文章编号:1671-4598(2026)10-0193-08 DOI:10.16526/j.cnki.11-4762/tp.2026.10.025 中图分类号:TP391.41 文献标识码:A

基于 YOLOv11n 的安全帽与反光衣穿戴规范检测算法

冯兴兴，郭 斌，陶梓涵，梁超珩，董 军
（广东电网有限责任公司 广州供电局，广州 510000）

摘要：在电力行业中，现场作业环境复杂且危险因素众多，作业人员的违规行为如未佩戴安全帽和穿反光防护服等极易引发严重事故；传统的人工巡查和视频回放等安全监管方式存在主观性强、反应滞后和监控效率低等问题，为此，提出了一种基于改进 YOLOv11n 的安全帽与反光衣穿戴规范检测算法；该算法设计了多尺度边缘信息生成器模块，将浅层特征中的边缘细节信息与不同深层特征融合，增强了模型对边缘信息的提取能力；引入 BiFPN，通过可学习权重动态调整不同层级特征的贡献，更好地保留小目标特征；改进了检测头，在降低模型参数量的同时提升了准确度；使用 MPDIoU 替换原本的损失函数，有效增强了对不规则目标的检测能力并加速了收敛过程；实验结果表明，与基准模型 YOLOv11n 相比，改进模型在 *mAP*50 指标上表现更优，达到了 94.5%，验证了其在现场作业人员违规行为检测中的有效性和优势。

关键词：缺陷检测；YOLOv11n；特征提取；空间金字塔；目标检测；MPDIoU

A Wearing Compliance Detection Algorithm for Safety Helmets and Reflective Clothing Based on YOLOv11n

FENG Xingxing，GUO Bin，TAO Zihan，LIANG Chaoheng，DONG Jun
（Guangzhou Power Supply Bureau，Guangdong Power Grid Co.，Ltd.，Guangzhou 510000，China）

Abstract：There are complex on-site operation environments and numerous hazardous factors in the power industry，along with operating personnel's violations such as not wearing safety helmets or reflective protective clothing，easily leading to serious accidents. Traditional safety supervision methods such as manual inspection and video playback exhibit strong subjectivity，lagging response，and low monitoring efficiency. Therefore，a detection algorithm for safety helmet and reflective vest compliance based on improved YOLOv11n is proposed，which designs a multi-scale edge information generator module to fuse the edge detail information in the shallow features with different deep features，enhancing the model's ability to extract edge information. A bidirectional feature pyramid network（BiFPN）is introduced to dynamically adjust the contribution of features at different levels through learnable weights，better preserving the feature of small targets. The detection head is improved to reduce the model's parameter count while improving the accuracy. A modified point distance intersection over union（MPDIoU）is used to replace the original loss function，effectively enhancing the detection ability for irregular targets while accelerating the convergence process. Experimental results show that the improved model outperforms the baseline model YOLOv11n on the *mAP*50 metric，achieving 94.5%，which validates its effectiveness and superiority in detecting violations among on-site operational personnel.

Keywords：defect detection；YOLOv11n；feature extraction；spatial pyramid；object detection；MPDIoU

收稿日期:2025-10-16； **修回日期**:2025-12-05。
基金项目:中国南方电网有限责任公司科技项目(GDKJXI20231147[030100KC23110051])。
作者简介:冯兴兴(1989-),男,硕士,高级工程师。
通讯作者:董 军(1989-),女,硕士,高级工程师。
引用格式:冯兴兴,郭 斌,陶梓涵,等.基于 YOLOv11n 的安全帽与反光衣穿戴规范检测算法[J].计算机测量与控制,2026,34(10):193-200.

0 引言

电力行业作为国家基础性产业之一，其生产现场作业环境复杂，危险因素众多，一旦发生违章作业，极易引发严重的人身伤亡及电网设备事故，其中因个人防护装备缺失（比如安全头盔与反光警示服）而引发的事故尤为常见[1]。近年来，随着信息技术、人工智能、计算机视觉等技术的发展，现场作业违章行为检测逐渐成为学术界和工业界的研究热点。如何高效、准确地检测并预警现场作业中的违章行为，已成为保障电力行业作业安全、提高管理效率的关键问题。传统的现场安全监管主要依赖人工巡查和视频回放，存在主观性强、反应滞后、监控效率低等问题。随着计算机视觉与深度学习技术的日趋成熟与融合，违章行为的自动检测已成为现实可能[2]。其核心实现方式，便是依托于深度学习模型，对作业现场的实时视频流及图像资料加以分析，进而检测安全帽佩戴、工作服着装规范等违章行为。结合电力行业的专业知识和实际需求，对传统的机器学习算法进行改进和优化，提高了违章行为检测的准确率和鲁棒性。

从设计理念角度出发，基于深度学习的目标检测技术划分为两类：一类是以 R-CNN[3]、Fast R-CNN[4] 和 Faster R-CNN[5] 等为代表的两阶段检测算法。此类方法先对候选区域进行生成或筛选，再在这些区域内执行目标检测与分类，并对边界框回归进行定位优化。虽然两阶段检测算法目标检测精度较高，但是检测速度较慢，无法达到实时检测的要求。另一类是以 SSD[6]、RetinaNet[7]、YOLO[8] 等基于卷积神经网络的单阶段检测算法。其中，YOLO 算法将目标检测任务转化为一个回归问题，直接在图像上预测目标的类别和位置，具有检测速度快的优势，能够满足实时性要求较高的电力作业现场违章检测需求。

