

[文章编号] 1003—4684(2023)01-0027-06

# 基于改进 MobileNetV3 的 PCB 裸板缺陷检测

张鹏飞, 王淑青, 王年涛, 顿伟超, 黄剑锋

(湖北工业大学电气与电子工程学院, 湖北 武汉 430068)

**[摘 要]** 为解决传统 PCB 裸板缺陷检测效率低、误检率高、通用性差等问题, 提出一种基于改进 MobileNetV3 的 PCB 表面缺陷检测模型。首先对 PCB 数据集进行预处理, 然后采用多方向协调注意力代替原网络中的挤压和激励注意力模块, 提升特征定位精度从而增强感受野; 最后利用软池化优化 MobileNetV3 的末端结构, 以在简化后的激活映射中保留更多的特征信息。实验结果证明, 提出的模型对 PCB 裸板缺陷检测的平均准确率可达 96.1%, 图片平均检测速度为 25.1 ms, 能够高效识别 PCB 裸板的多种缺陷类型, 对工业生产中 PCB 裸板的质量检测有实际应用价值。

**[关键词]** PCB 裸板; 缺陷检测; MobileNetV3; 软池化; 深度学习

**[中图分类号]** TP391.4      **[文献标识码]** A

随着电子通讯、智能驾驶、智慧医疗、工业控制等领域的电力电子设备向着高精密、智能化及更加轻薄的发展方向, 印刷电路板 (PCB) 的电路绘制以及功能元件量也越来越多, PCB 高度集成模块化也是必然趋势<sup>[1]</sup>。但 PCB 作为电子产品的核心组件, 其生产工艺非常复杂, 包含繁多的制造工序, 这将导致 PCB 在生产过程中不可避免地出现多种质量缺陷, 影响整体性能<sup>[2]</sup>。因此, PCB 裸板缺陷检测在整个生产制造工艺过程中显得极为重要。

目前, PCB 裸板缺陷检测方法可分为三大类: 接触检测法、机器视觉检测法及深度学习检测法<sup>[3]</sup>。其中前两类传统方法中存在检测效率低以及易受人为因素影响的问题, 而深度学习检测法<sup>[4]</sup>既符合当前人工智能时代的发展趋势, 同时也可以更好的解决这些问题。V. A. Adibhatla 等<sup>[5]</sup>采用卷积神经网络对 PCB 图像进行了缺陷分类, 精度较低。在此基础上, 瞿栋等<sup>[6]</sup>使用卷积神经网络结合迁移学习对 PCB 图像进行了缺陷检测, 但检测缺陷类型较少。耿朝辉等<sup>[7]</sup>在 Faster RCNN 网络中加入了特征金字塔并优化损失函数对 PCB 裸板的多种缺陷进行检测, 但数据集数量较小有待优化。谢黎等<sup>[8]</sup>通过在 YOLOv4 网络中强化特征融合, 并结合 Kmeans 聚类改进网络模型对电路板元器件进行了缺陷检测。为进一步提高 PCB 裸板的检测精度及速度, 降低误检率, 本研究采用前沿的轻量级网络 MobileNetV3<sup>[9]</sup>, 并通过改进注意力机制及池化效

果增强了模型的整体性能, 实现对 PCB 裸板多种缺陷的高效检测, 对 PCB 裸板生产工艺的质量规范具有实际意义。

## 1 PCB 裸板检测网络原理

PCB 裸板缺陷检测方法主要采用 MobileNetV3<sup>[9]</sup>网络, 是由 Google 在 2019 年提出的网络架构, 其网络建立在高效的构建块 bneck 上 (图 1)。




