

# 控制与决策

Control and Decision

## 基于注意力机制与多尺度特征融合的 电极缺陷YOLO检测算法

李雅雯, 孙浩然, 胡跃明, 韩有军

引用本文:

李雅雯, 孙浩然, 胡跃明, 韩有军. 基于注意力机制与多尺度特征融合的 电极缺陷YOLO检测算法[J]. *控制与决策*, 2023, 38(9): 2578–2586.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0772>

---

### 您可能感兴趣的其他文章

#### Articles you may be interested in

##### [基于双分支特征融合的场景文本检测方法](#)

A scene text detection based on dual-path feature fusion

*控制与决策*. 2021, 36(9): 2179–2186 <https://doi.org/10.13195/j.kzyjc.2020.0002>

##### [Anchor-free的尺度自适应行人检测算法](#)

Anchor-free scale adaptive pedestrian detection algorithm

*控制与决策*. 2021, 36(2): 295–302 <https://doi.org/10.13195/j.kzyjc.2020.0124>

##### [多目标小尺度车辆目标检测方法](#)

Multi-target and small-scale vehicle target detection method

*控制与决策*. 2021, 36(11): 2707–2712 <https://doi.org/10.13195/j.kzyjc.2020.0635>

##### [改进YOLOv2的端到端自然场景中文字符检测](#)

End-to-end Chinese character detection in natural scene based on improved YOLOv2

*控制与决策*. 2021, 36(10): 2483–2489 <https://doi.org/10.13195/j.kzyjc.2020.0270>

##### [复杂背景下全景视频运动小目标检测算法](#)

Panoramic video motion small target detection algorithm in complex background

*控制与决策*. 2021, 36(1): 249–256 <https://doi.org/10.13195/j.kzyjc.2019.0686>

# 基于注意力机制与多尺度特征融合的 电极缺陷YOLO检测算法

李雅雯<sup>1,2†</sup>, 孙浩然<sup>1,2</sup>, 胡跃明<sup>1,2</sup>, 韩有军<sup>1,2</sup>

(1. 华南理工大学 自动化科学与工程学院, 广州 510640; 2. 精密电子制造装备教育部工程研究中心  
广东省高端芯片智能封测装备工程实验室, 广州 510640)

**摘要:** 为了满足锂离子电池电极缺陷检测精度与实时性的需求, 解决电极图像背景噪声复杂、缺陷微小且对比度低等问题, 提出一种基于注意力机制与多尺度特征融合的电极缺陷YOLO检测算法. 在YOLOv4的基础上, 首先, 将SE(squeeze-and-excitation)注意力模块嵌入特征提取主干网络中, 区分feature map中不同通道的重要性, 强化目标区域的关键特征, 提高网络的检测精度; 其次, 加入融合空洞卷积的池化金字塔(ASPP)结构, 增大网络感受野的同时最大程度地保留多尺度特征信息, 提高算法对小目标的检测性能; 然后, 设计一种多尺度稠密特征金字塔, 在三尺度特征图的基础上增加一个浅层特征, 采用稠密连接的方式融合特征, 提升浅层细节特征与高级语义信息的融合能力, 增强对微小缺陷特征的提取; 最后, 采用K-means++算法聚类先验框, 引入focal loss损失函数增大小目标样本的损失权重, 有效提高网络学习的收敛速度. 实验结果表明, 所提算法较原YOLOv4模型的mAP值提升6.42%, 较其他常用算法综合性能上有着较大的优势, 可较好地满足实际工业生产的实时监测需求.

**关键词:** 锂离子电池; 电极缺陷检测; 注意力机制; 稠密特征金字塔网络; 空洞卷积池化金字塔; YOLOv4

中图分类号: TP391.41; TM912

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0772

引用格式: 李雅雯, 孙浩然, 胡跃明, 等. 基于注意力机制与多尺度特征融合的电极缺陷YOLO检测算法[J]. 控制与决策, 2023, 38(9): 2578-2586.

## Electrode defect YOLO detection algorithm based on attention mechanism and multi-scale feature fusion

LI Ya-wen<sup>1,2†</sup>, SUN Hao-ran<sup>1,2</sup>, HU Yue-ming<sup>1,2</sup>, HAN You-jun<sup>1,2</sup>

(1. College of Automation Science and Engineering, South China University of Technology, Guangzhou 510640, China;  
2. Ministry of Education & Guangdong Provincial Engineering Laboratory for Advanced Chip Intelligent Packaging Equipment, Engineering Research Center for Precision Electronic Manufacturing Equipment, Guangzhou 510640, China)

**Abstract:** In order to meet the requirements of detection accuracy and real-time performance of lithium-ion battery electrode defects, and to solve the problems of complex background noise of electrode images, small defects and low contrast, this paper proposes a electrode defect YOLO detection algorithm based on attention mechanism and multi-scale feature fusion. On the basis of YOLOv4. First, we embed the SE (squeeze-and-excitation) attention module in the feature extraction backbone network to distinguish the importance of different channels in the feature map, strengthen the key features of the target area, and improve the detection accuracy of the network; secondly add the pooling pyramid (ASPP) structure fused with atrous convolution to increase the network receptive field while retaining the multi-scale feature information to the greatest extent, and improve the detection performance of the algorithm for small targets; then design a multi-scale dense feature pyramid, on the basis of the three-scale feature map, a shallow feature is added, and the feature is fused by dense connection, which improves the fusion ability of shallow detail features and high-level semantic information, and enhances the extraction of small defect features; finally, the K-means++ algorithm is used for clustering. In the prior box, the focal loss function is introduced to increase the loss weight of small target samples, which effectively improves the convergence speed of network learning. The experimental results show that the mAP value of the proposed algorithm is increased by 6.42% compared with the original YOLOv4 model, which has a greater advantage in comprehensive performance than other commonly used algorithms, and can better meet the real-time monitoring needs of actual industrial production.

