

doi: 10.7690/bgzdh.2025.04.008

PTB-YOLOv8s: 轻量级离散分布安全装备检测的方法

张 杨¹, 张雪琴²

(1. 河南应用技术职业学院, 郑州 450042; 2. 西安交通大学城市学院, 西安 710018)

摘要: 针对电力人工巡检维修工作中, 安全帽和高空作业安全带等关键安全装备合规使用的监测效率低等问题, 提出一种基于 YOLOv8s 的检测模型, 旨在降低人工成本, 提升检测效率。通过设计 C2f_PT B 特征提取模块, 结合 Transformer 的全局信息捕获和卷积神经网络的局部特征提取能力, 提升模型对小尺寸和分散目标的检测效率; 引入标准化高斯瓦瑟斯坦距离(normalized Gaussian Wasserstein distance, NGWD)损失函数, 增强模型对微小安全装备检测的稳定性与准确性; 设计基于 StarNet 的轻量化主干网络 C2f_star 模块, 降低网络参数。实验结果表明, 改进后的模型在电力安全装备数据集上的 mAP 达到 93.7%, 相比基准模型检测精度提升 5.6%, 检测速度提升 10 帧/秒, 证明所提出的方法能够有效提升检测效果。

关键词: 电力安全; 安全装备检测; 目标重叠; 特征融合; Transformer; 损失函数; 主干轻量化

中图分类号: TP391 **文献标志码:** A

PTB-YOLOv8s: A Lightweight Method for Safety Equipment Detection Based on Discrete Distribution

Zhang Yang¹, Zhang Xueqin²

(1. He'nan Vocational College of Applied Technology, Zhengzhou 450042, China;

2. Xi'an Jiaotong University City College, Xi'an 710018, China)

Abstract: In view of the low monitoring efficiency of compliance use of key safety equipment such as safety helmet and safety belt for working at heights in manual inspection and maintenance of electric power, a detection model based on YOLOv8s is proposed to reduce labor costs and improve detection efficiency. By designing the C2f_PT B feature extraction module, combining the global information capture of Transformer and the local feature extraction ability of convolutional neural network, the detection efficiency of the model for small size and scattered targets is improved; The normalized Gaussian Wasserstein distance (NGWD) loss function is introduced to enhance the stability and accuracy of the model for the detection of small safety equipment; Lightweight backbone network C2f_star module based on StarNet is designed to reduce network parameters. Experimental results show that the mAP of the improved model reaches 93.7% on the power safety equipment data set, the detection accuracy is improved by 5.6% and the detection speed is improved by 10 frames per second compared with the benchmark model, which proves that the proposed method can effectively improve the detection effect.

Keywords: electric power safety; safety equipment detection; target overlap; feature fusion; Transformer; loss function; lightweighting backbone

0 引言

随着电力基础设施的快速发展, 变电站维护和检修的工作也愈加繁重。由于电力安全管理不到位和巡检人员缺乏足够的安全意识, 电力生产安全事故频繁发生, 带来了严重的经济损失^[1]。研究结果表明: 当电力巡检人员正确使用安全帽和安全带等安全装备时, 可以大大降低受伤和死亡的风险^[2]。传统的安全装备检测往往依赖操作者的自觉和安全员的人工检测, 费时费力且效果比较差。近年来, 计算机视觉领域的发展能够通过图像自动检测电力行业工作场所的不规范着装信息, 这种方法不仅操

作简便, 还能避免与工作人员的直接接触, 从而确保工人的安全, 有效预防电力施工过程中的安全事故, 具有广泛的研究潜力和应用价值。

在研究初期, 研究人员主要关注安全帽检测^[3-4]。刘晓慧等^[4]利用肤色检测技术定位脸部以上的区域, 将 Hu 矩作为特征向量, 利用支持向量机(support vector machine, SVM)来判断是否佩戴安全帽。在实际应用场景中, 获取工人的正面面部信息以进行相应处理是一项具有挑战性的任务。随着深度学习模型的不断发展和普及, 国内外学者应用该方法对安全帽进行检测^[5-6]。Shen 等^[6]使用卷积神经网络进行安全帽检测, 结合人脸检测和边界框回

