像素 × 1 440 像素。




图 2 奶牛体况评分样本示例
Fig.2 Example of BCS for dairy cow

共构建 2 个数据集:①奶牛体况评分数据集,用于奶牛自然状态下的体况评分实验,共 4 500 幅图像,按比例 6:2:2 分为训练集(2 700 幅)、验证集(900 幅)、测试集(900 幅)。源泰良种奶牛繁育中心与吴忠牛乳(宁夏奶牛)标准化核心生产基地所采数据比例为 6:4。其中各体况评分(BCS 值)分布如下:BCS = 2.0 为 135 幅;BCS = 2.5 为 372 幅;BCS = 3.0 为 1 196 幅;BCS = 3.5 为 1 661 幅;BCS = 4.0 为 896 幅;BCS = 5.0 为 240 幅。②奶牛运动模糊图像复原数据集,包括 4 400 对奶牛清晰图像和运动模糊图像,用于奶牛运动模糊状态下的体况评分实验。其构建方法为,选取 104 段时长为 2 ~ 3 min 的视频,利用 FFmpeg 工具提取奶牛清晰图像共 4 400 幅;为更好地模拟实际的运动模糊情况,通过创建和旋转一个特定的核矩阵生成任意角度的运动模糊效果。首先创建 1 个 $d \times d$ 的模糊核矩阵 K ,其主对角线元素为 $1/d$,其他元素为 0,再利用旋转矩阵 $R(\theta)$,将 K 旋转角度 θ ,以模拟实际环境中模糊核的不确定性。计算式为

$$K' = R(\theta)KR(\theta)^T \tag{1}$$

其中

$$R(\theta) = \begin{bmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{bmatrix} \tag{2}$$

通过设置不同模糊核 K 大小和方向 θ ,生成 4 400 幅对应的运动模糊图像,与所选的 4 400 幅清晰图像一起构成数据集,其中 4 000 对为训练集,其余 400 对为测试集。

1.2 实验平台

所有实验均在 Windows 10 操作系统下进行,处理器型号为 AMD Ryzen 9 5900 12-Core Processor@3.20 GHz,显卡型号为 NVIDIA GeForce RTX 4060ti。深度学习框架为 PyTorch 1.9,编程环境为 PyCharm,编程语言为 Python 3.8。目标检测实验中,迭代次

共采集视频约 500 段,帧率为 25 f/s,视频时长为 40 ~ 60 min。视频场景如图 1 所示。

1.1.2 数据集构建

针对奶牛体况评分的数据标注,使用国内常用的 5 分法,并参照文献[18]制定了评分标准,奶牛体况评分类别(Body condition score, BCS)示例如图 2 所示。

数(Epoch)设置为 150,采取优化算法 SGD;训练批量大小(Batchsize)设置为 16;去运动模糊实验中,训练批量大小设置为 8。

2 研究方法

2.1 奶牛目标检测

2.1.1 YOLO v8s 模型结构

采用 YOLO v8s 算法作为奶牛体况评分任务中的基础检测模型。YOLO v8s 算法回归损失函数采用了 CIOU Loss 与 DFL(Distribution focal loss)的组合,并引入解耦合头(Decoupled head)、任务对齐分配(Task-aligned assigner)等策略^[19-22]。

YOLO v8s 模型结构主要分为 3 个部分:主干网络 Backbone 主要由 BConv 和 C2f 组成,用于提取图像特征;颈部网络 Neck 由路径聚合特征金字塔网络(PAFPN)结构组成,通过引入自下而上的路径,有效地整合不同层次的特征,促进底层信息向高层传递,用于融合多尺度特征信息;预测网络 Prediction 通过 CBS(Cross stage binary)结构调整 P3、P4、P5 3 个不同尺度的特征图像通道数,最后用于预测置信度、类别和锚框。

2.1.2 C2f 模块和骨干网络改进

奶牛重要体况特征(如肋骨、骨盆区域、髋关节等)分布在身体不同部位,在体表图像中彼此距离较远,难以建立有效关联。同时,利用 YOLO v8s 主干网络进行的多次奶牛检测实验发现,奶牛体形会因不同的姿势和角度而产生形变,使关键体况评分区域的可见性和形态发生变化,严重影响特征提取的准确性。

针对此问题,将 iRMB 模块嵌入 YOLO v8s 的 Backbone 中的 C2f 模块。iRMB 是一种混合网络模块,其结合了深度可分离卷积(DW-Conv)和自注

