

DOI:10.19651/j.cnki.emt.2519569

基于YOLOv8改进的指针式仪表检测算法*

孙小龙 许燕

(新疆大学机械工程学院 乌鲁木齐 830047)

摘要: 针对室内外复杂场景中,由于拍摄距离较远导致仪表区域像素比例较小,从而引发表盘检测精度低、漏检率高以及实时性差等问题,提出了一种基于YOLOv8改进的指针式仪表检测算法——GRCP-YOLOv8。首先,设计了一种融合CGA注意力机制的C2f_CGA模块,以增强模型对不同尺度特征的表达能力,并替代了主干网络中的所有C2f模块。其次,提出使用RFACnv替代传统卷积层,以解决普通卷积模块由于参数共享带来的特征表达不足问题。继而,设计了新型颈部网络结构CCFPN,通过引入主干网络提取的高分辨率特征图,提升了对小目标的感知能力,并通过 1×1 卷积减少卷积层通道数,从而减小了模型的参数量与计算量。最后,基于重参数化卷积(RepConv)设计了新的检测头——RepHead,有效降低了推理阶段的计算量和内存消耗。实验结果表明,改进后的算法在精度、召回率和mAP@50上的表现分别为94.3%、91.6%和92.5%,相比YOLOv8n模型,召回率和mAP@50分别提升了1.3%和1.2%。在计算复杂度和参数数量上分别降低了39%和27%,且模型体积仅为4.22 MB,表明所提算法在提升检测准确率的同时,更适合部署于边缘设备。

关键词: YOLOv8; 目标检测; 指针式仪表; 轻量化; 注意力机制

中图分类号: TH391.4; TN98 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Pointer instrument detection algorithm improved by YOLOv8

Sun Xiaolong Xu Yan

(School of Intelligent Manufacturing Modern Industry, Xinjiang University, Urumqi 830047, China)

Abstract: To address the issues of low detection accuracy, high missed detection rate, and poor real-time performance in complex indoor and outdoor scenarios, where the instrument area occupies a small pixel ratio due to the long shooting distance, this paper proposes an improved pointer instrument detection algorithm based on YOLOv8, named GRCP-YOLOv8. First, a C2f_CGA module, integrated with the CGA attention mechanism, is designed to enhance the model's ability to express features at different scales and replace all C2f modules in the backbone network. Secondly, RFACnv is introduced to replace the conventional convolution layers, addressing the insufficient feature representation caused by parameter sharing in standard convolution modules. Subsequently, a new neck network structure, CCFPN is designed. By incorporating high-resolution feature maps extracted from the backbone network, it improves the model's capability to detect small targets, while reducing the number of channels in convolution layers via 1×1 convolutions, thus reducing the model's parameter count and computational complexity. Finally, a new detection head, RepHead, based on reparameterized convolution (RepConv), is introduced to reduce computational load and memory consumption during inference. Experimental results show that the proposed algorithm achieves accuracy, recall rate, and mAP@50 of 94.3%, 91.6%, and 92.5%, respectively, with recall and mAP@50 improving by 1.3% and 1.2% compared to the YOLOv8n model. The algorithm also reduces computational complexity and parameter count by 39% and 27%, respectively, while the model size is only 4.22 MB. These results demonstrate that the proposed algorithm not only improves detection accuracy but is also more suitable for deployment on edge devices.

Keywords: YOLOv8; target detection; pointer instrument; lightweight; attention mechanism

0 引言

在油气站等工业场景中,仪表广泛用于监测管道压力、

温度等物理量,其示值大小是判断油气站是否安全运行的关键因素。相比数字式仪表,指针式仪表具有抗干扰能力强、结构简单、维护方便、成本低等显著优势,因此被广泛应

收稿日期:2025-08-10

* 基金项目:新疆维吾尔自治区天山英才培养计划(2022TSYCLJ0044)项目资助

用于工业领域^[1]。传统的仪表巡检主要依赖人工完成。然而,由于仪表种类繁多、数量庞大,且受到雨雾等恶劣环境的干扰,人工巡检过程中经常出现误检和漏检现象,且已无法满足实时性的要求^[2]。因此,研究一种可靠、稳定且快速的指针式仪表检测方法具有重要意义。

目前,指针式仪表的检测方法可分为基于图像处理的传统目标检测方法和基于深度学习的目标检测方法^[3]。传统的基于图像处理的检测算法,如Hough变换圆检测^[4],通过圆形轮廓特征检测仪表区域,但当背景中存在类似圆形特征的物体时,检测精度会显著下降;特征点匹配法,如加速稳健特征(speeded up robust features, SURF)^[5]图像匹配法和尺度不变特征变换(scale-invariant feature transform, SIFT)^[6]方法,能够快速定位表盘区域并完成仪表检测任务,但这些方法主要针对固定场景中的少数仪表类别,难以适应复杂工业环境中多类别仪表的检测需求。

近年来,深度学习在模式识别^[7]、图像分类^[8]及目标检测等领域取得了显著突破。基于深度学习的目标检测算法主要分为两类:两阶段的区域卷积神经网络(region-based convolutional neural networks, R-CNN)系列^[9]和单阶段的YOLO(you only look once)^[10]系列以及单次多边框检测(single shot multiBox detector, SSD)^[11]等算法,已广泛应用于表盘检测领域。文献[12]提出改进YOLOv5s算法,针对数显仪表数字区域在不同图像中占用像素比例不同的问题,提出基于感兴趣区域(region of interest, ROI)的迭代检测方法,并采用广义交并比(generalized intersection over union, GIOU)替代传统交并比(intersection over union, IOU)作为位置损失函数,加速了模型训练过程中的收敛速度,改进后的精确率和召回率达到了99%,实现了高精度的数显仪表读数。文献[13]提出将改进的SSD应用于仪表检测,通过不同层级的特征图隔层融合,实验证明该算法在置信度阈值为0.2时,仪表的误检率为0,漏检率为0.53,在多种工况下均能准确检测仪表。文献[14]提出了改进的YOLOv3算法,通过采用轻量化主干网络MobileNet,压缩了模型体积,提高了检测速度,并使用小批量K-均值(mini batch kmeans, MBK)模型优化边界框尺寸,从而减少了计算时间。文献[15]应用基于区域的快速卷积神经网络(fast region-based convolutional neural networks, Fast R-CNN)模型在变电站环境下实现了精确的仪表定位。文献[16]提出在复杂场景下引入Faster R-CNN并采用残差网络(residual network 50, ResNet50)替代视觉几何组(visual geometry group 16, VGG16)作为主干网络,解决了网络退化问题,提高了表盘区域检测的准确性。文献[17]提出将特征金字塔网络(feature pyramid network, FPN)与Faster R-CNN结合,提高了仪表区域检测的精度。文献[18]使用YOLOv4检测算法,并结合透视变换技术,成功对倾斜拍摄的仪表图像进行矫正。

