

DOI: 10.13382/j.jemi.B2407599

基于改进 YOLOv8n 的圆柱电池壳多维缺陷检测技术研究*

吴永泽^{1,2} 俞建峰^{1,2} 化春健^{1,2} 蒋毅^{1,2} 钱陈豪^{1,2}

(1. 江南大学机械工程学院 无锡 214122; 2. 江苏省食品先进制造装备技术重点实验室 无锡 214122)

摘要: 圆柱电池壳的多维缺陷检测是保证锂电池质量和安全的关键技术。由于生产加工和运输过程中涉及的工艺环节不同,圆柱电池壳的每个部位均会产生缺陷。为解决现有检测方法在处理种类繁多、尺度不一的圆柱电池壳缺陷时检测精度低的问题,本文根据圆柱电池壳各部位特征搭建图像采集装置,构建了圆柱电池壳多维缺陷数据集,提出了一种基于改进 YOLOv8n 的圆柱电池壳多维缺陷检测技术。首先,引入可切换空洞卷积改进 C2f 模块,增强多尺度特征提取能力;其次,结合平均池化和最大池化策略改进下采样模块,在降低特征图空间尺寸的同时保留关键信息;最后,引入 LSKA 注意力机制,增强多尺度特征的融合效果。实验结果表明,改进后的 YOLOv8n 模型在自制的圆柱电池壳缺陷数据集上平均检测精度可达 77.4%,相较于原始模型提升了 4.3%,计算量下降了 17%,模型大小仅为 6 MB,检测速度达到 177 FPS,满足工业大批量实时检测的要求。

关键词: 圆柱电池壳;多维缺陷检测;YOLOv8n;可切换空洞卷积;LSKA 注意力

中图分类号: TP391;TN911.73 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Research on multi-dimensional defect detection technology for cylindrical battery shells based on improved YOLOv8n

Wu Yongze^{1,2} Yu Jianfeng^{1,2} Hua Chunjian^{1,2} Jiang Yi^{1,2} Qian Chenhao^{1,2}

(1. School of Mechanical Engineering, Jiangnan University, Wuxi 214122, China; 2. Jiangsu Key Laboratory of Advanced Food Manufacturing Equipment and Technology, Wuxi 214122, China)

Abstract: The multi-dimensional defect detection of cylindrical battery shells is a critical technology for ensuring the quality and safety of lithium batteries. Due to the different processes involved in production and transportation, defects may occur in each part of the cylindrical battery shells. To solve the problem of low detection accuracy in existing methods when handling the diverse and variably scaled defects of cylindrical battery shells, this study designs an image acquisition system based on the characteristics of each part of the battery shells and constructs a multi-dimensional defect dataset. Additionally, a multi-dimensional defect detection technology is proposed based on an improved YOLOv8n. Firstly, the switchable atrous convolution is used in the C2f module to improve the multi-scale feature extraction capability. Secondly, the down sampling module is refined by combining average pooling and max pooling strategies, reducing the spatial dimensions of feature maps while retaining key information. Finally, the LSKA attention mechanism is introduced to enhance the fusion effect of multi-scale features. Experimental results show that the improved YOLOv8n model achieves an average detection accuracy of 77.4% on a custom cylindrical battery shell defect dataset, which is 4.3% higher than the original model. Furthermore, the computational load is reduced by 17%, the model size is only 6 MB, and the detection speed reaches 177 FPS, meeting the requirements for real-time industrial mass detection.

Keywords: cylindrical battery shell; multi-dimensional defect detection; YOLOv8n; switchable atrous convolution; LSKA attention

0 引言

圆柱锂电池因其高能量密度、体积小、寿命长等优点,被广泛应用于便携式电子设备和新能源汽车等领域^[1-2]。圆柱电池壳是圆柱锂电池的重要组成部分,为锂电池内部的电芯提供结构支撑与保护。在圆柱电池壳的生产过程中,由于加工工艺、清洗不彻底或壳体间碰撞等因素,圆柱电池壳表面会出现划伤和水渍等缺陷,口部出现豁口,内部混入异物^[3-4]。这些缺陷会导致电池的结构强度减弱,影响产品性能,严重时甚至会引发短路、漏液或热失控,危及生命安全^[5]。因此,出厂前对圆柱电池壳进行缺陷检测尤为重要。

目前,圆柱电池壳的缺陷检测主要采用人工目视检测和自动化检测两种方法。人工目视检测通过人眼反复观察传送带上滚动的圆柱电池壳,挑选出存在缺陷的电池壳。该方法效率低、准确率低且人工成本高,难以满足高效和高质量的检测需求。相比之下,基于机器视觉的自动化检测更准确高效。郭绍陶等^[6]通过多光源采集、时域平均及异常值剔除和灰度分布曲线分析等技术实现对圆柱电池壳端面凹坑缺陷的精准检测。Chen 等^[7]针对电池表面凹坑和锈迹等缺陷设计了包括阈值分割、模板匹配和霍夫圆检测在内的特定检测方法,实现了电池表面缺陷的自动化检测;邵天成等^[8]通过改进的光度立体模型计算出电池表面的三维特征信息,有效增强电池金属表面浅划伤、浅凹陷等微弱缺陷的表现,提高了微弱缺陷在检测任务中的检测精度。然而传统机器视觉技术主要依赖图像处理技术和传统机器学习方法,在面对复杂无规则的数据时,常面临特征提取困难和泛化能力有限的问题^[9]。深度学习技术与缺陷检测任务的结合有效解决了传统机器视觉检测方法中存在的问题,已有学者将深度学习技术应用于圆柱电池壳的缺陷检测任务中。Hu 等^[10]提出一种用于 YOLOv5s 模型的轻量级空间金字塔池化结构,在减少模型参数数量的同时增强特征提取能力,但其数据集中缺陷的大小和形态相对单一,限制了模型处理复杂和多样化缺陷的能力。Dandage 等^[11]提出一种多尺度图像增强方法扩充电池表面缺陷数据集,但源图像数量有限,导致模型在处理复杂缺陷类型时泛化能力和检测精度不足;Zhang 等^[12]在原有的 YOLOv5 网络模型上增加小目标检测层和卷积块注意力模块(convolutional block attention module, CBAM)注意力机制改善模型对小缺陷的检测效果,但其缺陷检测的准确率较低,仅达到 67.5%,难以满足实际应用的高精度需求。封学勇^[13]将 Cascade R-CNN、Faster R-CNN 和 YOLOv3 这 3 种深度学习模型应用于电池钢壳的表面缺陷检测任务,但并未针对电池钢壳不同类型缺陷的特征

