

基于改进 YOLOv8 的电力作业人员安全带检测

范宇恒¹, 焦良葆^{1,2}, 郑良成¹, 钱予阳¹, 孟琳^{1,2}

(1. 南京工程学院 人工智能产业技术研究院, 南京 211167;
2. 江苏省智能感知技术与装备工程研究中心, 南京 211167)

摘要: 正确穿戴安全带是预防电力作业人员高空坠落的重要措施; 针对在电力现场中作业人员是否穿戴安全带检测效率低以及实效性差的问题, 提出了一种基于 YOLOv8n 的电力作业人员安全带检测方法; 该算法在特征提取网络中添加通道注意力模块, 提升了模型的识别能力; 引入了加权双向特征金字塔网络结构进行特征融合, 提高特征学习能力, 并降低模型复杂度; 将原先的 CIOU 损失函数替换为 WIOU 损失函数, 进一步提高了模型的检测效率以及对于小目标的辨识能力; 实验结果表明, 该算法的 mAP 平均精度均值达到 96.5%, 识别效果明显提升, 并且优于其他经典目标检测模型, 验证了新算法的有效性。

关键词: 安全带检测; YOLOv8; 注意力机制; 金字塔网络; 损失函数

Seat Belt Detection for Electrical Workers Based on Improved YOLOv8

FAN Yuheng¹, JIAO Liangbao^{1,2}, ZHENG Liangcheng¹, QIAN Yuyang¹, MENG Lin^{1,2}

(1. AI Industrial Technology Research Institute, Nanjing Institute of Technology, Nanjing 211167, China;
2. Jiangsu intelligent perception technology and equipment Engineering Research Center, Nanjing 211167, China)

Abstract: Wearing seat belts correctly is an important measure to prevent electrical workers from falling from heights. In order to solve the low efficiency and poor effectiveness of wearing seat belts for workers in power sites, a safety belt detection method for power workers based on improved YOLOv8 is proposed. The algorithm adds a squeeze and excitation (SE) attention mechanism in the network to improve the recognition ability of the model. Also, a weighted bidirectional feature pyramid network structure is introduced to perform the feature fusion, and improve the feature learning ability, and reduce the complexity of the model. The WIOU loss function is used to replace the original CIOU loss function, which further improves the detection accuracy and adaptability of the model to small targets. Experimental results show that the proposed algorithm reaches the average accuracy by 96.5%, improving the recognition effect significantly, the proposed model is better than other classical object detection ones, which verifies the effectiveness of the new algorithm.

Keywords: seat belt detection; YOLOv8; attention mechanism; pyramid network; loss function

0 引言

随着电网的不断扩张和电力设施的不断更新, 电力高空作业已成为维护和发展电力系统不可或缺的一部分。在进行电力设备的安装、维护、检修等工作时, 电力作业人员往往需要面临高空环境下的各种安全风险。根据《国家电网公司电力安全工作规程》明确指出, 在高空作业现场, 由于存在高坠以及物体打击的风险, 作业人员应正确佩戴安全帽; 高处作业人员应正确使用安全带, 在攀登或转移作业位置过程中不得失去保护; 在电力作业现场, 作业负责人和专职监管人员必须始终在场, 对电力作业人员的安全行为进行密切监督, 并立即纠正任何不安全行为。目前在电网企业中通常以人力巡检或相关人员进行视频监控来对电力作业人员违规行为进行实时监督以免发生意外, 但存在着时效性差、监管效率低等问题。因此, 结合现有的

视频采集设备, 将检测模块部署到边缘计算设备中, 利用计算机视觉技术进行对电力作业人员行为规范的自动检测, 大大降低人工成本, 实现更及时、准确地发现不安全行为^[1]。

近年来, 深度学习在目标检测领域得到广泛应用, 使得目标检测技术日趋成熟^[2]。当前, 深度学习目标检测算法主要可分为两类: 一是双阶段目标检测算法, 例如 R-CNN 系列和 Faster R-CNN 等。它们通过预先提出的区域 (region proposal) 和卷积神经网络进行样本分类和计算; 另一类是单阶段目标检测算法, 例如 YOLO 系列和 SSD 等。它们直接在网络中提取特征值进行目标分类和定位, 具有快速和高精度的优势^[3]。目前已有一些算法对于电力作业人员安全带的检测。文献 [4] 提出了结合空洞卷积和深度可分离卷积的轻量级特征提取网络来检测高空作业是否佩戴安全带, 但在适应复杂环境和实际可行性有一定的

