Research on Deep Learning-Based Algorithms for Detecting Compliance with Safety Belt Wearing Regulations for High-Altitude Workers *

LIN Libo[1], QIN Shenfeng[1], CHEN Lizhong[2], CHEN Qian[2], WU Linfeng[2], MAO Keji[3], QIAN Xiaofeng[4]
(1.Construction Branch, State Grid Zhejiang Electric Power Co., Ltd., Hangzhou Zhejiang 310008, China;
2.Zhejiang Zheneng Wenzhou Liquefied Natural Gas Co., LTD, Wenzhou Zhejiang 325701, China;
3.College of Computer, Science and Technology, Zhejiang University of Technology, Hangzhou Zhejiang 310023, China;
4.School of Architecture, Zhijiang College, Zhejiang University of Technology, Shaoxing Zhejiang 312030, China)

Abstract: Safety belts play a crucial role in high-altitude operations, ensuring the life safety of personnel and reducing the occurrence of accidents. Due to the diversity and complexity of safety belt usage in high-altitude tasks, it is common for personnel to wear safety belts improperly, preventing them from providing the intended protection. At present, there is limited research focused on the real-time detection of proper safety belt usage, and the values of accuracy of existing methods are often low. Therefore, a high-altitude operation safety belt wearing dataset and is constructed and a deep learning-based algorithm is designed for detecting the compliance of safety belt usage among high-altitude workers. Initially, the optimized EfficientNet is employed to extract features from the original images. Subsequently, YOLOv8 is used to extract the regions of interest for the safety belts. Finally, an attention mechanism-based feature fusion module is designed to combine both sets of features, enhancing the model's ability to focus on the safety belts in the original images. Experimental results on the custom dataset demonstrate that the proposed model achieves an average accuracy of 87.4%. Compared with current mainstream algorithms, the proposed model shows significant performance advantages, meeting the practical requirements for detecting the compliance of safety belt usage in high-altitude operations.

Key words: working at high altitude; safety belt compliance; YOLOv8; EFFICIENTNET; attention mechanism
EEACC: 6135 **doi**: 10.3969/j.issn.1004-1699.2025.11.013

基于深度学习的高空作业人员安全带佩戴规范性检测算法研究 *

林立波[1], 秦沈峰[1], 陈利忠[2], 陈 谦[2], 吴林峰[2], 毛科技[3], 钱晓峰[4]*
(1.国网浙江省电力有限公司建设分公司, 浙江 杭州 310008; 2.浙江浙能温州液化天然气有限公司, 浙江 温州 325701;
3.浙江工业大学计算机科学与技术学院, 浙江 杭州 310023; 4.浙江工业大学之江学院建筑学院, 浙江 , 浙江 绍兴 312030)

摘 要: 安全带在高空作业中扮演着至关重要的角色, 是保障高空作业人员生命安全和减少事故发生的必须装备。由于高空作业中的安全带佩戴的多样性与复杂性, 所以经常会出现高空作业人员安全带佩戴不规范等, 导致安全带起不到应有的保护作用。目前专门针对安全带佩戴的规范性实时检测的研究较少而且精度不高, 所以本文构建了高空作业安全带佩戴数据集, 设计了一种基于深度学习的高空作业人员安全带佩戴规范性检测算法。本文首先采用优化的 EfficientNet 对原始图像进行特征提取, 然后利用 YOLOv8 进行安全带兴趣区域提取, 最后设计了一种带有注意力机制的特征融合模块, 将两种特征相结合, 以增强模型对原始图像中安全带的关注能力。在自制数据集上的实验结果显示, 本文提出的模型平均准确度达到了 87.4%, 与当前主流算法相比, 该模型在性能上表现出了显著优势, 满足了高空作业中安全带佩戴规范性检测的实际需求。

关键词: 高空作业; 安全带佩戴规范性; YOLOv8; EfficientNet; 注意力机制
中图分类号: TN911.73; TP183 **文献标识码**: A **文章编号**: 1004-1699(2025)11-2025-07

高空作业在建筑、维修、清洁等领域中广泛存在, 如电塔高空作业、液化天然气高空作业等, 其安全问题是行业关注的焦点。根据国家安全生产事故统计年报中的数据显示, 高空作业引发的安全事故数量多年来居高不下, 成为工业和建筑领域的重大安全隐患。例如, 2022 年, 全国因高空作业导致的

