

DOI: 10.19650/j.cnki.cjsi.J2311695

基于视觉的汽车装配件缺陷检测研究进展*

张瀚丹, 吴一全

(南京航空航天大学电子信息工程学院 南京 211106)

摘要:汽车装配件的缺陷检测是汽车制造流程中的重要环节,不仅可以提升产品质量,降低退货率,避免成本浪费,还可以为驾驶人员提供安全保障。最早的缺陷检测依靠专家经验,准确度低,人力成本大,而无损检测技术依靠介质,且效率不高。引入机器视觉不仅可以平衡检测精度和效率的问题,还能提高检测系统的鲁棒性,是最有发展潜力的缺陷检测技术之一。本文首先给出了视觉缺陷检测的定义和主要流程,简述了视觉缺陷检测系统中的图像采集硬件,然后从常用的缺陷分割方法、特征提取方法、卷积神经网络3个方面综述了近年来汽车装配件缺陷检测的研究进展,并对比分析了相关方法的优缺点。接着把汽车的装配件大致分为轮毂轮胎、车身漆面、零件、发动机等4类,总结了缺陷类型及其缺陷检测算法的研究现状。随后介绍了与汽车工业相关的10个数据集和缺陷检测性能评价指标。最后指出针对汽车装配件的缺陷检测目前面临着诸多方面的技术挑战,并对进一步的工作进行了展望。

关键词:汽车装配件;缺陷检测;机器视觉;深度学习;性能评价指标

中图分类号: TP391.41 TH89 U466 **文献标识码:** A **国家标准学科分类代码:** 510.4050 520.20

Research progress of vehicle assembly defect detection methods based on vision

Zhang Handan, Wu Yiquan

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

Abstract: The defect detection of automotive assembly parts is an important part in the automotive manufacturing process, which can not only improve product quality, reduce the return rate, avoid cost waste, but also provide safety protection for drivers. The earliest defect detection relies on expert experience, which is low accuracy and high labor cost. The nondestructive testing technology relies on media and is not efficient. The introduction of machine vision can not only balance the problem of detection accuracy and efficiency, but also improve the robustness of the detection system, which is one of the most promising defect detection technologies. This article firstly gives the definition and main process of visual defect detection, briefly introduces the hardware of image acquisition in visual defect detection system. Then, the research progress of automobile assembly defect detection in recent years is reviewed from three aspects of commonly used defect segmentation methods, feature extraction methods and convolutional neural networks. The advantages and disadvantages of related methods are compared and analyzed. The automobile assembly parts are roughly divided into four categories, such as wheel tires, body paint, parts and engines. The research status of defect types and defect detection algorithms are summarized. Next, 10 data sets related to the automobile industry and defect detection performance evaluation indicators are introduced. Finally, it is pointed out that the defect detection of automobile assembly is faced with many technical challenges, and the prospect of further work is given.

Keywords: automobile assembly; defect detection; machine vision; deep learning; performance evaluation index

0 引言

近年来,汽车已成为人们出行的重要选择,由此汽车

制造业也进入了蓬勃发展的时期。目前,在汽车制造产线上已大量应用了无人化自动生产,然而,生产环节中不可避免地会产生一些不合格装配件,造成成本浪费,装配线退货率高,因此汽车装配件的生产质量是汽车制造商