为了提升安全帽和反光衣的检测精度，研究人员对模型进行了改进。文献［9］在 YOLOv8 的基础上利用残差思想和并行空洞卷积在不损失图像分辨率的情况下进一步扩大感受野，显著提升了在复杂天气下的检测精度。文献［10］引入 GhostNet 网络结构中的 Ghost 模块在降低模型复杂度的同时抑制无效信息，增强对特征丰富区域的提取。文献［11］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。文献［12］改进 YOLOv3 网络，在主干网络中加入坐标注意力（CA，coordinate attention）机制模块来增强目标特征的表征能力。文献［13］在 YOLOv5s 的基础上增加了一个小目标检测头，提高了模型对小目标的识别能力。文献［14］引入了 MobileNetv3 和 BiFPN 降低了算法的参数量和计算量同时增强了算法的特征提取与特征表达能力，降低了误检率。文献［15］改进 SSD 算法，同时结合多人姿态估计算法来判断安全帽的佩戴情况，大幅度提高了提高煤矿井下作业场景的工人安全帽佩戴识别准确度，其准确率达到了 91.9%，但其推理速度较慢。

尽管现有技术在一定程度上提升了目标检测的准确率，但普遍面临计算资源消耗大、对硬件配置依赖性强的问题。此外，多数研究仍局限于对安全帽的单一识别，缺乏对反光衣的同步检测能力，导致其在复杂场景下的适用性受限。因此针对目前安全帽和反光衣检测算法存在的问题，本文提出一种基于改进 YOLOv11n 的检测算法：首先设计了一个多尺度边缘信息生成器模块，增强模型对边缘信息的提取能力，提升模型精度；引用 BiFPN 通过可学习权重动态融合不同层级特征，保留小目标细节，提升计算效率；接着对检测头进行改进，降低模型参数量的同时提升模型的准确度；最后使用 MPDIoU 替换原本的损失函数，有效增强了对不规则目标的检测能力，并加速了收敛过程。

1 YOLOv11 算法

YOLOv11 由 Ultralytics 提供，已成为主流的先进（SOTA）模型之一，整体结构可分为主干网络（Backbone）、特征融合网络（Neck）和检测头（Head）。其通过 CSP[16] 结构分离与合并特征流，减少梯度信息重复，提高计算效率，并使用 C3k2 模块代替传统 C2f 模块，采用更小卷积核（Kernel size＝2）与跨阶段特征连接，提升特征提取效率并降低计算量。在特征融合网络部分采用 PANet[17] 实现自上而下与自下而上的特征传递路径，融合不同层级的语义信息与位置信息。在特征融合阶段引入 C2PSA 模块，将卷积特征与并行空间注意力机制结合，动态调整不同区域特征权重。而检测头通过 Anchor-free 设计直接预测边界框中心点、宽高及类别概率，减少锚框匹配计算。YOLOv11 支持多任务预测，可扩展至实例分割、姿态估计和方向检测等任务[18]。

2 改进 YOLOv11n 算法

为了提升 YOLOv11n 模型对现场作业违章行为的检测能力，改进算法的网络由主干（Backbone）、颈部（Neck）、头部（Head）共 3 部分组成，结构如图 1 所示。

首先在主干网络设计多尺度边缘信息增强模块（MSEIG，multi-scale edge information generator）提高模型对边缘信息的检测能力，并通过边缘卷积统合模块（ECF，edge convolutional fusion）对不同尺度的边缘信息进行有效的融合；其次，在颈部网络引入 BiFPN，高效地进行多尺度特征融合，进而增强模型小目标检测性

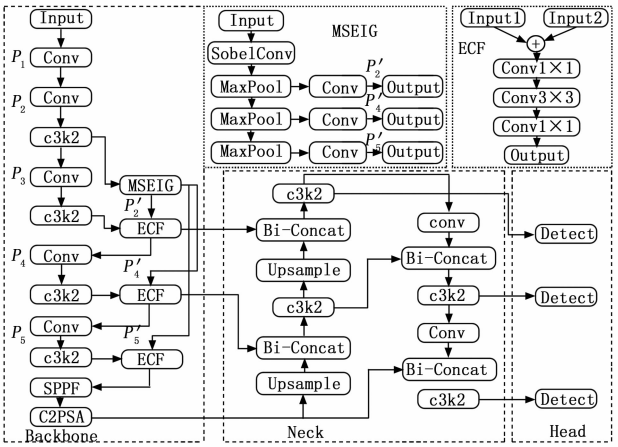


图 1　改进算法网络结构图

能；然后，设计轻量化检测头，提升精度的同时，降低模型复杂度；最后采用 MPDIoU 损失函数进一步增强模型的检测能力。

2.1　主干网络改进

传统的深度学习目标检测模型通常依赖于深层网络提取的高级语义特征。然而，这些特征在经过多次下采样后，对于小目标（像素数量少）的细节信息会丢失严重，导致模型漏检率高、定位不准确。因此设计多尺度边缘信息增强模块，捕获不同分辨率下的边缘特征，并对每个尺度的边缘特征进行通道调整，把浅层特征（P_2）中提取到的边缘信息传递到整个网络上，并与不同尺度（P_3，P_4 和 P_5）的特征进行融合。然后通过边缘卷积融合模块将生成的边缘信息与普通卷积特征进行融合来增强对边缘信息的捕捉能力。