意力机制。首先, iRMB 模块采用自注意力机制, 能够在特征提取过程中关注整个输入空间。这意味着模型可以捕捉到远距离特征之间的关系, 无论这些特征在图像中的位置如何。这种全局视角使得模型能捕捉奶牛不同体况关键部位间相互联系, 从而解除它们在图像中的空间距离限制。其次, iRMB 模块通过深度可分离卷积捕捉局部特征。DW-Conv 能够有效提取图像中奶牛的肌肉线条、脂肪分布等局部细节特征, 这对体况的准确评估至关重要。再者, iRMB 模块通过全局特征提取机制, 能够更好地应对奶牛的姿势和角度等形态变化, 捕捉到关键特征的关系, 从而提高检测准确性。此外, iRMB 模块通过更强的特征关联能力, 能够在一定程度上过滤掉背景噪声的影响, 减少复杂背景和其他奶牛的干扰。同时, 其能提高计算效率, 实现对计算资源的有效利用和高准确率, 适用于移动设备上的密集检测任务^[20]。

iRMB 模块的设计来源于元移动块 (Meta-mobile block, MMB) 的灵活应用。如图 3a (λ 表示通道数扩大倍数, 使模型在更高维度的特征空间中对信息进行更丰富地表达) 所示, MMB 模块将卷积、自注意力等操作集成到 1 个统一框架中, 通过不同的扩展比率和高效操作符实现模块化设计, 可根据需要调整容量, 无需重新设计整个网络, 提高了模型的效率和灵活性。




图 3 iRMB 模块流程图

Fig. 3 iRMB module flowchart

设输入图像 $X (\in \mathbf{R}^{C \times H \times W})$, 其中 C 表示通道数, H 表示高度, W 表示宽度。MMB 首先使用输出/输入比为 λ 的 MLPe 扩展通道维数, 即

$$X_e = \text{MLPe}(X) \quad (\in \mathbf{R}^{\lambda C \times H \times W}) \quad (3)$$

高效操作符 F 将进一步增强图像特征, 即

$$X_f = F(X_e) \quad (\in \mathbf{R}^{\lambda C \times H \times W}) \quad (4)$$

使用 1 个反向输入/输出比等于 λ 的收缩 MLPs 收缩通道尺寸, 即

$$X_s = \text{MLPs}(X_f) \quad (\in \mathbf{R}^{C \times H \times W}) \quad (5)$$

使用残差连接获得最终的输出, 即

$$Y = X + X_s \quad (\in \mathbf{R}^{C \times H \times W}) \quad (6)$$

基于 MMB 反向残差移动块 (iRMB) 如图 3b (查询向量 (Query, Q) 表示当前需要检索的信息或特征; 键向量 (Key, K) 对应于输入中各位置的特征标识, 用于与查询向量计算相似度分数; 值向量 (Value, V) 则包含需要加权整合的信息) 所示, 1×1 卷积用于通道数的压缩和扩张, 以此优化计算效率。DW-Conv 用于捕捉空间特征, 而注意力机制则用于捕获特征间的全局依赖关系。对于高效操作符 F , 为节约计算复杂度, 使用级联的 EW-MHSA 和 DW-Conv 卷积, 即

$$F(\cdot) = \text{Conv}(\text{MHSA}(\cdot)) \quad (7)$$

将 iRMB 嵌入 C2f 模块中, 形成 C2f_iRMB 模块。相较于 C2f 模块, C2f_iRMB 具有更强的图像特征提取能力, 可对全局特征进行重点提取, 帮助检测模型提取出奶牛体况特征在空间上的联动关系, 有效缓解奶牛体表特征空间上差异的影响, 从而保障更高的检测精度。使用 C2f_iRMB 模块替换 Backbone 中 C2f 模块, 改进的骨干网络兼顾了全局和局部特征提取, 从而提升了网络对复杂场景下奶牛体况检测效果。

2.1.3 空间金字塔池化改进

YOLO v8s 中采用的 SPPF 结构可自适应地融合不同尺度的特征信息。通过实验发现, 在奶牛存在部分遮挡情况时, SPPF 模块会丢失部分全局信息, 影响模型性能。虽通过添加自注意力机制或者采用较大卷积核可实现输入图像的长程依赖性, 如大核注意力 (Large kernel attention, LKA)^[23] 采用了具有深度卷积的膨胀卷积 (DW-D-Conv) 获取更大的有效感受野, 但这导致计算量大幅增加。

改进的可分离版本 LSKA, 通过标准深度卷积 (DW-Conv) 捕获图像的局部上下文信息, 使用具有大感受野内核的深度膨胀卷积 (DW-D-Conv) 模拟长程依赖性。将深度卷积层 2D 卷积核分解为级联的水平和垂直 1D 内核, 降低了计算复杂度和内存需求, 同时保持了高效的图像处理能力。这种分解方式可直接使用注意力模块中大内核深度卷积, 具备超大内核的可扩展性。LSKA 结构如图 4b 所示。

为此, 将 LSKA 嵌入到 SPPF 中, 形成 SPPF_LSKA 模块, 如图 5 所示。将 SPPF 最终融合后的特征图通过级联具有水平 1D 和垂直 1D 内核的深度卷积和深度膨胀卷积捕捉上下文信息和实现长程依赖性, 然后将输出馈送到 1×1 卷积以推断注意力




图 4 LSKA 模块流程图
Fig.4 LSKA module flowchart

图,最后将输出注意力图乘以输入特征以进行自适应特征细化,提升了特征表达和感知能力;得益于水平 1D 和垂直 1D 内核的设计,模型计算量并不会增加。

原骨干网络的 C2f 模块被改进的 C2f_iRMB 模块取代,原网络中的空间金字塔池模块被 SPPF_LSKA 模块取代。改进的 YOLO v8 模型结构如图 6 所示。