收稿日期: 2024-05-27; 修回日期: 2024-06-17。

基金项目: 江苏省产学研合作项目 (BY20230656)。

作者简介: 范宇恒 (2000-), 男, 硕士研究生。

焦良葆 (1972-), 男, 教授, 硕士研究生导师。

引用格式: 范宇恒, 焦良葆, 郑良成, 等. 基于改进 YOLOv8 的电力作业人员安全带检测[J]. 计算机测量与控制, 2024, 32(11): 140-145.

局限性。文献 [5] 基于 YOLOx 模型来进行安全带检测, 利用 Mosaic 和 MixUp 来进行数据的增扩, 提高模型的鲁棒性, 但在实际场景检测效果欠佳。文献 [6] 提出了一种基于改进 MobileNet_YOLOv4 网络的电力高空作业识别, 并调整空间金字塔结构, 提高网络的检测精度, 但出现对于监护袖章的小目标检测精度较低的问题。

为了针对上述存在的准确性、实时性等难题, 本文以 YOLOv8n 算法为基础对电力高空作业场景下人员是否穿戴安全带、安全帽以及是否有监护人员在场进行目标检测, 首先通过添加 SE 注意力机制, 提高算法检测精度^[7]; 再引入加权双向特征金字塔网络结构, 提高低层细节和高层语义信息的多尺度特征融合^[8], 提升算法对于目标的学习能力; 然后通过使用 WIoUv3 损失函数替换了原先的 CIoU 损失函数, 提高了模型在不同复杂环境下的适应性^[9]。

1 YOLOv8 网络结构

YOLOv8 是 Ultralytics 公司于 2023 年 1 月 10 日发布的最新版本之一, 属于 YOLO (You Only Look Once) 系列模型, 其融合了 YOLOv5 的成功经验, 并引入了一些新的功能和改进, 以进一步提升性能和灵活性^[10]。相对于其它版本, YOLOv8n 采用了更为轻量级的网络结构, 拥有更小的参数量和计算复杂度, 适用于资源受限的设备和场景。它在保持高水准的检测精度的同时, 具备更快的推理速度和更小的模型体积。因此, 鉴于电力现场的实际需求, 需将检测模块部署到边缘计算设备中实现实时运行, 本文将采用 YOLOv8n 作为基础模型。YOLOv8n 的网络结构可以分为 4 个部分: 输入端 (Input)、特征提取网络 (Backbone)、特征融合网络 (Neck) 以及输出端 (Output)^[11]。

输入端通常接受批量的图像数据作为输入, 并进行一些预处理操作, 将不同大小的图像进行缩放、裁剪以及归一化等操作, 加快了后续模型的检测速率。而在最后几轮训练中关闭 Mosaic 数据增强, 使得模型具有更好的稳定性和性能, 减少了过拟合的风险。

主干网络包括了 C2f、CBS 和 SPPF 结构, 其中 C2f 模块融合了 C3 模块和 ELAN 结构^[12], 这种设计有助于减少特征图的维度, 保证模型在轻量化的同时提高了模型的效率和性能。CBS 结构在 C2 的基础上添加了一个瓶颈结构, 进一步增加了模型的非线性表达能力。SPPF 模块是空间金字塔池化融合结构, 延续了 YOLOv5 的网络结构, 能够捕获不同尺度的语义信息, 具有融合全局特征与局部特征的能力。

在颈部 Neck 中, YOLOv8n 网络还是采用了 PANet 结构, 是一种用于多尺度目标检测的网络结构。它构建特征金字塔来实现不同通道间特征信息的获取, 有效提高了目标检测的性能和鲁棒性。

最后在检测头部分, YOLOv8 引入了解耦头 (Decoupled-Head) 结构, 使用两条并行分支分别提取目标的类别信息和位置信息, 有助于减少网络的计算复杂度, 并且能够更好地提高目标检测的精度和效率。