收稿日期: 2024-08-11; 修回日期: 2024-09-22

第一作者: 张 杨(1987—), 男, 河南人。

归技术,采用 DenseNet 的深度转移学习,通过特征提取和微调策略提升了识别效果,但该方法对于实际场景工程实践的应用不足,且存在漏检误检现象。

近年来,许多国内外的研究者也开始将深度学习技术应用于检测安全带、工作制服以及绝缘手套等安全设备上,并在这些检测领域取得了诸多研究成果^[7-9]。现有研究大多集中于单一目标的检测,仅关注电力从业人员佩戴安全装备中的某一部分:冯志珍等^[10]提出一种基于 Mask R-CNN 的高空作业安全带检测方法,将安全带检测和人体关键点信息结合,判断作业人员的违规情况,但该方法的检测框架是基于双阶段的方法,其时效性难以满足实际应用需求;张伍康等^[11]采用改进 RetinaNet 算法来监测电力工作人员绝缘手套的佩戴情况,通过多尺度特征提取骨干网络 Res2Net 提取图像特征,输出包含绝缘手套边界框的图像;袁一丹^[12]根据黑白像素点的分布来判断工作服的穿着情况,并采用 Inception-v3 网络和 Softmax 分类判断安全帽的佩戴情况。

尽管现有文献对电力复杂场景下的工作人员佩戴安全装备情况进行了研究,但极少有研究直接检测电力从业人员在实际工作中是否正确佩戴所有安全装备。这种研究缺失导致机器视觉在检测电力巡检人员安全装备未能充分发挥潜在作用。现有的模型算法关于检测多类安全装备目标方面的研究成果较少且效果不佳,同时这类离散式分布的目标特征对现有的研究算法仍极具挑战。笔者提出一种改进模型,专门用于电力巡检人员安全装备的检测,主要贡献如下:

1) 设计 C2f_PTB 特征提取模块。主要通过 Transformer 提取全局上下文信息和卷积神经网络收集局部特征信息,将两者有机结合,获取精细全面的特征信息,以此来提升模型检测精度。

2) 引入新的锚框回归度量形式。通过引入 NWD 损失函数,解决小目标锚框回归位置偏差问题,提升锚框回归效率,进而提升小目标检测精度。

3) 设计轻量级主干网络。通过引入 StarNet 的 Star 运算,降低 Transformer 引入来带的计算复杂度,将其堆叠构建轻量化主干网络,在保证减少模型计算量的同时提升检测精度。

1 改进 YOLOv8s 算法

为保证实时性及轻便性检测要求,在 YOLOv8s

的基础上提出一种改进 YOLOv8s 的电力巡检人员安全装备的检测方法。首先,基于 Transformer 设计全局特征提取模块作为检测头的输入层,提供更好的特征提取效果;其次,引入新的锚框度量方式——标准化高斯瓦瑟斯坦距离(NGWD),提升微小型目标的检测性能;最后,设计一种轻量化主干网络——Star Backbone,降低参数量,提升多目标尺度输入适应性。改进后的 YOLOv8s 模型结构如图 1 所示。




图 1 改进后模型结构

1.1 C2f_PTB 特征提取模块

在实际的电力安全巡检场景中,安全装备往往占整个检测图像的像素小部分,同时例如安全带等检测目标,在标注框中所占的正样本特征比较离散,因此常规的特征提取模块效果较差。基于此,设计 C2f_PTB 特征提取模块,实现局部特征和全局特征的融合,提升模型检测效果,结构如图 2 所示。

在计算机视觉任务中,Transformer 结构因其强大的全局特征提取能力而受到广泛关注。由于 Transformer 结构的计算复杂度较高,直接将其应用于所有通道会导致显著的计算开销。为了在保证高效特征提取的同时降低计算成本,设计了一种混合结构——Partially Transformer Block,将输入特征图按照 1:3 的比例分为 2 部分,分别由 CNN 和

