

DOI: 10.19650/j.cnki.cjsi.J2412901

基于机器视觉的锂电池缺陷检测研究进展*

于瀚文, 吴一全

(南京航空航天大学电子信息工程学院 南京 211106)

摘 要: 锂电池作为新能源汽车的核心组件之一,其复杂的制造工艺流程不可避免地引入各种缺陷,严重影响产品的质量,缺陷检测已成为锂电池制造流程中的重要环节,而兼顾了精度与速度优势的机器视觉方法受到高度关注。本文综述了近 15 年来基于机器视觉的锂电池缺陷检测方法的研究进展。首先简介锂电池表面常见的缺陷类型,阐明视觉缺陷检测的主要流程。然后重点阐述了基于传统图像处理的锂电池缺陷检测方法,对检测流程中的图像预处理、图像分割、特征提取、分类识别 4 大步骤进行了详细的解释说明,并对比每个步骤中各类方法的优缺点。接着按分类网络、检测网络、分割网络这 3 类综述了基于深度学习的锂电池缺陷检测方法。随后整理了 10 个锂电池自建数据集和缺陷检测性能评价指标。最后指出针对锂电池缺陷检测目前面临着诸多方面的技术挑战,并对未来的工作进行了展望。

关键词: 锂电池;缺陷检测;机器视觉;图像处理;深度学习;性能评价指标

中图分类号: TP391.41 TH89 TK02 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Research progress on defect detection of lithium battery based on machine vision

Yu Hanwen, Wu Yiquan

(College of Electronic and Information Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

Abstract: Lithium battery is one of the core components of new energy vehicles. But, the complex manufacturing process of lithium battery inevitably introduces various defects, which seriously affects the quality of products. Therefore, defect detection has become an important part of lithium battery manufacturing process. The machine vision method takes into account the advantages of accuracy and speed, which has been paid much attention to. In this article, the research progress of defect detection methods for lithium battery based on machine vision in recent 15 years is reviewed. Firstly, the common surface defect types of lithium battery are introduced, and the main flow of visual defect detection is clarified. Next, the defect detection method of lithium battery based on traditional image processing is emphasized. The four steps, including image preprocessing, image segmentation, feature extraction and classification recognition, are explained in detail. The advantages and disadvantages of each step are compared. Then, the defect detection methods based on deep learning are summarized according to the classification network, detection network and segmentation network. Afterwards, 10 self-built datasets of lithium battery and performance evaluation index of defect detection are sorted out. Finally, it is pointed out that the defect detection of lithium battery is faced with many technical challenges, and the future work is prospected.

Keywords: lithium battery; defect detection; machine vision; image process; deep learning; performance evaluation index

0 引 言

近年来,国家积极倡导绿色环保出行,新能源产品大量涌入市场,其中新能源汽车的关注度日益提升。锂电池作为新能源汽车的主要动力源,种类大致可以分为柱

形锂电池、方形锂电池以及软包锂电池 3 种。柱形锂电池工艺成熟,供压稳定,生产成本不高,有着较高的普及率,日常生活中所用的 5 号电池即为柱形锂电池。方形锂电池主要分为钢壳式和铝壳式,其结构简单,封装可靠性高,能量密度高于圆柱形锂电池,在国内市场占有一定的份额。软包锂电池循环性能好、寿命长、安全性高,一

收稿日期:2024-05-30 Received Date: 2024-05-30

* 基金项目:国家自然科学基金(61573183)项目资助

般不会出现其他类型电池爆炸的情况,并且设计灵活,有着显著的经济效益。

不同类型的锂电池有着相似的制造工艺流程,总体可将锂电池的生产工艺分为前、中、后 3 道工序。前段工序主要是锂电池极片制造,从原材料制备到分切固定规格的极片,主要有制浆、涂布、烘烤、辊压、裁剪等步骤;中段工序主要完成锂电池电芯生产,根据规格需求将分切好的极片按叠片或者卷绕的方式处理,主要有制片、卷绕、封装、注液等步骤;后段工序作为最后一步,主要是完成锂电池一系列的质检,保证电池的质量和安全性,主要有组装和测试等步骤。

在锂电池的生产过程中,锂电池表面易受到原料品质、生产设备状态、生产工序以及人为主观差异等多种因素的影响而出现气泡、划痕、褶皱等各式各样的缺陷,进而影响着产品的表面质量。产品表面质量不仅是其商业价值的重要保证,更是产品质量的关键组成部分,已成为市场竞争的重要指标之一。于是,表面缺陷检测如今已成为锂电池生产过程中不可或缺的步骤。目前,大量锂电池生产企业的缺陷检测方式仍然以人工检测方式为主,这种方式检测效率低,且高强度的工作环境容易导致高误检率和高漏检率。另外,人工的操作会给车间带入大量灰尘等脏污粘到电池表面,且不留意可能会损伤电池,无形中增加了次品率。随着无损检测技术的发展,锂电池的缺陷检测迎来了新的研究热潮,热成像检测^[1-3]、射线检测^[4-6]、超声检测^[7]、磁场成像检测^[8]被广泛应用于其中。热成像检测灵敏度高,使用安全,但红外热图像对比度低,不易满足高精度的需求,且设备昂贵,难以普及;射线检测的被测结果可直观显示,但需要专门的曝光室和处理胶片的设备,检验成本较高,此外,安全防护的问题也必须考虑;超声检测速度快、成本低,但对形状不规则、表面不光滑的缺陷难以检测,且缺陷定性及定量困难;磁场成像检测能提供高质量的影像,但电池的金属外壳可能对测量的磁场产生巨大的影响,并且还存在着检测周期长、成本高的缺点。

为了寻找更佳的缺陷检测方案,研究人员将机器视觉技术引入其中。机器视觉检测技术利用机器代替人眼做出各种测量和判断,通过互补金属氧化物半导体(complementary metal oxide semiconductor, CMOS)或电荷耦合器件(charge coupled device, CCD)这两种摄像装置将目标转换成图像信号,传送给专用的图像处理系统,得到目标的形态信息,根据像素分布和亮度、颜色等信息,转变成数字化信号;图像系统对这些信号进行处理和分析,实现对目标的识别、分类、定位、跟踪等操作。在锂电池的制造流程中,使用机器视觉检测技术在电池表面提取图像的特征信息,识别相应的缺陷类型,还可以计算出缺陷的尺寸、面积等。机器视觉检测的引入显著提高了

缺陷检测率,并节省了时间和人工成本,但传统的视觉检测算法在复杂背景和低光照条件下无法应对更精密、繁杂的缺陷类型,因此需要提出更好的解决方案。深度学习使计算机能够自动学习图像的数学特征,甚至更高层次的图像表达,使视觉检测更准确、快速。基于深度学习的模型在特征提取方面表现出更好的性能,且具有更强的鲁棒性,不受单一应用场景的限制,模型可随时调整训练,方便部署,现已成为最主要的缺陷检测方法之一。

近年来关于锂电池缺陷检测的研究受到了广泛关注,但都是根据企业需求,针对某一类锂电池来进行研究讨论,相关综述非常稀少,仅有文献[9]分析了锂电池的安全隐患,简要阐述了锂电池的表面缺陷检测、电极缺陷检测、内部结构缺陷检测这 3 部分,对于目前主流的机器视觉检测并没有做出详细讨论,且没有比较各方法的优缺点。此外,文献[10-11]综述了通用的基于视觉的主流缺陷检测技术,但没有针对锂电池缺陷检测进行介绍。鉴于此,本文梳理和分析大量基于机器视觉的锂电池缺陷检测方法,对机器视觉技术在锂电池缺陷检测中的应用进行全面系统的综述,希望提供有价值的参考。本文做出如下安排:第 1 部分介绍各类缺陷并给出其形成的原因,阐述利用机器视觉技术对锂电池进行缺陷检测的系统,对视觉缺陷检测系统中的图像采集硬件进行讨论说明。第 2 部分概述基于传统图像处理方式及传统机器学习模型的锂电池缺陷检测方法,对检测步骤中的图像预处理、缺陷分割、特征提取、分类识别这 4 方面做出详细说明。第 3 部分概述基于深度学习的锂电池缺陷检测方法,把缺陷检测网络分为分类网络、目标检测网络、分割网络 3 大类。第 4 部分介绍锂电池的缺陷数据集,并整理常见的缺陷检测性能评价指标。第 5 部分指出锂电池缺陷检测面临的技术挑战,并针对这些挑战对未来的研究工作进行展望。

1 锂电池缺陷类型及缺陷检测流程

1.1 锂电池缺陷类型







锂电池生产工艺十分复杂,在其生产过程中不可避免地会产生一些表面缺陷。本文总结了几种常见的锂电池表面缺陷,有划痕、凹坑、脱碳、漏金属、气泡、亮点、褶皱等,缺陷的图示、形成原因及特征分析如表 1 所示。

1.2 缺陷检测流程

锂电池表面缺陷检测流程主要包括硬件和软件两部分,前者即图像采集装置,后者则为图像处理算法及软件。在图像采集装置中通过光源、镜头、相机等设备摄取图像信息,把图像信息传输到软件系统里,利用相应的图像处理算法来实现表面缺陷的检测与分割。基于机器

表 1 缺陷种类以及形成原因和特征分析

Table 1 Types of defects and analysis of their causes and characteristics

缺陷种类	图示	缺陷形成原因	缺陷特征分析
划痕		在生产过程中受到设备碰撞或相互之间碰撞造成	形状为条形,颜色与金属基色相近
凹坑		被钝器撞击	一般为不规则凹陷或孔洞,深度和形状不定
脱碳		浆料制作过程中浆料搅拌不充分或涂布过程中涂布不均匀	形状和面积大小随机且不规则,缺陷区域灰度值低于背景区域
漏金属		涂料或辊压过程中,极片破损后导致的金属泄露	形状多为点状,大小不一,缺陷区域灰度值明显高于背景区域
气泡		浆料制备搅拌时或者涂布过程中混入了气体	呈现环形,环内灰度值比背景灰度值低,环上灰度值则相对较高
亮点		浆料制备时或涂布过程中混入颗粒型杂质	呈现圆形,面积较小,亮度较高
褶皱		热塑时金属塑膜表面不平整	呈现凸起形状,大小不一

视觉的锂电池缺陷检测流程主要由图像采集、图像预处理和图像分析 3 大模块构成,如图 1 所示。




图 1 锂电池视觉缺陷检测流程

Fig. 1 Flow of lithium battery defect detection based on vision

1) 缺陷检测流程硬件部分

光源、镜头、相机等设备是图像采集模块的重要组成部分,决定了成像质量的优劣,进而影响着算法

的检测性能。

在视觉检测中,光源的作用是将光线集中到被测物体上,以防止环境光的干扰。根据发光原理的不同,光源可分为卤素灯、荧光灯、LED 灯、氙气灯、白炽灯等。合适的光源不仅可以提高缺陷图像的对比度,使图像的前景与背景得到良好的分离,还可以减少图像中的噪声,降低后续算法处理的难度。不同光源的具体性质如表 2 所示。此外,针对不同的锂电池检测场景,选择正确的照明方式也尤为重要,常见的照明方式有:直接照明、背光照明、暗场照明、散射照明、同轴照明等。不同的照明方式所能提供的照射角度、高度和范围均不相同,适用于不同的检测对象和检测环境,多种照明方式的定义和特点如表 3 所示。

确定好光源类型和照明方式后,镜头的选择也是机器视觉检测系统中的重要一环,其种类可分为定焦镜头

表 2 不同光源的性质对比

Table 2 Comparison of the properties of different light sources

类型	颜色	光效/(lm/W)	平均寿命/h	色温/K	特点
卤素灯	白偏黄	10~20	2 000~4 000	2 700~3 200	价格便宜,尺寸小,较为耗电
荧光灯	冷白	50~100	8 000~10 000	2 700~6 500	节能,寿命较长,适用于大面积照射
LED 灯	各种颜色	130~250	100 000	全系列	能效极高,寿命长,使用范围广
氙气灯	各种颜色	50~70	2 000	3 000~12 000	光照强度高,可连续快速点亮
白炽灯	白偏黄	15	750~2 000	2 500~3 000	成本低,即开即亮,寿命短

