

DOI:10.19651/j.cnki.emt.2519477

基于改进 YOLO11n 的电力高空作业 安全防护装备检测算法*

刘志龙 王成 杜俊男 王天一

(贵州大学大数据与信息工程学院 贵阳 550025)

摘要:为了解决电力场景中高空作业人员安全防护装备检测中存在的检测目标相对单一、检测精度低、泛化能力差等问题,提出了一种改进的 YOLO11n 高空作业安全防护装备检测算法。首先,在颈部网络中引入 DySample 动态上采样方法,有效避免了特征信息在上采样过程中出现的过度放大或丢失问题,在提升图像特征保留能力的同时,保证了模型整体的检测性能;其次,利用深度可分离卷积优化 RCM 构建 CFSCM 模块,同时在空间和通道两个层面上表达关键特征,提升模型对前景安全装备的感知能力;最后,创新性的设计了一个 LQEH 检测头,将回归分支输出的定位质量估计分数与分类分支输出进行融合,解决了原检测头两分支相互独立,缺乏信息交互的问题,增强了分类与定位之间的关联性。实验结果表明,该改进算法的 mAP@0.5、精确度和召回率达到了 93.1%、96.1%和 86.7%,相较于原模型分别提高了 3.2%、0.7%和 2.3%,并且检测速率达到 131 fps。此外,在 Roboflow 网站上的高空作业安全防护装备检测数据集上进行泛化实验,改进算法的 mAP@0.5、精确度和召回率相较于原模型分别提高了 2.1%、5.2%和 2.2%,实验结果充分验证了改进算法的提高检测精度和泛化能力。

关键词: YOLO11;高空作业;安全防护装备;动态上采样;深度可分离卷积;定位质量估计

中图分类号: TP391.41;TN911.73 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Detection algorithm for electric power aerial work safetyprotective equipment based on improved YOLO11n

Liu Zhilong Wang Cheng Du Junnan Wang Tianyi

(School of Big Data and Information Engineering, Guizhou University, Guiyang 550025, China)

Abstract: To address the issues of limited target diversity, low detection accuracy, and poor generalization in the detection of safety protective equipment for aerial workers in electric power scenarios, this paper proposes an improved YOLO11n-based detection algorithm tailored for high-altitude safety protective equipment detection. Firstly, a DySample dynamic upsampling method is introduced into the neck network to effectively prevent excessive amplification or information loss during upsampling, thereby enhancing feature retention while maintaining overall detection performance. Secondly, the RCM is optimized using depthwise separable convolutions to construct a new CFSCM, which captures key features across both spatial and channel dimensions, improving the model's perception of foreground protective equipment. Finally, a novel LQEH is designed to integrate the localization quality scores from the regression branch with the outputs of the classification branch, thereby addressing the lack of interaction between the two original branches and enhancing the correlation between classification and localization tasks. Experimental results demonstrate that the proposed algorithm achieves a mAP@0.5 of 93.1%, precision of 96.1%, and recall of 86.7%, representing improvements of 3.2%, 0.7% and 2.3% over the baseline model, respectively, with a detection speed of 131 fps. In addition, generalization experiments conducted on a high-altitude safety protective equipment dataset from the Roboflow platform show respective improvements of 2.1%, 5.2%, and 2.2% in mAP@0.5, precision, and recall compared to the baseline, validating the effectiveness of the proposed improvements in enhancing detection accuracy and generalization capability.

Keywords: YOLO11; aerial work; safety protective equipment; dynamic upsampling; depthwise separable convolution; localization quality estimation

0 引言

高空作业是电力系统施工和维护的常见作业方式,其

面临的最大的安全隐患之一就是坠落事故。根据世界卫生组织的统计,高空作业事故是全球范围内职业事故中的主要死亡原因之一。高空作业人员未使用或未正确使用安全防

收稿日期:2025-07-29

* 基金项目:国家自然科学基金(62361009)、贵州省科技计划项目(黔科合基础-ZK[2021]304)资助

护设施是高空坠落事故的主要原因^[1]。因此,确保高空作业人员佩戴安全帽和安全带等合适的安全防护设备,是降低事故发生率、保障人员安全的重要措施。在传统的电力高空作业安全检查中,安全巡查员通常需要对每个作业人员进行逐一检查,这不仅效率低下,还容易受主观因素的影响,导致检查漏项或误判,特别是在复杂的高空作业环境中,作业人员的安全防护情况往往难以得到及时和准确的识别。以人力检查为主的安全监督在管理幅度、效率上均存在漏洞与不足。因此,迫切需要开发一种基于深度学习的安全防护装备检测方法,以提高高空作业现场的安全检查效率和准确性,为高空作业安全监管提供技术支持。

随着人工智能、计算机视觉和深度学习技术的不断发展^[2-4],基于深度学习的自动化安全防护装备检测技术为高空作业安全管理提供了新的解决方案^[5]。例如,文家燕等^[6]提出了一种基于改进 YOLOv7-tiny^[7]的高空作业人员安防装备检测算法,通过重新设计网络结构、扩展梯度传输路径、以及替换下采样部分来压缩模型参数和提升特征提取能力。但是其模型参数量较大,达到 10.78 M,导致检测速率较慢,不适合在高空电力作业场景中的实时检测。李永福等^[8]提出了一种基于 EPSA-YOLOv5 网络的高空安全带佩戴检测方法,通过引入高效金字塔压缩注意力(efficient pyramid squeeze attention, EPSA)^[9]模块,优化了目标特征的提取与上下文信息的融合,提高了检测的准确性和模型效率。但是该方法仅对安全带进行识别,目标单一,并且平均精度均值(mean average precision, mAP)仅有 76.8%,难以在实际高空作业复杂场景中实现精确检测。Yan 等^[10]提出了 YOLO-DFAN 算法,通过在 YOLOv4-tiny 的基础上引入空洞空间金字塔池化、依赖融合注意力网络(deep feedback attention network, DFAN)和路径聚合网络(path aggregation network, PANet)^[11]3 项改进,有效提升了高空安全带的检测精度和实时检测能力。然而,将该算法在 Pascal voc07+12 数据集上进行泛化实验, mAP 仅有 70.8%,需要进一步提升模型泛化能力。王茹等^[12]提出了一种改进 YOLOv8 的变电站电力人员安全装备检测算法 Wear-YOLO,通过将主干网络替换为融合 Transformer^[13]结构的 MobileViTv3^[14]模块,提升了模型在复杂场景中的特征提取能力,并引入小目标检测层以优化绝缘手套等小目标的检测精度。尽管该算法在检测精度和鲁棒性上有所提升,但是每秒帧数(frame per second, FPS)仅有 100 fps,检测效率难以满足现实场景中实时检测需求。