Transformer 处理, 然后再通道方向进行整合, 最后利用普通卷积操作整合特征。在 Transformer 部分为了增强全局特征信息的提取能力同时进一步降低计算成本, 利用原有的多头注意力机制负责提取全局特征, 同时引入门控线性卷积模块(convolutional

gated linear unit, CGLU)^[13]增强非线性特征表达能力。在 CGLU 模块结构主要包括 2 个线性投影分支, 同时在一个分支上添加简单的深度可分离卷积和激活函数, 这样的结构设计在原文中已被证实相较于传统反馈网络具有更强的性能。




图 2 C2f_PT B 模块结构

为了确保检测头能够接收到全面而深入的特征描述, 将 PTB 模块融入到模型中原有的 C2f 模块中, 构建增强版的 C2f_PT B 模块, 以此替代标准 C2f 模块。这一替换旨在为检测头供应丰富多元的信息输入, 不仅包含了细腻的局部特征, 而且有强有力的全局上下文信息。后期实验将证明这种设计在捕捉离散分布的目标及小尺度对象的特征方面尤为有效。

1.2 NWD 损失函数

在基于锚框的物体检测技术中, 交并比(intersection over union, IoU)作为评估边界框相似性的关键指标, 被广泛采纳。为了弥合训练与实际检测性能之间的差异, IoU-Loss 被引入作为优化策略。该方法在 2 种特定情境下暴露出局限性, 因而无法有效提供梯度信息以指导网络学习: 1) 当预测边界框 P 与实际目标框 G 不存在任何重叠(即 $|P \cap G| = 0$); 2) 在 P 完全包围 G 或反之($|P \cap G| = P$ 或 G)的情况下, IoU-Loss 亦显得无能为力。这 2 种情形在微小物体检测中尤为突出, 因为微小物体的细微位移极易导致 P 与 G 错失重叠, 或者预测框意外地全面覆盖真实框, 进一步加剧了检测难度。鉴于 IoU-Loss 对微小物体定位偏差的高度敏感性, 尽管改进版的度量标准如 CIoU 和 DIoU 在一定程度上缓解了上述问题——如同笔者使用的基础检测模型

YOLOv8s 采用的 CIoU 回归损失所示——这些方法本质上仍根植于 IoU 的概念, 故在处理微小物体的精确定位时, 其敏感性问题依然存在。为突破这一瓶颈, 引入归一化瓦瑟斯坦距离(normalized Wasserstein distance, NWD)度量^[14], 并据此设计损失函数, 旨在更稳健地应对微小物体检测中的位置偏差, 从而在保持高精度的同时, 增强对微小细节变化的鲁棒性。NWD loss 表示如式(1)所示:

$$l_{\text{NWD}} = 1 - \text{NWD}(N_p, N_g). \quad (1)$$

式中: N_p 为预测框 p 的高斯分布模型; N_g 为真实框 g 的高斯分布模型。在 NWD 度量标准中, 通过将 2 个边界框 p 和 g 之间的相似度转换为 2 个高斯分布之间的分布距离进行求解。以预测框 $p = (c_{x_p}, c_{y_p}, w_p, h_p)$ 真实框 $g = (c_{x_g}, c_{y_g}, w_g, h_g)$ 为例, 其中 (c_x, c_y) , w 和 h 分别为边界框的中心坐标, 宽度和高度。其距离度量计算可表示为:

$$w_2^2(N_p, N_g) = \left\| \left[\begin{matrix} c_{x_p} & c_{y_p} & w_p/2 & h_p/2 \end{matrix} \right]^T, \left[\begin{matrix} c_{x_g} & c_{y_g} & w_g/2 & h_g/2 \end{matrix} \right]^T \right\|_2^2. \quad (2)$$

