



## 基于FDI-YOLOv10n的锂离子电池表面缺陷多通道图像融合检测算法研究

王阳阳<sup>1,2</sup>, 王卫军<sup>1,2</sup>, 王建<sup>2</sup>, 黄祖成<sup>2</sup>, 陈金源<sup>2</sup>, 江旭耀<sup>2</sup>

(<sup>1</sup>西安建筑科技大学机电工程学院, 陕西 西安 710055; <sup>2</sup>广州中国科学院先进技术研究所, 广东 广州 511458)

**摘要:** 针对镍片连接片微小缺陷(划痕、凹坑等)在二维灰度和三维深度信息中均呈现对比度低、深度变化弱的检测难点, 本研究提出一种基于FDI-YOLOv10n模型的多通道图像融合检测框架。首先通过通道级图像融合方法, 将灰度图像2D纹理特征与深度图像3D空间特征在通道维度深度融合, 增强模型对缺陷的表征能力。其次, 为进一步提升特征提取效率, 设计FasterCGLU-MANet混合聚合模块, 结合改进型FasterBlock-CGLU单元与MANet架构, 提升特征语义表达深度并加速推理; 同时引入鲁棒特征下采样(RFD)机制, 通过浅层与深层分级处理策略, 有效缓解了图像冗余信息干扰问题; 最后, 设计Inner-MPDIoU复合损失函数, 结合内部区域重叠约束与边界对齐优化, 显著提升了边界框回归稳定性。实验结果表明, 所提模型在自制数据集上达到96.1%的mAP@0.5及333.3帧/s的检测速度, 实现锂离子电池工业级高精度与实时性的检测需求。

**关键词:** FDI-YOLOv10n; 多通道图像融合; 混合聚合模块; 鲁棒特征下采样

doi: 10.19799/j.cnki.2095-4239.2025.0905

中图分类号: TP 274

文献标志码: A

文章编号: 2095-4239 (2026) 04-1396-13

## Research on a multi-channel image fusion detection algorithm for surface defects of lithium-ion batteries based on FDI-YOLOv10n

WANG Yangyang<sup>1,2</sup>, WANG Weijun<sup>1,2</sup>, WANG Jian<sup>2</sup>, HUANG Zucheng<sup>2</sup>, CHEN Jinyuan<sup>2</sup>,  
JIANG Xuyao<sup>2</sup>

(<sup>1</sup>School of Mechanical and Electrical Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, Shaanxi, China; <sup>2</sup>Institute of Advanced Technology, Chinese Academy of Sciences, Guangzhou 511458, Guangdong, China)

**Abstract:** Micro-defects on nickel sheet connection pieces, such as scratches and pits, are challenging to detect due to their low contrast and weak depth variations in both two-dimensional grayscale images and three-dimensional depth data. To address this challenge, this study proposes a multi-channel image fusion detection framework based on the FDI-YOLOv10n model. First, a channel-level image fusion strategy is employed to deeply integrate two-dimensional texture information from grayscale images with three-dimensional spatial

收稿日期: 2025-10-14; 修改稿日期: 2025-11-05。

第一作者: 王阳阳(2001—), 女, 硕士研究生, 主要研究方向为智能检测技术应用开发, E-mail: 18091656937@163.com; 通信作者: 王卫军, 正高级工程师, 主要研究方向为自动化技术、机械工业、计算机软件及计算机应用等, E-mail: wj.wang@giat.ac.cn。

引用本文: 王阳阳, 王卫军, 王建, 等. 基于FDI-YOLOv10n的锂离子电池表面缺陷多通道图像融合检测算法研究[J]. 储能科学与技术, 2026, 15(4): 1396-1408.

**Citation:** WANG Yangyang, WANG Weijun, WANG Jian, et al. Research on a multi-channel image fusion detection algorithm for surface defects of lithium-ion batteries based on FDI-YOLOv10n[J]. Energy Storage Science and Technology, 2026, 15(4): 1396-1408.

features from depth images at the channel level, thereby enhancing the ability of the model to extract discriminative defect features. Second, to further improve feature extraction efficiency, a FasterCGLU-MANet hybrid aggregation module is developed by combining an improved FasterBlock-CGLU unit with the MANet architecture, enabling richer semantic feature representation while accelerating inference. Additionally, a robust feature downsampling mechanism is introduced to mitigate interference from redundant image information through a hierarchical processing strategy spanning shallow and deep network layers. Finally, an Inner-MPDIoU composite loss function is designed by integrating internal-region overlap constraints with boundary alignment optimization, thereby substantially improving the stability of bounding-box regression. Experimental results demonstrate that the proposed model achieves a mAP@0.5 of 96.1% and a detection speed of 333.3 fps on a self-constructed dataset, satisfying industrial requirements for high-precision and real-time defect detection in lithium-ion battery manufacturing.

**Keywords:** FDI-YOLOv10n; multi-channel image fusion; hybrid aggregation module; robust feature downsampling

在全球能源转型加速推进的背景下, 锂离子电池作为新能源汽车、储能设备等领域的核心动力来源, 其安全性与可靠性备受关注<sup>[1]</sup>。方形锂电池模组电池包中的镍片连接片作为极柱与汇流排的关键连接件, 是保障电池系统电气导通的核心组件, 其表面质量直接决定模组连接的可靠性及整体性能<sup>[2]</sup>。镍片连接片表面缺陷的位置、类型、尺寸及数量, 对极柱与汇流排的接触稳定性会产生梯度化影响。严重时, 可能引发使用中电池的爆炸, 带来严重安全隐患, 甚至造成短路、热失控等安全事故<sup>[3-4]</sup>。因此, 实现对锂离子电池模组镍片连接片表面缺陷的高精度检测, 对于保障电池系统安全性、提升模组使用寿命及推动智能制造升级具有重要的现实意义。

目前, 锂电池的表面检测以人工检测、视觉分析和基于深度学习的检测方法为主。人为的检测方法在很大程度上降低了检测的准确性<sup>[5]</sup>, 深度学习通过输入的大量数据对搭建的神经网络进行训练, 对数据特征自动进行学习和识别, 目前已经成为表面缺陷检测技术的热点<sup>[6]</sup>。此类算法主要包含一阶段与两阶段两大类方法, 其中一阶段检测算法的代表为SSD<sup>[7]</sup>、YOLO<sup>[8-10]</sup>系列算法, 两阶段检测算法的代表为Faster R-CNN<sup>[11]</sup>。也有学者构建了基于Transformer的目标检测模型DETR<sup>[12]</sup>、Co-DETR<sup>[13]</sup>等, 实现完全端到端的架构。例如, 邢远秀等<sup>[14]</sup>针对锂电池端面缺陷尺度差异导致的小目标

检测难题, 提出BDD-DETR检测算法, 通过自适应特征感知模块与多路径融合机制, 实现网络深层次特征的多维度整合, 有效强化关键特征表征并抑制冗余信息。朱永平等<sup>[15]</sup>提出一种优化YOLOv5s的软包锂离子电池表面缺陷检测方法, 通过增强边缘细节捕捉及微小缺陷特征提取能力, 使模型mAP提升至89.1%(提升4.8%), 检测速度达40.0帧/s, 满足工业实时检测需求。何涛等<sup>[16]</sup>针对软包锂离子电池表面微小凹坑检测难题(缺陷区域狭小、对比度薄弱及镜面反射干扰), 设计了一种融合多尺度图像增强技术与优化DeepLabV3架构的检测方案, 改进网络在自建数据集上实现85.98%的平均交并比与98.33%的缺陷识别精度。孙浩然等<sup>[17]</sup>提出一种结合拓扑滤波与优化Canny算子的电极缺陷检测方法, 能够有效保留图像边缘细节, 并且可以精确定位缺陷的实际边界。实验显示, 这一算法在检测精度和抗噪性能方面有明显提升。Dai等<sup>[18]</sup>设计了一种三支特征增强金字塔网络, 该结构在上采样过程中通过嵌入特征对齐组件, 使上采样特征的空间信息更好地对齐, 从而提升多尺度特征融合时的匹配准确性。