**Keywords:** lithium-ion battery; electrode defect detection; attention mechanism; dense feature pyramid network; atrous convolution pooling pyramid; YOLOv4

收稿日期: 2022-05-06; 录用日期: 2022-09-03.

基金项目: 国家自然科学基金项目(61573146); 国家重大科技专项(2014ZX02503).

†通讯作者. E-mail: 1642595556@qq.com.

\*本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

## 0 引言

锂离子电池作为一种成熟的储能装置,具有能量密度高、循环寿命长、安全性高、污染小等特点,广泛应用于各个领域<sup>[1]</sup>. 锂离子电池电极生产工艺复杂,且易受环境、设备、人工等因素影响,造成电极表面存在漏金属、孔洞、划痕、气泡等缺陷<sup>[2]</sup>. 这些缺陷严重影响电池性能,致使电池容量与使用寿命降低,甚至引发起火、爆炸等严重安全事故<sup>[3-4]</sup>. 因此,高效的电极表面缺陷检测技术成为制约锂电行业发展亟待解决的关键问题.

随着图像处理技术的快速发展,越来越多的学者聚焦于将基于机器视觉的自动检测技术应用到表面缺陷检测中<sup>[5]</sup>. 传统图像处理算法提出较早且发展成熟,在表面缺陷检测领域应用广泛,当前锂电池电极表面缺陷检测的研究也大多基于传统算法. Xu等<sup>[6]</sup>通过对比度调整、Canny算子与逻辑运算等传统图像处理工具对锂电池极片图像进行处理,获得缺陷区域的纹理特征、边缘特征和HOG特征,并利用粒子群优化的支持向量机进行识别与分类,算法在测试集上对多类缺陷的平均识别率可达98.3%; Liu等<sup>[7]</sup>针对锂离子电池电极厚度不均、拍摄环境光照不均等因素对缺陷识别造成干扰的问题,提出一种快速背景补偿算法,显著优化了缺陷区域的ROI提取效果,同时采用基于灰度直方图重建的自适应阈值分割算法,与Otsu等经典算法相比检测效果和运行时间都得到了大幅提升. 然而随着制造工业的不断发展,传统算法已难以满足日益提高的检测精度与实时性的需求,基于卷积神经网络(CNN)的目标检测算法凭借强大的表征能力与出色的可移植性逐渐取代传统算法,成为表面缺陷检测领域研究的热点.

目前基于CNN的缺陷检测网络从结构上可分为单阶段(one-stage)算法和两阶段(two-stage)算法. Girshick等先后提出的R-CNN<sup>[8]</sup>、fast R-CNN<sup>[9]</sup>、faster R-CNN<sup>[10]</sup>等一系列two-stage检测器,具有精度高、速度慢的特点,不适用于实时监测需求较高的锂电池电极检测.

以YOLO、SSD为代表的one-stage目标检测算法将分类问题转化成回归问题,直接预测输入图片的位置信息与类别概率,提高了检测精度和速度的均衡性,适合实时性要求高的目标检测. YOLO算法<sup>[11]</sup>由Redmon等于2016年初次提出,后续作者对其进行不断改进,逐渐衍生出YOLOv2<sup>[12]</sup>与YOLOv3<sup>[13]</sup>,检测性能稳步提升,引起业界的广泛关注与研究. Cao等<sup>[14]</sup>针对晶圆表面微小缺陷难以检测的问题,将

SPP模块引入YOLOv3的主干网络和特征融合网络中并采用Mish激活函数,改善因局部信息缺失导致小物体检测性能差的问题,mAP提升了13个百分点,并提高了检测速度; Lan等<sup>[15]</sup>基于YOLOv3模型结构,合并BN层与卷积层缩短模型训练时间,同时采用GIoU损失函数与K-means++聚类算法,提高微小缺陷的定位精度,改进模型的mAP达92.13%,较原YOLOv3提高了7.89%,检测速度也有一定的优化; 柳长源等<sup>[16]</sup>选用MobileNetv2轻量化模型替换原YOLOv3的主干网络,融合深浅层次特征并加入特征增强模块,与原始YOLOv3相比改进算法的mAP增加约9%,检测速度提升一倍. Bochkovskiy等<sup>[17]</sup>在传统YOLO的基础上极具创新性地融合多个实用模块,提出了YOLOv4算法,效率更高且检测效果更精确,得到大量专家学者的研究与改进. Xie等<sup>[18]</sup>将多级残差混合注意力模块(MRHAM)引入YOLOv4网络结构,并通过K-means++聚类算法聚类先验框,在提高模型对小目标的检测性能的同时结合数据增强、迁移学习等方法增强模型的泛化能力,改进算法被应用于印制电路板的表面缺陷检测,在测试集上的mAP达99.71%,相比原YOLOv4提升3.50%; Huang等<sup>[19]</sup>优化了YOLOv4中的PANet结构,扩展出新的浅层特征并与原特征层进行融合,同时轻量化网络模型,有效提高了小目标检测的精度与速度,与原始YOLOv4相比,改进算法在芯片表面缺陷测试集上的mAP增加了3.4%,检测速度获得29%的显著提升. 上述目标检测研究在提高模型识别准确率和效率方面都取得了初步成果,但对于对比度低、形态多变的微小目标仍然存在漏检、错检等问题.

