

DOI:10.19651/j.cnki.emt.2520167

基于 SRPMNet 的变电站指针式仪表检测模型^{*}李豪¹ 马振哲¹ 杨云云^{1,2} 李芝锐¹ 续欣莹¹

(1. 太原理工大学电气与动力工程学院 太原 030024; 2. 先进控制与工业智能山西省重点实验室 太原 030024)

摘要: 随着电力系统智能化与无人值守变电站的快速发展,智能巡检机器人在设备运行状态感知与安全监测中发挥着日益重要的作用。针对巡检机器人在光照条件复杂、目标尺度变化的变电站环境下,仪表检测过程中存在漏检、误检等问题,提出一种变电站智能巡检机器人指针式仪表检测模型(SRPMNet)。通过构建平均池化下采样(ADown)模块来降低计算复杂度,提升对小目标仪表的检测精度;并设计轻量级注意力机制,以突出关键特征信息并抑制无关背景干扰。为进一步提升变电站复杂环境下对指针式仪表检测的精度与特征表达能力,构建了辅助检测头策略。同时,在边界框回归过程中提出自适应完备损失函数(Wise-CIoU),以提高模型在变电站复杂背景下的定位精度与收敛稳定性。搭建了变电站智能巡检机器人平台进行数据采集,实验结果表明,该模型在自建变电站指针式仪表数据集及公开工业仪表数据集上的 mAP@0.5 指标分别达到了 91.7% 和 90.4%,相较于基线模型分别提升了 3.0% 和 5.3%,有效解决了漏检与误检问题,为变电站智能巡检任务提供了有效的技术支持。

关键词: 变电站智能巡检机器人;指针式仪表;目标检测;平均池化下采样;注意力机制;辅助检测头;Wise-CIoU

中图分类号: TN911.73 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Substation pointer meter detection model based on SRPMNet

Li Hao¹ Ma Zhenzhe¹ Yang Yunyun^{1,2} Li Zhirui¹ Xu Xinying¹

(1. College of Electrical and Power Engineering, Taiyuan University of Technology, Taiyuan 030024, China;

2. Shanxi Key Laboratory of Advanced Control and Industrial Intelligence, Taiyuan 030024, China)

Abstract: With the rapid development of power system intelligence and unattended substations, intelligent inspection robot play an increasingly important role in equipment operation state perception and safety monitoring. Aiming at the problems of missed detection and false detection in the meter detection process of the inspection robot in the substation environment with complex lighting conditions and changing target scales, this study proposes a pointer meter detection model of substation intelligent inspection robot (SRPMNet). By constructing the average pooling down sampling (ADown) module, the computational complexity is reduced and the detection accuracy of the small target meter is improved. A lightweight attention mechanism is designed to highlight key feature information and suppress irrelevant background interference. In order to further improve the accuracy and feature expression ability of pointer meter detection in complex environment of substation, this study constructs an auxiliary detection head strategy. At the same time, the wise complete intersection over union (Wise-CIoU) is proposed in the boundary frame regression process to improve the positioning accuracy and convergence stability of the model in the complex background of the substation. This study builds a substation intelligent inspection robot platform for data collection. The experimental results show that the mAP@0.5 index of the model on the self-built substation pointer meter dataset and the public industrial meter dataset reaches 91.7% and 90.4%, respectively, which is 3.0% and 5.3% higher than the baseline model. It effectively solves the problem of missed detection and false detection, and provides effective technical support for substation intelligent inspection tasks.

Keywords: substation intelligent inspection robot; pointer meter; object detection; average pooling down sampling; attention mechanism; auxiliary detection head; Wise-CIoU

0 引言

随着电力系统智能化与无人值守变电站的快速发展,

电力设备的运行监测与安全管控对供电系统的可靠性与稳定性起着至关重要的作用^[1]。变电站作为电网输配电的重要枢纽,其设备运行状态直接影响整个电力系统的安全水

收稿日期:2025-11-04

* 基金项目:国家自然科学基金(62006169)、虚拟现实技术与系统全国重点实验室开放课题基金(VRLAB2023A06)、山西省自然科学研究面上项目(202303021221002)资助

平。为确保设备长期稳定运行,巡检工作是必不可少的环节。而传统的人工巡检模式存在效率低、成本高等问题,且在高压、高温或恶劣气候条件下存在一定安全风险^[2]。近年来,变电站智能巡检机器人凭借其自主导航、环境感知与数据分析能力,成为替代人工巡检、实现无人值守和智能运维的重要手段。

为保证变电站的平稳运行,需要使用大量的仪表对变电站中的设备进行监测。虽然部分变电站已逐步引入数字仪表,但其存在建设周期长、设备成本高及兼容性问题,并且变电站内存在严重的电磁干扰,传统的指针式仪表由于具有结构简单、成本低、环境适应能力强、抗电磁干扰能力强等优势,仍然起着不可替代的作用^[3]。因此,准确检测与识别指针式仪表的状态,是变电站安全巡检任务中至关重要的环节。

然而,指针式仪表检测任务具有显著的复杂性与挑战性,主要表现为仪表类型和外观多样、光照条件复杂、目标尺度变化大以及背景干扰严重;同时,巡检机器人在不同角度与距离下采集的图像中,仪表目标通常占比很小且姿态多变。因此,智能巡检机器人在仪表检测过程中往往存在漏检、误检等问题^[4]。传统基于人工特征或传统图像处理的方法对光照与视角变化极为敏感,难以满足复杂变电站场景下的鲁棒性要求。

