

DOI:10.19651/j.cnki.emt.2313912

电子元器件缺陷检测模型的自动训练系统^{*}

陈瑞阳¹ 周静¹ 王瑞丰¹ 刘鹏飞² 罗守华¹

(1.东南大学生物科学与医学工程学院 南京 210096; 2.深圳明锐理想科技有限公司 深圳 518000)

摘要:深度学习方法可提高AOI的速度和精度,但因实际工业生产中AOI场景多变,模型需不断更新以保证性能,耗时长,人力成本高。为了提高实际AOI中深度学习模型的迭代效率,研发了一套面向PCBA贴片电子元器件的缺陷检测模型自动训练系统,对常见的四类电子元器件(Chip、IC、SOT、排插)所需的缺陷检测模型实现了自动训练,自动训练过程分为自动数据增强、自动调参与自动部署3个部分。实验结果表明,该系统自动训练得到的模型性能总体优于人工手动训练的模型,相较人工手动训练,训练耗时缩短36%~42%,整体准确率提升1.3%~4.1%。目前该系统已经完成测试,自动训练出的模型能满足实际AOI的检测要求,有效提高了模型迭代速度,减少了人力成本,具有较好的应用前景。

关键词:PCBA;缺陷检测;深度学习;自动训练;工业应用

中图分类号: TP2 文献标识码: A 国家标准学科分类代码: 510.1050

Automatic training system of electronic component defect detection model

Chen Ruiyang¹ Zhou Jing¹ Wang Ruiyong¹ Liu Pengfei² Luo Shouhua¹

(1. School of Biological Science and Medical Engineering, Southeast University, Nanjing 210096, China;

2. Magic Ray Technology Co., Ltd., Shenzhen 518000, China)

Abstract: Deep learning methods can improve the speed and accuracy of AOI. However, due to the variable nature of industrial production scenarios, the models have to be updated continuously to ensure performance, which increases time and labor consumption. In order to improve the model iteration efficiency of deep learning methods in actual practice of AOI, an automatic training system for defect detection models of PCBA electronic components is developed in this paper. The system can automatically train the defect detection models required for four common types of electronic components(Chip, IC, SOT, and Plug-in). The automatic training process is divided into three parts: automatic data enhancement, parameter tuning, and deployment. Experimental results show that the models automatically trained by the system outperform the manual training models. Compared with manual training, the training time is shortened by 36% to 42%, and the overall accuracy is increased by 1.3% to 4.1%. At present, the proposed system has completed testing and the automatically trained model can meet the requirements of actual practice of AOI. It effectively improves the speed of model iteration, reduces labor costs and demonstrates its good application prospects.

Keywords: PCBA; defect detection; deep learning; automatic training; industrial application

0 引言

工业4.0时代,自动光学检测(automated optical inspection, AOI)逐渐代替人工目检,成为目前较先进的印刷电路板组件(printed circuit board assembly, PCBA)贴片电子元器件缺陷检测方式^[1-3]。近年来,深度学习在AOI的应用进一步提高了工业生产的自动化和智能化程度,解

决了传统工业检测技术的缺陷和瓶颈^[4-7],引起了许多国内外专业的AOI检测设备研发公司的重视和应用。神州视觉在ALD7710S机器中将传统图像处理算法与深度学习算法结合起来提高检测精度;盟拓以Chip元件检测为主,在产品内部配备了机器学习算法,并提供人工智能(artificial intelligence, AI)复判解决方案;KOH YOUNG提出KSMART解决方案,在Zenith2产品中实现了AI自动编

收稿日期:2023-06-15

*基金项目:国家自然科学基金(61871126)、江苏省重点研发计划(BE2022828)、江苏省前沿引领技术基础研究专项(BK20222002)资助

程与采集图像质量提升; VITROX 提出 V-ONE 解决方案, 在其 AOI 产品中应用了 AI 复判检测系统来辅助检测, 提高了检测精度, 降低了产线误报率。

尽管深度学习的方法可以更高效地解决 AOI 在工业生产中缺陷检测的问题, 但是由于生产线上的产品数量大、种类多、更新快, 模型需不断更新以保证性能, 所涉数据集制作、模型结构选择、超参数优化等操作仍需人工干预, 使得工业检测中深度学习方法的应用无法实现完全的自动化^[8-9]。随着智能化转型下企业应用开发需求大增, 关于自动化深度学习(automated machine learning, AutoML)的产品层出不穷^[10], 如华为开发了面向开发者的一站式 AI 开发平台 ModelArts、旷视自研了人工智能算法平台 Brain++、共达地推出了自研的 AutoML 自动化 AI 训练平台。但由于开发难度大、成本高且无法保证数据安全, 大部分公司目前仅使用深度学习算法辅助 AOI 检测, 模型自动化训练服务仍待进一步的开发与完善。

综上, 为了满足 AOI 检测对于模型迭代速度、精度和管理的需求, 提高模型训练的自动化程度, 本文开发了一套应用于多电子元器件缺陷检测的模型自动训练系统。在下面章节中对系统的实现细节进行了介绍: 首先设计了自动训练系统的整体架构; 接着对系统架构中的整体训练流程, 包括半自动数据标注、自动数据增强、自动调参与自动部署四个环节分别进行了设计与开发; 在实验部分, 本文首先在 Chip 数据集上, 围绕自研的自动数据增强算法展开实验, 分析了自研算法的性能, 然后均衡考虑自动训练系统的整体精度与效率, 对常见的 Chip、IC、SOT、排插四种数据集均进行了五类缺陷检测模型的训练与测试, 对测试结果进行了分析; 最后对本文方法进行了总结。

1 需求分析与架构设计

AOI 检测涉及到的电子元器件种类繁多, 各类电子元器件的缺陷类型也不尽相同, 每种电子元器件都需要进行相应的定制化检测, 开发难度高。表 1 展示了四类常见的电子元器件(Chip、IC、SOT、排插)的样式结构以及其可能出现的缺陷类型。

王瑞丰^[11]等研究了针对这四类电子元器件的 AI 缺陷检测方法(如图 1 所示), 并取得了较高的检测准确率。整体检测方法分为两个阶段, 第一阶段使用本体焊点定位网络对电子元器件图像中的本体和焊点区域进行定位; 第二阶段对定位到的本体数据, 根据有无字符判定进行本体字符识别或本体颜色识别, 并与电子元器件原始标注结果比较是否匹配, 对于定位到的焊点使用焊点缺陷检测网络判定是否出现缺陷。若本体与焊点的检测结果均无缺陷或不匹配, 则判定电子元器件正常(OK); 否则判定为缺陷(NG)。