2.1.4 损失函数

在奶牛体况评分任务中,由于样本不平衡,模型对困难样本的学习不足。为解决此问题,引入了




图 5 改进 SPPF (SPPF_LSKA) 模块
Fig.5 Improved SPPF(SPPF_LSKA) module

Slide Loss(图 7)。Slide Loss 通过设定基于预测框和真实框之间的 IoU 阈值,辅助区分简单和困难样本。IoU 值位于阈值边界附近的为困难样本,Slide Loss 使它们对模型的损失贡献更大,其权重函数为

$$f(x) = \begin{cases} 1 & (x \leq \mu - 0.1) \\ e^{1-\mu} & (\mu - 0.1 < x < \mu) \\ e^{1-x} & (x \geq \mu) \end{cases} \quad (8)$$

Slide Loss 能够基于阈值对样本损失进行自适应加权,对边界附近的样本赋予更高的权重,增加模型对困难样本的关注,从而提高对这些样本的分类准确性^[24]。

2.1.5 参数设置与评价指标

模型输入尺寸为 640 像素 × 640 像素,初始学习率设为 0.1,权重衰减系数为 0.000 5,共训练 150




图 6 改进 YOLO v8 网络结构
Fig.6 Improved YOLO v8 network structure




图 7 Slide Loss 示意图

Fig. 7 Slide loss diagram

轮次。采用精确率 (Precision, P)、召回率 (Recall, R)、平均精度 (Average precision, AP)、平均精度均值 (mean Average Precision, mAP) 和参数量等指标进行目标检测评价,设定交并比 (Intersection over union, IoU) 大于等于 0.5 为对奶牛体况的正确检测。

2.2 奶牛运动模糊图像复原

2.2.1 改进 NAFNet 模型

NAFNet 是基于多尺度 Encoder - Decoder 网络的图像去模糊方法^[25-26]。其通过 U 型编码-解码器网络输出多尺度特征图,通过将扩张卷积引入编码器和解码器中的 NAFNet 模块,扩大了多尺度特征图的感受野,并结合注意力机制,丰富了各尺度特征间的交互信息,提高了图像去模糊性能。NAFNet 是基于 U-Net 架构,其内部设计如图 8a 所示。




图 8 NAFNet 模型改进

Fig. 8 Improved NAFNet model

SCA) 是一种用于增强卷积神经网络性能的机制,主要通过学习通道间的依赖关系优化特征表示。其中,SimpleGate 将特征图在通道维度分为 2 部分 (大小相同),而后逐像素相乘,如图 9 所示。




图 9 SimpleGate 模块原理示意图

Fig. 9 SimpleGate module schematic

SCA 通过“压缩”和“激励”2 个步骤调整通道权重,从而使网络能够更好地关注重要的特征通道。在压缩阶段,SCA 通过全局平均池化 (Global average pooling, GAP) 操作将每个通道的特征图压缩为 1 个单一数值,表示该通道的全局特征,对每个通道重要性进行初步评估。在激励阶段,SCA 使用 1 个全连接层学习通道间的关系,并生成通道权重。最后,SCA 将生成的通道权重应用于原始特征图,以调整每个通道的特征表示。

SCA 通过全局平均池化聚合通道信息,压缩图像的空间维度,只保留每个通道的全局统计信息。而在图像高质量复原任务中,涉及对图像中不同频率特征的处理。通道间的交互有助于融合高频和低频特征。通过通道交互机制,模型可以动态分配注意力。如果忽略通道间的信息流动,图像易出现颜色边缘不对齐或纹理模糊。

为此,将 SCA 模块更换为 CPCA 模块,在通道和空间维度上动态分配注意力权重,如图 10 所示。首先通过平均池化和最大池化提取特征图的空间信息,聚合成通道注意力图;通过输入特征和通道注意力图的元素相乘获得通道先验,随后与多尺度深度可分离卷积模块相乘生成空间注意力图;使用卷积模块对其进行通道混合,结果与通道先验相乘,获得新的特征图,完成特征细化与增强^[27]。改进 NAFNet 模型如图 8b 所示,实现运动模糊图像复原。

2.2.2 评价指标

模型输入尺寸为 1 080 像素 × 1 080 像素,采用峰值信噪比 (Peak signal to noise ratio, PSNR)、结构相似度 (Structure similarity index measure, SSIM) 评估图像质量,其中 PSNR 更偏重于量化误差,SSIM 更关注于视觉感知质量。

2.3 集成运动模糊图像复原的奶牛体况评分方法

为提高数据的代表性和减少冗余,对监控视频每 25 帧采集 1 帧进行保存;针对运动模糊图像,采用改进的噪声自适应流网络 (NAFNet) 算法进行图

图 8a 中,注意力模块 (Simple channel attention,




图 10 CPCA 模块原理示意图

Fig. 10 CPCA module schematic

像复原,然后利用改进的 YOLO v8 模型对奶牛进行
体况评分,从而提高奶牛体况评分精度。NAF -

YOLO v8 方法流程如图 11 所示,图中 n 表示级联的
残差连接的卷积模块数量。




图 11 基于 NAF-YOLO v8 的奶牛评分方法流程图

Fig. 11 Flowchart of cow scoring method based on NAF-YOLO v8

3 结果与分析

3.1 奶牛体况评分区域检测

3.1.1 对检测模型改进方法的消融实验

为进一步验证所使用改进方法的有效性,以及融合后模型在奶牛检测性能上的提升效果,对改进方法进行消融实验,分 5 种情况训练网络,分别为采用原 C2f 和 SPPF、只改进 C2f 和 SPPF 中的 1 个、同时改进 C2f 和 SPPF 以及同时采用 3 个改进,验证 5 种情况下网络检测性能,结果如表 1 所示。