MSEIG 模块网络结构如图 1 所示。首先利用 SobelConv 对原始输入特征图进行边缘提取，生成最高分辨率的边缘特征图。之后边缘特征图会进行 3 次 MaxPool 操作，实现 3 次的 2×2 下采样。每次下采样都会生成一个分辨率减半的边缘特征图，从而构建多尺度金字塔。最后每个下采样后的边缘图通过 1×1 卷积层，以调整其通道数，最终输出一系列分辨率递减的边缘特征。MSEIG 的公式如下：

$$MSEIG(X)=\begin{pmatrix}C_{1\times1}\{P[S(X)]\},\\C_{1\times1}\{P\{P[S(X)]\}\},\\C_{1\times1}\{P\{P\{P[S(X)]\}\}\}\end{pmatrix} \tag{1}$$

式中，X 为输入，S 为 SobelConv 操作，P 为 MaxPool 操作，$C_{1\times1}$ 为 1×1 的卷积。经过 MSEIG 模块后生成 3 个不同尺度的特征图输出。

Sobel 卷积核是用于边缘检测的离散微分算子，通过两个 3×3 的卷积核来近似计算水平方向和垂直方向的偏导数，用于检测边缘信息[19]。Sebel 算子 x 方向和 y 方向的卷积核分别为：

$$G_x=\begin{bmatrix}-1&0&1\\-2&0&2\\-1&0&1\end{bmatrix}\quad G_y=\begin{bmatrix}-1&-2&-1\\0&0&0\\1&2&1\end{bmatrix}$$

其中：G_x 为水平核，突出水平方向的亮度变化，G_y 为垂直核，忽略水平影响。Sobel 卷积核对输入图像进行边缘检测，提取图像中的显著边缘特征。能够更加准确地识别边缘信息，避免因物体的模糊或低对比度部分而丢失关键信息。

卷积边缘特征融合（ECF）模块将 MSEIG 生成的不同尺度的边缘信息进行有效的融合，生成统一且更丰富的边缘特征表示。ECF 网络结构如图 1 所示。首先，将输入的多个尺度边缘特征图在通道维度上与对应尺度的特征图进行拼接；接着，通过 1×1 卷积层来整合拼接后的所有边缘特征通道，并将其降维至目标输出通道数的一半，实现跨尺度信息的初步融合。然后，通过 3×3 卷积层用于在融合后的特征上捕获更深层次的局部空间上下文信息，增强边缘表示的判别力。最后通过 1×1 卷积层调整特征通道数，完成特征融合过程。ECF 的公式表示为：

$$ECF(I_1,I_2)=C_{1\times1}\{C_{3\times3}[C_{1\times1}(I_1+I_2)]\} \tag{2}$$

式中，I_1、I_2 为输入，$C_{1\times1}$ 和 $C_{3\times3}$ 分别为 1×1 的卷积和 3×3 的卷积；I_1 和 I_2 分别为两个输入特征图；+ 表示将多个特征图沿通道维度拼接。

如图 1 中 Backbone 所示，首先将 P_2 层作为 MSEIG 模块的输入，得到 P_3，P_4 和 P_5 对应的边缘特征作为输出；然后将 P_3 和 P_3 的边缘特征通过 ECF 模块进行融合，得到更丰富的边缘特征表示作为输出，同时输出的特征图将进行后续的下采样和输入到 Neck 中；之后分别将 P_4 和 P_5 与其对应的边缘特征通过 ECF 模块融合，完成特征提取，得到边缘信息更丰富的特征图。

2.2　BiFPN

在现场作业违章检测数据集中，小目标和被遮挡的目标占了很大的比例，模型可能会面临误检和漏检的问题，通常，低层特征图中的小目标特征更加明显。经典的 PANet 架构整合了自顶向下的 FPN[20] 路径与自底向上的 PAN[21] 路径，通过构建双向特征传输通道，有效地强化了浅层特征图的语义表征能力，但其简单的逐元素相加或拼接的特征融合方式可能导致底层细节信息的丢失。YOLOv11n 的颈部网络延续 PAN-FPN 的设计。

BiFPN[22] 通过可学习的权重动态调整不同层级特征的贡献，底层特征在融合过程中不会被简单覆盖，而是通过权重分配得到增强，能够更好地保留小目标特征。传统 PAN-FPN 采用简单的加和，而 BiFPN 通过一个轻量的参数化加权机制，动态调整不同输入特征的重要

性。在融合路径中引入更多跨层连接，并重复多次双向融合，提升特征的表达能力。其特征融合公式为：

$$O=\sum_i \frac{w_i}{\varepsilon+\sum_j w_j}\cdot F_i \tag{3}$$

其中：O 为融合后的输出特征图，F_i 是第 i 个输入特征图，w_i 是对应于第 i 个输入特征图的可学习权重，$\varepsilon=10^{-4}$ 用于避免数值不稳定。以 P_4 层为例，特征融合表达式为：

$$p_4^{\text{out}}=\text{Conv}\left(\frac{\omega'_1 p_4^{\text{in}}+\omega'_2 p_4^{\text{td}}+\omega'_3 \text{Resize}(p_3^{\text{out}})}{\omega'_1+\omega'_2+\omega'_3+\varepsilon}\right) \tag{4}$$