四类电子元器件的 AI 缺陷检测方法^[11]或多或少包含图 1 网络的部分或全部网络模型的组合, 其中包括用于本

表 1 4 种类型电子元器件样式及检测的缺陷类型

电子元器件类别	图例	可检测缺陷类型
Chip	有字符	缺件、错件、破损、少锡、多锡、连锡、立碑、偏位
	无字符	
排插	有焊点	
	无焊点	缺件、安装反向
IC	四边焊点	缺件、短路
二极管		
SOT	三极管	缺件、错件、短路
	多引脚	

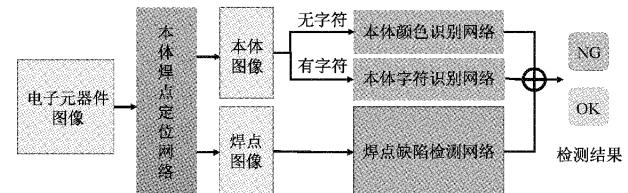


图 1 电子元器件 AI 缺陷检测方法

体与焊点定位的单次多盒检测器(single shot MultiBox detector, SSD)^[12]网络、用于本体颜色识别的双线性卷积(bilinear convolutional neural network, BCNN)^[13]网络、用于本体单字符定位的 CRAFT(character region awareness for text detection)^[14]网络、用于本体单字符分类的 MobileNetV2-4^[15]网络和用于焊点二分类(OK 或 NG)的 MobileNetV2^[15]网络等。为了保证 AI 缺陷检测方法的检测效果, 每类电子元器件检测方法中所有模型均需要单独训练, 手动训练周期较长, 无法较好地满足工业应用需求。

因此, 本文提出了一套应用于多电子元器件缺陷检测框架的深度学习模型自动训练系统, 系统整体架构如图 2

所示。该系统主要分为客户端与服务器端。客户端基于 MFC(microsoft foundation class library) 开发, 使用产线上的 AOI 图像采集接口进行电子元器件数据输入、缺陷检测、半自动数据标注、发布自动训练任务、下载网络模型等; 服务端由基于 Kubernetes 搭建的主-从服务器集群和基于 Django 开发的后台管理网页组成, 主服务器可接受一定量客户端的连接请求与数据传输并进行负载均衡, 将自动训练任务安排给多个子服务器执行, 技术人员可以从后台管理网页监测、管理当前的自动训练任务。对于完成的自动训练任务, 客户端可以从服务器上将最新的模型下载到本地进行部署, 快速实现模型更新。

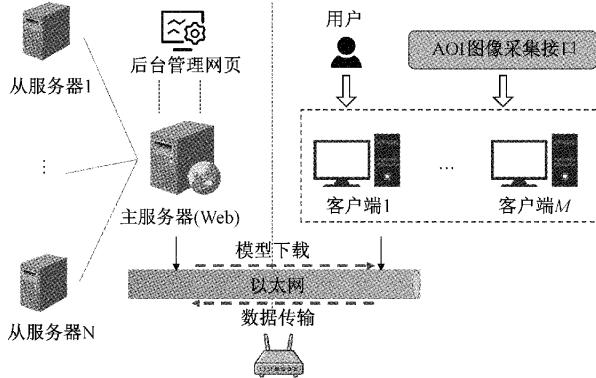


图 2 电子元器件缺陷检测自动训练系统框架

2 方 法

2.1 电子元器件缺陷检测深度学习模型自动训练流程

本文系统中的整体自动训练流程如图 3 所示。首先, 输入电子元器件图像确定类型后进行相应的 AI 缺陷检测, 对检测结果进行评估。如存在多张误判、漏判, 则对当前类型的电子元器件缺陷检测框架中的所有模型进行自动训练。本文的自动训练包含 4 个部分: 半自动数据标注、自动数据增强、自动调参、自动部署。在确定需要自动训练之后, 将之前误判、漏判等数据进行重新标注, 利用自动数据增强算法得到最佳增强策略, 再进行模型自动调参, 尽可能地最大化提升模型性能。当训练达到设定要求后, 将新模型自动部署回原来检测方法中, 完成一次模型的自动迭代过程。

2.2 半自动数据标注方法

深度学习模型前期需要投入大量人力与时间进行数据标注, 导致任务执行效率降低。因此本文基于现有的电子元器件缺陷检测方法, 设计了一种半自动数据标注的方法: 通过使用预训练的网络模型, 对电子元器件数据进行预测得到预标注结果, 再对该结果进行人工修正。这样尽可能减少人工的数据标注操作, 在提高数据标注效率的同时保证模型性能不会降低。图 4 以各个类型电子元器件本体焊点缺陷检测网络的数据标注为例, 展示了本文半自动数据标注的流程。

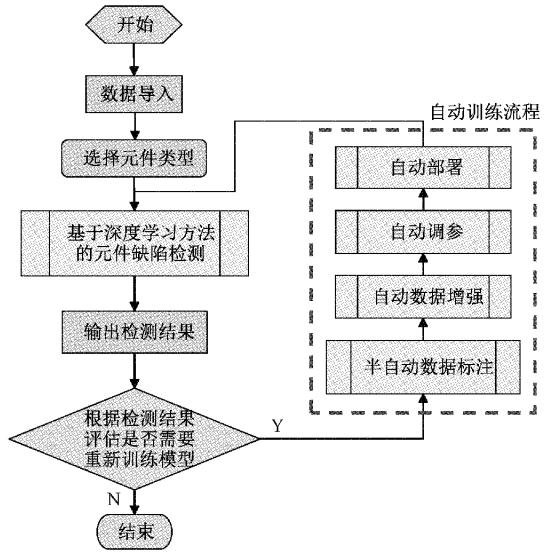


图 3 电子元器件缺陷检测深度学习模型

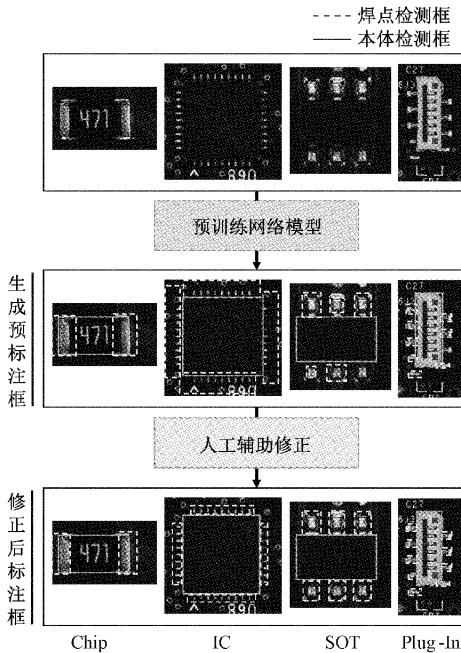


图 4 半自动数据标注流程(以本体焊点定位网络为例展示)