表 1 模型消融实验结果					
Tab.1 Results of model ablation experiment %					
C2f_iRMB	SPPF_LSKA	Slide Loss	精确率	召回率	mAP
×	×	×	92.2	89.2	90.6
√	×	×	93.2	89.7	92.3
×	√	×	93.8	89.1	93.7
√	√	×	95.2	89.8	93.8
√	√	√	95.3	90.1	94.1

注:√表示采用此模块,×表示不采用此模块。

由表 1 可看出,采用 C2f_iRMB 模块改进骨干网络,相较原始 YOLO v8s 模型,精确率提升 1.0 个百分点,召回率提升 0.5 个百分点,平均精度均值提升 1.7 个百分点。采用 SPPF_LSKA 模块,相

比于原始 YOLO v8s 模型,精确率提升 1.6 个百分点,mAP 提升 3.1 个百分点。采用所有模块的改进模型,相较原始 YOLO v8s 模型,精确率提升 3.1 个百分点,召回率提升 0.2 个百分点,mAP 提升 3.5 个百分点。结果表明,改进空间金字塔池化模块(SPPF_LSKA)与骨干网络(C2f_iRMB)均在不增加模型参数量情况下,对提升目标检测性能起到了重要作用。同时,相较于仅采用改进空间金字塔池化模块(SPPF_LSKA)与骨干网络(C2f_iRMB)的模型,精确率提升 0.1 个百分点,召回率提升 0.3 个百分点,mAP 提升 0.3 个百分点,这表明 Slide Loss 进一步提高了模型整体的分类准确性,提升了整体检测效果。

使用上述优化算法与原始 YOLO v8s 模型,针对奶牛图像实例进行了测试,结果如图 12 所示。从图像 1 可见,由于遮挡导致奶牛部分体况特征丢失,YOLO v8s 模型出现漏检。图像 2 中,YOLO v8s 将评分为 3.0 的奶牛误检为 3.5。而改进模型能够正确对奶牛体况进行评价,这得益于加入反向残差移动块(iRMB),通过捕捉和利用长距离依赖将 LSKA 注意力机制应用于 SPPF,调整每个特征图上的空间权重和通道权重,使模型关注于与目标相关的特征,从而提高检测精度,有效地降低误检和漏检概率。



图 12 算法优化前后奶牛体况检测对比

Fig. 12 Comparison of cow body condition detection before and after algorithm optimization

尽管在大面积遮挡的极端情况下,体况评分的准确性可能受到影响,但给出评分仍具有重要意义。这是因为,即使模型无法完全准确可信地评分,但能够检测到奶牛并给出可依据条件下尽可能准确的评分,对奶牛群体体况的总体评估是有价值的,为人工核查和管理提供了重要参考。

3.1.2 不同模型对奶牛体况评分区域检测

为验证改进 YOLO v8 模型的检测性能,采用构建的奶牛体况评分数据集分别训练 YOLO v5l 模型、YOLOX - m 模型、YOLO v8s 模型,并在测试集数据上进行模型性能评估,结果如表 2 所示。

表 2 不同检测模型对奶牛体况评分区域的检测结果

Tab.2 Detection results of different detection models on body condition scoring area of dairy cows

模型	精确率/%	召回率/%	平均精度/%	参数量
YOLO v5l	90.5	89.8	87.6	4.650×10^7
YOLOX - m	82.3	90.4	77.8	2.510×10^7
YOLO v8s	92.2	89.2	90.6	1.253×10^7
改进的 YOLO v8	95.3	90.1	94.1	1.111×10^7

由表 2 可以看出,相较于 YOLO v5l、原 YOLO v8s,改进 YOLO v8 模型精确率、召回率和平均精度




图 13 类激活图的可视化结果

Fig. 13 Visualization of Grad - CAM

均有提高,较原始 YOLO v8s 分别提升 3.1、0.9、3.5 个百分点;较 YOLO v5l 分别提升 4.8、0.3、6.5 个百分点。与 YOLOX - m 相比,精确率与平均精度分别提高 13.0、16.3 个百分点。由表 2 可知,改进模型的参数量最低,较 YOLOX - m 减少 1.399×10^7 ,较 YOLO v8s 减少 1.420×10^6 ,仅相当于 YOLO v5l 的 23.9%。这是由于本文模型 C2f_iRMB 模块采用级联的 EW - MHSA 和 DW - Conv 卷积,在兼顾特征提取的同时,减少了模型参数量,降低了模型复杂度,表明改进模块的有效性。