针对上述问题,已有相关研究在指针式仪表检测方面取得了一定进展。Gao 等^[5]利用加速鲁棒特征方法(speed up robust features, SURF)与模板图像进行匹配,从巡检机器人捕获的实时图像中检测仪表区域。邢浩强等^[6]提出一种完整的变电站指针式仪表的自动检测与识别方法,不依赖于预先获取的高质量图像,避免了前期复杂的仪表位置标定工作,可以在不同变电站中方便的迁移部署,满足变电站实际应用需求。徐发兵等^[7]采用改进的 YOLO 9000 网络快速检测仪表表盘框的位置,有效去除冗余背景信息的干扰。Liu 等^[8]采用两阶段目标检测算法 Faster R-CNN 来检测目标仪表的位置。陈方彬等^[9]提出一种轻量化智能电能表目标检测算法,能够满足电力现场巡检实时性需求。胡欣等^[10]提出变电站指针式仪表识别模型 YOLOv5s-BCGS,将路径聚合网络替换为加权双向特征金字塔网络,以更好地融合特征图中的位置与细节信息。范新南等^[11]采用 MobileNetV3 作为主干特征提取网络,并引入深度可分离卷积,利用 TensorRT 对模型进行优化,使其更适用于性能有限的嵌入式设备中。何敏等^[12]提出一种基于轻量级 YOLOX 网络的电力仪表图像识别方法,将空间金字塔池化结构融入到 Transformer 计算中,通过全局感受野下的 Transformer 进行整体目标定位,实现仪表的细粒度特征定位。Soudeep 等^[13]将动态图神经网络 DGNNs 与 YOLO11 相结合,构建随时间更新的图结构以表达对象间交互与上下文关系,增强对小尺度、遮挡目标的检测与跟踪能力。Li 等^[14]提出以 Transformer 为基础的单视觉模型

SVDIR 用于仪表读数识别,通过注意力机制实现对表盘或刻度局部细节的全局上下文建模,减弱局部噪声对判别的影响。Shehzadi 等^[15]提出一种新型的端到端半监督目标检测模型,显著改善基于 Transformer 的检测器在小目标与遮挡目标上的学习效率与伪标签质量。Wu 等^[16]提出动态稀疏注意力策略 DSAT,结合分层特征融合以在保证计算效率的同时选择性聚焦多尺度目标区域,提升对小尺度与弱对比目标的检测能力,对推动变电站智能化场景具有很好的借鉴作用。

现有指针式仪表检测研究虽在检测精度与实时性方面取得了一定进展,但多数方法仍存在对光照干扰与复杂背景适应性不足的问题。同时,现有模型在小目标仪表检测方面的能力有限,难以满足无人值守变电站环境下对指针式仪表检测的实际需求。因此,研究一种具备高鲁棒性、高精度的指针式仪表检测模型具有重要的工程应用价值与现实意义。

针对上述问题与挑战,本研究旨在提出一种新颖的变电站智能巡检机器人指针式仪表检测网络(pointer meter detection network of intelligent inspection robot for substation, SRPMNet),专门用于变电站智能机器人巡检任务。该模型的核心目标是有效应对变电站环境中光照干扰强、背景复杂、目标尺度差异大等问题,从而提升对不同尺寸与姿态的仪表的检测精度与鲁棒性。本研究期望通过该模型为变电站智能巡检提供高效、稳定的技术支撑,助力电力系统的自动化与智能化发展。

1 模型与方法

1.1 网络模型总体结构设计

变电站智能巡检机器人采集的指针式仪表图像通常具有光照干扰强、背景复杂以及目标尺度差异大的特点。实际巡检场景中,仪表表盘的关键判别信息主要集中于刻度线、指针和边缘轮廓等细粒度结构。在深度网络多次下采样与特征聚合过程中,这类小目标易发生特征退化,从而导致漏检和定位不稳定等问题,通用目标检测模型在复杂变电站场景下仍存在一定局限性。

因此,本文提出一种变电站智能巡检机器人指针式仪表检测模型 SRPMNet,其总体结构如图 1 所示。该模型以 YOLOv12^[17] 目标检测框架为基础,在保持其端到端高效检测优势的前提下,围绕复杂变电站环境下小目标特征保持与鲁棒检测需求,从特征下采样、注意力建模、监督策略以及回归优化等关键环节进行针对性设计。

SRPMNet 在骨干网络中构建平均池化下采样(average pooling down sampling, ADown)模块,通过融合全局统计特征与局部显著响应,缓解传统下采样操作对小目标细节信息的过度压缩问题;在特征增强阶段设计轻量级注意力机制,以自适应强化与仪表表盘相关的判别特征,抑制复杂背景干扰。在检测阶段,模型构建主-辅双检测头




图 1 SRPMNet 模型框架结构

Fig. 1 The model framework of SRPMNet

结构,通过多层监督引导网络在浅层与中层阶段充分学习表盘结构特征,从而提升小目标检测的稳定性与精度。同时,在边界框回归过程中提出自适应完备损失函数(wise complete intersection over union, Wise-CIoU),以有效提高仪表目标的定位精度与训练收敛稳定性,从而实现了在变电站复杂环境下对指针式仪表目标的精准检测。

1.2 平均池化下采样模块

在室外变电站巡检场景中,严重光照干扰、强反射以及背景结构复杂等因素使得指针式仪表在图像中通常呈现为小尺寸、低对比度的目标。在骨干网络特征提取过程中,下采样操作虽然能够有效降低特征图分辨率并扩大感受野,但同时也是导致小目标关键结构信息退化的主要原因之一。传统依赖步幅卷积或最大池化的下采样方式,在压缩特征空间时往往过度关注局部极值响应,对光照变化和噪声较为敏感,容易放大非目标区域的高响应,从而削弱仪表表盘等低频结构特征,最终导致漏检或误检问题。

针对上述特征退化现象,本文从下采样机理出发,构建一种 ADown 模块来替代骨干网络中的传统卷积,在下采样阶段通过融合不同统计特性的特征表示,提升小目标特征在尺度压缩过程中的稳定性,其框架结构如图 2 所示。ADown 集成了平均池化和最大池化,以在保留显著细节的同时保留全局上下文^[18]。