项目来源: 浙江省基础公益研究计划项目(LTGG23F020002, LGG22F020014); 国家自然科学基金(62072410)
收稿日期: 2024-08-16 **修改日期**: 2024-09-05

死亡人数占总工伤事故死亡人数的比例达到了18%。另外一项统计数据显示,2019 年全国发生的房屋市政工程生产安全事故 733 中,高处坠落事故占到施工安全生产事故的半数以上[1]。这些事故通常后果严重,不仅对作业人员的生命构成重大威胁,还对企业的财产和声誉造成不可估量的损失。具体来说,未佩戴安全带或安全带佩戴不规范是导致高空坠落事故的主要原因之一。根据 2017—2019 年高空坠落事故的直接原因统计数据显示,由于安全带未佩戴或未合格佩戴导致的高空坠落事故占 31%[2]。这一现象表明,尽管安全带已被规定为高空作业的必要防护装备,但在实际操作中,不规范佩戴的现象仍然普遍,需引起更广泛的关注。

如何有效监控和及时发现高空作业人员在安全带佩戴上的不规范行为,成为降低高空作业事故发生率的关键步骤。现有一些应用于车辆驾驶、建筑施工等场景的安全带佩戴不规范检测方法,并不能直接应用于高空作业场景,主要归因于高空作业中安全带佩戴的多样性与复杂性,不同类型的安全带有着各自独特的佩戴标准。如图 1 所示,速插式安全带的正确穿戴方式和位置、其“低挂高用”的佩戴原则、以及腰部安全带的规范使用都极大地增加了检测的难度。此外,与常规的图像识别任务相比,高空作业场景的复杂背景也大幅提升了检测的挑战性。诸如变化的光照条件、视线遮挡以及图像模糊等因素,均可能对检测结果产生不利影响。同时,安全带在整个高空作业场景中占据的视觉区域相对较小,这使得实现高精度检测更加困难。目前,在基于

图 1　六种安全带违章行为

深度学习的高空作业安全带佩戴不规范检测领域中,相关的研究和应用仍有不足,主要原因是检测的单一性,如只检测安全带是否佩戴,而且准确率也尚未达到实际应用的要求。文献[3]采用了传统的 YOLOv3 技术来识别高空作业人员是否正确佩戴了安全带;同时,文献[4]提出了一种称为 YOLO-DFAN 的改进检测算法,该算法基于轻量级的 YOLOv4-tiny 网络,并集成了依赖融合注意力网络,在不影响检测速度的前提下,相比 YOLOv4-tiny 提高了 5.13%的准确度;另外,文献[5]利用自监督方法预训练的 YOLOv5_MobileNetv3 模型,成功地检测了作业人员、安全带以及安全帽,显示出了较好的性能;文献[6]对 YOLOv8[7] 网络进行了改进,尽管他们实现了高精度,但研究范围仅限于安全带是否佩戴的基本识别任务。

因此,设计一种能够实时并准确检测高空作业安全领域安全带佩戴不规范行为的方法是当前中的一项重要任务。本文设计了一种针对高空作业安全带的多种佩戴不规范行为检测的方法,具体如下,首先,本文构建了高空作业安全带佩戴的数据集;其次,针对高空作业场景设计模型架构,基于 EfficientNet[8] 网络进行优化,对原始图像进行特征提取;同时利用 YOLOv8 的分割模式对原始图像中的安全带进行兴趣区域提取,获取安全带的细节信息;本文还通过设计一种带有注意力机制的特征融合模块,将两种特征相结合,以增强模型对原始图像中安全带的关注能力。最后,在自制数据集上验证模型的性能效果。

1　算法设计

本文首先采用了优化的 EfficientNet 对原始图像进行特征提取。EfficientNet 以其卓越的计算效率和高精度表现,能够从图像中提取出丰富的特征,为后续的分析提供基础,同时本文将 EfficientNet 中移动翻转瓶颈卷积(Mobile Inverted Residual Bottleneck Block,MBConv)模块的挤压与激励(Squeeze-and-Excitation,SE)[9] 注意力机制替换为通道和空间注意力模块(Convolutional Block Attention Module,CBAM)[10],从而提升模型对重要特征的关注度。为了进一步提升模型对安全带特征的关注度,引入了 YOLOv8 模型,对安全带区域进行专门的特征提取。通过 YOLOv8 的分割模式,能够精准地获取安全带的细节信息,使模型更加聚焦于与安全带相关的特征,从而为检测任务提供更精确的输入。在此基础上,本文设计了一种带有注意力机制的特征融

