

DOI:10.19651/j.cnki.emt.2209198

# 基于改进 YOLOv4 的锂电池缺陷检测方法<sup>\*</sup>

桂久琪 李林升 毛晓 王庆秋  
(上海电机学院电气学院 上海 201306)

**摘要:** 针对传统方法检测锂电池表面缺陷精度低、速度慢的问题,提出一种改进的 YOLOv4 算法。首先,在 CSPDarknet-53 骨干网络中使用空洞卷积代替传统卷积,提高了对不同尺度缺陷的检测。其次,将通道注意力机制插入到颈部网络中,自适应地选择一维卷积核的大小,降低模型的复杂度和计算量。最后,在分类和边界框回归中融合条件卷积来提高网络性能,并扩大数据集以解决由于缺陷样本太少而导致的网络训练过拟合问题。实验结果表明,改进后的 YOLOv4 算法可以有效检测锂电池表面缺陷并提高对于缺陷的识别和定位能力。改进算法的平均精度均值为 93.46%,相较原算法提高了 3.03%。

**关键词:** 深度学习;锂电池;缺陷检测;YOLOv4

中图分类号: TP391.41; TN29 文献标识码: A 国家标准学科分类代码: 510.4

## Lithium battery defect detection method based on improved YOLOv4

Gui Jiuqi Li Linsheng Mao Xiao Wang Qingqiu  
(School of Electrical Engineering, Shanghai Dianji University, Shanghai 201306, China)

**Abstract:** Aiming at the problems of low accuracy and slow speed in the detection of surface defects of lithium batteries by traditional methods, an improved YOLOv4 algorithm is proposed. Firstly, a dilated convolution is used to replace the conventional convolution in the CSPDarknet-53 backbone network, which improves detection of defects of different scales. Secondly, an efficient channel attention is inserted into the neck network to adaptively select the size of the one-dimensional convolution kernel to reduce the complexity and computations of the model. Finally, a conditional convolution is fused in classification and bounding box regression to improve the network performance, and the data set is expanded to solve the problem of network training overfitting caused by too few defective samples. The experimental results show that the improved YOLOv4 algorithm can effectively detect the surface defects of lithium batteries and improve the ability to identify and locate surface defects of lithium batteries. The mean average precision of the improved algorithm is 93.46%, which is 3.03% higher than the original algorithm.

**Keywords:** deep learning;lithium battery;defect detection;YOLOv4

## 0 引言

随着微电子产业的技术发展,小型电器设备对电源提出了较高要求,由此锂电池得到逐步广泛应用。作为组成锂电池的关键部分,锂电池的极耳和极片在生产制造的过程中极易出现气泡、压痕、破损等缺陷<sup>[1-2]</sup>,这对锂电池的安全产生极大影响。因此,采用有效的目标检测方法对锂电池表面缺陷的精识别与快速定位具有重大研究意义。传统人工检测易受主观因素影响,漏检率较高,不利于现代化生产<sup>[3-4]</sup>,所以应用被大大限制,而以深度学习为代表的新兴技术因其高效的自动化性能被广泛应用与研究。

很多学者利用卷积神经网络与计算机视觉的缺陷检测

方法实现了特征识别与分类。周佳禾等<sup>[5]</sup>针对 X 射线下锂电池电极缺陷的表现特点,提出了一种基于卷积神经网络与支持向量机的锂电池电极缺陷检测方法,检测的准确性优于 99%。封学勇<sup>[6]</sup>利用优化过的 Cascade R-CNN 对柱形锂电池钢壳表面缺陷进行检测,检测时间最短为 31 ms,平均漏检率为 6.21%。许海彪<sup>[7]</sup>采用 K-means 聚类对锂电池壳表面缺陷数据集的先验框数值进行优化,通过消融法简化网络复杂度,提出新的网络模型 YOLOv3-x,检测速度与精度均有显著提升。王延年等<sup>[8]</sup>针对太阳能电池缺陷分割提出一种改进的 U-Net 方法,引入密集连接结构及双注意力通道机制,同时添加批归一化层与激活层,显