本文将锂离子电池电极表面常见的3种缺陷(划痕、漏金属、孔洞)作为检测目标,实现了传统算法在电极表面缺陷检测的应用,达到一定的检测精度,但识别速度不够理想<sup>[20]</sup>. 在之前研究成果的基础上,本文针对电极表面纹理复杂、缺陷形态多变、微小缺陷占比较高问题,选择兼顾检测精度和速度的YOLOv4算法作为网络的基础框架,提出一种基于注意力机制与多尺度特征融合的电极缺陷YOLO检测算法,提高对微小缺陷的识别能力. 本文算法实现了对电极表面缺陷的精确、高效检测,可较好地满足实际工业生产的需求. 主要工作如下:

1) 针对微小电极缺陷特征损失严重的问题,将SE模块嵌入CSPnet的残差单元中,引入注意力机制区分不同通道之间的重要性,突出浅层网络包含的关键目标特征并削弱无关信息,提升算法对小目标的检

测性能。

2) 为解决SPP结构伴随图像分辨率损失的问题,采用ASPP(空洞卷积空间池化金字塔)模块代替原有SPP模块,增大卷积核感受野的同时更多地保留图像细节并增强信息相关性,微小缺陷的漏检、误检得到明显的改善。

3) 针对PANet对深浅层次特征的融合不够充分、不同尺度间的特征关联性弱,导致像素占比较低的微小缺陷识别效果较差的问题,提出稠密特征金字塔结构,在原YOLOv4三尺度特征层的基础上扩展特征检测尺度,引出一个新的蕴含更丰富细节信息的浅层特征,并以稠密连接的方式融合不同层次的特征图,增强模型的信息感知能力,有助于网络对小目标电极缺陷的识别。

4) 为获得更符合电极缺陷的先验框,提升网络训练的效率,采用K-means++算法对数据集标签进行聚类,生成符合缺陷数据分布的初始Anchor;针对锂电池电极正负样本数目不均衡、困难样本难以识别的问题,引入focal loss损失函数计算分类误差,调整正样本和难易样本的损失权重,提升网络的收敛速度与模型的识别精度。

### 1 电极缺陷YOLOv4检测存在的问题

YOLOv4将分类问题转化成回归问题,构建了一个训练门槛低的one-stage检测模型,实现了检测速度与准确率的最优平衡,是目前应用最广的表面缺陷检测模型之一。

尽管YOLOv4提出很多改进策略,但单阶段网络集成了缺陷的识别与定位,在提升检测速度的同时,对于微小、几何形态多变的缺陷无法兼顾检测精度。

待测电极缺陷中划痕缺陷形态多变,长短高宽不一,且与背景对比度较低,在提取特征时易受到周边环境的干扰,导致缺陷定位不够准确。孔洞缺陷相对过小且内部纹理与电极背景并无太大区别,但

YOLOv4网络结构只引出3个尺度的特征图,其中深层特征有利于类别信息的确认,浅层信息对位置信息更为敏感,FPN+PAN的特征融合方式并不适用于尺寸差异较大、微小目标占比较高的检测目标,导致原网络对细粒度特征提取不足,对小目标的检测存在大量漏检、错检等问题。YOLOv4的原始给定锚框不匹配电极缺陷,造成缺陷的定位和分类不准确。YOLOv4的分类误差采用交叉熵损失函数,难以解决本文数据集中难分类小目标样本较多的问题,不利于模型的收敛,影响缺陷识别的精度及准确率。

针对上述问题,结合电极缺陷数据集的特点,本文从增加注意力模块提升网络的特征提取能力、增强网络整体的感受野、构建有利于小目标缺陷识别的特征融合方式、选择合适的先验框及损失函数这4个方面,对YOLOv4算法进行改进,增强网络的学习能力,整体提高电极表面缺陷的检测精度及准确率。

### 2 改进的电极缺陷检测算法

结合本文数据集的具体情况,为解决电极表面缺陷存在分辨率低、尺寸微小、形态多变、纹理结构模糊等问题,满足电极表面缺陷检测的精度及准确率需求,本文在YOLOv4的基础上添加注意力机制,提出Attn-CSPDarknet53特征提取主干网络;添加ASPP模块以增加网络的感受野,构建稠密特征金字塔网络框架,加速信息流通的同时使浅层特征图包含更多的细节特征,增强对微小目标的检测能力;使用K-means++算法聚类合适的先验框, focal loss损失函数提高网络的收敛速度和检测精度。

该网络设定输入图像的尺寸为416×416,使用5个Attn-CSPnet模块,后4个模块输出特征图的分辨率分别为104×104、52×52、26×26、13×13,将其进行稠密连接,令4个尺度的特征图分别作为检测头的输入,可以满足尺寸跨度较大的目标检测。具体网络结构如图1所示。

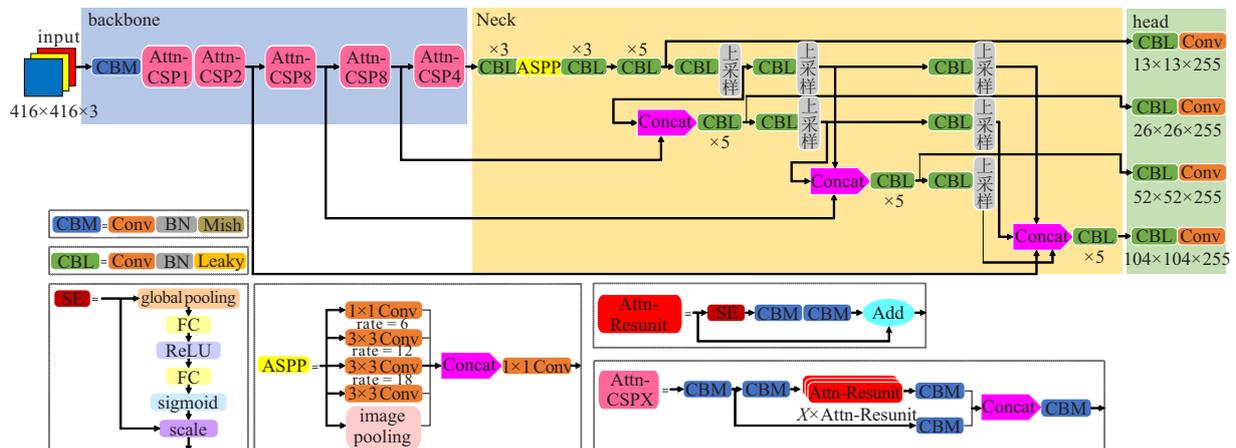


图1 改进的YOLOv4网络结构

### 2.1 嵌入注意力机制的主干网络

YOLOv4的backbone采用步长为2, 3×3大小的卷积核进行下采样, 该方式可以提取细粒度丰富的语义信息, 增加网络的感受野, 但同时也会导致小目标区域的特征信息丢失. 针对上述问题及电极图像的实际特征, 引入注意力机制以增强网络的表征能力.