图 1 MobileNetV3 构建块 bneck

MobileNetV3 首先引入深度可分离卷积 (DSConv), 对传统卷积层进行有效替换。DSConv 通过把空间滤波从特征生成机制中分离而出, 有效分解了传统卷积。DSConv 由两个单独的层来定义, 分别为用于空间滤波的轻量级深度卷积和用于特征生产的  $1 \times 1$  点卷积构成。其次, 引入了线性瓶颈的倒置残差结构, 通过采用低秩特性实现更高效的层结构, 该结构由  $1 \times 1$  膨胀卷积, 深度可分离卷积以及  $1 \times 1$  映射层构成。当且仅当输入和输出具有相同数量的通道时, 使用残差连接的方式, 使结构输入和输出更加紧凑, 同时在内部扩展到高维度特

[收稿日期] 2021—12—19

[第一作者] 张鹏飞(1995—), 男, 内蒙古呼和浩特人, 湖北工业大学硕士研究生, 研究方向为目标检测与智能控制系统

[通信作者] 王淑青(1969—), 女, 河北衡水人, 湖北工业大学教授, 研究方向为人工智能, 目标检测及智能控制

征空间,以增加非线性(NL)全通道转换的性能。

在此基础上,线性瓶颈结构中引入了挤压和激励的注意力模块(SE)<sup>[10]</sup>,同时提出了一种新的激活函数 H-Swish,增强特征提取精度,并提升检测速度,公式如下:

$$H\text{-Swish}(x) = x \cdot \text{ReLU6}(x + 3)/6$$

式中,ReLU6 为激活函数。为进一步提高网络预测功能,采用多方向协调注意力(MCA)模块替换 SE 模块,并对 MobileNetV3 的网络末端进行了进一步优化,采用软池化(Soft Pool)替代平均池化(Avg Pool)<sup>[11]</sup>,提高 PCB 裸板缺陷的检测性能。

## 2 特征提取网络优化

### 2.1 多方向协调注意力机制

SE 模块只考虑通过构建通道关系来重新衡量每个通道的重要性,而忽略了同样重要的位置信息。为此,本文采用 MCA 模块替换 SE 模块对特征提取网络进行改进。MCA 模块可以看作是一个计算单元,分为两步:协调信息嵌入和协调注意力生成;通过捕获位置信息和通道之间的明确关系,以增强移动网络的特征表达能力(图 2)。

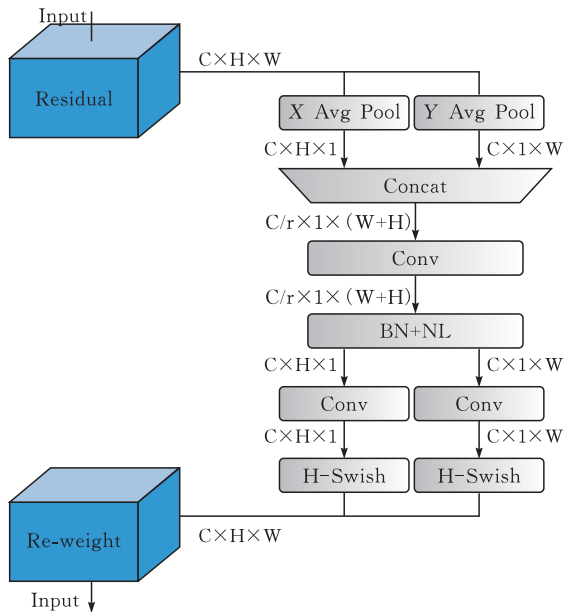


图 2 多方向协调注意力模块

如图 2 所示,在信道注意力中,通常使用全局池化(Global Pooling)<sup>[11]</sup>对空间信息进行全局编码,但全局空间信息压缩到信息描述符中往往无法保存位置信息,而位置信息是 PCB 裸板缺陷检测的关键。首先,通过选择任意特征张量  $X = [x_1, x_2, \dots, x_c] \in R^{C \times H \times W}$  作为输入,输出为一个带有增广表示的变换张量  $Y = [y_1, y_2, \dots, y_c]$  大小与  $X$  相同,其中  $R$  是对应二维空间区域的特征激活映射集合,  $C$  为通道数,  $H$  为高度,  $W$  为宽度。