收稿日期:2022-03-08

\* 基金项目:湖南省教育厅重点资助项目(15A160)资助

著提升模型检测精度。

随着模式识别、机器视觉、深度学习<sup>[9]</sup>的不断发展,卷积神经网络的视觉图像检测已经逐渐成熟<sup>[10]</sup>。YOLO<sup>[11]</sup>(you only look once)系列模型在众多模型中脱颖而出,该模型将生成候选框和分类回归集中在一个网络中,虽然能够显著提高检测速度,但检测精度相对较低。为了解决上述问题,YOLO 的一系列衍生模型被提了出来,如今提出的 YOLOv4<sup>[12]</sup>虽然能较好地兼顾检测速度与精度,但实际应用的精度仍然无法达到要求。针对上述问题,本文基于 YOLOv4 模型,在锂电池极耳与极片缺陷检测的应用场景下,提出了一种新的检测算法,本算法首先对采集到的数据进行预处理及增强,在主干网络第四次下采样加入空洞卷积,扩大感受野,提高对不同尺寸目标的特征提取能力。同时在颈部网路插入轻量级通道注意力机制,一维卷积核自适应生成,并在局部跨信道交互时保持维度,增强特征信息。最后在输出部分利用集成式条件卷积,减少计算开销,提升模型性能。试验结果表明本文提出的算法不仅可以保证锂电池表面缺陷检测的实时性,而且可以保证对不同尺寸、不同类别锂电池缺陷的检测精度,可以为今后锂电池工业生产提供一定的参考价值。

本文提出的检测算法主要分为数据集构建,模型训练及缺陷检测模块。在数据集构建模块,本算法对 CCD 相机采集的锂电池缺陷图像进行图像预处理及数据增强,接着对处理完成的图像进行标注并构建成数据集,随后将数据集输入到模型中对模型参数进行训练,最终训练好的模型

会被部署到缺陷检测模块,测试模型的实际检测结果。

## 1 基于改进 YOLOv4 的锂电池表面缺陷检测方法

### 1.1 YOLOv4 基本原理

YOLO 系列模型网络结构采用端到端的模式,在产生候选区域的同时完成分类和位置调整,使计算资源能够得到充分利用,节约目标检测时间。YOLOv4 是 YOLO 系列的衍生版本之一, YOLOv4 模型主要改进了骨干网络 CSPDarknet53<sup>[13]</sup>,该部分由 CBM 模块和 CSP 模块组成。CSPDarknet53 在 Darknet53 的基础上进行了改进,可以更好地提升网络性能,减少计算瓶颈,提高内存利用率。其中,CBM 模块包括卷积层、批归一化层和 Mish 激活函数,相较于原先系列中的 Leaky ReLU 函数,曲线更为平滑,能更好地深入神经网络,从而提高准确性与泛化能力。YOLOv4 的颈部网络由空间金字塔池化<sup>[14]</sup>(spatial pyramid pooling, SPP)、特征金字塔网络<sup>[15]</sup>(feature pyramid network, FPN)与路径汇聚网络<sup>[16]</sup>(path aggregation network, PAN)组成,经过 5 次下采样,将输出的  $13 \times 13$  特征图经过  $3 \times 3$  的卷积核处理后送入 SPP 模块,再经过 4 个不同尺度的最大池化处理后,输出大小分别为  $13 \times 13, 9 \times 9, 5 \times 5, 1 \times 1$  的卷积核。最后通过自下而上的路径增强结构,缩短信息流通路径,提高底层信息流通速度。在边界框的预测方式上将不同层级的特征进行融合,最后进行输出预测结果。YOLOv4 结构如图 1 所示。