#### 2.1.1 SE注意力模块

CSP-Darknet53是局部跨阶段残差网络, 每个CSPnet都是通过融合有限感受野范围内获取的空间特征和通道特征, 构建相应的特征向量, 但并未区分各个特征通道的重要性. SE注意力机制<sup>[21]</sup>可以解决卷积池化过程中由通道重要性差异所引起的信息损失问题, 因此引入SE模块增强网络的注意力, 突出关键特征.

SE模块结构图由压缩(squeeze)、激励(excitation)和scale三部分组成. 压缩操作将特征图通过全局平均池化进行空间维度上的压缩, 输出的维度和输入的

特征通道数一致. 激励操作通过两个全连接层, 使每个特征通道根据通道间的相关性生成一个权重, 其代表特征通道的重要程度. 最后的scale操作将权重分别加权到相应的特征值上, 完成根据通道的重要性对原始特征的重标定.

#### 2.1.2 改进后的CSPnet

SE模块插入的位置直接关系到网络的表征能力与学习能力. 若将注意力模块嵌入特征金字塔内或是检测头部分, 很难从融合后的feature map中区分出冗余信息与关键特征, 反而会导致信息传递的错误, 降低网络的特征提取能力. 对于主干的backbone, 浅层网络主要包含图像的细节特征, 这些细节特征的增强有利于小目标缺陷的检测. 此外, 网络层数的加深会导致区域的纹理信息与轮廓信息部分丢失, 因此本文选择将SE模块嵌入CSPnet的残差单元中, 先将特征图通过注意力机制突出关键特征, 弱化无关信息, 再经过残差操作深入提取特征, 最后合并输出. 改进后的Attn-CSPnet模块如图2所示.

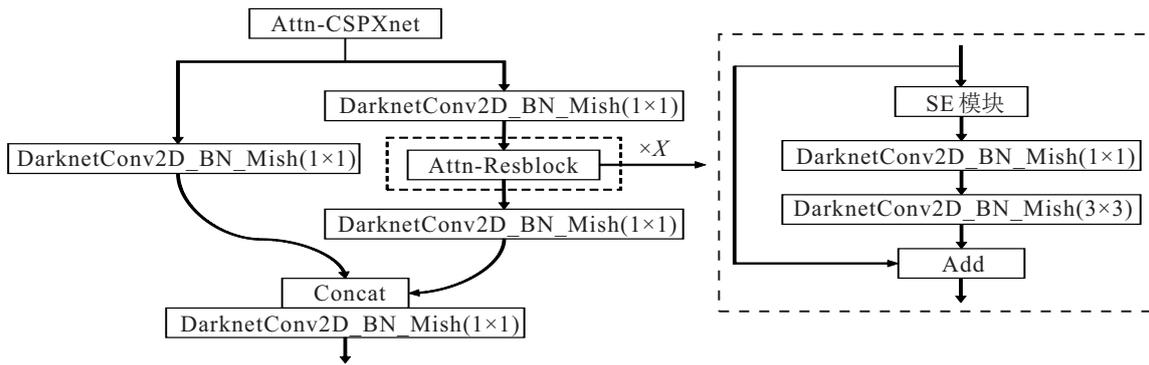


图2 添加SE后的CSPnet

### 2.2 空洞卷积池化金字塔

YOLOv4引入SPP结构, 对输入特征图进行多尺度采样并融合, 但伴随较为严重的图像分辨率损失, 增加整体网络对大小目标的识别难度. ASPP(空洞卷积空间池化金字塔)结构<sup>[22]</sup>可以在增大卷积核感受野的同时更多地保留图像细节信息, 以获得更精确的目标定位效果. 因此引入ASPP模块代替原有SPP模块, 获取更完整的局部特征, 提高网络对微小电极缺陷的识别能力.

ASPP模块由扩张率分别为1、6、12、18且卷积核为3×3的空洞卷积和图像池化层组成. 4种不同大小扩张率的空洞卷积并行运算, 可提供不同大小的感受野, 获取多尺度的特征信息. 扩张率对卷积层的感受野影响如下所示:

$$R = (r' - 1) \times (k - 1) + k. \quad (1)$$

其中:  $k$ 为卷积核大小,  $r'$ 为扩张率. 由式(1)可知感受野大小与扩张率成正比, 较大的感受野可捕获更多的特征信息, 但局部特征的提取难度也随之增大. 自适应均值池化层对图像进行全局特征信息提取, 再经 $1 \times 1$ 卷积后上采样恢复至输入特征图像大小. ASPP模块将不同尺度的特征信息与全局特征串接起来, 通过卷积操作调整输出通道数, 得到网络最终的输出特征图. ASPP模块改善了单一空洞卷积所带来的信息损失, 增强信息相关性的同时保留更多的图像特征, 提升对大小目标的检测效果.

