

基于 Darknet 网络和 YOLO4 的实时电路板故障检测算法

赵岩¹, 孔祥伟¹, 马春斌¹, 杨浩²

(1. 国营长虹机械厂, 广西 桂林 541003; 2. 北京钛航信息技术有限公司, 北京 100195)

摘要: 针对现有的接触式电路板故障检测方法难以应用到大规模集成电路故障检测中的问题, 提出一种实时、非接触式的基于深度学习的电路板故障诊断算法; 建立 PCB 板缺陷检测和元器件识别图像数据集, 并采用数据增强技术, 对数据进行数据增强来提高训练的数据量, 以提升模型检测精度和鲁棒性; 基于 Darknet 框架和 YOLO4 算法训练得到元器件检测模型, 并通过采用 k-means 聚类算法设计合理的 Anchors, 使得模型具备多尺度缺陷检测的功能; 使用图像配准算法在红外图像和可见光图像上实现配准和融合; 根据 PCB 板设计时划分的功能区域, 利用测温热像仪连续采集 5 个该区域的平均温度, 通过判断 5 个平均温度之间的关系从而判断短路或者短路状态; 经过试验测试, 使用预先设置好故障的电路板作为实验对象, 通过采集实验对象运行过程中的红外和可见光图像数据, 基于设计的故障检测模型, 不仅能够实时且有效地识别出元器件位置, 并能够直观地标识出现短路、短路故障元器件; 经过实际应用, 能够满足设备运行时的实时电路板故障检测工程应用。

关键词: 电路板; 故障检测; 图像处理; Darknet; YOLO4

Real-time PCB Fault Detection Algorithm Based on Darknet Network and YOLO4 Algorithm

ZHAO Yan¹, KONG Xiangwei¹, MA Chunbin¹, YANG Hao²

(1. State-owned Changhong Machinery Factory, Guilin 541003, China;

2. Beijing Techhand Information Co., Ltd., Beijing 100195, China)

Abstract: Aimed at the problem that existing contact circuit board fault detection methods are difficult to be applied in large scale integrated circuit fault detections, a real time contactless circuit board fault diagnosis algorithm based on deep learning is proposed. The image data set of PCB board defect detection and component recognition is established, and the data enhancement technology is used to enhance the data volume of training, and improve the accuracy and robustness of the model detection. The component detection model based on Darknet framework and YOLO4 algorithm training is obtained, and K-means clustering algorithm is used to make the model have the multi-scale defect detection function. Image registration algorithms are used to register and fuse infrared and visible images. According to the divided functional area of the PCB board design, the average temperature of five areas is collected continuously by the thermometry thermal imager, and the short circuit or short circuit status is judged by the relationship between five average temperatures. After testing, the pre-set faulty circuit board is used as the experimental object, the infrared and visible image data is collected during the operation of the experimental object, based on the designed fault detection model, the real-time and effective identification of short-circuit faults with component and regional components is realized, and it can meet a engineering application of real-time circuit board fault detection for equipment running.

Keywords: PCB; defect detection; image processing; Darknet; YOLO4

0 引言

随着现代电子集成技术的快速发展, 复杂装备中核心的系统功能已经通过大规模集成电路进行实现, 且电路板上元件越来越密集, 电路也更加复杂。一方面使用集成电路技术使得装备在精密化、小型化、计算能力上有了显著的提升; 另一方面, 电路板出现故障以后往往很难进行检

测, 也伴随着装备突发失效的风险。电子设备维修保障中, 集成电路执行的功能越来越重要, 快速识别和检修故障是至关重要的步骤。随着印制电路板的密集化和多层化, 传统的接触式电路板检测技术的各种限制和缺陷变得越来越明显, 不但需要接触式检测, 而且只能发现已经出现的故障, 对于潜在的故障难以诊断。传统的接触式电路板故障检测在微波、毫米波等高频电路中检测时, 使用接触式检

收稿日期: 2023-03-14; 修回日期: 2023-03-27。

作者简介: 赵岩(1982-), 男, 黑龙江依安人, 硕士, 高级工程师, 主要从事武器装备技术方向的研究。

通讯作者: 孔祥伟(1978-), 男, 广西桂林人, 工程师, 主要从事武器装备技术方向的研究。

引用格式: 赵岩, 孔祥伟, 马春斌, 等. 基于 Darknet 网络和 YOLO4 的实时电路板故障检测算法[J]. 计算机测量与控制, 2023, 31(6):

101-108.

测可能会导致在检测时影响到电路分布参数,影响原来的电路工作,所以接触式检测不能适用于高频电路的检测。除此之外,接触式电路板检测需要对电路板进行拆卸和组装,这可能会增加故障的概率。接触式检测需要使用探针进行接触,这可能会对电路板造成损伤,需要对每个测试点进行测试,测试时间较长。随着电子设备的不断发展,接触式电路板检测技术的局限性越来越明显,需要研究新的非接触式电路板检测技术。