合模块。该模块通过将 YOLOv8 提取的安全带特征作为提示信息,与 EfficientNet 的特征输出相结合。在融合过程中,注意力机制被引入,以动态调整模型对各个特征的关注程度。通过这种方式,模型能够更加有效地聚焦于原始图像中的安全带区域,大幅度提高了对安全带佩戴不规范行为的检测能力。模型整体结构如图 2 所示。

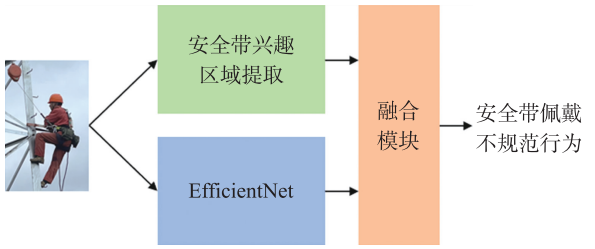

图 2　模型整体结构图

1.1　EfficientNet 网络的优化

1.1.1　EfficientNet 网络

EfficientNet 网络以其复合缩放策略和高效的卷积操作在图像分类任务中取得了卓越的性能。EfficientNet 通过网络参数 α,β 和 γ 来分别控制网络的深度、宽度和分辨率,从而在训练资源一定的情况下,使模型性能得到最优提升。复合缩放方法如式(1)所示:

$$\text{depth}=\alpha^{d},\text{width}=\beta^{w},\text{resolution}=\gamma^{r} \tag{1}$$

式中:α,β 和 γ 是通过网格搜索优化得出的常数组合,保证了不同模型尺寸(EfficientNet-B0 到 B7)之间计算效率和精度的最优平衡。MBConv 是 EfficientNet 网络的核心模块,其设计灵感来源于 MobileNetV2[11] 中的倒残差结构。MBConv 模块的设计旨在提高计算效率和模型性能,具体结构如图 3 所示。

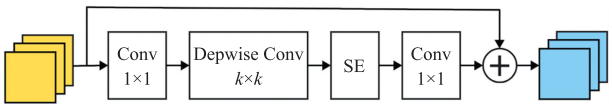

图 3　MBConv 模块结构

首先输入特征图通过一个 1×1 卷积扩展到更高维度,并使用 ReLU 激活函数增加特征图的表达能力。接着是深度可分离卷积[12],将传统卷积分解为深度卷积和逐点卷积,以减少计算量和参数量,同时保留特征提取能力。随后是 SE 模块,通过全局平均池化和两个全连接层生成通道加权特征图,从而自适应调整各通道的权重。之后通过 1×1 卷积将扩展后的高维特征重新压缩为低维特征,以减少计算量和参数量。最后是跳跃连接,将模块的输入与输出相加,以保留输入特征和输出特征之间的信息传递。MBConv 模块通过这五部分的设计,实现了计算效率和特征提取能力的平衡,使 EfficientNet 在保持高效性的同时,具备了较强的特征表达能力和模型性能。

由于高空作业的图像背景通常高度复杂,包含多种视觉干扰因素,例如各种构件、电线、工具以及自然环境等。这对图像处理和特征提取提出了更高的要求,需要模型具有更强的特征表达和识别能力。在这种复杂背景下,EfficientNet-B7 作为该系列中参数量最大、尺度最高的版本,能够提供更高的分辨率、更深的网络层次和更多的特征通道,从而更有效地捕捉和区分图像中的细节信息,因此,本文采用 EfficientNet-B7 作为模型的主干网络。

1.1.2　CBAM 注意力机制

为了进一步增强 EfficientNet 网络对关键特征的识别能力,本文将其 MBConv 模块中的 SE 注意力机制替换为 CBAM 模块。CBAM 注意力机制能够在通道和空间两个维度上对特征进行加权,从而提升模型对重要特征的关注度,具体包括通道注意力模块和空间注意力模块两部分。