2 YOLOv8 改进网络

2.1 改进后的网络结构

为了能够达到在不同复杂场景下对于电力作业人员是否穿戴安全带的检测精度要求, 首先由于作业现场环境复杂且检测目标较远, 作业人员容易出现遮挡的情况, 对于安全带等小目标检测效果不佳等问题, 本文在骨干网络添加 SE 注意力机制, 来增强对电力作业人员以及安全带的检测; 其次, 原 YOLOv8n 网络采用的 PANet 网络结构, 计算成本过大, 存在一些冗余, 会影响边缘计算模块推理速度, 因此本文引入加权双向特征金字塔网络 (BiFPN) 以减少模型计算量, 同时提升检测精度; 最后, 采用 WIoUv3 损失函数取代原始网络的 CIoU 损失函数, 进一步提升网络整体性能。改进后的网络结构如图 1 所示。

2.2 SE 注意力机制

注意力机制 (attention mechanism) 是一种模拟人类视觉系统的方法, 在应对大量输入信息时, 能够有效的集中于当前任务更为重要的信息, 减少对其它信息的注意, 甚至将不相关的信息进行筛选, 进而解决信息超载问题, 并提高任务执行效率和准确性^[13]。

Hu 等人^[14]提出了一种轻量级的通道注意力模块 (Squeeze-and-Excitation), 简称 SE 模块, 其具体结构如图 2 所示。该模块的核心思想是通过两个全连接层对输入信息进行加权平均池化, 得到一个权重矩阵, 其每个特征通道都会赋予不同的权重值, 即权重系数越大, 对应的通道信息越重要^[15]。

SE 注意力机制由压缩 (squeeze), 激励 (excitation) 和调节 (scale) 3 个主要步骤组成。

压缩过程中, SE 注意力机制通过全局平均池化操作将输入大小为 $H \times W \times C$ 的特征图压缩为 $1 \times 1 \times C$ 的特征向量, 从而减少了每个通道的维数并增加了模型的全局感受野。其计算公式如下所示:

$$Z = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (1)$$

式中, Z 为输出的特征向量; F_{sq} 为压缩函数; H, W 为输入特征图 u_c 的高和宽; i, j 为图像长宽的相对位置。

在激励阶段, 将压缩后的特征通过两个全连接层来学习每个通道的权重, 来捕获每个通道间的依赖关系, 以增强重要通道的响应, 其计算公式为:

$$s = F_{ex}(z, W) = \sigma(W_2 \delta(W_1 z)) \quad (2)$$

式中, s 为每个通道的权重值; F_{ex} 为激发函数; σ 为 Sigmoid 激活函数; W_1 和 W_2 为两个全连接层的学习参数。

最后进行权重调节, 将每个通道的权重与原始特征图进行逐通道相乘操作, 以此提高特征图中重要信道的关注。

$$F_{scale}(s_c, u_c) = s_c u_c \quad (3)$$

式中, s_c 为第 c 通道的裁剪系数; u_c 为第 c 通道的特征图。

2.3 改进的特征融合结构

原本的 YOLOv8n 网络在特征融合部分采用 PANet 金字塔结构, 是对 FPN 的一种改进, 如图 3 (a) (b) 所示。

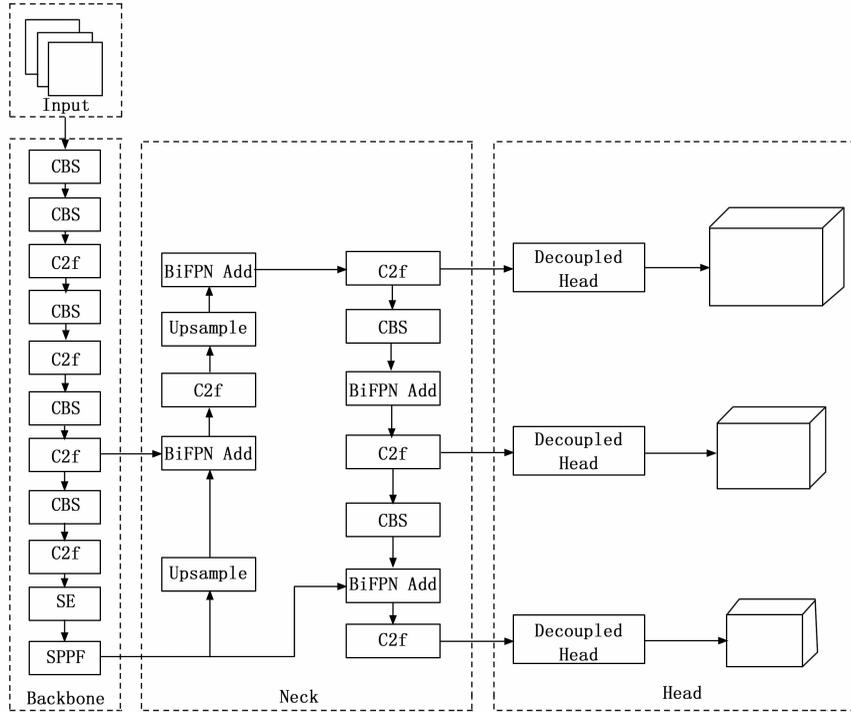


图 1 改进的 YOLOv8n 网络结构

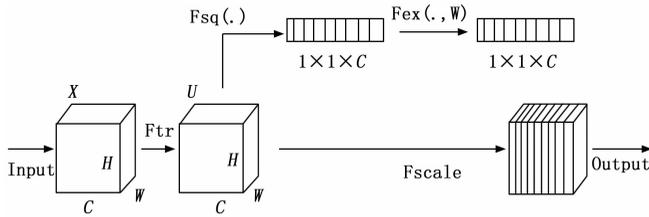


图 2 SE 注意力模块结构

其引入了路径聚合的方式，将浅层特征图和深层特征图进行聚合，并沿着自顶而下和自底而上的双路径进行传递特征信息，但只能实现两个层次的特征融合，不仅对于小目标的识别精度较差，还增加了额外的参数和计算量。

为此，本文提出了加权双向特征金字塔网络^[16] (Bidirectional Feature Pyramid Network)，如图 3 (c) 所示。该结构既可以在不同层级之间进行信息交互来提高特征融合效果，又通过删除冗余节点来降低参数计算量，实现多尺度特征融合，提高模型检测精度^[17]。

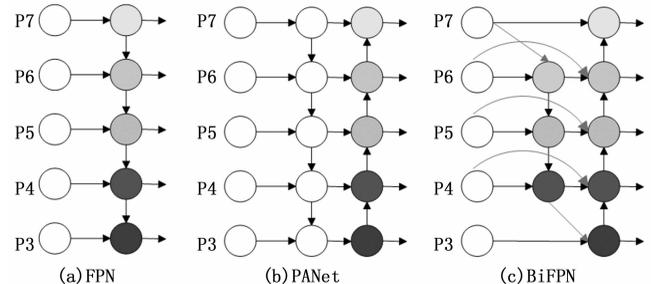


图 3 不同特征融合结构图

BiFPN 金字塔网络结构与 PANet 也有所不同，首先去掉了一些只有具有传输特征信息的节点，但并不影响整体网络的性能。其次，如果输入和输出节点处于同一层次，则额外添加一条路径，在不增加太多的计算成本的前提下，更好地实现多尺度特征融合。

当不同尺度的特征图进行融合时，通常情况下是将其特征图尺度调整为相同大小，然而每个特征图对输出特征的影响不同，导致效果并不理想。因此为解决这一问题，BiFPN 采用归一化加权融合方式，公式如式 (4) 所示：

$$O = \sum_i \frac{\omega_i}{\epsilon + \sum_j \omega_j} I_i \quad (4)$$

其中： I_i 为特征图； ω_i 为学习权重；每个 ω_i 后加 ReLU 激活函数，可以确保 $\omega_i \geq 0$ ； $\epsilon = 0.0001$ ，用来避免数据不稳定性，最终使得每个归一化权重在 0 到 1 之间。以图 7 (c) 中 P6 层为例，其特征如下式 (5) (6) 所示：

$$P_6^{nd} = \text{Conv}\left(\frac{\omega_1 p_6^m + \omega_2 \text{Resize}(P_7^m)}{\omega_1 + \omega_2 + \epsilon}\right) \quad (5)$$

$$P_6^{\text{out}} = \text{Conv}\left(\frac{\omega_1 p_6^m + \omega_2 P_6^{nd} + \omega_3 \text{Resize}(P_5^{\text{out}})}{\omega_1 + \omega_2 + \omega_3 + \epsilon}\right) \quad (6)$$