差异做出针对性改进;陈昭霏^[14]通过 VGG16 分类网络配合图像后处理的方式检测电池壳有无缺陷和缺陷位置的判断,但实际测试过程中每个电池壳的检测时间平均需要花费 0.53 s,不满足工业实时检测的需求;

综上所述,圆柱电池壳的缺陷检测任务仍存在以下问题:圆柱电池壳的缺陷类型繁多,同种缺陷也会呈现出不同的形态特征,模型在检测多尺度缺陷时需具备较强的泛化能力以有效识别各种形态的缺陷;目前大部分研究仅针对圆柱电池壳的底部或侧面等单部位缺陷进行检测,未涵盖圆柱电池壳所有可能存在缺陷的部位,限制了圆柱电池壳缺陷检测算法在工业实时检测场景下的应用;针对上述问题,根据实际工业场景搭建图像采集装置,采集电池壳底部、口部、内部和侧面图像并构建圆柱电池壳多维缺陷数据集,提出一种基于改进 YOLOv8n 模型的圆柱电池壳多维缺陷检测算法。首先,基于可切换空洞卷积重新设计 C2f 模块,在提取图像多尺度特征时动态调整感受野,同时捕捉不同尺度的特征;其次改进原模型中的下采样模块,在降低特征图空间尺寸的同时保留全局信息和关键特征;最后,在 Neck 部分引入大型可分离卷积核注意力机制增强多尺度特征的融合效果,减少特征信息的丢失。

1 圆柱电池壳多维缺陷检测算法

1.1 YOLOv8 目标检测算法

YOLO 作为一种经典的目标检测网络,可以直接预测目标的类别与位置,自问世以来在目标检测任务中得到了广泛应用。经过多次迭代和版本升级,自 YOLOv5 起,YOLO 模型的性能已经超越 Faster R-CNN^[15]、SSD^[16]和 EfficientDet^[17]等模型。YOLOv8 是 Ultralytics 团队基于 YOLOv5 推出的全新版本,通过改进网络结构设计、损失函数和在线数据增强等方面,进一步优化了模型的训练和推理效率,适用于更广泛的应用场景。

YOLOv8 网络模型主要由 Backbone、Neck 和 Head 这 3 个部分组成^[18]。Backbone 部分通过卷积模块、C2f 模块和快速空间金字塔池化层(spatial pyramid pooling fast, SPPF)实现输入图片的特征提取,随着卷积层数的增加,生成不同层次的特征图;Neck 部分接收这些特征图,通过特征融合、上采样和下采样操作构建双向特征金字塔结构,融合不同尺度的特征图,检测不同大小的目标;Head 部分生成最终的检测结果,包括边界框的回归和类别置信度的预测。

1.2 改进 YOLOv8n 目标检测算法

YOLOv8 网络模型有多个版本,通过模型名称中的特定字母后缀表示其规模、复杂程度和适用场景,例如

YOLOv8n、YOLOv8s 和 YOLOv8m 等。考虑到计算资源和圆柱电池壳缺陷检测任务高精度和实时性的应用需求,选用轻量化的 YOLOv8n 作为基础模型。但是将 YOLOv8n 直接应用在圆柱电池壳缺陷检测任务时,存在

多尺度特征提取能力不足、下采样过程中丢失信息和特征融合不够充分的问题,因此对 YOLOv8n 网络模型进行改进,以进一步提升模型在圆柱电池壳缺陷检测任务中的检测精度。改进后的 YOLOv8n 网络结构如图 1 所示。

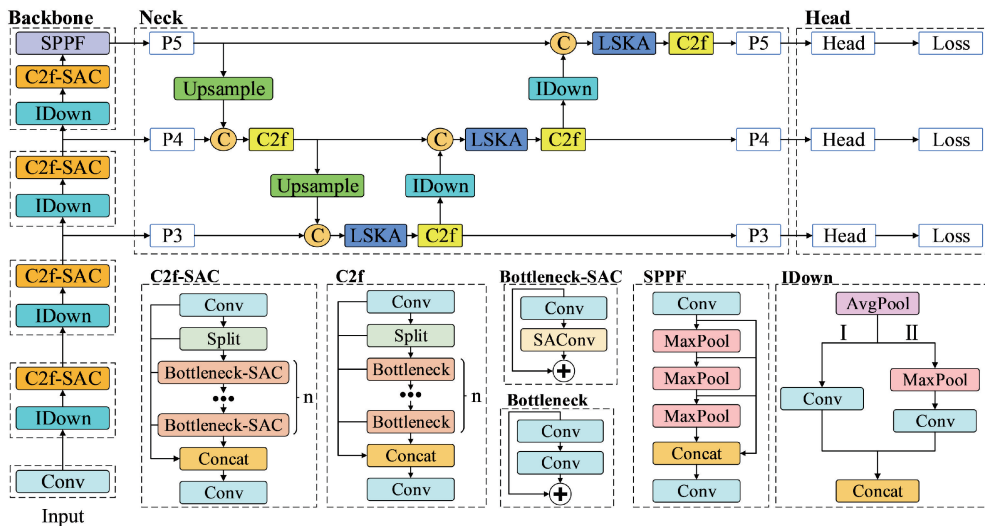


图 1 改进后的 YOLOv8n 网络结构

Fig. 1 Improved YOLOv8n network structure

1) 融合可切换空洞卷积的 C2f-SAC 模块

圆柱电池壳的缺陷尺度差异较大,在提取不同尺度的缺陷特征时,深层卷积层能够提取大尺度缺陷特征,而小尺度缺陷特征经过多层卷积和下采样后逐渐被稀释,导致特征提取不平衡^[19]。为增强模型多尺度特征提取的能力,引入可切换空洞卷积 (switchable atrous convolution, SAC) 重构 C2f 模块,捕捉不同尺度的特征,实现多尺度特征提取^[20]。重构后的 C2f-SAC 模块如图 1 所示。