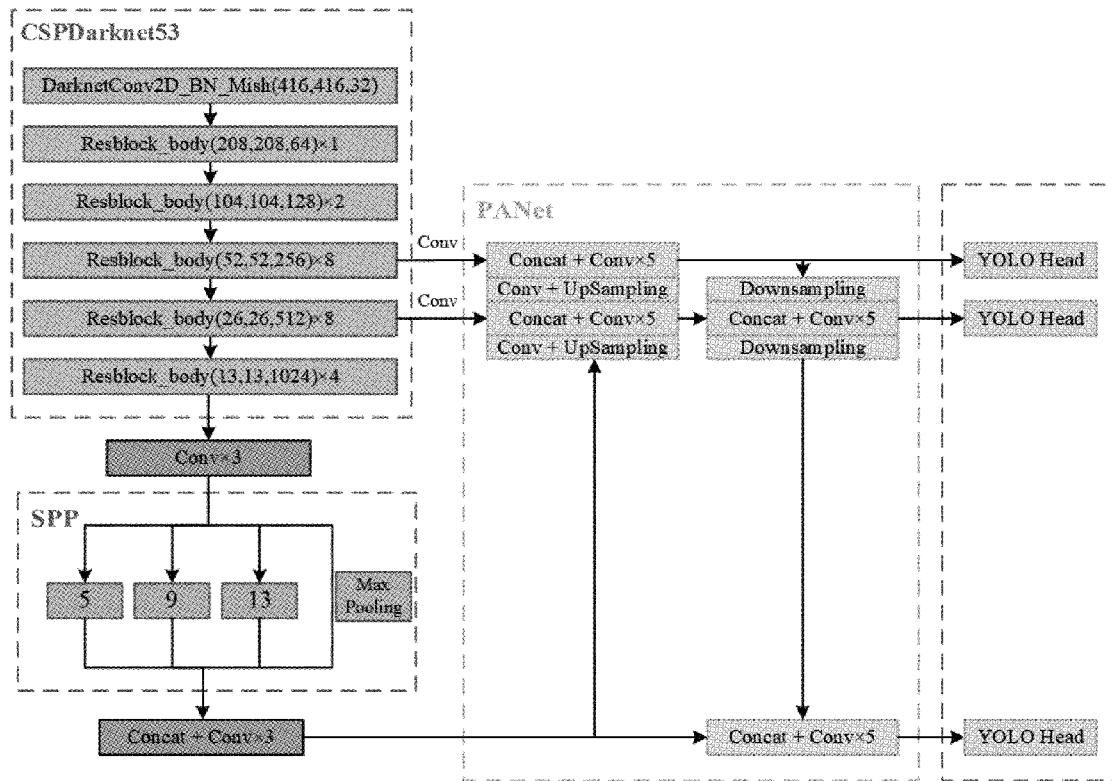


图 1 YOLOv4 结构

## 1.2 模型改进及优化

### 1) 融合空洞卷积

在图像分割任务中,通过池化层压缩含有不同语义信息的特征图,卷积层则主要用来提取边缘信息与图像特征。因此特征图缩小再放大的过程会引起图像特征信息无法完全提取。为了获得可靠的语义信息,一些目标检测器叠加越来越多的池化和降采样操作,使得在前向传播中逐渐丢失微小目标特征,因此降低了对多尺度目标的检测性能。由于锂电池表面背景单一,缺陷尺寸相差较大,针对微小缺陷,普通卷积神经网络无法敏感识别,因此本文在骨干网络中引入空洞卷积<sup>[17]</sup>(dilated convolution),空洞卷积可以在保证参数量不增加的同时提高输出感受野范围的新型卷积结构,在卷积核内部加入的空洞个数被称为扩张率。为了不丢失锂电池表面的细微缺陷特征,在图像分割时利用空洞卷积代替传统卷积采样操作,在增加感受野的同时保证特征图的尺寸不变。特征图的输出大小如式(1)所示。

$$V_{\text{out}} = \frac{V_{\text{in}} + 2P - F}{S} - 1 \quad (1)$$

其中,  $V_{\text{out}}$  为输出特征图的尺寸;  $V_{\text{in}}$  为输入特征图的尺寸;  $F$  为卷积核的大小;  $P$  为特征图填充的圈数;  $S$  为卷积的步长。为了适应锂电池表面尺寸大小不一的缺陷数据,本文在传统卷积的基础上加入了空洞卷积,改进后的结构如图 2 所示。

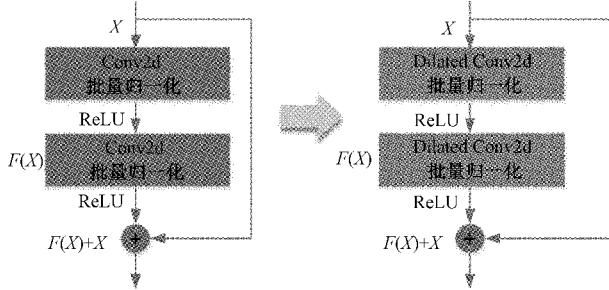


图 2 原始残差块与改进后残差块示意图

在特征转移层中通过调整扩张率来控制数据之间的距离,在保持特征分辨率的基础上,扩大网络输出的感受野,获取更多的图像特征信息,使得每次输出的特征图都包含大量的语义信息。设置的扩张率越大,其对应的卷积核与特征提取感受野越大。由图 3 可以看出,通过设置不同的扩张率, $3 \times 3$  卷积的感受野可以扩大至 $5 \times 5$ 、 $7 \times 7$  的效果。

假设  $K$  为空洞卷积的卷积核,  $D$  为空洞率, 则等效卷积核  $K'$  如式(2)所示。

$$K' = (D-1) \times (K-1) + K \quad (2)$$

本文需要检测的缺陷目标尺寸相差较大, 替换主干网络 CSPDarknet53 的底层网络效果不明显, 因此本文在第 4 次下采样时加入空洞卷积, 扩大感受野, 第 5 次再进行普

