

# 基于改进 YOLOv8 的铜电解短路检测

陈莉莉<sup>1</sup>, 郝文康<sup>2</sup>

(1. 湖南工业职业技术学院, 湖南 长沙 410083; 2. 中南大学 自动化学院, 长沙 410083)

**[摘要]** 铜电解精炼是铜冶炼的重要环节, 电解过程中电极短路现象难以避免。本文提出了一种基于 YOLOv8 的轻量级短路检测算法, 以有效解决复杂热分布下的短路检测问题。首先, 集成了 ShuffleNet 和 SqueezeNet 的先进技术, 在 YOLOv8 框架中增加了特征提取模块, 减少模型参数的同时保持了特征提取能力, 从而提升算法的检测速度; 其次, 针对检测精度不足及关联性差的问题, 根据短路数据集的特性, 优化损失函数并重新分配各损失权重, 有效提升了检测准确率; 最后, 对红外检测系统采集的电解槽图像进行实验, 结果显示, 改进后的算法不仅保持了较高的检测精度, 还降低了资源消耗, 平均精度 (mAP) 提升至 0.854。

**[关键词]** YOLOv8; 深度学习; 特征提取; 铜电解; 短路检测

**[中图分类号]** TF3; TF811

**[文献标志码]** B

**[文章编号]** 2097-2423(2025)02-0038-10

**DOI:** 10.19610/j.cnki.cn10-1873/tf.2025.02.006

## 0 引言

在有色金属冶炼过程中, 电精炼是一个必不可少的步骤。铜具有良好的导电性和导热性, 是应用最广泛的有色金属之一。在铜的电解过程中, 电解槽生产系统是发生电化学反应的主要场所。该系统由多个呈矩阵式分布的电解槽组成, 一旦电解槽发生短路, 电能消耗会很大, 铜的产量和质量将受到严重影响<sup>[1]</sup>。与传统的短路检测方法相比, 非接触式红外热成像检测具有许多明显的优势。此外, 为了提高检测效率, 检测数据处理算法应该要能适应电解车间复杂多样的环境。因此, 在保证精度的前提下提高检测速度, 已成为电解槽短路检测中亟待解决的问题。为解决以上问题, 本文提出了一种既能保证精度又能提高速度、易于部署实现的检测算法。

目前的短路检测方法包括直接检测和间接检测。其中, 直接检测又包括人工观察和电压电流检

测方法, 前者依赖于工人的主观操作经验, 后者则通过布置在阴阳极板和导电母排的电接触点的传感器来测量电解槽的电压和电流。基于直接检测方法的短路检测容易实现, 但也存在不足, 如过分依赖经验、对传感器要求高、维护成本高等。因此, 研究基于间接检测的铜电解短路检测具有重要意义。

间接检测是指通过红外测温枪或红外热像仪获得的表面温度进行短路测量。通过红外图像检测潜在的短路区域, 需要结合适当的处理算法。这些算法主要分为基于图像处理的传统方法和基于深度学习的物体检测方法。目前, 基于图像处理的传统短路检测方法已经有了大量研究。例如, Ojala 等<sup>[2]</sup>提出了一种局部二值模式, 通过比较局部区域的像素值进行分类。Ke 等<sup>[3]</sup>在尺度不变特征基础上, 利用主成分分析法实现了更高的检测性能。但是, 由红外测温枪实现的短路检测方法总是受环境限制而无法实现。传统图像处理方法对红外热图像的泛化能力较弱, 其特征提取能力有限。而基于深度学习的检测可以充分发挥自身优势, 更高效地完成对红外热图像的检测。

基于深度学习的目标检测与分类方法已受到广泛关注, 并在工业检测中取得了非常显著的效果。目前, 常用方法主要包括两阶段目标检测算法和单阶段目标检测算法两种。两阶段目标检测算法的主要代表是 R-CNN (Region-based Convolutional Neural Networks) 系列, 此类检测算法检测精度比较高, 但是检测速度比较慢; 单阶段目标检测算法的主要代

**[收稿日期]** 2024-12-06

**[基金项目]** 湖南省自然科学基金(2022JJ60029)。

**[作者简介]** 陈莉莉(1985—), 女, 硕士, 讲师, 主要研究方向为自动化技术在冶金工业中的应用。

**[引用格式]** 陈莉莉, 郝文康. 基于改进 YOLOv8 的铜电解短路检测[J]. 绿色矿冶, 2025, 41(2): 38-47.

CHEN Lili, HAO Wenkang. Detection of copper electrolytic short circuit based on the improved YOLOv8 [J]. Sustainable Mining and Metallurgy, 2025, 41(2): 38-47.

表有SSD(Single Shot MultiBox Detector)系列、YOLO系列、Anchor-Free系列等,此类算法精度一般,但是检测速度快。上述两种算法在工业领域都表现出了卓越的性能。例如,Zhu等<sup>[4]</sup>提出了一种基于Mask R-CNN的改进算法,优化了生成策略和非最大抑制算法,减少了电解池故障的漏检概率。Li等<sup>[5]</sup>在Faster R-CNN中引入了注意力模块,以提高获得丰富表征的能力,同时结合了参数调整和迁移学习的策略。

与典型的先提取候选区域再对候选区域进行分类的两阶段方法相比,单阶段方法具有更高的精度和速度,因为它通常自动调整锚箱,而不是先提取候选区域。因此,越来越多的研究人员致力于设计和应用YOLO系列来完成检测项目。目前,YOLO系列的检测速度和精度在持续快速地提高,卷积结构也越来越复杂。将YOLO算法应用于电解槽极板短路检测还存在以下需要解决的问题:①现有的目标检测方法为了追求更高的精度,检测范围越来越广且深度越来越深,造成了网络参数的爆炸式增长,追求高精度势必消耗大量的计算资源,对硬件性能的依赖性越来越强;②面对相对固定的工业场景,需要对目标检测方法作相应修改。因此,如何采取合理措施减少参数数量和模型大小,部署轻量级网络,以满足工业检测的要求成为关键问题。