### 2.3 稠密特征金字塔结构

原YOLOv4网络通过FPN+PAN结构对深浅特征进行融合, 分别按照原输入特征图的1/32、1/16、1/8输出特征层. 例如输入 $416 \times 416$ 的图像, 分别输出分辨率为 $52 \times 52$ 、 $26 \times 26$ 、 $13 \times 13$ 的3个不同尺度的

特征图. 该结构对FPN的信息进行重复使用,将不同层次的特征转化后相加,并未很好地融合各个尺度特征. 三尺度的PANet对于尺寸分布较广的目标检测效果较好,但对存在大量微小缺陷的电极表面无法达到良好的识别性能. 低分辨率的深层特征具有高级的语义信息,但对细节的感知能力较弱,在大目标检测方面起更大的作用;高分辨率的浅层特征包含更多的边缘信息和更强的几何表征能力,更适合小目标的识别. 因此,更好地利用浅层特征信息是提高微小缺陷检测效果的重要举措. 本文提出稠密特征金字塔结构,框架如图3所示. 首先扩展原YOLOv4

的三尺度特征层,从Attn-CSP2net引出一个尺寸为浅层特征,以获取更浅层的微小缺陷特征信息,见图3粗实线标注;接着借鉴DenseNet思想,将稠密连接<sup>[23]</sup>引入特征金字塔网络(FPN)<sup>[24]</sup>中,实现跨尺度融合深浅层特征,其在图3中用粗虚线标出. 为使上采样后的深层特征与浅层特征更好融合,用Concat操作代替Add,使每个尺度的输出特征层在保留当前尺度下较为完整的细节特征的同时融合较深层的语义信息. 稠密特征金字塔结构可以降低信息的冗余,获取更浅层特征信息,对微小缺陷的特征提取能力更强.

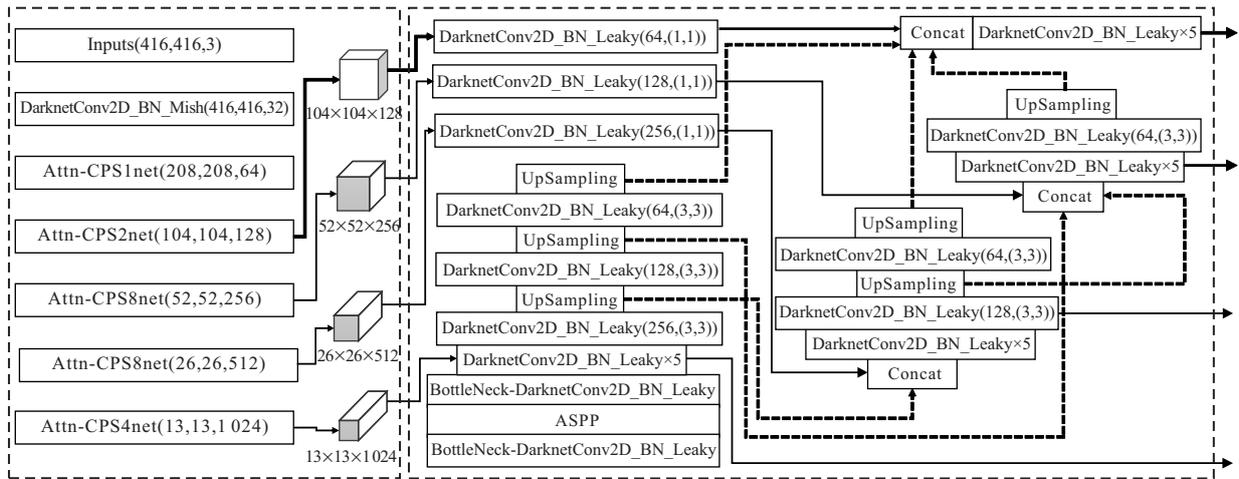


图3 稠密特征金字塔框架

2.4 先验框的优化设计

选取合适的先验框对提升网络训练效果有关键的作用. 由于电极表面缺陷微小,形态多变,原YOLOv4基于COCO数据集得到的初始先验框不能满足检测需求,且K-means算法随机选取初始值,聚类效果与稳定性不佳. 为降低先验框尺寸问题所造成的误差,本文选取K-means++算法<sup>[25]</sup>,对电极缺陷数据集标签进行聚类,生成12组不同宽高比的Anchor. 聚类结果如表1所示,该算法聚类效果更稳定,且生成的先验框更接近数据集实际大小分布.

表1 K-means++生成先验框

特征图	感受野	Anchor
13×13	大	(102, 53), (68, 83), (78, 128)
26×26	中	(42, 50), (50, 86), (37, 132)
52×52	小	(27, 34), (36, 35), (31, 44)
104×104	微小	(19, 26), (25, 28), (22, 35)

2.5 focal loss 损失函数

电极缺陷目标微小,其像素在整幅图像内的占

比较低,导致训练过程中正负样本数目不平衡. 原YOLOv4并未增加小目标损失权重在损失函数中的占比,导致微小缺陷训练效果差. 本文引入focal loss损失函数<sup>[26]</sup>计算分类误差,解决样本不平衡及困难样本等问题,公式如下所示:

$$FL(p_i) = -\alpha_i(1 - p_i)^\zeta \log(p_i). \tag{2}$$

$$\alpha_i = \begin{cases} \alpha, & y = 1; \\ 1 - \alpha, & \text{otherwise.} \end{cases} \tag{3}$$

$$p_i = \begin{cases} p, & y = 1; \\ 1 - p, & \text{otherwise.} \end{cases} \tag{4}$$

其中: $p$ 为样本预测概率; $\alpha$ 为平衡参数,例如若正样本数量较少,通过减小 $\alpha$ 可增大对错误样本的惩罚,从而改善样本的不平衡性; $\zeta$ 为聚焦参数,通过该调制因子聚焦难分样本,其增大可降低易分类样本权重,增大难以识别的小目标样本的损失比例. 本文中 $\alpha$ 取值0.25, $\zeta$ 取3,能有效提高网络学习的收敛速度,提升检测精度.

### 3 实验与结果分析

#### 3.1 平台搭建与模型训练

本文模型训练与测试采用的软件环境和硬件环境配置为: Windows10 操作系统, Tensorflow 深度学习框架, CUDA v11.2, Cudnn v8.1.1, OpenCV v4.5.5, CPU Intel i5-7300HQ@2.50 GHz, 16 GB RAM, GPU NVIDIA GeForce RTX 2080Ti.

由于本文原始数据集分辨率较高, 本实验设置输入图片的大小为 416×416, 模型训练时对图像进行缩放处理. 网络总共进行 100 次迭代, 其训练分两个阶段, 先冻结模型的前 249 层网络, 进行 50 个 epoch 的冻结训练, 设置 batch size 为 8, 学习率为 1e-3; 接着解冻主干网络, 迭代剩余的 50 个 epoch, 设此阶段的 batch size 为 4, 学习率为 1e-4. 每个 epoch 都更新一次学习率, 衰减率设为 0.94.