综上所述,本文模型具有最优精确率、平均精度和模型参数量。由此可见,改进模型在对奶牛体况进行精确评分方面更具优越性。

3.1.3 奶牛体况特征提取可视化

为更直观地对比不同方法特征提取效果,采用类激活图 (Grad - CAM) 进行可视化^[28-29],如图 13 所示。图中越接近红色的区域表示模型的关注度越高,蓝色区域表示模型关注度低。由图 13 可见,YOLO v5l 模型、YOLOX - m 模型多关注奶牛的脊椎骨区域,外轮廓特征在体况特征中占比大,原始 YOLO v8s 模型对于体况特征的提取散乱,既无法形成空间上关联,还出现对非奶牛体况特征区域的关注。对比发现,本文方法对奶牛体况特征的关注更全面、清晰,与真实标签最接近。这些可视化结果也与表 2 结果相吻合,进一步证明了本文提出的体况评分方法可靠性。

3.2 奶牛运动模糊图像复原实验

为验证改进 NAFNet 模型的图像去模糊性能,采用构建的图像去模糊训练集数据对 Deblurgan 模型、Deblurganv2 模型、Restormer 模型、原 NAFNet 模型以及改进 NAFNet 模型进行训练,并利用测试集数据对模型进行性能评估,结果如表 3 所示。

表 3 图像质量对比实验

指标	模糊 图像	模型				
		Deblurgan	Deblurganv2	Restormer	NAFNet	改进 NAFNet
PSNR/dB	16.55	17.02	17.23	17.30	17.54	19.21
SSIM	0.391 5	0.401 2	0.432 7	0.475 2	0.572 0	0.675 8

由表 3 可以看出,改进 NAFNet 生成的图像的 PSNR 相比原始运动模糊图像提高 2.66 dB,SSIM 提高 0.284 3,相较于 Deblurgan、Deblurganv2、




图 14 运动模糊图像复原效果可视化

Fig. 14 Visualization of motion blur image restoration effect

由图 14 可知,由于运动模糊,该奶牛体况特征在骶骨韧带处的部分信息丢失。像素在空间上的移动,使得细小的纹理、边缘信息混合和模糊,同时使特征和背景之间的区分度减弱,造成特征提取不准确。另外摄像机本身的噪声以及受光照影响的环境噪声,都会叠加运动模糊为奶牛体况特征提取带来更严重干扰。相比 Deblurgan、Deblurganv2、Restormer 以及原始 NAFNet 模型,改进 NAFNet 模型对边缘信息有更好的恢复效果,奶牛的骨骼轮廓信息更加显性,其次对于图像噪点,也有更强的去除效果,能够有效地减少对特征提取的影响。这是由于改进 NAFNet 模型中 CPCA 模块通过动态调整通道和空间上的注意力权重,能自适应地提取感兴趣区域,并优化特征提取,完成关键特征区域的有效特征复原。

3.3 集成运动模糊图像复原的奶牛体况评分实验

为验证图像去模糊算法在奶牛体况评分任务上的检测性能,在奶牛运动模糊测试集上进行测试,并将不同组合模型进行对比,结果如表 4 所示。

由表 4 可看出,相较 YOLO v8-I,Deblurgan + YOLO v8-I、Deblurganv2 + YOLO v8-I、Restormer + YOLO v8-I 以及 NAFNet + YOLO v8-I,本文 NAF-YOLO v8 模型精确率和平均精度均有提高,其中精确率为 80.7%,分别提升 8.2、7.2、6.6、3.4、2.0 个百分点;平均精度为 80.1%,分别提升 8.0、6.9、5.4、3.9、1.8 个百分点。因此,本文 NAF-YOLO v8 方法综合性能更好,能够在奶牛运动模糊时的体况

Restormer 以及原 NAFNet 模型的 PSNR 分别提高 2.19、1.98、1.91、1.67 dB,SSIM 分别提高 0.284 3、0.274 6、0.200 6 和 0.103 8,表明改进 NAFNet 在去噪和还原细节方面均表现出色,去噪后的图像质量明显优于原始图像,有效支撑后续奶牛体况评分任务的准确性。为验证 NAFNet 对运动模糊图像的复原效果,将输入模糊图像、Deblurgan、Deblurganv2、Restormer、原始 NAFNet 以及改进后 NAFNet 模型生成的高质量图像进行可视化对比分析,如图 14 所示。

评分中表现出更高的精度和可靠性。

表 4 图像去模糊前后奶牛体况评分结果对比

Tab.4 Comparison of body condition scores of cows before and after image deblurring				%
去模糊方法	模型	精确率	召回率	平均精度
无	YOLO v8-I	72.5	70.6	72.1
Deblurgan	Deblurgan + YOLO v8-I	73.5	70.9	73.2
Deblurganv2	Deblurganv2 + YOLO v8-I	74.1	75.2	74.7
Restormer	Restormer + YOLO v8-I	77.3	74.5	76.2
NAFNet	NAFNet + YOLO v8-I	78.7	80.1	78.3
改进的 NAFNet	NAF-YOLO v8	80.7	75.3	80.1