电力高空作业场景中,安全防护装备检测面临背景复杂、目标遮挡、小目标易忽视、光照与天气变化大等挑战,导致检测精度下降,易出现误检和漏检。现有方法常存在计算复杂度高、精度与效率难以兼顾、泛化能力弱等问题。因此,本文针对电力高空作业场景的特殊需求提出了一种改进的 YOLO11n 目标检测方法,具体改进措施包括:

1)为了避免传统上采样方法的信息丢失和过度放大问题,利用轻量、高效的 DySample^[15]动态上采样方法替换传统的 upsample 上采样方法。从而在不同层级的特征图中动态调整采样策略,保留更多的细粒度信息。

2)为了解决难以处理的前景背景分割、多尺度物体检测和通道信息融合这些问题,提出基于矩形自校准模块(rectangular self-calibration module, RCM)^[16]的通道融合空间校准模块(channel fusion spatial calibration module, CFSCM),不仅提升模型对前景安全装备的感知能力,还能够空间和通道两个层面上更加充分地表达关键特征。

3)利用定位质量估计(localization quality estimation, LQE)^[17]机制设计了一种新的定位质量估计检测头(localization quality estimation head, LQEH),通过回归分支输出的边界框分布构建统计特征,并进一步预测定位质量得分,将其与分类分支输出相结合,实现检测得分的统一表达,解决原检测头分类分支与回归分支相互独立,缺乏有效的信息交互的问题,从而提升模型对复杂场景中模糊目标、遮挡目标的判别能力。

1 YOLO11 模型

YOLO11 引入了改进的主干网络与颈部结构,显著提升了特征提取能力与复杂任务表现。如图 1 所示,整体网络包括主干网络(backbone)、颈部网络(neck)和检测头(head)。图像输入后经预处理送入主干网络提取特征,接着通过颈部网络进行多尺度特征融合,最终由检测头完成目标检测与定位。

主干中将 C2f 替换为 C3k2,并新增 C2PSA 模块,引入点式空间注意力(position-sensitive attention, PSA)块以增强特征表达。颈部网络使用 PANet 和特征金字塔网络(feature pyramid network, FPN)结构,并在其中使用了 C3K2 模块。检测头将分类与回归任务分支解耦,分类头中的卷积替换为深度可分离卷积以降低计算量。YOLO11 采用无锚框(anchor-free)设计,使用任务对齐分配器(task-aligned assigner)实现正负样本动态分配,损失函数计算包括分类和回归两个分支,分类分支采用二元交叉熵(binary cross-entropy, BCE)损失函数。回归分支使用了分布焦点损失(distribution focal loss, DFL)^[18]和完整交并比(complete intersection over union, CIoU)^[19]损失函数。

YOLO11 具有 n/s/m/l/x 不同尺度大小的模型, YOLO11n 相较于 YOLO11 的其他版本,网络通道数和层数采用了更小的网络结构,具有更低的参数量和计算复杂度,特别适用于资源受限的设备和场景。该模型在保持较高检测精度的同时,提供了更快的推理速度和更小的模型体积,更加适用于电力高空作业场景。