式中， P_5^m 为 P_5 层的输入特征； P_5^{nd} 为自顶而下的 P_5 层的中间特征； P_5^{out} 为自底而上的 P_5 层的输出特征；Conv 为深度可分离卷积。

2.4 优化损失函数

损失函数被用来度量模型预测值与真实标签值之间的差异或误差，合理设计损失函数对模型检测性能具有重要的意义。YOLOv8 模型中默认使用 CIoU (complete inter-

section over union) 损失函数^[18]。CIoU 在目标框回归上, 综合考虑了 3 个重要的几何因素, 即预测框与真实框的重叠部分、纵横比以及中心点距离, 从而提高模型的目标检测精度。但是对于低质量标注框和小目标框的回归有一定的局限性, 且由于使用复杂的函数计算, 会增加模型训练时间^[19]。基于此, 本文提出了 WIoUv3 损失函数^[20], WIoU 是基于动态非单调聚焦机制, 没有进行纵横比计算, 相比 CIoU 具有更快的检测速度。其结构如图 4 所示。

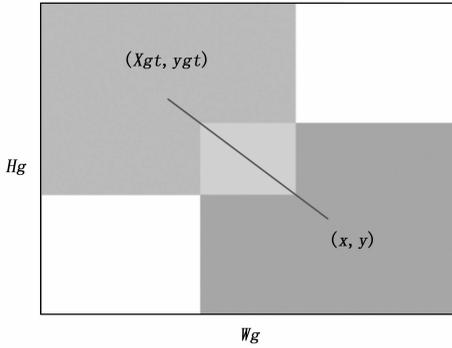


图 4 WIoU 损失函数结构图

WIoU 损失函数的计算公式如下所示:

$$L_{IoU} = 1 - IoU \quad (7)$$

$$R_{WIoU} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)}\right) \quad (8)$$

$$L_{WIoUv1} = R_{WIoU} L_{IoU} \quad (9)$$

式中, W_g 和 H_g 为真实框和预测框的最小闭合区域的宽和高; x_{gt} 和 y_{gt} 为真实框的中心点坐标, x 和 y 为预测框的中心点坐标。

为了使模型对于低质量图像具有更好的分类性能, WIoUv2 引入了单调聚焦系数 L_{IoU}^* , 则其损失函数的计算公式为:

$$L_{WIoUv2} = \left(\frac{L_{IoU}^*}{L_{IoU}}\right) L_{WIoUv1} \quad (10)$$

式中, \bar{L}_{IoU} 为动量的平均运行值, 动态更新归一化因子以保持梯度增益处于较高水平。

WIoUv3 将引入非单调聚焦系数 β 应用于 WIoUv1 中, 得到:

$$\beta = \frac{L_{IoU}^*}{L_{IoU}} \in [0, +\infty) \quad (11)$$

$$L_{WIoUv3} = r L_{WIoUv1}, r = \frac{\beta}{\delta \alpha^{\beta - \delta}} \quad (12)$$

式中, β 为离群值; α 和 δ 是控制梯度增益 r 的超参数。

本文将原网络的 CIoU 损失函数替换为 WIoUv3 损失函数, 动态优化了损失中高低质量锚框的权重, 并减少了重叠锚框中心点位置的敏感度, 提升了模型的整体检测精度。

3 实验与分析

3.1 数据集和实验环境

本实验使用的数据集为某市供电公司所提供的电力作

业现场高空检修人员以及地面监护人员的图像, 经过数据清洗后共选取 1 279 张在视频监控下截取的不同场景的实时图片。对于已经准备好的数据集, 将采用 LabelImg 软件按照标签进行标注, 软件操作界面如图 7 所示, 标注完后产生的 xml 文件保存在相应的路径下, 运用 python 代码将 xml 格式转换为 txt 格式, 并以 8:2 的比例划分训练集、测试集。其中数据集包括检修人员 (worker)、袖章 (badge)、安全带 (belt) 以及安全帽 (helmet) 4 类样本标签。