多通道图像融合技术通过整合不同来源或模态的图像信息, 弥补单一通道数据在特征表达上的局限性, 已成为计算机视觉领域提升复杂场景下信息利用率的核心手段。根据信息整合的不同阶段, 融合策略通常被划分为数据层融合、特征层融合和决

策层融合3个层次。Li等<sup>[19]</sup>提出一种无需严格配准的红外-可见光融合框架，首先在数据层利用可变形卷积实现弱对齐下的像素级重组，再通过对抗损失约束融合图像的纹理与热辐射一致性，显著降低对先验几何的依赖。Wang等<sup>[20]</sup>针对RGB-D显著目标检测，设计轻量级数据层重组模块，将深度图与RGB图像在输入端拼接为多通道张量，并引入深度置信度掩膜抑制无效深度区域，在保持实时性的同时提升了边缘定位精度。

Chen等<sup>[21]</sup>面向LiDAR-相机3D目标检测，提出对象级特征融合模块：先由PointNet++和ResNet独立提取点云与图像特征，再利用交叉注意力实现体素-像素双向对齐，最终在特征层生成统一表征送入检测头，相较早期拼接策略mAP提升4.7%。Lyu等人<sup>[22]</sup>在红外-可见光场景引入语义信息引导的SigFusion网络，利用预训练分割网络生成高层语义掩膜，在特征层通过门控机制动态加权红外与可见光特征，显著增强了融合图像对小目标与遮挡区域的鲁棒性。谢雨欣等人<sup>[23]</sup>在YOLOv8网络模型的基础上，利用改进的对称主干网络结构提取RGB和深度特征的有效特征层，引入RGB-D数据特征融合模块，实现了RGB特征和深度特性在空间与通道位置的融合。李明等<sup>[24]</sup>提出一种基于RGB-D图像融合的分步式检测方法，通过子阶段路径聚合(SPA)模块实现RGB-D特征级融合，并采用基于像素级融合的GR-ConvNet结合背景填充预处理算法降低遮挡干扰，使抓取检测精度提升23%。虽然图像融合技术在各层面都取得了一定进展，但该技术仍存在挑战，如数据层对数据对齐要求高、特征层网络复杂度过高、决策层难以充分利用底层信息且处理结果不一致能力弱等。

在锂离子电池模组中，镍片连接片的缺陷检测任务较为复杂。缺陷通常同时包含灰度对比度差和深度信息等多种特征，二者经常耦合存在。在这种情况下，仅依靠单一模态的特征或采用传统特征拼接方法难以获得既具备纹理细节又具备空间深度感的高判别性特征。针对锂电池镍片连接片表面缺陷检测任务，本研究提出一种FDI-YOLOv10n模型，主要工作如下。

(1) 通过自制的缺陷检测平台采集锂离子电池模组镍片连接片表面缺陷图像，构建并标注了包含凹陷、黑点、划痕、颗粒和焊锡5类缺陷的灰度及对应

深度的锂离子电池模组镍片连接片表面缺陷数据集。

(2) 提出一种通道级图像融合方法，实现灰度图像2D纹理特征与深度图像3D空间特征在通道维度的深度语义耦合，使融合特征张量集成灰度强度、边缘梯度及深度距离等多特征信息，提升目标检测模型对缺陷的表征能力。

(3) 设计FasterCGLU-MANet混合聚合模块，通过融合改进型FasterBlock-CGLU单元与MANet架构，替代传统C2f模块，集成1×1通道重校准卷积、深度可分离卷积及自适应门控卷积核，提升特征语义深度。

(4) 引入鲁棒特征下采样(RFD)机制，通过浅层与深层分级处理策略，有效缓解了图像冗余信息干扰问题；设计Inner-MPDIoU复合损失函数，结合内部区域重叠约束与边界对齐优化，显著提升了边界框回归稳定性。

## 1 多通道图像融合算法

### 1.1 多通道图像融合

本研究提出一种多通道图像融合方法，通过维度扩展策略实现灰度信息与深度信息的特征级集成，提升目标检测模型对镍片表面缺陷的多维特征表征能力。将灰度图像标准化处理，赋值至三通道张量 $T \in R^{H \times W \times 3}$ 的R通道，将深度图通过掩膜约束仅对有效测距区域进行线性变换，赋值至G通道，B通道则采用零值初始化策略进行填充，形成标准化的三通道数据结构。具体数学表达式为：

$$T(x, y) = \begin{cases} I_g(x, y) \\ N[D_d(x, y)] \\ 0 \end{cases} \quad (1)$$

其中， $I_g \in R^{H \times W}$ 为灰度图像， $D_d \in R^{H \times W}$ 为深度图像， $N(\cdot)$ 表示带掩码的Min-Max归一化操作：

$$N(D) = \frac{D - D_{\min}}{D_{\max} - D_{\min}} \cdot 255 \quad (2)$$

其中 $D_{\min}$ 和 $D_{\max}$ 分别为有效区域内的最小和最大深度值。

本工作构建了包含视觉强度特征与几何结构特征的复合输入图像，既保留了灰度图像的表面纹理特征，又整合了深度图像的空间距离特征，有效避免了传统数据拼接方式可能引发的维度冲突与信息冗余问题，有效整合了镍片连接片表面的二维视觉特征与三维深度信息，为下文缺陷检测模型提供更全面的信息表征。

### 1.2 数据集采集

本研究针对镍片连接片表面缺陷检测任务，使用的图像采集设备为深圳广成创新技术有限公司 GCI Pardus 系列 P150 3D 结构光相机。该设备集成高精度结构光三维成像模组(基准工作距离 310 mm，深度测量范围±30 mm)与 1200 万像素全局快门 CMOS 传感器，可同步输出 2040×1536 分辨率灰度图与 16 位深度图。

拍摄样品为带有转制镍片的国轩磷酸铁锂电池(国轩磷酸铁锂电池，长 144 mm、宽 100 mm、厚 20 mm)图像。图像采集平台搭建如图 1 所示，具体包括铝型材龙门架、条形光源、光源控制器、3D 相机、方形锂电池、计算机。




图 1 图像采集平台  
Fig. 1 Image acquisition platform

采集原始图像后对缺陷类别进行汇总和统计，将镍片连接片表面缺陷分为凹陷、黑点、划痕、颗粒和焊锡五类，不同类型见图 2，共构建 621 组灰度图和对应深度图。灰度图能够清晰地反映镍片表面的纹理和外观特征，深度图则提供了三维深度信息。所有图像在同一视角和分辨率下获得，保证灰度图与深度图的对应关系。

### 1.3 数据集预处理

使用 Labelimg 软件标注镍片连接片表面缺陷图像，记录缺陷类别、位置及大小等信息于标签文件。图像与标签按 7 : 2 : 1 比例分为训练集、测试集和验证集。确保模型训练的充分性和测试的有效性，更全面地检验模型在新的数据环境下的泛化能力。同时为提高模型的鲁棒性，针对数据分布不均