可切换空洞卷积在空洞卷积的基础上引入动态选择机制,根据输入特征的局部和全局信息生成调节因子,调整标准卷积和空洞卷积的加权系数,实现两者之间的动态转换^[21]。SAC 模块架构如图 2 所示,主要包括 3 个组件,分别是两个全局上下文组件和可切换空洞卷积组件。输入特征图首先经过全局上下文组件,通过全局平均池化和 1×1 卷积汇聚特征,再将汇聚后的全局信息与原始输入逐元素累加;然后将融合了全局信息的特征图输入到可切换空洞卷积组件中,通过 Switch 开关函数计算出标准卷积和空洞卷积的权重比例,最终输出两者的加权结果,如式(1)所示。

$$y = S(x) Conv(x, w, 1) + (1 - S(x)) Conv(x, w + \Delta w, r) \quad (1)$$

其中, y 为可切换空洞卷积的输出, x 为输入的特征图; w 为卷积核的训练参数; r 为空洞卷积的空洞率,当 r 为 1 时代表普通卷积; Δw 为可训练的权重差值; $S(x)$ 为

Switch 开关函数,由 5×5 的平均池化层和 1×1 的卷积层组成;

最后,特征图再次经过全局上下文组件,进一步整合局部细节和全局信息,确保最终的输出特征图充分提取到多尺度特征。

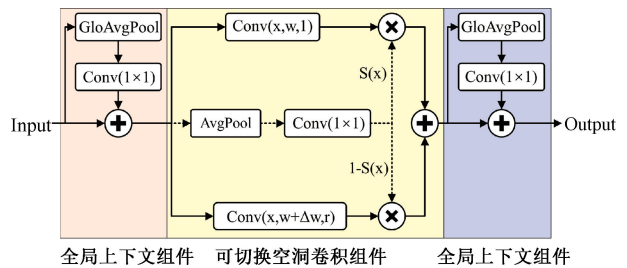


图 2 SAC 结构示意图

Fig. 2 Architecture of the SAC module

2) 改进下采样模块

在原始 YOLOv8n 网络模型中,下采样主要通过卷积核大小为 3、步长为 2、填充为 1 的卷积层实现,该卷积层包含二维卷积、批量归一化和 SiLU 激活函数。但在下采样过程中,由于卷积的步长为 2,采样密度不均匀,某些像素在生成特征图时参与程度较低,可能会导致部分特征信息被遗漏^[22]。因此,在标准卷积模块的基础上进行改进,改进后的下采样模块结构 (improved downsample, IDown) 如图 1 的 IDown 模块所示。首先,通过平均池化层对输入特征图进行下采样,将池化后的特征图在通道

维度上均等分割为两部分,分别送入两个并行的处理分支。在第一个分支中,分割后的特征图经过 3×3 的标准卷积模块捕捉空间特征,实现空间尺寸的下采样;在另一个分支中,分割后的特征图首先经过一个最大池化层提取最突出的特征,再经过 1×1 卷积模块调整通道数,进一步融合和压缩特征。两个分支的处理完成后,将两部分特征图在通道维度上重新拼接,融合全局和细节信息,有效解决了传统下采样过程中的信息丢失问题。

3) LSKA 注意力机制

圆柱电池壳的缺陷尺寸和形态各异,YOLOv8n 网络模型的 Neck 部分在融合多尺度特征时,既要理解大尺度目标的全局信息,也要捕捉小尺度目标的细节信息。因此,在 Neck 部分引入大型可分离卷积核注意力机制 (large separable kernel attention, LSKA),使模型在特征图

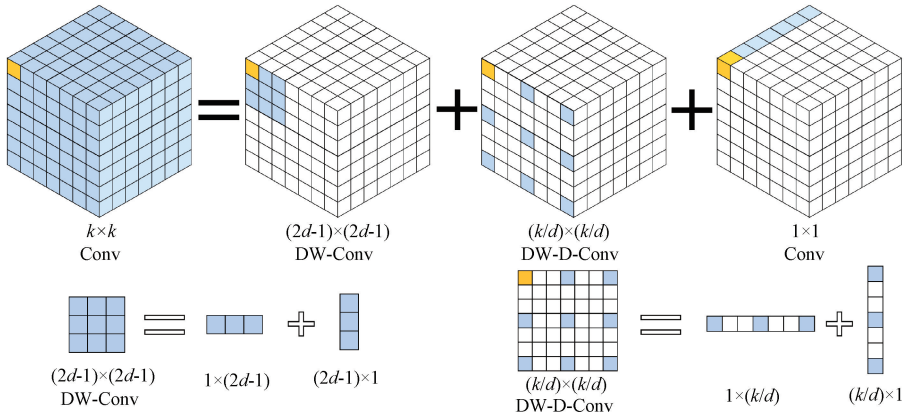


图 3 大型卷积核分解过程图

Fig. 3 Large convolution kernel decomposition process

原始输入特征图首先经过水平和垂直的一维深度卷积,提取图像不同方向上的空间特征;再经过水平和垂直的一维深度空洞卷积,进一步扩大感受野,捕捉更广泛的空间信息;最后通过逐点卷积实现通道间的信息整合,生成注意力图,与原始输入特征图逐元素相乘,加权输入特征图。具体的工作过程如式(2)~(5)所示。

$$\bar{Z}^C = \sum_{H,W} \mathbf{W}_{(2d-1) \times 1}^C \left(\sum_{H,W} \mathbf{W}_{1 \times (2d-1)}^C \mathbf{F}^C \right) \quad (2)$$