式中 $w_2^2(N_p, N_g)$ 为距离度量, 不能直接用作相似性度量。因此, 使用其指数形式进行归一化, 如式(3)所示:

$$\text{NWD}(N_p, N_g) = \exp(-\sqrt{w_2^2(N_p, N_g)}/C)。(3)$$

式中 C 为与数据集密切相关的常数, 在后续实验中凭经验将其设置为所使用数据集目标的平均绝对尺寸, 以此获取最佳性能。

相较于传统的 IoU 指标, NWD 在微小物体检测领域展现出若干显著优势, 在后续的实验部分将严谨地验证这些理论优势, 通过实证数据明确展示 NWD 在提升电力巡检人员微小安全装备目标检测

精度、稳定性和泛化能力方面的突出贡献, 进一步确定改进方法的有效性。

1.3 轻量化主干网络

为了减轻 Transformer 模型引入带来的计算密集型问题, 笔者采纳了轻量化架构——StarNet^[15], 将其融入基础模型之中。图 3 所示为 C2f_Star 模块结构示意, 其构建轻量化的主干网络, 缩减模型体积, 确保模型高性能表现。




图 3 C2f_star 模块结构

StarNet 主要通过元素级乘法将不同子空间的特征进行融合, 从而展现出出色的性能和效率。Star 运算可以表示为:

$$\delta_1^T x * \delta_2^T x = \alpha(1,1)x^1x^1 + \dots + \alpha(4,5)x^4x^5 + \dots + \alpha(d+1,d+2)x^{d+1}x^{d+2}。(4)$$

式中: $\delta_1^T x * \delta_2^T x$ 为元素乘法融合 2 个线性变换的特征; i 和 j 为通道索引; α 为每个项的系数。 $\delta_1^T x * \delta_2^T x$ 可以将其展开为 $(d+2)(d+1)/2$ 不同项的组合。在 d 维度空间中使用 Star 运算, 可以得到 $(d+2)(d+1)/2 \approx (d/\sqrt{2})^2 (d \gg 2)$ 个隐式维度特征空间, 从而在显著放大特征维度的同时, 不会在单层内产生任何额外的计算开销。

如图 3 所示, 在 Star 模块中, 通过深度可分离卷积 (DW-Conv) 进行特征提取, 同时经过 2 个全连接层全索引提取的特征, 然后利用 Star 运算进行特征融合, 后面再接全连接层和深度可分离卷积。通过这样的架构, 实现多维度特征提取及融合同时降低计算开销。由于 StarNet Bottleneck 特征提取的高效性能, 将其引入 C2f 模块, 构建 C2f_Faster 模块, 并利用其堆叠组成轻量化主干网络, 如图 4 所示。优化的主干网络结构被划分为 4 个清晰阶段, 每阶段均由步长为 2 的卷积层引领, 紧随其后的是多个 C2f_Star 模块。在后续实验中, 可以证明改进后的主干网络不仅降低了检测模型的计算量同时检测精度得到了一定的提升。




图 4 改进后的主干网络结构

2 实验结果

2.1 数据及实施细节

笔者训练模型使用的数据集来自天池算法大赛中广东电网智慧现场作业挑战赛相关数据集。经过数据清洗之后共选取了 3 327 张图片, 并使用 Labellmg 软件对每张图片的样本标签进行标注, 标签格式为.txt。数据集按照 9:1 的比例划分为 2 994 张训练集和 333 张测试集。数据集中包括非工作人员、着地状态工作人员、离地状态工作人员、操作

杆、安全帽、未佩戴绝缘手套、安全带、佩戴绝缘手套、袖章、挽衣袖和挽裤腿 11 类样本标签, 具体样本标签及解释如表 1 所示。

实验所使用的软件环境为 CUDA11.3+pytorch1.11.0+python3.8, 实验设备配备了 8 GB 内存的 NVIDIA GeForce RTX 3060Ti。笔者采用深度卷积神经网络对安全装备进行识别和跟踪, 设定了主要超参数, 初始学习率为 0.01, 训练周期为 200, 图像的输入尺寸为 640×640, 批量大小为 8。模型