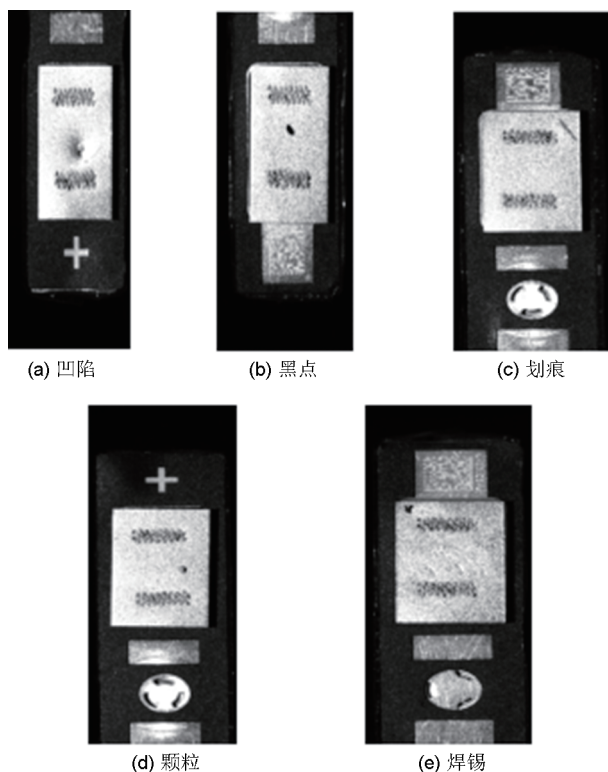


图 2 镍片连接片表面缺陷灰度  
Fig. 2 Grayscale of surface defects on nickel sheet connection sheets




图 3 扩充前后各类缺陷目标数量  
Fig. 3 The number of various defect targets before and after expansion

衡的问题，本研究使用旋转、改变图像亮度、添加高斯噪声等方法对训练集进行数据增强，最终得到 3105 张训练集图像，扩充前后缺陷目标数量统计分别如图 3 所示。

## 2 FDI-YOLOv10 架构

YOLOv10 作为新一代高性能单阶段目标检测

框架,采用一致的双重分配策略,消除了YOLO系列的非极大值抑制训练依赖。模型具体分为YOLOv10n、YOLOv10s、YOLOv10m、YOLOv10b、YOLOv10l和YOLOv10x6个模型,可针对不同的应用场景进行检测。基于锂离子电池模组镍片连接片表面缺陷检测的工业部署需求,本研究选择尺寸最小、推理速度最快的YOLOv10n作为基础模

型开展研究。在YOLOv10n模型的基础上,通过集成FasterCGLU-MANet混合聚合模块和RFD模块并替换损失函数,提出了一种适用于锂离子电池模组镍片连接片表面缺陷检测的FDI-YOLOv10n模型。该算法主要由输入图像预处理、主干提取网络、颈部融合网络以及头部检测网络4个部分组成,其具体结构如图4所示。

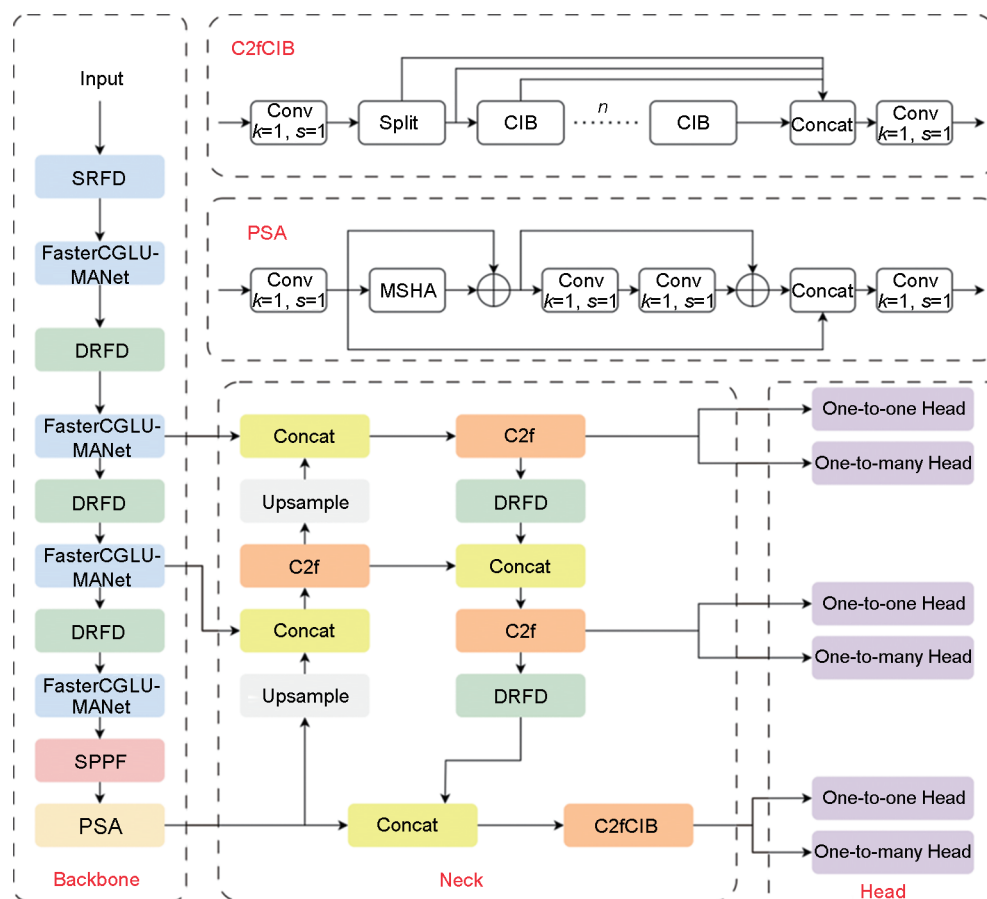


图4 FDI-YOLOv10n  
Fig. 4 FDI-YOLOv10n

## 2.1 FasterCGLU-MANet混合聚合模块

为了增强网络的特征提取能力,本研究设计了FasterCGLU-MANet混合聚合模块,使用FasterBlock-CGLU与MANet网络相结合替换Backbone中的C2f模块。

FasterBlock保持了较高的浮点运算次数,并提出了一种新的局部卷积PConv,这使得FasterBlock在具备更快运行速度的同时,还实现了更少的参数量,并产生了有限的精度损失,优势显著。CGLU模块图如图5所示,该设计在CGLU门控路径中引入 $3\times 3$ 深度可变形卷积层,使特征单

元能够基于局部邻域细粒度信息生成自适应门控权重,满足了部分无位置编码设计的ViT模型对深度卷积所提供位置信息的需求。结合CGLU门控机制与FasterBlock卷积结构以形成一种高效率FasterBlock-CGLU复合单元。

将FasterBlock-CGLU模块与混合聚合网络(MANet)相结合,如图6所示。MANet架构独特地融合了三种卷积变体: $1\times 1$ 卷积分支重校准通道特征,深度可分离卷积(DSConv)优化空间特征表达,FasterCGLU模块提升特征层次整合能力。这种融合策略在模型训练过程中丰富了梯度流的多样性,