其中：p_4^{out} 为自下而上第四层的输出结果，p_4^{td} 为中间结果，Resize 为上采样或下采样操作，Conv 为普通卷积，$\omega_1-\omega_3$ 为学习到的特征权重。BiFPN 的结构如图 2 所示。

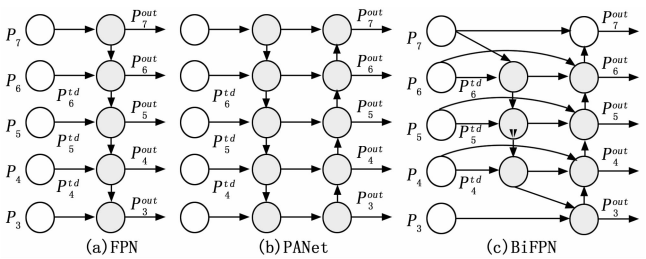


图 2 不同特征金字塔网络的比较

如图 1 中 Neck 所示，其中的 Bi-Concat 即为 BiFPN 融合模块，实现了高效的多尺度特征融合。

2.3 轻量化检测头

在检测头方面，基于组归一化（GN，group normalization）[22]的卷积对其进行改进，设计了一个轻量化检测头。GroupNorm 作为一种有效的归一化方法，能够在小批量数据或小批量训练时提升模型的稳定性和收敛速度，尤其在处理较小尺寸输入数据时表现优越。通过引入 GroupNorm，提出的改进模型能够更好地处理不同尺寸和尺度的数据，提高特征提取的能力，并在减少模型参数量的基础上进一步提高模型的检测精度。与批归一化（BN，batch normalization）不同，组归一化在定位和分类任务中表现更优，BN 严重依赖批次大小，当批次大小较小时可能会导致性能下降[23]，而 GN 则通过将所有通道分组并计算每个组的均值和方差来进行归一化，与批次大小无关。因此，将卷积中的归一化策略替换为 GN，以提高性能。YOLOv11 在处理小物体时，由于其标准卷积和深度可分离卷积的结构，难以有效捕捉细节信息，尤其是在复杂背景中，容易漏检小物体。通过引入 Conv _ GN 模块，能够增强模型对小物体的检测能力，尤其是在复杂背景中，增强了模型的感知能力。具体结构如图 3 所示。如图 1 所示，在 head 部分的 3 个 detect 模块均使用改进的轻量检测头。

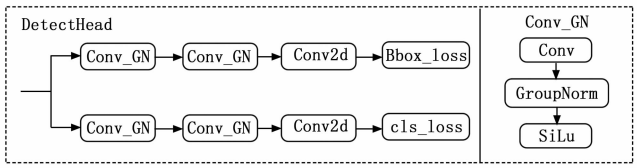


图 3 轻量化检测头

2.4 MPDIoU 损失函数

使用 MPDIoU[24] 替换 YOLOv11 的损失函数，YOLOv11 原损失函数主要围绕分类损失、边界框回归损失及置信度损失构建。其中，边界框回归损失通常采用 CIoU（Complete IoU）损失。CIoU 损失在计算时，考虑了边界框的重叠面积、中心点距离以及边界框的长宽比。在复杂场景下，当目标存在严重遮挡、密集分布时，对边界框回归的精准度提升有限；对于不同尺度的目标，尤其是小目标，其对中心点距离和长宽比的权衡难以完全适配，易导致回归偏差，影响检测精度。MPDIoU 损失函数针对边界框回归进行优化，同时考虑了重叠区域、中心点距离以及宽度和高度的偏差，来优化框的位置和形状匹配，提升多尺度目标的定位精度。其表示为：

$$LOSS_{MPDIoU}=1-IoU+\frac{d_1^2}{h^2+w^2}+\frac{d_2^2}{h^2+w^2} \tag{5}$$

其中：IoU 为预测框与真实框的重叠程度。d_1 和 d_2 分别代表预测框左上角和右下角与真实框对应角点之间的欧氏距离。w 和 h 分别为输入图像的宽度与高度，用于对距离项进行尺度归一化，确保损失函数对不同尺寸图像具有鲁棒性。

3 实验

3.1 实验环境和数据集

本实验的实验环境和模型参数设置见表 1。为了满足实验模型对安全帽及反光衣的高精度检测需求，本文建立了一个包含 6 960 张图像的专用数据集。原始的 2 214 张图片采集自百度图库及公开数据集，其中涵盖各类工地作业环境。为了增强样本的丰富度并提升模型的泛化能力，对原始数据集采用了包括图像旋转、增加高

表 1 实验环境和模型参数设置

名称	值
操作系统	Linux
深度学习框架	PyTorch
CUDA	12.4
GPU	RTX 4090
Python	3.10
训练轮次(Epochs)	300
图片尺寸(Images)	640×640
批次大小(Batchsize)	32
学习率(lr0)	0.01
优化器(Optimizer)	SGD

斯噪声、亮度变换、模糊化及掩码处理在内的数据增强技术，将数据集扩充到 6 960 张图像。最后，所有样本被随机分配至训练、验证及测试子集中，分配比例设定为 7∶2∶1。数据集中包含 5 种类别：人（Person）、安全帽（Helmet）、安全背心（Vest）、未佩戴安全帽（No-Helmet）和未佩戴安全背心（No-Vest）。