近些年来,国内外对电路板故障诊断技术的研究力度逐步加大,主要侧重在使用机器学习方法来实现故障诊断模型。其中,周金祖^[1]等提出基于改进隐马尔科夫模型的电路板故障诊断算法,并引入遗传算法训练模型的参数,克服了传统算法的收敛速度慢、易陷入局部最优解和运算复杂等缺点,改进后模型的故障预测准确率、收敛速度和收敛稳定性都有明显改善;郝建新^[2]等提出基于 SVM 与改进 D-S 理论电路板故障诊断方法,所提算法可以有效降低各证据体对诊断结论的冲突,增强正确诊断结果的信度显著提高;王力^[3]等提出基于 BCL-ASA-BP 神经网络的模拟电路板芯片故障诊断,其提出的方法对芯片故障综合诊断准确率可达 98.35%,较传统 BP 算法提升 13.9%。谢永成^[4]等提出基于 GA-BP 神经网络的装甲车辆电路板故障诊断,能够有效提升装甲车辆电气系统电路板故障诊断效率和质量,郝建新等^[5]提出了一种由特征提取网络与关系学习网络并行构成的可综合利用温度序列局部特征及特征间关系的电路板故障诊断模型,实现电路板故障的高准确度诊断。黄威等^[6]提出了基于深度学习的机器人电路板自主故障检测系统,提升模型对细小故障的检测,精确故障定位。Song 等^[7]提出一种结合计算机视觉的简单高效的智能故障诊断方法,有效提取部件的热故障特征,减少误诊和误诊不足。

随着深度学习技术的发展及应用,针对图像识别检测领域,一些专家也使用深度学习技术进行了相关探索,其中 Darknet 深度学习框架结合 YOLO^[8]在图像检测方向成果显著。王辉等^[9]研究了基于 Darknet 和 YOLO3 的水果图像识别,所构建模型能够有效提取水果图像的不同层特征,与原模型相比不依赖于批量大小,准确率达到 95.6%;使用改进的 DarkNet-53 作为主干网络的水果目标检测模型,平均识别精度达到 85.91%;李珣等^[10]研究了基于 Darknet 框架下 YOLO v2 算法的车辆多目标检测方法,基于 YOLO-vocRV 模型的车辆多目标检测方法的检测率在自由流状态下可达 99.11%,同步流状态下可达 97.62%,阻塞流状态下可达到 97.14%,具有较小的误检率和良好的鲁棒性。虞浒等^[11]针对深度诊断模型较难处理信号紧邻特征点以及多变工况导致模型诊断精度和泛化性能不足的问题,梅玲玲等^[12]研究设计了一种基于深度学习的道路车辆目标检测系统,简历改进的 YOLOv4 模型处理噪声干扰信息,减少了模型计算参数量,提高检测准确性。魏小玉等^[13]提出一种基于改进轻量化神经网络的手势识别方法,检测准确度较

整体提升 2.62%,达到了 96.18%。段中兴等^[14]针对盲道障碍物检测提出改进 YOLOv4 算法,提高检测准确。牛振振等^[15]提出了基于 YOLOv5s 的一个轻量型的 CNN 模型 YOLO_AD,用于 PCB 缺陷检测,减少模型参数数量的同时加大对细节特征的提取,提升了识别率。侯玥等^[16]提出一种新的小样本目标检测模型。谢黎等^[17]提出一种基于改进 YOLOv4 网络的电路板元器件缺陷检测方法,对电路板上的不同元器件进行识别。何国忠等^[18]提出了一种基于卷积神经网络的电路板缺陷检测网络,基于 YOLO v4 网络加入全局注意力机制,提高了对 PCB 电路板缺陷检测的精度。崔俊佳等^[19]提出了基于 YOLOv5s 加 ResNet18 的自冲铆接偏铆缺陷检测算法,对所提供的数据测试集的识别准确度达到 100%。本文基于格拉姆角场(GAF)和 DarkNet-53 图像识别算法提出 GAF-DarkNet 算法,对滚动轴承故障诊断具有更好的泛化能力和识别效果。

综上所述,针对电路板故障诊断问题,使用基于图像的人工智能方法来提高电路板诊断识别率已经成为主流的研究方向,本文在此研究基础上,研究重心侧重在实时电路板故障检测工程应用角度,将采用以红外和可见光结合的图像处理与分析方式,通过特征提取能力更强的深度学习架构来进一步提高电路板故障诊断能力,并依托于非接触式的方式,能够基于视频流进行实时的故障诊断,在工程应用上更具备可行性。核心优化点包括:

- 1) 构建完备的缺陷电路板图像样本数据集,并经过图像增强技术提高样本丰富度和规模,为深度学习大批量训练提供数据基础;
- 2) 引入更先进的 Darknet 框架和 YOLO4 算法来实现电路板元器件的精确目标检测;
- 3) 采用红外成像和可见光结合的形式,对图像进行配准后,以红外温度指标作为异常表征,并反向确定故障的元器件。

1 数据集说明

本算法样本图像采集使用海康威视 MV-CE120-10UC 工业相机,成像像素 1 200 万,搭配海康威视 MVL-HF0824M-10MP 工业相机镜头,光源为环形面光,采集到的图像为 bmp 格式。为提高数据样本量,以及丰富不同场景的数据样本,采集了多种规格的电路板图像。

样本中的电路板缺陷为完整电路板人为制造,元器件识别样本为完整电路板。样本采集过程中保存同一块电路板不同位置、不同角度的图像,同时针对同一种类的不同电路板,对图像进行翻转、裁剪、旋转、缩放、平移和添加噪声等操作对数据集进行扩展,尽可能增加数据集所覆盖的情况,提高模型的鲁棒性。