尽管上述研究实现了仪表检测的自动化,但在实际应用中仍存在以下3个主要问题:一是高处仪表在图像中占据的像素比例较小,导致检测精度较低;二是现有检测网络在处理大量待检仪表时实时性差;三是模型较为复杂,难以在边缘设备上高效部署。YOLOv8作为YOLO系列成熟且稳定的版本,在骨干网络、特征融合机制及损失函数等方面相比YOLO系列以前版本均有改进,展现出更强的泛化能力和更高的推理效率,且在工业检测场景中展现出良好的潜力。因此,本文以YOLOv8为基础模型进行改进。在面向指针式仪表这一特定任务时,YOLOv8仍存在明显局限:1)其主干网络中的C2f模块(CSP bottleneck with 2 convolutions)采用标准卷积与残差连接,缺乏对小目标关键区域(如指针、刻度线)的自适应关注能力;2)颈部网络FPN结构未充分融合高分辨率浅层特征,导致拍摄距离较远时表盘特征在深层语义抽象过程中被弱化甚至丢失;3)检测头采用固定卷积结构,计算冗余大,不利于部署在资源受限的边缘设备上。

针对上述问题,已有相关研究提出多种改进的YOLOv8如:文献[19]提出将卷积注意力模块(convolutional block attention module, CBAM)注意力机制嵌入主干网络中,提升了特征辨别力,但未考虑通道与空间注意力的级联协同,且增加了计算复杂度;文献[20]引入了一种简单注意力模块(simple attention module, SimAM)注意力机制,显著提高了对细粒度特征的提取能力,但其主要应用于光伏电池缺陷检测,并未针对指针仪表的特征进行优化;文献[21]通过添加小目标检测头提升了对无人机巡检中小目标的检测精度,但同时增加了模型的计算开销和参数量,影响后续模型的边缘端部署。综上所述,这些改进虽较为先进,但多偏向于单一方面的提升(如精度或轻量化),忽略了性能与精度的平衡。因此,本文基于YOLOv8网络,针对上述问题提出的改进包括:

1)基于级联群体注意力(cascaded group attention, CGA)注意力机制^[22],提出改进的C2f_CGA模块,替代主干网络中的C2f模块。同时,在卷积模块中引入感受野注意力机制,形成新的卷积模块感受野注意力卷积运算(receptive-field attention convolutional operation, RFACConv)^[23],并将其应用于主干网络中除第一层外的所有卷积层。通过这些改进,提升模型对目标区域的关注度,使其更有效地识别图像中的小目标。

2)基于实时监测转换器(real-time detection transformer, RT-DETR)^[24]网络架构,设计了新的颈部网络基于卷积神经网络的跨尺度特征金字塔(cnn-based cross-scale feature fusion, CCFPN),并减少了颈部网络中卷积层的通道数,从而降低了模型的参数量。通过横向连接引入主干网络提取的高分辨率特征图,与深层语义特征融合,提升了模型对小目标的感知能力。

3)基于重参数卷积(re-parameterization convolutional,

RepConv)^[25],重新设计了检测头,提出了新的检测头 RepHead,显著降低了推理阶段的计算量和内存消耗,便于模型在边缘设备上的部署。

1 数据集和改进方法

1.1 数据集准备

本研究构建的指针式仪表数据集包含 2 557 张 JPG 格式的仪表工作图像,涵盖 4 种不同环境下的工况,包括:549 张室内实验室仪表图像、696 张室内现场仪表图像、1 206 张室外现场仪表图像以及 106 张反例图像。其中,室内实验室仪表图像由论文作者亲自采集。由于原始图像数量有限,数据集在样本数量和多样性上存在不足,因此,部分图像数据来源于互联网,另一部分则基于文献[26]中创

建的数据集。

鉴于直接使用原始图像进行训练、验证和测试存在困难,首先需要对数据集中的图像进行目标位置标注,以便进行仪表区域检测。因此,本实验使用 LabelImg 软件对表盘区域及其类别进行标注,并将标注信息保存为 txt 格式。数据集被划分为训练集和测试集,比例为 8:2。如图 1(a)所示,展示了数据集中部分图像的示例。

为了增加训练样本数量,提升实验框架的可信度,本文对原始数据集中的 2 557 张图像进行了数据增强,以提高网络的学习效果和泛化能力,从而更好地模拟多种自然环境中的指针式仪表检测。所采用的增强方法包括旋转、翻转、裁剪、仿射变换等。图 1(b)展示了数据增强后的部分图像。扩展后的数据集包含 4 018 张图像。

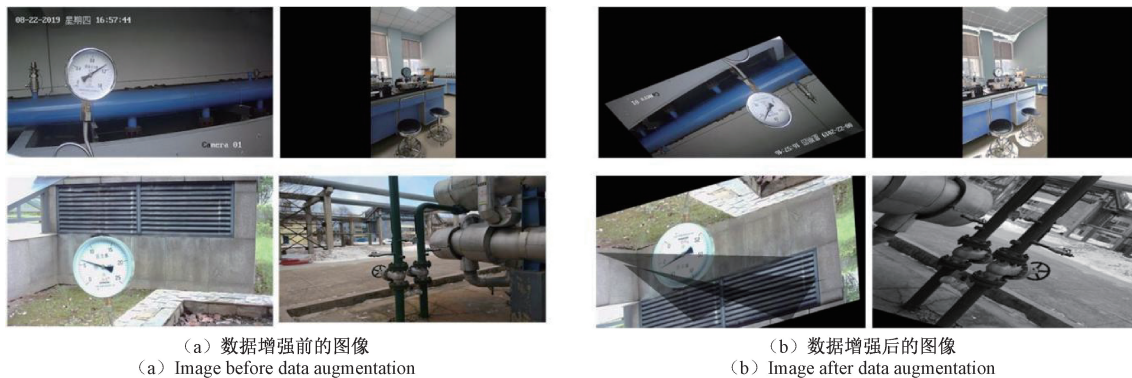


图 1 数据集部分图片

Fig. 1 Some images from the dataset

1.2 YOLOv8 网络结构

YOLOv8 框架采用了基于深度卷积神经网络(convolutional neural networks, CNN)的架构。其核心组件是 C2f,该模块通过集成瓶颈结构来增强特征表示。瓶颈结构包括一系列卷积层、批量归一化层和激活函数。在 YOLOv8 的官方文档中,卷积层、批量归一化层和激活函数的合并被称为“Conv 块”。此外,YOLOv8 还通过更高效的 C2f 和空间金字塔池化(Spatial Pyramid Pooling, SPPF)模块,分别加速了跨阶段部分融合和空间池化机制。SPPF 模块通过应用不同内核大小的最大池化操作,能够捕捉多尺度特征,从而聚合上下文信息。整个框架通过上采样层和连接机制有效融合不同阶段的特征,进而实现高级和低级特征信息的有效结合。