3.2　评估指标

为了全面衡量模型性能，实验中选用了 6 项评价指标：准确率（P，precision）、召回率（R，recall）、平均精度均值（mAP，mean average precision）、参数数量（Pa，parameters）、浮点运算次数（F，FLOPs）。相关指标的计算方法如下：

$$P = \frac{TP}{TP + FP} \tag{6}$$

$$R = \frac{TP}{TP + FN} \tag{7}$$

$$AP = \int_0^1 P(R)\mathrm{d}R \tag{8}$$

$$mAP = \frac{1}{N}\sum_{i=1}^{N} AP_i \tag{9}$$

其中：TP 为模型正确预测为正类的样本数，FP 为模型错误预测为正类但实际为负类的样本数，FN 指的是模型错误预测为负类但实际为正类的样本数。N 为全部检测类别的数量，P（R）表示在特定召回率 R 下对应的精度值。$mAP50$ 是指以 IOU（交并比）阈值为 50%时计算得到的平均精度，而 $mAP50{\sim}95$ 则是指 IOU 阈值从 50%～95%，以 5%的间隔逐步计算出的平均精度值，并对其取平均。

3.3　对比试验

为验证改进模的检测性能，选取 YOLOv8n、YOLOv9n、YOLOv10n、YOLOv11n、YOLOv12n 文献[25]和文献[26]作为对比模型，在统一实验环境（相同数据集、训练参数、硬件配置）下开展实验。采用精确率（P）、召回率（R）、$mAP50$（IoU 阈值为 0.5 时的平均精度均值）、模型参数量（Pa）、每秒浮点运算数（FLOPs，F）作为评价指标，全面衡量模型检测能力与效率。实验结果如表 2 所示。

表 2　对比试验

训练模型	P/%	R/%	$mAP50$/%	Pa/M	F/G
YOLOv8n	91.6	**90.0**	93.2	3.0	8.1
YOLOv9n	93.8	88.1	93.1	2.6	10.7
YOLOv10n	90.6	89.0	91.8	**2.2**	6.5
YOLOv11n	92.3	89.7	93.3	2.6	6.4
YOLOv12n	91.1	89.6	92.9	2.5	**5.8**
文献[25]	—	—	91.6	3.6	13.8
文献[26]	89.0	85.5	91.2	2.0	6.4
Ours-n	**94.0**	89.3	**94.5**	2.7	6.6

从表 2 中可以看出，改进模型在 P（精度）和 $mAP50$（平均精度）关键性能指标上，与其他版本的 YOLO 模型相比显示了更高的性能。尤其是在 $mAP50$ 指标上，改进模型达到了 94.5%，明显高于 YOLOv8n、YOLOv9n、YOLOv10n 和 YOLOv12n 模型的 93.2%、93.1%、91.8%和 92.9%的值，体现了改进方法在提升物体检测精度方面的有效性。其次，虽然在参数量和计算量方面，改进模型较 YOLOv11n 略有增长，但较 YOLOv8n 仍具有一定优势。与其它类似改进算法对比，在 $mAP50$ 指标上，改进模型比文献[25]和文献[26]所提出的模型高 2.9%和 3.3%；尽管在参数量和计算量上，改进模型较文献[26]高 0.7 M 和 0.2 G，但考虑到精度高比其高 3.3%，改进模型整体性能优于文献[26]提出的模型。同时通过实验验证改进模型的检测速度达到了 116 FPS，在现场检测时可以实现实时监测。因此，本研究提出的模型展现了更强的鲁棒性和准确性，具有较高的应用潜力。

3.4　消融实验

为验证改进模型中多尺度边缘信息生成器（A）、引入 BiFPN 特征融合网络（B）、改进轻量化检测头（C）、MPDIoU 损失函数（D）的独立与协同作用，开展消融实验。通过逐步添加模块（从基础模型 YOLOv11n 开始，依次引入 A、B、C、D），对比模型在精确率、召回率、$mAP50$、参数量、计算量的变化，明确各模块对检测性能的贡献。以 YOLOv11n 为基准模型，设计了消融实验，结果如表 3 所示。

表 3　消融实验

训练方法	P/%	R/%	$mAP50$/%	Pa/M	F/G
YOLOv11n	92.3	89.7	93.3	2.6	6.4
＋A	93.4	89.0	93.7	3.4	9.7
＋B	92.4	89.9	93.8	2.3	**5.1**
＋C	90.6	**90.5**	93.6	**1.9**	6.4
＋A＋B	93.1	89.6	93.9	3.3	7.7
＋A＋C	92.6	89.1	93.9	2.9	7.9
＋A＋B＋C	93.4	89.8	94.1	2.7	6.6
＋A＋B＋C＋D	**94.0**	89.3	**94.5**	2.7	6.6

与 YOLOv11n 对比，只加入多尺度边缘信息增强模块后，模型 $mAP50$ 提升 0.4%，表明 A 模块通过 MSEIG 增强了边缘特征提取，同时 ECF 则将不同尺度的边缘信息进行有效的融合，提升了模型对缺陷边界的识别能力；只引入 B 模块，模型 $mAP50$ 提升 0.5%，提高了模型的整体检测能力，证实了 BiFPN 通过动态调整不同输入特征的重要性，更好地保留小目标特征，实现了有效的多尺度特征融合；只加入改进轻量化检测头，模型召回率提升 0.8%，$mAP50$ 提升 0.3%，参数量降低，说明 C 模块通过引入组归一化在减少模型参