为激励注意力模块通过精确的位置信息捕捉远距离空间交互作用,将全局池化对应分解为一对一维编码操作,给定输入  $X$ ,通过两个池化核空间范围  $(H, 1)$  或  $(1, W)$  分别沿水平坐标核垂直坐标对每个通道进行编码。因此,可以将第  $c$  个通道在高度  $h$  处的输出表示如下:

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} x_c(h, i) \quad (1)$$

式(1)中,  $W$  为通道宽度特征向量,  $x_c$  为第  $c$  个通道的输入值。同理可以得出第  $c$  个通道在宽度  $w$  处的输出表达式:

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j < H} x_c(j, w) \quad (2)$$

式(2)中,  $H$  为通道高度特征向量,  $x_c$  为第  $c$  个通道的输入值。以上两种转换操作分别沿着两个空间方向聚合特征,生成一对方向感知特征映射。这与 SE 模块中的挤压操作是不同的。这两种转换操作让注意力块捕捉到空间方向上的长期依赖关系,并在另一个空间方向上保留了精确的位置信息,使得网络能够更加精准的定位感兴趣区域。

为进一步利用式(1)和式(2)产生的表达性特征,采用协调注意力生成的方式尽可能地保持提取过程的简洁和高效,捕捉通道间的联系;同时可以充分利用定位信息,准确地突出感兴趣区域。协调注意力机制将生成的聚合特征映射连接起来,然后传送到  $1 \times 1$  卷积变换函数  $F_1$  中,具体操作见下式:

$$f = \delta(F_1([z^h, z^w]))$$

式中,  $f \in R^{C/r \times (H+W)}$  是中间过程在水平和垂直方向上的编码空间信息特征表示,其中  $r$  是控制模块大小的缩减比例参数,如 SE 模块。 $\delta$  为非线性激活函数;  $[z^h, z^w]$  为空间维度的连接操作。对生成的卷积进行批量归一化及非线性操作之后,沿着空间维度将  $f$  函数分解为两个张量,分别为  $f^h \in R^{C/r \times H}$  和  $f^w \in R^{C/r \times W}$ 。通过两个  $1 \times 1$  卷积变换函数  $F_h$  和  $F_w$  分别将  $f^h$  和  $f^w$  变换到与原有输入  $X$  相同通道数的张量上来,如下:

$$\begin{cases} g^h = \rho(F_h(f^h)) \\ g^w = \rho(F_w(f^w)) \end{cases}$$

式中,  $\rho$  表示激活函数 H-Swish,  $g^h$  和  $g^w$  表示不同方向上的注意力权重。最后结合各通道输入值  $x_c$  构成 MCA 模块的最终输出,如下:

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j)$$

式中,  $g_c^h(i)$ ,  $g_c^w(j)$  分别表示不同方向上第  $c$  个通道的权重值,  $y_c(i, j)$  为第  $c$  个通道的注意力模块输出值。MCA 模块不同于只关注衡量不同通道重要性的 SE 模块,在水平和垂直方向同时施加注意力作用于输入张量,以确认两种特征表示中的每

个元素是否存在于感兴趣区域的对应位置。这种操作方式使 MCA 模块能更精确地定位有效特征位置,从而实现对 PCB 裸板上各类缺陷的有效识别。

### 2.2 软池化方式

Soft Pool 是基于 Softmax<sup>[12]</sup> 的加权方法,采用自然指数  $e$  以确保较大的激活值对输出产生更大的影响,同时保持了可微性,软池化包含了信息的正向传播和反向传播过程中的梯度计算,也就是下采样过程<sup>[7]</sup>;与其他池化方式相似,都具有一个用于描述非线性变换域与对应激活关系的权重值  $w_i$ ,且