通道注意力模块通过对输入特征图进行全局平均池化和全局最大池化,生成两个一维特征图,表示每个通道的全局特征。接着,这两个特征图分别经过共享权重的全连接层(Fully Connected Layer,FC),并通过 Sigmoid 激活函数生成通道加权特征图。最后,将两个加权特征图相加,并与原始输入特征图逐通道相乘,实现特征的重标定,使得模型能够更关注那些对当前任务更重要的通道特征。其整体过程如式(2)所示,其中,F 表示输入的特征图,GlobalAvgPool(F) 和 GlobalMaxPool(F) 分别表示对 F 进行全局平均池化和全局最大池化操作生成的特征图,FC 表示全连接层,σ 表示 Sigmoid 激活函数,F' 表示经过通道加权后的特征图。

$$F'=F\times\sigma\{\text{FC}[\text{GlobalAvgPool}(F)]+\text{FC}[\text{GlobalMaxPool}(F)]\} \tag{2}$$

$$F''=F'\times\sigma(\text{Conv}_{7\times7}\{[\text{Mean}(F',\text{axis}=C);\text{Max}(F',\text{axis}=C)]\}) \tag{3}$$

空间注意力模块通过对输入特征图在通道维度上进行平均池化和最大池化,生成两个二维特征图;然后,将这两个特征图在通道维度上进行拼接,生成一个融合特征图;接着,对融合特征图通过一个 7×7 卷积层处理,生成空间加权特征图,并通过 Sigmoid 激活函数得到最终的空间注意力特征图;最后,将空间注意力特征图与通道注意力模块输出的特征图逐元素相乘,实现特征的重标定,使得模型能够更关注

图像中的重要区域。其整体过程如式(3)所示,其中,F'表示通道加权后的特征图,Mean(F',axis=C)和 Max(F',axis=C)分别表示对 F'在通道维度进行的平均池化和最大池化操作生成的特征图,$\mathrm{Conv}_{7\times7}$表示 7×7 卷积操作,σ 表示 Sigmoid 激活函数,F''表示经过空间加权后的特征图。

通过将 MBConv 模块中的 SE 模块替换为 CBAM 模块,EfficientNet 网络能够在通道和空间两个维度上同时进行注意力加权,提升模型对关键特征的识别能力和图像分类性能。CBAM 模块的引入使得网络能够自适应地调整各通道及空间位置的权重,增强了网络对关键特征的捕捉和识别能力,为高效准确的高空作业安全带佩戴不规范检测奠定了坚实基础。

1.2 兴趣区域的提取

在高空作业人员的佩戴不规范检测中,准确提取安全带的兴趣区域对于后续的分析和特征融合至关重要。本文采用了 YOLOv8 的分割模式,对高空作业人员的图像兴趣区域进行提取。

YOLOv8 采用了多尺度特征融合和改进的目标框架,能够在复杂背景下准确识别和分割出目标物体。在本文中,YOLOv8 的分割模式被用于对输入图像进行处理,以分割出包含安全带的区域。这些区域在图像中通常较小且容易被忽略,因此通过 YOLOv8 分割出安全带的兴趣区域,可以有效地提高模型对安全带特征的关注度,为后续的特征融合奠定基础。在具体操作中,首先将原始高空作业图像输入到 YOLOv8 模型中,模型通过特征金字塔结构提取出不同尺度的特征图。然后,通过分割头将这些特征图用于生成高精度的分割掩码。该掩码精准地标注出图像中安全带所在的区域,形成安全带的兴趣区域图。提取出的安全带兴趣区域不仅包含了安全带的轮廓信息,还包含了其在复杂背景下的细节特征,这对于后续的特征融合和安全带佩戴不规范检测具有重要意义。

1.3 特征融合模块

本文提出的带有注意力机制的特征融合模块是通过融合 EfficientNet 和 YOLOv8 的特征输出,将安全带特征作为一种提示信息,使模型能够更加关注图像中的安全带区域,从而提高特征提取的准确性和鲁棒性,具体结构如图 4 所示。

首先,将安全带区域的特征作为初始查询向量 $\boldsymbol{q}$,然后利用 EfficientNet 的特征输出作为键 k 和值 v,进行注意力融合,从而更新和丰富安全带的表征。这一过程通过注意力权重确保安全带能够有效捕捉