$$\mathbf{Z}^C = \sum_{H,W} \mathbf{W}_{(k/d) \times 1}^C \left(\sum_{H,W} \mathbf{W}_{1 \times (k/d)}^C \bar{Z}^C \right) \quad (3)$$

$$\mathbf{A}^C = \mathbf{W}_{1 \times 1}^C \mathbf{Z}^C \quad (4)$$

$$\bar{\mathbf{F}}^C = \mathbf{A}^C \otimes \mathbf{F}^C \quad (5)$$

其中, H 和 W 为特征图的高度与宽度; C 表示特征图

的通道数; \mathbf{F}^C 为输入特征图; \bar{Z}^C 和 \mathbf{Z}^C 为中间特征图; $\mathbf{W}_{(2d-1) \times 1}^C$ 和 $\mathbf{W}_{1 \times (2d-1)}^C$ 分别表示尺寸为 $(2d-1) \times 1$ 的水平深度卷积核和尺寸为 $1 \times (2d-1)$ 的垂直深度卷积核; $\mathbf{W}_{(k/d) \times 1}^C$ 和 $\mathbf{W}_{1 \times (k/d)}^C$ 分别表示尺寸为 $(k/d) \times 1$ 的水平深度空洞卷积核和尺寸为 $1 \times (k/d)$ 的垂直深度空洞卷积核;

传递和特征融合过程中聚焦关键特征区域,更好地保留和利用重要信息^[23]。

LSKA 注意力机制通过大型可分离卷积核生成注意力图,原始特征图中的每个元素根据注意力图进行加权,强化重要特征,提升模型对重点信息的关注能力。大型可分离卷积核的分解过程如图 3 所示,将 $k \times k$ 的大型卷积核分解为 $(2d-1) \times (2d-1)$ 的深度卷积、 $(k/d) \times (k/d)$ 的深度空洞卷积和 1×1 的逐点卷积。其中, k 为原始大型卷积核的大小, d 为深度空洞卷积的空洞率。二维的深度卷积核和深度空洞卷积核再次分解为水平和垂直方向的一维卷积核。将大型卷积核分解有效降低了计算复杂度和内存占用,同时保持原有大型卷积核的较大感受野,捕捉丰富的特征信息。

\mathbf{A}^C 代表注意力图; $\bar{\mathbf{F}}^C$ 代表加权后的输出特征图。

2 实验与结果分析

2.1 数据集构建

在工业生产现场搭建圆柱电池壳多维缺陷检测系统后采集原始图像,电池壳型号为 18 650,电池壳直径为 18 mm,高度为 65 mm。根据圆柱电池壳不同部位的特性布置工业相机、光源和传感器,如图 4 所示,面阵检测部分使用 3 个面阵相机采集圆柱电池壳的底部、口部和内部图像;线扫检测部分使用线扫相机连续扫描滚动带上的圆柱电池壳,采集完整的侧面图像。

采集到原始图像后汇总并统计缺陷类别,各部位典型缺陷如图 5 所示,共有水渍、划痕、异物、豁口、脏污、拉丝、黄斑和夹缝 8 类缺陷类型。

由于原始图片分辨率较大,直接将其输入至模型进行训练会增加计算资源和内存需求,所以在训练前对原

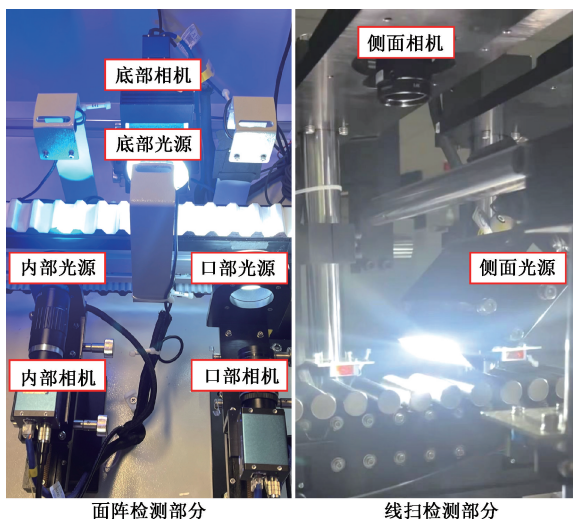


图 4 图像采集装置

Fig. 4 Image acquisition device

始图片进行数据清洗、目标提取、裁剪等预处理操作, 总共得到 6 960 张圆柱电池壳缺陷图片。使用 Labelimg 软件对圆柱电池壳缺陷图片进行手工标注, 将缺陷的类别、位置和大小信息存储在标签文件中。将图片和标签文件按照 8 : 1 : 1 的比例划分为训练集、验证集和测试集。针对数据分布不均衡的问题, 对训练集的数据进行离线数据增强, 随机采用翻转、亮度调整、高斯模糊和仿射变换等操作扩充训练数据。最终得到 8 328 张训练图像, 原始训练集和增强后训练集中各缺陷数量如表 1 所示。

表 1 数据增强前后各缺陷数量

Table 1 Defect counts before and after data augmentation

缺陷类别	原始数据/个	增强后数据/个
水渍	1 810	1 810
划痕	1 434	1 434
异物	272	692
豁口	461	1 273
脏污	2 102	2 102
拉丝	536	1 594
黄斑	343	1 011
夹缝	477	1 397
合计	7 435	11 313

2.2 实验环境

本研究中, 用于模型训练和测试的服务器硬件配置和软件环境如表 2 所示。在模型训练过程中, 输入图片尺寸为 640×640, 训练轮数 (epochs) 设置为 200, 批次数 (batch-size) 设置为 16, 初始学习率设置为 0.01, 学习率动量设置为 0.937, 权重优化器选择随机梯度下降 (stochastic gradient descent, SGD), 权重衰减系数设置为 0.0005。