2.3 自动数据增强方法

模型训练时往往利用多种数据增强随机结合的方式对有限的数据进行扩充, 以尽可能提高模型的泛化能力。为了保证数据增强对模型泛化能力具有正向反馈, 数据增强操作组合需要依赖技术人员经验、大量实验和精心的设计, 增加了深度学习应用的复杂性和工作量。

近年来, 部分学者利用强化学习(reinforcement learning, RL)方法研究深度学习中数据强增策略的设计问题^[16-18]。Cubuk 等^[19] 提出了基于 RL 的自动数据增强算法 Autoaugment(AA), 根据循环神经网络(recurrent neural

network, RNN)的训练结果,从搜索空间中得到最优的数据增强策略;Lim 等^[20]提出了 Fast AutoAugment (Fast AA) 算法,该算法使用基于密度匹配的有效搜索策略来学习增强策略;Hataya 等^[21]提出了 Faster AutoAugment (Faster AA) 算法,该算法沿用 Fast AA 中的数据集拆分方式,对训练集进行对半拆分,且引入梯度近似,使策略搜索

过程端到端可微,显著减少了搜索时间。

本文基于 Faster AA 算法,对 AOI 电子元器件 AI 缺陷检测模型的自动数据增强算法从数据集划分、数据增强搜索空间和策略搜索 3 个部分加以改进,提出了基于数据类别的差异化自动数据增强算法(category-based faster autoaugment, CFAA),其完整流程如图 5 所示。

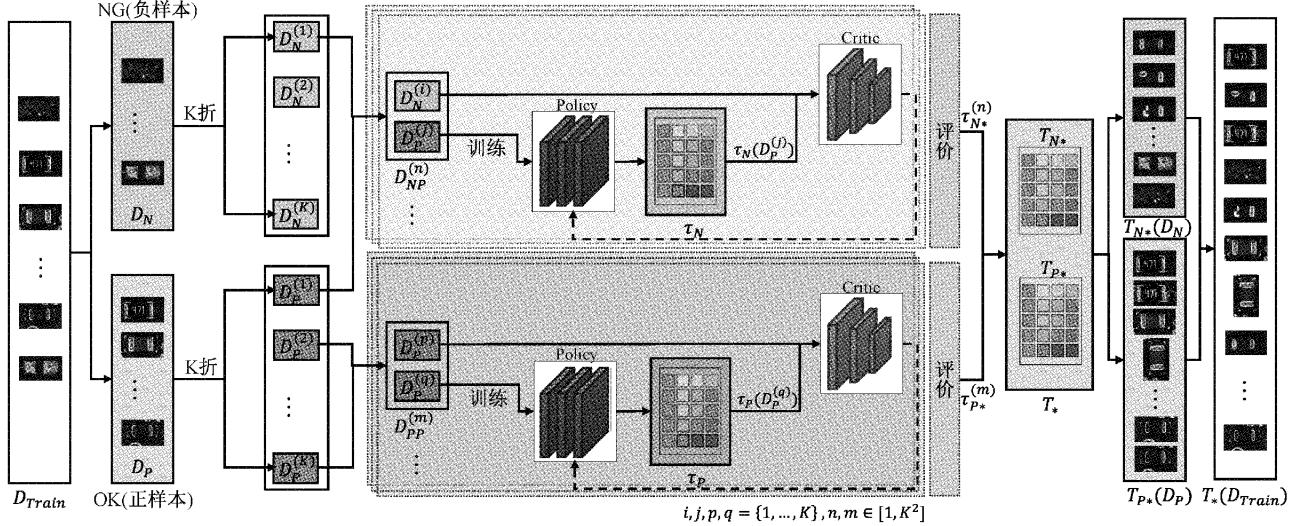


图 5 CFAA 算法流程

1) 按数据类别划分数据集

对 AOI 某类电子元器件数据集而言,不同型号的电子元器件数据之间存在些许大小、颜色、物料上的差异,除了正常数据与缺陷数据数量不均衡之外,在正常数据中不同型号的数据也存在不均衡的问题,网络对于数据量较少的类别识别率往往偏低。

因此,本文根据电子元器件数据集中的正负类别划分子数据集,对每个类别的电子元器件数据分别进行数据增强策略搜索,实现类别差异化数据增强,保证对数据量较少的类别有充分的增强,以解决数据集中类别不均衡的问题,如图 6 所示。

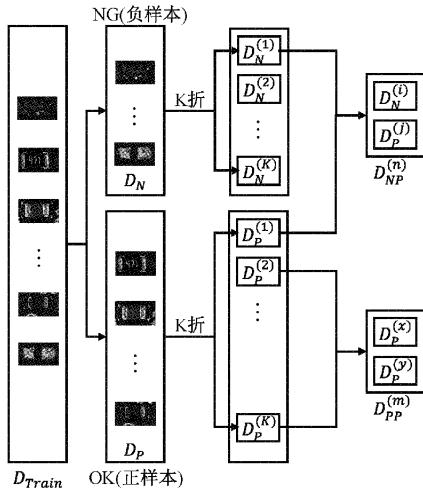


图 6 本文自动数据增强算法中的数据集划分方法

将目标训练数据集 D_{Train} 按数据类别划分为正样本集 D_P 和负样本集 D_N , 分别进行 K 折拆分。随机选择一个负样本子集 $D_N^{(j)}$ 和一个正样本子集 $D_P^{(j)} (j = 1, \dots, K)$ 组合成负样本训练子集 $D_{NP}^{(j)}$ ($j = 1, \dots, K$) 和正样本训练子集 $D_{PP}^{(m)}$ ($m = 1, \dots, M_P$) 组成正样本训练子集 $D_{PP}^{(m)}$ ($m = 1, \dots, M_P$)。其中 M_N 代表负样本最大子集数量, M_P 代表正样本最大子集数量, $D_{NP}^{(j)}$ 和 $D_{PP}^{(m)}$ 用于后期的网络训练。