表 3 不同照明方式的定义和特点

Table 3 Definitions and characteristics of different lighting modes

照明方式	定义	特点
直接照明	利用光源直接照射到被测物体上	可获得高对比度图像,但常会引入反光,造成干扰
背光照明	利用光源从物体背面进行照射	可获得较高对比度图像,突出物体轮廓,但无法体现纹理特征
暗场照明	光源以一定角度照明,相机处于光源的非反射方向	适用于被测物表面有突起或纹理的场景,但图像亮度较低
散射照明	以漫反射方式采用比较均匀的光源照明	可突出被测物表面的细节,但不易显示立体形态和表面结构
同轴照明	在光源前加入分光镜,光源、相机及被测物在同一直线	提供均匀照明,能克服反光造成的干扰,但会导致边缘不够清晰

和变焦镜头,按焦距分类又可以分为广角镜头、标准镜头、长焦镜头。镜头的作用是将光线聚集在相机的成像平面上,其主要参数包括焦距、光圈、景深、分辨率、镜头接口、工作距离等,这些参数的定义和注意因素如表 4 所示。在选镜头型号之前,需要从理论的角度出发,对相关参数进行推导和计算,从而选择出合适的镜头型号。

表 4 镜头参数的定义和注意因素

Table 4 Definition of lens parameters and considerations

镜头参数	定义	注意因素
焦距	镜头中心点到焦点的距离	根据拍摄对象的远近、大小以及想要达到的画面效果来选择
光圈	镜头通光孔径的大小	决定了进入相机的光量,同时也影响到背景虚化的效果
景深	照片中前后都能保持清晰的范围	景深由光圈大小决定,选择合适景深确定缺陷成像清晰
分辨率	表明镜头分辨被摄物体细节的能力	要确保镜头的分辨率与相机的像素相匹配
镜头接口	镜头与相机的连接方式	确保镜头与相机的接口相匹配,若不匹配需要转接环
工作距离	镜头到被摄物体表面的距离	镜头工作距离有限,不能对任意工作距离都成像清晰

相机是成像过程中的关键设备,负责将输入镜头的光线通过靶面芯片转换为数字信号。锂电池缺陷图像都是利用工业相机进行拍摄,与普通的民用相机相比,工业相机具有高帧率、宽光谱和高稳定性等特点,能够持续长时间高效运作。工业相机按照芯片工艺可划分为 CCD 和 CMOS 两类;也可按照结构差异,分为面阵相机和线阵相机;还可依据图像模式,分为彩色相机和黑白相机。选择哪种类型的相机,除了要注意相机本身的分辨率、帧率、感光芯片类型等参数,还需考虑现场环境条件、检测任务的复杂程度、预算限制等实际情况。各类相机分类的具体信息如表 5 所示。

综上,光源、镜头、相机 3 类设备对成像质量的好坏都

有着关键性的影响,需考虑多方面来确定它们的选型,合理的选型和配置可以使后续软件部分的工作事半功倍。

2) 缺陷检测流程软件部分

缺陷检测流程中的软件部分可分为图像预处理和图像分析两大模块。图像预处理的主要目的是抑制图像中无关的信息,恢复有用的真实信息,降低后续图像分析的计算成本,也可以极大改善分析结果的性能,其主要步骤有感兴趣区域(region of interest, ROI)提取、图像去噪、图像增强等。图像分析则可根据需求,对预处理后的图像进行区域分割、特征提取等操作,利用國值判断、列表查询等传统图像处理方式或机器学习模型来实现缺陷的分类识别和位置输出。

表 5 相机的分类
Table 5 Classification of cameras

分类模式	相机	说明
芯片工艺	CMOS 相机	功耗小、价格低、集成度高、成像速度较快,图像本身会有比较多的噪声
	CCD 相机	提供很好的图像质量与抗噪能力,价格相对较高,成像速度较慢
结构差异	线阵相机	传感器呈长条形,获取图像耗时但分辨率高,适用于大视野高分辨率场景
	面阵相机	由像元组成的一个面,能够一次性获取完整的图像,成像速度较快,适用于静态或低动态场景的成像
图像模式	彩色相机	拍摄的图像是彩色图像
	黑白相机	拍摄的图像是黑白图像

2 基于传统图像处理方式及传统机器学习模型的锂电池缺陷检测方法

传统图像处理方式及传统机器学习模型统称为传统方法,新兴方法即深度学习模型放在下一节讨论。传统方法的一般步骤为:图像预处理、图像分割、特征提取、分类识别。下面对这 4 个步骤进行详细的分类说明,其中图像预处理分为空域处理和频域处理两类;图像分割包含了阈值分割、边缘检测、区域分割及一些其他分割方法;特征提取从灰度特征、形状特征、纹理特征、特征算子 4 个角度进行概括;分类识别是利用支持向量机(support vector machine, SVM)、K 近邻(K-nearest-neighbor, KNN)算法、决策树等机器学习模型实现。

2.1 锂电池缺陷检测中的图像预处理方法

不同的锂电池缺陷在图像中具有不同的特征表现,因此研究人员需要根据缺陷特征来进行相应的预处理工作。图像预处理的方式可分为空域处理和频域处理两大类。

1) 空域处理

空域处理指的是图像在空间域里进行图像点运算、几何运算、空间邻域运算等操作。文献[12]根据电池片表面缺陷的结构特点,采用中值滤波法,去除斑点噪声和椒盐噪声的效果十分明显,后续还利用直方图均衡化来增强图像的对比度,能更加精确地定位到缺陷区域,但中值滤波算法存在损失图像细节、速度较慢的问题。文献[13]提出一种快速中值滤波算法,只考虑加入和移出的像素值对上一个窗口中值的影响,跳过了对无变化的像素值的比较,实验结果证明该算法在保证平滑效果的同时,显著缩短了图像处理的时间,但图像细节损失的问题依旧没有解决。文献[14]以中值滤波为基础,提出一种改进的自适应中值滤波结合连通域的滤波算法,通过自适应调节中值滤波窗口,较好地保留了非噪声点,并利用连通域数据处理对残留的噪声进行进一步的滤除,该算法尽可能地保留了图像细节,但算法速率有待进一步提升。文献[15]考虑到均值、中值、高斯滤波等常用图

像预处理算法的不足,提出一种背景标准化算法来抑制 ROI 区域图像竖直方向上的明暗条纹噪声,经过定性与定量的分析,该算法不仅减少了背景区域像素点灰度值的波动,而且保护了前景区域的有效信息,但对竖直方向外其他类型的灰度值波动抑制效果一般。文献[16]利用双边滤波算法,结合图像的空间邻近度与像素值相似度,保留了较多的缺陷内外边缘轮廓信息,均方误差和峰值信噪比的评价结果表明该双边滤波算法效果较好,但计算复杂度高,且易受光照变化的影响。文献[17]设计了具有凹坑纹理结构特征的双高斯纹理滤波模板,抑制了图像中不必要的纹理信息,突出了凹坑的灰度突变特征,可以应用于光照不均和反射不均的情况,但该算法仅在自建图库上进行了验证,泛化性有待讨论。

2) 频域处理

频域处理指的是将图像从空域转换到频域进行处理,通过对图像频谱的操作来实现图像的去噪和增强。文献[18]针对锂电池表面凸点缺陷图像存在反光、对比度低等问题,在频域上采用高斯滤波器进行预处理,提高了图像凸点缺陷区域和邻域的对比度,与未加频域预处理直接进行检测的方法相比,检测准确率有显著提升,但高斯滤波计算复杂度较高,且会导致一些细节信息的丢失。文献[19]使用小波阈值对图像进行去噪处理,根据所选阈值仅对背景的白色噪点进行收敛,相比于高斯滤波、双边滤波等传统滤波算法,该方法能更好地去除背景噪点和保留缺陷特征信息,但算法的自适应性还有待提高。文献[20]在图像增强方面,利用小波变换把原图像分解成低频平滑子图和高频细节子图,对低频和高频分量分别采用线性调整和多尺度细节增强的处理方式,与直方图均衡化、同态滤波等其他图像增强算法相比,此方法能更好地解决光照不均、细节信息模糊的问题,但复杂性较高,耗时较长。文献[21]观察到锂电池正极图像光照不均的现象,提出一种改进频域函数的同态滤波算法,将原频域函数分为低频抑制和高频增强两方面,对于反射分量依旧采用高通滤波函数进行增强,而入射分量则借助传统低频滤波函数进行抑制,经过主观和客观的综

合评价,该改进算法提高了图像的亮度与对比度,凸显了边缘信息,但参数调整技术要求高,且处理时间较长。文献[22]针对软包电池表面的反光特性,提出了基于光度立体法与 Gabor 滤波相结合的缺陷检测方法,对光源入射方向不同的图像进行梯度信息重构,然后在频域内对重构的图像进行 Gabor 滤波操作,研究结果表明光度立体法降低了反光造成的影响,而 Gabor 滤波处理则强化图像边缘的纹理信息,有助于提高缺陷的识别精度,但滤波参数需要针对不同场景进行调整。文献[23]在传统

Gabor 滤波器的基础上,增加调整参数,根据图像信息合理设置参数阈值以实现滤波器的自适应,滤波结果表明该滤波算法能较好平滑图像的同时,又凸显出缺陷目标,但计算复杂度高,实时处理困难。

综上,空域处理操作简单直观,能更好地提取局部特征信息,而频域处理可充分利用图像的频域信息,对图像进行更加精细和复杂的处理。空域处理和频域处理各有优势和特点,应用于不同的场景和任务中,具体方法对比如表 6 所示。

表 6 常用的图像预处理方法对比
Table 6 Comparison of commonly used image preprocessing methods

类别	文献	具体方法	贡献	局限性
空域 处理	[12]	中值滤波和直方图均衡化	去除斑点噪声和椒盐噪声,增强图像的对比度	图像细节损失,速度较慢
	[13]	快速中值滤波算法	缩短图像处理的时间	图像细节损失
	[14]	自适应中值滤波结合连通域	去除噪声的同时保留了图像细节	速度较慢
	[15]	背景标准化算法	减少背景区域像素点灰度值的波动,保护前景区域的有效信息	对竖直方向外其他类型的灰度值波动抑制效果一般
	[16]	双边滤波	保留较多的缺陷内外边缘轮廓信息	计算复杂度高,且易受光照变化的影响
	[17]	双高斯纹理滤波模板	排除干扰纹理,突出有效信息,可应用于光照不均和反射不均的情况	泛化性有待讨论
	[18]	傅里叶变换和高斯滤波	提高图像缺陷区域和邻域的对比度	计算复杂度较高,丢失细节信息
频域 处理	[19]	小波阈值	去除背景白色噪点,保留缺陷特征信息	自适应性有待提高
	[20]	小波变换	解决光照不均、细节信息模糊的问题	复杂性较高,耗时较长
	[21]	改进频域函数的同态滤波	提高图像的亮度与对比度,凸显边缘信息	参数调整技术要求高,处理时间较长
	[22]	光度立体法结合 Gabor 滤波	降低反光造成的影响,强化图像边缘的纹理信息	滤波参数选择复杂
	[23]	自适应 Gabor 滤波	实现滤波器的自适应改进,平滑图像,凸显缺陷目标	计算复杂度高,实时处理困难

2.2 锂电池缺陷检测中的图像分割方法

由于工业相机采集的图像分辨率较高,通常需要在图像预处理后将缺陷区域分割出来,更加精确地定位缺陷的位置和大小,有助于后续的分析和处理。图像分割指的是将原始图像细分为多个图像子集的过程,其中每个子集在某种程度上是同质的。下面主要介绍图像分割中常用的阈值分割、边缘检测、区域分割等方法。

1) 阈值分割

阈值分割是一种基于灰度级的图像分割方法,根据一个或多个阈值将图像中的像素分为不同的组别。文献[24]针对表面划痕缺陷采用全局固定阈值的分割方法,选取梯度的均方差作为全局阈值分割的零界点,有着较高的检出率和较低的误检率,但该方法仅对灰度值相差很大的目标和背景有效,对目标与背景灰度值差异不大的情况分割效果差或无法分割。文献[25]采用 Otsu 阈值法代替传统的阈值分割方法以实现薄膜缺陷区域的分割,这是一种基于类间方差最大原则的自适应阈值分