该模块的核心思想是通过多路径、异构的特征融合方式,在实现空间下采样的同时保留丰富的语义信息与纹理

细节。给定输入特征图 $\mathbf{X}$, 首先采用二维平均池化对其进行下采样处理,以抑制高频噪声并保留具有全局一致性的低频结构信息,从而增强对仪表表盘整体形态的建模能力,其过程如式(1)所示。

$$\mathbf{X}_{\text{avg}} = \text{AvgPool2d}(\mathbf{X}) \quad (1)$$

其次,将特征图划分为 $\mathbf{X}_1$ 和 $\mathbf{X}_2$ 两个并行分支。 $\mathbf{X}_1$ 分支通过二维最大池化处理,保留局部显著响应,再通过 1×1 卷积层提取图像特征,来补充判别性较强的局部特征:

$$\mathbf{Y}_1 = \text{Conv}(\text{MaxPool2d}(\mathbf{X}_1)) \quad (2)$$

$\mathbf{X}_2$ 分支则通过 3×3 卷积层直接执行空间下采样,压缩特征图的空间维度,以增强对仪表指针、刻度线等纹理细节和边缘结构的表征能力:

$$\mathbf{Y}_2 = \text{Conv}(\mathbf{X}_2) \quad (3)$$

最终,两个分支沿着通道维度进行拼接并输出,形成融合全局统计特征与局部判别特征的下采样结果,如式(4)所示。

$$\mathbf{Y} = \text{Concat}(\mathbf{Y}_1, \mathbf{Y}_2) = \text{Concat}(\text{Conv}(\text{MaxPool2d}(\mathbf{X}_1)), \text{Conv}(\mathbf{X}_2)) \quad (4)$$

该双分支结构采用异构采样策略^[19],在实现有效降维的同时,降低了下采样过程中信息分布的不稳定性,使网络在复杂变电站环境下能够更好地保持指针式仪表小目标的关键结构特征,为后续特征增强与检测阶段提供更加稳定的输入表示。




图 2 平均池化下采样模块结构

Fig. 2 The average pooling down sampling module structure

1.3 轻量级注意力模块

在变电站巡检场景中,指针式仪表常处于光照干扰严重、背景纹理复杂且目标与背景视觉相似度较高的环境中,仅依赖卷积操作提取特征,容易导致目标区域与干扰区域响应混杂,从而降低模型对关键结构的判别能力。因此,在特征增强阶段设计合理的注意力建模机制,是提升复杂环境下仪表检测鲁棒性的有效途径。

现有的注意力模块如 SE^[20]、CBAM^[21]、ECA^[22] 等通常沿通道或空间维度对特征进行加权,其隐含假设是不同维度之间相互独立:通道注意力在同一通道内对所有空间位置赋予相同权重;空间注意力则对不同通道采用统一的空间权重,这种注意力建模方式在处理指针式仪表这类结构细粒度且空间-语义高度耦合的工业目标时,容易限制特征区分能力,难以同时刻画刻度、指针与局部反光等复杂响应特征。

基于上述分析,本文设计了一种基于神经元能量建模的轻量级注意力模块(simple attention module, SimAM),其框架结构如图 3 所示,该模块无需额外参数,而是受神经科学中“空域抑制”机理启发^[23],通过评估特征图中每个神经元在空间和通道维度上的能量密度,自适应衡量其重要性,从而实现跨通道与空间维度的三维注意力加权。此

建模方式避免了对注意力维度的先验假设,更适合刻画复杂变电站场景中目标与背景之间的细微差异。




图 3 轻量级注意力模块结构

Fig. 3 The simple attention module structure

该模块的核心思想是通过计算特征图中每个通道的全局平均池化值,来捕捉通道间重要信息。然后将得到的通道注意力权重与原始特征图相乘,从而实现对特征图的加权调整。SimAM 的能量函数为:

$$e_i(w_i, b_i, y, x_i) = \frac{1}{M-1} \sum_{i=1}^{M-1} (-1 - (w_i x_i + b_i))^2 + (1 - (w_i t + b_i))^2 + \lambda w_i^2 \quad (5)$$

其中, t 和 x_i 分别为在输入特征 $\mathbf{X} \in \mathbf{R}^{C \times H \times W}$ 中目标神经元和单个输入特征通道的其他神经元, w_i 为训练权重, b_i 为偏置,每个通道具有 $M = H \times W$ 个能量函数,其解析解为:

$$w_i = -\frac{2(t - \mu_i)}{(t - \mu_i)^2 + 2\sigma_i^2 + 2\lambda} \quad (6)$$

$$b_i = -\frac{1}{2}(t + \mu_i)w_i \quad (7)$$

其中, $\mu_i = \frac{1}{M-1} \sum_{i=1}^{M-1} x_i$, $\sigma_i^2 = \frac{1}{M-1} \sum_{i=1}^{M-1} (x_i - \mu_i)^2$, μ_i 与 σ_i 是目标神经元与周围神经元的均值与方差,神经元的线性可分性可通过求得能量最小值得到:

$$e_i^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(t - \hat{\mu})^2 + 2\hat{\sigma}^2 + 2\lambda} \quad (8)$$

由上述公式可得,能量越低,神经元 t 与周围神经元的差异越显著,其重要性越高。因此将神经元的重要性定义为 $1/e_i^*$ 。为了更有效地关注关键特征,注意力机制必须增强这些特征。这个过程有助于增加网络对输入数据的注意力,使其能够更好地理解和利用关键信息,增强过程如式(9)所示。

$$\tilde{\mathbf{X}} = \text{sigmoid}\left(\frac{1}{E}\right) \odot \mathbf{X} \quad (9)$$

其中, E 为跨通道与空间维度的 e_i^* 的集合。

通过设计 SimAM 模块,网络能够在不增加模型复杂

度的前提下,自适应强化与指针式仪表表盘、刻度及指针相关的关键结构特征,同时有效抑制复杂背景和光照干扰带来的无关响应,为后续检测头提供更加清晰且具有判别性的特征表示。

1.4 辅助检测头策略

在复杂变电站环境中进行指针式仪表检测任务时,表盘区域往往受到光照不均、反光、污渍以及局部遮挡等因素影响,其关键结构特征在特征提取过程中容易被削弱。尤其是在深层目标检测网络中,随着网络深度的增加,浅层所包含的边缘轮廓、刻度线等细粒度信息易被高层语义特征所掩盖,从而导致模型在小尺度仪表检测任务中出现定位不稳定或漏检现象。

现有检测模型通常仅在最终检测头阶段对预测结果施加监督约束,这种单一监督方式在复杂变电站场景下难以保证中浅层特征对目标结构的充分表达^[24]。针对这一问题,本文从特征学习机制角度出发,提出一种辅助检测头驱动的渐进式特征学习策略,在主检测头之外构建辅助检测分支 DetectAux,其总体框架结构如图 4 所示。该策略的核心目的并非简单增加检测头数量,而是通过在特征金字塔的中间层引入额外监督信号,引导网络在早期阶段即关注指针式仪表表盘的几何结构与局部纹理特征。