基于 YOLOv8 的原始模型架构,本文首先提出将融合了 CGA 的 C2f_CGA 模块替换原主干网络中的 C2f 模块,同时使用 RFACnv 替代主干网络中除第 1 层外的其他卷积层。其次,设计了新的颈部网络 CCFPN,替换了原有的颈部网络。最后,采用改进的 RepHead 替代原始检测头。改进后的 YOLOv8 模型结构如图 2 所示。接下来,将重点介绍以上 4 个创新模块的设计与实现。

1) 结合 CGA 的 C2f_CGA 模块

CGA 架构如图 3 所示。在 YOLOv8 架构中,主干网络包含多个 C2f 模块,特征提取能力主要受该模块的影响。为了实现多尺度特征表示,一种常见的方式是将注意力机制集成到 C2f 模块后。然而,独立添加的注意力机制不仅会增加计算复杂性,还可能导致模型检测效果下降。为了解决这一问题,本文提出了一种轻量级的 C2f_CGA 模块,作为对现有 C2f 模块的替代。C2f_CGA 模块集成了级联群体注意力机制,其架构细节分别在图 4(a)和(b)中进行了可视化展示。通过分组卷积和深度可分离卷积,C2f_CGA 模块显著减少了参数量和计算量。同时,支持多头注意力机制,有效处理不同尺度的特征,并增强了注意力权重的表达,能够更充分地捕捉特征图的空间关系。

C2f_CGA 模块通过动态偏置增强表盘区域的特征表达,使得算法能够更准确地定位到表盘区域。这对于工业场景中的表盘图像尤其重要,因为这些图像常常受到噪声、光照不均和遮挡的影响。与传统的 C2f 模块不同,C2f_CGA 模块由两个 CBS 模块和多个堆叠的 CGA_Bottleneck 模块组成。C2f_CGA 的结构如图 4 所示。输入特征图首先通过一个卷积核大小为 1、步长为 1 的 CBS 模块进行

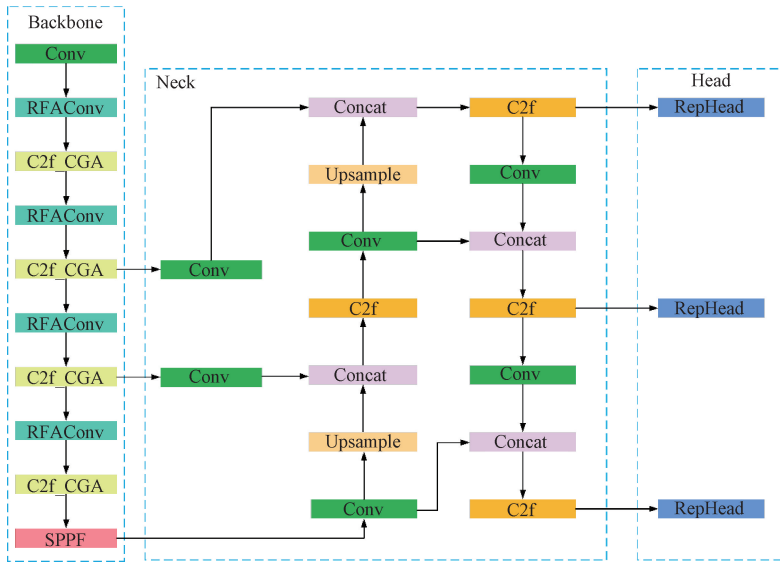


图2 改进的YOLOv8的网络结构
Fig. 2 Improved YOLOv8 network structure

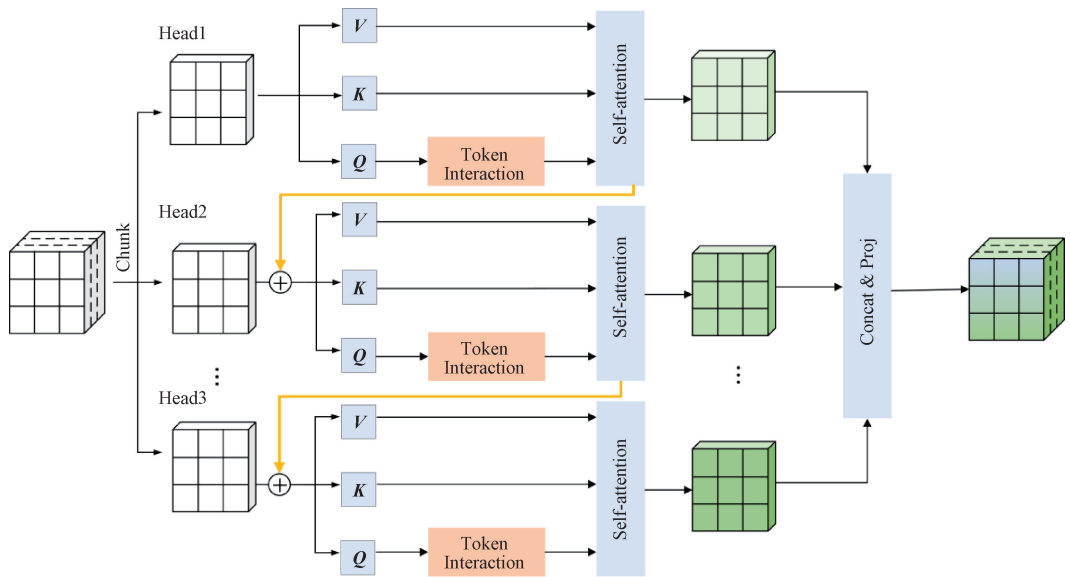


图3 级联群体注意力机制(CGA)架构
Fig. 3 Architecture of the cascaded group attention mechanism (CGA)

处理。然后,特征图被分成并行分支,其中第1个分支通过堆叠的CGA_Bottleneck进行处理。接着,CGA_Bottleneck块的输出与CBS块的原始特征图进行拼接,形成结合低级和高级特征的丰富特征表示。第2个CBS块进一步细化这些特征图,通过应用相同步幅和卷积核大小为1的卷积操作。通过整合级联群体注意力机制,C2f_CGA模块有效增强了网络捕捉复杂模式的能力,从而优化了特征表示。

2)RFACnv

YOLOv8模型通过标准卷积操作提取多尺度特征,但由于标准卷积的感受野是固定的,当卷积核在输入图像上

滑动并生成特征图时,其参数保持不变,这意味着卷积核在不同位置使用相同的权重来提取特征。由于这一机制,标准卷积无法捕捉到输入图像在不同位置所带来的信息差异,这在一定程度上限制了卷积神经网络的性能。为了解决这一问题,RFACnv引入了感受野注意力机制,能够动态调整感受野的大小和形状,使得网络能够在不同位置和尺度上捕捉到更多的上下文信息,从而增强对表盘区域特征的提取能力。