基于现有问题,通常有两种方法可以解决,即模型压缩和网络结构轻量化。模型压缩包含知识提炼、模型剪枝、量化和低秩分解,网络性能可能会有一定损失;而网络结构轻量化则是从本质上减少参数数量,通过高效计算保证网络的优越性能。如Iandola等<sup>[6]</sup>分析了小型CNN架构的三个关键优势,并提出了Squeeze网络。Ma等<sup>[7]</sup>为移动设备设计了一种计算效率极高的CNN架构——ShuffleNet。Howard等<sup>[8]</sup>提出在MobileNet网络结构中,深度可分离卷积是减少参数的先进方法,并采用神经网络架构搜索(NAS)来确认最优架构。上述每种网络都有更高效的变体,如SqueezeNext、ShuffleNetv2、MobileNetv2-3等。

除此之外,数值轻量级网络将模型压缩或上述轻量化技巧与YOLO系列相结合,如Tiny-YOLO、NanoDet、YOLOX等。受YOLO的良好性能和上述轻量级网络结构的启发,通过整合最新YOLOv8的出色特征提取和检测性能,设计出轻量级骨干网络实现电解槽的高效短路检测成为可能。然而,参数

的减少总会导致精度降低,需要通过重新设计损失函数来实现性能提升。例如,张银胜等<sup>[9]</sup>针对现有损耗的窘境提出了一种有效的交叉联合损耗,结合YOLOv5的结构,该方法在风机表面缺陷检测方面取得了令人满意的结果。Xu等<sup>[10]</sup>引入了SIOU损失,增强了YOLOv5模型自动识别焊缝X射线缺陷的能力。针对上述研究现状,为解决硬件性能依赖性强、检测速度慢、网络结构与应用场景关联性差等关键问题,本文提出了一种基于YOLOv8的轻量级结构。该结构融合了目前出色的轻量级技术,针对电解槽短路的特殊表现形式,优化了损耗函数,进一步提高了检测精度。该方法可以减少资源消耗,提高检测速度,更适合铜电解极板短路检测的应用场景。本文的主要贡献概述如下:

1)在短路检测中,针对边缘设备部署困难、检测结果滞后的问题,构建了轻量级结构。该结构延续了模块化设计,改进了YOLOv8的骨干网络,同时集成了ShuffleNet<sup>[7]</sup>的信道随机切换和SqueezeNet<sup>[11]</sup>的压缩、扩展功能,在减少参数的同时保持了特征提取能力。

2)针对检测精度低、场景关联性差的问题,基于现有数据分析了短路的特点,提出了损失函数优化策略,并按重要程度重新分配各损失的权重,这两种方法都提高了检测准确率。

3)通过铜电解车间红外检测系统采集电解槽表面图像,建立各种短路状态的数据集。通过详细的对比实验,证明了本文所提出的轻量级检测算法具有准确性高和检测速度快的特点。

总之,本文设计了一个特征提取模块作为最新YOLOv8的骨干网络,解决了边缘设备部署困难和检测结果滞后的问题,并提出了损失函数优化策略,以保持检测精度。因此,所提出的轻量级网络可以更好地适应实际应用场景,减少资源消耗。

## 1 研究方法

本文提出的电解槽短路检测方法的总体框架如图1所示。在铜电解车间,为了监控整个铜电解过程,数字热成像仪垂直悬挂在电解槽上方,然后将热图像按顺序收集起来,并传输到服务器的数据库中。接着,利用提出的轻量级短路检测网络接收数据,并进行一些必要的预处理,如畸变校正等。然后,图像经过骨干模块、颈部模块和检测头,得到最终所需结果。最后,工作人员根据显示的短路位置和类型做

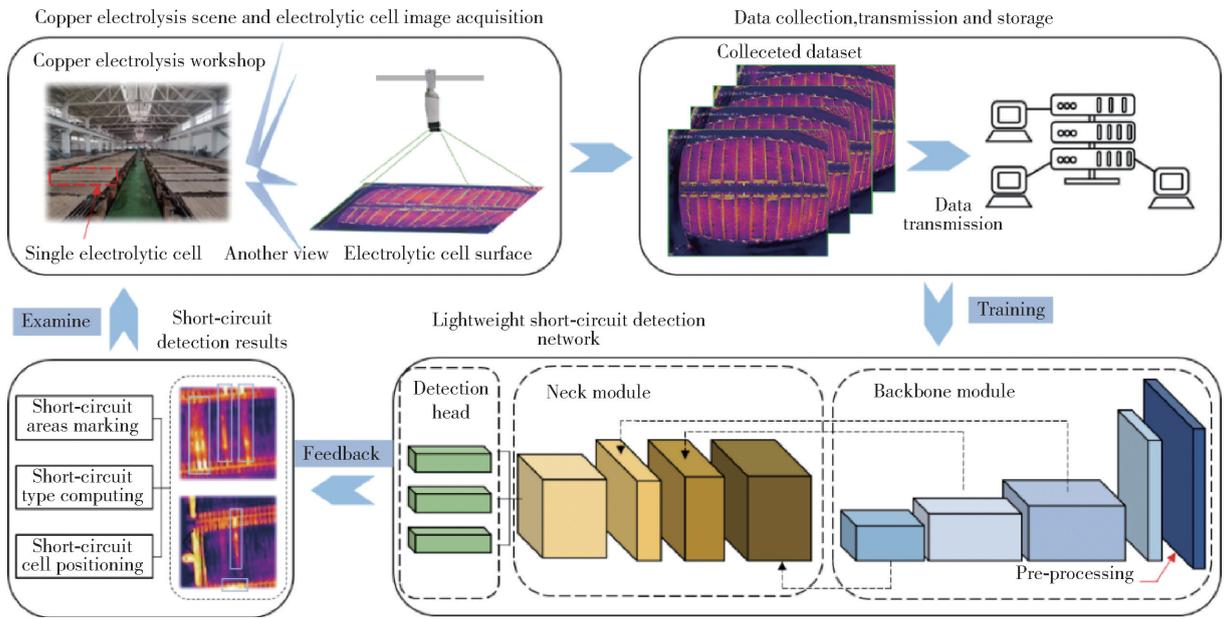


图1 电解槽短路检测的总体框架

相应处理。

在本节中,重点讨论轻量级检测网络,它对短路测量的准确性和高效性起着决定性作用。首先,详细介绍主干模块的构建思路,并分析该模块在特征提取方面的优势。其次,介绍了专有损失策略,该策略可更好地反映预测框规模的影响。