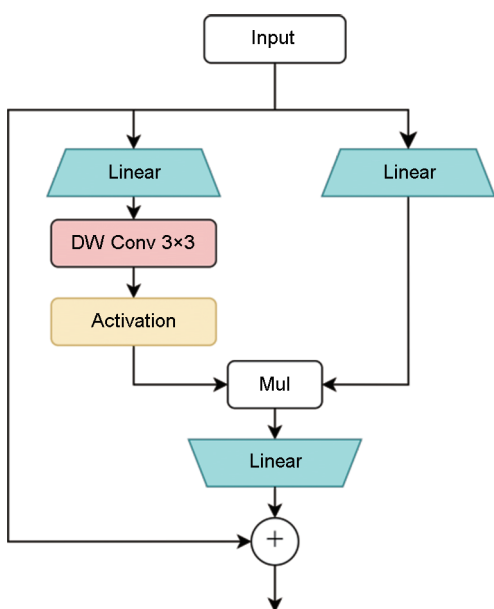


图 5 CGLU 模块  
Fig. 5 CGLU module

显著提升了 5 个关键阶段中基本特征的语义表达深度。数学表达式可概括表述如下：

$$\begin{cases}
 \mathbf{X}_{\text{mid}} = \text{Conv}_1(\mathbf{X}_{\text{in}}) \\
 \mathbf{X}_1 = \text{Conv}_2(\mathbf{X}_{\text{mid}}) \\
 \mathbf{X}_2 = \text{DSConv}[\text{Conv}_3(\mathbf{X}_{\text{mid}})] \\
 \mathbf{X}_3, \mathbf{X}_4 = \text{Split}(\mathbf{X}_{\text{mid}}) \\
 \mathbf{X}_5 = \text{FasterCGLU}(\mathbf{X}_4) + \mathbf{X}_4 \\
 \mathbf{X}_6 = \text{FasterCGLU}(\mathbf{X}_5) + \mathbf{X}_5 \\
 \dots \\
 \mathbf{X}_{4+n} = \text{FasterCGLU}(\mathbf{X}_{3+n}) + \mathbf{X}_{3+n}
 \end{cases} \quad (3)$$

其中  $\mathbf{X}_{\text{mid}}$  的通道数为  $2c$ ，而  $\mathbf{X}_1, \mathbf{X}_2 \dots \mathbf{X}_{4+n}$  的通道计数为  $c$ ，本研究通过串联操作将三种类型特征的语义信息融合，并使用  $1 \times 1$  卷积压缩通道数，以生成通道数为  $2c$  的  $\mathbf{X}_{\text{out}}$ ，如下所示：

$$\mathbf{X}_{\text{out}} = \text{Conv}_0(\mathbf{X}_1 \parallel \mathbf{X}_2 \parallel \dots \parallel \mathbf{X}_{4+n}) \quad (4)$$

$\text{Conv}_0$  表示  $1 \times 1$  卷积操作，用于将融合后特征映射的通道数调整为  $2c$ 。

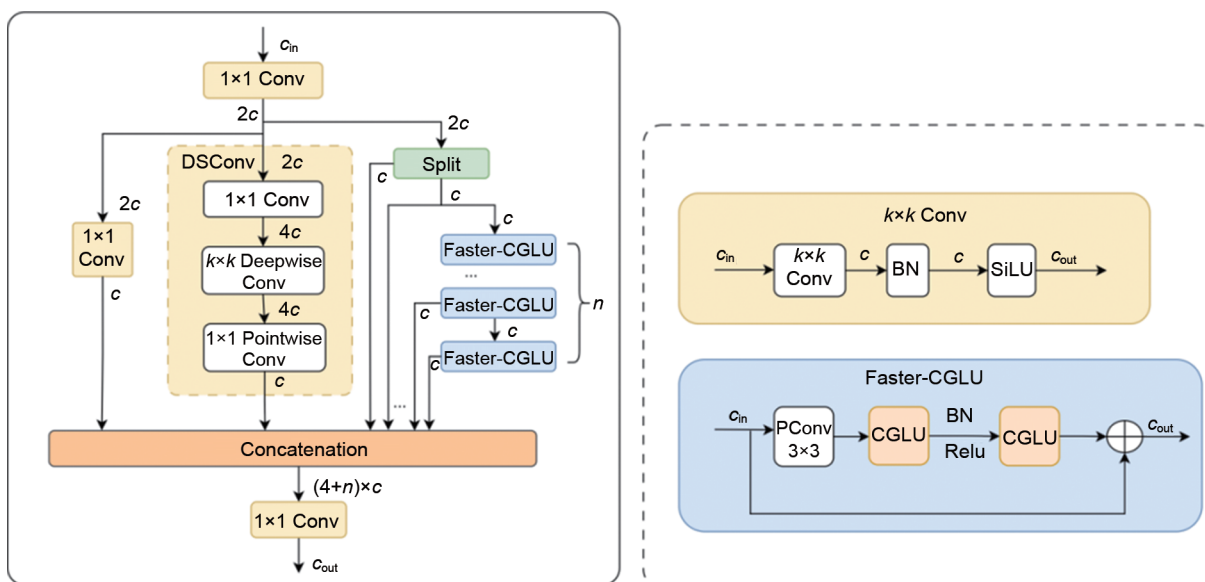


图 6 FasterCGLU-MANet 模块  
Fig. 6 FasterCGLU-MANet module

## 2.2 鲁棒特征下采样

在检测锂电池模组镍片连接片表面缺陷时，初始图像往往包含大量信息以及像素级冗余。在主干网络提取与融合特征的过程中，有效过滤冗余信息，同时增强关键特征，是一待解决的挑战。下采样层通常借助卷积操作来减小特征图尺寸，这种方法虽能较好地整合局部信息，但在保留细粒度细节方面表现欠佳，容易造成特征模糊或丢失。RFD 方法是克服遥感图像处理中由于低分辨率、小物体目

标和特征稀缺造成不良影响的新型下采样方法。RFD 分为浅层鲁棒特征下采样(SRFD)及深层鲁棒特征下采样(DRFD)。SRFD 主要用于替代网络的第一级浅下采样层，结构如图 7 所示。在锂电池模组镍片连接片图像处理中，该模块对输入图像采用  $7 \times 7$  卷积核进行初始特征提取，通过扩大感受野有效捕获镍片连接片表面图像的全局上下文信息。随后，将生成的特征图分为两个分支进行处理。

其中一个分支采用基于像素切分的切片下采样

方法(CutD),通过对相邻像素点进行切片,在缩小特征图尺寸的同时尽量保留原始特征信息。另一个分支使用 $3\times 3$ 分组卷积(GConv)和深度可分离卷积(DWConvD)完成下采样,通过参数共享提升局部特征的聚合能力,协同提升特征融合效果。两个分支产生的特征图进行拼接,经过 $1\times 1$ 卷积层调整通道数。在特征图下采样 $2\sim 4$ 倍的过程中,采用多种方式获得不同输出特征图,再将这些特征图拼接并统一通道数,得到最终输出。该过程提升了模型处理复杂背景的过滤性能,使其更好地聚焦锂电池模组镍片连接片的缺陷特征,增强特征表达的鲁

棒性。

深层鲁棒特征下采样模块(DRFD)主要应用于 $2\sim 5$ 级下采样层,结构如图8所示。在锂电池模组镍片连接片表面缺陷检测任务中,这些阶段的特征图已经包含较为丰富的语义信息。下采样操作时,减少信息损失成为核心。DRFD模块与SRFD模块工作方式类似。输入特征图先后经过卷积(Conv)、CutD、最大池化(MaxD)处理,分别得到多种输出特征图。各特征图应用GELU激活函数并拼接,通道数由原始的 $C$ 扩展到 $6C$ 。随后通过 $1\times 1$ 卷积调整通道数至 $C$ ,确保有丰富的语义信息。