图 4 辅助检测头框架结构

Fig. 4 The auxiliary detection head framework

DetectAux 在训练阶段与主检测头并行工作,对中层特征图进行目标定位与分类监督,使网络在浅层和中层阶段逐步形成对表盘区域的判别性表示。辅助检测头中的 Assigner 采用动态匹配策略,根据预测结果与真实标注之间的统计特性自适应调整匹配阈值,并摒弃传统基于固定锚框尺度的约束方式,直接基于特征点生成预测框。这种设计能够有效避免由于仪表表盘宽高比变化较大而引起的定位偏差,同时结合 Loss 对边界框坐标分布的精细化学习,提升表盘区域关键结构的定位精度。

通过构建 DetectAux 辅助检测头,网络在训练过程中为主干网络(Backbone)提供更加直接且稳定的梯度引导,

有效缓解了深层网络中浅层特征退化和梯度衰减的问题,从而增强了模型对不同尺寸、姿态、角度条件下指针式仪表的适应能力;在推理阶段,主检测头与辅助检测头的预测结果形成互补,进一步提升了复杂变电站环境下仪表检测的准确性与鲁棒性。

1.5 自适应完备损失函数

在变电站指针式仪表检测任务中,表盘目标在尺度、完整性及可见性方面存在显著差异,尤其是在小尺度、局部遮挡或边界模糊情况下,边界框回归过程容易出现梯度震荡与定位不稳定等问题。现有 IoU 系列损失函数如 GIoU^[25]、DiIoU^[26]、EIoU^[27]等,尽管在一定程度上缓解了仅以重叠区域为衡量标准的局限性,但仍存在收敛速度慢、定位不稳定以及尺度适应性不足等问题。

针对上述问题,本文从回归误差建模与梯度分配机制角度出发,提出 Wise-CIoU。该损失函数并非简单叠加几何约束项,而是在 CIoU 的基础上引入基于预测框质量的动态加权机制,使模型在训练过程中能够自适应调整不同预测样本对回归优化的贡献,从而提升边界框回归的稳定性与精度。

Wise-CIoU 以 CIoU 为基础损失项,引入来自 Wise-IoU 的动态权重因子,对不同预测框施加差异化约束。即在 Wise-IoU^[28]损失函数的基础上,进一步扩展 CIoU 为 $L_{\text{CIoU}}^{\text{Wise}}$,以该损失函数平衡了准确性和稳定性,其公式定义为:

$$L_{\text{CIoU}}^{\text{Wise}} = R_{\text{CIoU}} L_{\text{mIoU}} \quad (10)$$

其中, L_{mIoU} 根据多个预测框和真实框的平均 IoU 计算得到。Wise-IoU 损失引入了一个额外的动态因子 β ,用于平衡多目标检测场景中不同目标的重要性,该动态权重进一步通过式(11)进行自适应调节,使高质量预测框在训练后期获得更精细的回归约束,而低质量预测框在训练早期仍能获得足够的梯度引导。

$$\beta = \frac{L_{\text{mIoU}}}{L_{\text{IoU}}} \quad (11)$$

在此基础上,Wise-CIoU 损失函数的最终表达式为:

$$L_{\text{Wise-CIoU}} = \frac{L_{\text{CIoU}}^{\text{Wise}}}{\gamma \alpha^r} \quad (12)$$

其中, γ 、 α 和 r 是控制损失动态调整的超参数,确保边界框中心距离、尺度一致性及纵横比约束之间的协同优化。通过上述自适应机制,Wise-CIoU 在保持 CIoU 几何完备性的同时,有效缓解了不同尺度仪表目标在回归过程中的优化不均衡问题。Wise-CIoU 通过在损失函数层面对边界框回归过程进行动态建模,使模型能够根据预测框质量自适应分配优化重点,从而在复杂变电站环境下显著提升指针式仪表检测任务中的定位精度。

2 实验与结果分析

2.1 变电站智能巡检机器人平台

针对变电站指针式仪表检测任务中缺乏真实复杂环

境下专用数据集的问题,本研究搭建了基于多传感器融合的智能巡检机器人实验平台,以获取并构建高质量的指针式仪表数据资源,为模型训练与性能验证提供有效支撑,机器人平台实物如图 5 所示。



图 5 变电站智能巡检机器人平台

Fig. 5 The substation intelligent inspection robot platform

智能巡检机器人平台以实验室自动驾驶底盘为基础,进行了多传感器系统集成与结构优化设计。平台集成了 Livox Mid-360 多线激光雷达、RealSense D435i 深度相机、ZED 2i 双目相机、RPLIDAR-A2 单线激光雷达、高精度云台以及基于 NVIDIA 的边缘计算设备。通过自主设计的支架结构与电气系统,实现了各种传感器的稳固安装、电源管理与数据通信。该机器人平台能够在变电站复杂环境中高效采集大量指针式仪表图像数据,为本文所提出的指针式仪表检测模型的训练与性能评估提供了有效的数据支撑。

2.2 数据集与评价指标

1) 数据集

由于缺乏公开且适用于变电站真实复杂环境的专用仪表数据集,本研究构建了变电站指针式仪表数据集(substation pointer meter dataset, SPMD),用于验证本文所提算法的性能。另外,为了验证所提算法的泛化性能,本文进一步在公开工业仪表数据集(industrial meter dataset, IMD)上进行了实验验证。关于数据集的具体情况如下:

(1) 变电站指针式仪表数据集 SPMD: 以上述搭建的变电站智能巡检机器人作为数据采集平台,利用机器人上搭载的 RealSense D435i 深度相机作为数据采集设备,通过从变电站现场采集与网络公开数据中搜集,最终筛选出合适的指针式仪表图像数据并使用 LabelImg 工具对其进行

标注,构建了 SPMD 数据集。该数据集中包含 1 314 张图像,均为 JPG 格式,分辨率为 640×480 。为了确保训练过程中的数据分布和泛化能力,将数据集按 3:1:1 的比例随机划分为训练集、验证集、测试集,分别用于模型的训练、验证和测试。