感受野的空间特征是为卷积核特别设计的,并基于卷积核的大小动态生成。以 3×3 卷积核为例,如图5所示,其中“空间特征”指原始特征图,“感受域空间特征”是由空

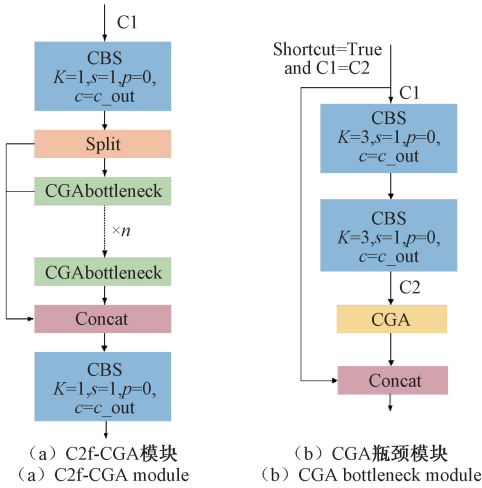


图 4 C2f-CGA 详细架构

Fig. 4 Detailed architecture of C2f-CGA

间特征转换而成的特征图,呈现为不重叠的滑动窗口结构。感受场空间特征中的每个 3×3 窗口代表一个感受场滑块。




图 5 对空间特征进行变换得到接收场空间特征

Fig. 5 The spatial features are transformed to obtain the spatial features of the received field

针对感受野的空间特征,本文提出了 RFACConv。如图 6 所示,RFACConv 的整体结构以 3×3 卷积核为例。在 RFACConv 中,本文采用组卷积方法提取感受野空间特征,通过交互信息增强网络性能。类似地,通过交互接收场特征信息并学习注意力图,RFACConv 进一步提升了网络性能。然而,与每个接收场特征进行交互会增加额外的计算开销。为了最小化计算开销和参数量,本文利用全局平均池化(average pooling, AvgPool)来聚合每个接收场特征的全局信息,随后通过 1×1 组卷积进行信息交互。最终,使用 softmax 函数对每个特征在接收场特征中的重要性进行加权,从而强调关键特征。通常,RFA 的计算可表示为:

$$\mathbf{F} = \text{Softmax}(\mathbf{g}^{1 \times 1}(\text{AvgPool}(\mathbf{X}))) \times \text{ReLU}(\text{Norm}(\mathbf{g}^{k \times k}(\mathbf{X}))) = \mathbf{A}_{rf} \times \mathbf{F}_{rf} \quad (1)$$

其中, $\mathbf{g}^{1 \times 1}$ 表示大小为 $i \times i$ 的分组卷积, k 表示卷积核的大小, Norm 表示归一化, \mathbf{X} 表示输入特征图, \mathbf{F} 是通

过将注意力图 \mathbf{A}_{rf} 与变换后的感受场空间特征 \mathbf{F}_{rf} 相乘而获得的。RFACConv 通过强调感受野滑块内不同特征的重要性并优先考虑感受野空间特征来完全解决卷积运算参数共享问题。

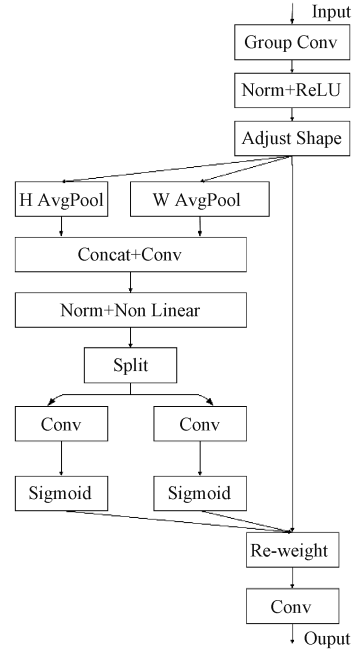


图 6 RFACConv 结构

Fig. 6 RFACConv structure

3) 改进的颈部网络 CCFPN

YOLOv8 模型通过使用步幅为 2、大小为 3×3 的卷积核来提取多尺度特征。随着网络深度的增加,特征图的通道数也呈倍数增加,直接进行 3×3 卷积的计算量将显著增大。为了应对这一挑战,并不影响主干网络特征提取能力的前提下,本文设计了一种新的颈部网络结构。该结构主要通过使用 1×1 卷积核进行通道数降维,从而显著减少后续卷积操作的计算量。例如,将通道数从 1 024 降至 256 后, 3×3 卷积的计算量减少了约 4 倍。传统 3×3 卷积的计算量为: $H \times W \times C_{in} \times C_{out} \times 3 \times 3$, 而 1×1 卷积的计算量为: $H \times W \times C_{in} \times C_{out} \times 1 \times 1$, 仅为传统 3×3 卷积计算量的 $1/9$ 。

受 RT-DETR 网络中跨尺度特征融合(cross-scale feature fusion, CCF)模块的启发,本文结合该模块对 YOLOv8 的颈部网络进行了改进设计。首先,在 SPPF 层之后使用 1×1 卷积,以降低运算量并调整输出通道数,确保在进行特征拼接(concat)之前,所有特征图的通道数一致,从而避免维度不匹配引发的错误。在 FPN 进行特征图拼接之前,对主干网络提取的 P3 和 P4 特征图进行 1×1 卷积处理,将通道数降至 256,这不仅减少了计算量,还通过 1×1 卷积学习了通道间的关联性,增强了特征表达,同时整合了不同尺度的通道信息,避免了特征冗余。改进后的颈部网络结构如图 7 所示。

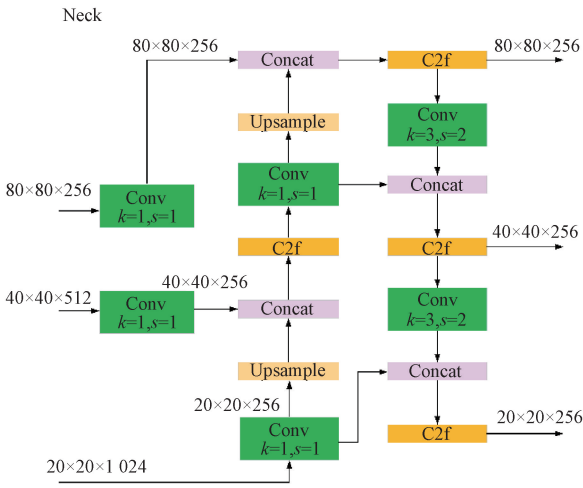


图7 CCFPN 颈部结构
Fig.7 CCFPN neck structure

4)改进的检测头 RepHead

本文在YOLOv8的检测头部分引入了RepConv技术的重参数检测头(RepHead)。RepConv是一种重参数化卷积方法,其核心思想是在训练阶段采用多分支结构,在推理阶段将其等效转换为单分支结构,从而实现高效的目标检测。在训练阶段,RepConv的每个阶段由一个 3×3 卷积层、一个 1×1 卷积层以及一个恒等映射(identity mapping)组成。这种多分支结构能够增强特征提取能力,提高模型的表达能力与泛化性能。推理阶段,RepConv将多分支结构融合为单一的 3×3 卷积层,显著减少计算量与内存消耗,从而提升推理速度。RepConv在训练与推理阶段的结构示意如图8所示。