#### 3.2 消融实验

本文选取预测框与目标框的交并比 (IOU) 阈值大于 0.5 作为判定目标检测的标准, 平均精度 (AP)、平均精度均值 (mAP) 和每秒帧数 (fps) 作为模型的评

价指标.  $P$  为准确率, 表示正确预测的样本占有检测出目标的比例;  $R$  为召回率, 表示正确预测样本占有所有目标的比例; AP 为 P-R 曲线与坐标轴围成的面积. 计算公式如下所示:

$$P = \frac{TP}{TP + FP}, \tag{5}$$

$$R = \frac{TP}{TP + FN}, \tag{6}$$

$$AP = \int_0^1 P(R) dR, \tag{7}$$

$$mAP = \sum AP / n. \tag{8}$$

#### 3.3 评价指标

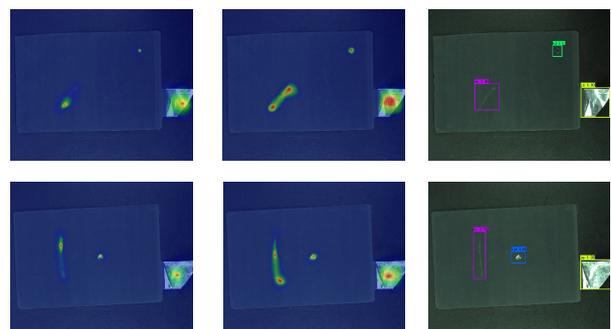
为更加全面分析 Attn-YOLOv4 中各个改进模块对于电极缺陷检测的优越性, 本文在原 YOLOv4 的基础上设计消融实验. 将改进后的主干网络、特征融合网络分别加入原 YOLOv4 中, 与原算法作为对照组, 具体实验内容与测试结果如表 2 所示, 其中 ★ 代表此项存在. 通过表 2 分析每项改进策略对本文网络的贡献, 从实验中发现, 每个模块对模型的整体性能都有不同程度的提升.

表 2 Attn-YOLOv4 的模块消融实验

模型	Attn-CSPnet	ASPP	稠密特征金字塔	K-means++	focal loss	AP/%				mAP/%
						划痕	漏金属	孔洞	极耳	
1						81.89	89.27	91.14	92.49	88.70
2	★					85.42	92.65	94.79	93.97	91.71
3		★				86.32	90.89	93.01	96.21	91.61
4			★	★		84.85	93.18	95.06	95.33	92.11
5			★	★	★	87.55	93.95	96.22	96.42	93.54
6	★	★	★	★	★	89.06	94.34	97.43	99.65	95.12

模型 2 在残差网络中引入 SE 注意力机制, 提升网络表征能力的同时突出关键特征, 有效解决电极图像背景纹理复杂导致特征提取困难、网络传播特征信息损失较大的问题. 为进一步验证该模型的优越性, 引入类激活图, 如图 4 所示, 红色区域对图像分为正类的贡献最大, 蓝色贡献最小. 易发现引入注意力机制后, 成功优化了网络对小目标的识别性能, 提升算法的 mAP 至 91.71%, 大大提高了网络的检测精度.

模型 3 将 YOLOv4 的 SPP 模块替换成 ASPP, 各个类别的 AP 都得到一定的提升, mAP 提高了 2.91%. 该模块扩大网络的感受野, 提升了对划痕缺陷、极耳这类较大目标的检测能力; 通过不同扩张率的空洞卷积, 较原 YOLOv4 算法, 减少特征信息的损失, 保留更多的细节特征, 改善了对孔洞、漏金属这类微小目标的特征提取效果, 有效提高了网络整体性能.



(a) 原 YOLOv4 (b) 嵌入注意力模块后的 YOLOv4 (c) 检测结果

图 4 引入注意力机制前后的类激活图

通过各个实验结果对比发现, 模型 4 的稠密特征金字塔与 K-means++ 对提升细小孔洞缺陷和漏金属缺陷的精度有着更积极的影响, 这两类缺陷的 AP 提升了 4 个百分点, 整体检测精度提升 3.41%. 该模块通过扩展特征层的尺度, 增强各个特征层中的细节信

息;引入稠密连接提升高级语义信息与浅层几何特征的融合能力,降低信息冗余的负面影响;重新设计更匹配电极缺陷的先验框,更适应网络框架四尺度特征层的情况,从而大大提升模型对像素占比较低的两种缺陷的识别能力,解决微小缺陷的漏检错检问题,但对于形状细长多变且标注框较大的划痕缺陷,稠密特征金字塔的新增特征层会导致参数冗余,使划痕缺陷的精度提升较低。

模型5在模型4的基础上引入 focal loss 损失函数作为分类误差,进一步提升 mAP 值,从 92.11% 提升至 93.54%。对于边缘模糊的漏金属、划痕缺陷,损失函数中的聚焦参数可以增大这些困难样本的损失值,对于目标微小的孔洞、漏金属缺陷,平衡参数会增大预测错误的惩罚,二者结合从而达到整体检测精度的提升。

通过消融实验的对比发现,加入各个改进模块后的模型6,即本文所提的 Attn-YOLOv4 的性能提升最为显著,本文算法对边缘不清晰的待测缺陷、像素占比低的微小目标的漏检误检问题有很大的改善,4类检测目标都取得良好的检测效果,平均检测精度值提升了 6.42%,验证了本文算法对电极表面缺陷识别的有效性。