割方法,充分利用了图像的灰度分布特性,但当缺陷目标在整幅图像中所占比例较小的情况下该方法的处理效果往往不理想,且对噪声也较为敏感。文献[20]引入粒子群算法来优化传统的 Otsu 阈值算法,将类间方差作为粒子群算法中的适应度函数,借助信息共享和协作机制能更快地寻找到最优阈值,提升运算速度,且能避免局部最优解的情况,但对噪声敏感的问题仍未解决。文献[26]利用局部阈值法来提取锂电池上的条形码与字符,相比于全局阈值法,此方法能更好地适应图像的局部变化,处理光照不均或背景复杂的图像效果较好,可以有效抑制噪声的干扰,但算法计算复杂度过高,处理时间较长。

2) 边缘检测

边缘检测是一种基于边缘部分像素值出现“跳跃”或较大变化的图像分割方法,通过计算图像的一阶或二阶导数以确定图像的边缘位置。文献[27]在对比度调整和 Gamma 矫正的预处理后,利用 LOG 算法分割出锂电池极片缺陷区域,该算法先采用高斯滤波以消除噪声

的影响,再结合拉普拉斯运算提取图像二阶导数的过零点来判定边缘点,对于复杂的图像边缘检测效果较好,但计算复杂度较高,参数选择敏感。文献[28]利用 Canny 边缘检测算法得到锂电池极片缺陷的边缘轮廓,考虑到部分边缘的丢失,后续增加了形态学处理和逻辑与运算来提取缺陷区域,Canny 算法在边缘检测任务中准确性和稳定性方面表现都不错,但面对低对比度微小缺陷的情况,依旧存在难以检测的问题。为此,文献[29]提出一种基于改进 Canny 算子的锂电池极片表面缺陷检测方法,引入双边滤波、多尺度细节增强和阈值自适应获取来对传统的 Canny 算法进行改进,改进算法能更有效地滤除背景噪声,有更加优秀的检测效果,但是对于划痕这类缺陷的边缘检测精度还有待提高。

3) 区域分割

区域分割是一种以区域为基础实现图像分割的技术,将图像划分为多个具有独特性质的区域,按分割方向有两种基本形式:一种是从局部向整体分割的区域生长,一种是从整体向局部分割的区域分裂合并。文献[16]利用区域生长算法实现缺陷的分割,以灰度值为 8 的像素作为初始的生长点,相比于部分阈值分割算法,区域生长算法很好地抑制了噪声且较完整地保存了分割出的缺陷特征信息,但在复杂背景下初始生长点的选择较为困难,参数设定也较为复杂。文献[30]分析麻点缺陷的灰度分布特征及其复杂背景,提出一种基于改进的凹线段幅值法来定位麻点缺陷的种子点,然后采用基于线生长

的区域生长算法,有着较低的漏检率,但算法的误检率较高,对明暗的边缘过渡带较为敏感。文献[19]在采用小波阈值对图像进行去噪后,利用区域分裂合并算法分割缺陷,该分割方法与 Otsu 算法、自适应阈值算法、普通阈值算法进行对比分析,得出此方法既不受噪声的干扰,也不受缺陷灰度值差异的影响,但算法计算量大,且分裂可能破坏区域边界。

4) 其他分割方法

在锂电池缺陷图像分割任务中,除了阈值分割、边缘检测和区域分割的方法外,还存在一些其他分割方法。文献[23]在对图像进行二值化处理之后,利用分水岭算法实现缺陷边缘的提取,这是一种模拟地理学中水流过程的图像分割技术,有着思路简单、计算速度较快、轮廓线封闭性好的优点,但可能会存在过分割现象。文献[31]提出一种基于改进多尺度小波变换的锂电池极片缺陷检测方法,对锂电池极片图像先进行自适应伽马矫正的处理,由小波变换得到图像的高频分量和低频分量,利用改进的形态学对低频分量进行边缘检测,同时再采用模极大值对高频分量进行边缘检测,最后将二者检测结果叠加融合以获得边缘信息,该方法很好地保护了边缘细节,但部分划痕缺陷的边缘提取还不够完整。

综上,每一种图像分割方法都有它的优势与弊端,良好的分割结果可以为后续缺陷的特征提取和分类做好坚实的基础,具体方法对比如表 7 所示。

表 7 常用的缺陷分割方法对比
Table 7 Comparison of commonly used defect segmentation methods

类别	文献	具体方法	贡献	局限性
阈值分割	[24]	全局固定阈值	目标和背景的灰度值相差大时有着较好的分割效果	不适用于目标和背景灰度值差异不大的情况
	[25]	Otsu 阈值法	自适应确定阈值,有较好的分割效果	不适用于缺陷目标占背景比例较小的情况,对噪声较为敏感
	[20]	粒子群算法结合 Otsu 阈值法	提升运算速度,避免局部最优解的情况	对噪声较为敏感
	[26]	局部阈值法	处理复杂背景效果较好,能有效抑制噪声的干扰	计算复杂度过高,处理时间较长
边缘检测	[27]	LOG 算法	对于复杂图像的边缘检测效果较好	计算复杂度较高,参数选择敏感
	[28]	Canny 算法	准确性和稳定性方面都表现不错	难以检测低对比度的微小缺陷
	[29]	改进 Canny 算法	对背景噪声滤除效果好,对于微小缺陷的检测效果优秀	对于划痕这类缺陷的边缘检测精度有待提高
区域分割	[16]	区域生长算法	抑制噪声效果好,完整保存分割出的缺陷特征信息	复杂背景下初始生长点选择较为困难,参数设定较为复杂
	[30]	基于线生长的区域生长算法	适用于复杂背景,漏检率较低	误检率较高,对明暗的边缘过渡带较为敏感
	[19]	区域分裂合并算法	不受噪声和缺陷灰度值差异的影响	计算量大,可能破坏区域边界
其他方法	[23]	分水岭算法	计算速度快,轮廓线封闭性好	存在过分割现象的可能
	[31]	小波变换	保护边缘细节	部分划痕缺陷的边缘提取不够完整

2.3 锂电池缺陷检测中的特征提取方法

在分割出缺陷区域后,需要从图像数据中提取有效信息来减小图像数据的复杂性,建立旨在提供非冗余信息的特征,从而促进后续的学习和泛化步骤。本节主要介绍传统的特征提取方法,从灰度特征、形状特征、纹理特征、特征算子这4个方面进行阐述。

1) 灰度特征

灰度特征就是与像素灰度值分布有关的特征,通常以灰度分布曲线或灰度分布直方图为基础。文献[32]分析了凹坑缺陷的整体特征,提出基于高斯梯度卷积和灰度特征的缺陷检测法,利用高斯梯度卷积进行图像增强后,根据背景和缺陷的灰度值差异过大,在灰度分布直方图中利用 3σ 准则对凹坑缺陷初步定位,后续提出多区域均值差异法和灰度均值差异法来排除脏污干扰,实现明显凹坑和浅凹坑的区分,但此方法不适用于目标和背景对比度低的情况。文献[33]提取凹坑缺陷图像的多列灰度分布曲线,利用灰度差分模型实现凹坑缺陷的初检测,再利用曲率变化量排除油污的干扰,实验表明此方法较完整地分割出了不同深度不同尺寸的凹坑,在目标与背景灰度差异较小的情况下也有良好的分割效果,但仅针对自建数据库进行了验证。文献[34]根据误差分析理论和凹坑在灰度分布曲线中的形态,提取灰度分布曲线的3个特征数据:平均偏差、凹凸曲线段峰谷差和凹凸曲线段宽度比,将这3个特征数据输入到BP神经网络模型中进行训练,结果表明该算法没有漏检误检,但算法同样也只在自建数据库里得到验证。

2) 形状特征

形状特征是直观表现出来的一种视觉特征,具有易理解性,常用的形状特征有:面积、周长、矩形体、圆形体、偏心率等。文献[35]分析了极片缺陷的形状特征,提取了长、宽、面积、伸长度、圆形体等特征参数,设定阈值来判断是否为缺陷,并对缺陷进行分类,该方法思路简单易于实现。文献[36]将锂电池极片表面缺陷的圆形体、偏心率等形状特征作为分类器的输入,利用树分类器把复杂的多类别分类问题逐级转化为若干简单的分类问题,有着较快的检测速度和较高的检测率。对于上述文献,基于形状特征的方法,普遍存在对尺度敏感、受光照影响大的问题。

3) 纹理特征

纹理特征是一种反映图像中同质现象的视觉特征,通过像素及其周围空间邻域的灰度分布来表现,其分析方法主要有统计法和结构法等。文献[37]在灰度特征和形状特征的基础上,引入了灰度共生矩阵法(gray-level co-occurrence matrix, GLCM)进行特征融合,增加了能量、局部均匀性、相关性和对比度这4个GLCM纹理特征,经实验验证,分类准确率在引入了GLCM纹理特征后有了

显著的提升。文献[38]基于灰度共生矩阵获得惯性矩的纹理特征信息,以惯性矩为参数提取缺陷的边缘信息。虽说纹理特征通常具有旋转不变性和较强的抗干扰能力,但其较高的计算复杂度是不可忽视的。

4) 特征算子

特征算子与上述传统特征不同,它偏向于图像的局部特征,能够捕捉到图像中的细微差异,常见的特征描述算子有方向梯度直方图(histogram of oriented gradient, HOG)^[39]、尺度不变特征转换(scale-invariant feature transform, SIFT)^[40]、加速鲁棒特征(speeded up robust features, SURF)^[41]等。文献[42]采用HOG特征向量与几何特征向量加权融合的方法,构建出更加全面的缺陷特征信息,利用向量机完成了对划痕、气泡和孔洞3种缺陷的分类和识别,该方法虽然对图像梯度信息进行了有效捕捉,但却存在对环境变化敏感和对小物体检测限制的局限性。文献[43]为了解决锂电池焊线的图像匹配问题,选用SIFT和SURF特征点检测算法进行图像匹配实验,并利用RANSAC算法优化图像匹配效果,SIFT特征和SURF特征在特征稳定性和不变性方面都体现出了一定的优势,但会存在重复匹配和识别率较低的问题。文献[44]考虑到支持向量机的输入要求,采用BoF模型将SURF特征量化到统一的维度,此外还与灰度特征加权融合并设置权值系数,利用改进粒子群算法优化支持向量机的参数,此算法展现了较好的分类性能,但仅对3类缺陷进行了实验分析。

综上,缺陷的特征提取是锂电池缺陷检测中非常关键的步骤之一,不同类型的特征可以用于解决不同的问题,具体方法对比如表8所示。

2.4 锂电池缺陷检测中的分类识别方法

分类识别是将不同的图像根据其内容划分到相应的类别中,对于已提取好的缺陷特征,需要将它们放入机器学习模型中进行训练,最终得到缺陷的分类识别结果。下面将对一些常用的机器学习模型进行总结。

支持向量机是一种监督学习算法,其核心思想是寻找一个超平面,这个超平面能够最好地将不同类型的数据分开,同时使得两个类别之间的间隔最大化,这种间隔最大化的策略使得SVM具有较强的泛化能力。文献[45]提出采用支持向量机的算法来实现电池顶峰封印异物缺陷的检测,识别准确率达到97.5%。文献[46]利用卷积神经网络提取特征,结合支持向量机的分类方法对褶皱缺陷进行检测,结果表明该方法具有较高的检测精度和较快的检测速度,但褶皱缺陷样本的均衡度有待改善。文献[28]利用粒子群优化算法对SVM的惩罚参数和核参数进行寻优,相比于未优化的SVM分类器,平均识别准确率提升了13.9%。文献[47]提取了14个几何特征作为SVM分类器的输入,并采用遗传算法优

表 8 常用的缺陷特征提取方法对比

Table 8 Comparison of commonly used defect feature extraction methods

类别	文献	具体方法	贡献	局限性
灰度特征	[32]	灰度分布直方图和均值差异法	算法处理速度快	不适用于目标和背景对比度低的情况
	[33]	灰度差分模型结合曲率变化量	有效提取特征,适用于目标与背景灰度差异较小的情况	算法的泛化能力有待考察
	[34]	基于灰度分布曲线的特征提取	没有漏检误检,可应用于强干扰信号下弱信号的检测问题	算法的泛化能力有待考察
形状特征	[35]	提取长、宽、面积、伸长度、圆形度等特征	思路简单,直观性强	对尺度敏感,受光照影响大
	[36]	提取圆形度、偏心率等特征	检测速度快,检测率高	对尺度敏感,受光照影响大
纹理特征	[37]	GLCM 特征与其余特征融合	GLCM 纹理特征显著提升了分类准确率	较高的计算复杂度
	[38]	基于 GLCM 提取惯性矩特征	可有效提取缺陷边缘信息	较高的计算复杂度
特征算子	[42]	HOG 特征与几何特征加权融合	有效捕捉图像梯度信息	对环境变化敏感,不可检测小目标
	[43]	SIFT 特征和 SURF 特征	特征具有稳定性和不变性	存在重复匹配和识别率较低的问题
	[44]	BoF-SURF 特征与灰度特征加权融合	从不同角度更全面地描述缺陷	样本多样性不足