2) 增加自定义数据增强操作

对于电子元器件数据集中极少数的缺陷数据,使用 Faster AA 算法中包含的 16 种基础的数据增强操作进行统一化处理无法提高网络对于缺陷数据的泛化能力,甚至会造成过拟合。因此本方法增加了 3 种针对 Chip 类电子元器件的自定义数据增强算法^[22],分别为电极移位(electrode shifting, ES)、随机缺省(random dropping, RD)、电极形变(electrode morphology transformation, EMT),通过由正常数据构造缺陷数据的方式实现对缺陷样本的增强,如图 7 所示。考虑到实际使用的网络类型、电子元器件类型与缺陷检测项等因素,本文在研究中不同程度地剔除了部分基础数据增强操作,并根据元器件的特点增加了对应的自定义数据增强,最后总结本文的自动数据增强算法中定义的搜索空间如表 2 所示。

3) 基于生成对抗网络的自动数据增强策略搜索

本文沿用了 Faster AA 中定义的 Differentiable Architecture Search(DARTS) 算法^[23] 作为策略生成器,选

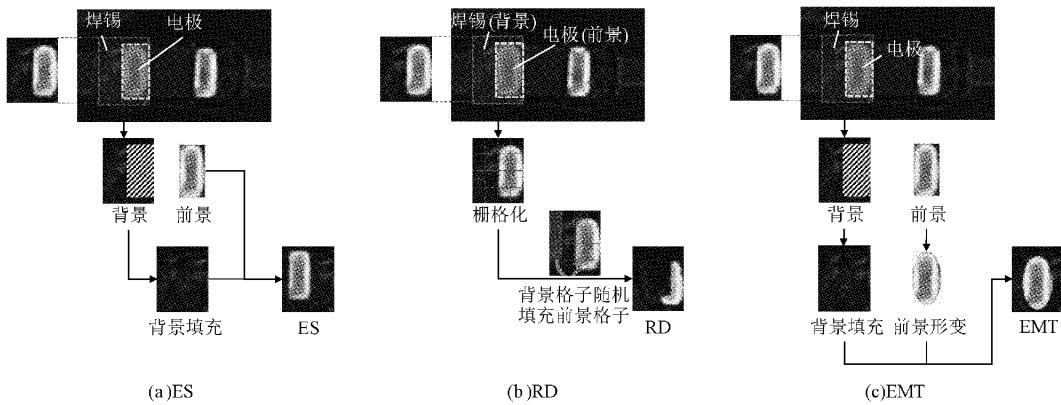


图 7 3 种自定义数据增强

表 2 本文自动数据增强算法中搜索空间定义

电子元器件类别	数据类型	数据增强搜索空间
Chip	正常(OK)	自动对比度、翻转、反转、均衡化、对比度、颜色空间变换、亮度、锐度
	缺陷(NG)	基础数据增强同上 + ES、RD、EMT
IC	正常(OK)	旋转、自动对比度、反转、均衡化、对比度、颜色空间变换、亮度、锐度
	缺陷(NG)	基础数据增强同上 + RD、EMT
SOT	正常(OK)	自动对比度、反转、均衡化、对比度、颜色空间变换、亮度、锐度
	缺陷(NG)	基础数据增强同上 + RD
排插	正常(OK)	自动对比度、翻转、均衡化、对比度、颜色空间变换、亮度、锐度
	缺陷(NG)	基础数据增强同上 + RD

取了轻量级的 MobileNetV2 作为判别器(Critic)的结构,针对于电子元器件数据集 OK 与 NG 类别采用了不同数据集组合方式进行生成对抗网络的训练,同时对于 OK 和 NG 数据增强搜索空间也有不同的定义。

对于负样本数据的数据增强空间 S_N 定义增加了由正样本数据生产负样本数据的自定义数据增强操作,如图 8(a)所示,因此对于负样本数据的数据增强策略搜索采用以负样本子数据集 D_N 和正样本子数据集 D_P 组合成训练数据 D_{NP} 的方式, D_P 作为 Policy 的输入来生成增强后能近似负样本数据的增强策略 τ_N ,而 $\tau_N(D_P)$ 和 D_N 作为 Critic 的输入用于训练能够识别增强和原始负样本数据的判别器来优化策略生成算法(Policy),最终根据最小化损失函数^[22]来得到最佳的负样本数据增强子策略 τ_{N*} 。

对于正样本数据的数据增强空间 S_P 有基础的数据增强操作组成,如图 8(b)所示,因此对于正样本数据的数据增强策略搜索采用两个正样本子数据集 D_P^1 和 D_P^2 组合成训练数据 D_{PP} 的方式, D_P^2 作为 Policy 的输入来生成增强后能近似正样本数据的增强策略 τ_P ,而 $\tau_P(D_P^2)$ 和 D_P^1 作为 Critic 的输入用于训练能够识别增强和原始正样本数据的判别器来优化 Policy,最终根据最小化损失函数来得到最佳的正样本数据增强子策略 τ_{P*} 。

对于子数据集 $D_{NP}^{(n)}$ 可以训练得到的最佳负样本数据增强子策略 $\tau_{N*}^{(n)}$,而对于子数据集 $D_{PP}^{(n)}$ 可以训练得到的最

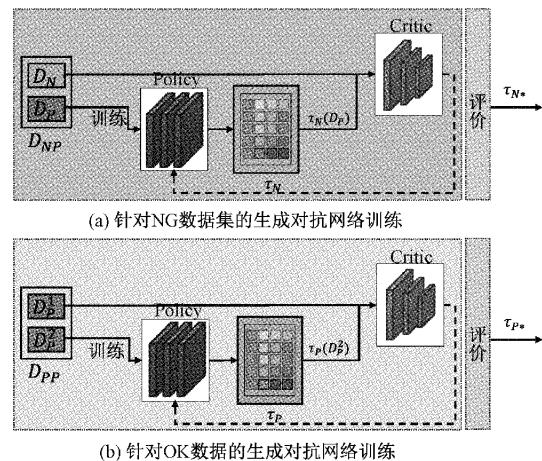


图 8 基于不同数据类别的生成对抗网络训练

佳正样本数据增强子策略 $\tau_{P*}^{(n)}$,取验证表现最佳前 u 个最佳子策略作为最佳数据增强策略 T_* 。对于最佳正样本数据增强策略 T_P 和最佳负样本数据增强策略 T_N 可分别表示为:

$$T_{P*} = \bigcup_{\tau_{P*} \in S_P}^u \{\tau_{P*}\} \quad (1)$$

$$T_{N*} = \bigcup_{\tau_{N*} \in S_N}^u \{\tau_{N*}\} \quad (2)$$

其中, u 为数据增强策略 T 中子策略 τ 的数量, S_P 和

S_N 分别为正样本和负样本的数据增强操作搜索空间。最终得到的训练数据集 D_{Train} 整体的数据增强策略记为 $T_* = T_{P^*} \cup T_{N^*}$ 。