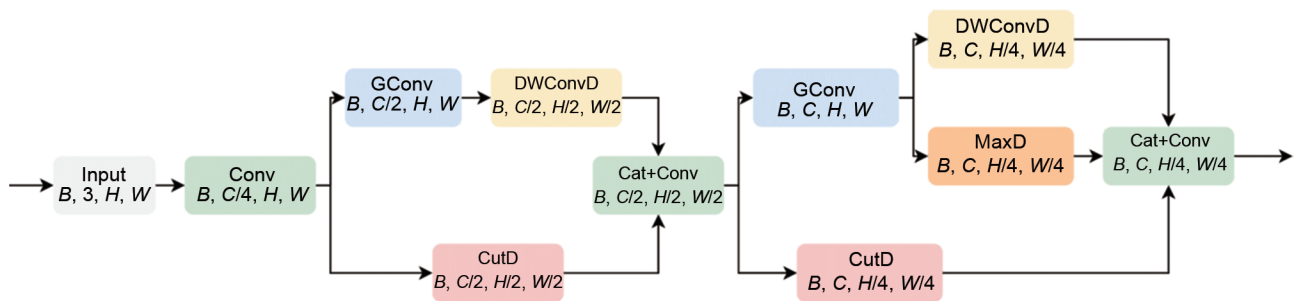


图7 浅层鲁棒特征下采样模块

Fig. 7 Shallow robust feature downsampling module

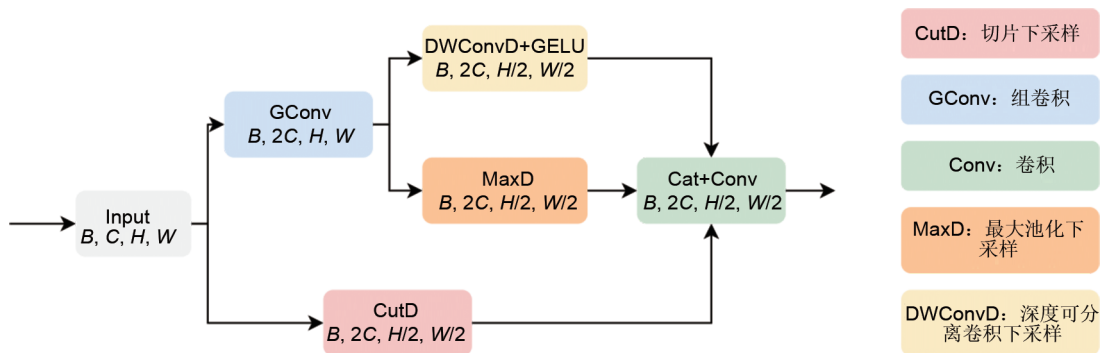



图8 深层鲁棒特征下采样模块

Fig. 8 Deep robust feature downsampling module



### 2.3 Inner-MPDIoU

YOLOv10n 采用  $\text{CIoU}^{[25]}$  作为核心损失函数,通过量化预测框与真实框的重叠区域、几何中心间距及宽高比差异,有效提升缺陷定位精度。但该函数对中心距和宽高比的权重分配存在失衡,当检测目标发生显著方向偏移时,易引发损失函数波动,导致收敛稳定性下降。因此本研究提出一种融合 Inner-IoU 和 MPD-IoU 的复合损失函数 (Inner-MPD),通过多层次几何约束优化边界框回归性能。

本研究提出 InnerMPDIoU 损失函数,聚焦于

预测框与真实框的内部区域重叠程度,而非传统全局区域匹配。当预测框主体部分嵌入真实框内部时,该指标可赋予显著更高的量化评分。该方法在 MPDIoU 度量机制基础上构建双重优化目标,不仅对内部区域重叠进行有效度量,还增加了用于强化边界对齐的约束,用于提升检测框定位的准确性。

#### 2.3.1 Inner-IoU

在边界框回归任务中, Inner-IoU 借助辅助边界框以优化 IoU 损失计算。其通过按比例因子  $s$  缩小真实框与预测框的尺寸,计算缩小后两框的交并

比, 进而提升回归精度。其中, 真实框、预测框中心点分别为  $(x_c^{gt}, y_c^{gt})$  和  $(x_c, y_c)$ ,  $w^{gt}$ 、 $h^{gt}$  与  $w$ 、 $h$  为真实框和预测框的宽高, 两个框之间重叠区域面积为  $inter$ , 覆盖区域面积为  $union$ , 据此得出交并比, 公式如下:

$$b_l^{gt} = x_c^{gt} - \frac{w^{gt} \cdot s}{2}, b_r^{gt} = x_c^{gt} + \frac{w^{gt} \cdot s}{2} \quad (5)$$

$$b_t^{gt} = y_c^{gt} - \frac{h^{gt} \cdot s}{2}, b_b^{gt} = y_c^{gt} + \frac{h^{gt} \cdot s}{2} \quad (6)$$

$$b_l = x_c - \frac{w \cdot s}{2}, b_r = x_c + \frac{w \cdot s}{2} \quad (7)$$

$$b_t = y_c - \frac{h \cdot s}{2}, b_b = y_c + \frac{h \cdot s}{2} \quad (8)$$

$$inter = \max[(\min(b_r^{gt}, b_r) - \max(b_l^{gt}, b_l)) \cdot \max[(\min(b_b^{gt}, b_b) - \max(b_t^{gt}, b_t))] \quad (9)$$

$$union = (w^{gt} \cdot h^{gt}) \cdot s^2 + (w \cdot h) \cdot s^2 - inter \quad (10)$$

$$IoU_{Inner} = \frac{inter}{union} \quad (11)$$

$$L_{Inner-loU} = 1 - IoU_{Inner} \quad (12)$$

### 2.3.2 MPD-IoU

MPD-IoU 通过优化预测框和真实框左上角与右下角坐标的差异, 增强边界框回归的准确性, 同时提升运算效率。该方法综合考虑预测框与真实框的重叠与非重叠区域、中心点间距和宽高比的偏差, 简化整体的计算流程。在实际训练过程中, 此方法改善了边界框回归的性能, 提高训练收敛速度。

$$L_{MPD-IoU} = 1 - MPD_{IoU} \quad (13)$$

$$MPD_{IoU} = \frac{inter}{union} + \frac{d_1^2}{w^2 + h^2} + \frac{d_2^2}{w^2 + h^2} \quad (14)$$

$$d_1^2 = (x_1^{pred} - x_1^{gt})^2 + (y_1^{pred} - y_1^{gt})^2 \quad (15)$$

$$d_2^2 = (x_2^{pred} - x_2^{gt})^2 + (y_2^{pred} - y_2^{gt})^2 \quad (16)$$

本研究使用 Inner-IoU 损失函数的思想优化 MPDIoU, 以 Inner-MPDIoU 替换 CIoU, 改进后的公式为:

$$IoU_{Inner-MPD} = \frac{inter}{union} - \frac{d_1^2}{w^2 + h^2} - \frac{d_2^2}{w^2 + h^2} \quad (17)$$

## 3 实验与分析

表 1 详细列出了本研究模型训练与测试所用的服务器硬件配置及软件环境。模型训练阶段参数配置包括: 批量大小 32, 训练次数为 300 次, 批处理规模为 8。采用随机梯度下降(SGD)优化器, 初始学习率 0.01, 动量 0.937, 并设定权重衰减率至 0.0005。

为了对缺陷检测模型进行评估, 本研究选取准确

表 1 硬件配置和软件环境

Table 1 Hardware configuration and software environment

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 i9-14900k(128 GB)
GPU	RTX4090(24 GB)
深度学习框架	PyTorch 2.5.2
运算环境	cu121
集成开发环境	Pycharm
编译器	Python 3.10.14

率( $P$ )、召回率( $R$ )、平均精度均值(mAP)、参数量、计算量(FLOPs)、帧率(FPS)作为评价指标, 公式如下:

$$P = \frac{TP}{TP + FP} \quad (18)$$

$$R = \frac{TP}{TP + FN} \quad (19)$$

$$AP = \int_1^0 PdR \quad (20)$$

$$mAP = \frac{\sum_{i=1}^N AP_i}{N} \quad (21)$$

$$FPS = \frac{Framenum}{ElapsedTime} \quad (22)$$

其中, 真阳性(TP)反映正确识别的目标数量, 误报阳性(FP)和漏报阳性(FN)分别对应错误检测与未检测到的目标数, 而平均精确度(AP)则衡量  $P$ - $R$  曲线与坐标轴围成的面积。Framenum 代表检测图片总数; ElapsedTime 表示检测所需总时间。