生产过程中的重要指标,需要对汽车的装配件进行缺陷检测。

传统的缺陷检测技术手段通常是采用人工目视检查,由专业的技术人员和专家靠触感和肉眼分辨汽车装配件上的缺陷,此类方法不仅非常耗时,也产生了大量的人工成本。另外,缺陷检测精度不高,对微小缺陷的识别能力不足,而汽车制造过程中含有上千个精密零件,如果无法做到准确检测,导致次品流入市场,不仅会给企业造成巨大损失,而且重要部件如发动机、轮胎、安全带等的缺陷更会危及到驾驶人员的生命安全。随着无损检测技术的发展,汽车装配件的缺陷检测也迎来了新的研究热潮,传统的5大无损检测技术包含超声波检测、射线探伤、渗透检测、磁粉检测和涡流探伤,其中超声波检测^[1]和射线探伤^[2-3]在汽车工业中的应用最多,超声波检测技术必须依靠介质,对于形状不规则、表面不光滑的缺陷难以检测,且缺陷定性及定量困难;射线探伤技术适合密度差异大的材料,另外,需要专门的曝光室和处理胶片的设备,成本昂贵,对操作人员也易造成辐射伤害;渗透检测技术无法检测表面不开口的缺陷,清洗着色剂时会造成环境污染;磁粉检测技术一般用于铁磁性且表面光滑的物体,检测范围小,速度慢;涡流探伤技术要求材料具有导电性,多用于金属表面缺陷检测。

为了寻找更佳的缺陷检测方案,研究者们逐渐将机器视觉引入汽车行业^[4]。机器视觉检测技术指的是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)相机拍摄待检测目标的图像,然后根据图像的灰度值分布和形状、颜色等信息提取合适的数字特征,最后根据实际的项目要求来处理这些特征。在汽车工业中,使用机器视觉检测技术在汽车装配件表面进行缺陷特征搜寻,分析特征参数中包含的缺陷信息,识别相应的缺陷类型,还可以计算出缺陷的尺寸、面积等。通过调研发现,在引入视觉检测后,产品的缺陷检测率大幅提升,节省了不必要的时间和人工成本,然而传统的视觉检测算法依赖于人工设计的特征,在复杂图像背景和光照条件不足的情况下,无法应对更加精密和复杂的缺陷类型,因此需要提出更好的解决方案。深度学习的出现,让计算机能够自动学习图像的数学特征甚至更高抽象层的图像表达,使得视觉检测更加快速、准确。基于深度学习的模型在特征提取方面表现出更佳的性能,且系统鲁棒性增强,不受单一应用场景的限制,模型可随时调整训练,方便部署,因此成为目前最主要的缺陷检测方法之一。

近年来关于汽车装配件缺陷检测的研究受到广泛关注,相关综述文献情况如下:文献[5]介绍了传统的5大无损检测技术在汽车装配件上的应用,没有提及机器视

觉部分,也没有整理数据集和性能评价指标。文献[4,6]通过几个实例展示了机器视觉在汽车制造业中的应用,包括外观测量、缺陷检测、零件标识和字符识别等,但没有专门针对缺陷检测的具体技术方法进行归纳整理。文献[7]总结了全钢子午线轮胎的自动缺陷检测技术,但未涉及汽车的其他装配件,仅参考了5年前的相关文献。文献[8]按照时间线对汽车轻合金铸件X射线图像的缺陷检测技术进行综述,涉及轮毂、发动机缸体等部件,但是没有整理相关数据集,且没有比较各方法的优缺点。文献[9-10]综述了通用的基于视觉的主流缺陷检测技术,但都没有针对汽车工业进行介绍。

通过查阅文献发现,现有研究主要针对汽车某个单一装配件的有无缺陷和有哪种缺陷的检测,并设计相关的视觉检测系统,暂时没有发现对汽车装配件全品类主流缺陷检测技术研究现状进行总结的综述。本文详细综述并分析了现有的汽车装配件缺陷检测方法:1)给出了视觉缺陷检测的定义,介绍了图像采集硬件,然后阐述了主要的缺陷分割方法和特征提取方法,接着分析了汽车装配件缺陷检测中常用的3种深度卷积神经网络,包含分类、检测、分割网络。2)总结了4类主要的汽车装配件,并归纳了现有的检测方法研究现状。3)收集了与汽车工业相关的数据集,包括钢材、铝材、轮胎、漆面和零件等,另外,整理了常见的性能评价指标。4)概述了汽车装配件缺陷检测的技术挑战,并针对这些挑战对未来的研究工作进行了展望。最后,对本文进行了系统的总结。