图 5 软件操作界面

本次实验平台配置如下: 实验平台操作系统为 Ubuntu18.04, 编程语言为 Python, 实验框架选用 Pytorch, CPU 为 AMD Ryzen Threadripper 3970X, GPU 为 NVIDIA GeForce RTX 3090 显卡 * 3, 显存 24 G, 内存 128 G。

3.2 参数设置与评价指标

模型训练参数设置: 输入的图片大小 (images) 为 640×640 , 迭代次数 (epochs) 为 200 轮, 批次大小 (batch) 为 16, 调用 3 个 GPU, 最终 batch-size 设置为 48, 初始学习率为 0.01, 本实验均是在不加载预训练权重的情况下进行。

为了比较不同的模型对电力作业人员违规行为的检测精度, 实验将采用的参数指标有模型参数量、模型权重文件大小、查全率 (Recall)、查准率 (Precision)、平均精度均值 (mAP) 以及每秒检测帧数 (Frames Per Second)。其中 P 、 R 、 AP 和 mAP 的计算公式如下所示:

$$P = \frac{TP}{TP + FP} \quad (13)$$

$$R = \frac{TP}{TP + FN} \quad (14)$$

$$AP = \sum_{i=1}^{n-1} (r_{i+1} - r_i) P_{inter}(r_i + 1) \quad (15)$$

$$MAP = \frac{\sum_{i=1}^k AP_i}{k} \quad (16)$$

式中, TP (True Positives) 表示被正确检测出的目标数, FP (False Positives) 表示检测错误的目标数, FN (False Negatives) 表示未被检测出来的目标数。所以, 查准率 P 表示正确检测出的目标数与所有检测目标数的比值, 召回率 R 表示正确检测出的目标数与数据集中所有的目标数的

比值。由于查准率、召回率通常忽高忽低，因此选取平均精度均值 (mAP) 作为评判检测精度的指标。

3.3 实验结果及分析

3.3.1 注意力机制实验对比

为了验证模块引入注意力机制后算法的检测能力是否有进一步的提升，则本实验在 Backbone 层的同一位置添加了 SimAM、ECA、CBAM、SE 四种注意力机制，改进后的模块实验结果如表 1 所示。从实验结果可以看到，相比于其他两个注意力机制，SE 注意力机制的引入对网络的性能提升最为显著，查全率由原先的 89.8% 上升到 91.2%，提升了 1.4%， mAP 值由原先的 94.5% 上升到 95.5%，提升了 1.0%，大大增加了检测精度。

表 1 注意力机制对比实验

算法	模型参数量/万	查准率/%	查全率/%	$mAP@0.5/%$	FPS
YOLOv8n	300	95.5	89.8	94.5	56
YOLOv8n+SimAM	300	96.1	90.5	94.9	56
YOLOv8n+ECA	301	95.6	91.0	95.1	57
YOLOv8n+CBAM	308	95.0	91.0	94.5	58
YOLOv8n+SE	301	94.5	91.2	95.5	57

3.3.2 损失函数实验对比

为了验证采用 WIoUv3 损失函数的有效性，本实验将原始网络的 CIoU 损失函数更换为 WIoUv3 损失函数，并通过采用 DIoU、SIoU、GIoU 以及 WIoUv1 和 WIoUv2 五种损失函数进行对比，检测模型其他部分都保持不变，且在同一数据集下进行测试，改进后的损失函数实验结果如表 2 所示。可以看出，WIoUv3 损失函数对于网络性能的提升效果最为明显，相较于其他损失函数它的 mAP 值提升的最多，与原始网络比提升了 1.2%。

表 2 损失函数对比实验

损失函数	模型参数量/万	查准率/%	查全率/%	$mAP@0.5/%$	FPS
DIoU	303	96.3	90.3	95.2	56
SIoU	303	95.2	91.3	95.1	54
GIoU	303	96.1	89.2	93.7	56
WIoUv1	303	94.9	90.9	94.9	58
WIoUv2	303	96.1	91.6	95.2	60
WIoUv3	303	97.2	90.2	95.7	58