(2) 工业仪表数据集 IMD: 该数据集来源于真实工业场景,包含 2 136 张仪表图像,涵盖多种仪表类型与尺寸,具有丰富的拍摄角度、光照条件和背景变化,能够充分反映工业现场的复杂视觉特征,其中 1 973 张图像用于训练、163 张图像用于验证。

2) 评价指标

为了综合评估所提模型在变电站指针式仪表检测任务中的性能,本文采用了 Lin 等^[29]提出的在目标检测任务中广泛使用的几个评价指标,包括平均精确率 $mAP@0.5$ 、 $mAP@0.5:0.95$ 、精确率 (precision, P)、召回率 (recall, R)、 F_1 值 (F_1 score)。此外,采用模型参数量 (Params) 评估模型大小与复杂度,采用帧率 (frames per second, FPS) 评估模型推理速度与实时性。 mAP 、 P 、 R 、 F_1 的计算公式如下:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (13)$$

$$P = \frac{TP}{TP + FP} \quad (14)$$

$$R = \frac{TP}{TP + FN} \quad (15)$$

$$F_1 = \frac{2 \times P \times R}{P + R} \quad (16)$$

其中, N 为检测类别的总数; AP 表示不同召回率下的精度平均值; mAP 是所有类别平均精度的平均值,用于评估模型的整体性能, mAP 越大,表示模型定位与检测的准确率越高; TP 代表预测为正样本并且预测正确的样本数量; FP 代表预测为正样本,但是实际上是负样本的样本数量; FN 代表实际为正样本,但是预测为负样本的样本数量; 精确率 P 表示模型预测的所有仪表样本中,正确预测为仪表的比例; 召回率 R 表示所有实际仪表样本中,正确预测为仪表的比例; F_1 值是精确率和召回率的调和平均值,用于综合评估模型的精确性和召回能力。

2.3 实验环境与参数设置

为了确保评估的公平性和可重复性,所有实验均使用 PyTorch 2.2.2 深度学习框架,环境语言为 Python 3.10,并采用 CUDA 12.1 提供的 GPU 加速,模型训练在运行 Linux 操作系统的高性能计算平台上进行,硬件配置包括具有 12 G 显存的 NVIDIA GeForce RTX 3060 GPU,可实现深度神经网络的高效训练和推理。

训练采用随机梯度下降优化器,动量设置为 0.937,共迭代 150 个周期 (Epoch),批量大小 (Batch Size) 设置为 32,将输入图像统一调整为 640×640 尺寸后做归一化处理。初始学习率设置为 0.01,权重衰减系数为 0.000 5。

为保证收敛稳定性,训练过程集成了 warm-up 及学习率动态调整策略。当损失和 mAP 均收敛时,采用提前停止机制,以防止过拟合,提高泛化性能。

为减小随机初始化和训练过程不确定性对实验结果的影响,本文在相同实验环境配置下对主要实验结果进行了多次独立重复验证,以关注模型性能提升在不同训练过程中的一致性 & 稳定性。

表 1 不同模型在 SPMD 数据集上的性能比较

Table 1 Performance comparison of different models on the SPMD dataset

模型	$P/\%$	$R/\%$	mAP@0.5/%	mAP@0.5;0.95/%	$F_1/\%$	Params/($\times 10^6$)	FPS/fps
YOLOv5	91.7	86.7	91.4	68.6	89.1	2.5	81.6
YOLOv8	95.3	82.1	90.4	67.5	88.2	3.0	80.9
YOLOv10	89.1	81.2	86.4	63.5	84.9	2.7	77.6
YOLOv11	95.1	81.2	88.7	64.4	87.6	2.6	78.3
YOLOv12	91.7	80.1	87.7	62.3	85.5	2.5	75.8
SRPMNet	94.0	86.9	91.7	65.8	90.3	2.5	72.4

实验结果表明,SRPMNet 在多个关键指标上均表现出稳定且一致的性能优势。与基线模型 YOLOv12 相比,SRPMNet 模型的精确率提升了 2.3%,召回率提升了 6.8%,其中 mAP@0.5 提高了 3.0%,mAP@0.5;0.95 提高了 3.5%。SRPMNet 在几乎所有指标上均达到了最先进的检测性能,其精确率仅略低于 YOLOv8 和 YOLOv11,但在召回率上显著优于所有对比算法,说明本文所提方法有效增强了模型的整体检测覆盖率,显著减少了仪表检测过程中的漏检情况。在模型参数量基本保持不变的情况下,实现了检测精度的有效提升,同时推理速度仍能满足智能巡检机器人在变电站环境下的实时性检测需求。

定性对比结果如图 6 所示。根据可视化结果,在光照条件复杂、目标尺度变化的复杂变电站环境下,本文提出

2.4 模型对比实验

为全面评估本文提出的 SRPMNet 模型在变电站复杂环境下的指针式仪表检测性能,本文在相同的实验环境下,将 SRPMNet 在自建 SPMD 数据集上与多种先进且具有代表性的目标检测算法进行了对比实验,包括 YOLOv5、YOLOv8^[30]、YOLOv10^[31]、YOLOv11^[32] 和 YOLOv12,实验结果如表 1 所示。

的 SRPMNet 模型能够在多种复杂条件下保持稳定的指针式仪表目标检测性能,表现出良好的鲁棒性与泛化能力,有效解决了现有方法在仪表检测过程中易出现的漏检与误检问题。为智能巡检机器人在变电站复杂环境下实现高精度仪表检测提供了可靠的技术支持。

2.5 消融实验与分析

1) 模块消融实验

为验证本研究中各个改进模块的有效性及其协同作用,本文在自建 SPMD 数据集上进行了一系列消融实验。所有实验均以 YOLOv12 为基线模型(Baseline),在相同的实验环境配置下,分别引入 ADown 模块、辅助检测头、SimAM、Wise-CIoU 单个模块及不同模块组合,以分析各模块对模型性能的独立贡献与协同效果。具体实验结果如表 2 所示,其中“√”表示当前模型中使用了对应模块。