### 1.1 FireNet 单元:新的特征提取模块

受主流轻量级模型优秀设计策略的启发,提出了一种新的 FireNet 单元作为基本块结构,其设计遵循了 shuffle2 中提出的原理。如图 2(a) 所示, FireNet 单元采用常见的残余结构,并在开头设置了一个通道分离器。该分离器可将输入特征通道分为两个分支,其中的一个分支保持不变,另一个分支包含三层,分别是两个 Fire 模块(紧跟批量归一化层和 ReLU 激活层)和一个  $1 \times 1$  的点式卷积。

为了用较少的参数保持较高精度, Fire 模块 [squeezenet] 将压缩 ( $1 \times 1$  卷积) 和扩展 ( $1 \times 1$  和  $3 \times 3$  卷积的混合) 结合起来使用,如图 2 所示。与使用  $3 \times 3$  过滤器堆叠的模块相比,这种结构可以使用较少的参数获得更大的激活图。许多研究已经证明,  $1 \times 1$  过滤器比  $3 \times 3$  过滤器的参数少 9 倍。在许多网络结构中,  $1 \times 1$  滤波器被视为一种很好的升维或降维方法,因此压缩  $3 \times 3$  滤波器的输入通道可以有效控制参数个数。此外,两个 Fire 模块之间的  $1 \times 1$  点式卷积的输入和输出通道是相等的,只是提供了更多的非线性,而相等的通道宽度又可以最小化内存访问成本 [shuffle2]。在上述两个分支结合

之后,随机使用一个通道来更好地关联不同通道的特征。

图 2(b) 显示的是 2 倍采样的情况, Fire 单元作了微调,删除了通道分离器,并在另一个空闲分支上添加了一个 Fire 模块。同时,在输出前放置了一个 maxpool 运算符,以保持特征图的大小。与 YOLOv8 的基本 C2f 块(图 2(c)) 相比,新的 FireNet 单元在以下方面显得更加简单高效。C2f 块主要包含两个  $1 \times 1$  卷积层和  $n$  个瓶颈(突出显示的虚线方框)。两个带有可选快捷方式的  $3 \times 3$  卷积层构成了一个瓶颈,每个卷积层后都有一个批处理归一化层和一个 Silu 激活层,卷积操作占用了过多的参数,而且为了追求高性能,大量残差连接被用于传输特征。考虑到上述因素的影响,本文的设计减少了单元深度、卷积层和残差连接。

### 1.2 优化损耗机制

损失机制在整个检测网络中起着重要作用,严重影响网络的收敛性。YOLOv8 最初的损失函数由三项组成,如式(1)所示。

$$L_{\text{total}} = L_{\text{cls}} + L_{\text{dfl}} + L_{\text{iou}} \quad (1)$$

式中,  $L_{\text{cls}}$  指的是类损失,由二元交叉熵计算得出,数值报告会引入 VFL loss (目标类别分类损失) 作为 YOLOv8 的类损失,不过,目前官方正逐渐放弃,而使用 VFL 代替;  $L_{\text{dfl}}$  是指分布式聚焦损失函数,为了快速聚焦目标位置周围的分布,DFL 损失优化了这些位置的概率,有利于解决不平衡问题;  $L_{\text{iou}}$  是指预测位置和目标位置之间的交集损失函数, YOLOv8

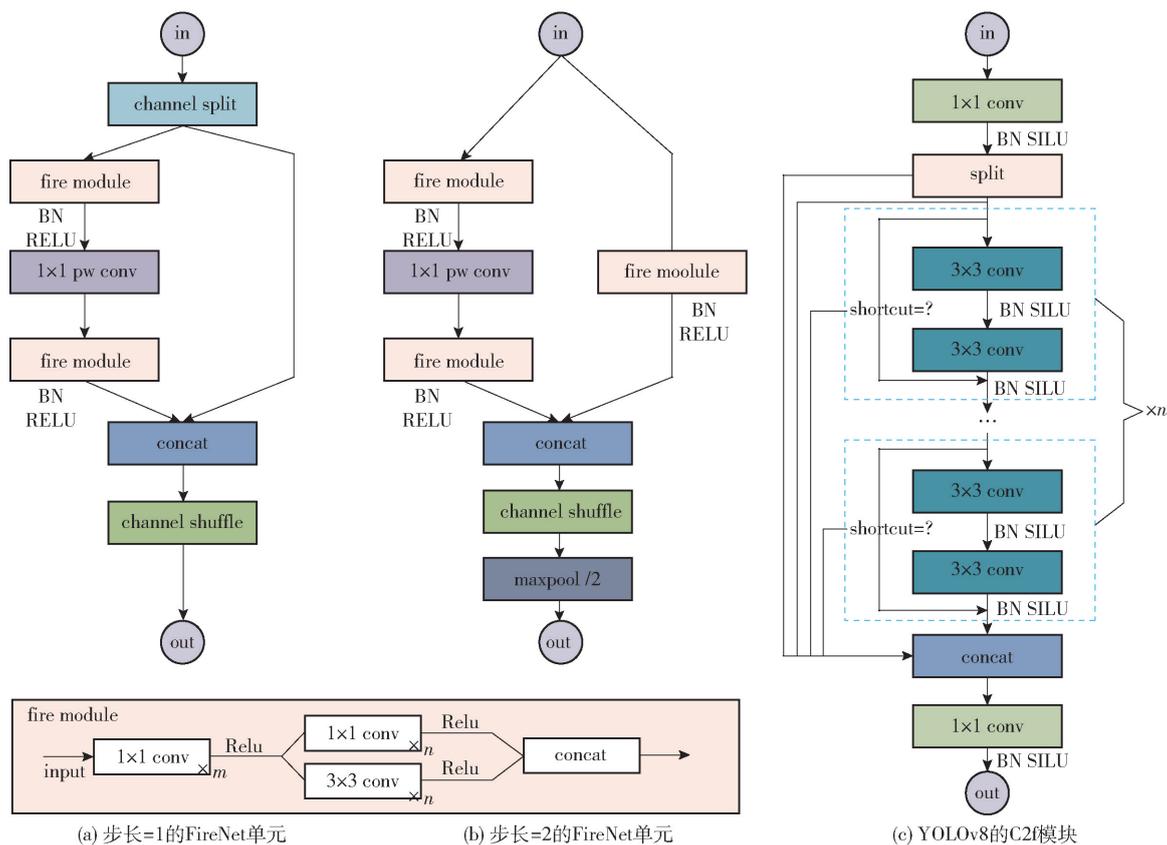


图2 FireNet单元和YOLOv8的C2f模块

的默认 IOU 损失是 CIOU, CIOU 解决了之前的 GIOU 和 DIOU 的缺点。CIOU 损失考虑了三个重要因素,包括重叠区域、中心点邻近度和长宽比,如式(2)所示。

$$L_{iou} = 1 - IOU + \frac{\rho^2(\mathbf{b}, \mathbf{b}^{gt})}{c^2} + \alpha\nu \quad (2)$$