### 3.1 多通道融合方法对比实验

为验证本研究数据层通道融合策略的有效性, 本研究将其与经典的图像融合算法 TIF<sup>[26]</sup>进行了对比实验。实验将灰度图、TIF 融合图像及本研究方法融合图像在 YOLOv10n 检测框架下进行训练与测试。实验训练参数设置及实验环境参考表 1, 实验结果如表 2 所示。

表 2 结果显示, TIF 融合算法虽使精确率提升至 86.5%, 但召回率降至 74.2%, mAP@0.5 仅提

表 2 多通道融合方法对比实验

Table 2 Comparative experiments on the multi-channel fusion methods

模型	$P/\%$	$R/\%$	mAP@0.5/%
灰度图	70.5	83.3	80.8
TIF 融合	86.5	74.2	82.7
本研究融合	83.2	83.3	89.2

高1.9%，表明细节增强同时放大了背景噪声，导致漏检。相比之下，本研究融合在维持83.3%召回率的同时，mAP@0.5大幅跃升至89.2%，较灰度单通道提升8.4%，较TIF融合算法提升6.5%。本研究融合策略有效保留了灰度-深度的空间对应关系，规避了冗余计算，验证了其在检测前置表征中的有效性与优越性。

### 3.2 单类缺陷对比实验

本研究为了验证提出的多通道图像融合方法在不同类型镍片连接片表面缺陷上的有效性，设计单类缺陷对比实验。将每一类缺陷作为单独的数据集依次在基准模型中进行检测，通过对比每类缺陷的灰度图与融合后图像的评价指标，检测融合方法对不同类型缺陷的适应性和有效性，实验结果如表3所示。

表3 单类缺陷对比实验

Table 3 Single-type defect comparison experiment

缺陷类型	数据类型	P/%	R/%	mAP@0.5/%
凹陷	灰度图	59.4	57.1	54.9
	融合图	83.9	74.7	80.2
黑点	灰度图	86.4	74.6	85.7
	融合图	87.8	88.1	90
划痕	灰度图	71.3	56.8	60.6
	融合图	67	57.9	60.9
颗粒	灰度图	82	94.7	95.8
	融合图	95.6	96.1	98.3
焊锡	灰度图	82.7	83.1	86.8
	融合图	93.3	84.8	89.7

通过单类缺陷的对比实验数据可以看出，本研究提出的多通道图像融合方法在镍片连接片表面缺陷检测任务中，整体检测性能具有明显提升。对于大部分缺陷类型，融合多通道数据后在精确率、召回率和平均精度等指标上均高于单一灰度图像的检测结果。针对在灰度图中特征表达不充分或易与背景混淆的缺陷类型，如凹陷，通过引入深度信息，模型的检测性能明显提高，mAP由54.9%提升到80.2%。对于颗粒缺陷，多通道融合后mAP由95.8%提升至98.3%。

对于浅表层缺陷，如划痕，这类缺陷大多呈现出线性或曲线状的细微形貌，其深度变化较小，因此模型在识别与定位时存在一定难度。融合深度信息后，模型可捕捉到划痕区域轻微的深度变化特

征，对提升检测的准确性有明显帮助。

实验数据表明该融合策略能够有效整合灰度图像的纹理细节与深度图像的空间信息，有效缓解小目标检测中的特征丢失问题，从而提高模型对各类缺陷的识别能力，减少误检和漏检情况的发生。

### 3.3 损失函数对比实验

为了验证 Inner-MPDIoU 损失函数的有效性，在模型加入 FasterCGLU-MANet 混合聚合模块，采用鲁棒特征下采样改进的基础上，在自制锂电池模组镍片连接片表面缺陷数据集上，逐一使用 CloU、FocalerIoU、InnerIoU、MPDIoU、Focaler\_MPDIoU 和 InnerMPDIoU 损失函数进行训练，实验结果如表4所示。

表4 损失函数对比实验

Table 4 Loss function comparison experiment

损失函数	P/%	R/%	mAP/%
CloU	86.6	85.9	90.3
FocalerIoU	87.8	85.9	90.2
InnerIoU	85.1	83.4	89.3
MPDIoU	83.5	81.1	86.7
Focaler_MPDIoU	85.3	80.8	89.2
InnerMPDIoU	91.1	89.8	96.1

从表4可以看出，与 CloU 相比，单独使用 InnerIoU 时，精确率有所下降，但平均精度均值略有提升；单独使用 MPDIoU 时，虽然平均精度均值下降，但召回率有所提高。将 MPDIoU 与 InnerIoU 结合形成的 Inner-MPDIoU 损失函数，在精确率、召回率和平均精度均值上均取得了最佳性能，充分证明了 Inner-MPDIoU 损失函数能有效弥补 CloU 的不足，对提升模型的缺陷检测性能具有显著效果。

### 3.4 FasterCGLU-MANet 混合聚合模块对比实验

为验证 FasterCGLU-MANet 混合聚合模块的有效性，本研究对比了基础模型 YOLOv10n，在基础模型上仅采用 MANet 替换 C2f 的 MAN 模型、MANet 结合 FasterBlock 的 MAN-Faster 模型，本研究设计的 FasterCGLU-MANet 模型的核心性能指标，实验结果如表5。

实验结果表明，本研究提出的 FasterCGLU-MANet 在目标检测任务中展现出较强的性能优势。与 MAN、MAN-Faster 两种结构对比，FasterCGLU-MANet 在准确率、召回率和 mAP 这三项指标中均表现出更高的数值。检测速度上，Faster

表5 FasterCGLU-MANet混合聚合模块对比实验结果  
Table 5 Comparative experimental results of the FasterCGLU-MANet hybrid polymerization module

模型	P/%	R/%	mAP/%	参数量 /M	计算量 /G	帧率 /(帧/s)
YOLOv10n	83.2	83.3	89.2	2.3	6.5	285.7
MAN	76.8	81.3	87.5	2.8	8.3	250
MAN-Faster	80.3	78.3	83.8	2.4	6.7	196.1
FasterCGLU -MANet	88	85.1	90.3	2.3	6.5	185.2

CGLU-MANet的帧率为185.2帧/s。引入FasterBlock-CGLU结构以后，模型在不显著增加参数量和推理计算量的情况下，有效提升了检测精度。结果验证了该结构的特征提取能力和模型效率，通过高效融合卷积和门控机制，能够显著提升模型的检测性能，同时保持较低的复杂度，具备良好的应用前景。

### 3.5 消融实验

本研究以YOLOv10n为基线模型，对其进行三个方面改进，为检验每个改进点对基准模型的提升效果，本研究在镍片连接片表面缺陷数据集上进行了7组消融实验。结果如表6所示，其中M1表示FasterCGLU-MANet混合聚合模块，M2表示采用鲁棒特征下采样改进、M3表示将损失函数替换为InnerMPDIoU损失函数。

表6 消融实验结果

Table 6 Results of the ablation experiment

模型	P/%	R/%	mAP/%	参数量/M	计算量/G	帧率/(帧/s)
Yolov10n	83.2	83.3	89.2	2.3	6.5	285.7
+M1	88	85.1	90.3	2.3	6.5	185.2
+M2	92.1	88.6	94.2	2.7	8.4	227.3
+M3	79.4	91.8	93.1	2.3	6.5	217.4
+M1+M2	86.6	85.9	90.3	2.6	7.8	243.9
+M1+M3	82.3	88.6	91	2.3	6.5	303
+M2+M3	87.7	89.6	94.2	2.7	8.5	232.6
+M1+ M2+M3	91.1	89.8	96.1	2.6	7.8	333.3