训练过程中未采用预训练的权重，其他细节都严格按照 YOLOv8s 测试的标准流程来执行。

表 1 电力安全装备数据集标签说明

标签	标签名称	标签解释
0	no-worker	非工作人员
1	groundworker	着地状态工作人员
2	offgroundworker	离地状态工作人员
3	operatingbar	操作杆
4	helmet	安全帽
5	wrongglove	未佩戴绝缘手套
6	safebelt	安全带
7	rightglove	佩戴绝缘手套
8	badge	袖章
9	wrongtop	挽衣袖
10	wrongbotton	挽裤腿

2.2 评价指标

在实验设计与验证过程中，不仅使用固定的并集交集 (IoU) 值 0.5 来计算 mAP，而且测量了 COCO^[16]度量平均精度 (AP)，该度量通常用作目标检测的评估指标。此外，利用 APs(实例面积小于 32*32 的 AP)，APm(实例面积大于 32*32 小于 96*96 的 AP) 和 API(实例面积大于 96*96 的 AP) 来评估模型在不同尺寸的检测性能。其计算公式为：

表 2 消融实验

模型	C2f_Star	C2f_PTB	NWD Loss	mAP/%	APs/%	参数量/Mb	FPS/帧
YOLOv8s	×	×	×	88.1	65.9	11.1	108
优化模型 1	√	×	×	89.3	64.4	8.6	137
优化模型 2	×	√	×	91.5	70.6	13.3	89
优化模型 3	×	×	√	90.8	71.7	11.2	123
优化模型 4	√	√	×	91.7	68.7	10.4	111
本文中模型	√	√	√	93.7	73.9	10.5	118

如表 2 所示，优化模型 1 中，引入轻量级模块 C2f_Star 后，模型参数量从 11.1 Mb 降到了 8.6 Mb，检测速度提升了 29 帧/s，同时检测精度得到了小幅度提升。因此，可以证明该模块的引入达到了轻量化网络模型的目的。优化模型 2 中，使用 C2f_PTB 特征提取模块后，尽管参数量略有升高，但是检测精度得到 3.4 个百分点的提升，达到了提升检测精度的目的。优化模型 3 中，NWD 损失函数的引入，给检测精度带来了 2.7 个百分点的提升，尤其在小目标检测方面，更是实现了 5.8 个百分点的提升，该方法达到了提升小目标检测能力的设计初衷。优化模型 4 中，同时引入 C2f_Star 和 C2f_PTB 模块，检测精度得到提升的同时，模型参数量实现了降低。综上所述，证明了提出的改进方法的合理性与有效性。

Precision=TP/(TP+FP); (5)

Recall=TP/(TP+FN); (6)

$AP_i = \int_0^1 (P_i \cdot R_i) ;$ (7)

$mAP = \frac{1}{N} \sum_{i=1}^N AP_i .$ (8)

式中：TP 为正检次数；FP 为错检次数；FN 为漏检次数。利用每秒检测帧数 FPS，验证算法检测模型的时效性。

FPS=1 000/time。 (9)

式中：FPS 为模型每秒处理的图像数量；time 为模型处理单个图像所需的持续时间，ms。

2.3 改进方法有效性验证

为了系统地评估各项改进措施对 YOLOv8s 模型性能提升的具体贡献，设计了消融实验。先后对于 YOLOv8s 网络模型进行了以下改进：优化模型 1，利用 C2f_Star 模块轻量化主干网络；优化模型 2，利用 C2f_PTB 模块替换 C2f 做为给检测头提供特征信息；优化模型 3，引入 NWD 损失函数；优化模型 4，将模型 2 和模型 3 改进方法组合。消融实验结果如表 2 所示。