图 6 指针式仪表检测可视化结果
Fig. 6 The visualization results of pointer meter detection

表 2 各模块消融实验
Table 2 Ablation experiment of each module

Adown	DetectAux	SimAM	Wise-ClIoU	P/%	R/%	mAP@0.5/%	mAP@0.5:0.95/%	F_1 /%	Params/ ($\times 10^6$)	FPS/fps
		Baseline		91.7	80.1	87.7	62.3	85.5	2.5	75.8
✓				88.7	84.4	88.5	63.4	86.5	2.1	78.9
	✓			91.5	83.5	89.4	62.1	87.3	3.0	69.2
		✓		91.0	81.4	90.1	62.9	85.9	2.5	73.4
			✓	92.3	81.2	89.3	62.5	86.4	2.5	75.6
✓	✓			93.9	85.2	91.0	65.2	89.3	2.5	72.8
✓		✓		93.2	82.1	90.6	65.7	87.3	2.1	76.0
✓			✓	89.3	84.4	90.2	63.1	86.8	2.1	78.5
✓	✓	✓		93.6	85.1	91.6	65.9	89.1	2.5	71.2
✓	✓	✓	✓	94.0	86.9	91.7	65.8	90.3	2.5	72.4

实验结果表明,各个改进模块的引入均有效提升了模型的检测性能。基线模型在精确率、召回率和 F_1 值上分别为 91.7%、80.1% 和 85.5%,整体表现尚可,但在复杂背景下存在漏检和边界定位不准的问题。从特征下采样角度分析,当仅引入 ADown 模块时,模型的召回率显著提升至 84.4%,说明该模块能够有效降低特征下采样过程中细节信息的损失,从而增强对小尺寸仪表目标的感知能力。在同时引入 ADown 模块与辅助检测头后,精确率提升至 93.9%,mAP@0.5 提高至 91.0%,表明多检测头结构有效融合了深层与浅层特征信息,增强了模型在多尺度目标检测中的表现。从特征增强角度考虑,再引入 SimAM 后,模型的 mAP@0.5 和 mAP@0.5:0.95 分别进一步提升至 91.6% 和 65.9%,说明该机制能够突出仪表关键区域的特征响应,抑制无关背景信息,使模型在复杂光照、反射及遮

挡条件下仍能保持稳定的检测性能。在同时引入所有模块的情况下,当多个模块协同作用时,模型的整体性能达到最优,精确率提升至 94.0%,召回率提高至 86.9%,mAP@0.5 达到 91.7%, F_1 值提升至 90.3%。该损失函数通过在回归过程中引入动态权重分配,使得模型能够更准确地拟合不同尺度目标的边界框,显著提升了定位精度与收敛稳定性。

为进一步分析不同模块对模型的影响,本文绘制了多种消融模型训练过程中的 mAP@0.5-Epoch 学习曲线,如图 7 所示,结果表明,相较于基线模型,SRPMNet 在训练早期取得了更高的检测精度,并在中后期保持更加平稳的收敛趋势,未出现过拟合现象,证明不同模块具有良好的协同作用与训练稳定性。

综合来看,各模块之间在不同层面形成了有效的互补




图 7 消融实验学习曲线

Fig. 7 The ablation experiment learning curve

与协同作用。ADown 模块增强了特征表达的完整性, DetectAux 改善了多尺度融合效果, SimAM 注意力机制强化了特征聚焦能力, 而 Wise-CIoU 损失函数进一步优化了边界框回归过程。最终融合全部改进模块的 SRPMNet 模型在各项指标上均取得最优表现, 表现出较高的检测精度与稳定性, 说明各模块之间具有良好的协同作用, 有效提升了模型在复杂变电站环境下的整体检测性能。

2)注意力模块对比实验

在上述消融实验中, 通过引入 SimAM, 模型在检测精度取得了一定提升。为进一步验证 SimAM 模块在本研究任务中的有效性, 本文在基线模型中加入 ADown 与 DetectAux 的基础上, 将 SimAM 与其他常用注意力模块进行横向对比, 包括 CPCA^[33]、MLCA^[34]、MPCA^[35] 以及 Triplet Attention^[36], 实验结果如表 3 所示。

表 3 不同注意力模块对比

Table 3 Comparison of different attention modules

(%)				
注意力模块	<i>P</i>	<i>R</i>	mAP@0.5	mAP@0.5:0.95
CPCA	94.7	84.0	90.6	65.1
MLCA	97.5	81.9	89.8	64.9
MPCA	96.2	82.7	89.6	64.9
Triplet Attention	96.9	83.3	90.7	64.5
SimAM	93.6	85.1	91.6	65.9

不同注意力模块均在一定程度上提升了模型性能, 但提升幅度存在差异。SimAM 模块在 mAP@0.5 和 mAP@0.5:0.95 指标上分别达到 91.6% 和 65.9%, 均为最高值, 说明其在提升检测精度和模型泛化性方面效果最为显著。SimAM 在保持较高精确率的同时, 召回率提升至 85.1%, 实现了更好的检测平衡性。由此可见, SimAM 在综合性能上优于其他注意力模块, 能够有效突出关键特征区域并抑制背景干扰, 使模型在复杂场景下的检测能力更为稳定可靠。

3)损失函数对比实验

为进一步验证所提出的 Wise-CIoU 的有效性, 本文在基线模型中加入 ADown, DetectAux 与 SimAM 的基础上, 对比了不同边界框回归损失函数的检测性能, 实验结果如表 4 所示。

表 4 不同损失函数对比

Table 4 Comparison of different loss functions

(%)				
损失函数	<i>P</i>	<i>R</i>	mAP@0.5	mAP@0.5:0.95
WISE-IOU	93.4	82.7	90.1	65.1
WISE-DIOU	95.6	84.1	91.1	66.0
WISE-EIOU	92.0	85.0	90.6	65.2
WISE-GIOU	95.5	85.5	90.9	64.6
WISE-CIoU	94.0	86.9	91.7	65.8

不同损失函数对模型性能的影响存在明显差异。Wise-CIoU 在召回率(86.9%)与 mAP@0.5(91.7%)方面均取得最优表现, 同时在 mAP@0.5:0.95 指标上也达到最高值(65.8%), 由此可知, 损失函数 Wise-CIoU 相较于其他损失函数更能够提升边界框精度, 增强模型对变电站指针式仪表的检测能力。

2.6 泛化实验

为了进一步验证所提变电站智能巡检机器人指针式仪表检测模型 SRPMNet 的鲁棒性和泛化性能, 将 SRPMNet 模型在公开工业仪表 IMD 数据集上进行实验。