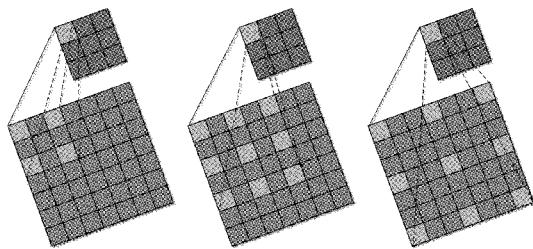


图 3 空洞卷积

通卷积时就可以保持网络维度一致, 避免丢失微小的缺陷特征, 在不增加多余计算量的前提下能更好提高网络对不同尺度目标的检测效果。

### 2) ECA-Net 注意力通道机制

通道注意机制是增强神经网络深度的有效手段之一, 然而为了获取更好的网络性能, 大多数选择叠加多种注意模块, 这会直接加剧模型的复杂程度。目前主流的 CBAM 注意力机制虽然可以同时作用于空间与通道, 但由于计算相互独立, 导致模型整体计算时间和计算量剧增。基于此, 本文融合一种通道注意力机制 ECA-Net<sup>[18]</sup>, 该模块沿用了 SENet 的部分结构, 主要改进点在于自适应选择一维卷积核的尺寸, 并在局部跨信道交互时保持维度, 降低网络复杂度, 提升模型性能。其工作原理如图 4 所示。其中  $H$  为图像的高度,  $W$  为宽度,  $C$  为通道维数。

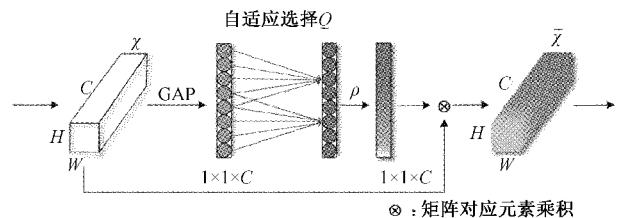


图 4 ECA-Net 结构

首先输入原始特征图片, 对原始图片的所有通道全局平均池化(global average pooling, GAP)处理后, 再利用大小为  $Q$  的快速一维卷积产生通道权值, 计算出不同通道的对应概率后再与原始输入特征相乘, 作为下一层的输入。该方法通过函数自适应的方式确定  $Q$  值, 其取值与通道维数  $C$  成正比, 如式(3)、(4)所示。

$$C = \phi(Q) = 2^{(\lambda * Q - b)} \quad (3)$$

$$Q = \psi(C) = \left| \frac{\log_2(C)}{\lambda} + \frac{b}{\lambda} \right|_{odd} \quad (4)$$

其中,  $| \cdot |_{odd}$  表示最近的奇数,  $\lambda = 2, b = 1$ 。ECA-Net 结构灵活轻便, 可以自适应选择一维卷积核, 避免降维直接进行跨信道交流, 增强特征图中有用的语义信息, 剔除冗余无效信息, 提高对锂电池表面缺陷特征的有效提取, 使卷积神经网络性能上有所提升, 能够更适应本文样本。

### 3) 集成式条件卷积

目前, 模型尺寸与容量的提升及数据集的扩容使得卷

积神经网络的性能得到显著优化,然而模型尺寸的增加却进一步加剧了神经网络的计算量和优秀模型的部署难度,往往改进后的实际检测也不能达到预期效果。

由于锂电池缺陷特征的背景简单,噪声较多,破损与气泡缺陷形态较为类似,难以区分,所以对一般静态卷积特征提取的敏感度不佳。因为条件卷积<sup>[19]</sup>(conditionally convolutions)更为灵活,所以本文在 YOLO Head 部分利用条件卷积替代传统卷积。在常规静态卷积层中,卷积核是固定不变的,同样的卷积核要应用于每个特征。为了提升模型的性能,往往会叠加更多层卷积增强信息的提取能力,或改变卷积核的大小及通道维数,这样就会使计算变得复杂,内存占用更多,降低实时检测效率。在条件卷积层中,卷积核作为输入示例的函数来计算,集成多个分支,使每个卷积层拥有多套权重,最终加权求和。集成后的输出可以通过式(5)得到:

$$Output(x) = \sigma((\alpha_1 \cdot W_1 + \dots + \alpha_n \cdot W_n) * x) \quad (5)$$