式中,  $\rho$  代表计算两点间的欧氏距离,  $\mathbf{b}$  和  $\mathbf{b}^{gt}$  分别代表预测框和目标框的中心点,  $c$  是预测框与真实框的边界矩形的对角线距离;  $\nu$  是用来度量长宽比的相似性,定义为:

$$\nu = \frac{4}{\pi^2} \left( \arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \quad (3)$$

式中,  $w$  和  $h$  分别代表预测框的宽度和高度,  $w^{gt}$  和  $h^{gt}$  分别代表真实框的宽度和高度。  $\alpha$  是权重系数。

$$\alpha = \frac{\nu}{(1 - IOU) + \nu} \quad (4)$$

然而,  $L_{iou}$  定义似乎不够明确和专业,为了更好地配合铜电解槽极板短路检测的要求,根据要分析的数据特点,对  $L_{iou}$  做了相应修改。短路检测的对象是以矩阵式分布的电解槽组,为避免电解液蒸发,电解槽表面有盖布覆盖。图3显示了几种短路情况

下电解槽板的红外图像,从中可以看出每个电解槽之间的热传导比较复杂,灰度分布也不均匀。经分析各类目标盒的长宽比分布如图4所示。由图4可知,入口和出口处的长宽比与其他三种也有很大差异。因此,为了保留不同长宽比的分布特征,将长宽比引入函数,从而使 IOU 损失在预期方向上衰减得更快。

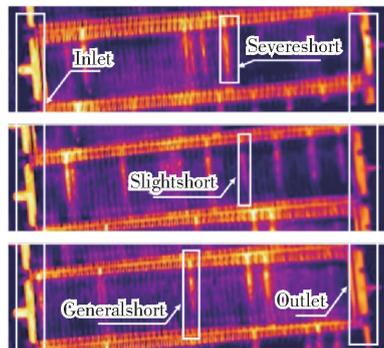


图3 突出显示短路类型的电解槽板红外图像

综上所述,优化后的 IOU 损失函数和总损失分别为:

$$\alpha \left( \frac{h}{w} \right) = \frac{\nu}{(1 - IOU - f\left(\frac{h}{w}\right)) + \nu} \quad (5)$$

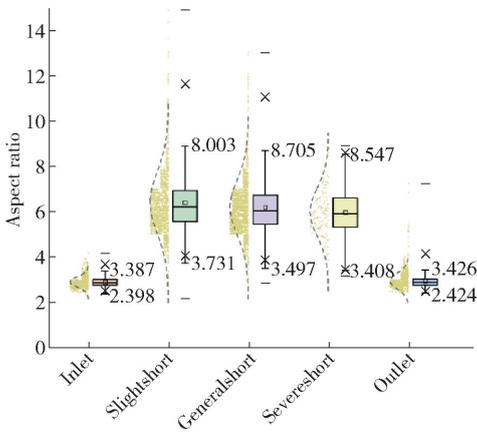


图4 不同类型的纵横比统计

$$L_{\text{improved\_iou}} = 1 - IOU + \frac{\rho^2(\mathbf{b}, \mathbf{b}^{\text{gt}})}{c^2} + \alpha \left( \frac{h}{w} \right) \nu \quad (6)$$

$$L_{\text{total}} = L_{\text{cls}} + L_{\text{dfl}} + L_{\text{improved\_iou}} \quad (7)$$

在工程实施过程中,应根据检测要求调整三种损失的权重,这将在第2.3节中进一步讨论。

### 1.3 短路检测网络的总体结构

基于YOLOv8的极板短路检测网络的整体结构和详细参数如图5所示。按照单阶段检测网络的一贯风格,该网络由三部分组成:提取语义特征的骨干、融合特征的颈部和检测的头部。骨干主要由FireNet单元堆叠组成,分为三个阶段。在每个阶段,首先构建一个步长为2的FireNet单元,然后构建一个步长为1的FireNet单元。每一阶段的输出通道都是前一阶段的2倍,特征图的大小减半。图5中还给出了FireNet单元的详细参数,这些参数清楚地反映了通道的内在变化。颈部在连接中起着重要作用,通过金字塔设计融合语义信息。本结构采用PAN-FPN作为颈部。与YOLO系列之前的版本相比,YOLOv8将检测器改为无锚方式,并采用了更精密的检测技术,例如,去耦合头部大幅提高收敛速度;任务对齐分配器采用动态方式解决分类和回归之间的冲突等。整个网络可以很好地处理输入图像