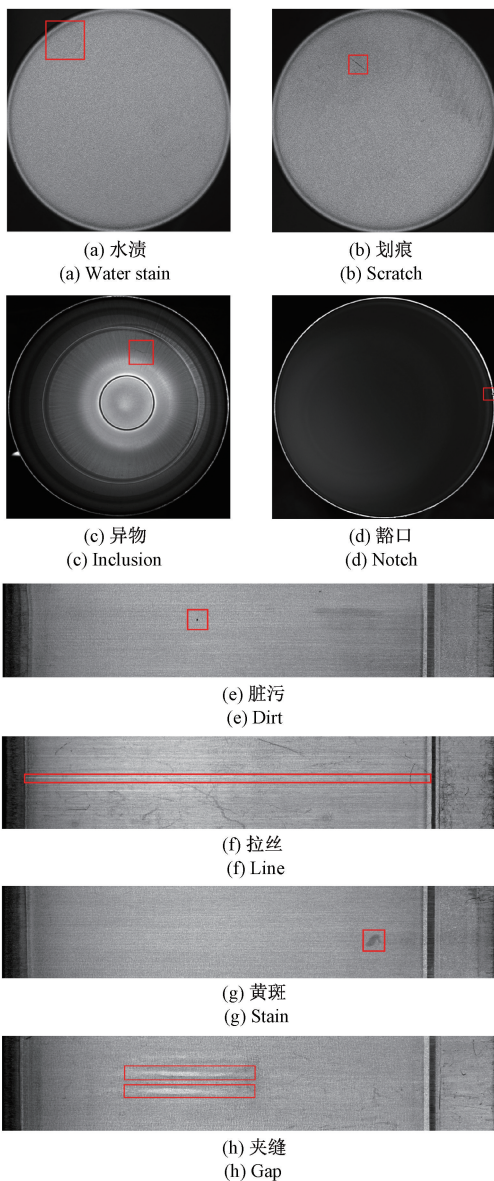


图 5 各部位典型缺陷示意图

Fig. 5 Typical defects in various parts

表 2 硬件配置与软件环境

Table 2 Hardware and software configuration

硬件配置和软件环境	配置名和版本
操作系统	Ubuntu 20.04
CPU	Intel Core i7-12700K (32 GB)
GPU	NVIDIA GeForce RTX3080 (10 GB)
深度学习框架	PyTorch 1.7.1
运算平台	CUDA 11.0
集成开发环境	Pycharm 2022.2.2
编译器	python 3.8

2.3 评价指标

为更准确地评估算法模型在圆柱电池壳缺陷检测任

务中的检测效果,采用精确率 (precision, P)、召回率 (recall, R)、平均精度 (average precision, AP)、平均检测精度 (mean average precision, mAP)、模型参数量 (params)、模型大小 (weight size)、模型消耗算力 (floating point operations, FLOPs) 和每秒传输帧数 (frames per second, FPS) 作为评价指标。其中, P 、 R 、 AP 和 mAP 的具体计算公式如式 (6) ~ (9) 所示。

$$P = \frac{TP}{TP + FP} \quad (6)$$

$$R = \frac{TP}{TP + FN} \quad (7)$$

$$AP = \int_0^1 P(R) dR \quad (8)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (9)$$

其中, TP 为被正确检测的缺陷数, FP 为被错误检测的缺陷数, FN 为未被检测到的缺陷数; N 为缺陷种类数目, AP_i 表示第 i 类缺陷的 AP 值。

2.4 实验结果与分析

1) 改进点对比实验

为了验证提出的每个改进点对模型性能的影响,使用自制的圆柱电池壳缺陷数据集进行实验并分析。

(1) C2f-SAC 模块

将 YOLOv8n 网络模型中的 C2f 模块替换为带有可切换空洞卷积的 C2f-SAC 模块,以增强模型提取不同尺度特征的能力。为确定最佳的替换位置,设计以下实验研究 C2f-SAC 不同替换位置对模型的改进效果:实验 1 基准模型;实验 2 替换 Backbone 部分的 C2f 模块;实验 3 替换 Neck 部分的 C2f 模块;实验 4. 同时替换 Backbone 部分和 Neck 部分的 C2f 模块。实验结果如表 3 所示。

表 3 C2f-SAC 模块实验结果

Table 3 C2f-SAC module experimental results

序号	$P/\%$	$R/\%$	$mAP/\%$	参数量/M	FPS/(帧·s ⁻¹)
1	70.1	70.3	73.1	3.01	232
2	68.1	73.4	75	3.45	196
3	70.1	72.4	73.3	3.44	200
4	72.0	70.7	74.4	3.74	182

分析上表可知,基于可切换空洞卷积重构 C2f 模块后,模型的检测精度相比于基准模型均有所提升。其中,实验 2 的 mAP 相较于基准实验提升了 1.9%,证明替换 Backbone 部分的 C2f 模块可以在不显著增加参数量的情况下提升模型的平均检测精度。实验 3 的 mAP 提升了 0.2%,提升幅度小,模型的复杂度增加。实验 4 同时替换了 Backbone 和 Neck 部分的 C2f 模块,虽然 mAP 同样实现了提升,但提升幅度低于实验 2。这说明 Backbone 部分已经显著提升了特征提取的质量,在此基础上替换

Neck 部分的 C2f 模块可能会引入冗余特征,导致特征融合的效果有限。并且将 C2f 模块全部替换后导致整体模型计算复杂度增加,直接表现为实验 4 的参数量增加和 FPS 降低。

对比实验结果,选择替换 Backbone 部分的 C2f 模块,在不显著增加模型复杂度的情况下实现检测精度提升,同时仍然保持相对高效的实时处理速度。

(2) 改进下采样模块

为验证改进后的下采样模块对模型性能的提升效果,确定最佳的改进措施,设计以下实验研究改进效果:实验 1 基准模型;实验 2 改进 Backbone 部分的下采样模块;实验 3 改进 Neck 部分的下采样模块;实验 4 同时改进 Backbone 部分和 Neck 部分的下采样模块。实验结果如表 4 所示。