IMD 数据集与室外变电站场景存在一定差异。变电站指针式仪表检测通常面临光照干扰、背景复杂、目标尺度小且姿态多变等挑战, 而该数据集主要来源于室内工业环境, 整体光照条件相对稳定, 但其涵盖多种工业场景下的不同类型仪表, 结构差异明显, 拍摄角度、成像距离及背景环境变化较大, 部分图像存在遮挡、反射及复杂纹理干扰, 对模型的特征泛化能力和跨场景适应能力提出较高要求。

在相同的实验环境下, 分别采用 YOLOv5、YOLOv8、YOLOv10、YOLOv11、YOLOv12 算法与所提 SRPMNet 模型进行对比实验, 实验结果如表 5 所示。

实验结果表明, 公开工业仪表 IMD 数据集上, SRPMNet 相较于基线模型始终保持了稳定且一致的性能优势。SRPMNet 的精确率提升了 1.8%, 召回率提升了 8.5%, 其中 mAP@0.5 提高了 5.3%, mAP@0.5:0.95 提高了 4.0%。SRPMNet 在精确率与召回率之间取得了良好的平衡, 说明其不仅能够准确检测工业仪表目标, 同时能够有效降低漏检率, 实现更全面的目标覆盖。

SRPMNet 在 IMD 数据集上的表现充分验证了其泛化能力与鲁棒性, 在模型参数量基本保持不变的情况下, 实现了检测精度的有效提升, 同时推理速度仍能满足复杂工业场景下的实时性检测需求。为智能巡检机器人在多

表 5 不同模型在 IMD 数据集上的性能比较

Table 5 Performance comparison of different models on the IMD dataset

模型	$P/\%$	$R/\%$	mAP@0.5/%	mAP@0.5:0.95/%	$F_1/\%$	Params/($\times 10^6$)	FPS/fps
YOLOv5	88.2	85.5	89.7	66.8	86.8	2.5	76.5
YOLOv8	92.5	79.3	87.3	64.1	85.4	3.0	75.4
YOLOv10	87.6	78.7	83.9	62.7	82.9	2.7	70.8
YOLOv11	91.7	80.6	88.2	61.8	85.8	2.6	72.2
YOLOv12	90.4	77.4	85.1	60.2	83.4	2.6	68.9
SRPMNet	92.2	85.9	90.4	64.2	88.9	2.5	66.7

样化工业环境下的指针式仪表检测提供了可靠技术保障。

3 结 论

本文针对变电站复杂环境下智能巡检机器人指针式仪表检测任务,提出了 SRPMNet 模型,有效解决了在小目标、光照干扰及复杂背景下存在的漏检和误检问题。该模型通过引入 ADown 模块提升小目标检测精度,利用轻量级注意力机制突出关键特征并抑制背景干扰,同时构建辅助检测头以增强特征表达能力,并采用 Wise-CIoU 优化边界框回归过程。实验结果表明,在自建变电站指针式仪表数据集及公开工业仪表数据集上,SRPMNet 在精确率、召回率及泛化性能方面均表现出显著优势。消融实验进一步验证了各模块的有效性与协同作用。综上所述,SRPMNet 具备优异的检测精度、鲁棒性和泛化能力,可为变电站无人值守智能巡检提供可靠的技术支撑。未来将进一步探索模型的轻量化与端侧部署,以提升其在变电站智能巡检机器人系统中的实时性能。

参考文献

[1] 张瑶,王傲寒,张宏. 中国智能电网发展综述[J]. 电力系统保护与控制, 2021, 49(5): 180-187.
Zhang Yao, Wang Aohan, Zhang Hong. Overview of smart grid development in China[J]. Power System Protection and Control, 2021, 49(5): 180-187.

[2] 钱玉宝,王紫涵,邱腾煌. 指针式仪表读数识别的研究现状与发展[J]. 电子测量技术, 2024, 47(8): 110-119.
Qian Yubao, Wang Zihan, Qiu Tenghuang. Research status and development of pointer meter reading recognition[J]. Electronic Measurement Technology, 2024, 47(8): 110-119.

[3] Lu S Y, Zhang Y, Su J J. Mobile robot for power substation inspection: A survey [J]. IEEE/CAA Journal of Automatica Sinica, 2017, 4(4): 830-847.

[4] 黄山,吴振升,任志刚,等. 电力智能巡检机器人研究综述[J]. 电测与仪表, 2020, 57(2): 26-38.
Huang Shan, Wu Zhensheng, Ren Zhigang, et al. Review of electric power intelligent inspection robot[J].

Electrical Measurement & Instrumentation, 2020, 57(2): 26-38.

[5] Gao J W, Xie H T, Zuo L, et al. A robust pointer meter reading recognition method for substation inspection robot [C]//International Conference on Robotics and Automation Sciences, 2017: 43-47.

[6] 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 Haoqiang, Du Zhiqi, Su Bo. Detection and recognition method for pointer-type meter in transformer substation [J]. Chinese Journal of Scientific Instrument, 2017, 38(11): 2813-2821.

[7] 徐发兵,吴怀宇,陈志环,等. 基于深度学习的指针式仪表检测与识别研究[J]. 高技术通讯, 2019, 29(12): 1206-1215.
Xu Fabing, Wu Huaiyu, Chen Zhihuan, et al. Research on pointer instrument detection and recognition based on deep learning[J]. Chinese High Technology Letters, 2019, 29(12): 1206-1215.

[8] Liu Y, Liu J, Ke Y C. A detection and recognition system of pointer meters in substations based on computer vision [J]. Measurement, 2020, 152: 107333.

[9] 陈方彬,赵仲勇,王建,等. 基于 YOLO-MCSL 的轻量化智能电能表热缺陷目标检测方法[J]. 仪器仪表学报, 2025, 46(8): 108-119.
Chen Fangbin, Zhao Zhongyong, Wang Jian, et al. A lightweight thermal defect detection method for smart electricity meters based on YOLO-MCSL[J]. Chinese Journal of Scientific Instrument, 2025, 46(8): 108-119.