样本标注使用 labelImg^[9]进行,标注过程如图 1 所示。

标注后生成标定数据,即 Yolo4 目标检测算法需要的标注数据,数据组成为:

$$data = \{label, place_x, place_y, width, height\} \quad (1)$$



图 1 使用 labelImg 进行样本标注

式中, $label$ 为样本类别序号; $place_x$ 为框选目标左上角 X 坐标; $place_y$ 为框选目标左上角 Y 坐标; $width$ 为框选目标宽度; $height$ 为框选目标高度。

以上数据均进行归一化处理, 即符合 Yolo4 训练所需坐标格式。如图 2 所示。

```

0.txt - 记事本
文件(F) 编辑(E) 格式(O) 查看(V) 帮助(H)
2 0.276250 0.542161 0.017500 0.025033
2 0.332250 0.479249 0.026000 0.030303
0 0.308875 0.699605 0.022750 0.012516
1 0.605000 0.653821 0.021500 0.032279
1 0.654125 0.458663 0.009250 0.026021
0 0.290125 0.601779 0.013750 0.030962
0 0.331000 0.634223 0.013500 0.031950
0 0.310000 0.578393 0.022500 0.011858
0 0.279875 0.694829 0.010750 0.027339
0 0.521875 0.452734 0.031750 0.066841
    
```

图 2 图像样本标注样式

样本集由训练样本和样本标注数据组成, 即样本图片+样本标注数据, 命名方式根据样本图片的命名, 即训练样本名称和标注数据名称相同。训练样本图片与标注数据放于同一级目录中以便算法读取。验证集从标注样本后的样本中选取, 选取比例:

$$train:valid = 7:3 \quad (2)$$

2 算法介绍

2.1 检测算法

元器件目标检测是电路板故障定位的核心, 本算法以 Darknet 深度学习框架作为基础, 使用 YOLO4 目标检测算法, 具有更好的分层特征提取、学习能力和特定硬件环境下实时高效处理大规模数据的能力, 能更好地满足基于机器学习的红外图像故障检测算法系统对识别精度和实时性的要求。

首先设计并搭建基于深度学习的目标检测识别模型, 以数据为驱动, 数据越完备, 模型学习到的目标检测识别能力的泛化性越强。模型具有较高的特征提取、学习、处理大规模数据的能力, 能更好地满足基于机器学习的红外图像故障检测算法系统对识别精度和实时性的要求。在学习阶段, 模型迭代输入小规模数据集中的序列图像, 输出预测的待识别目标信息, 然后计算预测结果与真实标签之

间的损失值, 通过梯度反向传播的方式对模型参数进行迭代优化, 挖掘小样本数据集中包含的输入图像序列数据集与待识别目标之间的复杂映射关系, 训练学习过程中采用的数据增强、特征提取模块设计、学习优化方案等保证了算法模型的泛化能力。在辅助识别阶段, 实时输入新采集的序列图像, 模型学习到的检测识别能力对每一帧图像中的目标进行识别, 给出识别目标的大小、位置、置信度等信息。

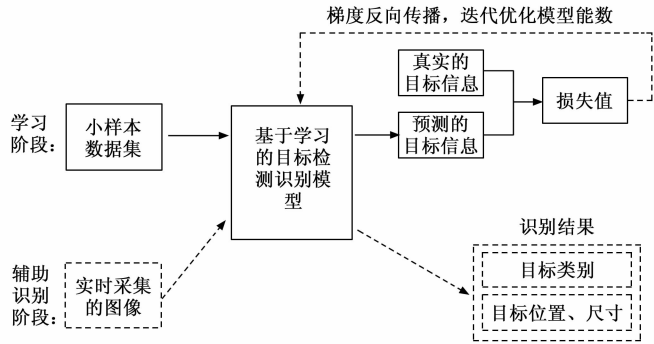


图 3 元器件目标检测算法流程

2.1.1 模型结构

如图 4 所示, 基于 Darknet+YOLO4 的目标检测模型采用神经网络结构, 主要包括特征提取主干网络 (CSP-DarkNet53)、颈部网络 (Neck Network) 和 head 预测模块三部分。

其中:

1) 主干特征提取网络: CSPDarkNet53 作为算法的主干特征提取网络, 由 5 个 CSPNet 子模块组成 (对应图 3 中的 Residual X), 充分提取图像特征后, 将后 3 个 CSPNet 模块提取的不同尺度图像特征传入 SPP 网络和 PANet 网络进行特征融合。

2) 颈部网络: 颈部网络由空间金字塔池化 SPP 模块和路径聚合网络 PANet 组合而成。SPP 模块对特征层进行 1×1 、 5×5 、 9×9 和 13×13 四种尺度的最大值池化 (Max pooling), 能有效提高网络的感受野, 更加有效地增加了主干特征的接收范围, 显著地分离了重要的上下文特征。PANet 是在特征金字塔网络 (FPN, feature pyramid network) 上添加了一个自下而上的路径增强结构, 避免在传递过程中出现浅层信息丢失的问题, 对传入的图像特征进行反复特征提取, 自底而上融合从主干网络不同特征层提取的特征, 形成强定位特征, 进一步提高特征提取和定位能力。