其中,  $x$  为上一层输出,  $n$  表示这一层条件卷积中有  $n$  个卷积核  $W$ ,  $\sigma$  为激活函数,  $r_i = \alpha_i$  表示样本依赖的可训练的加权参数。在卷积之前,根据上一层输出的  $x$ ,通过路由函数计算出每一个卷积核  $W$  的系数  $\alpha_i$ ,再通过线性组合得到条件卷积层的卷积核,最后与输入  $x$  做卷积。路由函数赋予参数  $W_i$ ,计算方式如式(6)所示。

$$r(x) = Sigmoid(GAP(x)R) \quad (6)$$

对输入  $x$  做全局平均池化处理,再与矩阵  $R$  相乘,使得维度映射到每一个卷积核  $W$ ,为后续实现线性组合提供条件,最后  $Sigmoid$  激活函数限制每个维度的加权值在  $[0,1]$  之间。根据输入的  $x$  不同,得到的路由函数也有所差异,因此每个条件卷积层的卷积核大小也不相同。条件卷积流程如图 5 所示,集成后计算开销明显减少,体现了这种设计的优越性。

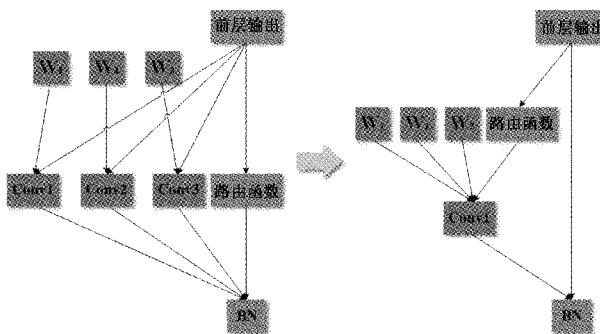


图 5 条件卷积结构

## 2 实验与结果分析

### 2.1 数据集与数据预处理

锂电池表面缺陷图像通过工业 CCD 相机采集,分为极耳和极片 2 个部分。受制于工业生产技术,锂电池的极耳与极片表面会出现多种缺陷。本文根据缺陷形态定义了 4

种类型:极耳异常(abnormal-areas)、气泡(bubble)、压痕(indentation)与破损(damage),标准锂电池极耳与极片图像与典型缺陷类型如图 6 所示。

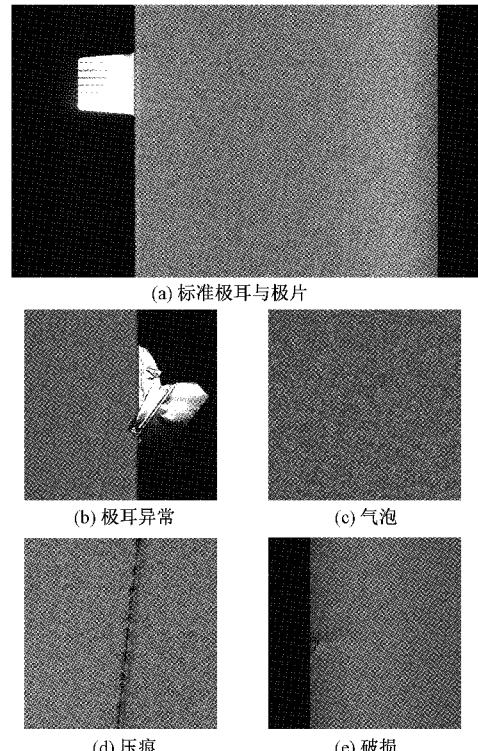


图 6 标准锂电池与典型缺陷示例

本文共采集含缺陷的锂电池图像 520 张,无法保证每种缺陷样本数量达到要求,故进行数据增强处理。通过对原始图像进行随机尺度变换、随机翻转、对比度调节等处理,可以有效避免模型训练时过拟合,提升模型的泛化能力和鲁棒性<sup>[20]</sup>。数据增强后,数据集共有缺陷图像 2 080 张,这些图像包含一处或多处缺陷,本文将锂电池表面缺陷图像按照 8 : 2 的比例随机分为训练集与测试集。训练数据使用标注软件 LabelImg 人工标注(如图 7 所示),并生成相应的 xml 文件。

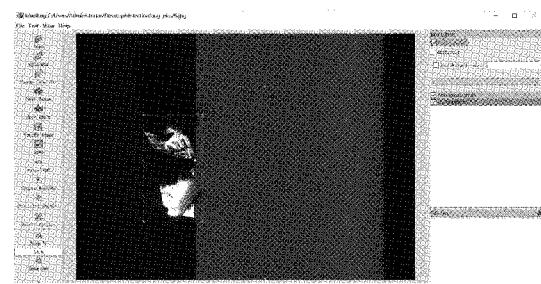


图 7 锂电池表面缺陷样本数据标注

### 2.2 网络训练

本文在 64 位 Windows 10 操作系统下采用 Pytorch 框架搭建网络,硬件环境如下:Intel Xeon E5-2630L v3 处理器,16 GB RAM, GPU 为 GTX 2080Ti(显存为 12 GB)。