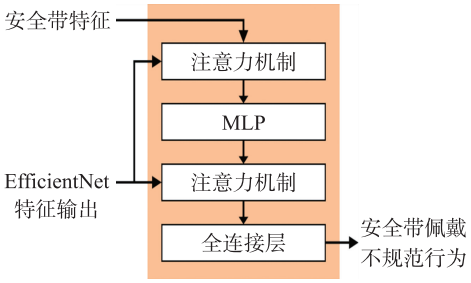

图 4 融合模块结构图

到整体图像中与其相关的信息。计算过程如式(4)所示:

$$\tilde{E}_{\mathrm{belt}}=\mathrm{softmax}\left[\frac{E_{\mathrm{belt}}\boldsymbol{W}_q(E_{\mathrm{image}}\boldsymbol{W}_k)^{\mathrm{T}}}{\sqrt{d_k}}\right]E_{\mathrm{image}}\boldsymbol{W}_v \quad (4)$$

式中:E_{belt}、E_{image} 分别为安全带特征表示和 EfficientNet 特征输出,$\boldsymbol{W}_q$、$\boldsymbol{W}_k$ 和 $\boldsymbol{W}_v$ 是权重矩阵,d_k 是注意力的缩放因子。

然后,更新后的安全带表征通过一个两层的多层感知机进行特征变换,以调整维度进行后续的计算。然后,EfficientNet 特征输出被用作新的查询,再次与已更新的安全带表征进行注意力融合,确保整体图像能够更精确地关注安全带中的重要信息。计算过程如式(5)所示:

$$\tilde{E}_{\mathrm{image}}=\mathrm{softmax}\left[\frac{E_{\mathrm{image}}\boldsymbol{W}_q(\tilde{E}_{\mathrm{belt}}\boldsymbol{W}_k)^{\mathrm{T}}}{\sqrt{d_k}}\right]\tilde{E}_{\mathrm{belt}}\boldsymbol{W}_v \quad (5)$$

式中:$\tilde{E}_{\mathrm{belt}}$为式(4)得到的特征表示。

最后,通过一个全连接层,将整合后的特征映射到最终的输出空间,以得到最终的预测。

2 实验结果与分析

2.1 数据集制作

为了有效开展高空作业人员安全带佩戴不规范检测的研究,本文使用的数据来源于国家电网提供的现场施工图片数据集。该数据集共包含 1451 张高分辨率图像,涵盖了各种复杂的工作环境和多样的作业场景。这些图像经过严格筛选和整理,确保了数据的多样性和代表性。

在数据集的构建过程中,本文将 1 451 张图像分为训练集和验证集。其中,1 161 张图像用于模型的训练,以确保模型能够充分学习各种情况下的特征和模式;其余 290 张图像用于验证模型的性能,以评估其在未见过的数据上的泛化能力。这样的数据划分能够保证模型在实际应用中的稳定性和可靠性。

此外,针对本文的研究需求,专门为该数据集制作了两套标签,两套标签的图片数量均为 1 451 张,具体如下:

①安全带佩戴不规范行为标签:该标签集用于标注图像中存在安全带佩戴不当或未佩戴安全带的情况,包括速插式安全带位置错误、速插式安全带松弛、速插式安全带低挂高用、速插式安全带未系、腰部安全带未系、腰部安全带低挂高用六种安全带佩戴不规范行为。每个类别的样本数据分布如表 1 所示。这一标签集将作为本文模型的主要训练标签,帮助模型识别出高空作业人员的安全带是否存在佩戴不规范行为。

表 1　安全带佩戴不规范行为标签样本分布情况

	速插式安全带位置错误	速插式安全带松弛	速插式安全带低挂高用	速插式安全带未系	腰部安全带未系	腰部安全带低挂高用
训练集	105	191	174	204	227	71
验证集	41	42	47	39	52	29

②安全带实例分割标签:该标签集用于标注图像中安全带的具体位置和形状,精确划分出安全带在图像中的像素区域,标签类别为高空作业人员、速插式安全带和腰部安全带三种,标注示例如图 5 所示,每个类别的样本数据分布如表 2 所示。这一标签集主要用于安全带兴趣区域提取部分,帮助模型在复杂的背景下精确分割出安全带的区域,为后续的特征融合提供支持。

图 5　安全带实例分割标注

表 2　安全带实例分割标签样本分布情况

	高空作业人员	速插式安全带	腰部安全带
训练集	1 161	957	934
验证集	290	251	238

通过对数据集的合理划分和标签制作,本文构建了一个高质量的、自定义的数据集,为后续的模型训练和验证提供了坚实的基础。这一数据集不仅涵盖了丰富的高空作业场景,还能够支持多种检测任务,确保了研究成果的实用性和推广价值。