3.3.3 消融实验

本文对于原始网络 YOLOv8n 提出了 3 个改进点：采用 WIoUv3 损失函数替换了原先的 CIoU 损失函数、将特征融合部分引入加权双向特征金字塔网络 (BiFPN)、在网络中添加 SE 注意力机制。所以对于提出的改进方法进行了消融实验，实验结果如表 3 所示。根据下表可以发现，当网络在引入 SE 注意力模块的同时将特征融合结构为加权双向特征金字塔网络时，查全率和 mAP 值都有了明显的提升，分别增加了 1.3%，1.4%。最后将 3 个改进点一并加入使用时，相较于

前面的几种改进方法， mAP 值提升的最高，达到了 96.5%，证明了本文提出的改进点对于目标检测算法的有效性。

表 3 消融实验结果

SE 注意力机制	BiFPN 结构	WIoUv3	模型参数量/万	查准率/%	查全率/%	$mAP@0.5/%$	FPS
✓			301	94.5	91.0	95.5	57
	✓		302	96.8	89.6	95.4	56
		✓	303	97.2	90.2	95.7	58
✓	✓		303	96.1	91.1	95.9	56
✓	✓	✓	303	96.2	91.5	96.5	59

3.3.4 对比实验

为了更好地验证本文改进算法的优越性，则通过选用 YOLOv5s、YOLOv4、YOLOX、RetinaNet 网络以及 SSD 模型等一些主流的目标检测算法与本文改进算法进行对比，实验结果如表 4 所示。

表 4 对比实验结果

算法	查准率/%	查全率/%	$mAP@0.5/%$	FPS
SSD	89.6	87.2	89.3	18
YOLOv5s	93.5	88.7	93.2	48
YOLOv4 ^[6]	89.8	89.6	88.6	36
YOLOX ^[5]	93.1	90.9	93.7	78
RetinaNet ^[21]	89.2	85.8	85.4	23
本文算法	96.2	91.5	96.5	59

根据实验结果可以得到，无论从平均精度均值以及检测速度方面上，本文改进算法参数大小优势明显，检测精度较高，具有较好的识别效果。其中，YOLOX 算法的检测速度虽然相较于其他几种检测算法有一定的优势，但是检测精度却较低，只有 93.7%。而本文提出的改进后的算法在保持检测速度不错的情况下，有着较高的检测精度，达到 96.5%，比 YOLOX 算法提高了 2.8%，检测精度优势明显，综合表现较为突出，验证了本文改进算法的优越性。

为了更加直观地发现改进后的算法对于目标检测精度的提升，本文将以原始 YOLOv8n 网络与改进后的网络对数据集进行检测实验。如图 6 所示，图 6 (a) 表示原始 YOLOv8n 网络检测结果，图 6 (b) 表示改进后的网络检测结果。

根据上图可以看到，本文将检测模块部署到边缘计算设备中，通过球机进行视频监控来自动检测在作业现场中电力作业人员的安全规范行为，保障电力人员的人身安全，以免发生意外，其中包括是否佩戴安全帽、是否穿戴电力安全带以及现场是否有监护人员。但是，可以发现利用原始的 YOLOv8n 网络对于电力作业现场的人员违规行为目标的一些检测精度都相对较低，其中对电力安全带检测精度只有 0.87，且还在一些复杂场景中出现漏检以及误检的问题。而改进后的网络对于行为目标检测效果就得到了进一步的改善，其安全带检测精度也达到了 0.92，同时也减少了漏检、误检的情况，大大提升检测精度，检测效果相对较好。



(a) 原YOLOv8n检测效果 (b) 改进后的YOLOv8n检测效果

图 6 算法改进前后的检测效果对比图

4 结束语

针对电力作业人员在视频监控中距离较远、背景较为复杂,且对于安全带以及监护袖章这些小目标检测难度较大,存在着漏检、误检等情况发生,因此本文将提出一种基于改进 YOLOv8n 的电力作业人员安全带检测算法。通过添加 SE 注意力模块,提高了模型对小目标的识别能力;在网络特征融合部分引入加权双向特征金字塔网络结构,将低层细节与高层特征信息相融合,增强网络特征提取能力,提高模型的检测精度;将 WIoUv3 损失函数替换原始网络的 CIoU 损失函数,提升网络对于复杂环境的适应性。实验结果证明,改进后的 YOLOv8n 算法平均检测精度达到 96.5%,比原始网络提高了 2.0%,且适合于在边缘计算设备上部署操作。但是对于改进后的 YOLOv8 检测算法在检测速度还有很大的进步空间,并在后续工作中还可以继续扩充不同电力作业场景下的数据集,进一步优化模型的检测速度和检测效果。

参考文献:

[1] 王彦生,朱佳佳,王紫仪,等. 基于改进 YOLOv5 的电厂人员绝缘手套佩戴检测 [J]. 计算机测量与控制, 2023, 31 (11): 60-65.