3) 头部网络: Head 网络用于回归和分类, 从颈部网络输入三种不同尺度的特征图, 分别检测小、中、大 3 种目标, 预测层经过处理输出目标得分、预测锚框尺寸坐标、分类置信度等。

4) 模型学习策略: 模型损失函数由回归框预测损失 L_{Clou} 、置信度损失 L_{Conf} 、分类损失 L_{cls} 三部分, 公式如下:

$$loss = L_{Clou} + L_{Conf} + L_{cls} \quad (3)$$

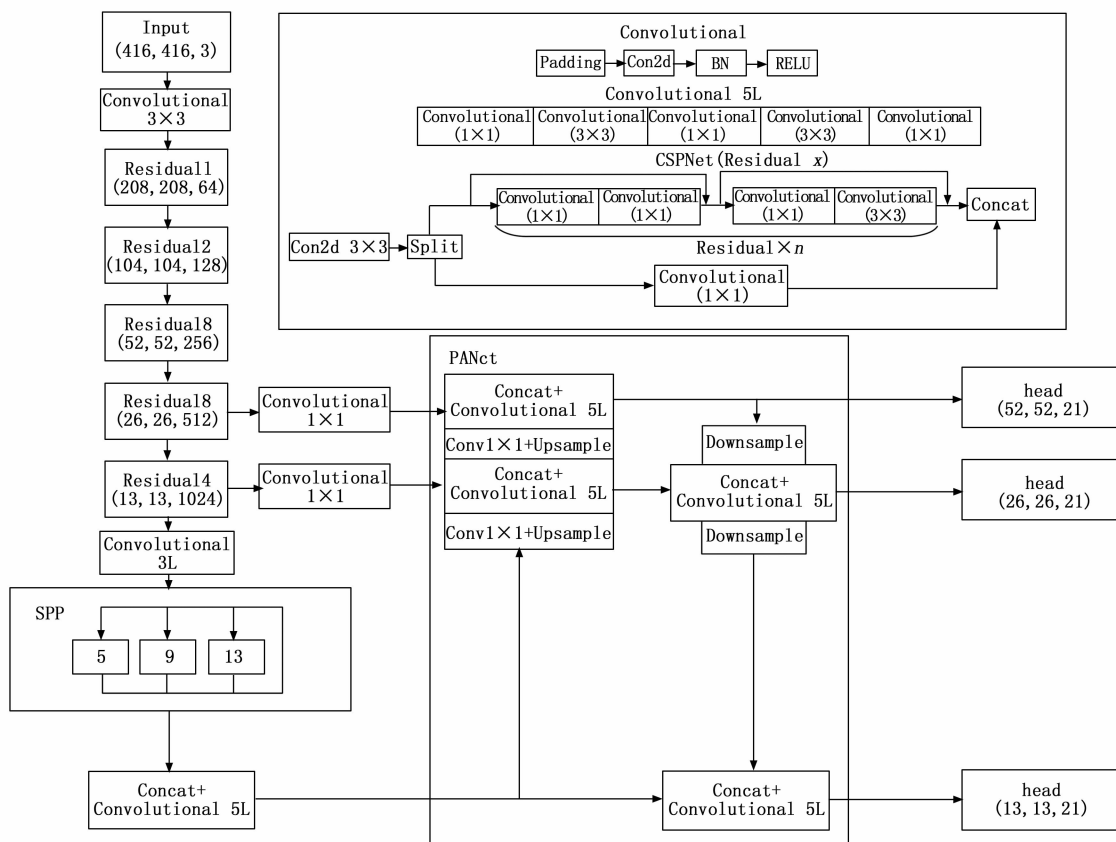


图 4 Darknet+YOLOv4 的目标检测模型结构

2.1.2 模型训练

本次训练采用命令行进行，经过对 YOLOv4 源码进行编译后，使用的训练命令如图 5 所示。

```

1 darknet.exe detector train
2 xxx.data xxx.cfg yolov4.conv.137
3 -map -gpus 0,1
    
```

图 5 模型训练指令

训练还需对整体文件进行配置，即手动设定 data 文件。xxx.data 文件为目录文件，包括了权重保存位置 (backup)、训练集序文件地址 (train)、验证集序文件地址 (val-id)、类名地址 (names)、类别数量 (classes)。

训练过程如图 6 所示，可以看出，当迭代训练 12 000 次后，模型的误差损失已经降为 0.459 7，mAP@0.5 为 99.2%，整体精度能够满足目标检测要求。

2.1.3 Weights 文件筛选

训练权重文件筛选主要依靠训练中的 Loss 曲线和 mAP 曲线以及对实时保存（每 100 epoch 保存一次）的模型进行单张预测或批量预测进行。

训练过程中算法会显示训练的实时 Loss 曲线和 mAP 曲线，每一个 epoch 的 Loss 和每 100 个 epoch (epoch > 1 000) 的 mAP 会形成曲线图。若 Loss 持续下降或成振荡