2.4 改进方法优越性验证

本文中改进模型和基准模型 YOLOv8s 在训练过程中 mAP 变化曲线如图 5 所示。




图 5 mAP50 曲线对比

由图 5 可见：相较于基准模型，笔者模型以更快的收敛速度达到最高检测精度。即在前 70 轮检测精度迅速上升，在 70 轮后缓慢上升，最终稳定在 93.7%左右。可以看出，本文中模型在训练过程中表现优越。

为验证笔者所提改进的算法优越性，将其与其它优秀检测方法在相同条件下进行对比试验，以 mAP@0.5、FPS 和参数量作为评价标准。结果如表 3 所示。

表 3 改进方法与其他模型对比实验结果

标签	Faster RCNN	YOLOv5s	YOLOv8s	文献[18]	文献[19]	本文中模型
no-worker	98.9	97.9	96.2	97.80	97.20	98.5
groundworker	95.1	96.1	96.3	95.00	95.40	96.1
offgroundworker	78.7	79.6	84.4	90.70	84.10	87.7
operatingbar	80.2	80.6	86.7	81.60	92.10	93.8
helmet	92.0	95.1	95.7	92.30	96.80	96.0
wrongglove	33.4	70.6	69.6	72.90	81.60	86.3
safebelt	55.7	63.8	64.5	70.20	73.10	78.9
rightglove	88.0	84.6	86.3	85.60	92.10	94.7
badge	57.7	90.1	90.4	82.10	96.70	95.5
wrongtop	43.7	76.7	79.7	74.90	78.40	81.2
wrongbotton	67.8	75.7	80.9	78.80	83.30	86.8
mAP@0.5/%	78.7	86.5	88.1	85.40	92.10	93.7
FPS/帧	27.0	107.0	108.0	23.00	100.00	118.0
参数量/Mb	137.0	7.1	11.1	38.23	3.61	10.5

根据表 3 可以看出：笔者所提模型检测精度达到 93.7%，其检测精度远远高于 Faster RCNN^[16]、YOLOv5s 和 YOLOv8s 等经典检测算法，同时模型参数量具有竞争力。相较于同期相关检测算法——文献[17]和[18]，笔者所提模型检测精度上分别高出 8.3%和 1.6%，检测速度分别高出 95 和 18 帧/s，因此笔者所提模型具有更高的综合检测性能。在各类别的检测精度中，有一半以上的类别检测精度处于领先，同时其他类别都保持着较高的检测精度。因此可以证明该模型是目前关于电力巡检人员安全装备检测极具竞争力的检测方法。

为了直观展示笔者所提模型的检测效果，将检测结果按照在不同情景下的检测结果与基准模型做了对比，结果展示如图 6 所示。




图 6 高空作业人群检测效果对比

图 6 中左边基准模型在高空作业情景下，对作业人员的安全带佩戴检测出现了漏检，而本文中模型通过针对安全带这种特征较离散型目标所设计的模块，实现了成功检测并且获得较高的置信度。