1 基于视觉的汽车装配件缺陷检测通用方法

1.1 视觉缺陷检测的定义

视觉缺陷检测通常是指利用机器视觉技术,搭建硬件和软件平台,对待测物体表面缺陷进行位置检测与种类识别,常见缺陷有污点、划伤、凹坑、凸起和异物等。检测后可进一步提取缺陷的尺寸、面积等信息用于后续的数据分析。基于视觉的缺陷检测主要模块有图像采集、图像预处理和图像分析,如图1所示。

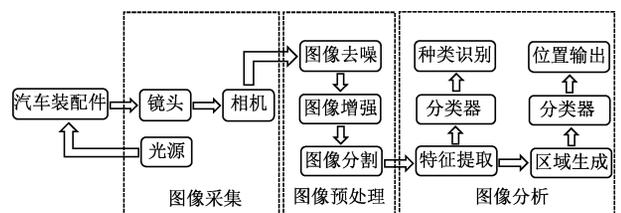


图1 汽车装配件视觉缺陷检测流程

Fig. 1 Flow of automotive assembly parts defect detection based on vision

1.2 视觉缺陷检测系统中的图像采集硬件

在基于视觉的缺陷检测系统中,图像采集主要通过光源、镜头和相机等设备实现,它们对检测结果的好坏有着直接影响。其中光源是影响成像好坏的重要因素,如果光源布置不佳则会导致采集到的图像缺陷信息不充分,对最终的识别准确率造成影响,通常使用人造发光二极管(light emitting diode,LED)光源针对不同待测物体调整颜色、角度和照明方式。镜头是影响成像的另一个重要因素,由于每种镜头的光学能力不同,导致最终图像的畸变程度不同,可根据焦距、畸变、光圈和物距等参数进行选择。而相机负责将输入镜头的光线通过靶面芯片转换为数字信号,不同芯片的选型也会对最终成像造成影响,可根据像元靶面尺寸、分辨率、拍摄帧率等参数进行选择。综上,基于视觉的缺陷检测系统对图像采集硬件的选择和光源布置上尤为重要。

1.3 汽车装配件缺陷检测中的缺陷分割方法

工业相机采集的图像通常分辨率较高,导致缺陷所占比例小,因此需要先把缺陷区域从原始图像中分割出来,再进行后续的图像处理。图像分割指把原始图像划分成不同的区域,同个区域中的灰度、纹理、形状、颜色等特征相似,而与其他区域有明显的差异性。本节主要介绍常用的阈值分割、边缘检测、区域生长等方法。

1) 阈值分割与形态学

阈值法的原理是统计图像的全部灰度值,设置一个或多个合适的阈值范围,并判断图像中所有像素点的灰度值是否在预设阈值内,最终把像素值分为两类,分割后的图像以黑白形式表示,故也称为二值化。例如,文献[11]针对轮毂 X 射线图像中缺陷区域灰度值变异的特点,通过动态阈值分割法获得缺陷区域,再利用形态学重建算法,以二次分割的结果作为标记重构初次分割的图像,准确重构出缺陷形状,改善了由轮毂几何形状带来的漏检和错判问题,但是当灰度值差异不大时,对阈值的

选择较难,无法准确分割区域。文献[12]针对汽车涂膜中存在的模糊缺陷不易分割的问题,提出图像中心化处理和图像去背景操作相结合的分割方法,使用形态学运算将缺陷的过渡带进行填补,有效保留了图像的缺陷细节,但是会引入部分虚假边缘,造成误判。

2) 边缘检测

边缘检测的原理是通过检测不同区域包含的边缘将图像分为多个区域。通常相邻两个区域的边缘处会出现灰度值剧烈变化的现象,利用此特点可寻找到边缘。文献[13]将小波与中值滤波相结合用于图像去噪,最后采用 Sobel 边缘算子,进行汽车管路连接件表面的缺陷特征提取,但是 Sobel 算子对灰度变化不敏感,检测效果较差。文献[14]使用 Canny 算子检测缺陷边缘,再利用数学形态学的方法对边缘准确提取,最后用模糊模式识别算法分类汽车方向盘的铸件缺陷,但是容易把噪点误判为边界,且自适应能力较差。