化其中的参数,为实现锂电池生产过程中的自动膨胀缺陷检测提供了一种有效的方法,但实验的样本数量有待提升。由上述文献可得支持向量机算法有着强大的非线性映射能力,在分类任务中有很高的准确率,但其本身是一个二分类器,不能解决多分类问题,且对参数和核函数选择敏感。

K 近邻算法是一种基本的分类与回归方法,其核心思想在于:根据距离目标样本最近的 K 个样本的类别来决定目标样本的类别,是一种非参数的惰性学习算法。文献[48]基于三维数据模型,提出一种改进的 KNN 体素密度策略,结合欧式聚类分割对锂电池缺陷进行检测,解决了稀疏点滤波和点云欠分割问题,经实验验证此方法达到了 99.2% 的准确率,但 KNN 算法对异常值较为敏感,对样本不平衡情况的处理不佳。

决策树是一种树形结构的统计学习模型,其中每个内部节点代表在一个属性上的判断,每个分支代表判断的结果,而叶节点则对应最终的分类结果。文献[49]对电池隔板缺陷进行特征分析,利用决策树算法生成分类器,完成了针孔等 6 种缺陷的分类识别,总准确率高达 93.6%,但决策树算法容易出现过拟合,当类别过多时,算法的分类性能就表现一般。文献[12]依据特征评判标准,对 6 种不同类型缺陷的特征参数进行对比,提出了一种决策树结合 SVM 的分类方法,先利用决策树成功判别出 4 类缺陷,再对剩余的黑点和脱碳两类缺陷采用主成分分析法进行特征向量降维,通过 SVM 实现二分类检测,整体的分类正确率可以达到 96.7%,但整个算法的检测流程需要优化,算法检测速度有待提高。

随机森林(random forest, RF)是一种集成学习算法,通过组合多个决策树来提高整体的预测性能,最终的预

测结果通常取决于所有树预测结果的投票或平均,有效地减少了模型的过拟合风险。文献[50]将空域信息和频域信息融合,对融合后的高维特征数据进行 PCA 降维,比较了 RF 分类器和 SVM 分类器对缺陷的分类性能,在精度上 SVM 分类器略优于 RF 分类器,但在速度上 RF 分类器远胜于 SVM 分类器。需注意的是,随机森林对高维数据的处理能力有限,在处理类别不平衡的数据时也可能面临挑战。

支持 Tucker 机(support Tucker machines, STuMs)是一种基于张量分解的机器学习方法,通过学习训练样本中的结构信息,能够有效地对数据进行表示和分类。文献[51]考虑到 SVM 训练数据产生的向量空间问题,很可能破坏图像矩阵的二维结构,于是提出了监督张量学习方法,采用支持 Tucher 机对锂电池单元的缺陷进行检测,更有效地保留了图像二维结构,STuMs 分类准确率优于 SVM 的实验结果也正验证了此想法,但支持 Tucker 机的计算效率和性能在一些情况下可能不如其他机器学习模型。

BP 神经网络也称误差反向传播网络(back propagation neural network, BPNN),其核心在于很好的非线性特征学习能力,通过学习输入与输出之间的映射关系来对数据进行分类或预测。文献[52]在 BP 神经网络模型的基础上,采用鲸鱼优化算法对其模型参数进行调优,与 SVM 进行对比实验评估后发现,BP 神经网络的分类性能更胜一筹,但存在训练成本较高,解释性差的不足。

综上,每一类机器学习模型都有其独特的优缺点,选择合适的机器学习方法需要综合考虑数据的特点、问题的复杂性以及计算资源的可用性,具体对比方法如表 9 所示。

表 9 常用的缺陷分类识别方法对比

Table 9 Comparison of commonly used defect classification and recognition methods

文献	具体方法	贡献	局限性	性能指标
[45]	支持向量机	较高的识别精度、较强的泛化能力	仅支持二分类,对参数选择敏感	准确率:97.5%
[46]	支持向量机	检测精度较高、速度较快	缺陷样本的均衡度有待改善,仅支持二分类	准确率:99.04% 预测时间:0.27 ms
[29]	粒子群算法优化后的支持向量机	提升了识别准确率	仅支持二分类,对微小缺陷的检测精度较低	准确率:98.3%
[47]	遗传算法优化后的支持向量机	提升了识别准确率	仅支持二分类,对参数和核函数选择敏感	准确率:98.15%
[48]	改进 KNN 算法	无需训练,准确率高,支持多分类	对异常值较为敏感,不适用于样本不平衡的情况	准确率:99.2% F1-score:99.6%
[49]	决策树	易于理解,可解释性强	容易出现过拟合现象	准确率:93.6%
[12]	决策树结合支持向量机	提高了分类准确率	检测流程需要优化,检测速度有待提高	准确率:96.7% 检测时间:142 ms
[50]	随机森林	能有效减少过拟合的风险	对高维数据处理能力有限,不适用于类别不平衡的数据	准确率:93.65% 检测时间:1.45 s
[51]	支持 Tucker 机	保护图像矩阵的二维结构	计算效率不高	-
[52]	BP 神经网络	强大的非线性特征学习能力	训练成本较高,解释性差	准确率:97.08% 漏检率:1.68%

3 基于深度学习的锂电池缺陷检测方法

传统的视觉检测方法在面对不同的应用场景时,为了确保检测的准确性和效率,需要针对性地设计系统和算法,深度学习在图像处理领域里的应用则一定程度上

减少了这种定制化需求。相比于传统方法,深度神经网络(deep neural network, DNN)有着自动提取特征和自动分类识别的功能,在计算机视觉任务中已取得巨大成功。现将应用于锂电池缺陷检测的深度学习神经网络分为 3 类:分类网络、检测网络、分割网络,表 10 给出了这 3 类网络的特征对比。

表 10 深度学习神经网络方式对比

Table 10 Comparison of deep natural network methods

类别	具体实例	数据标签类型	特点	局限性
分类网络	VGG、ResNet、DenseNet 等	类别	适用于图像分类任务,标注成本低	只可识别图像中单个对象类别,无法处理多对象或对象位置信息
检测网络	Faster R-CNN、YOLO 等	矩形框	可识别多个对象并给出位置信息,标注成本较高	计算复杂度较高,需要处理大量候选框
分割网络	U-Net、Mask R-CNN 等	多边形框	能实现精确分割,直观表达缺陷具体外形,标注成本高	计算复杂度高,需要处理大量高分辨率特征图

3.1 分类网络

分类网络的主要目标是识别图像中的对象类别,通常接收一张图像作为输入,并输出一个概率分布,表示该图像属于不同类别的概率,分类网络的典型代表有 AlexNet^[53]、VGG^[54]、GoogLeNet^[55]、ResNet^[56]、DenseNet^[57]等。在锂电池缺陷检测任务中,这些分类网

络通过多层卷积层、激活函数和全连接层来提取缺陷图像的特征,并给出缺陷的分类识别结果。

文献[58]以 AlexNet 网络模型为基础,构建使用了空洞卷积的跳跃连接,并优化模型的参数结构和激活函数,解决了原始模型中细节特征丢失、神经元死亡的问题。文献[59]搭建基于卷积神经网络的深度学习模型,

与经典网络模型 AlexNet 进行比较,实验表明该文献提出的网络有着更优秀的性能指标。文献[60]摒弃从头开始训练的传统学习方法,利用迁移学习思想,以 VGG19 为基础网络架构并对其结构进行微调,实现了锂电池缺陷图像的精准分类。文献[61]提出一种基于改进密集块结构和学习率优化的检测方法,在分类性能方面优于其他机器学习方法。文献[62]在卷积神经网络的基础上,利用焦点损失函数,解决了数据训练不平衡带来的问题。文献[63]采用 DenseNet201 微调结

构完成缺陷图像分类任务,同时提出通过增加惩罚系数来修正损失函数的思想,在保持较好精度的同时降低模型的误报率。文献[64]利用 EfficientNetB6 模型,引入一个改进的损失函数进行训练,研究表明修改后的模型精度得到了提高。

综上可得,利用深度神经网络进行缺陷分类时,可以在经典网络模型的基础上进行优化改进,也可以自主设计网络结构,总的目的都是为了模型能有更优秀的分类性能,具体对比方法如表 11 所示。

表 11 常用的分类网络方法对比
Table 11 Comparison of commonly used classification network methods

文献	具体方法	创新点	局限性	性能指标
[58]	基于 AlexNet	改进卷积核、加入批量归一化、引入跳跃连接和空洞卷积、改进激活函数	基础网络属于早期迭代版本	准确率:99.34% 检测时间:51 ms
[59]	基于卷积神经网络	—	仅与早期版本网络进行比较	准确率:92% 损失值:0.20
[60]	基于 VGG19	利用迁移学习思想,设置预训练权重	—	AUROC:1.000
[61]	基于卷积神经网络	改进密集块结构,优化学习率	—	准确率:0.993 F1-score:0.988
[62]	基于卷积神经网络	使用焦点损失函数代替传统的交叉熵损失函数	未与其他经典网络作比较	准确率:99.50%
[63]	基于 DenseNet201	增加惩罚系数来修正二值损失函数	仅完成了褶皱缺陷的检测任务,其余缺陷未被检测	准确率:0.975 6 FPR:0.005 4
[64]	基于 EfficientNetB6	引入改进的损失函数	数据不平衡导致模型过拟合,模型准确性有待提升	准确率:94.26% F1-score:0.94

3.2 检测网络

目标检测网络的核心任务是从图像中准确地找出感兴趣的目标,并确定它们的类别和位置,相比于分类网络的单个类别输出,检测网络在缺陷检测任务中能识别多个缺陷并通过外接矩形框确定缺陷位置信息。目前,基于深度学习的目标检测方法主要可以分为 3 类:双阶段目标检测、单阶段目标检测和基于 Transformer 的目标检测。

1) 双阶段目标检测

双阶段目标检测由 2 阶段组成,第 1 个阶段通常涉及到生成候选区域,这些区域是算法认为可能包含目标的部分;第 2 个阶段则对这些候选区域进行分类和精确定位。这种方法对每个候选区域都进行了处理,能较为准确地识别图像中的目标,但处理速度则相对较慢,其经典网络有 R-CNN^[65]、Fast R-CNN^[66]、Faster R-CNN^[67]等。

Faster R-CNN 较前两代,检测性能有很大的提升,其引入了区域建议网络(region proposal network, RPN),该网络与检测网络共享卷积特征图,有效提高了候选区域

的生成速度和质量,通过多任务损失函数,兼顾了算法的准确性和速度。文献[68]为了满足实际工业中对锂电池表面缺陷的高精度检测需求,以 Faster R-CNN 为网络基本框架,通过稠密连接的方法实现宏观特征与细节特征的融合,并设计了基于自适应特征池化的特征聚合算法,对于微小缺陷有着更高的检测精度,但整体的检测准确率仍有待提升。文献[69]考虑到 Faster R-CNN 的交并比(intersection over union, IoU)阈值选择困难,选择了基于级联结构的 Cascade R-CNN^[70],该网络将多个 RCNN 网络基于不同的 IoU 阈值进行级联,不断优化检测结果,此外还通过排除微小缺陷、调整置信度阈值等方法进一步修正检测结果。

2) 单阶段目标检测

单阶段目标检测简化了流程,不需要先生成候选区域再进行分类,直接通过一个单一的网络同时进行目标的分类和定位,有着更快的检测速度,其经典网络有 YOLO 系列^[71-76]、SSD^[77]、RetinaNet^[78]等。