$$w_i = \frac{e^{a_i}}{\sum_{j \in R} e^{a_j}} \tag{3}$$

式中,每个激活  $a_i$  和对应的映射  $i$  都具有一个对应权重  $w_i$ ,表示为特定激活指数相对于邻域  $R$  内所有激活指数总和的占比。这使得在 2 维特征空间中能够突出更大的激活特性,以保留 PCB 裸板图像中更易于区别的特征,相比于均值池化更具备合理性。软池化操作的输出值是通过内核领域  $R$  内的所有加权激活总和而产生的,如下式:

$$\tilde{a} = \sum_{i \in R} w_i \cdot a_i \tag{4}$$

最终,将式(1)代入式(2)得到软池化具体描述公式如下:

$$\tilde{a} = \sum_{i \in R} \frac{e^{a_i} * a_i}{\sum_{j \in R} e^{a_j}}$$

与原有的 Avg Pool<sup>[9]</sup> 相比,Soft Pool 不需要可训练的参数,并具有更大的计算和记忆效率,由于 Soft Pool 具有可微性,在反向传播过程中为每个输入获得了梯度值,提高了训练速度。既对整个区域显示进行了一定程度的抑制,又保留了一些较为突出的特征,这对于更加精准的检测 PCB 裸板的缺陷是更加有利的,PCB 图像特征的软池化过程见图 3。




图 3 PCB 裸板软池化示意图

如图 3 所示,通过  $2 \times 2$  卷积核对原始 PCB 图像进行下采样,输出基于内核区域内原始像素的指数加权和,从而改善高对比度区域、线路边缘区域以及特定特征激活映射,更好地提取 PCB 裸板的缺陷特征。

特征提取网络使用池化操作来减小激活映射,这个过程对于增加接收域和减少后续卷积计算量是

至关重要的。为在初始映射过程中不增加额外计算条件下保留更丰富的最小化信息,采用上述 Soft Pool 操作,替换 MobileNetV3 末端网络中的 Avg Pool 操作,改进后的末端网络结构如图 4 所示。




图 4 改进的 MobileNetV3 末端网络

最后,将改进的 MobileNetV3 作为主干网络 (Backbone),以 YOLOv5<sup>[13]</sup> 网络作为检测模型,实现 PCB 裸板的缺陷检测,检测模型整体框架如图 5 所示。

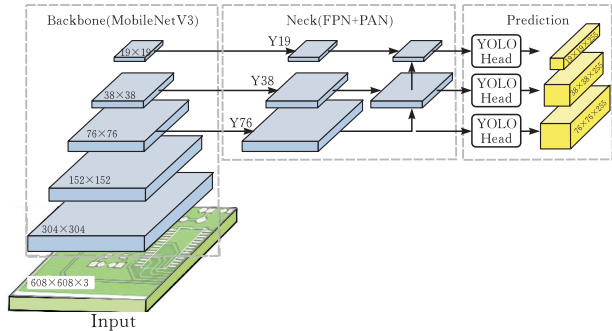


图 5 PCB 裸板缺陷检测模型整体框架

## 3 实验过程与结果分析

### 3.1 实验环境配置

本实验的平台为 PC 机 Windows10 系统,CPU 为 Intel(R) Core (TM) i7-10700K @ 3.8GHz、GPU 为 NVIDIA GeForce RTX 3080Ti、显存 12G、内存 16G;实验环境及软件为 Anaconda3、PyCharm 2020.2.1、GPU 加速包为 CUDA11.1 和 CUDnn10.1 以及深度学习框架 Pytorch 1.7。

### 3.2 数据预处理

实验采用 PCB 公共数据集<sup>[13]</sup>,共包含 10668 张 PCB 裸板图像,其中包含短路、断路、缺口、余铜、漏焊、毛刺 6 种缺陷类型(图 6)。