2.2　模型训练

实验在 Windows 11 操作系统上进行,使用 Python 语言和 PyTorch 框架构建模型,显卡采用 GeForce RTX 3080 GPU。本文的模型训练过程分为两个阶段。首先,在第一阶段中,训练 YOLOv8 的安全带分割模型,用于提取安全带的兴趣区域。训练完成后,冻结分割模型的参数,使其作为安全带特征提取器。接着,进入第二阶段,训练改进后的 EfficientNet-B7,并结合特征融合模块。此阶段使用二元交叉熵损失函数(Binary Cross-Entropy Loss, BCE Loss)[13] 进行优化。整体训练采用 Adam[14] 优化器,初始学习率设为 0.001,epoch 大小为 32,训练 100 轮次。通过这种训练方式,模型不仅关注整体图像的特征,还能细致地识别安全带区域,最终本文的模型在自制数据集上的准确度达到了 87.4%。

2.3　结果分析

2.3.1　对比实验

在对比实验中,本文将所提出的模型与当前的几种主流模型在自制数据集上进行比较,具体包括 Resnet50[15]、EfficientNet-B7、YOLOv8 等深度学习模型。对比的指标主要包括准确度(Accuracy)、召回率(Recall)和 F1 值(F1-Score),以全面评估模型在实际应用中的性能。

由表 3 可以看出,本文的模型通过引入了特征融合和注意力机制,在准确度、召回率和 F1 值上均优于其他模型,证实了提出的改进方法的有效性。

表 3　不同模型对比实验

模型	Accuracy	Recall	F1-Score
EfficientNet-B7	0.768	0.795	0.784
Resnet50	0.771	0.789	0.788
Swin Transformer[16]	0.776	0.792	0.791
YOLOv8	0.796	0.821	0.807
EfficientViT[17]	0.812	0.834	0.832
YOLOv8-seg	0.849	0.865	0.853
本文模型	**0.874**	**0.902**	**0.893**

2.3.2　消融实验

为了评估不同模块对模型整体性能的影响,本文设计了消融实验,结果如表 4 所示,表中 M1 表示不添加特征融合模块的原始 EfficientNet-B7,M2 表示不添加特征融合模块的改进 EfficientNet-B7,M3 表示用简单的特征拼接方式替换特征融合模块的模型,M4 表示本文提出的最终模型。

表 4 消融实验

模型	Accuracy	Recall	F1-Score
M1	0.768	0.795	0.784
M2	0.779	0.806	0.785
M3	0.823	0.857	0.859
M4	0.874	0.902	0.893

实验结果表明,原始 EfficientNet-B7 在复杂场景中的检测性能有限,而通过引入 CBAM 模块,改进后的 EfficientNet-B7 提升了 1%的准确度,但仍然不满足安全带佩戴不规范检测的需求。同时,使用简单特征拼接的模型性能虽然有所上升,但其未能充分利用特征信息,仍有提升空间。最后,本文提出的最终模型通过结合改进的 EfficientNet-B7、设计的特征融合模块以及 YOLOv8 的分割提示信息,在各项指标上均表现优异,显著提升了模型的检测精度和鲁棒性,验证了所提方法的有效性。

3 总结

本文提出了一种基于深度学习的高空作业安全带佩戴不规范检测方法。首先,改进了 EfficientNet 网络,通过引入 CBAM 注意力机制,提高了模型对关键特征的关注能力,从而增强了检测的准确性。其次,利用 YOLOv8 的分割模式对安全带区域进行了精准分割,使模型能够更好地捕捉到安全带的细节特征,并作为提示信息引导模型进行更有效的特征提取。最后,通过设计特征融合模块,将提取的安全带区域特征与 EfficientNet 的输出特征进行融合,在特征融合过程中进一步加强了模型对安全带区域的关注。

通过实验验证,本文提出的模型在安全带佩戴不规范检测任务中表现出了优异的性能。对比实验表明,改进后的 EfficientNet 与特征融合模块的结合显著提升了检测的精度。消融实验进一步证明了每个组件对模型性能的贡献。

综上所述,本文为高空作业人员的安全监管提供了一种有效的技术手段,能够在复杂环境下实现高效准确的安全带佩戴不规范检测。这一方法不仅具有较强的实际应用价值,同时也为相关领域的研究提供了新的思路和方向。未来的研究可以进一步优化模型的计算效率,或结合更多先进的深度学习技术,以提高检测的实时性和精度。

参考文献:

[1] 中华人民共和国住房和城乡建设部办公厅. 住房和城乡建设部办公厅关于 2019 年房屋市政工程生产安全事故情况的通报[EB/OL]. (2020-06-19). http://www. fangchan. com/policy/29/2020 - 06 - 30/6683570358119108894.html.