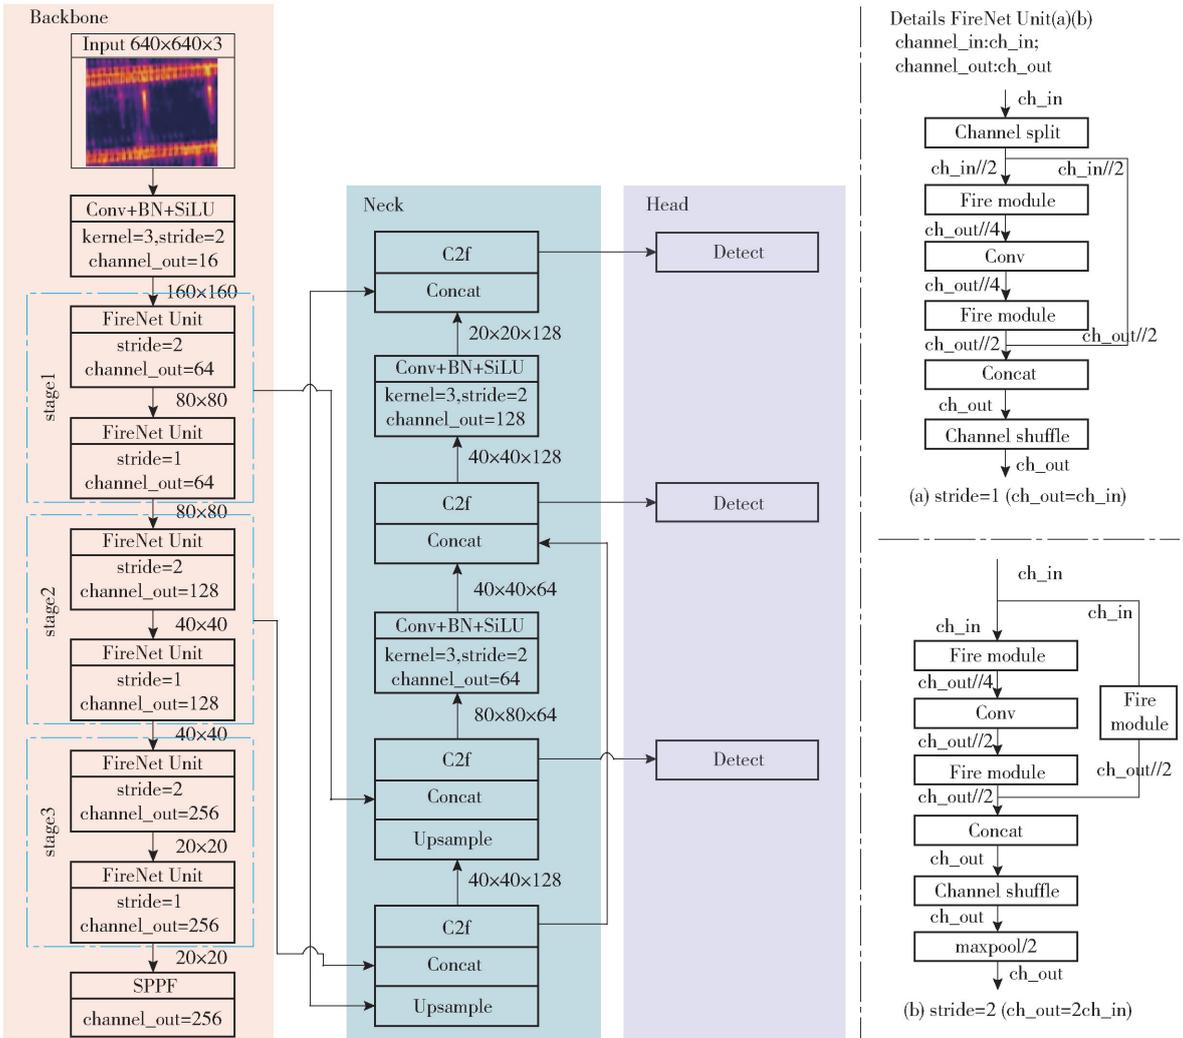


图5 基于YOLOv8的极板短路检测网络的整体结构

并进行分类和回归。

## 2 实验

### 2.1 短路检测实验数据集

为了验证轻量级检测算法的性能,利用从某冶炼厂车间收集的数据进行了检测实验。如图6所示,对垂直于电解槽平面的摄像头拍摄的红外图像进行预处理,基于多项式拟合的方法实现了桶形畸变校正,并利用像素累积峰值法对图像进行简单分割<sup>[12]</sup>。在畸变校正过程中采用三次映射关系描述校正前后半径之间的关系,即:

$$r_n = \sum_{i=0}^3 k_i r^i \quad (8)$$

式中, $r_n$ 为矫正像素到矫正中心的距离; $r$ 为畸变像素到畸变中心的距离; $k_i$ 为畸变参数。最终通过拟合畸变图像中槽边界的像素坐标得到估计参数: $k_0 = 10, k_1 = 1, k_2 = 3.52 \times 10^{-4}, k_3 = 8 \times 10^{-7}$ 。

其次,利用像素累积峰值即可对单槽图像进行完整提取,像素累积计算公式为:

$$y_i = \sum_{j=1}^N p_{ij} \quad (9)$$

$$y_j = \sum_{i=1}^M p_{ij} \quad (10)$$

式中, $p_{ij}$ 为图像的灰度值, $M$ 和 $N$ 分别为图像的宽和高。

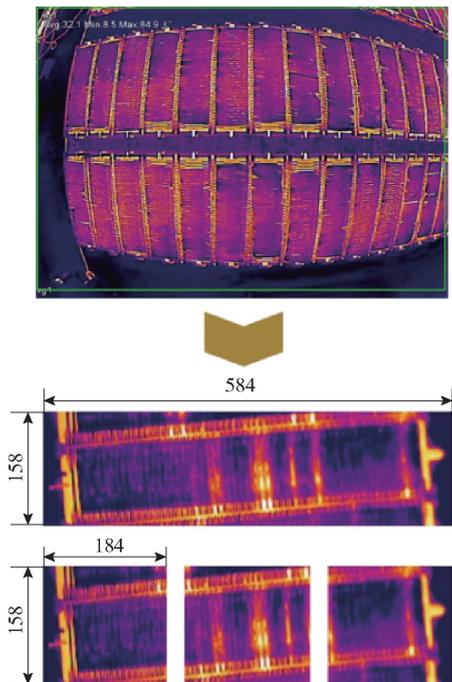


图6 收集和预处理的红外图像

最后,1400张原始图像被分割成4200张图像,大小为155 px × 184 px × 3 px,训练集和验证集的比例为6:4。根据图3,使用标注软件标注了5个类别,包括3种不同程度的短路,即轻微、一般、严重,电解液入口(In)和出口(Out)。

### 2.2 实验设置

建立数据集后,将提出的轻量级短路检测网络在PyTorch深度学习框架上进行训练。运行环境为Windows 10, GPU为NVIDIA GeForce GTX 1660Ti。考虑到该网络是基于YOLOv8构建的,在保持原有参数设置的基础上,选择带有scale-n的YOLOv8作为主要比较算法。同时,为了体现轻量级性能,使用ShuffleNetV2(YOLOv8-Shuffle)替换YOLOv8骨干网络作为另一种比较方法,其中ShuffleNetV2被认为是一种具有较高精度的优秀的轻量级结构。