图 6 PCB 裸板缺陷类型



采用 LableImage 对 PCB 裸板的 6 种缺陷类型进行标记,生成对应的.xml 格式文件,文件内主要包含了 PCB 裸板图片名称 filename,图片尺寸宽度 width 和高度 heights,标注目标 object,类别标签 labels,标注框 bndbox 及其位置信息 xmin、ymin、xmax、ymax 等。数据按训练集和测试集 7:3 的比例随机分配,其中训练集 7467 张图像,测试集包含 3201 张图像。在训练前,对数据设置文件内 VOC、COCO 的类别名称、数量以及训练路径等相关参数进行初始化。在训练过程中采用动量衰减因子为 0.9 的 SGD 优化器对所有模型进行训练,调整图像大小为  $608 \times 608$ ,批处理大小设为 8,最大迭代轮数设为 300 轮;权重衰减系数设为 0.0005,初始学习速率设为 0.001。

3.3 模型评估指标

模型评估指标是衡量模型好坏的重要参数,其中平均精度值(AP)是根据在 PCB 裸板数据集上预测得到的精确率(Precision)和召回率(Recall)决定的,如下:

$$\begin{cases} Precision = TP / (TP + FP) \\ Recall = TP / (TP + FN) \end{cases} \quad (5)$$

式中,TP 为被正确预测的正类、FP 为被正确预测的负类、FN 为被错误预测的正类。以 Precision 为纵轴,Recall 为横轴的曲线被称为 P-R 曲线,曲线下围成的面积占总面积的比例为 AP。PCB 裸板各类缺陷的 AP 平均值为 mAP 值;FPS 为每秒处理图片的帧数,上述各指标值越大,说明检测模型的预测效果越好。模型的损失值(Loss)表示预测样本与真实样本的误差,Loss 越小代表模型越稳定,检测效果越好。

3.4 模型结果与分析

训练完的模型会生成对应的训练日志,其中包含了所有迭代轮数下的评估指标,通过适当的平滑处理,将 PCB 裸板缺陷检测模型的整体平均损失值、训练精度值以及召回率绘制成相应曲线图,进行模型评估(图 7、图 8)。




图 7 模型整体平均损失值

从图 7 可以看出,模型整体平均损失值曲线收敛速度较快,在 300 轮次的迭代下,最终损失值降至

0.001 以下,说明 PCB 裸板缺陷分类的效果较好,预测值与真实值之间的偏差较低,有着较稳定的缺陷检测性能。




图 8 训练精度值和召回率

从图 8 可以看出,PCB 裸板缺陷检测模型的精度值及召回率较高,表示该模型能对于 PCB 裸板各类缺陷进行精准的预测,漏检率较低;同时较高的召回率可以大大减低 PCB 裸板缺陷的误检率,最终的平均精确值和召回率分别为 98.52%、94.76%,能够较好地完成 PCB 裸板的缺陷检测任务。

在完成 PCB 裸板缺陷检测模型的训练及指标获取后,为进一步对改进的模型进行评估,保持实验环境配置信息不变,使用 Faster-RCNN<sup>[7]</sup>、SSD<sup>[14]</sup>、YOLOv4<sup>[8]</sup> 和 YOLOv5<sup>[15]</sup> 深度学习模型在相同数据集上测试,并选择上述模型的最佳权重在测试集上进行比较,各模型的 PCB 缺陷裸板缺陷平均精度值 AP 对比见表 1;各模型整体性能对比见表 2。

表 1 检测模型的 PCB 裸板缺陷检测平均精度值 AP 对比

检测模型	主干网络	平均精度值 AP/%						
		短路	断路	缺口	余铜	漏焊	毛刺	
Faster-RCNN	ResNet101	89.3	88.5	86.7	89.8	90.2	85.9	
SSD	VGG16	86.9	87.5	84.2	86.7	88.1	83.8	
YOLOv4	CSPDarknet53	93.4	92.8	89.5	92.1	93.6	89.4	
YOLOv5m	Focus+CSPNet	95.5	95.9	93.4	94.7	96.4	92.3	
YOLOv5	MobileNetV3	93.5	94.4	91.3	93.9	95.1	91.6	
YOLOv5	MobileNetV3+ MAC+Soft Pool	96.7	96.5	93.6	96.8	98.3	94.7	