YOLO 系列算法在目标检测领域具有里程碑式的意

义,它的出现极大地推动了实时目标检测技术的发展,随着版本的迭代,YOLO 系列网络在保持高速度的同时,也在不断提高检测的准确性,已成为锂电池缺陷检测网络的首选。文献[79]利用 K-means 聚类算法生成锚框,应用检测网络 YOLOv3 输出缺陷的类型和位置信息。文献[80]对 YOLOv3 进行优化,通过消融法减少卷积层的数量,并替换激活函数,提出了新的网络模型 YOLOv3-x,该模型相比于原模型有着更高的 mAP 值和更快的检测速度。文献[81]针对 YOLO 系列进行改进,设计了一个基于串联分组卷积块的轻量化网络模型,其下采样网络由串联分组卷积块组成,上采样网络是基于 YOLOv3 输出部分的网络结构,解决了弱特征信息缺陷难以检测的问题。

YOLOv4 由 YOLOv3 升级改造而成,从数据处理、主干网络、网络训练、激活函数、损失函数等方面对子结构进行了大量的改进,在 COCO 数据集上比 YOLOv3 有着更高的检测精度。文献[82]对 YOLOv4 网络进行改进,将主干网络替换成使用了深度可分离卷积的 MobileNetv1,针对锂电池小目标缺陷利用 K-means++ 聚类算法重新获取先验框,同时构建注意力机制 ECSA 模块聚焦于关键信息,实现了柱形锂电池缺陷检测的实时性与高精度。文献[83]基于 YOLOv4 网络,加入空洞卷积来扩大感受野,利用 ECA-Net 结构实现特征图中语义信息的增强,并在分类和边界框回归中融合条件卷积来提高网络性能。文献[84]相比于文献[83],除了利用注意力模块和空洞卷积外,还设计一种多尺度稠密特征金字塔,提升浅层细节特征与高级语义信息的融合能力,并引入 focal loss 损失函数增大小目标样本的权重损失,该文提出的算法兼顾精度与速度,综合性能较为优越,后续可进行轻量化改进。

YOLOv5 在 YOLOv4 的基础上进行了一些改进,其采用了一种新的网络架构设计,即 C3 模块,通过多尺度特征融合技术和跨通道信息传递机制来提高特征图的表达能力,此外,YOLOv5 引入了更多的数据增强技术,使用了新的损失函数和正则化方法,在目标检测任务上更加高效和准确,受到了广大研究者的青睐。文献[85]提出一种改进 YOLOv5 的特征检测算法,采用混合型注意力机制获取更多的特征信息,改进损失函数达到保留有利特征和提高收敛速度的目的,实验结果表明改进模型在缺陷目标检测上有更高的准确率,且速度满足工业上的实时要求。文献[86]以 YOLOv5 模型为基础,增加了基于通道和空间注意力机制进行改进的 CA 模块,并利用 CIoU 替换损失函数,能更准确地返回预测框。文献[87]提出一种称为 Sim-YOLOv5s 的缺陷检测模型,模型中有一种快速的空间池金字塔结构 SimSPPF,并在主干网络里嵌入注意力机制模块,此外,该模型使用更大感知域的

上采样算子,执行跨层连接操作将浅层特征信息与深层特征信息融合,为工业锂电池产品的实时检测奠定基础。文献[88]对 YOLOv5 的骨干网络、头部网络、损失函数进行了改进,不仅在自己的数据集上效果显著,还在公开的数据集上得到了验证,表明改进的网络可以有效地检测小目标缺陷。

YOLOv7 是 YOLOv4 团队的续作,主要是针对模型结构重参化和动态标签分配问题进行了优化,相比于前面几代,YOLOv7 的参数量和计算量大幅度减少,但性能仍能保持少量的提升。文献[89]为了实现对锂电池焊点缺陷的高效高精度检测,提出一种改进的 YOLOv7 检测算法,该算法通过引入 C3SE 模块提高了模型的特征提取能力,此外,采用 BiFPN 结构增强不同网络层之间的信息传输,同时,改进 MP 模块来减少小目标漏检的发生,实验结果表明改进算法平均准确率达到了 96.4%,FPS 高达 158.6,后续可在保持准确性的同时进一步降低网络的复杂度。

3) 基于 Transformer 的目标检测

双阶段目标检测和单阶段目标检测是基于卷积神经网络的目标检测方法,而基于 Transformer 的方法是一种新的架构,其通过自注意力机制能够有效地捕捉图像中的全局上下文信息,在小目标检测方向上有着更大的潜力。文献[90]提出了一种基于 Transformer 的端到端锂电池缺陷检测方法,针对锂电池表面缺陷检测任务中因噪声和复杂背景信息干扰导致的漏检问题,在编码器部分增加了 AIA 模块,使模型更加关注正确的缺陷信息,有效提高了模型的检测精度,但和 YOLO 等网络相比,该模型的参数更复杂,后续可进行轻量化改进。

综上,双阶段检测网络有着较高的检测精度,却难以满足实时检测需求,而单阶段检测网络有很快的检测速度,随着模型的不断改进发展,其检测精度也可与双阶段检测网络相媲美,此外,基于 Transformer 的目标检测有着独特的结构和机制,在处理小目标检测等方面展现出了明显的优势,具体对比方法如表 12 所示。

3.3 分割网络

分割网络将表面缺陷检测任务转化为缺陷与正常区域的语义分割或实例分割问题,通过对每个像素点进行分类来实现缺陷区域的精细分割,提供了面积、轮廓等丰富的几何信息,有助于后续的缺陷分析和质量评估。分割网络的典型代表有 U-Net^[91]、Mask R-CNN^[92]、Deeplab 系列^[93-96]等,其中 U-Net 网络应用最广泛。它在 2015 年被提出,首先用于解决生物医学图像分割问题,由于其出色的性能,后来被广泛应用于语义分割的各个领域,包括卫星图像分割和工业缺陷检测等,目前大部分应用于锂电池缺陷检测的分割网络都是基于 U-Net 改进而成的。

文献[97]利用 VGG16 替换原 U-Net 网络中的编码

表 12 常用的检测网络方法对比

Table 12 Comparison of commonly used detection network methods

文献	具体方法	创新点	局限性	性能指标
[68]	基于 Faster R-CNN	设计稠密连接的特征金字塔网络,采用基于反卷积的上采样方法,采用自适应特征池化方法	信息冗余,算法运行时间久	mAP:80.58% 时间:1.37 s
[69]	基于 Cascade R-CNN	排除微小缺陷,调整置信度阈值	对污渍和硬印两种缺陷的检测效果不佳	误检率:3.91% 漏检率:6.21%
[79]	基于 YOLOv3	利用 K-means 算法重新聚类先验框	可进一步优化模型追求更好的检测效果	mAP:94% FPS:25
[80]	yolov3-x	利用 K-means 算法重新聚类先验框,修改骨干网络,替换激活函数	模型分类能力不足,检测速度较低	mAP:54.73%
[81]	ConcateXnet	基于串联分组卷积块	可细化网络结构追求更好检测效果	mAP:92% FPS:26
[82]	YOLOv4-MEK	更改主干网络,嵌入 ECSA 注意力模块,利用 K-means++算法重新聚类先验框	需进一步轻量化改进	mAP:93.25% FPS:54.67
[83]	基于 YOLOv4	使用空洞卷积代替传统卷积,插入通道注意力机制,在分类和边界框回归中融合条件卷积	-	mAP:93.64% FPS:29
[84]	Attn-YOLOv4	嵌入 SE 注意力模块,加入 ASPP 结构,设计一种多尺度稠密特征金字塔,采用 K-means++算法重新聚类先验框,引入新的损失函数	算法泛化能力有待提升	mAP:95.12% FPS:24.91
[85]	YOLOv5-CE	引入卷积注意力模块,使用 EIoU 作为损失函数	-	mAP:91.2% FPS:27
[86]	YOLOv5-CC	引入坐标注意力机制模块 CA,使用 Ciou 作为损失函数	-	mAP:88.93% FPS:25
[87]	Sim-YOLOv5s	提出 SimSPPF 结构,嵌入注意力机制模块,使用新的上采样算子,执行跨层连接操作	需进一步轻量化处理	mAP:88.3% FPS:71
[88]	基于 YOLOv5	替换卷积核,使用 SPPSE 模块,引入 RepVGG 模块,使用 Siou 作为损失函数	-	mAP:97% FPS:270
[89]	基于 YOLOv7	引入 C3SE 模块,采用 BiFPN 结构,改进下采样模块	网络复杂度过高	mAP:96.4% FPS:158.6
[90]	AIA DETR	在 Transformer 编码器部分增加了 AIA 模块	参数较为复杂	mAP:81.9% Params:45 M

结构,将简易的特征融合模块 SFPN 加入在网络的跳跃连接上,并运用标签平滑来优化损失函数,该方法更准确、高效地完成了锂电池极片表面缺陷的像素级分割检测,但平均交并比的精度还可以进一步的提升。文献[98]提出了一种基于双通道改进 U-Net 分割网络的缺陷检测方法,通过对模板图像和实物图像叠加通道进而实现变化特征学习,此外还对网络结构和损失函数进行了优化,取得了较好的分割效果。文献[99]提出了一种用于锂电池封钉缺陷检测的少样本学习方法,先利用偏振成像技术获取多维图像信息,再通过一种新的 Copy-Paste 数据增强算法来扩充数据集,以经典网络 U-Net 为

例证明了该方法在分割检测模型中的准确性和可行性。文献[100]提出了一种基于多任务深度学习模型的锂电池缺陷检测技术,该模型以 U-Net 为体系结构,ResNet 为编码器骨干网络,解码端连接着缺陷区域检测任务网络、缺陷轮廓检测任务网络、缺陷二分类网络这 3 个任务相关网络,取得了良好的效果,有效缓解了样本数量不足的问题。文献[101]以 DeepLabV3 网络为基础,通过引入位置注意力机制提升网络的特征表达能力,实验结果表明改进后的算法显著改善了边缘分割精度,实现了缺陷的精确定位,但该算法中的空洞卷积会导致局部信息丢失,对小缺陷的分割效果可能不佳。

综上,分割网络有着直观表达缺陷具体外形的特点,但其数据标注成本十分高,研究者们针对此问题也提出了优化网络结构、采取数据增强等解决办法,具体对比方法如表 13 所示。

表 13 常用的分割网络方法对比
 Table 13 Comparison of commonly used segmentation network methods

文献	具体方法	创新点	局限性	性能指标
[97]	基于 U-Net	替换编码结构,增加特征融合模块,使用标签平滑方法	平均交并比的精度仍有待提升	准确率:93. 70% mIoU:85. 01%
[98]	基于双通道 U-Net	采用 Siamese 网络中通道融合思想,引入 DenseNet121 结构,采用 Focal Loss 损失函数	图像标注成本太高	误检率:2. 689% 漏检率:1. 612%
[99]	基于少样本学习	利用偏振成像技术获取多维图像信息,采取一种新的 Copy-Paste 数据增强算法	模型泛化能力受到限制	mAP:63. 6%
[100]	基于多任务学习	解码端连接着 3 个任务相关网络	计算复杂度高	mIoU:0. 750
[101]	基于 DeepLabV3	引入位置注意力模块	对小缺陷的分割效果不佳	mIoU:85. 98% 准确率:98. 33%

4 数据集及评估指标

4. 1 数据集

锂电池缺陷图像采集的技术要求高、设备成本昂贵,且需要长时间的技术积累和研究发展,这就导致了锂电池缺陷图像采集周期长,目前并没有公开的锂电池缺陷数据集。研究者们通常进行自建数据集的采集和标注,或是由合作公司直接提供实际生产过程中所拍摄的缺陷图像,表 14 列出了 10 个自建锂电池缺陷数据集,以供参考。

表 14 自建锂电池表面缺陷数据集
 Table 14 Self-built surface defect data sets for lithium battery