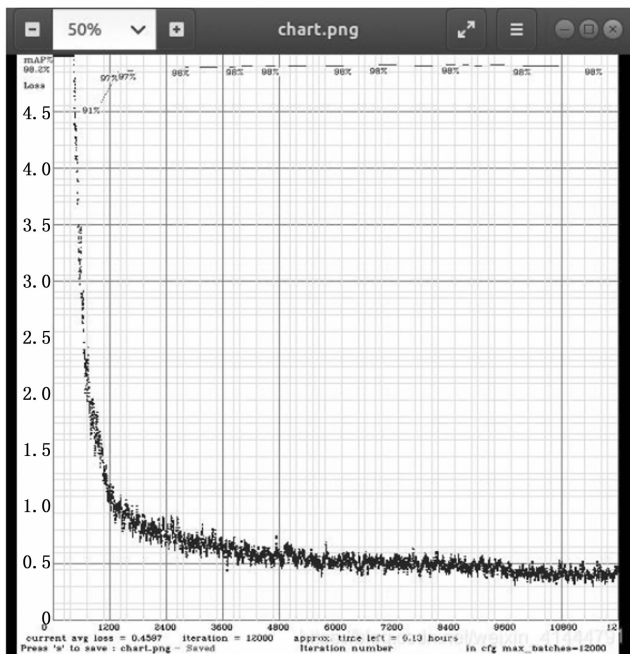


图 6 训练过程

下降过程，mAP 呈上升趋势为较好的训练结果。但是为防止过拟合出现，应根据实际情况进行判断是否停止训练。

根据实时的保存模型也可对训练效果进行筛选。使用

命令对权重文件进行单张不同图像 (不在训练集和测试集, 单独采集的图像) 进行预测, 通过预测结果对当前模型训练效果进行判断。

模型测试时需要关闭 `cfg` 中 `Train` 下的 `batch` 和 `subdivisions`, 打开 `Test` 下的 `batch` 和 `subdivisions`, 即使 `batch` 和 `subdivisions` 都为 1。

2.1.4 模型测试

输入实时采集的图像之后, 模型先将输入的图像缩放到固定的尺寸 (416×416), 然后输入到特征提取网络中进行特征提取, 经过颈部网络处理后将输入的图像提取成 $S \times S$ 的特征网格。在 `Head` 预测模块, 每个网格负责检测落在格子中的物体, 每个格子做以下几种预测, 该网格是否包含物体, 包含物体的置信度和包含物体的位置坐标分别是多少。因此, 每个小格需要预测的数据维度为 $B \times (1+4) + C$, 其中, B 代表每个网格先验框的个数, C 表示要检测的物体 (不包含背景) 类别个数, 包含每个类别的预测。1 表示该网格是否包含物体以及包含物体的置信度得分, 4 用于预测矩形框的位置坐标。因此, 网络模型最终特征层的大小为 $S \times S \times (B \times 5 + C)$, 也即每个网格包含 5 个预测值, 分别是 4 个位置坐标和 1 个置信度。置信度分数反映模型预测的边界框中是否包含物体, 及其预测的边界框的准确程度。如果该单元格中不存在目标, 则置信度分数为 0; 否则, 置信度分数应该等于预测框与真实值的 `IoU`。实际上, 这一步得到的结果并不是真实预测框, 还需要对其进行解码, 即用提前预设的先验锚框宽高对特征层的宽高进行计算, 计算真实预测框的公式为:

$$\begin{aligned} b_x &= \sigma(t_x) + c_x \\ b_y &= \sigma(t_y) + c_y \\ b_w &= p_w e^{t_w} \\ b_h &= p_h e^{t_h} \\ P_r(object) \times IoU(b, object) &= \sigma(t_0) \end{aligned} \quad (4)$$

结合图 7, 图中实线框代表预测框, 虚线框代表先验框, 公式中各参数的含义如下: c_x 和 c_y 代表先验框中心点所在区域的左上角的坐标, p_w 和 p_h 代表了当前先验框的宽和高, b_x, b_y, b_w, b_h 代表预测框的中心点坐标和长宽, t_x, t_y, t_w, t_h 代表模型学习得到的预测框相对于先验框的偏移量。公式中的 σ 代表 sigmoid 函数, 作用是将坐标偏移量变换到 $[0, 1]$ 区间, 这样得到的预测框的中心点坐标 b_x, b_y 会限制在当前区域内, 保证一个区域只预测中心点在该区域内的物体, 有利于模型收敛。最后, b_x, b_y, b_w, b_h 就是得到最后预测框的中心坐标以及宽高。

其中, 由于不同数据集的先验锚框尺寸也不尽相同, 在实际应用场景中需要根据数据集计算相应的锚框尺寸。本系统采用 K-means 聚类算法^[20] 计算锚框尺寸, 具体计算步骤如图 8 所示。