表 2 检测模型性能对比

检测模型	主干网络	mAP@.5/%	FPS/帧
Faster-RCNN	ResNet101	88.4	18.9
SSD	VGG16	86.2	27.3
YOLOv4	CSPDarknet53	91.8	32.5
YOLOv5m	Focus+CSPNet	94.7	40.6
YOLOv5	MobileNetV3	93.3	43.7
YOLOv5	MobileNetV3+ MAC+Soft Pool	96.1	39.8

由表 1 和表 2 可知,与 Faster-RCNN、SSD、YOLOv4 模型相比,改进的模型 mAP 值分别提升了 7.7%、9.9%、4.3%;每秒检测图片的速度分别提升了 20.9 帧,12.5 帧,7.3 帧,模型性能占明显优势。对于不同主干网络的 YOLOv5 模型,改进的模型比

YOLOv5m 提高了 1.4%，比 YOLOv5 (MobileNetV3) 提升了 2.8%；而检测速度比 YOLOv5m 降低了 0.8 帧，比 YOLOv5 (MobileNetV3) 降低了 3.9 帧。虽然检测速度有些许下降，但同样满足 PCB 裸板工业缺陷检测需求，并且在此基础上提高了缺陷检测精度，这对于 PCB 裸板生产的质量保障更为重要；由此证明，改进后的 PCB 裸板缺陷检测模型的综合性能效果更好，PCB 裸板缺陷检测结果见图 9。




图 9 PCB 裸板缺陷检测结果

从图中可以看出，改进后的模型对于 PCB 裸板的短路、断路、余铜、漏焊、缺口、毛刺 6 类缺陷的实际检测效果较好，其中一些较小的缺陷，如缺口、毛刺也能很好的识别，强化了 PCB 裸板多种缺陷的检测性能，大大降低了误检率。

4 结论

提出了一种改进 MobileNetV3 特征提取网络的 PCB 裸板表面缺陷检测方法，通过多方向协调注意力模块优化 MobileNetV3 线性瓶颈结构中的挤压和激励注意力跨块，结合通道和位置信息的明确关系，增强网络的表征能力；并采用 Soft Pool 替换 MobileNetV3 末端网络的平均池化操作，保留了更丰富的最小化特征信息。采用 YOLOv5 网络作为检测模型，完成 PCB 裸板缺陷检测；由模型的评估及对比实验可知，提出的模型检测效果更好，具有更强的综合性能，可部署于 PCB 裸板工业缺陷检测环节中，对 PCB 裸板的质量保障具有一定的实际意义。

[ 参 考 文 献 ]

[1] 李磊, 秦伟鹏, 江庭富. 印制电路板钻孔毛刺的产生原因与改善探讨[J]. 印制电路信息, 2021, 29(11): 10-13.

[2] IKIRI Y, FUMIYA SAKO, MASAKI HASHIZUME, et al. Open defect detection in assembled circuit boards with built-in relaxation oscillators[J]. In IEEE Transactions on Components, Packaging and Manufacturing Technology, 2021, 11(06): 931-943.

[3] 魏嘉莉,王瑞丰,冀运景,等.基于机器视觉的PCB板电解电容极性自动定位[J].电子测量技术,2021,44(16):148-155.

[4] 陶显,侯伟,徐德.基于深度学习的表面缺陷检测方法综述[J].自动化学报,2021,47(05):1017-1034.

[5] ADIBHATLA V A, SHIEH J, ABBOD M F, et al. Detecting defects in PCB using deep learning via convolution neural networks[C]. 2018 13th International Microsystems, Packaging, Assembly and Circuits Technology Conference (IMPACT), 2018: 202-205.

[6] 瞿栋,汪鹏宇,黄允,等.基于卷积神经网络的PCB缺陷图像识别[J].计量与测试技术,2021,48(08):21-23.