### 3.4 性能对比

为进一步验证本文所提 Attn-YOLOv4 的优越性,将该算法与目前缺陷检测领域常见的几种经典算法进行比较,包括 two-stage 检测器中针对微小目标检

测效果优越的基于柔性非极大值抑制与特征金字塔的 faster R-CNN<sup>[27]</sup>,以及 one-stage 检测器中综合性能较好的 YOLOv4、YOLOv4-tiny。对比实验选取 mAP 与 fps 作为各算法的评价指标,在本文数据集上设置相同的超参数进行模型的训练与测试,检测结果如表 3 所列,图 5 了给出不同算法的缺陷识别效果。

表 3 不同算法的检测性能对比

model	backbone	mAP/ %	fps
改进的 fast R-CNN	Resnet50	86.70	10.13
YOLOv4	CSPDarknet53	88.70	27.53
YOLOv4-tiny	CSPDarknet53-tiny	77.83	40.26
Attn-YOLOv4	Attn-CSPDarknet53	95.12	24.91

结合表 3 与图 5 分析可知,改进的 faster R-CNN 作为较先进的两阶段检测算法,其对微小电极缺陷具有一定的检测能力,除部分划痕缺陷的标定稍有偏差外,各类缺陷的预测框的定位与大小基本正确且类别判断无误,但实时性远远达不到实际生产需求。单阶段算法 YOLOv4 相比改进的 faster R-CNN 识别准确率有一定的提高,各类别缺陷的预测范围更贴近真实值,形态多变的划痕缺陷的定位精度相对较高,同时检测速度显著提升了 2.5 倍以上,算法的总体性能得到大幅优化。YOLOv4-tiny 在 YOLOv4 算法的基础上轻量化网络结构,极大地提高模型的识别速度, fps 达到近改进的 faster R-CNN 的 4 倍,但存在 mAP 严重降低的问题。观察图 5 发现该算法划痕缺陷整体检测效果较差,漏金属缺陷也有个别样本未被检出,存

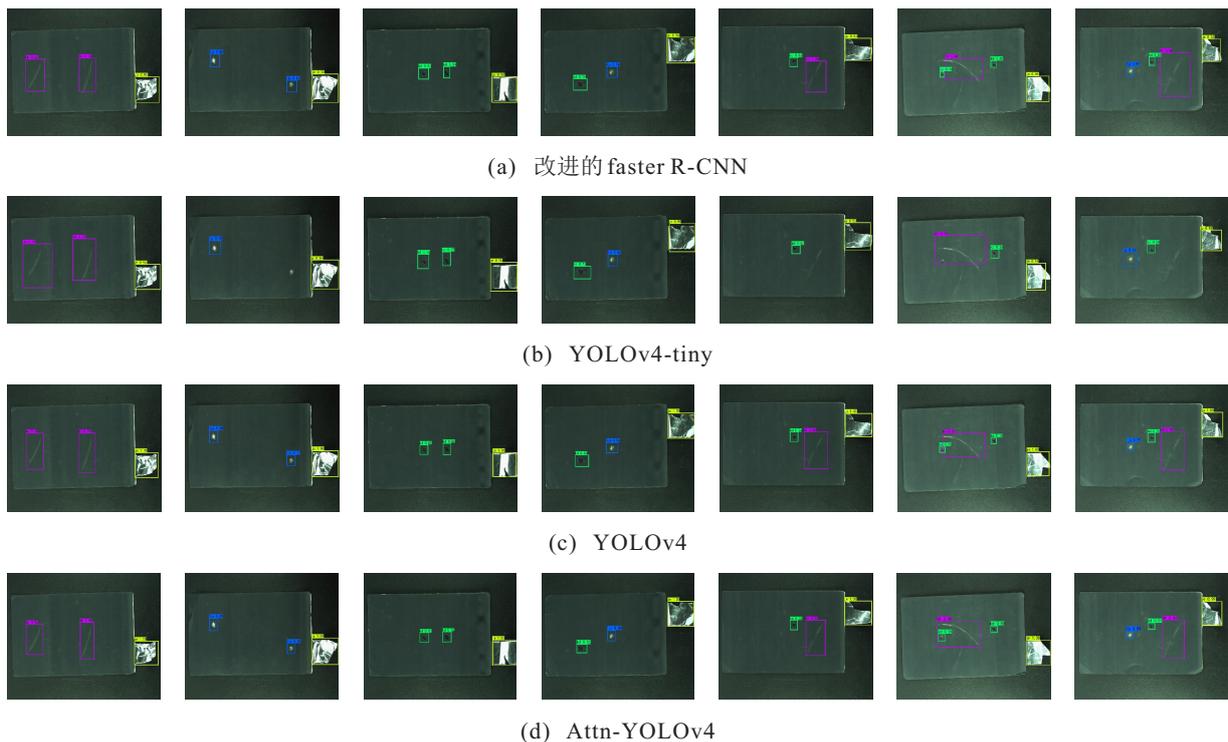


图 5 不同检测算法的检测结果

在明显的缺陷漏检与定位偏差现象,无法满足电极生产环节对缺陷检测准确率的要求. 本文提出的Attn-YOLOv4在上述4种算法中mAP表现最为优秀,相比改进的faster R-CNN、YOLOv4、YOLOv4-tiny分别提升了8.42%、6.42%、17.29%. 由图5可见本文算法的预测框最接近实际缺陷的位置和大小分布,且置信度最高,对于其他常见算法均表现不佳的划痕缺陷也表现出更令人满意的识别效果;Attn-YOLOv4的fps与原YOLOv4相比略有降低,但仍远超改进的faster R-CNN,能够满足锂电池电极生产中高精度高速度的需求. 结合上述实验结果,本文提出的Attn-YOLOv4算法是一种兼具检测精度和实时性的锂电池电极表面缺陷检测算法,综合性能十分优越,具有较高的应用价值.

## 4 结论

针对YOLOv4算法对电极表面缺陷检测出现的小目标漏检、误检等问题,本文提出一种基于注意力机制与多尺度特征融合的电极缺陷YOLO检测算法,实现对电极缺陷的精准定位和识别. 该模型在主干网络中加入注意力模块,提升网络的表征能力;结合空洞卷积改进空间池化金字塔,增大网络感受野的同时有效保留图像的细节特征;设计稠密特征金字塔框架扩展特征层尺度的同时提高深浅层特征的融合能力,增加丰富的边缘细节信息;引入K-means++算法优化先验框,应用focal loss损失函数计算分类误差,降低正负样本不均衡和难易样本对检测精度的影响.