数量的基础上进一步提高模型的检测精度，该设计优化了特征筛选，减少了背景噪声干扰，体现轻量化检测头对模型效率的优化作用。同时加入 A、B 模块后，*mAP*50%为 93.9%，BiFPN 能够更好地融合多尺度信息，而多尺度边缘信息生成模块捕捉到更多细节特征，二者协同作用提升了检测精度；同时加入 A、C 模块后，在保持高精度的同时，参数量增加较少。同时加入 A、B、C 模块后，精度达到了 94.1%，*mAP*50 提升了 0.8%，在检测准确度和效率之间取得了良好的平衡；再引入 MPDIoU 损失函数，在不增加复杂度的前提下，通过定位精度优化，*mAP*50 进一步提升 0.4%，验证改进模型设计的有效性。综上所述，改进模型在参数量和计算量增加较少的条件下，*mAP*50 提升了 1.3%，具有较高的应用潜力。

3.5 损失函数对比

为了验证 MPDIoU 损失函数的有效性，在改进模型的基础上，分别使用 MPDIoU、CIoU[27]、EIoU、DIoU[28]、GIoU[29]以及 WIoU[30]损失函数进行了对比实验，实验结果如表 4 所示，结果表明使用 MPDIoU 损失函数的模型性能最优。

表 4 不同损失函数对比

损失函数	*P*/%	*R*/%	*mAP*50/%
CIoU	93.4	89.8	94.1
EIoU	92.0	89.6	93.7
DIoU	91.5	89.8	93.5
GIoU	91.8	90.2	94.2
WIoU	92.6	90.4	94.3
MPDIoU	94.0	89.3	94.5

MPDIoU 通过动态调整高质量和低质量锚框的权重，显著提升了模型对高质量锚框的关注度，同时有效降低了低质量锚框对训练过程的干扰。这种机制不仅加速了模型的收敛速度，还显著减少了回归定位损失，从而提高了检测精度。此外，MPDIoU 能够更好地处理目标重叠、尺度变化以及边界模糊等问题，具有更强的鲁棒性和泛化能力，MPDIoU 具有更强的适应性，能够更精准地优化检测框的质量，使得模型在各种复杂情况下仍能保持较高的检测性能。

3.6 可视化对比

为了更加直观地展示所提出模型在物体检测任务中的优势，进行了可视化对比实验，结果如图 4 所示。

通过对比 YOLOv8n、YOLOv11n 和改进后的模型在不同场景中的检测表现，结果表明改进模型在物体检测、分类和定位精度上均表现出色。在图 4（a）场景中，虽然 YOLOv8n 和 YOLOv11n 能够识别“人”并进行标记，但对“安全帽”和“安全背心”的检测存在一

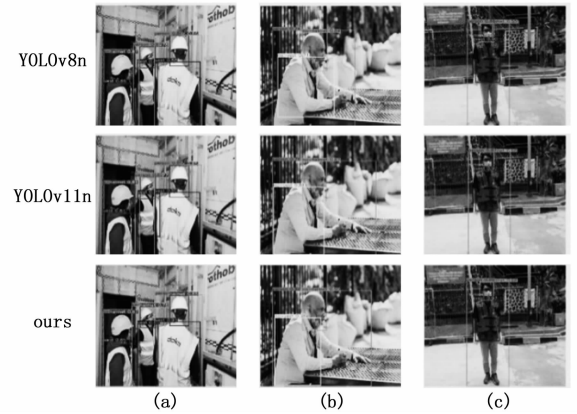


图 4 可视化实验

定的误差，置信度相对较低。相对而言，改进模型在细节部分表现得更加精准，特别是对“安全帽”和“安全背心”的识别，其定位更为精确，置信度更高。图（b）中 YOLOv8n 的检测结果较为简单且置信度较低，而 YOLOv11n 的表现稍好，能够较为准确地识别“未佩戴安全帽”部分，但改进模型在复杂背景下仍然表现优越，能够更加精确地检测到人物及其各部分。图（c）中的场景中，YOLOv8n 和 YOLOv11n 在检测“安全背心”时表现较弱，边界框定位不够精确，置信度较低，而改进的模型则能更紧密地定位物体，特别是在小物体的检测上展现了更高的精度和置信度。总体而言，提出的改进模型在多个场景中均优于 YOLOv8n 和 YOLOv11n，尤其在复杂背景和小物体检测中展现了更高的鲁棒性和精度。

为了评估不同目标检测模型在现场作业违章行为检测中的表现，选择了 4 个不同版本的 YOLO 模型（YOLOv8n、YOLOv9n、YOLOv11n）以及提出的改进模型进行对比，结果如图 5 所示。