3) 区域生长

区域生长的原理是先划定不同的生长区域,然后分配不同的种子像素,接着选择某个种子,寻找该种子像素邻域里可以合并的其他像素,并将其作为新种子,最后重复上述寻找过程直到结束。由于较浅的划痕不易被检测到,且提取出目标区域后存在断裂问题,文献[15]提出了一种解决方案,使用基于方向梯度的区域生长算法分割发动机涡轮壳零件图像中的划痕缺陷,可以连接断开的划痕,但由于采用迭代计算的形式,检测效率较低。文献[16]采用基于 8 邻域连通域的区域生长算法查找缺陷的坐标,并提出了边界清除方法,删除与边界相连的所有连通域的坐标,排除边界干扰,快速且准确地识别出汽车水箱钎焊表面典型缺陷,但是对形状差异较大的缺陷识别率较低。

综上,图像分割结果的好坏直接影响着后续特征提取算法的准确率,具体方法对比如表 1 所示。

表 1 常用的缺陷分割方法对比

Table 1 Comparison of commonly used defect segmentation methods

文献	具体方法	应用对象	优点	局限性
[11]	动态阈值分割算法和形态学重建处理	汽车轮毂	改善了由轮毂几何形状带来的漏检和错判问题	抗噪性差,对灰度值变化大的情况不敏感
[12]	图像中心化处理和图像去背景操作相结合,使用形态学填补	汽车涂膜	对模糊边缘检测效果好	输出图像存在“云絮”现象,易引入虚假边缘
[13]	Sobel 算子边缘检测	汽车管路连接件	计算简单,对椒盐斑状噪声和高频噪声效果好	准确率较低,检测出的边缘不是单像素宽度
[14]	Canny 算子边缘检测	汽车方向盘	边缘提取准确率高,运算速度快	易把噪点误判为边缘,自适应能力差
[15]	基于方向梯度的区域生长算法,连接断开的划痕	发动机涡轮壳零件	有效避免了把同一条划痕识别成若干断裂的小划痕	计算量大,耗时长,灰度值分布杂乱时可能会出现空洞区域和过分割
[16]	基于 8 邻域连通域的区域生长算法查找缺陷的坐标	汽车水箱钎焊	可以清除边界干扰	计算量大,耗时长,灰度值分布杂乱时可能会出现空洞区域和过分割

1.4 汽车零配件缺陷检测中的特征提取方法

分割出缺陷区域后,把区域的图像信号构建为数值、符号和向量等数学参数,这一图像处理过程被称为特征提取,而图像特征提取的效果是影响最终分类识别性能和准确率的关键因素。传统的特征提取算法通过分析纹理、颜色和形状等特征,进行缺陷识别,常用方法有局部二值模式(local binary pattern, LBP)、灰度共生矩阵(grey level co-occurrence matrix, GLCM)、傅里叶变换(Fourier transform, FT)、Gabor 小波变换、马尔可夫随机场(Markov random field, MRF)等。

1) LBP 与 GLCM

LBP 和 GLCM 是常见的纹理特征描述符,LBP 因为其显著的旋转不变性和灰度不变性优势被广泛使用,GLCM 矩阵描述了像素在空间上的依赖关系。文献[17]对 GLCM 和 LBP 两种特征进行验证对比,得出 LBP 特征比 GLCM 特征计算效率高的结论,所以目前利用 LBP 进行缺陷识别的研究更多。文献[18]使用 LBP 算子提取灰度均值比难以区分的区域特征,对汽车卡钳表面进行缺陷检测,但是 LBP 存在全局描述能力弱、噪声敏感等缺点。文献[19]融合 HOG 特征和 LBP 特征对轮胎外观进行缺陷识别,多特征融合能提高检测精度,但是运算量增大,检测速度变慢。为此研究人员不断提出 LBP 的变体,如 Tan 等^[20]提出的局部三值模式(local ternary pattern, LTP)、由 Guo 等^[21]提出的完整局部二值模式(complete local binary patterns, CLBP)等,这些方法能有效地抑制噪声,增强鲁棒性。