2.4 自动调参方法

在训练神经网络的时候,调节超参数可以更科学地训练出高效的深度学习模型。调节超参数的步骤一般都是通过监测训练过程中的指标(如损失函数的值、验证集与测试集上的准确率)来判断这个模型性能是否达标,不达标则需根据一定的深度学习经验修改超参数重新训练,最终达到提高模型性能的目的。近年来,许多针对深度学习中自动调参算法的研究层出不穷,目前主流的调参算法包括网格化搜索(grid search)^[24]、随机搜索(random search)^[25]、基于树状结构帕尔森估计器的贝叶斯优化(Bayesian optimization with tree-structured parzen estimator, BO-TPE)^[26]、基于概率随机森林的贝叶斯优化算法(Bayesian optimization sequential model-based algorithm configuration, BO-SMAC)^[27]等。本文比较了随机搜索、BO-TPE 和 BO-SMAC 3 种主流的自动调参算法训练的 Chip 元件焊点缺陷分类网络,结果如表 3 所示,其中 M_{avg} 为平均验证性能,取 5 次优化结果的平均值。

表 3 自动调参算法对比结果

调参算法	训练时长/h	M_{avg} /%
Random Search	32	94.9
BO-TPE	13	99.0
BO-SMAC	14	98.8

可见,BO-TPE 和 BO-SMAC 算法较 Random Search 能够更容易在较短时间内找到最佳参数,获得较高的模型验证性能。BO-TPE 的优化算法主要是利用先验信息(之前已经搜索过的参数表现结果)预测下一次的参数。总体上,使用 BO-TPE 进行调参的模型获得了较短的搜索时间和较好的平均验证性能。考虑到实际工厂中的设备条件,本文系统采用了 BO-TPE 作为每个模型的自动调参算法。

2.5 自动部署

机器学习工程中的模型部署环节常采用人工部署的方式,该方法需要根据设备配置情况对训练好的模型文件进行格式转化、命名管理等操作再迁移到应用端使用,本文将这一系列操作自动化实现了自动部署,减少人工工作量的同时也节省了大量的时间。

如图 9 所示,本文将人工手动部署的流程中的模型文件转化和命名管理自动化,当服务接收到客户端的模型下载请求后,会根据客户端的配置信息将相应的模型进行自动转换和自命名,并记录客户端模型版本使用情况,随后发送给客户端,保存在其本地存储环境中。手动部署需要人工反复检查部署机器的配置信息与训练环境配置信息以保证使用的工具包版本匹配,再进行模型转换。同时还

需要对转换后的模型进行命名管理等最后部署到存储位置,而自动部署则显著简化了这一流程。

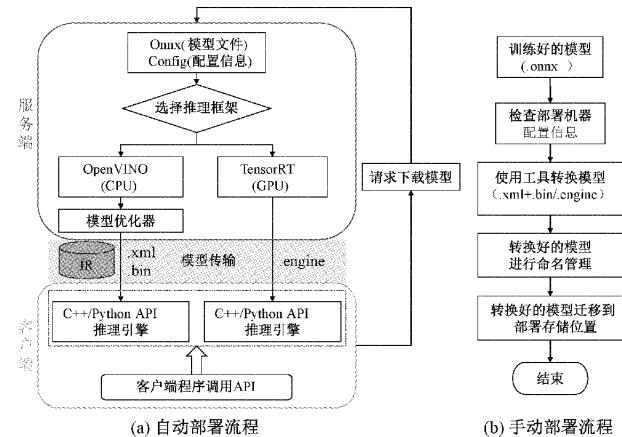


图 9 自动部署与手动部署流程图

3 实验结果与分析

3.1 自动数据增强方法实验结果

本文制作了 4 种类型元件的数据集:Chip 数据集、IC 数据集、SOT 数据集和排插数据集。Chip 数据集由 234 89 张 Chip 电子元器件图像组成,其中缺陷图像有 4 873 张;IC 数据集由 13 282 张 IC 元件图像组成,其中缺陷图像 2 342 张;SOT 数据集由 27 275 张 SOT 组成,其中缺陷图像 1 022 张;排插数据集由 12 820 张排插图像组成,缺陷图像有 1 932 张。

由于篇幅所限,本文的 CFAA 分别基于针对 Faster AA 所做的 3 种改进在 Chip 类型电子元器件数据集上进行消融实验,以验证其对各缺陷检测模型的性能影响。由于数据集中正常数据较多,因此本文仅从正常数据中随机抽取 5 000 张作为训练集,其余部分用作测试集;对于缺陷数据,则随机选取 70% 作为训练集,30% 作为测试集。表 4 为消融实验条件设置情况,其中按类别划分数据集部分取拆分数 K=2,引入了自定义数据增强等选项。

表 4 消融实验条件设置情况表

算法	按类别划分		Critic 结构为 MobileNetV2
	数据集	自定义数据增强	
a1	—	—	—
a2	✓	—	—
a3	✓	✓	—
a4	—	—	✓
a5	✓	✓	✓

实验基于 Intel(R) Core(TM) i7-8700K CPU,16 GB 内存,搭载 NVIDIA GeForce RTX 3090 显卡的硬件环境,在 Windows 11 操作系统,CUDA11.0 版本,Python 3.8,Pytorch-GPU1.13.2 的深度学习环境下进行。

表 5 展示了基于 a1~a5 条件设置下的 Faster AA 在 Chip 数据集上的各模型验证结果。如表 5 中消融实验 a1 和 a2 的结果所示,按类别划分数据集的 Faster AA 较随机划分的 Faster AA 所得到的数据增强策略对各缺陷检测模型性能略有提升;在 a3 中,基于类别划分数据集的基础之上按需将 3 种自定义增强方法引入 Faster AA 的搜索空