2 改进 YOLO11n 模型

为了提高电力高空作业安全装备的检测效果,本文提

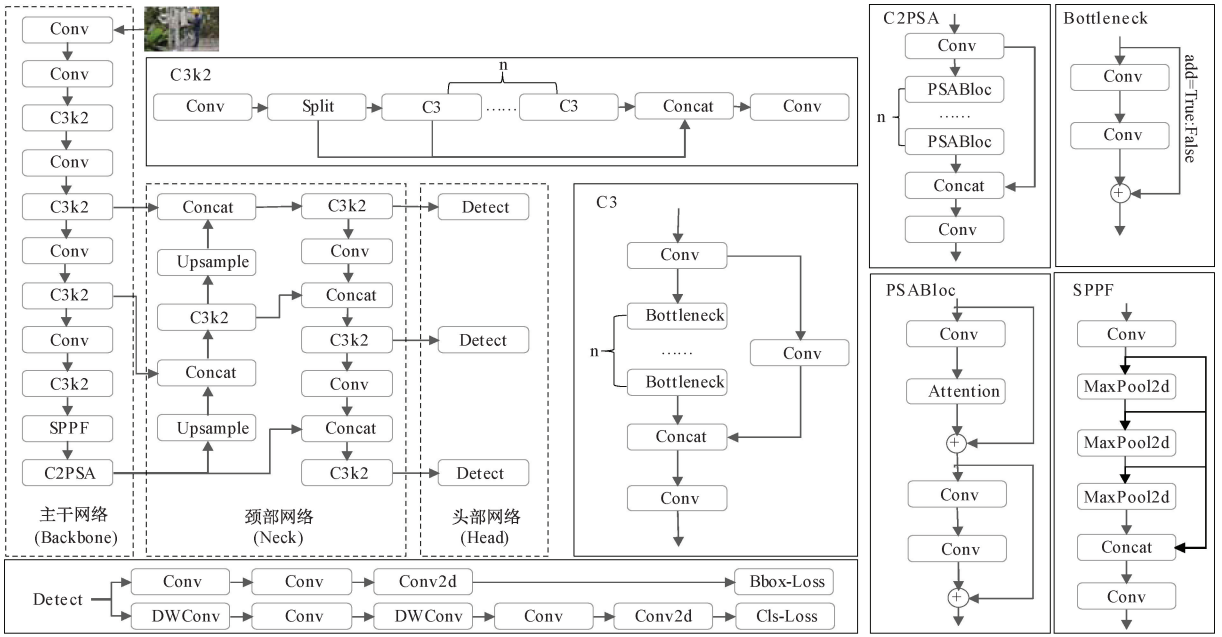


图 1 YOLO11 网络结构
Fig. 1 YOLO11 network structure

出了改进的 YOLO11n 算法,网络结构如图 2 所示。

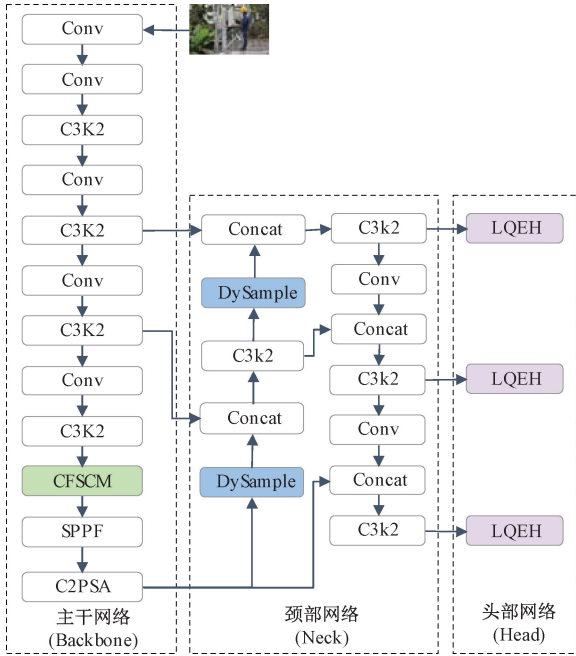


图 2 改进后 YOLO11 算法结构

Fig. 2 Improved YOLO11 algorithm structure

本文首先考虑将颈部网络中传统上采样方法替换成轻量、高效的 DySample 动态上采样方法,从而在不同层级的特征图中动态调整采样策略,保留特征图更多的细粒度信息。在此基础上,针对前景背景分割、多尺度物体检测和通道信息融合这些问题,构建了 CFSCM 模块,使模型在通道和空间两个维度进行特征表达,提高了在复杂作业环

境下的检测精度与鲁棒性。最后,设计了一种新的 LQEH 检测头,利用 LQE 机制解决了原检测头分类分支与回归分支相互独立,缺乏有效的信息交互的问题,提升了模型在电力高空作业场景中对安全防护装备的检测精度。

2.1 动态上采样算子 DySample

电力高空作业场景中背景复杂、光照变化大且遮挡严重,易导致检测精度下降,尤其对小目标和尺度变化目标识别困难。传统 upsample 采用固定比例上采样,易引发特征图过度平滑或失真,难以保留高层细节信息。为此,在 YOLO11 中引入轻量高效的 DySample 动态上采样方法,以动态调整策略,更好适应不同尺度特征,提高复杂场景下的检测效果。

DySample 可根据局部特征动态调整上采样策略,更精准地恢复复杂背景下的细节,提升模型对高空作业中光照变化、遮挡等情况的适应能力,尤其提升对小目标和远景目标(如安全帽、安全带)的检测精度。DySample 结构如图 3 所示。




图 3 DySample 结构
Fig. 3 DySample structure

在上采样过程中,输入特征图 X 大小为 $H_1 \times W_1 \times C_1$,点采样集 S 大小为 $H_2 \times W_2 \times 2g$,其中 $2g$ 为 x 轴与 y 轴的坐标,通过 Grid_Sample 函数来使用点采样集 S 中的

位置对假设的双线性插值 X 进行重新采样,生成新的大小为 $H_2 \times W_2 \times C_2$ 的特征图 X_1 ,如式(1)所示。

$$X_1 = \text{Grid_Sample}(X, S) \quad (1)$$

动态上采样算子 DySample 处理输入的尺寸为 $H_1 \times W_1 \times C_1$ 的多通道张量后,通过两个并行的线性变换层(linear)分别输出两个偏移量,尺寸为 $H \times W \times 2gs^2$,其中 s 为上采样的尺度因子。

偏移量的取值范围是 $[-1, 1]$,这会导致相邻的 s^2 个采样点范围过大、容易重叠、采样点分布混乱,从而引发边界错乱、语义伪影等问题,为避免采样点“乱跑”,需要给偏移加一个约束,让它落在一个合理的范围。

通过几何推导发现:如果每个上采样点的偏移范围限制在 $[-0.25, 0.25]$,那么相邻点的采样范围刚好边界相切、不重叠。然而不同位置、不同语义区域的需求不同,引入一个全局固定值静态因子 0.25,使采样过程缺乏灵活性,无法自适应不同位置的需求,限制了模型的表示能力和泛化性。因此在 0.25 的基础上引入动态因子 0.5σ ,范围扩展到 $[0, 0.5]$,这样既保持了静态 0.25 的采样点不发生重叠,又提供了更强的自适应灵活性,让模型能自适应决定偏移范围。因此,将偏移量 O_1 的采样因子动态地设置为 0.5σ , O_2 采用默认采样因子进行输出,可表示为:

$$O_1 = 0.5\sigma(\text{linear}(X)) \quad (2)$$

$$O_2 = \text{linear}(X) \quad (3)$$

其中, σ 表示 Sigmoid 函数。

接下来,利用像素重组操作将 O_1 和 O_2 结合起来,形成一个新的偏移量 O ,尺寸为 $sH \times sW \times 2g$,且偏移的范围由静态因子和动态因子共同决定,如式(4)所示。

$$O = \text{pixel_shuffle}(O_1 \cdot O_2) \quad (4)$$

最终,通过结合偏移量 O 与原始数据 g ,生成的采样集 S 。动态点采样的整个生成过程如图 4 所示。




图4 动态点采样集生成过程

Fig. 4 Dynamic point sampling set generation process

DySample 通过引入基于输入特征自适应生成的动态偏移量,使采样点能够偏向语义显著区域,从而在上采样过程中对小目标边缘与细粒度特征进行重点保留与强化。同时,动态范围因子的设计保证了偏移范围在安全边界内灵活调节,避免了过度重叠或失真问题。相比固定规则的均匀插值,DySample 能够在小目标区域实现更精细的特征恢复,在背景区域保持平滑性,从而有效提升小目标的