表 4 改进下采样模块实验结果

Table 4 IDown module experimental results

序号	$P/\%$	$R/\%$	$mAP/\%$	参数量/M	FPS/(帧·s ⁻¹)
1	70.1	70.3	73.1	3.01	232
2	71.2	71.4	73.6	2.73	192
3	70.9	71.3	74	2.88	213
4	71.1	73.5	74.5	2.60	217

分析上表可知,改进 Backbone 和 Neck 部分的下采样模块均能有效提升模型的平均检测精度。其中,实验 2 表明在改进 Backbone 部分的下采样模块后, P 相较于基准网络提升了 1.1%, R 提升了 1.1%, mAP 提升了 0.5%,证明改进的下采样模块能更有效地捕捉和保留输入图像的关键信息,从而提升整体模型检测精度。实验 3 表明改进 Neck 部分的下采样模块后, P 相较于基准网络提升了 0.8%, R 提升了 1%, mAP 提升了 0.9%,证明改进的下采样模块在特征融合的过程中有效保证了信息的丰富性和完整性。并且根据实验 4 的结果可知,同时改进 Backbone 和 Neck 部分的下采样模块,模型各性能指标提升幅度最大,证明该改进措施最为有效,尽管检测速度有所下降,但仍保持在较高水平。因此,选择同时改进 Backbone 和 Neck 部分的下采样模块,模型在保持高性能的同时参数量显著下降。

(3) LSKA 注意力机制

LSKA 注意力机制通过大型可分离卷积核生成注意力地图,对输入特征图进行加权,从而增强模型对重要缺陷信息的关注程度,其中卷积核的大小直接影响模型性能和计算复杂度。因此,为验证在 YOLOv8n 网络模型的 Neck 部分引入 LSKA 注意力机制的改进效果,并确定最佳的卷积核大小,设计以下实验研究改进效果:实验 1 基准模型;实验 2 卷积核大小设置为 7;实验 3 卷积核大小设置为 11;实验 4 卷积核大小设置为 23;实验 5 卷积核大小设置为 35。实验结果如表 5 所示。

表 5 LSKA 注意力机制实验结果

Table 5 LSKA attention mechanism experimental results

序号	k_size	P/%	R/%	mAP/%	参数量/M	FPS/(帧·s ⁻¹)
1		70.1	70.3	73.1	3.01	232
2	7	74.1	68.4	74	3.11	187
3	11	71.2	72.2	74.6	3.11	187
4	23	72.0	70.7	74.8	3.11	182
5	35	68.8	70.4	72.5	3.12	171

分析上表可知,在 Neck 部分引入 LSKA 注意力机制可以提升模型检测精度。其中,实验 2~4 表明引入 LSKA 注意力机制后,随着卷积核大小的提升,mAP 随之提升;但是实验 5 表明当卷积核大小提升到 35 时,整体

表 6 消融实验结果

Table 6 Ablation experiment results

序号	C2f-SAC	IDown	LSKA	P/%	R/%	mAP/%	参数量/M	计算量/(FLOPs/G)	FPS/(帧·s ⁻¹)	模型大小/MB
1				70.1	70.3	73.1	3.01	8.1	232	6.0
2	√			68.1	73.4	75	3.45	7.4	196	6.6
3		√		71.1	73.5	74.5	2.60	7.3	217	5.2
4			√	72.0	70.7	74.8	3.11	8.9	182	6.5
5	√	√		74.4	74.1	76.4	2.89	6.7	179	5.8
6	√		√	75.3	72.3	76.0	3.40	8.2	164	6.8
7		√	√	71.8	72.2	75.1	2.69	7.4	176	5.4
8	√	√	√	75.8	71.5	77.4	2.98	6.7	177	6.0

从实验 2 结果可以看出,引入带有可切换空洞卷积的 C2f-SAC 后,模型的 mAP 值提升了 1.9%,表明 C2f-SAC 有效增强了模型的多尺度特征提取能力。具体而言,在圆柱电池壳多维缺陷检测任务中,缺陷种类多且尺寸与形态差异较大,要求模型具备多尺度特征信息提取能力,C2f-SAC 模块通过动态切换普通卷积和空洞卷积,实现了更有效的多尺度特征提取。单独改进下采样模块时,mAP 提升了 1.4%,并且参数量、计算量和模型大小均下降,说明该模块在实际检测任务中,通过通道切分、组合使用卷积与池化的方式优化了计算资源的使用,在减少模型计算量和参数量的同时保证良好的特征提取效果。添加 LSKA 注意力机制后,P 提升了 1.9%,R 提升了 0.4%,mAP 提升了 1.7%,表明模型更关注特征图中的显著特征,抑制不相关的背景信息,增强了模型的整体检测性能。

同时引入 C2f-SAC 模块和改进下采样模块时,P 提升了 4.3%,R 提升了 3.8%,mAP 提升的幅度达到了 3.3%,说明两者结合增强了模型捕捉图像细节和关注全局信息的能力。组合引入 C2f-SAC 模块与 LSKA 注意力机制时,P 提升了 5.2%,R 提升了 2%,mAP 提升了 2.9%,说明 C2f-SAC 提取到的多尺度特征图通过 LSKA 注意力机制增强了关键信息,从而整体提升了模型的性能;将改进的下采样模块与 LSKA 注意力机制组合后,有一定的性能提升,但提升幅度较小,这可能是由于特征图

性能下降,并且计算复杂度提升,影响模型的检测速度。虽然较大的卷积核理论上可以捕捉更多的特征信息,但必须考虑到卷积核大小与模型性能之间的平衡关系。因此,确定卷积核大小为 23,此时模型表现最佳,检测速度下降较少,仍能保持较好的实时性。

2) 消融实验

为了验证各改进点对模型整体性能的影响,设置 8 组消融实验,逐步引入带有可切换空洞卷积的 C2f-SAC 模块、改进下采样模块和添加 LSKA 注意力机制,分析每个改进点及其互相组合后对模型性能的影响。实验结果如表 6 所示。