YOLOv8原始检测头由多层标准卷积构成,通过逐层卷积提取特征并输出检测结果。为引入RepConv技术,本文基于其设计了动态模块(dynamic block, DB),该模块由两个RepConv单元串联组成,用于对输入特征图进行深度特征提取与增强。DB模块替换了原YOLOv8检测头中前两层标准卷积,随后采用 1×1 卷积对特征图进行进一步处理,并完成边界框回归与类别概率预测。该改进方案在保证检测精度的同时,显著降低了推理阶段的计算开销与内存占用,有效提升了模型的推理速度。改进后的检测头结构如图9所示。

2 试验与分析

2.1 试验环境

本文的试验环境如下:操作系统为Windows 11(家庭中文版),CPU型号为13th Gen Intel® Core™ i7-13650HX@2.6 GHz,内存为24 GB,GPU型号为RTX 4060,显存为8 GB,采用的深度学习框架为PyTorch 2.0.0,CUDA版本为11.8。编程语言为Python 3.9。模型训练的参数设置如下:优化器为SGD,BatchSize设为

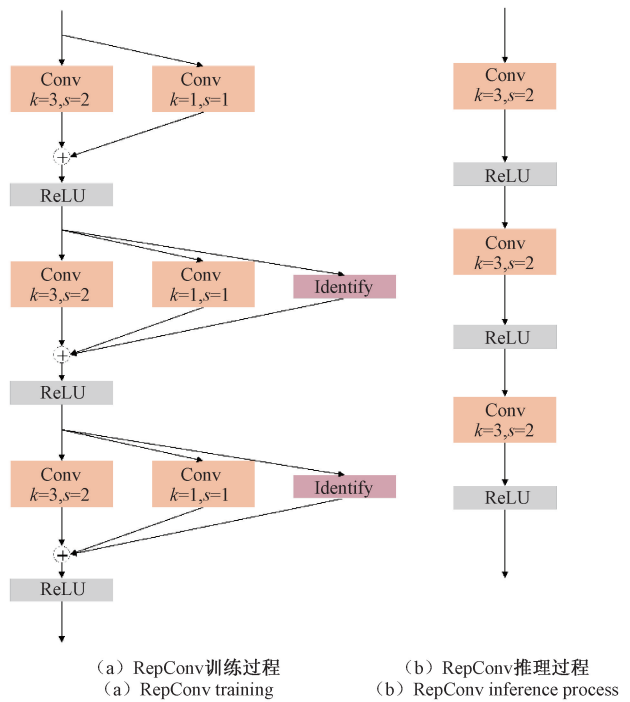


图8 RepConv 结构
Fig.8 RepConv structure

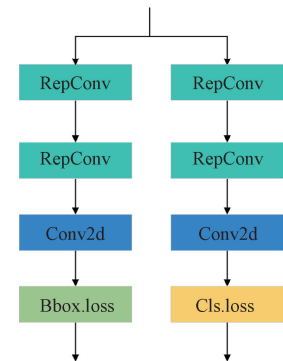


图9 改进的RepHead
Fig.9 Improved RepHead

16,学习率设置为0.01,权重衰减系数为0.0005,动量参数设置为0.937,Epoch设为200轮。

2.2 评价指标

为了评估本研究中提出的仪表区域检测框架的有效性,采用了5个关键指标,包括精度(Precision),召回率(Recall),IoU阈值为0.5(mAP@50)时的平均精度,FLOPs和参数(Params)。这些指标共同阐明了框架的检测精度和检测速度。

精确率是衡量框架准确预测阳性样本的能力的标准,公式为:

$$P = \frac{TP}{TP + FP} \tag{2}$$

召回率指标量化了框架准确识别出正样本案例的比

例,以及框架根据其预测识别出的真正积极案例的总数。公式为:

$$P = \frac{TP}{TP + FN} \quad (3)$$

mAP@50 指标量化当检测帧与真实帧重叠到指定程度时与准确性一致的检测结果的比例,给定 0.5 的 IoU 阈值。本质上,该指标阐明了框架在此预定义阈值下的检测精度,反映了其在规定条件下准确识别实例的能力。公式为:

$$mAP = \frac{\sum_{i=1}^n AP_i}{n} \quad (4)$$

其中,TP 表示模型预测结果为正类的正样本数目,FP 表示模型预测结果为正类的负样本数目,FN 表示模型预测结果为负类的正样本数目,n 表示需要检测目标的类别数。

表 1 不同改进型 C2f 模块性能比较

Table 1 Comparison of performance of different improved C2f modules

模型	Precision	Recall	mAP@50	GFLOPs/G	Params/M
YOLOv8	0.946	0.903	0.913	8.2	3.1
YOLOv8(C2f_Acmix)	0.940	0.912	0.919	8.4	3.2
YOLOv8(C2f_DLKA)	0.940	0.915	0.922	13.5	4.6
YOLOv8(C2f_FLA)	0.935	0.909	0.920	8.2	3.2
YOLOv8(C2f_iEMA)	0.944	0.911	0.916	8.3	3.1
YOLOv8(C2f_CGA)	0.949	0.906	0.928	8.4	3.1

其次,为进一步增强特征提取与上下文建模能力,本文在主干网络中使用 RFACnv 替换原始网络中的标准卷积进行降采样。通过与其他 4 种下采样模块的对比实验(表 2),结果表明,加入 RFACnv 后,YOLOv8 在召回率

2.3 与其他模块的比较

为验证所提出的 GRCP_YOLOv8 框架中各增强组件的有效性,本文分别与其他研究中提出的多种模块进行了对比分析,比较范围涵盖下采样卷积、C2f 改进模块、颈部网络及检测头。实验结果表明,所提出的增强策略在仪表盘检测任务中具有较高的实用性与适用性。

首先,在骨干网络中引入结合注意力机制的 C2f_CGA 模块,旨在提升改进模型对仪表盘特征的学习能力。本文将该模块与融合其他注意力机制的 C2f 模块进行了对比(表 1)。结果显示,在计算量和参数量接近的情况下,C2f_CGA 模块的性能优于其他同类模型。与原始 YOLOv8 相比,引入 C2f_CGA 模块的模型在准确率(Precision)与召回率(Recall)方面均有一定提升,mAP@50 则有显著增强。这表明,CGA 注意力机制能够有效提高模型的特征表达能力,从而更精确地定位仪表盘区域。