文献	图像总数	图像大小	标签类别	缺陷类别
[50]	863	640×640	矩形框	6 类(气泡、亮点、漏金属、亮条、脱碳、黑点)
[59]	3 600	128×128	类别	3 类(划痕、破损、暗斑)
[69]	1 037	1 728×1 224	矩形框	6 类(凹坑、夹缝、污渍、硬印、拉丝、壳口变形)
[80]	1 000	512×512	矩形框	5 类(露铝、凹痕、划痕、凹坑、针孔)
[82]	1 980	416×416	矩形框	3 类(磕伤、划痕、热缩膜破损)
[83]	2 080	416×416	矩形框	4 类(极耳异常、气泡、压痕、破损)
[85]	3 000	640×640	矩形框	3 类(孔洞、漏金属、划痕)
[102]	2 080	256×256	多边形框	6 类(气泡、亮斑、暗斑、漏金属、划痕、划伤)
[103]	3 345	640×480	矩形框	简化为 3 大类(块状缺陷、点状缺陷、线状缺陷)
[104]	4 023	256×256	矩形框	9 类(漏液结晶、通用变形、深凹坑点、异色沾污、表面划痕等)

4. 2 性能评估指标

当模型训练好时,需要一些指标来衡量检测系统的性能,这些指标反映了系统在识别过程中的准确性和可靠性。下面从图像分类、目标检测、图像分割 3 个角度给出一些常见的评估指标。

1) 图像分类
 以二分类问题为例,根据真实类别和预测类别的不同组合,将样本划分为如下 4 类:真阳性(true positive, TP)、

假阴性(false negative, FN)、假阳性(false positive, FP)和真阴性(true negative, TN),它们之间的关系如表 15 所示。

表 15 二分类评估符号
 Table 15 Binary evaluation notation

类别	实际正样本	实际负样本
预测正样本	TP	FP
预测负样本	FN	TN

针对图像分类任务,常用的评价指标有精确率 (precision)、召回率 (recall)、准确率 (accuracy)、F1 值等,具体定义如表 16 所示。

表 16 图像分类的评估指标
Table 16 Evaluation index of image classification

指标	含义	公式
精确率 (Precision)	预测正确的正样本数据占预测为正样本数据的比例	$Precision = \frac{TP}{TP + FP}$
召回率 (Recall)	预测正确的正样本数据占实际为正样本数据的比例	$Recall = \frac{TP}{TP + FN}$
准确率 (Accuracy)	预测正确的数据占总数据的比例	$Accuracy = \frac{TP + TN}{TP + FP + FN + TN}$
F1 值	模型精确率和召回率的调和平均值 ($0 < F1 < 1$), 值越大越好	$F1 = 2 \frac{precision \times recall}{precision + recall}$
误检率 (FPR)	负样本被误判的数据占总负样本数据的比例	$FPR = \frac{FP}{FP + TN}$
漏检率 (FNR)	正样本被误判的数据占总正样本数据的比例	$FNR = \frac{FN}{FN + TP}$
平均精度 (AP)	Precision-Recall 曲线下的面积,值越高代表模型性能越好	$AP = \int_0^1 P(r) dr$
平均精度均值 (mAP)	多个类别的 AP 值的均值 ($0 < mAP < 1$)	$mAP = \frac{\sum_{i=1}^k AP_i}{k}$
马修斯相关系数 (MCC)	比较全面的指标,可以评估样本不平衡下的缺陷检测模型	$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$
帧率 (FPS)	每秒计算机可处理的帧数	-

2) 目标检测

目标检测任务中的评价指标大多数与分类问题相同,此外,目标检测任务中还有交并比 *IoU* 指标,即预测矩形框和标注矩形框的交集与并集的比值,该值越大,说明预测结果框与初始标注框越接近,预测效果越好。根据不同的检测任务,可以调节不同的 *IoU* 阈值,大于此阈值的预测框被识别为 *TP*,小于等于此阈值的预测框被识别为 *FP*。由于图像分割任务也有此评价指标,具体公式放到表 17 一起讨论说明。

3) 图像分割

图像分割任务的评价指标都是以像素为基点,具体常见的评价指标如表 17 所示。

5 面临的技术挑战及展望

近年来,机器视觉技术已在锂电池缺陷检测中得到了广泛应用,随着深度学习的发展,缺陷检测精度和检测效率也在逐步提高,但在实际生产过程中仍有诸多问题

等待挑战,本节将总结相关的技术挑战及对应的技术展望。

5.1 技术挑战

- 1) 数据集匮乏与类别不平衡挑战
- 机器学习模型的性能很大程度上依赖于训练数据的质量和数量,而自建数据集的质量很难与公开数据集相比,没有公开的锂电池缺陷数据集成了锂电池缺陷检测技术发展的一大难题。此外,在实际生产中,各类缺陷出现的频率不一,某些罕见的缺陷类别样本可能会非常少,导致数据集中存在类别不平衡的问题。
- 2) 复杂背景挑战
- 复杂背景下的缺陷检测一直是一个热门话题,在真实复杂的工业环境下,获得的待检测图像具有对比度低、亮度不均、纹理背景等特点,极大地增加了缺陷检测的难度。此外,锂电池表面的微小缺陷会极易受到背景噪声的干扰,使得前景与背景更难以区分。
- 3) 小目标缺陷检测挑战
- 小尺寸缺陷对锂电池质量的影响也是不容忽视的,

表 17 图像分割的评估指标
Table 17 Evaluation index of image segmentation

指标	含义	公式
交并比(IoU)	预测区域 A 与标注区域 B 的交集与并集的比值	$IoU = \frac{A \cap B}{A \cup B}$
平均交并比($mIoU$)	k 类缺陷的交并比值的均值, $k+1$ 为加上背景的总体别数	$mIoU = \frac{1}{k+1} \sum_{i=0}^k IoU_i$
像素准确率(PA)	预测类别正确的像素数占总像素数的比例, P_{ij} 为第 i 类像素被判为 j 类的数量, P_{ii} 、 P_{ji} 的含义以此类推	$PA = \frac{\sum_{i=0}^k P_{ii}}{\sum_{i=0}^k \sum_{j=0}^k P_{ij}}$
平均像素准确率(mPA)	对像素准确率求平均,每个类被正确分类像素数的比例	$mPA = \frac{1}{k+1} \sum_{i=0}^k \frac{P_{ii}}{\sum_{j=0}^k P_{ij}}$
$Dice$ 相似系数	计算预测样本与标准样本的相似度	$Dice = \frac{\frac{2}{k+1} \sum_{i=1}^{k+1} P_i \times \frac{1}{k+1} \sum_{i=1}^{k+1} R_i}{\frac{1}{k+1} \sum_{i=1}^{k+1} P_i + \frac{1}{k+1} \sum_{i=1}^{k+1} R_i}$

但由于其在图像中的像素占比较低,可能导致特征信息不足,使得设计通用的特征描述器和分类器变得困难,而且现有的目标检测算法都是针对中大物体的,小目标缺陷特征会随着网络的加深而逐渐丢失,如何改进网络来提高小目标缺陷的检测率是待解决的问题。

4) 实时性挑战

在工业生产中,实时性是反映检测效率的一个重要指标。为了追求检测精度,通常会使用高分辨率设备采集图像,但是,高分辨率图像作为输入会给网络的计算带来负担,在计算机算力有限的情况下,应注意如何平衡好实时性与检测精度。

5) 模型泛化能力不足挑战

对于传统视觉检测方法,在处理不同类别的缺陷时需要设计不同的特征提取方式和处理算法,通用性较差;使用深度学习方法时,由于数据集资源有限,仅能在自建数据集里调试模型,对未在数据集里的缺陷识别能力较差,不具备泛化能力。

6) 模型轻量化挑战

大部分基于机器学习尤其是深度学习的网络有着上百层的结构,庞大的数据量使其很难应用于移动设备中,模型需要在有限的计算资源下高效运行,轻量化的处理不可避免,这对模型的设计提出了更高的要求。

5.2 技术展望

虽然基于机器视觉的锂电池缺陷检测在国内外取得了一系列的进展,但考虑到目前的技术还存在着各种的不足,针对上文提到的技术挑战,可以从如下 6 个方面进

行技术展望:

1) 使用缺陷样本生成技术,减缓数据依赖

在图像预处理时,通常会对原始图像进行旋转、缩放、裁剪等数据增强操作,虽说数据集得到了有效的扩充,却不利于数据多样性的提升,有着过拟合的风险,而生成对抗网络(generative adversarial networks, GAN)可以生成多样化的数据样本,其内部结构中的生成器和判别器采取竞争机制,能够不断学习如何生成更逼真的数据,可以有效解决传统数据增强方法无法涵盖所有数据变化的问题,进一步提高数据的质量和数量。

2) 基于无监督/半监督学习,提高训练效率

目前主流的目标检测网络都是基于监督学习的方式,虽有着良好的检测效果,但模型的训练时间有时甚至可以达到好几天,效率低下,上文提到的迁移学习可以有效缓解此问题。此外,还可以基于无/半监督学习,此方法不需要标记的数据或只需少量标记数据就可进行训练,大大降低了数据准备的成本和时间,后续还能不断地从未标记的数据中学习来适应新的数据分布,相比监督学习更灵活高效。

3) 基于多尺度特征,改善小目标难点

针对小目标缺陷难以检测的问题,可以设置更适合微小缺陷的检测锚框,还可以通过在不同的尺度上对图像进行处理,或是利用图像中的目标与其周围环境的关系,帮助模型更好地捕捉到小目标的特征。另外,引入注意力机制模块有助于减少背景噪声的干扰,在小目标检测方面有着显著的效果。

4) 扩展三维数据,减少外界干扰

目前的缺陷检测方法都是基于二维数据,而锂电池表面容易存在褶皱和凹坑等含有高度信息的缺陷,且其表面光滑,在光源照射下容易产生高光和阴影现象。相比于二维检测,三维检测技术可以复现物体表面状态,更清楚地获取缺陷的特征,减少外界带来的干扰,是很好的技术选择。

5) 精简模型结构,提高实时性

为了追求检测精度,现有的模型结构被改得越来越复杂,庞大的模型参量限制了其在嵌入式设备里的运用,为此需要精简网络结构,可借鉴一些轻量级网络的思想,如 ShuffleNet、EfficientNet 等,这些网络结构在保持较高性能的同时,大幅减少了参数量和计算复杂度。此外,还可应用模型剪枝、知识蒸馏等压缩技术,减小模型大小,提高运行速度。

6) 应用 Transformer 模型,捕捉全局信息

Transformer 在自然语言处理领域已取得巨大成功,其通过自注意力机制很好地捕捉到序列数据中的全局依赖关系,目前也有部分研究者将 Transformer 模型应用于目标检测领域,与卷积神经网络相比,Transformer 不限于提取局部特征,理论上可以直接将输入序列中的任何位置与其他位置关联起来,更好地理解数据中的复杂模式,将成为未来的研究趋势之一。

6 结 论

锂电池的缺陷检测近年来受到了广大学者和企业的关注,而基于机器视觉的方法凭借着其非接触性、高精度、高速度等优势已成为最主流的检测方法之一。本文对基于机器视觉的锂电池缺陷检测现状进行了全面综述,首先整理了常见的缺陷类型并阐明锂电池缺陷的检测流程,然后比较了各种检测方法的优缺点。传统的机器视觉方法是通过提取缺陷区域的形状、灰度、纹理等特征,再结合分类器进行分类,这种方法大多数是应用在较简单的检测任务中,一旦场景更换,则需重新设计检测算法,通用性较差。基于深度学习的方法拥有出色的特征提取和模式识别能力,在检测精度和检测速度上都有了很大的提升,并具备良好的鲁棒性和泛化能力。同时,从数据集、复杂背景、小目标、实时性等角度出发,指出了锂电池缺陷检测领域内所面临的挑战,并列出了相关的解决方案。通过以上总结和分析,期望可以提供有价值的参考。

参考文献

[1] SHARP N, ADAMS D, CARUTHERS J, et al. Lithium-ion battery electrode inspection using pulse thermogra-

phy[J]. NDT & E International, 2014, 64: 41-51.