图 7 中在背景复杂的情境中，基准模型漏检了

目标较小的未佩戴手套标签，而笔者所提模型获得了准确的识别效果。

图 8 中在光线暗淡的情景下，本文中模型相较于基准模型获得了更优质的检测结果，同时没有出现漏检测情况。




图 7 复杂背景下检测效果对比




图 8 光线暗淡环境下检测效果对比

图 9 中基准模型出现了错检，将工人错误挽袖识别成了未佩戴绝缘手套，在本文中模型中精准识

别到了该行为。通过与基准模型的效果对比可知:在电力巡检人员安全装备检测方面,笔者提出的模型能够实现更加精准的检测。



(a) YOLOv8s (b) 本文中模型
图9 光线暗淡环境下检测效果对比

3 结论

针对电力巡检人员安全装备的人工监测费时费力问题,笔者利用深度学习方法实现无人化实时精准检测,不仅有效减少了人力物力财力,而且能及时反馈纠正不安全行为。针对电力巡检人员安全装备检测面临的挑战,创新性地提出了一套改进方案,并在YOLOv8s框架基础上实现了显著的性能提升。这一检测模型改进关键在于设计C2f_PT B特征提取模块,成功融合Transformer的全局视角和CNN的局部细节捕捉能力,为复杂场景下的小目标检测提供了更为精确的特征描述。引入的NWD损失函数有效解决了小目标定位的偏差问题,显著增强了模型在微小安全装备检测上的稳定性与准确性。此外,在主干网络中引入StarNet构建轻量化主干网络,不仅实现了模型的轻量化,而且确保了检测效率与精度的双重优化。实验结果表明:改进后的模型在电力巡检人员安全装备检测中精度得到提高,错检漏检率低,检测速度满足实时性的要求,为后续电力人员安全装备规范检测提供了一定的参考。

参考文献:

- [1] 谢世勇. 基于深度学习的电力着装检测系统的设计与实现[D]. 武汉: 华中科技大学, 2023.
- [2] ZHANG G, ZHANG D, LI D, et al. Research on key Technologies of Video Intelligent Identification and Security Management and control system in substation[J]. Int Journal of Simulation--Systems, Sci & Technol, 2016, 17(20): 61-66.
- [3] WEN C Y. The safety helmet detection technology and its application to the surveillance system[J]. Journal of forensic sciences, 2004, 49(4): 770-780.
- [4] 刘晓慧, 叶西宁. 肤色检测和 Hu 矩在安全帽识别中的应用[J]. 华东理工大学学报: 自然科学版, 2014, 40(3): 365-370.
- [5] LONG X, CUI W, ZHENG Z. Safety helmet wearing detection based on deep learning[C]//2019 IEEE 3rd information technology, networking, electronic and automation control conference (ITNEC). IEEE, 2019: 2495-2499.
- [6] SHEN J, XIONG X, LI Y, et al. Detecting safety helmet wearing on construction sites with bounding - box regression and deep transfer learning[J]. Computer - Aided Civil and Infrastructure Engineering, 2021, 36(2): 180-196.
- [7] 刘思佳. 基于图像分割的工作人员着装检测系统设计与实现[D]. 武汉: 华中科技大学, 2022.
- [8] 刘欣宜, 张宝峰, 符烨, 等. 基于深度学习的污染场地作业人员着装规范性检测[J]. 中国安全生产科学技术, 2020, 16(7): 169-175.
- [9] 何国立, 齐冬莲, 闫云凤. 一种基于关键点检测和注意力机制的违规着装识别算法及其应用[J]. 中国电机工程学报, 2022, 42(5): 1826-1837.
- [10] 冯志珍, 张卫山, 郑宗超. 基于 Mask R-CNN 的高空作业安全带检测[J]. 计算机系统应用, 2021, 30(3): 202-207.
- [11] 张伍康, 潘立志, 郭志彬, 等. 电力场景下基于 RetinaNet 的绝缘手套异常状态视觉检测方法[J]. 湖南科技大学学报(自然科学版), 2022, 37(1): 85-91.
- [12] 袁一丹. 基于图像识别的工作人员穿戴规范性检测技术研究[D]. 成都: 电子科技大学, 2020.
- [13] SHI D. TransNeXt: Robust Foveal Visual Perception for Vision Transformers[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2024: 17773-17783.
- [14] WANG J, XU C, YANG W, et al. A normalized Gaussian Wasserstein distance for tiny object detection[J]. arxiv preprint arxiv, 2021, 2110(3): 13389-13401.
- [15] NGIAM J, CAINE B, HAN W, et al. Starnet: Targeted computation for object detection in point clouds[J]. arxiv preprint arxiv, 2019, 1908(5): 11069-11081.
- [16] ZHU Z, LIANG D, ZHANG S, et al. Traffic-sign detection and classification in the wild[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE, 2016: 2110-2118.
- [17] 张伍康, 潘立志, 郭志彬, 等. 电力场景下基于 RetinaNet 的绝缘手套异常状态视觉检测方法[J]. 湖南科技大学学报(自然科学版), 2022, 37(1): 85-91.
- [18] 王茹, 刘大明, 张建. 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.