间中,取得了相比于 a1 和 a2 更高的模型性能;在消融实验 a3 和 a5 的结果对比中,CFAA 将 Critic 骨干结构从 WideResNet-40-2 替换成 MobileNetV2 后,模型检测精度有所下降,可能的原因是 WideResNet-40-2 具有比 MobileNetV2 更好的特征提取能力,而 MobileNetV2 具有更加轻量、快捷的优点。

表 5 基于 Chip 数据集下的各缺陷检测模型消融实验结果

数据增 强策略	SSD			BCNN				CRAFT				MobileNetV2-4				MobileNetV2			
	AP_{body}	AP_{land}	mAP	P	R	H	$Top 1/\%$	P	R	H	$Top 1/\%$	P	R	H	$Top 1/\%$	P	R	H	$Top 1/\%$
a1	0.98	0.97	0.98	0.96	0.97	0.96	96.7	0.98	0.97	0.97	97.6	0.97	0.96	0.96	96.4	0.97	0.96	0.96	97.3
a2	0.98	0.97	0.98	0.97	0.97	0.97	96.9	0.98	0.98	0.98	97.9	0.97	0.96	0.96	96.5	0.97	0.97	0.97	97.6
a3	0.99	1.00	1.00	0.99	0.99	0.99	98.9	0.99	0.99	0.99	99.2	0.98	0.99	0.98	98.6	1.00	0.99	0.99	99.2
a4	0.96	0.95	0.96	0.96	0.96	0.96	95.8	0.96	0.95	0.95	94.9	0.95	0.94	0.94	94.2	0.97	0.96	0.96	96.8
a5	0.99	1.00	1.00	0.98	0.99	0.98	98.7	0.99	1.00	0.99	99.2	0.98	0.98	0.98	98.4	1.00	0.99	0.99	99.1

为了更好的验证算法的执行效率,本文继续比较了 a3 和 a5 在 Chip 数据集下的平均 GPU 时耗,结果显示 a3 平均时耗 33 h,a5 平均时耗 22 h,a3 相比 a5 牺牲了较多的计算时间来获取更好的模型性能。因此,以 MobileNetV2 为 Critic 骨干结构的 CFAA,其结构更简单、计算量较少,可取得更快的训练速度,更适合用于工业场景的应用以追求

更快速的模型优化过程。

此外,本文按类别划分数据集并引入自定义数据增强操作的搜索空间,在 Chip 数据集上进行对比实验。表 6 展示了各种数据增强策略下在 Chip 数据集上各个模型的验证结果,其中 a 为无策略,b 为人工设定策略,c 为 WideResNet-40-2 为 Critic 骨干的 Faster AA,d 为本文 CFAA 方法。

表 6 各种数据增强策略下基于 Chip 数据集训练的验证网络性能表

数据增 强策略	SSD			BCNN				CRAFT				MobileNetV2-4				MobileNetV2			
	AP_{body}	AP_{land}	mAP	P	R	H	$Top 1/\%$	P	R	H	$Top 1/\%$	P	R	H	$Top 1/\%$	P	R	H	$Top 1/\%$
a	0.91	0.94	0.93	0.88	0.87	0.87	87.4	0.91	0.90	0.90	91.0	0.85	0.91	0.88	87.8	0.89	0.85	0.87	88.0
b	0.97	0.93	0.95	0.91	0.91	0.91	91.2	0.94	0.92	0.93	94.3	0.93	0.95	0.94	94.2	0.95	0.93	0.94	94.3
c	0.98	0.97	0.98	0.96	0.97	0.96	96.8	0.98	0.97	0.97	97.6	0.97	0.96	0.96	96.7	0.97	0.96	0.96	97.3
d	0.99	1.00	1.00	0.98	0.99	0.98	98.7	0.99	1.00	0.99	99.2	0.98	0.98	0.98	98.4	1.00	0.99	0.99	99.1

结合应用场景分析,本文选择自动数据增强算法的标准需要从搜索速度和对模型性能提升两大方面综合考虑。由表 6 可知,CFAA 相比 Faster AA 在各个模型上表现出了更好的性能。在消融实验中,本文已验证了 CFAA 算法搜索具有较少的 GPU 时耗。从验证模型性能和算法 GPU 时耗两方面考量,本文设计的 CFAA 具有更少的搜索时间,与 Faster AA 算法相比,CFAA 算法所得到的数据增强策略对模型性能的提升能力更强。同时,CFAA 算法中的类别差异化的数据增强有效解决了电子元器件数据不均衡情况下模型精度的提升问题,因此相比于其他自动数据增强算法更适用于电子元器件 AI 缺陷检测场景。

3.2 整体系统测试

针对本文系统,分别进行了系统功能测试与系统性能测试。系统功能测试主要针对电子元器件缺陷检测模块、自动数据标注模块、自动数据增强模块、自动调参模块、自

动部署模块测试是否达到预期目标。目前各项功能测试效果与预期一致。

系统性能测试主要针对该系统的自动训练时长与模型准确率进行测试,并与人工训练的方法进行比较。实验基于 AMD@Ryzen5 2600X six-core CPU,16 GB 内存,搭载 NVIDIA GeForce RTX 3090 显卡的硬件环境,在 Ubuntu 18.04.6 LTS 操作系统,Docker 1.18.06、Mysql 8.0、Python 3.8.10、Pytorch 1.10.2 的深度学习环境下进行,推理框架使用 OpenVINO/TensorRT。

本部分实验中,Chip、IC、SOT、排插数据集同 3.1 节,每类元件具有多种类型的缺陷,每类元件的数据集按照正常图像、每类缺陷图像随机选取 70% 组成训练集,30% 组成测试集。本文分别对 4 种元件缺陷检测框架的所有模型进行自动训练和人工手动训练,统计整体准确率如表 7 所示。可见,采用本系统进行自动训练得到的元件缺陷检测框架整体准确率比手动训练得到的高 1.3%~4.1%。

表 7 自动训练与手动训练模式下 4 种电子元器件缺陷

电子元器件	检测框架整体准确率 %	
	自动训练	手动训练
Chip	99.5	98.2
IC	99.0	94.9
SOT	99.9	97.4
排插	99.7	96.8