检测响应和定位精度。

为验证 DySample 对小目标响应强度的提高,选取小目标佩戴安全帽、未佩戴安全帽和监管人员肩章的平均精度(average precision, AP)作为评价指标进行对比实验,实验结果如表 1 所示。

表 1 小目标检测对比

模型	Wear_helmet	No_helmet	Gardens
YOLO11n	95.2	72.0	93.3
+DySample	95.8	73.6	94.4

由表 1 可知,通过本文改善算法上采样模块,数据集中佩戴安全帽、未佩戴安全帽和监管人员肩章小目标的 AP 值分别提升了 0.6%、1.6% 和 1.1%,充分证明了 DySample 动态上采样模块的有效性,增强了模型对小目标的响应强度。

此外,DySample 的引入还能够提高计算效率,因为它仅在需要的区域进行更精细的特征恢复,而不是在整个图像上均匀进行高分辨率处理,从而减少了计算成本,同时保持了模型的检测性能。

2.2 CFSCM 模块

1) RCM 模块

RCM 模块由矩形自校准注意力机制(rectangular self-calibration attention, RCA)、批量归一化和多层感知机(multilayer perceptron, MLP)网络组成,它在水平和垂直方向上捕获轴向全局上下文信息,进而对矩形关键区域进行建模。该模块用于空间特征重建和金字塔上下文信息提取。其结构如图 5 所示。




图5 RCM 结构

Fig. 5 RCM structure

RCM 的核心模块是 RCA 注意力机制,其核心思想是显式建模矩形关键区域,通过横向和纵向全局信息生成注意力图。

RCA 注意力机制首先利用水平池化和垂直池化提取两个轴向的全局上下文特征,再将两个轴向特征进行广播相加,得到一个矩形的注意力区域。

其次,使用两个大卷积核的条带卷积对上述矩形注意力区域进行形状微调,使其更贴近真实前景目标形状,条带卷积参数是可学习的,使注意力图形状可训练地适应不同目标的形态。再经过 sigmoid 函数输出一个注意力图,

其过程可以表示为：

$$\xi_c(\bar{y}) = \sigma(\psi_{k \times 1}(\phi(\psi_{1 \times k}(\bar{y})))) \quad (5)$$

其中, ψ 表示大核条卷积, k 表示条卷积的核大小(本文取 11), ϕ 表示批量归一化和 ReLU 函数, \bar{y} 表示前一步输出的特征图。

进一步地,使用 3×3 深度卷积提取输入特征的局部细节,通过哈达玛积将校准后的注意力特征与输入特征融合：

$$\xi_F(x, y) = \psi_{3 \times 3}(x) \odot y \quad (6)$$

其中, $\psi_{3 \times 3}$ 表示 3×3 的深度卷积, y 是在前一步骤中获得的注意力特征, \odot 是哈达玛积。

最后,在 RCA 之后添加批归一化和 MLP 来细化特征,并利用残差连接进一步增强特征,可以描述为：

$$F_{out} = \rho(\xi_F(x, \xi_C(H_P(x) \oplus V_P(x)))) + x \quad (7)$$

其中, \oplus 表示广播加法, H_P 和 V_P 代表水平池化和垂直池化, ρ 指批归一化和 MLP。

2) 深度可分离卷积

深度可分离卷积是一种将标准卷积操作拆解为两个独立步骤的高效卷积结构。它首先对每个输入通道单独执行深度卷积,提取局部空间特征;随后通过逐点卷积将各通道的信息进行线性组合,实现跨通道特征融合,其结构如图 6 所示。

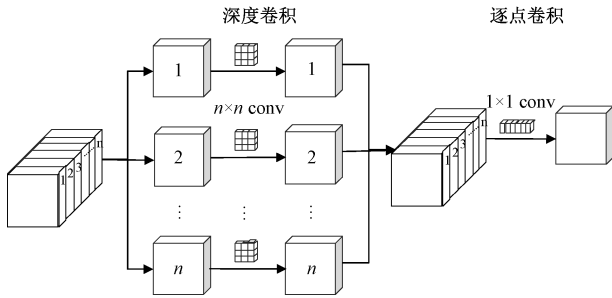


图 6 深度可分离卷积结构

Fig. 6 Depthwise separable convolution structure

深度可分离卷积通过将标准卷积拆分为逐通道卷积和逐点卷积,实现了空间特征提取与通道特征融合的解耦。其中,逐点卷积通过 1×1 卷积在不同通道之间进行加权组合,有效实现了通道间的信息交互与融合,使模型在大幅减少参数和计算量的同时,依然具备良好的特征表达能力。

3) CFSCM 模块

在电力高空作业安全防护装备检测任务中,场景复杂、目标易被遮挡,传统特征提取模块在捕捉关键目标区域时往往存在精度不足的问题。RCM 通过横向和纵向池化捕获轴向全局上下文信息,构建矩形注意力区域,并利用形状自校准机制将注意力区域自适应地调整至关键目标区域,在提升空间定位精度方面具有显著优势。然而,原始 RCM 结构中的深度卷积仅在空间维度上进行特征提