[7] 耿朝晖,龚涛.基于改进Faster R-CNN的PCB板表面缺陷检测[J].现代计算机,2021(19):89-93.

[8] 谢黎,袁小芳,尹柏鑫.基于改进YOLOv4网络的电路板元器件缺陷检测[J].测控技术,2022,41(04):9.

[9] HOWARD A, MARK SANDLER, BO CHEN, et al. Searching for MobileNetV3[C]. 2019 IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 1314-1324.

[10] JIE H, LI S, GANG S. Squeeze and excitation networks[C].// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2018:7132-7141.

[11] PALA T, GÜVENÇ U, KAHRAMAN H T, et al. Comparison of pooling methods for handwritten digit recognition problem[C]. 2018 International Conference on Artificial Intelligence and Data Processing (IDAP), 2018: 1-5.

[12] RAO Q, YU B, HE K, et al. Regularization and iterative initialization of softmax for fast training of convolutional neural networks[C]. 2019 International Joint Conference on Neural Networks (IJCNN), 2019: 1-8.

[13] DING R, DAI L, LI G, et al. TDD-net: a tiny defect detection network for printed circuit boards [J]. In CAAI Transactions on Intelligence Technology, 2019, 4(02): 110-116.

[14] HAO G, YINGKUN Y, YI Q. General target detection method based on improved SSD[C]. 2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference (ITAIC), 2019: 1787-1791.

[15] FENG H, JIANG Y. Recognition of insulator based on yolov5 algorithm[C]. 2021 IEEE 11th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER), 2021: 505-509.

# PCB Bare Board Defect Detection Based on Improved MobileNetV3

ZHANG Pengfei, WANG Shuqing, WANG Niantao, DUN Weichao, HUANG Jianfeng

(School of Electrical and Electronic Engineering, Hubei Univ. of Tech., Wuhan 430068, China)

**Abstract:** To solve the problems of low efficiency, high error detection rate and poor universality of traditional PCB bare board defect detection, a PCB surface defect detection method based on improved MobileNetV3 was proposed. Firstly, PCB data set was preprocessed. Then, multi-directional coordinated attention was used to replace the squeezing and motivating attention modules in the original network to improve the accuracy of feature localization and enhance the receptive field. Finally, the Soft Pool was used to optimize the terminal structure of MobileNetV3 to retain more feature information in the simplified activation map. Experimental results show that the average accuracy of the proposed model is 96.1%, and the average image detection speed is 25.1ms. The proposed model can efficiently identify various defect types of PCB bare board, and has practical application value for PCB bare board quality detection in industrial production.

**Keywords:** Bare PCB board; Defect detection; MobileNetV3; Soft pool; Deep learning

[责任编辑：张岩芳]

(上接第 14 页)

# Optimal Scheduling of Park Integrated Energy System Based on Chance Constraint

FU Bo, DENG Jingcheng, KANG Yiheng

(School of Electrical and Electronic Engin., Hubei Univ. of Tech., Wuhan, 430068, China)

**Abstract:** The uncertainty of renewable energy puts forward higher requirements for system backup, which affects the economy of the power system. Park integrated energy systems (PIES) are coupled with multiple energy demands and can effectively absorb renewable energy. However, the traditional optimal scheduling method considering uncertainty has a contradiction between practicability and solution accuracy. Based on the chance constraint theory to deal with the uncertainty of renewable energy, this paper constructs an optimal dispatch model for the park's comprehensive energy system considering the uncertainty. At the same time, for the stochastic optimization problem established after introducing the chance constraint, the sequence operation theory is used to transform the chance constraint deterministically to reduce the complexity of the solution, and CPLEX is used to solve the mixed integer linear programming (MILP) model obtained after the transformation. Numerical example simulation verifies the feasibility of the model and method, and the stability and solution speed are improved compared with the heuristic algorithm.

**Keywords:** chance constraint; sequence operation; demand response; park integrated energy system

[责任编辑：张岩芳]