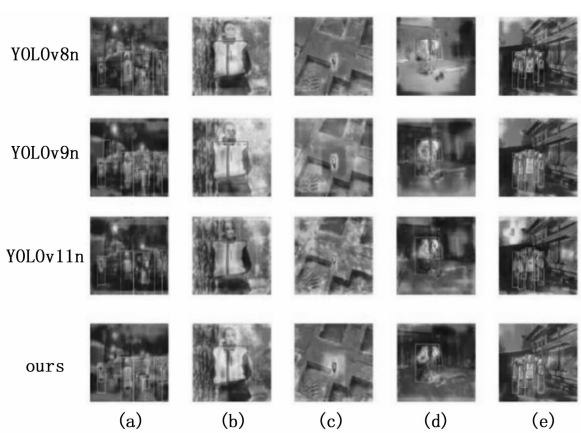


图 5 热力图对比

每个模型在相同数据集上进行测试，生成了对应的热力图，展示了模型对目标的关注区域以及检测结果。YOLOv8n 在检测过程中展示了较为分散的关注区域，

尤其是在复杂背景中，部分目标被误判或未能正确检测。在场景 d 图像的热力图中，YOLOv8n 模型对目标的关注多集中于目标的边缘，而非目标的完整区域，会导致模型对目标的定位不准确，从而影响检测精度。YOLOv9n 相比于 YOLOv8n 有所改进，热力图能够更好地集中于目标区域，但仍存在一定的误检测情况，尤其是在背景复杂的场景中。尽管目标区域的热力集中有所提高，但模型对小物体的检测表现较为薄弱，容易产生漏检。YOLOv11n 的热力图检测结果显示出更为集中的关注区域。热力图清晰地显示了模型对目标区域的高度关注，无论是在简单背景还是复杂场景中，都能够较好地聚焦于目标的核心区域。相较于 YOLOv8n、YOLOv9n 和 YOLOv11n，提出的改进模型能够有效减少漏检和误检现象，尤其是在目标重叠或遮挡的情况下，表现出更强的鲁棒性。此外，改进模型在小物体检测方面也有显著提升，能够更准确地检测到细节部分。

4　结束语

本文针对电力行业现场作业人员违规行为检测中存在的检测精度不足、模型计算量大等问题，提出了基于改进 YOLOv11n 的检测算法。通过设计多尺度边缘信息生成器模块、改进轻量化检测头、引入 BiFPN 以及使用 MPDIoU 损失函数，有效提升了模型对安全帽和反光防护服的检测精度，同时降低了模型的计算量。实验结果表明，改进模型在 mAP50 指标上优于 YOLO 系列模型，验证了改进策略的有效性。但本研究的数据集无法完全涵盖现场作业人员违规行为的所有复杂场景和情况。因此，模型在复杂场景（不同光照条件、多个作业人员等）下的鲁棒性仍有待提高，未来的研究将进一步优化模型结构，提高模型的检测性能，降低算法对硬件的要求，同时扩大现场数据采集范围、增加数据多样性，探索模型在更多电力作业违规行为检测中的应用。

参考文献：

[1] LI Y，HAN W，ZHENG H，et al. Deep learning-based safety helmet detection in engineering management based on convolutional neural networks [J]. Advances in Civil Engineering，2020：1－10.

[2] JIAO L，ZHANG F，LIU F，et al. A survey of deep learning-based object detection [J]. IEEE Access，2019，7：128837－128868.

[3] 陆启荣，宋智鹏，邱柏良，等. 基于作业安全监管的智能安全帽系统设计 [J]. 科学技术创新，2023 (18)：30－34.

[4] 叶　飞，骆星智，宋永春，等. 基于双特征融合的改进 R-CNN 电力小金具缺陷检测方法研究 [J]. 电子测量与仪器学报，2023，37 (7)：213－220.

[5] GIRSHICK R. Fast r-CNN [C] //Proceedings of the IEEE International Conference on Computer Vision，2015：1440－1448.

[6] REN S，HE K，GIRSHICK R，et al. FasterR-CNN：Towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence，2016，39 (6)：1137－1149.

[7] LIU W，ANGUELOV D，ERHAN D，et al. SSD：single shot multibox detector [C] //European Conference on Computer Vision. Cham：Springer International Publishing，2016：21－37.

[8] HUSSAINM. YOLO-v1toYOLO-v8 theriseofYOLOandits complementary nature toward digital manufacturing and industrial defect detection [J]. Machines，2023，11 (7)：677.

[9] 许　迪，张淑卿，葛　超. 面向复杂环境的 YOLOv8 安全装备检测 [J]. 电子测量技术，2024，47 (7)：121－129.

[10] 张学立，贾新春，王美刚，等. 安全帽与反光衣的轻量化检测：改进 YOLOv5s 的算法 [J]. 计算机工程与应用，2024，60 (1)：104－109.

[11] 张　杨，张雪琴. PTB-YOLOv8s：轻量级离散分布安全装备检测的方法 [J]. 兵工自动化，2025，44 (4)：37－43.

[12] WANG S，HAI X，CAO Y. Reflective safety clothes wearing detection in hydraulic engineering using YOLOv3-CCD [J]. AsianJ. Res. Comput. Sci.，2023，15(2)：11－24.

[13] ZHANG Y J，XIAO F S，LU Z M. Helmet wearing state detection based on improved YOLOv5s [J]. Sensors，2022，22 (24)：9843.

[14] 张国鹏，周金治，马光岑，等. 改进 YOLOv8 的轻量化安全帽佩戴检测算法 [J]. 电子测量技术，2024，47 (17)：147－154.

[15] 左明成，焦文华. 面向煤矿井下作业场景的安全帽佩戴识别算法 [J]. 中国安全科学学报，2024，34 (3)：237－246.