实验结果表明,本文所提模型在自建数据集中的mAP值达到95.12%,且fps保持在24.91,能够精确快速地检测出对比度较低、形态多变、边缘模糊、尺寸微小的电极表面缺陷. 相较于其他几种常用模型,本文YOLO算法在综合性能上有着较大的优势,可满足实际生产中电极表面检测的速度和精度需求. 后续应在保证算法精度的同时进行网络轻量化并提升算法的泛化能力,使其能够广泛应用于各个类型的电池电极缺陷的实时检测中.

## 参考文献(References)

[1] 田慧欣, 秦鹏亮, 李坤, 等. 基于HI-DD-AdaBoost.RT的锂离子动力电池SOH预测[J]. 控制与决策, 2021, 36(3): 686-692.  
(Tian H X, Qin P L, Li K, et al. Prediction of Li-ion battery SOH based on HI-DD-AdaBoost.RT[J]. Control and Decision, 2021, 36(3): 686-692.)

[2] Bockholt H, Indrikova M, Netz A, et al. The interaction of consecutive process steps in the manufacturing of lithium-ion battery electrodes with regard to structural and electrochemical properties[J]. Journal of Power Sources, 2016, 325: 140-151.

[3] Lai X, Jin C, 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: 470-499.

[4] Xiong R, Sun W, Yu Q, et al. Research progress, challenges and prospects of fault diagnosis on battery system of electric vehicles[J]. Applied Energy, 2020, 279: 115855.

[5] Chang M, Chen B C, Gabayno J L, et al. Development of an optical inspection platform for surface defect detection in touch panel glass[J]. International Journal of Optomechatronics, 2016, 10(2): 63-72.

[6] Xu C L, Li L S, Li J W, et al. Surface defects detection and identification of lithium battery pole piece based on multi-feature fusion and PSO-SVM[J]. IEEE Access, 2021, 9: 85232-85239.

[7] Liu Y, Chen Y, Xu J M. An automatic defects detection scheme for lithium-ion battery electrode surface[C]. International Symposium on Autonomous Systems (ISAS). Guangzhou, 2020: 94-99.

[8] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition. Columbus, 2014: 580-587.

[9] Girshick R. Fast R-CNN[C]. IEEE International Conference on Computer Vision. Santiago, 2015: 1440-1448.

[10] Ren S 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, 2017, 39(6): 1137-1149.

[11] Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, 2016: 779-788.

[12] Redmon J, Farhadi A. YOLO9000: Better, faster, stronger[C]. IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, 2017: 6517-6525.

[13] Redmon J, Farhadi A. Yolov3: An incremental improvement[J/OL]. 2018, arXiv: 1804.02767.

[14] Cao X K, Zhang F W, Yi C D, et al. Wafer surface defect detection based on improved YOLOv3 network[C]. The 5th International Conference on Mechanical, Control and Computer Engineering (ICMCCE). Harbin, 2020:

- 1475-1478.
- [15] Lan Z, Hong Y, Li Y. An improved YOLOv3 method for PCB surface defect detection[C]. IEEE International Conference on Power Electronics, Computer Applications. Shenyang, 2021: 1009-1015.
- [16] 柳长源, 王琪, 毕晓君. 多目标小尺度车辆目标检测方法[J]. 控制与决策, 2021, 36(11): 2707-2712.  
(Liu C Y, Wang Q, Bi X J. Multi-target and small-scale vehicle target detection method[J]. Control and Decision, 2021, 36(11): 2707-2712.)
- [17] Bochkovskiy A, Wang C Y, Liao H. YOLOv4: Optimal speed and accuracy of object detection[J/OL]. 2020, arXiv: 2004.10934.
- [18] Xie H F, Li Y, Li X C, et al. A method for surface defect detection of printed circuit board based on improved YOLOv4[C]. The 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering. Nanchang, 2021: 851-857.
- [19] Huang H X, Tang X D, Wen F, et al. Small object detection method with shallow feature fusion network for chip surface defect detection[J]. Scientific Reports, 2022, 12: 3914.
- [20] 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.  
(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.)
- [21] Hu J, Shen L, Albanie S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [22] Chen L C, Papandreou G, Kokkinos I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834-848.
- [23] Liu L, Nian Z C, Jung C. DCM-CNN: Densely connected multiloss convolutional neural networks for light field view synthesis[J]. IEEE Access, 2020, 8: 78542-78552.
- [24] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, 2017: 936-944.
- [25] Esteves R M, Hacker T, Rong C M. Competitive  $K$ -means, a new accurate and distributed  $K$ -means algorithm for large datasets[C]. The 5th International Conference on Cloud Computing Technology and Science. Bristol, 2013: 17-24.
- [26] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 318-327.
- [27] Li L, Jiang Z J, Li Y N. Surface defect detection algorithm of aluminum based on improved faster RCNN[C]. The 9th International Conference on Information, Communication and Networks. Xi'an, 2021: 527-531.

## 作者简介

李雅雯(1999—), 女, 硕士生, 从事图像处理、深度学习在锂电池电极缺陷检测的应用等研究, E-mail: 1642595556@qq.com;

孙浩然(1998—), 女, 硕士生, 从事图像处理、深度学习在锂电池电极缺陷检测的应用等研究, E-mail: 1124473655@qq.com;

胡跃明(1960—), 男, 教授, 博士, 从事先进制造、视觉检测与智能控制等研究, E-mail: auymhu@163.com;

韩有军(1987—), 男, 高级工程师, 博士生, 从事锂离子电池智能制造信息系统、人工智能技术在锂电池制造过程的应用等研究, E-mail: hanyoujun@gzjit.ac.cn.