在PP-PicoDet<sup>[13]</sup>的基础上还考虑了另外三种比较方法,即PicoDet-S、PicoDet-Shuffle和PPYOLOE-CRN。PicoDet-S是指带有scale-s的原始结构的目标检测模型,它以ESNet为骨干网络,CSP-PAN为颈部,PicoHead为检测头,并且使用SimOTA作为标签分配策略。PicoDet-Shuffle仅用ShuffleNetV2代替ESNet。PPYOLOE-CRN以CSPResNet为骨干,定制CSPPAN为颈部,以PP-YOLOE Head为检测头。表1列出了上述方法的通用训练参数。其中,批大小选择需要平衡计算资源和收敛速度,小批量可以更频繁地更新模型的权重,收敛速度较快;线程数为了改变数据的加载速度,合理的线程有利于提高整体的训练速度;初始学习率取决于模型和数据集的复杂度,学习率过小会导致训练过程变慢,而学习率太大可能导致模型不稳定;动量项是优化器中的一个超参数,可通过试验不同的动量值来调节训练过程的稳定性和速度,合理的设置可以加速收敛,减小训练时间;禁用数据增强时期是为了使模型聚焦于更具体的特征,在后期禁用数据增强可以防止模型在初始阶段陷入过拟合,且有助于提高模型的准确性。

表1 训练参数

图像大小	批大小	线程数	初始学习率	动量项	禁用数据增强的时期
640	16	8	0.01	0.9	最后10次

### 2.3 实验结果与分析

根据上述设置,对比前两种算法和本文的轻量级算法,在 IOU 值为 0.5 时的平均精度 (mAP@0.5) 如图 7 所示 (epoch 为 50)。在每种情况下,本文所提出的算法的 mAP@0.5 都略高于或与 YOLOv8 相当,尤其是在一般短路和严重短路情况下。YOLOv8-Shuffle 在轻微短路时的性能稍微差一点。图 8 显示了三种算法的损失收敛曲线,包括 CLS 损失、DFL 损失和 IOU 损失。值得注意的是,YOLOv8 和 YOLOv8-Shuffle 的 IOU 损失指的是原始 CIOU 损失,而本文的 IOU 损失指的是改进后的损失。由图 8 可知,各种损失都表现出相同的收敛

趋势,即在前 10 个 Epoch 急剧下降,然后减速,在第 40 个 Epoch 左右突然下降,这可能是在最后 10 个 Epoch 关闭了数据增加 (mosaic) 策略造成的。整个收敛过程没有过拟合现象。

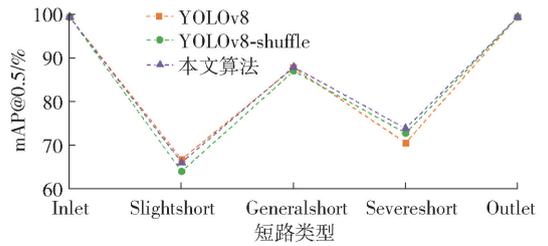


图 7 mAP@0.5 三种算法的比较

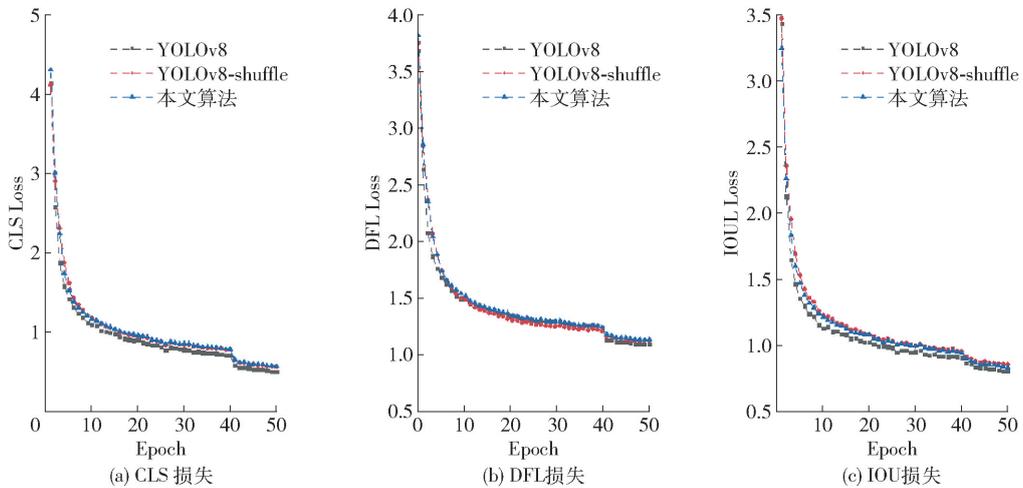


图 8 三种算法的损耗曲线

如第 1.2 节所述,本文的损失函数由三项组成,其中权重对网络的收敛性起着决定性作用。因此,通过实验来讨论数据集的最佳权重分配,结果如图 9 所示。考虑到时间消耗,本文只探讨了在原始损失和图像大小设置为 320 px × 320 px 的情况下,epoch 为 15 时 5 个不同比例 (group0 - group4) 的 mAP。从图 9 可知,在第 3 组中, mAP@0.5 达到 80%, mAP@0.5:0.95 超过 58%。因此,将三个项目的权重比例 1.5:1.0:7.0 作为最终的训练数据。

此外,讨论了不同 IOU 损失函数的效果,结果如图 10 所示。由图 10 可知,正如预期一样, mAP 显示 DIOU 损失函数由于忽略了长宽比的影响,所以表现最差。优化后的 IOU 损失在所有类别中都表现良好,尤其是在一般短路类别上表现最佳,虽然 mAP@0.5:0.95 的性能略有下降,但仍在可接受范围内。总之,实验结果表明,计算 IOU 损失时引入不同类型分布特征的策略是有效的。

在构建 FireNet 的过程中,受到数值 SOTA 技巧

的启发,本文进行了一系列实验来验证各种技巧的有效性。为了更好地讨论 FireNet 的结构,不考虑损失函数的影响,考虑使用 YOLOv8 的原始损失函数进行实验,实验结果见表 2。Epoch 和图像大小分别

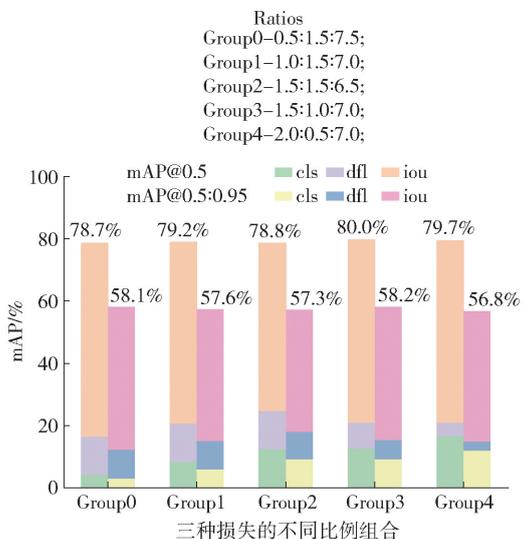
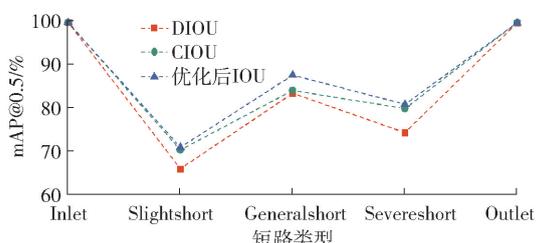