取,缺乏通道间的信息交互,限制了其对多维语义特征的融合能力。

为克服这一不足,本文将 RCA 中深度卷积替换为深度可分离卷积,构建通道融合空间校准注意力(channel fusion spatial calibration attention, CFSCA),并构建出 CFSCM 模块,如图 7 所示。深度可分离卷积通过“先空间、后通道”的处理方式,不仅保持了空间信息建模的高效性,还引入了通道间的特征融合,有助于模型挖掘更加丰富、具有辨别力的语义特征。




图 7 CFSCM 结构

Fig. 7 CFSCM structure

CFSCM 模块兼具空间注意力聚焦与通道信息交互能力:一方面,利用水平、垂直池化以及大核条形卷积自适应地提取水平和垂直方向上的上下文信息,实现空间特征建模,使网络能够更加聚焦于关键区域;另一方面,深度可分离卷积将通道间的相关性显式建模,在保持轻量化的同时有效增强了通道特征的交互与表达能力,通过将通道维度的全局依赖关系与空间维度的局部细粒度信息进行联合建模,实现了空间与通道特征的高效融合,使得 YOLO11n 在复杂电力作业场景中对安全帽、安全带等装备的识别更为精准与稳健,同时也控制了网络计算复杂度的增长。

2.3 LQEH 检测头

在 YOLO11 原始检测头结构中,分类分支和回归分支相互独立,分别负责类别判断与边界框定位,缺乏有效的信息交互与融合机制。在电力高空作业场景下,由于目标通常具有尺寸小、遮挡多、背景复杂等特点,检测任务对边界框定位与分类之间的协同关系提出更高要求。然而,原有结构中,回归分支预测的边界框质量信息无法反馈给分类分支,导致分类得分无法体现目标的真实定位精度,从而使得低质量目标在非极大值抑制(non-maximum suppression, NMS)排名中靠前,或高质量目标被误抑制。这种分类与定位质量脱节的问题显著限制了模型在安全帽、安全带等关键防护装备识别中的准确性与稳定性,不利于在电力高空作业场景中实现精确检测与预警。

为解决 YOLO11 原检测头中分类分支与回归分支之间缺乏信息交互的问题,本文在检测头中引入基于边界框分布的 LQE 机制,设计了 LQEH 检测头,利用回归分支输出的分布特征引导分类分支,实现二者融合优化,提升模型在电力高空作业场景中的检测稳定性与准确性。

在传统目标检测器中,边界框通常采用狄拉克 δ 函数分布建模,形式为：

$$\hat{y} = \int_{-\infty}^{+\infty} \delta(x - y) \cdot x dy \quad (8)$$

然而该建模方式无法表达不确定性。因此,本文采用从预测位置点到边界框 4 个边的相对偏移量作为回归目标,并通过广义分布^[18](general distribution)建模这些回归目标,即将预测的边界框 4 条边分别建模为离散概率分布:

$$P^\omega = [P^\omega(y_0), P^\omega(y_1), \dots, P^\omega(y_n)] \quad (9)$$

其中, $\omega \in \{l, r, t, b\}$, l, r, t, b 分别表示边界框的左、右、上、下 4 条边, $y_i \in [y_0, y_n]$ 为离散回归位置, $\sum_i P^\omega(y_i) = 1$ 。最终回归预测值可表示为加权期望:

$$\hat{y}_\omega = \sum_{i=0}^n P^\omega(y_i) \cdot y_i \quad (10)$$

预测分布曲线图越尖锐,意味着预测框越准确,反之则定位质量较差^[17]。因此,为衡量分布“尖锐程度”,本文选择 Top-k 值以及每个分布向量 P^ω 的平均值,并将它们连接起来作为基本统计特征 $F \in \mathbb{R}^{4 \times (k+1)}$:

$$F = \text{Concat}(\{\text{Topkm}(P^\omega) \mid \omega \in \{l, r, t, b\}\}) \quad (11)$$

其中, Topkm 表示计算 Top-k 值及其平均值的联合运算。Concat 表示将 4 个方向的统计特征拼接得到完整分布特征向量。

为了将边界框分布引入分类判定,本文设计了一个轻量的 MLP 网络,将广义分布的统计特征 F 作为输入,得到预测边界框的定位质量分数 I ,过程表示为:

$$I = \sigma(W_2 \cdot \phi(W_1 \cdot F)) \quad (12)$$

其中, W_1 和 W_2 为实数矩阵。

最后,将分类分支的初始分类分数 C 与回归分支得出的定位质量分数 I 相加,得到联合分数 J :

$$J = C + I \quad (13)$$

该联合得分融合了分类置信度与定位质量,可直接作为 NMS 的排序依据,提升最终预测结果的稳定性与合理性。LQEH 检测头结构如图 8 所示。

LQEH 检测头通过引入定位质量估计机制,将回归分支与分类分支有效结合,解决了原 YOLO11 中两个分支相互独立、信息脱节的问题。该结构能够利用边界框分布的统计特征预测目标的定位质量,并将其引导至分类分支,使最终的检测得分同时反映类别置信度与定位准确性。这一改进有效缓解了小目标漏检、遮挡目标误判以及背景干扰导致的误检等问题,显著提升了模型在电力高空作业场景中对安全防护装备的检测精度。

3 实验结果与分析

3.1 实验环境和数据集

本文所有实验均在同一实验环境下进行,编译环境为 Visual Studio Code, Windows 10 操作系统, CPU 为 Intel (R) Core(TM) i7-9700K, 内存 32 GB, 显卡选用 NVIDIA GeForce RTX 2080 Ti, 显存 11 GB, 深度学习框架 PyTorch2.2.1 + cu121, torchvision0.17.1 + cu121, Python 版本为 3.10.15, CUDA Version 为 12.6。训练超参数设