[2] 张瑶,卢焕章,张路平,等. 基于深度学习的视觉多目标跟踪算法综述 [J]. 计算机工程与应用, 2021, 57 (13): 55-66.

[3] 韦庚吾,李英娜. 基于改进 Yolov4 的输电线路鸟巢轻量级检测算法 [J]. 电力科学与工程, 2022, 38 (10): 64-72.

[4] 吴烈凡. 基于卷积神经网络的高空作业安全带识别与检测 [J]. 现代计算机, 2021, 27 (24): 124-130.

[5] 曹捷,郭志彬,潘立志,等. 高空作业场景下的安全带穿戴检测 [J]. 湖南科技大学学报(自然科学版), 2022, 37 (1): 92-99.

[6] 顿伟超,王淑青,张鹏飞,等. 基于改进 YOLOv4 的电力高空作业安全带检测 [J]. 湖北工业大学学报, 2022, 37 (5): 6-11.

[7] 郑凯东,舒心. 基于 BFDS 改进的 YOLOv8 疲劳驾驶检测算法 [J]. 信息技术与信息化, 2024 (2): 213-216.

[8] 苏佳,罗都,贾欣雨,等. 基于 YOLO-G 的 PCB 缺陷检测算法 [J]. 微电子学与计算机: 1-10 [2024-04-12]. https://kns.cnki.net/kcms2/article/abstract?v=UjEBX92ALNGFN523hrJkbgSANrCY0HuUJLbzN9MgRVPhVrDuTG16PQidc95Pd3i7wIguRwZGXsRyLktS1EAIZQckm2_9IjFVZFve16sFtXmDX16pGQKWcMz6Sj6rdQQk15VZayRd3maUjFyvPmkJ95oYvsU9Kx3DsKOGIvpUpAX3VwWserGcHb585Njg2wzW&uniplatfrom=NZKPT&language=CHS.

[9] 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.

[10] 陈晨,徐慧英,朱信忠,等. 基于 YOLOv8 改进的室内行人跌倒检测算法: FDW-YOLO [J/OL]. 计算机工程与科学: 1-14 [2024-04-12].

[11] 李猛坤,袁晨,王琪,等. 基于改进 Yolov8 算法的在线听课行为识别模型研究 [J/OL]. 计算机工程: 1-10 [2024-04-12].

[12] 陈伟,江志成,田子建,等. 基于 YOLOv8 的煤矿井下人员不安全动作检测算法 [J/OL]. 煤炭科学技术: 1-19 [2024-04-12].

[13] 冉二飞,贾小军,喻擎苍,等. 基于 SE 注意力 CycleGAN 的蓝印花布单纹样自动生成 [J]. 丝绸, 2024, 61 (1): 31-37.

[14] HU JIE, SHEN LI, SUN GANG. Squeeze-and-excitation networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2020; 2011-2023.

[15] 江超,杜金,南子洋,等. 基于改进 YOLOv7 算法的风机塔筒系统故障识别系统 [J]. 电力大数据, 2023, 26 (10): 17-25.

[16] TAN M, PANG R, LE Q V. EfficientDet: Scalable and efficient object detection [C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020.

[17] GUO Y, CHEN S, ZHAN R. et al. SAR ship detection based on YOLOv5 using CBAM and BiFPN [C] // IGARSS 2022—2022 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2022; 2147-2150.

[18] ZHENG Z, WANG P, REN D, 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.

[19] 王楠,侯涛,牛宏侠. 多尺度特征融合的铁路异物入侵检测研究 [J/OL]. 西安交通大学学报: 1-16 [2024-06-06].

[20] 陈卫彪,贾小军,朱响斌,等. G-YOLO v7: 面向无人机航拍图像的目标检测算法 [J/OL]. 光电子·激光: 1-14 [2024-06-06].

[21] 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.