最后, 解码之后可能会出现多个高度重复的预测框指向同一个目标的情况, 而目标检测任务中理想的检测结果应该是和检测目标一一对应, 所以还需要对检测结果进行




图 7 边界框回归示意图

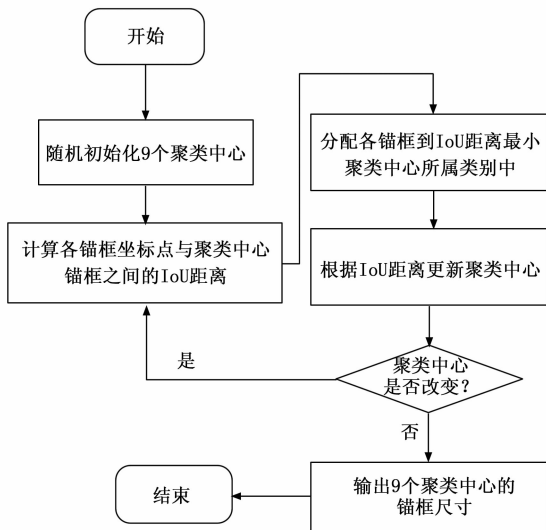


图 8 K-means 算法计算锚框尺寸

“去重”处理, 本系统使用非极大值抑制^[21] (NMS, non maximum suppression) 筛选出一定区域内属于同一种类的得分最高的预测框, 对检测结果进行“去重”。

2.2 红外温度识别

采用在线式监控测温热像仪进行视频拍摄, 能够实时地检测出电路板的温度变化。

2.3 图像配准

为了使可见光图像与红外图像实现配准, 配准值采用如下公式计算:

$$T_x = \left| \frac{LU_x}{W_s} * W_b - LU'_x \right| \quad (5)$$

其中: T_x 为配准值, LU_x 为红外图像中的框选轮廓外接矩形的左上角坐标 x 值, W_s 为红外图像宽, W_b 为可见光图像宽, LU'_x 为可见光图像框选轮廓外接矩形。Y 坐标配准同理所示。计算出的值为绝对值, 根据红外相机和可见光相机相对位置进行相应正负值设置。结合 PCB 板的电路设计和元器件指标的分析, 设置合适的温度阈值, 实现了异常发热元器件的定位。

2.4 故障检测

经过图像配准后, 通过设定异常温度阈值的形式, 能够判定温度异常区域, 然后该算法能够实现视频流下的元器件自动识别, 定位到元器件级短路故障, 以及短路故障

区域。

3 模型验证

3.1 整体框架

为验证基于 Darknet 网络和 YOLO4 的实时电路板故障检测算法性能,设计算法验证平台,主要包括软件算法和硬件处理平台,基本组成如图 9 所示。

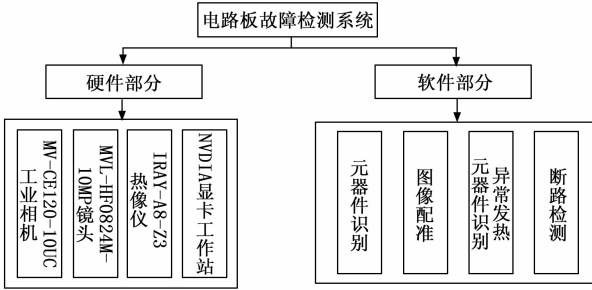


图 9 电路板故障诊断算法系统组成

3.1.1 硬件部分

本系统的硬件部分主要由 IRAY-A8-Z3 在线式监控测温热像仪、MV-CE120-10UC 工业相机,配套 MVL-HF0824M-10MP 镜头以及携有 NVIDIA 显卡的工作站构成。

3.1.2 软件部分

软件主要功能是实现特定缺陷检测、元器件识别、异常发热元器件识别和定位以及断路区域检测,并以人机交互的方式实现目标模型、参数的导入和设置以及检测识别结果的显示。

3.1.3 各模块功能简要说明

1) NVIDIA 显卡工作站:目前测试到的最低要求 GeForce 1050。由于构建软件识别的权重模型需要 GPU 进行高速计算,因此软件使用依赖于 NVIDIA 显卡。

2) 测温热像仪:采用 IRAY-A8-Z3 在线式监控测温热像仪,使用以太网网络接口及 I/O 信号输出。

3) 工业相机:采用海康威视 MV-CE120-10UC 工业相机,配套海康威视 MVL-HF0824M-10MP 镜头,使用 USB 进行数据传输。

4) 元器件识别:元器件识别指对 PCB 板上电阻、电容、电感等典型元器件进行识别和定位。

5) 图像配准:图像配准是指红外图像和可见光图像之间的对齐。

6) 异常发热元器件识别:异常发热元器件识别是指对 PCB 板上短路引起异常发热的元器件进行识别和定位。

7) 断路检测:断路检测是指针对元器件断路引起的 PCB 板不能正常工作的功能区域进行检测。

3.2 试验对象说明

如图 10 所示,为被测电路板设计原理图。电路板有多组电源转换电路、MCU 控制芯片,串口芯片、多路继电器控制电路、多路负载及指示灯组成。本电路能够在串口的控制下,实现不同继电器的开关闭合控制,从而接通或断

开不同的负载和指示灯。将这些状态预先定义为正常状态或某种故障状态,并通过红外相机进行拍摄和数据读取分析,根据红外成像的原理,在被测电路板元器件正常工作状态和非正常工作状态器件发热不同,红外成像的温度显示颜色不同,来分析出电路板故障位置和故障原因。从而达到演示红外成像故障诊断原理和验证红外成像故障诊断软件功能是否正常的效果。