本文以 4 类电子元器件的焊点缺陷分类网络模型为例,

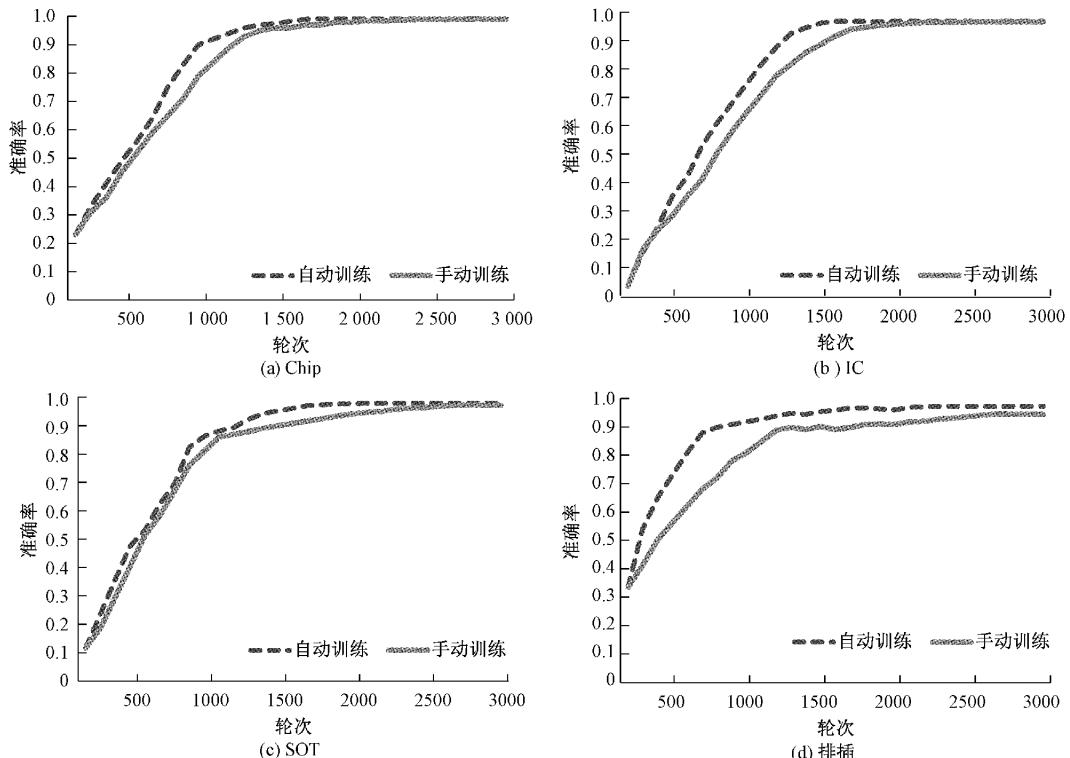
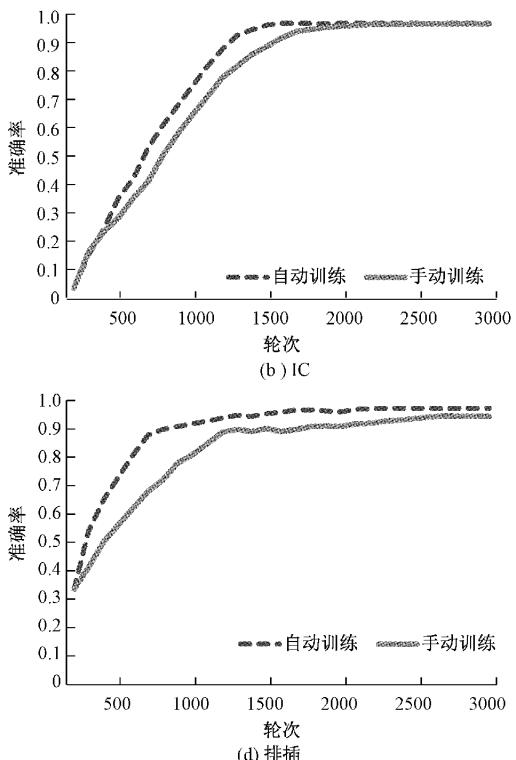


图 10 自动训练与手动训练电子元器件本体焊点定位 SSD 模型性能对比图

本文的自动训练系统无需依赖经验进行调参,通过特定的参数搜索空间,使用优化算法即可找到最佳参数,得到训练模型之后进行自动部署。表 8 展示了 4 种原件缺陷检测自动训练与手动训练的时间占比情况,其中由于经验调参时间无法估算,因此仅计算基于已获得的经验型超参数和自动训练参数的训练时间。本文的系统较手动训练

同类电子元器件以相同的初始权重、数据集分配,不同方法(自动训练与手动训练)获得的超参数配置训练其焊点缺陷分类网络,得到如图 10 所示的模型轮次-准确率折线图。实验发现,基于自动训练的分类模型收敛速度比基于手动训练的分类模型快 500~900 轮,且自动训练的分类模型准确率相比手动训练的分类模型准确率略有提升;自动训练得到的超参数更靠近全局最优解,使得模型优化朝着一个更快、更准的方向调整,而手动训练得到的超参数陷入局部最优解,数据增强设置、超参数调整主要依赖工程师的经验,训练模型往往耗费大量时间,且耗时不可衡量,对提升模型性能也收效甚微。



数据标注时间缩短 21%~48%,训练时间缩短 22%~53%,部署时间缩短 60%~75%,总体时间缩短 36%~42%。综合测试与实验结果,本系统模块交互体验较好,模型准确率高,迭代速度快,总体效果都显著高于传统手动训练的模式,基本达到预期的效果。

4 结 论

为了提高深度学习方法在 AOI 检测中的自动化应用程度、减少人工成本、提高模型精度和生产效率,本文研发了一套针对 4 类常见 PCBA 电子元器件(Chip、IC、SOT、排插)缺陷检测模型的自动训练系统,主要包括半自动数据标注部分、基于 CFAA 算法的自动数据增强部分、基于 BO-TPE 算法的自动调参部分和自动部署部分。经过测试与实验,本系统较传统手动训练 4 种电子元器件缺陷检测模型的整体迭代时间缩短 36%~42%,缺陷检测框架整

表 8 4 种电子元器件缺陷检测自动训练与

手动训练时间占比 h

电子元器件	手动训练时长/自动训练时长		
	数据标注	训练	部署
Chip	35.7/28	29.5/13.8	0.8/0.3
IC	24/14.8	28.7/16.3	1/0.4
SOT	21.5/11	12.9/9.4	0.3/0.1
排插	18/9.5	15.7/12.1	0.4/0.15