为验证 NAF-YOLO v8 模型对奶牛不同 BCS 类别的检测效果,在奶牛运动模型数据集上进行测试,结果如表 5 所示。

表 5 不同体况评分类别奶牛体况评分结果

Tab.5 Body condition scores of cows in different BCS categories		
体况评分类别	YOLO v8s/%	NAF-YOLO v8/%
2.0	80.0	81.8
2.5	83.3	90.3
3.0	71.0	81.9
3.5	67.6	77.9
4.0	77.6	81.6
5.0	76.5	82.3

由表 5 可看出,相较于原始 YOLO v8s,本文模型在 2.0、2.5、3.0、3.5、4.0、5.0 的 BCS 类别上精确

率均有提高,分别提升 1.8、7.0、10.9、10.3、4.0、5.8 个百分点。同时,模型在不同 BCS 类别上的检测性能存在差异,3.0、3.5 类别上模型检测精度提升幅度较大。这一现象可能与这 2 个 BCS 类别的特征更加复杂有关,而且运动模糊进一步增加了这些类别中体况特征的提取难度。而 NAF-YOLO v8 检测的准确性表现出其在复杂特征提取和运动模糊补偿方面的优势。

为验证图像运动模糊复原在奶牛体况评分任务上的实际应用效果,针对奶牛图像实例进行测试,结果如图 15 所示。CPCA 模块结合通道和空间维度的注意力

机制,能够在不同层次上关注重要特征,其动态空间注意力为每个特征通道提供了独立的空间权重,使得模型能够更灵活地处理不同通道间的空间变化,从而增强了重要特征,抑制了无关特征。这种细粒度的特征提取和增强,使得改进 NAFNet 模型在处理运动模糊图像时能够更好地恢复奶牛的轮廓和纹理信息,从而在奶牛体况评分任务中的表现更为出色。对比其他运动模糊复原结果使奶牛体况评分出现的漏检(图 15a~15c 体况评分 2.0)和误检(图 15a~15c 体况评分 3.5、图 15d、15e 体况评分 2.0)情况,改进 NAFNet 模型在奶牛体况评分任务中的表现更优。



图 15 集成运动模糊图像复原的奶牛体况评分结果

Fig. 15 Body condition scoring result with integrated motion blur image restoration for dairy cow

4 讨论

基于图像的运动模糊复原模型对奶牛体况图像进行处理。尽管基于视频的去运动模糊算法在一些应用中具有优势,但未采用,主要原因为

(1)模型机理差异。基于视频的去运动模糊算法通常依赖于时空特征,从视频的前后帧中提取相关信息,以预测模糊帧的清晰内容。这类方法的核心思想与基于单帧图像的运动模糊复原模型有本质上的差异,本研究专注于单帧图像中运动模糊特征的提取与复原,以直接应用于奶牛体况评分任务。而采用基于视频的算法需要依赖视频的帧间关联特性,这与奶牛体况评分流程的需求并不匹配。

(2)实践应用中局限性。尽管基于视频的去运动模糊算法在一些特定场景中表现优异,但其在奶牛体况评分场景中并不适用,具体原因有 2 点:①数据量及成本问题。基于视频的去运动模糊方法对计算效率和数据存储有较高要求,然而,在实际应用中,奶牛体况评分的处理环境和资源有限,采用此类算法将显著增加存储和计算成本,难以满足实际生产条件下的需求。②视频特性与场景不匹配。奶牛体况评分视频拍摄于挤奶厅内,每头奶牛有效视频通常较短(1~3 s),且奶牛在运动模糊过程中缺乏

有效的清晰帧作为参考。这导致视频的帧间关联性无法有效发挥作用。基于视频的去模糊方法在这种情况下只能依赖特征提取对模糊帧进行补全,难以发挥其优势。

综上所述,由于基于视频的去模糊算法与本文方法机理不同,同时在数据量、成本和实践场景中均存在显著的局限性,因此采用基于图像的运动模糊复原模型更符合奶牛体况评分任务的实际需求。

5 结论

(1)改进的 YOLO v8 算法相较于 YOLO v5l、原 YOLO v8s、YOLOX-m,其精确率分别提高 4.8、3.1、13.0 个百分点;平均精度分别提高 6.5、3.5、16.3 个百分点;具有最少的参数量,降低了模型复杂度。同时,由实例对比实验可知,改进的 YOLO v8 算法在奶牛目标遮挡情况下依然能够实现奶牛体况的准确检测,有效地降低误检和漏检概率,从而提高整体检测精度和管理效率。

(2)改进 NAFNet 模型运动模糊图像复原质量最高,相较于原始运动模糊图像,PSNR 提高 2.66 dB,SSIM 提高 0.284 3;相较于 Deblurgan、Deblurganv2、Restormer 以及原 NAFNet 模型的 PSNR 分别提高 2.19、1.98、1.91、1.67 dB,SSIM 分别提高 0.284 3、0.274 6、0.200 6 和 0.103 8;在去噪和还原图像细节

方面表现更优,去噪后图像质量明显优于原始图像,可有效消除运动模糊对奶牛体况评分的影响。

(3)提出了集成运动模糊图像复原的奶牛体况评分方法 NAF – YOLO v8,在奶牛运动模糊测试集上的精确率、召回率和平均精度分别达到 80.7%、75.3% 和 80.1%,较未进行图像复原的模型分别提高 8.2、4.7、8.0 个百分点,为运动模糊场景下奶牛体况精准监测提供了有效解决方案。