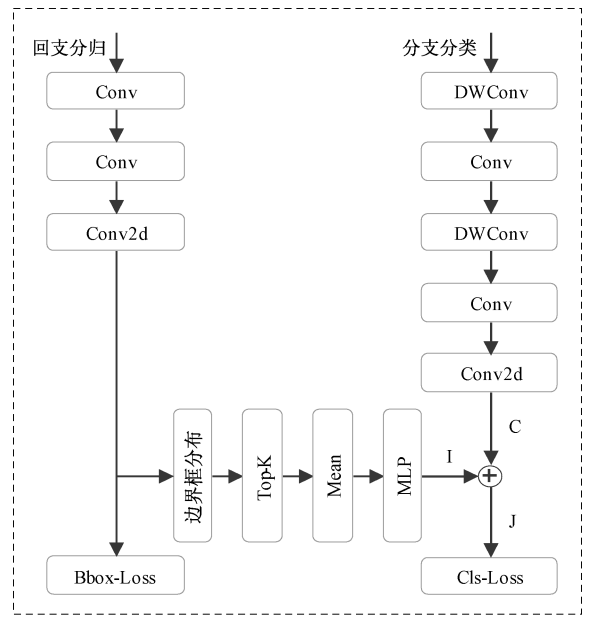


图 8 LQEH 结构

Fig. 8 LQEH structure

置如表 2 所示。

表 2 训练超参数设置

Table 2 Training hyperparameter settings

名称	参数
优化器(Optimizer)	SGD
动量值(Momentum)	0.937
迭代次数(Epoch)	200
批量尺寸(Batch_size)	16
线程数(Workers)	4
学习率(Learning_rate)	0.01
输入尺寸(Img_size)	640×640

实验训练模型使用的数据集是来自天池算法大赛中广东电网智慧现场作业挑战赛识别高空作业及安全带佩戴数据集以及网络资源,如图 9 所示。经过数据清洗之后共选取了 5 142 张图片,其中包含不同光照强度、不同作业场地、不同拍摄方向等多种类别电力高空作业图片。每张图片标签覆盖了电力高空作业现场常见的 7 大类样本标签包括高空作业人员、地面作业人员、监护人员、路人、安全带、佩戴安全帽、未佩戴安全帽。本文采用随机划分的方式将该数据集按照 8:1:1 的比例分成训练集、测试集和验证集。

3.2 评价指标

为了验证本文改进后的 YOLO11 性能,本文采用精确率(precision, P)、召回率(recall, R)、mAP 作为精确度检测的性能评估指标,采用模型参数量(params)衡量模型的复杂程度,以 FPS 衡量检测模型的运行速度。



图 9 数据集部分图像示例

Fig. 9 Sample images from the dataset

mAP 以 mAP@0.5 作为评价指标, mAP@0.5 表示 IoU 阈值设为 0.5 时的平均精确度, mAP 值越大则代表模型整体的精确度越高。精确率是指被模型预测为正类的样本中, 实际也为正类的比例。召回率是指所有实际为正类的样本中, 被模型正确预测为正类的比例。其中 P 、 R 、 AP 、 mAP 和 FPS 的计算公式为:

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

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

$$AP = \int_0^1 P(R) dR \quad (16)$$

$$mAP = \frac{1}{n} \sum_{i=0}^n AP_i \quad (17)$$

$$FPS = \frac{M}{T} \quad (18)$$

其中, TP 表示模型预测为正类且实际也为正类的样本数, FP 表示模型预测为正类但实际为负类的样本数, FN 表示模型预测为负类但实际为正类的样本数, N 表示类别的总数。 mAP 值是所有类别的平均精度, n 为类别总数, i 表示第 n 个类别, AP 值表示某一类别的平均精度, 定义为在不同召回率下的平均精度, M 表示总图片数量, T 表示所用的总时间。

3.3 对比实验

为了验证本文改进算法提高检测效果的有效性, 在相同实验环境下对其和现阶段常用目标检测算法进行对比实验, 对比算法包括 YOLOv8n、YOLOv10n^[20]、YOLOv10s、YOLO11n 和 YOLO11s 算法。实验结果如表 3 所示。

表 3 YOLO 系列算法对比结果

Table 3 Comparison results of YOLO series algorithms

算法	mAP@0.5/%	精确度/%	召回率/%	参数量/M	FPS
YOLOv8n	91.2	96.4	84.8	3.01	166
YOLOv10n	90.1	94.7	84.0	2.70	187
YOLOv10s	91.9	95.1	86.8	8.04	156
YOLO11n	89.9	95.4	84.4	2.58	142
YOLO11s	92.4	95.8	86.8	9.42	128
本文算法	93.1	96.1	86.7	2.96	131

由表 3 可以看出, 经过本文对基础模型 YOLO11n 的优化, 在参数量小幅增加的情况下, 平均精度均值、精确度和召回率相比于基础模型分别增加了 3.2%、0.7% 和 2.3%, FPS 达到了 131 fps。充分证明了本文对原模型改进的有效性。与其他传统模型对比, 本文算法在兼顾了运

行速度和部署难度的前提下, 提升了检测精度。

3.4 消融实验

为了分析改进的 DySample 模块、CFSCM 模块以及 LQEH 检测头的有效性, 本文在相同的数据集和训练参数下进行了消融实验, 实验结果如表 4 所示。

表 4 消融实验

Table 4 Ablation experiment

DySample 模块	CFSCM 模块	LQEH 检测头	mAP@0.5/%	精确度/%	召回率/%	参数量/M	FPS
			89.9	95.4	84.4	2.58	142
✓			90.6	95.1	85.8	2.60	133
	✓		92.5	96.2	87.9	2.92	140
		✓	90.4	95.8	84.9	2.59	141
	✓	✓	92.6	95.3	87.6	2.93	138
✓	✓		92.8	96.5	87.2	2.94	134
✓	✓	✓	93.1	96.1	86.7	2.96	131