体准确率提升 1.3%~4.1%。目前,该系统已完成多次测试,基本达到预期效果,能够有效缩减模型迭代时间,提升模型性能,满足工业缺陷检测对自动化解决方案的需求,且具备高度的可拓展性,应用前景广泛。不足的是,目前的结果仅为实验数据结果,需要在实际工业检测产线上进一步部署、测试和优化,系统在不同工业场景和平台上的部署和集成也有待完善。此外,除了 AOI 电子元器件检测算法外,系统增强算法库的拓展性还需增强,以减少前期算法的开发工作。

参考文献

- [1] 李维创,尹柏强.工业金属板带材表面缺陷自动视觉检测研究进展[J].电子测量与仪器学报,2021,35(6): 1-16.
- [2] 凌云.磁材自动光学检测设备的评价要素[J].国外电子测量技术,2015, 34(7): 13-18.
- [3] 刘莉,陈玉,程军,等.基于贝叶斯模型的印刷电路板 ECT 图像分割与识别方法[J].国外电子测量技术,2022, 41(9): 1-8.
- [4] PARK S, KO J H. Robust inspection of Micro-LED chip defects using unsupervised anomaly detection[C]. 2021 International Conference on Information and Communication Technology Convergence (ICTC), 2021: 1841-1843.
- [5] KIM J, KO J, CHOI H, et al. Printed circuit board defect detection using deep learning via a skip-connected convolutional autoencoder [J]. Sensors, 2021, 21(15): 4968.
- [6] BHATTACHARYA A, CLOUTIER S G. End-to-end deep learning framework for printed circuit board manufacturing defect classification[J]. Sci Rep, 2022, 12(1): 12559.
- [7] JEON M, YOO S, KIM S W. A contactless PCBA defect detection method: Convolutional neural networks with thermographic images [J]. IEEE Transactions on Components, Packaging and Manufacturing Technology, 2022, 12(3): 489-501.
- [8] KARMAKER S K, HASSAN M M, SMITH M J, et al. AutoML to date and beyond: Challenges and opportunities[J]. ACM Computing Surveys, 2022, 54(8): 1-36.
- [9] LI Y, WANG Z, DING B, et al. AutoML [C]. Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining, 2021: 4048-4049.
- [10] ZOPH B, LE Q V. Neural architecture search with reinforcement learning [J]. ArXiv Preprint, 2016, ArXiv:1611.01578.
- [11] 王瑞丰,魏嘉莉,周静,等.一种基于 AI 的 Chip 类元件 AOI 自动复判方法[J].电子测量技术,2021, 44(15): 114-121.
- [12] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector[C]. Computer Vision-ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11-14, 2016, Proceedings, Part I 14. Springer International Publishing, 2016: 21-37.
- [13] LIN T Y, ROYCHOWDHURY A, MAJI S. Bilinear CNN models for fine-grained visual recognition[C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1449-1457.
- [14] BAEK Y, LEE B, HAN D, et al. Character region awareness for text detection[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 9365-9374.
- [15] SANDLER M, HOWARD A, ZHU M, et al. Mobilenetv2: Inverted residuals and linear bottlenecks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
- [16] 郭梦杰,任安虎.基于深度强化学习的单路口信号控制算法[J].电子测量技术,2019, 42(24): 49-52.
- [17] 刘中明,周岩,刘博,等.基于改进深度强化学习的电力智慧供应链高维度决策模型研究[J].电子测量技术,2019, 42(23): 53-60.
- [18] 杨傲雷,陈燕玲,徐昱琳.基于强化学习的机器人手臂仿人运动规划方法[J].仪器仪表学报,2021, 42(12): 136-145.
- [19] CUBUK E D, ZOPH B, MANE D, et al. Autoaugment: Learning augmentation policies from data[J]. ArXiv Preprint, 2018, ArXiv:1805.09501.
- [20] LIM S, KIM I, KIM T, et al. Fast AutoAugment[C]. Proceedings of the 33rd International Conference on Neural Information Processing Systems, 2019: 6665-6675.
- [21] HATAYA R, ZDENEK J, YOSHIZOE K, et al. Faster autoaugment: Learning augmentation strategies using backpropagation[C]. Computer Vision-ECCV 2020: 16th European Conference, Glasgow, UK, August 23-28, 2020, Proceedings, Part XXV 16. Springer, 2020: 1-16.
- [22] ZHOU J, LI G, WANG R, et al. A novel contrastive self-supervised learning framework for solving data imbalance in solder joint defect detection[J]. Entropy, 2023, 25(2): 268.
- [23] LIU H, SIMONYAN K, YANG Y. Darts: Differentiable architecture search[J]. ArXiv Preprint, 2018, ArXiv:1806.09055.
- [24] LIASHCHYN SKYI P, LIASHCHYN SKYI P. Grid search, random search, genetic algorithm: A big

- comparison for NAS [J]. ArXiv Preprint, 2019, ArXiv:1912.06059.
- [25] 杨帆. 随机搜索算法在医疗器械人性化色泽设计中的应用[J]. 电子测量技术, 2020, 43(17): 92-96.
- [26] HOSEIN GHANEMI A, TARIGHAT A. Use of different hyperparameter optimization algorithms in ANN for predicting the compressive strength of concrete containing calcined clay [J]. Practice Periodical on Structural Design and Construction, 2022, 27(2): 04022002.
- [27] BISCHL B, BINDER M, LANG M, et al. Hyperparameter optimization: Foundations, algorithms, best practices, and open challenges [J]. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 2023, 13(2): e1484.

作者简介

陈瑞阳,硕士,主要研究方向为计算机视觉、目标检测、目标分割。

E-mail:847899115@qq.com

周静,硕士,主要研究方向为计算机视觉、缺陷检测、目标检测、自动训练。

E-mail:1021937079@qq.com

王瑞丰,硕士,主要研究方向为计算机视觉、人工智能、自动光学检测等。

E-mail:wrfseu@163.com

刘鹏飞,主要从事自动光学检测相关研究。

E-mail:liupengfei@magic-ray.com

罗守华(通信作者),教授,博士生导师,主要研究方向为医学图像处理、CT 图像重建、模式识别。

E-mail:luoshouhua@seu.edu.cn