[16] LIU Y K，HE G L，WANG Z H，et al. NRT-YOLO：improved YOLOv5 based on nested residual transformer for tiny remote sensing object detection [J]. Sensors，2022，22 (13)：4953.

[17] LIU S，QI L，QIN H F，et al. Path aggregation network for instance segmentation [C] //Salt Lake City，USA：IEEE，2018：6568－6577.

[18] SHARMA A，KUMAR V，LONGCHAMPS L. Comparative performance of YOLOv8，YOLOv9，YOLOv10，YOLOv11 and faster r-CNN models for detection of multiple weed species [J]. Smart Agricultural Technology，2024，9：100648.

[19] LIU W J, WANG L. Quantum image edge detection based on eight-direction Sobel operator for NEQR [J]. Quantum Information Processing, 2022, 21 (5): 190.
[20] LIN T Y, DOLLáR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2117 - 2125.
[21] TANG F, XU Z, HUANG Q, et al. DuAT: Dual-aggregation transformer network for medical image segmentation [C] //Chinese Conference on Pattern Recognition and Computer Vision (PRCV). Singapore: Springer Nature Singapore, 2023: 343 - 356.
[22] WU Y, HE K. Group normalization [C] //Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3 - 19.
[23] ZHANG Y F, REN W, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression [J]. Neurocomputing, 2022, 506: 146 - 157.
[24] MA S, XU Y. Mpdiou: a loss for efficient and accurate bounding box regression [J/OL]. (2023 - 07 - 14) [2025 - 10 - 15]. https: //arxiv. org/abs/2307.07662.
[25] LIN C, ZHANG Y, CHEN G. Intelligent detection of safety helmets and reflective vests based on deep learning [J]. Journal of Real-Time Image Processing, 2025, 22 (1): 5.
[26] CHEN X, WANG G. AF-YOLOv8: a lightweight algorithm suitable for helmet and vest detection [J]. The Journal of Supercomputing, 2025, 81 (8): 996.
[27] ZHENG Z, WANG F, XU S, et al. Complete intersection over union: a metric and loss for bounding box regression [J]. IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 6568 - 6577.
[28] ZHENG Z, WANG P, LIU W, et al. Distance-IoU-loss: faster and better learning for bounding box regression [C] //Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34 (7): 12993 - 13000.
[29] REZATOFIGHI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: a metric and a loss for bounding box regression [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 658 - 666.
[30] TONG Z, ZHANG Q, LIU H, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism [J]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 1234 - 1243.

(上接第 184 页)

[4] 王 斌，许萌敏，唐绪之. 基于多尺度双阶段网络航空发动机涡轮叶片故障检测研究 [J]. 计算机测量与控制，2026，34 (3)：1 - 8.
[5] 畅炳陆. 舵机智能化故障诊断方法的研究 [D]. 太原：中北大学，2020.
[6] ZHOU J, LI P G, ZHOU Y H, et al. Toward new-generation intelligent manufacturing [J]. Engineering, 2018, 4 (1): 11 - 20.
[7] CERRADA M, ZURITA G, CABRERA D, et al. Fault diagnosis in spur gears based on genetic algorithm and random forest [J]. Mechanical Systems and Signal Processing, 2016: 70 - 71.
[8] 宋 辉，张 勇，郭 峰，等. 一种智能化的 γ 辐照装置故障诊断系统设计 [J]. 计算机测量与控制，2026，34 (2)：10 - 15.
[9] 杨 春，杜舒明. 美国军用自动测试系统 (ATS) 的发展趋势 [J]. 国外电子测量技术，2004 (6)：5 - 7.
[10] 王俭勤，李永明，杜延飞. 美国海军自动测试设备 RTCASS 的软件平台——PAWS [J]. 测控技术，2005 (4)：46 - 48.
[11] 朱 旖，杜建军. 国外军用电子自动测试系统发展综述 [J]. 电子测量技术，2008 (8)：1 - 3.
[12] 张 波，陈岩申，张桂芝. 外军电子自动测试系统及其相关技术的应用与发展情况研究 [J]. 计算机测量与控制，2002，10 (1)：1 - 4.
[13] IEEE. Standard 488.1: IEEE standard for higher performance protocol for the standard digital interface for programmable instrumentation [S]. Institute of Electrical and Electronics Engineers, 2003: 1 - 140.
[14] CHANG B L, YANG R F, GUO C X, et al. Performance evaluation and prediction of rudders based on machine learning technology [J]. Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering, 2019, 233 (15): 5746 - 5757.
[15] CHANG B L, YANG R F, GUO C X, et al. A new application of optimized random forest algorithms in intelligent fault location of rudders [J]. IEEE Access, 2019, 7: 94276 - 94283.
[16] 刘世豪，王细洋，龚廷恺. 基于深度迁移学习的齿轮故障诊断方法 [J]. 机械传动，2023，47 (5)：134 - 142.
[17] 张万旋，张 箭，卢 哲，等. 火箭发动机故障检测的快速增量单分类支持向量机算法 [J]. 国防科技大学学报，2024，46 (2)：115 - 122.
[18] 郝 君. 舵机便携式通用测试平台的研究 [D]. 太原：中北大学，2014.
[19] 王伟丽. 基于深度学习的舵机检测技术研究 [D]. 太原：中北大学，2022.
[20] 秦 浩. 舵系统健康管理技术研究 [D]. 太原：中北大学，2022.