通过对消融实验数据进行分析，本研究提出的改进方法在镍片连接片表面缺陷检测任务中表现出较大优势。在YOLOv10n基线模型基础上加入M1后，模型的精确率提升4.8%，召回率提升1.8%，mAP提升1.1%，检测速度有明显提升，说明M1增强了模型的特征提取能力。引入M2后，精确率

和召回率分别增加8.9%和5.3%，mAP提升5%，虽然参数量和FLOPs有所增加，但细节特征提取效果明显更好，有助于模型对缺陷区域实现更为准确的识别。采用M3替换原有损失函数后，模型精确率下降到79.4%，召回率上升至91.8%，mAP达到93.1%，表明M3更注重模型对于缺陷的召回能力提升。

组合实验中，M1+M2的P和mAP提升明显，但R略微下降，FLOPs和帧率增加，表明混合模块与鲁棒特征下采样结合在提升检测性能方面具有协同效应；M2+M3的P、R和mAP均达到较高水平，计算量和帧率变化不大，表现出良好平衡；当M1、M2和M3三个模块全部引入时，模型在精确率P、召回率R和mAP上均取得了最佳结果，分别为91.1%、89.8%和96.1%，这充分证明了各改进模块之间的协同作用，可有效提升模型在镍片连接片表面缺陷检测任务中的综合性能。

综上所述，消融实验结果表明，本研究提出的改进方法在提升YOLOv10n模型的检测性能方面具有明显优势，能够有效提高模型对镍片连接片表面缺陷的识别能力，减少误检和漏检情况的发生。这些改进措施对于提高镍片连接片表面缺陷检测的精度和可靠性具有重要意义。

### 3.6 对比实验

为了验证本研究算法的卓越性能，在相同的实验条件下，将改进后的本研究算法在锂电池模组镍片连接片缺陷数据集上与前主流模型的算法进行对比实验，包括YOLOv3-tiny、YOLOv5n、YOLOv6s、YOLOv7-tiny、YOLOv8n、SSD、Faster-RCNN和DETR-main算法，实验结果如表7所示。

由对比实验结果可知，在镍片连接片表面缺陷数据集上，本研究改进后的YOLOv10n算法相较于其他主流模型展现出显著优势。SSD算法的mAP@0.5为59.1%，参数量为24.3 M，推理速度为62.1帧/s，计算量为287 G，其检测精度较低，同时计算量也有优化的空间；Faster-RCNN比SSD参数量增加17.06 M，但mAP@0.5提高29.2%，推理速度提升不明显，计算量减少108.6 G；DETR-main比SSD的mAP@0.5提高28.5%，参数量增加17.2 M，推理速度略有提升，计算量减少205.6 G；YOLOv3-tiny参数量为12.1 M，推理速度为270.3帧/s，计算量为18.9 G，但检测精度较

表7 对比实验结果

Table 7 Compare the experimental results

模型	mAP/%	参数量/M	计算量/G	帧率/(帧/s)
SSD	59.1	24.3	287	62.1
Faster-RCNN	88.3	41.36	178	64.1
DETR-main	87.6	41.5	81.4	63.9
YOLOv3-tiny	78.1	12.1	18.9	270.3
YOLOv5n	87.8	2.5	7.1	181.8
YOLOv6s	79.2	4.2	11.8	384.6
YOLOv7-tiny	78.1	6	13.2	140.8
YOLOv8n	90	3	8.1	285.7
YOLOv9s	90.7	7	26.7	285.7
FDI-YOLOv10n	96.1	2.6	7.8	333.3
YOLOv11n	88	2.6	6.3	333.3
YOLOv12n	79.2	2.6	6.3	312.5
YOLOv13n	87.8	2.5	6.2	303

低；YOLOv5n 推理速度为 181.8 帧/s，计算量为 7.1 G，但检测精度有待提高；YOLOv6s 参数量为 4.2 M，推理速度为 384.6 帧/s，但检测精度低于本研究算法；YOLOv7-tiny 推理速度为 140.8 帧/s，但检测精度和参数量均不占优；YOLOv8n 和 YOLOv9s 的推理速度有待提升；YOLOv11n、YOLOv12n、YOLOv13n 的参数量和计算量虽然低于本研究算法(FDI-YOLOv10n)，但其平均精度和检测速度有所提升。

本研究提出的改进 YOLOv10n 算法在镍片连接片缺陷数据集上达到 96.1% 的 mAP@0.5，显著优于 YOLOv8n、Faster-RCNN 等主流模型。同时，模型参数量(2.6 M)与计算量(7.8 G, FLOPs)保持轻量，推理速度达 333.3 帧/s，满足工业级实时检测需求。实验结果表明，改进后的 YOLOv10n 模型在精度、速度和模型效率之间实现了良好的平衡，为锂电池模组镍片连接片表面缺陷检测提供了高性能的解决方案。

### 3.7 可视化分析

为了全面验证改进算法的有效性，使用 EigenGradCAM 开展热力图可视化实验，相关结果呈现于图 9。在热力图中，红色区域是模型聚焦的重点，颜色愈深，对预测结果的贡献也愈大；黄色区域对结果有一定作用，而蓝色区域在预测过程中的影响力较小，往往为背景或目标的次要部分。从热力图可明显看出，改进后的模型能够更精准地定位目标区域，对其的响应更强烈且更集中，同时显著减少了对无关背景区域的注意力。




图9 热力图对比

Fig. 9 Heat map comparison

为了更直观地比较改进前后模型的检测效果，对比图 10(a)~(c)可以发现：FDI-YOLOv10n 对目标的定位更为准确，能更清晰地标记出缺陷区域，而且还减少了误检和漏检情况。同时，FDI-YOLOv10n 表现出更稳定的性能，其检测出的缺陷置信度也均高于 YOLOv10n。




图10 检测效果对比

Fig. 10 Comparison of the detection effects

## 4 总结

本研究提出的 FDI-YOLOv10n 模型在锂电池模组镍片连接片表面缺陷检测任务中表现出色。多通道级图像融合策略将灰度图像和深度图像的特征信息加以整合，增强了模型对缺陷区域的表征能力。FasterCGLU-MANet 混合聚合模块提升了特征提取效率，鲁棒特征下采样机制去除了部分冗余信息，进一步强化模型对关键特征的捕捉能力。InnerMPDIoU 复合损失函数优化了边界框的回归精度。实验结果表明，改进后的模型在精确率、召回率和平均精度均值等指标上均优于其他主流模型，展现出良好的平衡性和优越的检测性能，为锂电池模组镍片连接片表面缺陷检测提供了一种高效、可靠的解决方案。然而在模型的检测速度和计算资源消耗方面，依然有进一步改善的空间。在未来的工作