[10] 胡欣,刘瑞峰,肖剑,等. 面向变电站嵌入式设备的指针式仪表识别方法[J]. 电子测量与仪器学报, 2025, 39(1): 253-263.
Hu Xin, Liu Ruifeng, Xiao Jian, et al. Pointer meter identification method for embedded devices in substations[J]. Journal of Electronic Measurement

- and Instrumentation, 2025, 39(1): 253-263.
- [11] 范新南, 黄伟盛, 史鹏飞, 等. 基于改进 YOLOv4 的嵌入式变电站仪表检测算法[J]. 图学学报, 2022, 43(3): 396-403.
Fan Xinnan, Huang Weisheng, Shi Pengfei, et al. Embedded substation instrument detection algorithm based on improved YOLOv4[J]. Journal of Graphics, 2022, 43(3): 396-403.
- [12] 何敏, 秦亮, 刘开培, 等. 变电站电力仪表智能检测算法研究[J]. 高电压技术, 2024, 50(7): 2942-2954.
He Min, Qin Liang, Liu Kaipei, et al. Research on intelligent detection algorithms for substation power instruments[J]. High Voltage Engineering, 2024, 50(7): 2942-2954.
- [13] Soudeep S, Jahin M A, Mridha M F. Interpretable dynamic graph neural networks for small occluded object detection and tracking[PP/OL]. V8. (2025-05-05) [2025-11-01]. <https://doi.org/10.48550/arXiv.2411.17251>.
- [14] Li X, Zeng C C, Yao Y, et al. Single visual model based on transformer for digital instrument reading recognition[J]. Measurement Science and Technology, 2024, 36(1): 0161b1.
- [15] Shehzadi T, Hashmi K A, Stricker D, et al. Sparse Semi-DETR: Sparse learnable queries for semi-supervised object detection[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 5840-5850.
- [16] Wu S L, Yang H, Liao L F, et al. DSAT: A dynamic sparse attention transformer for steel surface defect detection with hierarchical feature fusion[J]. Scientific Reports, 2025, 15(1): 29198.
- [17] Tian Y J, Ye Q X, Doermann D. YOLOv12: Attention-centric real-time object detectors[PP/OL]. V1. (2025-02-18) [2025-11-01]. <https://doi.org/10.48550/arXiv.2502.12524>.
- [18] Gu W J, Gao W Q, Zou Y, et al. ATW-YOLO: Reconstructing the downsampling process and attention mechanism of yolo network for rail foreign body detection [J]. Signal, Image and Video Processing, 2025, 19(5): 368.
- [19] Mathew M P, Mahesh T Y. Leaf-based disease detection in bell pepper plant using YOLO v5[J]. Signal, Image and Video Processing, 2022, 16(3): 841-847.
- [20] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [21] Woo S, Park J, Lee J Y, et al. CBAM: Convolutional block attention module[C]//European Conference on Computer Vision, 2018: 3-19.
- [22] Wang Q L, Wu B G, Zhu P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11534-11542.
- [23] Xu Y Q, Du W, Deng L W, et al. Ship target detection in SAR images based on SimAM attention YOLOv8[J]. IET Communications, 2024, 18(19): 1428-1436.
- [24] Hao Y, Rao L, Fu X L, et al. Tomato ripening detection in complex environments based on improved BiAttFPN fusion and YOLOv11-SLBA modeling[J]. Agriculture, 2025, 15(12): 1310.
- [25] Rezaatofghi H, Tsoi N, Gwak J Y, et al. Generalized intersection over union: A metric and a loss for bounding box regression[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 658-666.
- [26] Zheng Z H, Wang P, Liu W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C]//AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993-13000.
- [27] Zhang Y F, Ren W Q, Zhang Z, et al. Focal and efficient IOU loss for accurate bounding box regression [J]. Neurocomputing, 2022, 506: 146-157.
- [28] Tong Z J, Chen Y H, Xu Z W, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism[PP/OL]. V3. (2023-04-08)[2025-11-01]. <https://doi.org/10.48550/arXiv.2301.10051>.
- [29] Lin T Y, Maire M, Belongie S, et al. Microsoft COCO: Common objects in context [C]//European Conference on Computer Vision, 2014: 740-755.
- [30] Varghese R, Sambath M. YOLOv8: A novel object detection algorithm with enhanced performance and robustness[C]//International Conference on Advances in Data Engineering and Intelligent Computing Systems, 2024: 1-6.
- [31] Wang A, Chen H, Liu L H, et al. YOLOv10: Real-time end-to-end object detection [J]. Advances in Neural Information Processing Systems, 2024, 37: 107984-108011.
- [32] Khanam R, Hussain M. YOLOv11: An overview of the key architectural enhancements [PP/OL]. V1. (2024-10-23) [2025-11-01]. <https://doi.org/10.48550/arXiv.2410.17725>.

[33] Huang H J, Chen Z G, Zou Y, et al. Channel prior convolutional attention for medical image segmentation[J]. Computers in Biology and Medicine, 2024, 178: 108784.

[34] Wan D H, Lu R S, Shen S Y, et al. Mixed local channel attention for object detection[J]. Engineering Applications of Artificial Intelligence, 2023, 123: 106442.

[35] Zhou Z H, He A L, Wu Y L, et al. Spatial-frequency dual domain attention network for medical image segmentation[C]//IEEE International Conference on Bioinformatics and Biomedicine, 2024: 4076-4081.

[36] Misra D, Nalamada T, Arasanipalai A U, et al. Rotate to attend: Convolutional triplet attention module [C]//IEEE/CVF Winter Conference on Applications of Computer Vision, 2021: 3139-3148.

作者简介

李豪, 硕士研究生, 主要研究方向为智能机器人感知与控制、计算机视觉。

E-mail:L120613887@163.com

马振哲, 硕士研究生, 主要研究方向为计算机视觉、复杂场景下的目标检测。

E-mail:mzz1738039245@163.com

杨云云(通信作者), 博士, 副教授, 主要研究方向为计算机视觉、复杂系统与网络。

E-mail:yangyunyun@tyut.edu.cn

李芝锐, 硕士研究生, 主要研究方向为计算机视觉、深度学习与目标检测。

E-mail:2059767769@qq.com

续欣莹, 博士, 教授, 主要研究方向为智能系统与控制、计算机视觉。

E-mail:xuxinying@tyut.edu.cn