对极耳异常、气泡、压痕及破损这 4 类缺陷的样本图像分别进行标定之后,生成对应的 xml 格式标记文件。基于 YOLOv4 网络进行改进并搭建深度学习模型,设置训练样本时的一批样本数为 16,动量参数为 0.9,权重衰减正则项为 0.0005,最大迭代次数为 2500。图 8 为训练过程,随迭代次数的增加,损失函数的实时变化情况。

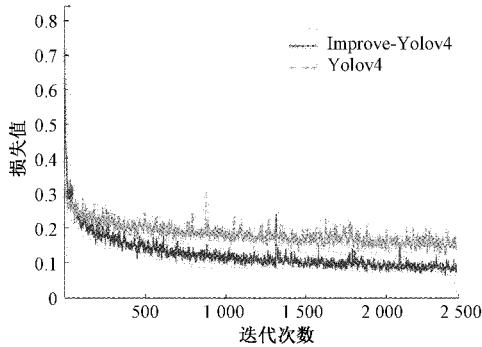


图 8 算法改进前后训练结果

通过分析图 8 可知,改进后的 YOLOv4 模型最终损失函数值明显低于原模型。在迭代进行到 1500 次时损失趋于稳定,loss 值稳定在 0.1 左右,有较好的收敛性,未发生过拟合现象,训练效果较为理想。

### 2.3 评价指标

为了定量评估本文改进的网络的性能,采用目标检测中常用的召回率(recall)、精确率(precision)、平均精度(average precision, AP)、平均精度均值(mean average precision, mAP)和每秒帧数(frames per second, FPS)来评价检测锂电池表面缺陷的效果。式(7)表示召回率的计算,式(8)表示精确率的计算,式(9)表示平均精度均值的计算。

$$Recall = \frac{T_p}{T_p + F_N} \quad (7)$$

$$Precision = \frac{T_p}{T_p + F_p} \quad (8)$$

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

其中,  $T_p$  为被正确分类的正样本数;  $F_p$  为被错分为正样本的负样本数;  $F_N$  为被错分为负样本的正样本数;  $\beta$  为缺陷样本种类的数量。利用每一张图像的召回率及精确率来确定每一类别的平均精度 AP,每类 AP 的均值即为平均精度均值 mAP,该参数可以反映模型对锂电池表面缺陷的检测性能。每秒帧数 FPS 则可以反映每秒检测图片的数量,即模型目标检测时的速度。

### 2.4 实验结果分析

为验证本文改进的 YOLOv4 模型实际检测效果,将其与 3 种模型进行可视化对比。图 9(a)为 SSD 模型识别效果,图 9(b)为 YOLOv3 模型识别效果,图 9(c)为原