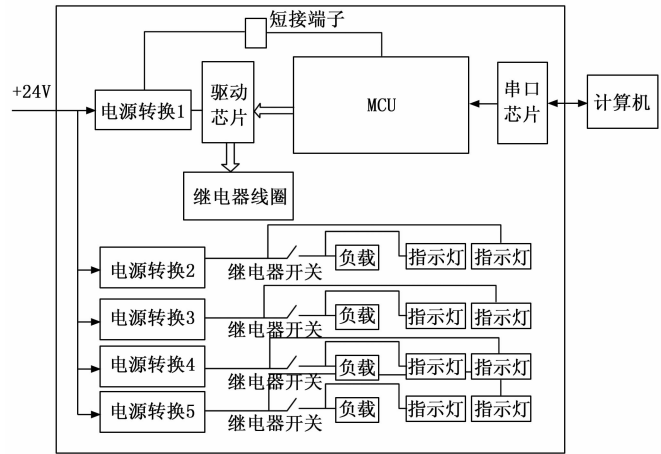


图 10 被测电路板设计原理图

3.2.1 电路板状态说明

电路板分为 4 个区域,每个区域通过 1 路电源控制后面 2 路负载通断,正常情况下,电路板上电后每个区域的电源正常工作,一路负载接通状态,另一路负载断开状态。这样红外相机测到不同区域正常状态时温度适中,短路状态温度偏高,断开状态温度偏低。电源无输出故障时电源区域温度偏低。

图 11 为标识电路板器件布局示意图,通过串口发送不同指令,使负载处于接通或断开状态,从而模拟不同的故障现象。




图 11 电路板器件布局示意图

3.2.2 被测电路板使用

被测电路板由多组电源转换电路、MCU 控制芯片,串口芯片、多路继电器控制电路、多路负载及指示灯组成。本电路能够在串口的控制下,实现不同继电器的开关闭合控制,从而接通或断开不同的负载和指示灯。将这些状态预先定义为正常状态或某种故障状态,并通过红外相机进

行拍摄和数据读取分析以及红外成像的原理, 根据被测电路板元器件正常工作状态和非正常工作状态器件发热的不同和红外成像温度显示颜色的不同, 分析出电路板故障位置和故障原因。从而达到演示红外成像故障诊断原理和验证红外成像故障诊断软件功能是否正常的效果。

将被测电路板连接线缆上电后, 被测电路板软件界面可通过串口连接被测电路板, 并通过发送指令来改变被测电路板工作状态, 从而模拟不同的故障现象, 提供给算法系统进行分析, 用于验证红外故障检测算法的功能。

4 实验结果与分析

PCB 红外故障检测软件主界面如图 12 所示, 通过采集实验对象运行过程中的红外图像数据提供给神经网络中训练为检测使用的图像模型, 进而识别出电路板预先设置好的故障。预想中的断路故障、短路故障和元器件等算法均可正确识别被测对象。将采集实验对象运行过程中的视频流, 输入到目标检测模型中, 用于元器件实时定位; 并基于红外图像识别温度异常, 经过图像配准后, 定位温度异常元器件, 以实现电路板元器件检测、元器件级短路, 以及区域级断路定位, 图 13~17 展示了实验结果。



图 12 PCB 红外故障检测主界面

通过 MV-CE120-10UC 工业相机及配套的 MVL-HF0824M-10MP 镜头, 采用 USB3.0 获取待检 PCB 板可见光图像, 然后进行图像配准, 将红外图像和可见光图像之间对齐, 如图 13 所示。



图 13 图像配准实验结果

元器件识别部分, 打开待识别的 PCB 电路板, 开始对 PCB 板上电阻、电容、电感等典型元器件进行识别和定位, 并打印出各种元器件的数量信息, 如图 14 所示。

断路检测针对元器件断路引起的 PCB 板不能正常工作的功能区域进行检测, 根据电路板的位置划定四个区域, 即将整个电路板区域分为平均分为 4 个小区域, 划定断路



图 14 元器件统计实验结果

检测区域, 进行检测。通过红外相机获取设定区域的平均温度, 包含最高温度, 最低温度, 使能状态, 平均温度, 相应温度坐标等。并进行相应的数据处理, 用来判定区域是否存在断路问题, 判断 PCB 是否断路的步骤:

- 1) 获取该区域的 5 个连续不同平均温度获取数量作为判断的灵敏度;
- 2) 判断这 5 个平均温度是否为依次减小的关系, 且第一个平均温度与第五个平均温度的差值大于 0.3, 设置 0.3 为判定阈值, 也可根据具体情况修改;
- 3) 若符合条件, 则为断路, 在图像中画出区域, 清空数据; 若不符合条件, 清空数据。

按照这个步骤得到的断路区域检测结果如图 15 所示, 并将得到的断路区域信息打印在主界面右下角, 提示区域断路。



图 15 断路区域检测

为方便调试和开发, 以及简化操作步骤, 断路检测判定以线程方式进行, 检测故障显示在红外发热检测线程进行, 与发热检测为顺序关系, 并通过发热检测的标志位进行控制。发热检测在进行元器件识别时需要降低资源占用关闭了相机, 因此断路检测暂停, 过程结束后自动恢复。

异常发热元器件识别对 PCB 板上短路引起异常发热的元器件进行识别和定位, 发热检测部分需要配置两组模型, 每组参数包括配置文件 cfg、data 文件和权重, 分别载入缺陷模型和元器件模型。采用 IRAY-A8-Z3 测温热像仪, 通过以太网和 I/O 口高速采集和传输红外图像和元器件工作温度。得到红外图像中的全局温度, 包含最高温度, 最低