经过下采样模块后已经提取到部分关键特征,引入 LSKA 注意力机制后导致功能上存在冗余,无法提供额外的信息增益。

同时引入 C2f-SAC 模块、改进下采样模块和添加 LSKA 注意力机制后的网络模型,与基准模型相比,P 提升了 5.7%,R 提升了 1.2%,mAP 提升了 4.3%,模型性能指标达到最高,参数量、计算量和模型大小均维持在轻量化水平,FPS 可以满足实时检测的需求,证明了改进方法的有效性。

3) 模型对比实验

为了进一步验证改进后模型的性能,选取 YOLOv5、YOLOv6、YOLOv9、YOLOv10 和 RT-DETR 等近年来性能较好的主流网络模型,在相同的数据集和实验环境下进行对比实验。实验结果如表 7 所示。

通过实验结果可知,改进后模型在自制的圆柱电池壳缺陷数据集上的检测精度、参数量、计算量和模型大小等多个性能指标均优于其他主流网络模型。分析不同模型的实验结果可知,YOLOv5n 和 YOLOv6n 的检测速度较快,mAP 分别达到 72.9% 和 70.7%。YOLOv5s 和 YOLOv6s 的网络结构更深、参数更多,mAP 分别达到 73.4% 和 72.5%,但模型的检测速度有所下降。YOLOv9t 的 mAP 为 71.4%,参数量为 2.6 M,计算量为 10.7 G,但检测速度仅达到 110 FPS,较其他检测模型略低。YOLOv10 n 的参数量仅有 2.6 M,模型大小仅有 5.5 MB,

表 7 模型对比实验结果


Table 7 Models comparison experiment results

模型	P/%	R/%	mAP@ 0.5/%	参数量/M	计算量/G	FPS/(帧·s ⁻¹)	模型大小/MB
YOLOv5n	69.9	70.0	72.9	3.01	7.1	225	5.1
YOLOv5s	74.7	68.4	73.4	9.11	23.8	130	17.7
YOLOv6n	71.0	66.5	70.7	4.2	11.8	222	8.3
YOLOv6s	68.0	70.3	72.5	16.3	44.0	116	31.3
YOLOv8n	70.1	70.3	73.1	3.01	8.1	232	6.0
YOLOv9t	71.3	66.9	71.4	2.6	10.7	110	5.9
YOLOv10n	64.0	61.8	66.4	2.6	8.2	222	5.5
YOLOv10m	68.7	67.8	70.9	16.5	63.5	60	31.9
RT-DETR	64.1	65.2	67.3	32.0	103.5	98	66.2
Our model	75.8	71.5	77.4	2.98	6.7	177	6.0


但 mAP 只有 66.4%，无法实现检测精度与检测速度的平衡。YOLOv10 m 的检测精度为 70.9%，但检测速度仅有 60 FPS。RT-DETR 结合了 Transformer 和 DETR 两种目标检测架构，但由于其参数量和计算量较大，在检测圆柱电池壳多维缺陷时 mAP 仅为 67.3%，难以在实时性要求高的圆柱电池壳缺陷检测场景中部署和应用。YOLOv8n 的 mAP 为 73.1%，参数量小，检测速度达到 232 FPS。改

进后模型与 YOLOv8n 相比， mAP 提升了 4.3%，参数量降低到 2.98 M，模型大小仅为 6 MB，虽然检测速度略有降低，但仍保持在较高水平，能够兼顾检测精度和实时检测性能，满足实际工业应用需求。

为了更直观地展示改进后模型的实际检测性能，对比 YOLOv8n 模型和改进后的 YOLOv8n 模型在测试集上的检测效果，检测效果对比如图 6 所示。从图中可以看



(a) YOLOv8n检测效果
(a) YOLOv8n detection results



(b) 改进YOLOv8n检测效果
(b) Improved YOLOv8n detection results

图 6 检测效果对比

Fig. 6 Comparison of detection results

出,改进后的 YOLOv8n 算法对每类缺陷的检测效果均有提升,检测置信度更高。并且对于位置相邻的黄斑和夹缝缺陷的检测效果更好,减少了漏检的情况。检测效果对比表明改进后的 YOLOv8n 模型在圆柱电池壳多维缺陷检测任务上表现更优异。

3 结 论

本文针对圆柱电池壳多维缺陷检测任务提出了基于改进 YOLOv8n 模型的缺陷检测算法,旨在解决因圆柱电池壳缺陷尺度差异大而导致的检测效果不佳的问题。针对圆柱电池壳多尺度缺陷特征提取困难的问题,基于可切换空洞卷积重新设计 C2f 模块,增强模型提取多尺度特征的能力;针对原有下采样模块引起的信息丢失问题,结合平均池化和最大池化策略做出改进,通过并行分支处理特征图的全局和局部信息,在实现下采样的同时保留关键信息;为解决多层次特征融合时关键特征难以捕捉的问题,在 Neck 部分引入 LSKA 注意力机制增强多尺度特征融合能力,提升模型在处理不同尺度和形态缺陷时的检测精度。实验结果表明,提出的算法模型在自制的圆柱电池壳缺陷数据集上的各项指标均高于基准模型,其中平均检测精度达到 77.4%,模型大小为 6 MB, FPS 达到 177,适合应用于圆柱电池壳多维缺陷检测任务中。未来的研究工作将进一步优化模型结构,此外,考虑引入对抗生成网络生成高质量图像,进一步扩充数据集并提升模型的泛化能力。