YOLOv4 模型识别效果,图 9(d)为本文提出的改进的 YOLOv4 模型识别效果。

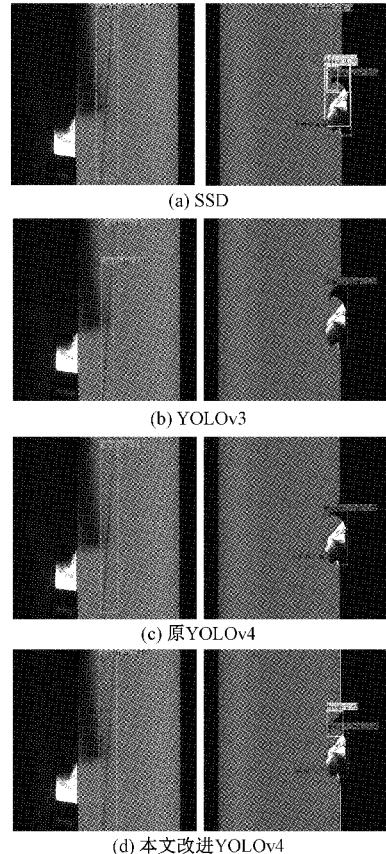


图 9 4 种模型识别效果

针对同一张缺陷图像,如图 9(a)所示,可以看到 SSD 模型针对锂电池表面缺陷检测图像分割性较差,在密集缺陷的区域误检率较高,缺陷相似时则无法有效识别,不能准确区分极片区域的破损与极耳部分异常。如图 9(b)所示,YOLOv3 模型在图像分割任务中表现不佳,将同一连贯的压痕缺陷分割成两部分。同时,对于微小的缺陷例如气泡,也无法有效识别。如图 9(c)所示,原 YOLOv4 模型虽能较为准确地检测出锂电池表面的多种缺陷,但不能完整分割出缺陷的全部区域,且在相似缺陷的区域时容易发生漏检,未能识别出图像边缘的破损缺陷,有一定漏检率。而本文提出的改进的 YOLOv4 模型不仅能够有效识别出四种缺陷,且改进后的模型所预测的边界框相比原始模型更加接近真实缺陷区域,更为完整。如图 9(d)所示,在缺陷密集的区域,改进后的模型也能够精确定位各个缺陷的位置。这说明改进后的 YOLOv4 模型不仅能显著提高检测精度,而且定位更加准确。

为了定量地比较改进的 YOLOv4 与其他模型的检测识别效果,将本文模型与 SSD、YOLOv3 及原 YOLOv4 进行对比,表 1 所示为四种模型检测四类缺陷的平均精度值结果,图 10 为本文改进的 YOLOv4 模型对锂电池表面缺

陷检测结果的混淆矩阵。

表 1 各模型检测不同缺陷的检测率

缺陷类型	极耳异常	气泡	压痕	破损
SSD	88.47	63.92	75.22	65.99
YOLOv3	95.24	79.74	87.21	85.97
YOLOv4	96.43	85.31	90.72	89.27
本文算法	98.04	91.21	93.20	91.39

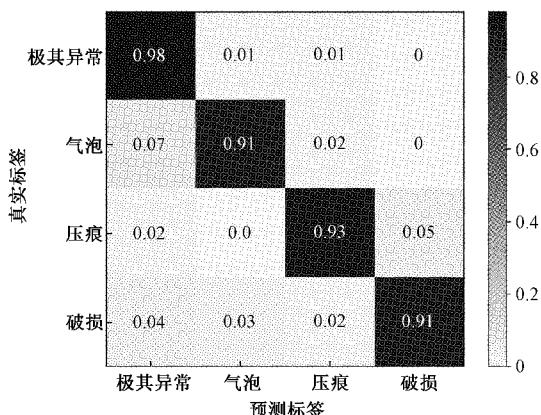


图 10 本文算法检测结果混淆矩阵

由表 1 可以看出, SSD 算法的识别效果最差,各项检测平均精度最低。在 YOLO 系列模型中,虽然 YOLOv3 模型识别效果较 SSD 模型有大幅度提升,但受限于对小目标检测精度的不足,破损、气泡等缺陷漏检率还是较高。而原 YOLOv4 模型由于改进了特征金字塔结构,利用不同尺度的池化进行处理,增强特征提取能力,因此检测效果较 YOLOv3 而言有所提升。与此同时,本文提出的改进的 YOLOv4 模型在主干网络加入空洞卷积,可以获取特征更高的分辨率,扩大对尺度不一的检测目标的感受野,提高了模型检测性能,实验结果表明,改进的 YOLOv4 模型对四类缺陷的识别精度均最高,提升明显。

为了验证本文改进算法较原模型在精度和速度上有所提升,将添加了空洞卷积与 ECA 模块的 YOLOv4 模型定义为 YOLOv4-ECA,将添加了空洞卷积与条件卷积的 YOLOv4 模型定义为 YOLOv4-Cond。表 2 为 6 种算法 mAP 和 FPS 结果。引入空洞卷积与 ECA-Net 模块的 YOLOv4-ECA 相较于原网络,平均精度均值提高了 1.11%,FPS 提高了 3 f/s,验证了空洞卷积与 ECA-Net 机制具有提高锂电池表面缺陷的准确度与速度的有效性。而采用空洞卷积与条件卷积的 YOLO-Cond 网络,相较于未改进的 YOLOv4 网络,mAP 值进一步提高了 2.01%,说明替换传统卷积对检测锂电池缺陷的精确值有较为明显的提高,有效地解决了样本噪声高,背景单一不利于特征提取的问题。本文改进的 YOLOv4 模型由于没有增加过多参数量,且在颈部网络中插入轻量级注意通道机制,

因此检测速度与原版相比没有大幅提升,而 mAP 比 SSD、YOLOv3、原始 YOLOv4、YOLOv4-ECA 及 YOLOv4-Cond 网络分别高出了 20.06%、6.42%、3.03%、1.92% 及 1.01%。由此可见本文方法综合性能表现最佳,可以同时满足工业生产中识别精度与速度的需求。