参 考 文 献

[1] 李恩泽,王克俭,司永胜,等. 基于改进 ConvNeXt 的奶牛行为识别方法[J]. 农业机械学报, 2024, 55(5): 282 – 289,404.
LI Enze, WANG Kejian, SI Yongsheng, et al. Cow behavior recognition based on improved ConvNeXt[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(5): 282 – 289,404. (in Chinese)

[2] 任秋鸿, 彭华, 董晓霞, 等. 奶农采用精准奶业技术行为的影响因素分析[J]. 农业工程学报, 2022, 38(11):231 – 238.
REN QiuHong, PENG Hua, DONG Xiaoxia, et al. Factors influencing farmers’ adoption of precision dairy technology[J]. Transactions of the CSAE, 2022,38(11):231 – 238. (in Chinese)

[3] 姜红花,李金鸿,法润萱,等. 基于多任务学习的同步奶牛体况评分和个体识别方法[J]. 农业机械学报, 2025, 56(11): 581 – 589.
JIANG Honghua, LI Jinhong, FA Runxuan, et al. Multi-task learning-based method for simultaneous dairy cow body condition scoring and individual identification[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(11): 581 – 589. (in Chinese)

[4] 孟德超. 集约化牛场体况管理对泌乳奶牛代谢、生产性能和健康的影响[D]. 大庆:黑龙江八一农垦大学, 2021.
MENG DeChao. Effects of body condition management on metabolism, performance and health of lactating dairy cows on intensive dairy farms[D]. Daqing:Heilongjiang Bayi Agricultural University, 2021. (in Chinese)

[5] 黄小平, 冯涛, 郭阳阳, 等. 基于改进 YOLO v5s 的轻量级奶牛体况评分方法[J]. 农业机械学报, 2023, 54(6):287 – 296.
HUANG Xiaoping, FENG Tao, GUO Yangyang, et al. Lightweight dairy cow body condition scoring method based on improved YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6):287 – 296. (in Chinese)

[6] 孙佳. 非接触式奶牛体况自动评分关键技术研究[D]. 哈尔滨:东北农业大学, 2021.
SUN Jia. Research on the key techniques for non-contact automatic scoring of dairy cow body condition[D]. Harbin:Northeast Agricultural University,2021. (in Chinese)

[7] 吴宇峰, 李一鸣, 赵远洋, 等. 基于计算机视觉的奶牛体况评分研究综述[J]. 农业机械学报, 2021, 52(增刊): 268 – 275.
WU Yufeng, LI Yiming, ZHAO Yuanyang, et al. Review of research on body condition score for dairy cows based on computer vision[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(Supp.): 268 – 275. (in Chinese)

[8] 张洁, 张程, 侯扶江. 奶牛体况与胎次、泌乳阶段和生产性能的关系[J]. 草业科学, 2016, 33(4): 771 – 777.
ZHANG Jie,ZHANG Cheng, HOU Fujiang. The relationship between cow body condition and parity,lactation stage,production performance[J]. Pratacultural Science, 2016, 33(4): 771 – 777. (in Chinese)

[9] 刘娜, 安晓萍, 王园. 机器视觉技术在奶牛精准化管理中的应用研究进展[J]. 中国畜牧杂志, 2024, 60(7):34 – 40.
LIU Na,AN Xiaoping,WANG Yuan. Research progress on the application of machine vision technology in precision management of dairy cattle[J]. Chinese Journal of Animal Science, 2024, 60(7):34 – 40. (in Chinese)

[10] HUANG X, HU Z, WANG X, et al. An improved single shot multibox detector method applied in body condition score for dairy cows[J]. Animals, 2019, 9(7): 470.

[11] ĆEVİK K K. Deep learning based real-time body condition score classification system[J]. IEEE Access, 2020, 8: 213950 – 213957.

[12] ZHAO K, ZHANG M, SHEN W, et al. Automatic body condition scoring for dairy cows based on efficient net and convex hull features of point clouds[J]. Computers and Electronics in Agriculture, 2023, 205: 107588.

[13] 黄正源, 谢维成, 黄化入, 等. 图像运动模糊还原技术综述[J]. 计算机工程与应用, 2020, 56(24): 28 – 34.
HUANG Zhengyuan, XIE Weicheng, HUANG Huaru, et al. Overview of motion deblurring techniques for images[J]. Computer Engineering and Applications, 2020, 56(24): 28 – 34. (in Chinese)

[14] KUPYN O, BUDZAN V, MYKHAILYCH M, et al. Deblurgan: blind motion deblurring using conditional adversarial networks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition,2018: 8183 – 8192.

[15] KUPYN O, MARTYNIUK T, WU J, et al. Deblurgan – v2: deblurring (orders-of-magnitude) faster and better[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 8878 – 8887.

[16] ZAMIR S W, ARORA A, KHAN S, et al. Restormer: efficient transformer for high-resolution image restoration [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 5728 – 5739.

[17] CHEN L, CHU X, ZHANG X, et al. Simple baselines for image restoration[C]//European Conference on Computer Vision, 2022: 17 – 33.