与 mAP@50 方面均有明显提升,尽管准确率略有下降,但整体检测能力增强,尤其是在减少误检与漏检方面效果突出。

在颈部网络改进方面,本文提出的 CCFPN 结构在不

表 2 不同下采样模块性能比较

Table 2 Comparison of performance of different down-sampling modules

模型	Precision	Recall	mAP@50	GFLOPs/G	Params/M
YOLOv8	0.946	0.903	0.913	8.2	3.1
YOLOv8(ContextGuidedBlock_Down)	0.940	0.915	0.923	7.8	2.8
YOLOv8(DiverseBranchBlock)	0.940	0.915	0.921	9.8	3.5
YOLOv8(ODConv)	0.934	0.915	0.917	7.2	4.2
YOLOv8(SACnv)	0.949	0.911	0.919	7.3	3.5
YOLOv8(RFACnv)	0.936	0.920	0.923	8.4	3.1

降低检测性能的前提下显著减少了计算量与参数量。对比实验(表 3)显示,改进后的颈部网络在精确率、召回率及 mAP@50 上均较原始 YOLOv8 有所提升,同时计算量与参数量显著下降,使得模型更加轻量化,有利于在移动端及嵌入式设备上部署。

最后,在检测头部分,本文引入基于 RepConv 的 RepHead 结构,通过在训练阶段采用多分支结构、推理阶

段合并为单分支,增强特征学习能力的同时,仅带来极小的 GFLOPs 增加,从而保持较高的 FPS 推理速度。检测头对比实验(表 4)表明,改进后的 RepHead 在计算量与参数量方面均优于其他检测头结构。在精确率略有下降的情况下,召回率与 mAP@50 取得最优表现,验证了其在提升检测精度和降低漏检率方面的有效性,尤其适用于数据集中难以识别的样本。

表3 不同颈部网络性能比较

Table 3 Comparison of different neck network performance

模型	Precision	Recall	mAP@50	GFLOPs/G	Params/M
YOLOv8	0.946	0.903	0.913	8.2	3.1
YOLOv8(ASF_YOLO)	0.939	0.911	0.919	8.7	3.1
YOLOv8(BiFPN)	0.944	0.911	0.919	8.2	2.8
YOLOv8(GoldYOLO)	0.937	0.910	0.919	17.6	8.1
YOLOv8(CCFPN)	0.948	0.916	0.919	6.7	1.9

表4 基于改进网络不同检测头性能比较

Table 4 Comparison of performance of different detection heads based on improved network

模型	Precision	Recall	mAP@50	GFLOPs/G	Params/M
GRC_YOLOv8(ASFFHead)	0.944	0.904	0.92	8.0	2.3
GRC_YOLOv8(DynamicHead)	0.947	0.909	0.921	7.9	2.4
GRC_YOLOv8(Detect_DBB)	0.942	0.905	0.923	7.4	2.1
GRC_YOLOv8(RFAHead)	0.941	0.912	0.922	6.1	1.9
GRC_YOLOv8(RepHead)	0.943	0.916	0.925	6.0	1.8

2.4 消融实验

表5汇总了本研究的消融实验结果,评估指标包括精确率(Precision)、召回率(Recall)、mAP@50、计算量(GFLOPs)以及参数量(Params)。如表5所示,YOLOv8n+CCFPN网络的精确率和召回率分别较原始YOLOv8n提

升了0.3%和1.3%,mAP@50提升了0.6%;与此同时,参数量和计算量分别减少了35%和18%。这一结果表明,CCFPN颈部网络的引入在检测精度与推理速度之间实现了良好的平衡,并增强了模型在工业复杂环境中对目标的识别能力。

表5 改进模型中各模块的消融实验

Table 5 Ablation experiments of each module in the improved model

模型	C2f_CGA	RFAConv	CCFPN	RepHead	Precision	Recall	mAP@50	GFLOPs/G	Params/M
YOLOv8n	×	×	×	×	0.946	0.903	0.913	8.2	3.1
	√	×	×	×	0.949	0.906	0.928	8.4	3.1
	×	√	×	×	0.936	0.920	0.923	8.4	3.1
	×	×	√	×	0.948	0.916	0.919	6.7	2.0
	×	×	×	√	0.943	0.908	0.921	8.5	4.1
	√	√	×	×	0.943	0.916	0.927	8.5	3.1
	√	√	√	×	0.950	0.902	0.925	7.1	2.1
	√	√	√	√	0.943	0.916	0.925	6.0	1.8

此外,实验结果进一步验证了本文提出的GRCP-YOLOv8作为仪表区域检测方法的可行性。与基线YOLOv8n相比,GRCP-YOLOv8在精确率仅略微下降0.3%的情况下,召回率和mAP@50分别提升了1.3%和1.2%,同时参数量和计算量分别减少了39%和26%。这些结果充分说明,GRCP-YOLOv8在面对工业复杂环境(包括遮挡、光照不均及其他干扰因素)时,能够显著提升仪表区域的检测性能,并在轻量化与高精度之间取得了有效平衡。

2.5 与其他网络模型比较

为全面评估GRCP-YOLOv8在仪表区域检测任务中的性能表现,本文在相同数据集条件下,将其与多种主流

检测框架进行对比,包括SSD、Faster R-CNN、YOLOv3-Tiny、YOLOv5n、YOLOv7-Tiny、YOLOv8n、YOLOv10n和YOLOv11n。表6给出了各模型的精确率(Precision)、召回率(Recall)、mAP@50、计算量(GFLOPs)及参数量(Params)等指标。

结果显示,SSD的精确率、召回率和mAP@50分别为93.4%、72.1%和87.7%,相较于基线模型(YOLOv8n)各项指标均有明显下降,表明其在仪表区域检测任务中稳健性不足。Faster R-CNN的精确率为所有模型中最低,且其参数量与计算量均为最大,突显出其在实时检测中的劣势及较高的误检率问题。

表 6 不同目标检测网络的对比结果

Table 6 Comparison results of different target detection networks

模型	Precision	Recall	mAP@50	GFLOPs/G	Params/M
SSD	0.934	0.721	0.877	62.70	26.3
Faster-RCNN	0.626	0.935	0.901	370.00	137.1
YOLOv3-Tiny	0.926	0.906	0.910	19.00	12.1
YOLOv5n	0.935	0.891	0.918	7.20	2.6
YOLOv6n	0.939	0.918	0.922	44.20	16.3
YOLOv7-Tiny	0.927	0.901	0.923	13.86	6.2
YOLOv8n	0.946	0.903	0.913	8.20	3.1
YOLOv10n	0.931	0.898	0.918	8.40	2.7
YOLOv11n	0.938	0.911	0.923	6.40	2.6
本文算法	0.943	0.916	0.925	6.00	1.8

在轻量化模型中, YOLOv10n 与 YOLOv11n 均在参数量与计算量上优于基线模型。其中, YOLOv10n 的精确率和召回率较基线模型分别下降 1.5% 和 0.5%, 未能有效缓解仪表检测中的误检与漏检问题。YOLOv11n 的精确率下降 0.8%, 但召回率与 mAP@50 分别提升了 0.8% 和 1.0%, 性能提升幅度仍不及本文提出的改进方法。