[2] 张萌. 基于深度学习的脚手架高空作业险态智能识别方法研究[D]. 镇江:江苏大学,2022.

[3] Shanti M Z,Cho C S,Byon Y J,et al. A Novel Implementation of an AI-Based Smart Construction Safety Inspection Protocol in the UAE [J]. IEEE Access, 2021, 9: 166603-166616.

[4] Yan W,Wang X,Tan S. YOLO-DFAN:Effective High-Altitude Safety Belt Detection Network[J]. Future Internet, 2022,14(12):349.

[5] Xiang Y, Yang Y, Sun J, et al. Research on Safety Belt Wearing Detection Algorithm based on Artificial Intelligence Working at Altitude[C]//2023 2nd International Conference on Artificial Intelligence and Blockchain Technology(AIBT),Zibo,China,2023:93-102.

[6] Jiang T,Li Z,Zhao J,et al. An Improved Safety Belt Detection Algorithm for High-Altitude Work Based on YOLOv8[J]. Electronics,2024,13(5):850.

[7] Varghese R,Sambath M. YOLOv8:A Novel Object Detection Algorithm with Enhanced Performance and Robustness[C]//2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems(ADICS),Chennai,India,2024:1-6.

[8] Tan M X,Le Q. EfficientNet:Rethinking model scaling for Convolutional Neural Networks[C]//36th International Conference on Machine Learning,Long Beach,CA,USA, 2019:6105-6114.

[9] Hu J, Shen L, Sun G. Squeeze-and-Excitation Networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City,UT,USA,2018: 7132-7141.

[10] Woo S,Park J,Lee J Y,et al. CBAM:Convolutional Block Attention Module[C]//2018 15th European Conference on Computer Vision (ECCV), Munich, Germany, Springer,2018:3-19.

[11] Sandler M, Howard A, Zhu M, et al. MobileNetv2: Inverted Residuals and Linear Bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition,Salt Lake City,UT,USA,2018:4510-4520.

[12] Chollet F. Xception:Deep Learning with Depthwise Separable Convolutions[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR),Honolulu, HI,USA,2017:1251-1258.

[13] Ruby U, Yendapalli V. Binary Cross Entropy with Deep Learning Technique for Image Classification[J]. International Journal of Advanced Trends in Computer Science and Engineering,2020,9(4):5393-5397.

[14] Kingma D P,Ba J. Adam:A Method for Stochastic Opti-

mization[C]//3rd International Conference on Learning Representations, San Diego, CA, USA, 2015: arxiv. 1412.6980.

[15] He K,Zhang X,Ren S,et al. Deep Residual Learning for Image Recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las, Vegas,NV,USA,2016:770-778.

[16] Liu Z,Lin Y,Cao Y,et al. Swin Transformer:Hierarchical Vision Transformer using Shifted Windows[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV),Montreal,QC,Canada,2021:9992-10002.

[17] Liu X,Peng H,Zheng N,et al. EfficientViT:Memory Efficient Vision Transformer with Cascaded Group Attention[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Vancouver, BC, Canada,2023:14420-14430.

林立波(1972—),男,高级工程师,国网浙江建设分公司安全总监,长期从事输变电工程安全管理工作;

秦沈峰(1977—),男,高级工程师,国网浙江建设公司基建安全质量管控中心副主任,长期从事输变电工程安全管理工作;

陈利忠(1968—),男,高级工程师,主要研究方向:LNG 接收站数字化管理等;

毛科技(1979—),男,博士,副教授,博士生导师,主要研究方向是智能计算、物联网技术、大数据分析等;

钱晓峰(1978—),男,硕士,通讯作者,浙江工业大学之江学院助理研究员,中共党员,主要研究方向为人工智能应用,02662@ zzjc.edu.cn。