首先, 将 YOLO11n 中的传统 upsample 替换为轻量高效的 DySample 动态上采样方法, 在参数量几乎不变的情

况下, mAP@0.5 提升了 0.7%。传统上采样采用固定比例, 易导致特征图过度平滑或失真, 难以保留小目标的细

节。DySample 可根据输入特征图自适应调整上采样因子,避免信息丢失或放大,并在不同层级动态优化采样策略,保留更多细粒度信息,提升电力高空作业中小目标防护装备的检测精度。

其次,设计一个 CFSCM 模块并融入到原模型中,在参数量几乎不变的情况下, mAP@0.5 提升了 2.6%。CFSCM 模块在矩形区域内进行轴向注意力建模的基础上,通过逐点卷积引入通道维度的信息交互,同时具备空间建模与通道特征融合能力,有效增强了特征表达的完整性与判别性。该模块在保持轻量化结构的同时,能够适应电力高空作业场景中复杂背景下的语义分布特征,更加精准地聚焦于安全防护装备区域,提升小目标检测的鲁棒性与精度。

进一步地,将检测头替换为本文设计的 LQEH 检测头后, mAP@0.5 提升 0.5%。传统检测头中分类与回归分支相互独立,信息无法共享,容易导致分类得分与定位精度不一致,影响目标筛选与 NMS 排序。LQEH 利用回归分支输出的边界框分布统计信息预测定位质量分数,与分类分支输出进行融合,增强了分类与定位之间的关联性,使得模型更准确地感知目标的语义与空间信息,显著提升

了电力高空作业场景中安全防护装备的检测精度。

最后,将 3 个改进整合应用时,改进后的模型 mAP@0.5、精确度和召回率分别提升了 3.2%、0.7% 和 2.3%, FPS 虽有小幅下降,但足以满足电力高空作业场景安全装备监测的实时性要求。因此,以上消融实验证明了本文 3 个改进点的有效性,使得模型兼顾运行速度和部署难度的同时,提升了识别精度。

3.5 检测效果可视化分析

为了更直观的对比本文改进算法与 YOLO11n 算法的检测效果,将两种算法用于电力高空作业人员工作的特定场景进行预测,部分预测结果如图 10 所示,其中上方为 YOLO11n 模型检测效果,下方为改进后算法效果。如图 10(a)所示,在背景复杂场景下,改进算法提升了各目标检测精度,解决了监管人员漏检问题;如图 10(b)所示,在光线昏暗条件下,改进算法实现了更准确的目标检测;如图 10(c)所示,在目标被遮挡情况下,有效检测出未佩戴安全帽的问题;如图 10(d)所示,在远距离场景下,改进算法小目标检测效果更加突出。整体来看,相较于原模型,改进后的模型在复杂高空作业环境中表现更优,具备更强适应性和更高的检测精度。

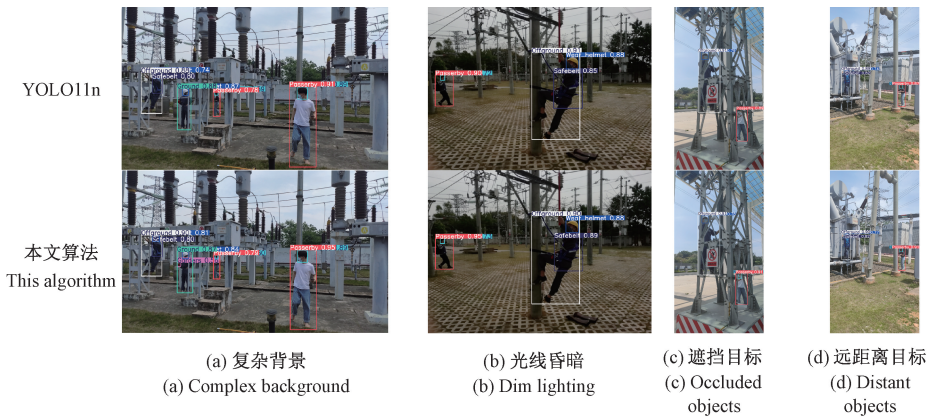


图 10 检测效果对比

Fig. 10 Comparison of detection results

3.6 模型泛化性验证

本文在 Roboflow 网站上下载高空作业安全防护装备检测数据集,通过数据清洗,整合等操作,构建了一个新的数据集,其中包含多种高空作业场景,共 3 780 张图片,如图 11 所示。



图 11 数据集部分图像示例

Fig. 11 Sample images from the dataset

为了验证本文改进的电力高空作业场景安全防护装备检测算法的适用性和泛用性,与 YOLO11n 基础模型在以上数据集上进行对比实验,实验结果如表 5 所示。

表 5 泛化实验

Table 5 Generalization experiment %

模型	mAP@0.5	精确度	召回率
YOLO11n	96.3	90.0	93.5
本文算法	98.4	95.2	95.7

从表 5 的实验结果可以看出,本文改进后的安全防护装备检测算法在该数据集上, mAP@0.5、精确度和召回率分别提升了 2.1%、5.2% 和 2.2%。

为了更直观的显示本文改进算法的泛化性能,将两种算法用于 Roboflow 数据集进行预测,部分预测结果如图 12 所示。从图 12 中可以看出,在 Roboflow 数据集上进行的泛化实验中,本文算法较好地解决了原模型中出