与基线模型相比, 优化后的 GRCP-YOLOv8 精确率仅小幅下降 0.3%, 但召回率和 mAP@50 分别提升了 1.3% 和 1.2%; 同时, 参数量与计算量分别减少 39% 和 27%。

这一结果表明, GRCP-YOLOv8 在提升检测性能的同时, 实现了显著的轻量化, 使其在保证精度的前提下更适合部署于移动端与嵌入式设备中。

为进一步验证 GRCP-YOLOv8 的先进性, 将本文算法与近年来提出的多种改进 YOLOv8 算法进行对比, 如表 7 所示, 改进算法的精确率和 mAP@50 均取得最优结果。本文算法相比模型 YOLOv8-CPAC 召回率较差的情况下, 在计算量和参数量方面均有所降低, 使模型一级保持在较低的水平, 充分证明了本文所提 C2f_CGA、RFACConv、CCFPN 与 RepHead 模块的有效性与先进性。

表 7 不同改进 YOLOv8 模型的对比结果

Table 7 Comparison results of different improved YOLOv8 models

模型	Precision	Recall	mAP@50	GFLOPs/G	Params/M
文献[27]	0.939	0.918	0.917	6.7	2.0
文献[28]	0.936	0.911	0.916	7.9	2.9
文献[29]	0.933	0.906	0.920	7.4	2.9
文献[30]	0.935	0.910	0.921	17.9	4.7
本文算法	0.943	0.916	0.925	6.0	1.8

3 结 论

本研究提出了一种基于 YOLOv8 的 GRCP-YOLO v8 模型, 用于在复杂工业环境中检测仪表表盘区域。该模型解决了仪表区域检测任务中的常见问题。它采用了一种新颖的颈部结构(CCFPN), 用于多尺度特征融合。通过利用主干网络中大尺寸特征图、增加多尺度特征融合的频率, 实现了空间和语义信息的平衡整合, 也显著降低了模型大小, 便于后续在嵌入式等移动端的部署。此外, 主干网络中包含了 RFACConv 模块作为下采样层和基于 CGA 的 C2f_CGA 模块。与标准卷积层相比, RFACConv 具有更高的特征提取效率, 并且能够解决标准卷积因参数共享导致的表盘信息特征提取不完全的问题。引入 CGA 的 C2f_

CGA 模块通过动态偏置增强表盘区域的特征表达, 使得算法能更准确的提取到表盘区域中指针和刻度线的特征, 使得模型更准确的识别定位到仪表区域。改进的 RepHead 检测头在训练阶段增强了对提取到的仪表特征的表达能力, 在推理阶段将多分支结构合并为一个单一的 3×3 卷积层, 降低了模型在移动端设备上推理时的计算量和内存消耗, 提升模型的推理速度。

实验结果表明, GRCP-YOLOv8 算法在自制的仪表数据集集中表现最佳, 其精确率、召回率和 mAP@50 分别达到了 94.3%、91.6% 和 92.5%, 其中精确率保持与 YOLOv8 相当水平, 召回率和 mAP@50 分别提升了 1.3% 和 1.2%。相比之下, GRCP-YOLOv8 模型在计算复杂度和参数量上分别降低了 39% 和 27%, 更容易部署到计算资

源受限的移动设备和边缘设备上。

当前的网络改进缺少损失函数,且只对颈部网络的结构做了些许改进,并未改进颈部网络中的各个模块,这表明在特定任务中还有进一步提升的空间。此外,GRCP-YOLOv8模型的评估仅限于本研究自制的数据集。为了全面评估网络在实际应用场景中的表现,应采集实际现场环境中各个工况下的图片来制作数据集进行进一步的评估,验证检测模型的泛化性能。

参考文献

- [1] 李俊,袁亮,冉腾. 基于YOLOv4的指针式仪表自动检测和读数方法研究[J]. 机电工程, 2021, 38(7): 912-917.
LI J, YUAN L, RAN T. Automatic detection and reading method of pointer instrument based on YOLOv4 [J]. Journal of Mechanical & Electrical Engineering, 2021, 38(7): 912-917.
- [2] 毛爱坤,刘昕明,陈文壮,等. 改进YOLOv5算法的变电站仪表目标检测方法[J]. 图学学报, 2023, 44(3): 448-455.
MAO AI K, LIU X M, CHEN W ZH, et al. Improved substation instrument target detection method for YOLOv5 algorithm [J]. Journal of Graphics, 2023, 44(3): 448-455.
- [3] 苑玮琦,刘文滔,李绍丽. 基于特征表征与学习反馈的动态带钢缺陷样本筛选方法[J]. 仪器仪表学报, 2025, 46(4): 240-250.
YUAN W Q, LIU W T, LI SH L. A dynamic sample selection method for steel strip defects based on feature representation and learning feedback [J]. Chinese Journal of Scientific Instrument, 2025, 46(4): 240-250.
- [4] SALANGHOUCHE S H, KABIR E, FAKHIMI A. Finding particle size distribution from soil images using circular Hough transform [J]. International Journal of Civil Engineering, 2025, 23: 1521-1533.
- [5] 崔建国,孙长库,李玉鹏,等. 基于SURF的快速图像匹配改进算法[J]. 仪器仪表学报, 2022, 43(8): 47-53.
CUI J G, SUN CH K, LI Y P, et al. An improved algorithm for fast image matching based on SURF[J]. Chinese Journal of Scientific Instrument, 2022, 43(8): 47-53.
- [6] AROOJ S, ALTAF S, AHMAD S, et al. Enhancing sign language recognition using CNN and SIFT: A case study on Pakistan sign language[J]. Journal of King Saud University-Computer and Information Sciences, 2024, 36(2): 101934.
- [7] 李淳,胡越,鞠宽,等. 基于载荷谱分析和混合深度学习车载储氢气瓶路况载荷模式识别[J]. 噪声与振动控制, 2024, 44(4): 205-210,277.
LI CH, HU Y, JU K, et al. Road load pattern recognition for vehicle-loaded Hydrogen storage cylinders based on load spectrum analysis and hybrid deep learning[J]. Noise and Vibration Control, 2024, 44(4): 205-210,277.
- [8] 刘鸿达,孙旭辉,李浙滨,等. 基于卷积神经网络的图像分类深度学习模型综述[J]. 计算机工程与应用, 2025, 61(11): 1-21.
LIU H D, SUN X H, LI Y B, et al. Review of deep learning models for image classification based on convolutional neural networks [J]. Computer Engineering and Applications, 2025, 61(11): 1-21.
- [9] KONG X H, LI X J, ZHU X X, et al. Detection model based on improved faster-RCNN in apple orchard environment [J]. Intelligent Systems with Applications, 2024, 21: 200325.
- [10] HUSSAIN M. YOLOv1 to v8: Unveiling each variant-a comprehensive review of YOLO[J]. IEEE Access, 2024, 12: 42816-42833.
- [11] GUO W J, FENG SH, FENG Q, et al. Cotton leaf disease detection method based on improved SSD[J]. International Journal of Agricultural and Biological Engineering, 2024, 17(2): 211-220.
- [12] 陈开峰,俞伟聪,唐雁文,等. 基于轻量化深度神经网络的数字仪表识别[J]. 科学技术与工程, 2023, 23(2): 674-680.
CHEN K F, YU W C, TANG Y W, et al. Digital instrument recognition based on lightweight deep learning network[J]. Science Technology and Engineering, 2023, 23(2): 674-680.
- [13] 邢浩强,杜志岐,苏波. 变电站指针式仪表检测与识别方法[J]. 仪器仪表学报, 2017, 38(11): 2813-2821.
XING H Q, DU ZH Q, SU B. Detection and recognition method for pointer-type meter in transforme substation[J]. Chinese Journal of Scientific Instrument, 2017, 38(11): 2813-2821.
- [14] 刘家乐,吴怀宇,陈志环. 改进YOLOv3的工业指针式仪表检测方法[J]. 计算机工程与设计, 2021, 42(7): 2001-2008.
LIU J L, WU H Y, CHEN ZH H. Improved YOLOv3 industrial pointer instrument detection method[J]. Computer Engineering and Design, 2021, 42(7): 2001-2008.
- [15] 王飞,陈向俊. 基于Fast R-CNN和DeepLabV3+的变电站仪表盘示数自动识别方法[J]. 工程设计学报, 2024, 31(6): 750-756.
WANG F, CHEN X J. Automatic recognition method for substation meter panel readings based on Fast R-CNN and DeepLabV3+ [J]. Chinese Journal of Engineering Design, 2024, 31(6): 750-756.