参考文献

- [1] CHEN Y, KANG Y, ZHAO Y, et al. A review of lithium-ion battery safety concerns: The issues, strategies, and testing standards [J]. *Journal of Energy Chemistry*, 2021, 59: 83-99.
- [2] MALLICK S, GAYEN D. Thermal behaviour and thermal runaway propagation in lithium-ion battery systems - A critical review [J]. *Journal of Energy Storage*, 2023, 62: 106894.
- [3] MADDIPATLA S, KONG L X, PECHT M. Safety analysis of lithium-ion cylindrical batteries using design and process failure mode and effect analysis [J]. *Batteries*, 2024, 10(3): 76.
- [4] QI L F, WANG Y, KONG L J, et al. Manufacturing processes and recycling technology of automotive lithium-ion battery: A review [J]. *Journal of Energy Storage*, 2023, 67: 107533.
- [5] LAI X, JIN CH Y, YI W, et al. Mechanism, modeling, detection, and prevention of the internal short circuit in lithium-ion batteries; Recent advances and perspectives [J]. *Energy Storage Materials*, 2021, 35(3): 470-499.
- [6] 郭绍陶,苑玮琦. 圆柱锂电池端面凹坑缺陷检测方法研究 [J]. *仪器仪表学报*, 2022, 43(3): 230-239.
GUO SH T, YUAN W Q. A research on the detection method of pit on the cylindrical lithium battery end surface [J]. *Chinese Journal of Scientific Instrument*, 2022, 43(3): 230-239.
- [7] CHEN Y G, SHU Y F, LI X M, et al. Research on detection algorithm of lithium battery surface defects based on embedded machine vision [J]. *Journal of Intelligent & Fuzzy Systems*, 2021, 41(3): 4327-4335.
- [8] 邵天成,吴静静. 基于多视图融合的微弱缺陷检测增强方法 [J]. *计算机测量与控制*, 2024, 32(8): 86-92.
SHAO T CH, WU J J. Enhanced method for faint defects detection based on multi-view fusion [J]. *Computer Measurement & Control*, 2024, 32(8): 86-92.
- [9] 张玥,陈锡伟,陈梦丹,等. 基于对比学习生成对抗网络的无监督工业品表面异常检测 [J]. *电子测量与仪器学报*, 2023, 37(10): 193-201.
ZHANG Y, CHEN X W, CHEN M D, et al. Unsupervised surface anomaly detection of industrial products based on contrastive learning generative adversarial network [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(10): 193-201.
- [10] HU H B, ZHU ZH H. Sim-YOLOv5s: A method for detecting defects on the end face of lithium battery steel shells [J]. *Advanced Engineering Informatics*, 2023, 55: 101824.
- [11] DANDAGE H K, LIN K M, LIN H H, et al. Surface defect detection of cylindrical lithium-ion battery by multiscale image augmentation and classification [J]. *International Journal of Modern Physics B*, 2021, 35(14n16): 2140011.
- [12] ZHANG Y, SHU SH B, LANG X L, et al. A real-time method for detecting bottom defects of lithium batteries based on an improved YOLOv5 model [J]. *Measurement Science and Technology*, 2023, 34(12): 125149.
- [13] 封学勇. 基于深度学习的柱形锂电池钢壳表面缺陷识别与分类方法 [D]. 合肥: 合肥工业大学, 2020.
FENG X Y. Recognition and classification of surface defects of cylindrical lithium battery steel shell based on deep learning [D]. Hefei: Hefei University of Technology, 2020.
- [14] 陈昭霖. 基于机器视觉的金属表面缺陷检测技术研究 [D]. 哈尔滨: 哈尔滨工业大学, 2022.
CHEN ZH F. Research on metal surface defect detection technology based on machine vision [D]. Harbin: Harbin

- Institute of Technology, 2022.
- [15] REN SH Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6): 1137-1149.
- [16] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector [C]. Computer Vision - ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11 - 14, 2016, Proceedings, Part I 14. Springer International Publishing, 2016; 21-37.
- [17] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781-10790.
- [18] 方涛涛, 王池社, 王洁, 等. 基于 YOLOv8n 的探地雷达图像管线定位方法 [J]. 国外电子测量技术, 2023, 42(11): 170-177.
FANG T T, WANG CH SH, WANG J, et al. Ground penetrating radar image pipeline location based on YOLOv8n [J]. Foreign Electronic Measurement Technology, 2023, 42(11): 170-177.
- [19] 童小钟, 魏俊宇, 苏绍璟, 等. 融合注意力和多尺度特征的典型水面小目标检测 [J]. 仪器仪表学报, 2023, 44(1): 212-222.
TONG X ZH, WEI J Y, SU SH J, et al. Typical small target detection on water surfaces fusing attention and multi-scale features [J]. Chinese Journal of Scientific Instrument, 2023, 44(1): 212-222.
- [20] HE Y ZH, YU H G ZHANG R, et al. From macro to micro: rethinking multi-scale pedestrian detection [J]. Multimedia Systems, 2023, 29(3): 1417-1429.
- [21] QIAO S Y, CHEN L C, YUILLE A. Detectors: Detecting objects with recursive feature pyramid and switchable atrous convolution [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 10213-10224.
- [22] 赵霖, 王素珍, 邵明伟, 等. 基于改进 YOLOv5 的输电线路鸟巢缺陷检测方法 [J]. 电子测量技术, 2023, 46(3): 157-165.
ZHAO L, WANG S ZH, SHAO M W, et al. Improved YOLOv5-based bird's nest defect detection method for transmission lines [J]. Electronic Measurement Technology, 2023, 46(3): 157-165.
- [23] LAU K W, PO L M, REHMAN Y A U. Large separable kernel attention: Rethinking the large kernel attention design in CNN [J]. Expert Systems with Applications, 2024, 236: 121352.

作者简介



吴永泽, 2022 年于常州大学获得学士学位, 现为江南大学硕士研究生, 主要研究方向为深度学习和目标检测。

E-mail: wuyongze5525@126.com

Wu Yongze received his B. Sc. degree from Changzhou University in 2022. Now his is a M. Sc. candidate of Jiangnan University. His main research interests include deep learning and object detection.



俞建峰 (通信作者), 2004 年于上海交通大学获得博士学位。现为江南大学机械工程学院教授, 主要研究方向为机器人技术、深度学习算法、嵌入式控制系统等。

E-mail: robotmcu@126.com

Yu Jianfeng (Corresponding author) received his Ph. D. degree from Shanghai Jiao Tong University in 2004. Now he is a professor in the School of Mechanical Engineering at Jiangnan University. His main research interests include robot technology, deep learning algorithm, and embedded control systems, etc.