表 2 各模型性能指标

网络模型	mAP/%	FPS
SSD	73.40	16
YOLOv3	87.04	24
YOLOv4	90.43	26
YOLOv4-ECA	91.54	29
YOLOv4-Cond	92.45	28
本文算法	93.46	29

### 3 结 论

本文利用改进后的 YOLOv4 算法,实现对锂电池极片的极耳异常、气泡、压痕与破损 4 类缺陷的检测。加入空洞卷积,在不增加多余计算量的前提下扩大感受野大小;使用 ECA-Net 结构增强特征图中语义信息,消除冗余信息;利用条件卷积替代传统卷积,有效增强特征提取能力。扩充锂电池表面缺陷的数据集后使用本文改进模型进行训练,并与 SSD、YOLOv3、YOLOv4、YOLOv4-ECA 和 YOLOv4-Cond 网络进行对比。结果表明,本文提出的方法平均识别率达到 93.46%,比原始网络提升 3.03%,能够为锂电池工业生产实时监测提供一定参考价值。

### 参 考 文 献

- [1] 黄梦涛,连一鑫.基于改进 Canny 算子的锂电池极片表面缺陷检测[J].仪器仪表学报,2021,42(10):199-209.
- [2] 陈功,朱锡芳,许清泉,等.最大熵和高斯模型在锂电池缺陷识别中的应用[J].电源技术,2014,38(6):1063-1065.
- [3] 王磊.基于机器视觉的电池表面缺陷检测技术研究[D].合肥:中国科学技术大学,2011.
- [4] 汤勃,孔建益,伍世虔.机器视觉表面缺陷检测综述[J].中国图象图形学报,2017,22(12):1640-1663.
- [5] 周佳禾,宫元九.利用卷积神经网络检测锂电池电极缺陷[J].电子测量技术,2019,42(19):182-186.
- [6] 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.
- [7] 许海彪.基于深度学习的锂电池壳表面缺陷视觉检测研究[D].秦皇岛:燕山大学,2021.
- [8] 王延年,刘宏涛,刘航宇,等.基于改进 U-Net 的太阳能电池图像缺陷检测方法[J].电子测量技术,2021,44(14):117-121.

- [9] 李策, 陈海霞, 汉语, 等. 深度学习算法中卷积神经网络的概念综述[J]. 电子测试, 2018(23): 61-62.
- [10] 蓝金辉, 王迪, 中小盼. 卷积神经网络在视觉图像检测的研究进展[J]. 仪器仪表学报, 2020, 41(1): 167-182.
- [11] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[J]. 2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), IEEE, 2016:779-788.
- [12] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv Preprint, 2020, ArXiv:2004.10934.
- [13] WANG C Y, LIAO H, WU Y H, et al. CSPNet: A new backbone that can enhance learning capability of CNN[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), IEEE, 2020.
- [14] HE K M, ZHANG X Y, REN S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. Pattern Analysis & Machine Intelligence IEEE Transactions on Pattern Analysis and Machine Intelligence (TPAMI), 2015, 37(9): 1904-1916.
- [15] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 936-944.
- [16] LIU S, QI L, QIN H F, et al. Path aggregation network for instance segmentation [C]. IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2018: 8759-8768.
- [17] WANG P Q, CHEN P F, YUAN L D, et al. Understanding convolution for semantic segmentation[C]. Proceedings of 2018 IEEE Winter Conference on Applications of Computer Vision (WACV), Lake Tahoe, USA: IEEE, 1451-1460.
- [18] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[J]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), IEEE, 2020.
- [19] YANG B, BENDER G, LE Q V, et al. Condconv: Conditionally parameterized convolutions for efficient inference [J]. Advances in Neural Information Processing Systems, 2019, DOI: 10.48550/arXiv.1904.04971.
- [20] 杨真真, 匡楠, 范露, 等. 基于卷积神经网络的图像分类算法综述[J]. 信号处理, 2018, 34(12):1474-1489.

#### 作者简介

桂久琪,硕士研究生,主要研究方向为图像处理与深度学习。

E-mail:854085275@qq.com

李林升,通讯作者,副教授,主要研究方向为机器视觉,机器人技术与电机控制。

E-mail:1545928587@qq.com

毛晓,硕士研究生,主要研究方向为图像处理与目标检测。

E-mail:3216512982@qq.com

王庆秋,硕士研究生,主要研究方向为图像处理与目标检测。

E-mail:1517740392@qq.com