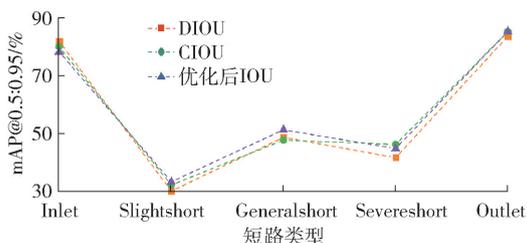
图 9 mAP 分析了三种损失项的不同比例

表2 在 FireNet 上研究 SOTA 技巧的有效性

RELU	SILU	Spatial attention	Channel attention	Dwconv (within Fire)	Training layers	mAP@0.5	Parameters/M
-	√	×	×	×	314	0.832	2.0
√	-	√	×	×	335	0.848	2.0
√	-	×	√	×	377	0.836	2.0
√	-	×	×	√	382	0.828	1.95
-	√	×	√	×	377	0.841	2.03
√	-	×	√	√	445	0.844	1.98
√	-	×	×	×	314	0.848	2.0



(a) mAP@0.5



(b) mAP@0.5:0.95

图10 不同 IOU 损失的 mAP 分析

设置为 50 和 640 px × 640 px。与最后一行的结果相对应,图 5 所示的当前 FireNet 单元是本文的基线。使 SILU 代替 RELU 作为激活函数可以在开始时加快收敛速度,但收敛趋势无法持续整个过程。

在检测网络中引入注意力机制通常是实现高精

度的有效方法。因此,分别采用了 CBAM<sup>[14]</sup> 中的空间注意力机制和 GhostNetV2<sup>[15]</sup> 中的通道注意力机制。空间注意力机制加在第一个 Fire 模块之后,而通道注意力机制则加在第一个 Fire 模块中。实验结果证明,空间注意力只会增加训练层,通道注意力甚至会带来负增益。

此外,在 Fire 模块中采用了深度可分离卷积操作<sup>[16]</sup>来替代传统的 3 × 3 卷积操作,从而减少了 0.05 M 的参数,同时 mAP 下降了 2%。尽管 mAP@0.5 比单一技巧更高,但同时替换激活函数和采用通道注意力机制对 mAP 和参数减少都没有正向增益。相比之下,同时替换 3 × 3 卷积和采用通道注意力机制会带来 0.05 M 的参数减少和 0.3% 的 mAP 改善。总之,流行的 SOTA 技巧可能不适用于任何架构,其影响需要通过实验来判断。对于轻量级网络,模块越多可能会导致冗余参数。因此,最终采用了图 5 所示的简要结构。

最后,本文在数据集上进行了大量实验,所有对比实验都使用了相同的硬件和代码库,实验结果见表 3。

表3 与 SOTA 算法的比较(粗体和斜体字体分别表示最佳和第二性能)

Model	mAP@0.5	mAP@0.5:0.95	Frame rate/fps	Parameters/M	FLOPs/G
YOLOv8	<i>0.848</i>	<b>0.669</b>	106.38	<i>3.0</i>	8.1
YOLOv8-Shuffle	0.846	0.652	<i>149.25</i>	<b>2.0</b>	<b>5.5</b>
PicoDet-S	<i>0.848</i>	0.617	132.96	3.8	—
PicoDet-Shuffle	0.819	0.605	<b>171.85</b>	4.5	—
PPYOLOE-CRN	0.763	0.576	39.5	29.23	—
本文算法	<b>0.854</b>	<i>0.653</i>	128.21	<b>2.0</b>	5.7

PicoDet-S 和 PicoDet-Shuffle 的图像大小设为 320 px × 320 px,其他算法保持 640 px × 640 px。在模型性能的评估中,除指标 mAP@0.5 和 mAP@0.5:

0.95 外,还考虑帧率(FPS)、模型参数量(Parameters)和浮点运算量(FLOPs)指标。帧率指模型每秒处理的图像帧数,用来衡量模型的推理速度和

模型的复杂性,通常减小模型的复杂性可提高帧率;模型参数量指的是模型中的可训练参数数量,更大的参数量通常意味着更强的模型表达能力,但会导致模型推理速度变慢;FLOPs代表了模型推理过程中需要进行的浮点运算次数,FLOPs越大,意味着模型在推理时需要的计算量越大,会导致推理速度变慢。

本文算法的 mAP@0.5 达到 85.4%,在所有模型中表现最优,mAP@0.5:0.95 达到 65.3%,仅次于 YOLOv8 模型的最优结果 66.9%。YOLOv8 由于含有大量的残差和卷积操作,在 mAP@0.5 指标中获得了和 PicoDet-S 模型相同的次优结果 84.8%,其 mAP@0.5:0.95 优于包括 PicoDet-S 在内的所有其他算法。与本文算法相比,YOLOv8 模型中的残差和卷积操作使其占用了过多的参数,导致帧率下降和浮点运算量较大。YOLOv8-Shuffle 与 ShuffleNetV2 相结合,尽管 mAP 略低,但却实现了最小的浮点运算量和最好的 FLOPs。本文算法与 YOLOv8-Shuffle 相比,保持了相同的参数,但 FLOPs 较大,帧率较小,mAP 较高。

除分辨率外,PicoDet 系列的整体性能略差,SimOTA策略和 ESNNet 块可能是主要原因。PicoDet-S 与 PicoDet-Shuffle 相比,ShuffleNetV2 在提高帧速率方面的效果突出,但在参数量提高的情况下,mAP 指标值变差。PPYOLOE-CRN 不是轻量级的模型,且在本文的数据集中表现较差。此外,通过仿真结果可发现,参数量和 FLOPs 具有一定的正相关性,而帧率与参数量和 FLOPs 呈负相关,mAP 与后三者的相关性不大。