- [2] JUST P, ROST J, ECHELMEYER T, et al. A method to quantify coating thickness and porosity of electrodes for lithium-ion-batteries[J]. Measurement, 2016, 89: 312-315.
- [3] O'REGAN P R. Defect detection for lithium ion battery manufacturing via automated image processing of pulse thermography[D]. West Lafayette: Purdue University, 2013.
- [4] 陈家智, 吴永明. 基于机器视觉的锂电池正负极冗余度缺陷检测[J]. 组合机床与自动化加工技术, 2021(12): 75-78.
- CHEN J ZH, WU Y M. Detection of positive and negative redundancy defects of lithium batteries based on machine vision[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2021(12): 75-78.
- [5] ETIEMBLE A, BESNARD N, ADRIEN J, et al. Quality control tool of electrode coating for lithium-ion batteries based on X-ray radiography[J]. Journal of Power Sources, 2015, 298: 285-291.
- [6] HU S, XU J, LYU M, et al. The application of industrial CT detection technology in defects inspection of lithium ion battery[C]. Journal of Physics: Conference Series. IOP Publishing, 2021, 2083(3): 032075.
- [7] YI M, JIANG F, LU L, et al. Ultrasonic tomography study of metal defect detection in lithium-ion battery[J]. Frontiers in Energy Research, 2021, 9: 806929.
- [8] BRAUCHLE F, GRIMSMANN F, VON KESSEL O, et al. Defect detection in lithium ion cells by magnetic field imaging and current reconstruction[J]. Journal of Power Sources, 2023, 558: 232587.
- [9] 陈佳慧, 王飞, 危荃, 等. 锂电池安全性能无损检测技术研究进展[J]. 无损检测, 2022, 44(12): 72-75.
- CHEN J H, WANG F, WEI Q, et al. Research progress on nondestructive testing technology of lithium battery safety performance[J]. Nondestructive Testing, 2022, 44(12): 72-75.
- [10] 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(5): 1017-1034.
- TAO X, HOU W, XU D. A surface of surface defect detection methods based on deep learning[J]. Acta Automatica Sinica, 2021, 47(5): 1017-1034.
- [11] 赵朗月, 吴一全. 基于机器视觉的表面缺陷检测方法

- 研究进展[J]. 仪器仪表学报, 2022, 43(1): 198-219.
- ZHAO L Y, WU Y Q. Research progress of surface defect detection methods based on machine vision[J]. Chinese Journal of Scientific Instrument, 2022, 43(1): 198-219.
- [12] 张志国. 基于智能学习的电池片表面缺陷视觉检测算法研究[D]. 广州: 华南理工大学, 2019.
- ZHANG ZH G. Research on visual detection algorithm for surface defects of cell based on intelligent learning[D]. Guangzhou: South China University of Technology, 2019.
- [13] 裴炜冬. 基于机器视觉的锂电池丝印 LOGO 缺陷检测系统研究与实现[D]. 广州: 广东工业大学, 2018.
- PEI W D. Research and implementation of lithium batteries printed LOGO defect inspection system based on machine vision[D]. Guangzhou: Guangdong University of Technology, 2018.
- [14] 姜宝超, 曾勇, 韩有军, 等. 基于 LO-RANSAC 的锂电池极片表面痕类缺陷检测[J]. 储能科学与技术, 2023, 12(2): 593-601.
- JIANG B CH, ZENG Y, HAN Y J, et al. Scratch defect detection of lithium battery electrode based on LO-RANSAC algorithm[J]. Energy Storage Science and Technology, 2023, 12(2): 593-601.
- [15] 陈洋. 基于机器视觉的锂电池电极片表面缺陷检测算法研究[D]. 广州: 华南理工大学, 2021.
- CHEN Y. Research on detection algorithm for surface defects of lithium-ion battery electrode based on machine vision[D]. Guangzhou: South China University of Technology, 2021.
- [16] 王庆秋, 李林升, 毛晓, 等. 基于双边滤波与区域生长的锂电池极片缺陷检测方法[J]. 机械设计与研究, 2022, 38(2): 158-162.
- WANG Q Q, LI L SH, MAO X, et al. Lithium battery pole piece defect detection method based on bilateral filtering and regional growth[J]. Machine Design and Research, 2022, 38(2): 158-162.
- [17] 郭绍陶, 苑玮琦. 基于双高斯纹理滤波模板和极值点韦伯对比度的圆柱锂电池凹坑缺陷检测[J]. 电子学报, 2022, 50(3): 637-642.
- GUO SH T, YUAN W Q. Pit defect detection of cylindrical lithium battery based on double gaussian texture filtering template and extreme point weber contrast[J]. Acta Electronic Sinica, 2022, 50(3): 637-642.
- [18] 曾臻, 王宏博, 王正家, 等. 软包装锂离子电池的表面凸点缺陷检测[J]. 电池, 2023, 53(3): 284-288.
- ZENG ZH, WANG H B, WANG ZH J, et al. Surface bump defect detection for pouch Li-ion battery[J]. Battery Bimonthly, 2023, 53(3): 284-288.
- [19] 毛伟生, 李林升, 周文一, 等. 基于小波阈值与区域分裂合并的锂电池极片缺陷检测方法[J]. 国外电子测量技术, 2022, 41(8): 46-53.
- MAO W SH, LI L SH, ZHOU W Y, et al. Defect detection method of lithium battery pole piece based on wavelet threshold and region splitting merging[J]. Foreign Electronic Measurement Technology, 2022, 41(8): 46-53.
- [20] 周新颖, 胡跃明. 基于小波增强与 Canny 算法融合的锂电池极片缺陷检测方法[J]. 电子测量技术, 2023, 46(4): 149-154.
- ZHOU X Y, HU Y M. Lithium battery electrode defect detection method based on fusion of wavelet enhancement and Canny algorithm[J]. Electronic Measurement Technology, 2023, 46(4): 149-154.
- [21] 王润泽. 动力锂电池正负极缺陷在线检测系统关键技术研究[D]. 徐州: 中国矿业大学, 2018.
- WANG R Z. Research on key technologies of online detection system for positive and negative defects of power lithium battery[D]. Xuzhou: China University of Mining and Technology, 2018.
- [22] 王正家, 咎傲, 谷峰. 基于 Gabor 滤波的软包电池表面缺陷检测[J]. 组合机床与自动化加工技术, 2023(11): 146-149.
- WANG ZH J, ZAN AO, GU F. Surface defect detection of pouch cells based on Gabor filtering[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2023(11): 146-149.
- [23] 周文一, 李林升, 陶怡帆, 等. 基于 Gabor 滤波与分水岭算法的锂电池极片缺陷检测方法[J]. 机械设计与研究, 2023, 39(5): 147-151, 157.
- ZHOU W Y, LI L SH, TAO Y F, et al. Electrode defect detection method for lithium battery based on adaptive Gabor filtering and watershed fusion[J]. Machine Design and Research, 2023, 39(5): 147-151, 157.

- [24] 谷峰,王正家,咎傲,等. 软包装锂离子电池表面划痕的检测方法[J]. 电池, 2023, 53(5): 514-518.
GU F, WANG ZH J, ZAN AO, et al. Detection method for surface scratches of pouch Li-ion battery[J]. Battery Bimonthly, 2023, 53(5): 514-518.
- [25] CHEN G, ZHU X F, XU Q Q, et al. Film defects of lithium battery recognition based on brightness and one-against-all support vector machine [J]. Applied Mechanics and Materials, 2014, 462: 155-158.
- [26] 唐东昂. 彩色图像下的圆柱形覆膜锂电池圆周面缺陷检测方法研究[D]. 沈阳: 沈阳工业大学, 2021.
TANG D ANG. Research on detection method of circumferential surface defects of cylindrical coated lithium battery under color image [D]. Shenyang: Shenyang University of Technology, 2021.
- [27] 许长路, 李林升, 立济伟. 基于 Gamma 矫正与 LOG 算法融合的锂电池极片缺陷检测方法[J]. 机械设计与研究, 2020, 36(6): 105-109.
XU CH L, LI L SH, LI J W. Lithium battery polar piece defect detection method based on Gamma correction and LOG algorithm fusion [J]. Machine Design and Research, 2020, 36(6): 105-109.
- [28] XU C L, LI L SH, 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, 99:1.
- [29] 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.
HUANG M T, LIAN Y X. Lithium battery electrode plate surface defect detection based on improved Canny operator[J]. Chinese Journal of Scientific Instrument, 2021, 42(10): 199-209.
- [30] 王奔. 圆柱形锂电池端面缺陷检测方法研究[D]. 沈阳: 沈阳工业大学, 2022.
WANG B. Research on the inspection method of cylindrical lithium battery end face defects [D]. Shenyang: Shenyang University of Technology, 2022.
- [31] 夏嘉伟, 胡跃明. 基于改进多尺度小波变换的锂电极片缺陷检测[J]. 激光杂志, 2023, 44(6): 67-71.
XIA J W, HU Y M. Lithium battery pole piece defect detection based on improved multi-scale wavelet transform[J]. Laser Journal, 2023, 44(6): 67-71.
- [32] 康熙川. 圆柱形锂电池圆周面缺陷在线检测方法研究[D]. 沈阳: 沈阳工业大学, 2019.
KANG ZH CH. Research on on-line detection method of cylindrical lithium battery surface defects [D]. Shenyang: Shenyang University of Technology, 2019.
- [33] 苑玮琦, 郭绍陶. 圆柱型覆膜锂电池圆周面凹坑检测方法研究[J]. 仪器仪表学报, 2020, 41(2): 146-156.
YUAN W Q, GUO SH T. Research on the detection method of pit on the cylindrical surface of cylindrical coated lithium battery[J]. Chinese Journal of Scientific Instrument, 2020, 41(2): 146-156.
- [34] 郭绍陶, 苑玮琦. 圆柱锂电池端面凹坑缺陷检测方法研究[J]. 仪器仪表学报, 2022, 43(3): 230-239.
GUO SH T, YUAN W Q. A research on the detection method of pit on the cylindrical lithium battery end surface [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 230-239.
- [35] 孙正军. 基于图像边缘提取的电池极片瑕疵检测研究[D]. 长沙: 中南大学, 2009.
SUN ZH J. Research on defect detection of battery electrode based on image edge extraction[D]. Changsha: Central South University, 2009.
- [36] 刘妍. 基于机器视觉的锂电池极片涂布缺陷检测系统设计[D]. 太原: 中北大学, 2012.
LIU Y. Defect detecting system of the lithium battery pole piece coating based on machine vision [D]. Taiyuan: North University of China, 2012.
- [37] 钟健平, 费韬. 基于 WOA-BPNN 的锂电池极片涂布缺陷检测识别[J]. 储能科学与技术, 2022, 11(8): 2537-2545.
ZHONG J P, FEI T. Defects detection and recognition of lithium battery electrode plate coating based on WOA-BPNN [J]. Energy Storage Science and Technology, 2022, 11(8): 2537-2545.
- [38] TAO Y F, LI L SH, MAO W SH, et al. Lithium battery pole piece defect detection method based on mean shift and gray-level co-occurrence matrix [C]. 2022 2nd International Conference on Electrical Engineering and Control Science (IC2ECS), 2022: 695-699.
- [39] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection [C]. 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition

- (CVPR), 2005, 1: 886-893.
- [40] LOWE D G. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [41] BAY H, TUYTELAARS T, GOOL L V. Surf: Speeded up robust features[C]. 2006 European Conference on Computer Vision (ECCV), 2006: 404-417.
- [42] 郭博. 基于机器视觉的锂电池极片缺陷检测技术[D]. 衡阳: 南华大学, 2021.
- WU B. Lithium battery pole piece defect detection technology based on machine vision[D]. Hengyang: University of South China, 2021.
- [43] 祝习龙. 基于机器视觉的锂电池焊线缺陷检测[D]. 广州: 暨南大学, 2019.
- ZHU X L. Lithium battery wire defect detection based on machine vision[D]. Guangzhou: Jinan University, 2019.
- [44] 王露. 基于机器视觉的锂电池极片缺陷检测与分类系统[D]. 西安: 西安科技大学, 2020.
- WANG L. Defect detecting and classification system of the lithium battery pole piece based on machine vision[D]. Xi'an: Xi'an University of Science and Technology, 2020.
- [45] 邓红红. 锂电池表面缺陷检测研究[D]. 哈尔滨: 哈尔滨工业大学, 2018.
- DENG H H. Research on surface defect detection of lithium battery [D]. Harbin: Harbin Institute of Technology, 2018.
- [46] 周佳禾, 宫临凡, 王盛瑶. 方形卷绕式锂电池电极褶皱检测方法研究[J]. 仪表技术与传感器, 2021(5): 107-111.
- ZHOU J H, GONG L F, WANG SH Y. Research on detection of electrode fold of spirally wound flattened lithium batteries[J]. Instrument Technique and Sensor, 2021(5): 107-111.
- [47] ZHAN Y Y, DENG J W, WANG T H. Lithium battery swollen detection based on computer vision[C]. 2013 IEEE 4th International Conference on Software Engineering and Service Science, 2013: 728-731.
- [48] LIU X H, WU L Q, GUO X Q, et al. A novel approach for surface defect detection of lithium battery based on improved K-nearest neighbor and Euclidean clustering segmentation[J]. The International Journal of Advanced Manufacturing Technology, 2023, 127(1/2): 971-985.
- [49] HUBER J, TAMMER C, KROTH S, et al. Method for classification of battery separator defects using optical inspection[J]. 49th CIRP Conference on Manufacturing Systems, 2017: 585-590.
- [50] 倪君仪. 基于机器视觉的锂电池电极片缺陷检测算法研究[D]. 广州: 华南理工大学, 2022.
- NI J Y. Research on defect detection algorithm of lithium battery electrode based on machine vision [D]. Guangzhou: South China University of Technology, 2022.
- [51] MA L Y, HU Y H, ZHANG Y. Support tucker machines based bubble defect detection of lithium-ion polymer cell sheets[J]. Engineering Letters, 2017, 25(1): 46-51.
- [52] 钟健平. 基于机器视觉的锂电池极片缺陷检测系统设计[D]. 广州: 华南理工大学, 2022.
- ZHONG J P. Design of defect detection system for lithium battery electrode plate based on machine vision[D]. Guangzhou: South China University of Technology, 2022.
- [53] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [54] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. ArXiv preprint arXiv:1409.1556, 2014.
- [55] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions [C]. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015: 1-9.
- [56] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition[C]. 29th IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770-778.
- [57] HUANG G, LIU ZH, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 4700-4708.
- [58] 鲁永帅, 唐英杰, 马鑫然, 等. 应用卷积神经网络的锂电池极片涂布缺陷分类[J]. 包装工程, 2022, 43(9): 231-238.
- LU Y SH, TANG Y J, MA X R, et al. Defect

- classification of lithium battery pole piece coating using convolutional neural network [J]. *Packaging Engineering*, 2022, 43(9): 231-238.
- [59] LI J W, LI L SH, XU CH L. Research on defect recognition of lithium battery pole piece based on deep learning [C]. *E3S Web of Conferences*, 2021, 261: 202126101021.
- [60] BADMOS O, KOPP A, BERNTHALER T, et al. Image-based defect detection in lithium-ion battery electrode using convolutional neural networks [J]. *Journal of Intelligent Manufacturing*, 2020, 31(4): 885-897.
- [61] MA L Y, XIE W, ZHANG Y. Blister defect detection based on convolutional neural network for polymer lithium-ion battery [J]. *Applied Sciences*, 2019, 9(6): 9061085.
- [62] JIANG SH B, WANG T T, ZHANG SH L, et al. Battery panel defect detection method based on deep convolutional neural network [C]. 2019 IEEE 11th International Conference on Wireless Communications and Signal Processing (WCSP), 2019: 1953-1958.
- [63] PENG J W, XUE M M, LOU Y J. Automatic internal wrinkles detection of lithium-ion batteries using convolutional neural network [C]. 2021 IEEE 17th International Conference on Automation Science and Engineering (CASE), 2021: 1422-1427.
- [64] DIN N U, ZHANG L, ZHOU Y, et al. Laser welding defects detection in lithium-ion battery poles [J]. *Engineering Science and Technology, An International Journal*, 2023, 46: 101495.
- [65] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2014: 580-587.
- [66] GIRSHICK R. Fast R-CNN [C]. 2015 IEEE International Conference on Computer Vision (ICCV), 2015: 1440-1448.
- [67] REN SH 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*, 2016, 39(6): 1137-1149.
- [68] 李瑞坤. 基于多尺度特征的锂电池表面缺陷检测方法研究 [D]. 哈尔滨: 哈尔滨工业大学, 2019.
- LI R K. Surface defect detection for lithium battery based on multi-scale features [D]. Harbin: Harbin Institute of Technology, 2019.
- [69] 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.
- FENG X Y. Recognition and classification of surface defects of cylindrical lithium battery steel shell based on deep learning [D]. Hefei: Hefei University of Technology, 2020.
- [70] CAI ZH W, VASCONCELOS N. Cascade R-CNN: Delving into high quality object detection [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 6154-6162.
- [71] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]. 29th IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 779-788.
- [72] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 6517-6525.
- [73] REDMON J, FARHADI A. YOLOv3: An incremental improvement [J]. *ArXiv preprint arXiv:1804.02767*, 2018.
- [74] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection [J]. *ArXiv preprint arXiv:2004.10934*, 2020.
- [75] LI C, LI L, JIANG H, et al. YOLOv6: A single-stage object detection framework for industrial applications [J]. *ArXiv preprint arXiv:2209.02976*, 2022.
- [76] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 7464-7475.
- [77] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. 2016 European Conference on Computer Vision (ECCV), 2016: 21-37.
- [78] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]. 2017 IEEE International Conference on Computer Vision (ICCV), 2017: 2999-3007.
- [79] LANG X L, ZHANG Y, SHU SH B, et al. Lithium

- battery surface defect detection based on the YOLOv3 detection algorithm[C]. Tenth International Symposium on Precision Mechanical Measurements, 2021, 12059.
- [80] 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.
- XU H B. Research on visual inspection of surface defects of lithium battery case based on deep learning [D]. Qinhuangdao: Yanshan University, 2021.
- [81] 黄罗华. 手机锂电池表面缺陷检测算法研究及应用[D]. 厦门: 厦门大学, 2020.
- HUANG L H. The research and application of detection algorithm for surface defects on mobile phone lithium battery[D]. Xiamen: Xiamen University, 2020.
- [82] 胡昊. 基于机器视觉的柱形锂电池缺陷检测研究[D]. 合肥: 合肥工业大学, 2022.
- HU H. Research on defect detection of cylindrical lithium battery based on machine vision [D]. Hefei: Hefei University of Technology, 2022.
- [83] 桂久琪, 李林升, 毛晓, 等. 基于改进 YOLOv4 的锂电池缺陷检测方法[J]. 电子测量技术, 2022, 45(15): 144-150.
- GUI J Q, LI L SH, MAO X, et al. Lithium battery defect detection method based on improved YOLOv4[J]. Electronic Measurement Technology, 2022, 45(15): 144-150.
- [84] 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.
- LI Y W, SUN H R, HU Y M, et al. Electrode defect YOLO detection algorithm based on attention mechanism and multi-scale feature fusion[J]. Control and Decision, 2023, 38(9): 2578-2586.
- [85] 葛钊明, 胡跃明. 基于改进 YOLOv5 的锂电池极片缺陷检测[J]. 激光杂志, 2023, 44(2): 25-29.
- GE ZH M, HU Y M. Lithium battery electrode defect detection method based on improved YOLOv5[J]. Laser Journal, 2023, 44(2): 25-29.
- [86] ZHOU H CH, GE ZH M, HU Y M, et al. An improved deep learning network based defect detection algorithm for lithium-ion battery pole chip[C]. 2023 8th International Conference on Cloud Computing and Big Data Analytics (ICCCBDA), 2023: 506-511.
- [87] HU H B, ZHU ZH H. Sim-YOLOv5s: A method for detecting defects on the end face of lithium battery steel shells[J]. Advanced Engineering Informatics, 2023, 55: 101824.
- [88] YANG Y T, ZHOU Y H, DIN N U, et al. An improved YOLOv5 model for detecting laser welding defects of lithium battery pole [J]. Applied Sciences, 2023, 13(4): 13042402.
- [89] YANG Y T, LI J Q, ZHOU Y H, et al. An improved YOLOv7 algorithm for solder defect detection of lithium battery[C]. 2023 4th International Seminar on Artificial Intelligence, Networking and Information Technology (AINIT), 2023: 588-592.
- [90] YANG K, ZHENG L X. An end-to-end lithium battery defect detection method based on detection transformer[C]. 2023 5th International Conference on Intelligent Control, Measurement and Signal Processing (ICMSP), 2023: 207-211.
- [91] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]. Medical Image Computing and Computer-Assisted Intervention (MICCAI), 2015: 234-241.
- [92] HE K M, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[C]. 2017 IEEE International Conference on Computer Vision (ICCV), 2017: 2980-2988.
- [93] CHEN L CH, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected crfs [J]. ArXiv preprint arXiv: 1412.7062, 2014.
- [94] CHEN L CH, 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, 2017, 40(4): 834-848.
- [95] CHEN L CH, PAPANDREOU G, SCHROFF F, et al. Rethinking atrous convolution for semantic image segmentation [J]. ArXiv preprint arXiv: 1706.05587, 2017.
- [96] CHEN L CH, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]. 2018 European Conference on Computer Vision (ECCV), 2018: 801-818.

[97]

陈晓荣, 杨雪荣, 成思源, 等. 基于改进 Unet 网络的锂电池极片表面缺陷检测[J]. 广东工业大学学报, 2023, 40(4): 60-66,93.
CHEN X R, YANG X R, CHENG S Y, et al. Surface defect detection of lithium battery electrodes based on improved Unet network [J]. Journal of Guangdong University of Technology, 2023, 40(4): 60-66,93.

[98]

陈滢. 锂电池丝网印刷缺陷视觉检测技术研究[D]. 广州: 广东技术师范大学, 2021.
CHEN Y. Research on visual detection technology for screen printed defect of lithium batteries [D]. Guangzhou: Guangdong Polytechnic Normal University, 2021.

[99]

XU C, YE Y, ZHANG J, et al. A few-shot learning method for the defect inspection of lithium battery sealing nails [C]. 2023 4th International Conference on Computing, Networks and Internet of Things. 2023: 983-989.

[100]

YU Y T, YAO ZH Y, TIAN F. Multi-task deep learning based defect detection for lithium battery tabs[C]. 2022 China Automation Congress (CAC), 2022: 2251-2256.

[101]

何涛, 张成娟, 雷卓, 等. 改进 DeepLabV3 的软包装锂离子电池表面凹坑缺陷检测方法[J/OL]. 电池, 1-5. [2024-08-30]. <http://kns.cnki.net/kcms/detail/43.1129.tm.20240116.1915.002.html>.
HE T, ZHANG CH J, LEI ZH, et al. Improved DeepLabV3 network for detecting surface crater defects of soft pack Li-ion battery[J/OL]. Battery Bimonthly, 1-5 [2024-08-30]. <http://kns.cnki.net/kcms/detail/43.1129.tm.20240116.1915.002.html>.

[102]

刘国栋. 基于深度学习的锂电池极片表面缺陷检测方法研究[D]. 广州: 广东工业大学, 2022.
LIU G D. Research on surface defect detection method of lithium battery electrode based on deep learning[D]. Guangzhou: Guangdong University of Technology, 2022.

[103]

陈灏一. 基于机器视觉的软包锂电池检测系统的研制[D]. 广州: 广东工业大学, 2022.
CHEN H Y. Development of a soft-pack lithium battery detection system based on machine vision [D]. Guangzhou: Guangdong University of Technology, 2022.

[104]

刘昕宇. 基于机器视觉的工业场景下手机锂电池缺陷检测[D]. 泉州: 华侨大学, 2021.
LIU X Y. Mobile phone lithium battery defect detection in industrial scenarios based on machine vision [D]. Quanzhou: Huaqiao University, 2021.

作者简介



Yu Hanwen received his B.Sc. degree from Nanjing University of Information Science and Technology in 2023. He is currently a Ph. D. candidate at Nanjing University of Aeronautics and Astronautics. His main research interests include image processing and machine vision.



吴一全 (通信作者), 1998 年于南京航空航天大学获得博士学位, 现为南京航空航天大学教授、博士生导师, 主要研究方向为视觉检测与图像测量、遥感图像处理与理解、红外目标检测与识别、视频处理与智能分析等。

Wu Yiquan (Corresponding author) received his Ph. D. degree from Nanjing University of Aeronautics and Astronautics in 1998. He is currently a professor and a Ph. D. advisor at Nanjing University of Aeronautics and Astronautics. His main research interests include visual detection and image measurement, remote sensing image processing and understanding, infrared target detection and recognition, video processing and intelligent analysis, et al.

于瀚文, 2023 年于南京信息工程大学获得学士学位, 现为南京航空航天大学博士研究生, 主要研究方向为图像处理与机器视觉。

E-mail: y2910627232@163.com