温度、最高温度坐标 (x, y)、最低温度坐标 (x, y), 如图 16~17 所示。



图 16 发热检测 (1)



图 17 发热检测 (2)

实验表明, 预设中的断路故障、短路故障和元器件等算法均可正确识别被测对象。

5 结束语

本文结合深度学习技术, 针对现有的接触式电路板故障检测方法存在的问题, 提出一种新的实时非接触式电路板故障检测方法, 即基于 Darknet 框架和 YOLO4 的电路板元器件目标检测算法, 该方法结合 K-means 聚类算法实现元器件的实时定位识别, 结合红外和可见光图像, 根据红外温度指标判断元器件级短路故障以及区域级短路故障, 实现实时的电路板故障检测, 具备较好的工程应用效果。

本文研究有利于电路板故障检测的发展, 目前本文针对特定电路板型号得到了良好的预测结果, 未来将针对不同型号武器装备上的电路板进行泛化测试, 通过增加样本种类、样本规模、故障类型来提高模型的检测准确度; 并优化模型设计, 以实现元器件级的短路故障检测。

参考文献:

[1] 周金祖, 史志才, 曾国辉, 等. 基于改进隐马尔科夫模型的电路板故障诊断算法的研究 [J]. 化工自动化及仪表, 2015, 42 (1): 51-53, 57.

[2] 郝建新, 贾春宇. 基于 SVM 与改进 D-S 理论电路板故障诊断算法 [J]. 现代电子技术, 2019, 42 (22): 15-20.

[3] 王 力, 刘学朋, 张亦弛. 基于 BCL-ASA-BP 神经网络的模

拟电路板芯片故障诊断 [J]. 电子测量技术, 2022, 45 (14): 164-171.

[4] 谢永成, 李光升, 魏 宁, 等. 基于 GA-BP 神经网络的装甲车辆电路板故障诊断 [J]. 自动化与仪表, 2022, 37 (8): 97-101.

[5] 郝建新, 王 力. 基于红外温度序列的电路板故障诊断研究 [J]. 红外与激光工程, 2023, 52 (4): 59-70.

[6] 黄 威, 袁廷翼, 邓百川, 等. 基于深度学习的机器人电路板自主故障检测系统 [J]. 电工电能新技术, 2022, 41 (2): 72-80.

[7] SONG X D, XIAO F W, YI W G, et al. BOSF-SVM: A thermal image-based fault diagnosis method of circuit boards [J]. J. Intell. Fuzzy Syst., 2022 (44): 2741-2752.

[8] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection [J]. ArXiv abs/2004.10934(2020).

[9] 王 辉, 张 帆, 刘晓凤, 等. 基于 DarkNet-53 和 YOLOv3 的水果图像识别 [J]. 东北师大学报 (自然科学版), 2020, 52 (4): 60-65.

[10] 李 珣, 刘 瑶, 李鹏飞, 等. 基于 Darknet 框架下 YOLO v2 算法的车辆多目标检测方法 [J]. 交通运输工程学报, 2018, 18 (6): 142-158.

[11] 虞 许, 缪小冬, 顾寅曦, 等. 基于 GAF-DarkNet 的滚动轴承故障诊断方法 [J/OL]. 轴承: 1-9 [2023-02-14]. <http://kns.cnki.net/kcms/detail/41.1148.th.20230203.1325.002.html>.

[12] 梅玲玲. 基于深度学习的道路车辆目标检测系统设计 [J]. 计算机测量与控制, 2023, 31 (2): 83-90.

[13] 魏小玉, 焦良葆, 刘子恒, 等. 融合 YOLO v3 与改进 ReX-Net 的手势识别方法研究 [J/OL]. 计算机测量与控制: 1-16 [2023-03-22]. <http://kns.cnki.net/kcms/detail/11.4762.TP.20230309.1541.020.html>.

[14] 段中兴, 王 剑, 丁青辉, 等. 基于深度学习的盲道障碍物检测算法研究 [J]. 计算机测量与控制, 2021, 29 (12): 27-32.

[15] 牛振振, 陈力荣, 王 震, 等. 注意力机制与空洞残差网络的 PCB 缺陷检测 [J]. 现代信息科技, 2023, 7 (4): 10-13, 17.

[16] 侯 玥, 王开宇, 金顺福. 一种基于 YOLOv5 的小样本目标检测模型 [J]. 燕山大学学报, 2023, 47 (1): 64-72.

[17] 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 (4): 19-27.

[18] 何国忠, 梁 宇. 基于卷积神经网络的 PCB 缺陷检测 [J]. 图学学报, 2022, 43 (1): 21-27.

[19] 崔俊佳, 张 军, 苜茹茹, 等. 基于深度学习的自冲铆接偏铆缺陷检测算法研究 [J]. 航空制造技术, 2023, 66 (6): 22-30.

[20] 张 蕊, 张业荣. 基于双线性插值与 K-means 聚类算法结合的位置指纹定位改进算法 [J]. 光通信技术, 2022, 46 (5): 45-49.

[21] 张诗文, 邓春华, 张俊雯. 各向异性非极大值抑制在工业目标检测中的应用 [J]. 计算机应用, 2022, 42 (7): 2210-2218.