总之,根据上述一系列实验结果,本文的方法取得了最佳的综合性能。同时,轻量级模型在边缘设备上部署也比较方便。

### 3 结论

针对电解槽短路检测中存在的对硬件性能依赖性强、检测速度慢、网络结构与应用场景关联性差等关键问题,提出了一种基于先进的 YOLOv8 框架的轻量级短路检测算法。整个研究总结如下:

1)为实现检测速度和精度的要求,基于轻量级原则设计了特征提取模块,融合了 SOTA 算法的优秀思想。然后,基于 YOLOv8 的损耗机制提出了损耗函数优化策略,充分考虑了各短路类型之间的差异。

2)为了验证轻量级检测算法的性能,通过在车间收集的实际数据对提出的算法进行了测试实验。实验结果表明,对于每种短路类型,尤其是一般短路和严重短路,本文算法的 mAP@0.5 都高于或相当于 YOLOv8。根据对损失函数的单独分析,将各损失项的比例设定为 1.5:1.0:7.0,以确保最佳收敛性。此外,进行了一系列消融实验,验证了所设计的骨干网络的合理性。最后,与目前的检测算法相比,本文算法实现了 85.4%的 mAP@0.5 和 65.3%的 mAP@0.5:0.95,综合考虑帧速率、参数和 FLOPs,这是非常好的结果。

3)为了提高网络结构和应用场景之间的关联性,分析了短路性能的特点,保留不同长宽比的分布特征,将长宽比引入函数,从而使 IOU 损失在预期方向上衰减得更快。在训练时使用数据增强技术,增强模型的泛化能力和适应性,使得模型在实际应用中能够更好地适应各种场景。

此外,本文研究还存在以下两个局限性:

1)数据集不平衡。在铜电解过程中,不同程度的短路发生概率是不同的。因此,采集到的电解槽红外图像中严重短路的情况较少,约为其他红外图像的 1/10 倍,这就造成了数据集不平衡的问题。本文缺乏对这一问题的关注。

2)机制探索。研究主要集中在间接检测算法上,导致缺乏对电极短路机理的相关研究。然而,对短路机理的预先了解也是提高检测精度的关键。

在今后的研究中,要加深对短路检测的研究。首先,考虑到不平衡对精度的影响,未来将研究一般方法的有效性,进一步提高严重短路的检测精度。然后,将探索电极短路的电热耦合模型,并进一步分析其分布规律,以改进本文的算法。

### [参考文献]

- [1] 曾箐雨,蒙毅,李纯,等.铜电解槽的极间短路温度效应[J].湿法冶金,2020,39(5):429-433.
- [2] OJALA T, PIETIKÄINEN M, MÄENPÄÄ T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2002(7): 971-987.
- [3] KE Y, SUKTHANKAR R. PCA-SIFT: A more distinctive representation for local image descriptors[J]. IEEE Computer Society, 2004, 4: 506-513.
- [4] ZHU H, PENG T, DAI Y, et al. Fault detection of elec-

- trolizer plate based on improved Mask R-CNN and infrared images[J]. *Measurement Science and Technology*, 2022, 33(8): 085405.
- [5] LI X, LI Y, WU R, et al. Short circuit recognition for metal electrorefining using an improved faster R-CNN with synthetic infrared images[J]. *Frontiers in Neurobotics*, 2021, 15: 751037.
- [6] IANDOLA F N, MOSKEWICZ M W, ASHRAF K, et al. FireCaffe: near-linear acceleration of deep neural network training on compute clusters [C] // *Computer Vision & Pattern Recognition*. IEEE, 2016.
- [7] MA N, ZHANG X, ZHENG H T, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design [C] // *European Conference on Computer Vision*. Springer, Cham, 2018.
- [8] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3 [C] // *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, 2020.
- [9] 张银胜, 杨宇龙, 吉茹, 等. 改进YOLOv5s的风力涡轮机表面缺陷检测[J]. *电子测量与仪器学报*, 2023(1): 40-49.
- [10] XU Lushuai, DONG Shaohua, WEI Haotian, et al. Defect signal intelligent recognition of weld radiographs based on YOLOv5 improvement [J]. *Journal of Manufacturing Processes*, 2023, 99: 373-381.
- [11] 郭子宁, 黄海龙, 高培根. 改进SqueezeNet卷积神经网络机械零件表面缺陷检测算法[J]. *制造业自动化*, 2024, 46(2): 121-124.
- [12] 李欣. 基于红外热图像的铜电解短路检测与电解运行状态评价方法研究[D]. 长沙: 中南大学, 2022.
- [13] YU Guanghua, CHANG Qinyao, LV Wenyu, et al. PP-PicoDet: A better real-time object detector on mobile devices [J]. Ithaca: Cornell University Library, arXiv.org, 2021.
- [14] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C] // *Computer Vision ECCV 2018*. Springer, Cham, 2018.
- [15] TANG Yehui, HAN Kai, GUO Jianyuan, et al. GhostNetV2: enhance cheap operation with long-range attention [J]. Ithaca: Cornell University Library, arXiv.org, 2022.
- [16] XU S, WANG X, LV W, et al. PP-YOLOE: An evolved version of YOLO [J]. Ithaca: Cornell University Library, arXiv.org, 2022.

## Detection of Copper Electrolytic Short Circuit Based on the Improved YOLOv8

CHEN Lili<sup>1</sup>, HAO Wenkang<sup>2</sup>

(1. Hunan Industry Polytechnic, Changsha 410083, China;

2. School of Automation, Central South University, Changsha 410083, China)

**Abstract:** Copper electrolytic refining is an important part of copper smelting, and electrode short circuit is unavoidable in the process of electrolysis. Therefore, this paper proposed a lightweight short-circuit detection algorithm based on YOLOv8 to effectively solve the problem of short-circuit detection under complex heat distribution. First, advanced technologies of ShuffleNet and SqueezeNet were integrated. A feature extraction module was added to the YOLOv8 framework, reducing model parameters while maintaining feature extraction capability, thereby improving the detection speed of the algorithm. Secondly, to solve the problem of insufficient detection accuracy and poor correlation, according to the characteristics of short-circuit data set, the loss function was optimized and each loss weight was reassigned, which effectively improved the detection accuracy. Finally, the experiment results show that the improved algorithm not only maintains high detection accuracy, but also reduces resource consumption, and the average accuracy (mAP) is increased to 0.854.

**Key words:** YOLOv8; deep learning; feature extraction; copper electrolysis; short-circuit detection