- [16] 万吉林, 王慧芳, 管敏渊, 等. 基于 Faster R-CNN 和 U-Net 的变电站指针式仪表读数自动识别方法[J]. 电网技术, 2020, 44(8): 3097-3105.
WAN J L, WANG H F, GUAN M Y, et al. An automatic identification for reading of substation pointer-type meters using Faster R-CNN and U-Net[J]. Power System Technology 2020, 44(8): 3097-3105.
- [17] 李娜, 姜志, 王军, 等. 基于 Faster R-CNN 的仪表识别方法[J]. 液晶与显示, 2020, 35(12): 1291-1298.
LI N, JIANG ZH, WANG J, et al. Instrument recognition method based on Faster R-CNN [J]. Chinese Journal of Liquid Crystals and Displays, 2020, 35(12): 1291-1298.
- [18] 彭道刚, 黄孟俊, 威尔江, 等. 基于 YOLOv4 的火电厂指针仪表识别方法研究[J]. 计算机应用与软件, 2023, 40(6): 166-172, 222.
PENG D G, HUANG M J, QI ER J, et al. Pointer gauge recognition method of thermal power plant based on YOLOv4 [J]. Computer Applications and Software, 2023, 40(6): 166-172, 222.
- [19] 胡久松, 刘张弛, 余谦, 等. 融入 GhostNet 和 CBAM 的 YOLOv8 烟雾识别算法[J]. 电子测量与仪器学报, 2024, 38(8): 201-207.
HU J S, LIU ZH CH, YU Q, et al. YOLOv8 smoke detection algorithm integrated with GhostNet and CBAM[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(8): 201-207.
- [20] 陈俊生, 陈沂蒙, 刘明杰, 等. 基于 MFES-YOLOV8n 的光伏电池缺陷检测方法[J]. 仪器仪表学报, 2025, 46(6): 251-262.
CHEN J SH, CHEN Y M, LIU M J, et al. A defect detection method for photovoltaic cells based on MFES-YOLOV8n[J]. Chinese Journal of Scientific Instrument, 2025, 46(6): 251-262.
- [21] 王迎龙, 孙备, 丁冰, 等. BG-YOLO: 复杂大视场下低慢小无人机目标检测方法[J]. 仪器仪表学报, 2025, 46(2): 255-266.
WANG Y L, SUN B, DING B, et al. BG-YOLO: A low-altitude slow-moving small UAV targets detection method in complex large field of view[J]. Chinese Journal of Scientific Instrument, 2025, 46(2): 255-266.
- [22] LIU X Y, PENG H W, ZHENG N X, et al. Efficientvit: Memory efficient vision transformer with cascaded group attention[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 14420-14430.
- [23] ZHANG X, LIU CH, YANG D G, et al. RFACConv: Innovating spatial attention and standard convolutional operation[J]. ArXiv preprint arXiv:2304.03198, 2023.
- [24] ZHAO Y AN, LYU W Y, XU SH L, et al. DETRs beat YOLOs on real-time object detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 16965-16974.
- [25] DING X H, ZHANG X Y, MA N N, et al. RepVGG: Making VGG-style convnets great again[C]. IEEE/CVF Conference on Computer Vision and pattern Recognition, 2021: 13733-13742.
- [26] SHU Y, LIU SH H, XU H L, et al. Read pointer meters based on a human-like alignment and recognition algorithm[C]. CCF National Conference of Computer Applications. Singapore: Springer Nature Singapore, 2023: 162-178.
- [27] 张彼德, 王泽林, 廖其龙, 等. 基于轻量化改进 YOLOv8 的光伏阵列表面缺陷检测[J]. 电子测量与仪器学报, 2025, 39(6): 100-111.
ZHANG B D, WANG Z L, LIAO Q L, et al. Surface defect detection of photovoltaic array based on lightweight improvement of YOLOv8[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(6): 100-111.
- [28] 李绪涛, 邓耀华. 电池字符缺陷检测 DDP-YOLOv8 模型方法[J]. 电子测量与仪器学报, 2025, 39(6): 165-173.
LI X T, DENG Y H. DDP-YOLOv8 model for battery character defect detection [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(6): 165-173.
- [29] 王海群, 武泽镭, 晁帅. 改进 YOLOv8n 的遥感图像目标检测算法[J]. 电子测量与仪器学报, 2025, 39(4): 84-94.
WANG H Q, WU Z K, CHAO SH. Improve the YOLOv8n object detection algorithm for remote sensing images[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(4): 84-94.
- [30] 吴永泽, 俞建峰, 化春键, 等. 基于改进 YOLOv8n 的圆柱电池壳多维缺陷检测技术研究[J]. 电子测量与仪器学报, 2024, 38(12): 62-71.
WU Y Z, YU J F, HUA CH J, et al. Research on multi-dimensional defect detection technology for cylindrical battery shells based on improved YOLOv8n[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(12): 62-71.

作者简介

孙小龙, 硕士研究生, 主要研究方向为计算机视觉目标检测方向。

E-mail: s15349136144@163.com

许燕(通信作者), 教授, 博士生导师, 主要研究方向为智能农机与特种机器人。

E-mail: lilixiu_z@163.com