[18] VASSEUR E, GIBBONS J, RUSHEN J, et al. Development and implementation of a training program to ensure high repeatability of body condition scoring of dairy cows[J]. Journal of Dairy Science, 2013, 96: 4725 – 4737.

[19] TERVEN J, CORDOVA-ESPARZA D M, ROMERO-GONZALEZ J A, et al. A comprehensive review of YOLO architectures in computer vision; from YOLOv1 to YOLOv8 and yolo-nas[J]. Machine Learning and Knowledge Extraction, 2023, 5(4): 1680 – 1716.

[20] ZHANG J, LI X, LI J, et al. Rethinking mobile block for efficient attention-based models[C] //2023 IEEE/CVF International Conference on Computer Vision (ICCV). IEEE Computer Society, 2023: 1389 – 1400.

[21] SOHAN M, SAI Ram T, REDDY R, et al. A review on yolov8 and its advancements[C] //International Conference on Data Intelligence and Cognitive Informatics, 2024: 529 – 545.

[22] HUSSAIN M. Yolov1 to v8; unveiling each variant—a comprehensive review of YOLO[J]. IEEE Access, 2024, 12: 42816 – 42833.

[23] LAU K W, PO L M, REHMAN Y A U. Large separable kernel attention; rethinking the large kernel attention design in CNN [J]. Expert Systems with Applications, 2024, 236: 121352.

[24] YU Z, HUANG H, CHEN W, et al. Yolo – facev2: a scale and occlusion aware face detector[J]. Pattern Recognition, 2024, 155: 110714.

[25] LI Y, ZHANG Y, TIMOFTE R, et al. NTIRE 2023 challenge on image denoising: methods and results[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 1905 – 1921.

[26] VASLUIANU F A, SEIZINGER T, ZHOU Z, et al. NTIRE 2024 image shadow removal challenge report[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 6547 – 6570.

[27] HUANG H, CHEN Z, ZOU Y, et al. Channel prior convolutional attention for medical image segmentation[J]. Computers in Biology and Medicine, 2024, 178: 108784.

[28] 陈冲, 陈杰, 张慧, 等. 深度学习可解释性综述[J]. 计算机科学, 2023, 50(5):52 – 63.
CHEN Chong, CHEN Jie, ZHANG Hui, et al. Review interpretability of deep learning[J]. Computer Science, 2023, 50(5): 52 – 63. (in Chinese)

[29] 路晓辰, 杨立明, 杨兴悦, 等. 深度学习方法在地震事件分类中的应用及可解释性研究[J]. 地震工程学报, 2023, 45(2):474 – 482.
LU Xiaochen, YANG Liming, YANG Xingyue, et al. Application and interpretability of deep learning methods in seismic event classification[J]. Journal of Earthquake Engineering, 2023, 45(2):474 – 482. (in Chinese)

(上接第 245 页)

[21] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84 – 90.

[22] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas; IEEE, 2016: 770 – 778.

[23] PAYMODE A S, MALODE V B. Transfer learning for multi-crop leaf disease image classification using convolutional neural network VGG[J]. Artificial Intelligence in Agriculture, 2022, 6: 23 – 33.

[24] GOMROKI M, HASANLOU M, REINARTZ P. STCD – EffV2T Unet; semi transfer learning EfficientNetV2 T – Unet network for urban/land cover change detection using Sentinel – 2 satellite images[J]. Remote Sensing, 2023, 15(5): 1232.

[25] ZHOU G Q, LIU W G, ZHU Q, et al. ECA – MobileNetV3 (large) + SegNet model for binary sugarcane classification of remotely sensed images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1 – 14.

[26] RETTENBERGER L, SZYMANSKI N J, GIUNTO A, et al. Leveraging unlabeled SEM datasets with self-supervised learning for enhanced particle segmentation[J]. npj Computational Materials, 2025, 11(1): 289.

[27] LIU D, DU J C, LI C H, et al. Multi-unit stacked architecture; an urban scene segmentation network based on UNet and ShuffleNetv2[J]. Applied Soft Computing, 2024, 165: 112065.

[28] STEFENON S F, SEMAN L O, KLAAR A C R, et al. Hypertuned – YOLO for interpretable distribution power grid fΔlt location based on EigenCAM[J]. Ain Shams Engineering Journal, 2024, 15(6): 102722.

[29] 褚文博, 甘露, 李国法, 等. 面向自动驾驶的大模型高效压缩技术:综述[J]. 机械工程学报, 2024, 60(22):224 – 240.
CHU Wenbo, GAN Lu, LI Guofa, et al. Large models efficient compression technology for autonomous driving: a review[J]. Journal of Mechanical Engineering, 2024, 60(22): 224 – 240. (in Chinese)

[30] JIANG Y, ZHANG T, GUO J, et al. Clustering-based nonlinear training algorithm for precision constrained photonic micro-ring convolution chip[J]. Journal of Lightwave Technology, 2024, 42(22): 1 – 8.

[31] YANG Q, DUAN S K, WANG L D. Efficient identification of apple leaf diseases in the wild using convolutional neural networks[J]. Agronomy, 2022, 12(11): 2784.