现的漏检和误检情况,并且检测目标的置信度均有所提升,进一步地说明了改进算法具有较强的泛化性和适应性,充分体现了其在多种场景下对安全防护装备检测的优越表现。



图 12 泛化实验可视化分析

Fig. 12 Visualization analysis of generalization experiments

4 结 论

为提升电力高空作业场景下安全防护装备检测的智能化水平,本文提出了一种改进的 YOLO11n 模型。针对原模型在小目标和遮挡情况下特征提取能力弱、检测精度低的问题,引入轻量高效的 DySample 动态上采样方法,在不同层级特征图中动态调整采样策略,保留更多细粒度信息,避免信息丢失与过度放大;构建 CFSCM 模块,同时在空间和通道两个层面进行特征融合,有效增强了特征表达的完整性;设计了一个 LQEH 检测头,将回归分支输出的定位质量分数与分类分支输出进行融合,增强了分类与定位之间的关联性。本文改进算法的 $mAP@0.5$ 、精确度和召回率达到了 93.1%、96.1% 和 86.7%,相较于原模型分别提高了 3.2%、0.7% 和 2.3%,并且 FPS 达到了 137 fps。此外,在泛化实验中,3 项指标分别提高了 2.1%、5.2% 和 2.2%,实验结果表明,改进模型在检测精度与泛化性能上均优于原模型。

参考文献

- [1] 许光. 论建筑施工防坠落事故成因及管控措施[J]. 现代职业安全, 2025(3): 36-38.
XU G. An analysis of the causes and management measures for fall prevention in building construction[J]. Modern Occupational Safety, 2025(3): 36-38.
- [2] HUANG J W, WANG K B, HOU Y, et al. LW-YOLO11: A lightweight arbitrary-oriented ship detection method based on improved YOLO11[J]. Sensors, 2024, 25(1): 65.
- [3] 吴葛, 朱宇凡, 叶天成. 改进 YOLOv10 的钢材表面缺陷检测方法[J]. 电子测量技术, 2025, 48(4): 158-168.

WU G, ZHU Y F, YE T CH. Improving the steel surface defect detection method of YOLOv10 [J]. Electronic Measurement Technology, 2025, 48 (4): 158-168.

- [4] 强浩南, 邹涌波, 马立东, 等. 基于 CPM-YOLO 的道路头盔检测方法[J]. 电子测量技术, 2025, 48(7): 152-162.
QIANG H N, ZOU Y B, MA L D, et al. Road helmets detection method based on CPM-YOLO[J]. Electronic Measurement Technology, 2025, 48 (7): 152-162.
- [5] 张兆云, 何冠锋, 黄世鸿, 等. 目标检测在电力巡检中的应用与发展趋势[J]. 湖北民族大学学报(自然科学版), 2021, 39(3): 305-314.
ZHANG ZH Y, HE G F, HUANG SH H, et al. Application and development trend of target detection in power inspection [J]. Journal of Hubei Minzu University (Natural Science Edition), 2021, 39 (3): 305-314.
- [6] 文家燕, 周志文, 辛华健, 等. 基于改进 YOLOv7-tiny 的高空作业人员安防装备检测算法[J]. 现代电子技术, 2024, 47(13): 164-171.
WEN J Y, ZHOU ZH W, XIN H J, et al. High-altitude operation personnel security equipment detection algorithm based on improved YOLOv7-tiny[J]. Modern Electronics Technique, 2024, 47(13): 164-171.
- [7] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.

- [8] 李永福,陈立斌,惠君伟,等.基于EPSA-YOLOv5电力高空作业安全带佩戴检测[J].西安工程大学学报,2024,38(2):18-25.
LI Y F, CHEN L B, HUI J W, et al. Safety belt wearing detection for electric aloft work based on EPSA-YOLOv5 [J]. Journal of Xi'an Polytechnic University, 2024,38(2):18-25.
- [9] ZHANG H, ZU K K, LU J, et al. EPSANet: An efficient pyramid squeeze attention block on convolutional neural network[C]. Asian Conference on Computer Vision, 2022: 1161-1177.
- [10] YAN W D, WANG X Y, TAN SH B. YOLO-DFAN: Effective high-altitude safety belt detection network [J]. Future Internet, 2022, 14(12): 349.
- [11] LIU SH, QI L, QIN H F, et al. Path aggregation network for instance segmentation [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8759-8768.
- [12] 王茹,刘大明,张健. Wear-YOLO:变电站电力人员安全装备检测方法研究[J].计算机工程与应用,2024,60(9):111-121.
WANG R, LIU D M, ZHANG J. Wear-YOLO: Research on detection methods of safety equipment for power personnel in substations [J]. Computer Engineering and Applications, 2024,60(9):111-121.
- [13] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. ArXiv preprint arXiv:1706.03762,2017.
- [14] WADEKAR S N, CHAURASIA A. Mobilevitv3: Mobile-friendly vision transformer with simple and effective fusion of local, global and input features[J]. ArXiv preprint arXiv:2209.15159, 2022.
- [15] LIU W Z, LU H, FU H T, et al. Learning to upsample by learning to sample [C]. IEEE/CVF International Conference on Computer Vision, 2023: 6027-6037.
- [16] NI ZH L, CHEN X H, ZHAI Y J, et al. Context-guided spatial feature reconstruction for efficient semantic segmentation [C]. European Conference on Computer Vision, 2024: 239-255.
- [17] LI X, WANG W H, HU X L, et al. Generalized focal loss v2: Learning reliable localization quality estimation for dense object detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 11632-11641.
- [18] LI X, WANG W H, WU L J, et al. Generalized focal loss: Learning qualified and distributed bounding boxes for dense object detection[J]. Advances in Neural Information Processing Systems, 2020, 33: 21002-21012.
- [19] ZHENG ZH H, WANG P, REN D W, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation[J]. IEEE Transactions on Cybernetics, 2021, 52(8): 8574-8586.
- [20] WANG AO, 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.

作者简介

刘志龙,硕士研究生,主要研究方向为深度学习、图像处理。

E-mail:2485253878@qq.com

王成,硕士研究生,主要研究方向为深度学习、图像处理。

E-mail:2231375292@qq.com

杜俊男,硕士研究生,主要研究方向为深度学习、图像处理。

E-mail:1277052091@qq.com

王天一(通信作者),博士,副教授,主要研究方向为机器学习理论与应用。

E-mail:tywang@gzu.edu.cn