中, 将继续研究优化改进策略, 使得 FDI-YOLOv10n 模型拥有更高的精度和更快的检测速度, 能够更好地满足工业缺陷检测的需求。

### 参考文献

- [1] MASIAS A, MARCICKI J, PAXTON W A. Opportunities and challenges of lithium ion batteries in automotive applications[J]. *ACS Energy Letters*, 2021, 6(2): 621-630.
- [2] 王莉, 谢乐琼, 田光宇, 等. 锂离子电池安全事故: 安全性问题, 还是可靠性问题[J]. *储能科学与技术*, 2021, 10(1): 1-6.  
WANG L, XIE L Q, TIAN G Y, et al. Safety accidents of Li-ion batteries: Reliability issues or safety issues[J]. *Energy Storage Science and Technology*, 2021, 10(1): 1-6.
- [3] 甘露雨, 陈汝颂, 潘弘毅, 等. 锂电池安全性多尺度研究策略: 实验与模拟方法[J]. *储能科学与技术*, 2022, 11(3): 852-865. DOI: 10.19799/j.cnki.2095-4239.2022.0047.  
GAN L Y, CHEN R S, PAN H Y, et al. Multiscale research strategy of lithium ion battery safety issue: Experimental and simulation methods[J]. *Energy Storage Science and Technology*, 2022, 11(3): 852-865. DOI:10.19799/j.cnki.2095-4239.2022.0047.
- [4] XU Y X, NIU L C, YANG H, et al. Optimization of lithium battery pole piece thickness control system based on GA-BP neural network[J]. *Journal of Nanoelectronics and Optoelectronics*, 2019, 14(7): 978-986. DOI:10.1166/jno.2019.2650.
- [5] 邵瑞. 基于深度学习的工业产品缺陷检测研究与应用[D]. 济南: 齐鲁工业大学, 2024.  
SHAO R. Research and application of industrial product defect detection based on deep learning[D]. Jinan: Qilu University of Technology, 2024.
- [6] 李博文, 杨续来, 葛肖尽, 等. 锂离子电池极片表面缺陷检测方法研究进展[J]. *仪器仪表学报*, 2025, 46(1): 125-146. DOI:10.19650/j.cnki.cjsi.J2413335.  
LI B W, YANG X L, GE X J, et al. Research progress on defect detection methods for electrode surface of lithium-ion battery[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(1): 125-146. DOI:10.19650/j.cnki.cjsi.J2413335.
- [7] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot MultiBox detector[C]//Computer Vision-ECCV 2016. Cham: Springer, 2016: 21-37. DOI:10.1007/978-3-319-46448-0\_2.
- [8] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). June 27-30, 2016. Las Vegas, NV, USA. IEEE, 2016: 779-788. DOI:10.1109/cvpr.2016.91.
- [9] WANG C Y, YE H I, MARK LIAO H Y. YOLOv9: Learning what you want to learn using programmable gradient information[C]//Computer Vision-ECCV 2024. Cham: Springer, 2025: 1-21. DOI: 10.1007/978-3-031-72751-1\_1.
- [10] CHEN H, CHEN K, DING G G, et al. YOLOv10: Real-time end-to-end object detection[C]//Advances in Neural Information Processing Systems 37. December 10-15, 2024. Vancouver, BC, Canada. Neural Information Processing Systems Foundation, Inc. (NeurIPS), 2024: 107984-108011. DOI:10.52202/079017-3429.
- [11] GIRSHICK R. Fast R-CNN[C]//Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV). ACM, 2015: 1440-1448. DOI:10.1109/ICCV.2015.169.
- [12] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[C]//Computer Vision-ECCV 2020. Cham: Springer, 2020: 213-229. DOI: 10.1007/978-3-030-58452-8\_13.
- [13] ZONG Z F, SONG G L, LIU Y. DETRs with collaborative hybrid assignments training[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). October 1-6, 2023, Paris, France. IEEE, 2024: 6725-6735. DOI:10.1109/ICCV51070.2023.00621.
- [14] 邢远秀, 刘颀玮, 邢玉峰, 等. BDD-DETR: 高效感知小目标的锂电池表面缺陷检测[J]. *储能科学与技术*, 2025, 14(1): 370-379.  
XING Y X, LIU Z W, XING Y F, et al. BDD-DETR: An efficient algorithm for detecting small surface defects on lithium batteries [J]. *Energy Storage Science and Technology*, 2025, 14(1): 370-379.
- [15] 朱永平, 程博, 熊聪, 等. 多尺度YOLOv5算法检测锂离子电池表面缺陷[J]. *电池*, 2025, 55(1): 71-77. DOI: 10.19535/j.1001-1579.2025.01.011.  
ZHU Y P, CHENG B, XIONG C, et al. Multiscale YOLOv5 algorithm for surface defect detection of pouch Li-ion battery[J]. *Battery Bimonthly*, 2025, 55(1): 71-77. DOI: 10.19535/j.1001-1579.2025.01.011.
- [16] 何涛, 张成娟, 雷卓, 等. 软包装锂离子电池表面凹坑缺陷检测方法[J]. *电池*, 2024, 54(3): 358-363. DOI: 10.19535/j.1001-1579.2024.03.014.  
HE T, ZHANG C J, LEI Z, et al. Surface pit defects detecting method of pouch Li-ion battery[J]. *Battery Bimonthly*, 2024, 54(3): 358-363. DOI:10.19535/j.1001-1579.2024.03.014.
- [17] 孙浩然, 李雅雯, 韩有军, 等. 基于拓扑滤波与改进Canny算子的锂离子电池电极缺陷检测[J]. *储能科学与技术*, 2022, 11(10): 3297-3305. DOI:10.19799/j.cnki.2095-4239.2022.0167.  
SUN H R, LI Y W, HAN Y J, et al. Lithium-ion battery electrode defect detection based on topological filtering and improved Canny operator[J]. *Energy Storage Science and Technology*, 2022, 11(10): 3297-3305. DOI:10.19799/j.cnki.2095-4239.2022.0167.
- [18] DAI X Y, CHEN Y P, XIAO B, et al. Dynamic head: Unifying object detection heads with attentions[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 20-25, 2021, Nashville, TN, USA. IEEE, 2021: 7369-7378. DOI: 10.1109/CVPR46437.2021.00729.
- [19] LI H, WU X J, KITTLER J. Infrared and visible image fusion using a deep learning framework[C]//2018 24th International Conference on Pattern Recognition (ICPR). August 20-24, 2018, Beijing, China. IEEE, 2018: 2705-2710. DOI:10.1109/ICPR.2018.8546006.
- [20] WANG X H, LI S, CHEN C, et al. Data-level recombination and lightweight fusion scheme for RGB-D salient object detection[J].

- IEEE Transactions on Image Processing, 2021, 30: 458-471. DOI: 10.1109/TIP.2020.3037470.
- [21] CHEN Y X, YAN F W, YIN Z S, et al. Robust LiDAR-camera 3-D object detection with object-level feature fusion[J]. IEEE Sensors Journal, 2024, 24(18): 29108-29120. DOI:10.1109/JSEN.2024.3436834.
- [22] LYU G H, SIMA C, GAO Y B, et al. SIGFusion: Semantic information-guided infrared and visible image fusion[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 5032218. DOI:10.1109/TIM.2024.3457951.
- [23] 谢雨欣, 龚辉飞, 谷心浩, 等. 基于RGB-D特征融合的焊缝表面缺陷检测方法[J]. 焊接学报, 2024, 45(12): 72-78. DOI: 10.12073/j.hjxb.20230712002.
- XIE Y X, GONG Y F, GU X H, et al. Research on weld surface defect detection method based on RGB-D feature fusion[J]. Transactions of the China Welding Institution, 2024, 45(12): 72-78. DOI:10.12073/j.hjxb.20230712002.
- [24] 李明, 鹿朋, 朱龙, 等. 基于RGB-D融合的密集遮挡抓取检测[J]. 控制与决策, 2023, 38(10): 2867-2874.
- LI M, LU P, ZHU L, et al. Densely occluded grasping objects detection based on RGB-D fusion[J]. Control and Decision, 2023, 38(10): 2867-2874.
- [25] ZHENG Z H, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993-13000. DOI:10.1609/aaai.v34i07.6999.
- [26] BAVIRISETTI D P, DHULI R. Two-scale image fusion of visible and infrared images using saliency detection[J]. Infrared Physics & Technology, 2016, 76: 52-64. DOI:10.1016/j.infrared.2016.01.009.