2) 傅里叶变换与小波变换

对于一些难以通过像素灰度值特性识别的缺陷,可以将时域的信号投射到频域中的不同位置,根据正常区域和缺陷区域的不同频谱分量等数学信息,进行特征提取,实

现缺陷的精准检测。文献[22]使用傅里叶变换把缺陷区域和正常区域频率分开,再使用低频滤波器把缺陷成分提取出来,实现对汽车安全带表面的缺陷检测。然而,在正常区域和缺陷区域的频域混叠度高的情况下,难以提取出完整准确的缺陷分量,容易互相干扰。因此,文献[23]结合离散傅里叶变换(discrete Fourier transform, DFT)和离散小波变换(discrete wavelet transform, DWT)提出了无监督车身漆膜缺陷检测算法。Gabor 小波具有优越的方向选择和尺度选择特性,即使当光源条件的变化极微小时,也能保证高度的准确性,但大多依靠模板匹配的方法,无法检测形状多变复杂的缺陷。结合多种特征提取算法可以有效提高准确率,文献[24]等同时采用 GLCM 和直方图、一维 Gabor 小波统计并提取轮胎的纹理特征,经实验对比验证,多融合方法在检测精度、识别能力等方面均优于单一方法,但是计算效率低,耗时长。

3) MRF

上述几种传统方法在检测形状复杂、背景多样的缺陷时都表现欠佳,而基于模型的方法可以通过学习不断优化内部参数,调整模型结构,从而更好地识别复杂背景下的缺陷。MRF 在 1983 年被 Cross 等^[25]提出,假设图像中某个像素点的值仅受到其邻域内的其他像素点影响,使用邻域内的概率条件分布来描述对应随机过程的局部特征。近年来研究表明,MRF 在工业表面缺陷检测中有很大的应用前景。例如,文献[26]等设计了基于 MRF 的高斯混合模型实现钢轨的缺陷检测,检测精确度达到 92.0%,该项研究表明将 MRF 应用于工业缺陷检测是可行的,也为进一步应用到汽车工业中提供思路。

特征提取是缺陷检测算法的核心,有效区分出缺陷特征和背景特征能大幅提升检测的准确率,具体方法对比如表 2 所示。

表 2 常用的特征提取方法对比
Table 2 Comparison of commonly used feature extraction methods

文献	具体方法	应用对象	优点	局限性
[18]	LBP 算子提取特征	汽车卡钳	运算简单,对灰度值差别大的缺陷效果好	全局描述能力弱,对噪声敏感
[19]	结合 HOG 特征和 LBP 特征	汽车轮胎	多特征结合,对比单特征可提高精度 1.6% 以上	对噪声敏感,计算量大,无法处理遮挡问题
[22]	基于傅里叶变换的频谱分析法	汽车安全带	检测速度快	背景与缺陷的频域特征易混杂,无法有效识别缺陷
[23]	结合 DFT 和 DWT	车身漆膜	不需要参考图像,自动分割缺陷,抗干扰能力好	在频谱中区分,需要先验知识,且对于小缺陷效果检测不佳
[24]	结合 GLCM 和直方图提取纹理特征;Gabor 小波模板匹配法	汽车轮胎	特征构建简单,计算方便	依靠模板匹配,只能检测瑕疵点等简单的缺陷
[26]	基于 MRF 的高斯混合检测模型	钢轨	有效识别复杂背景下的缺陷,更改参数方便	执行效率低,重复计算量较大

1.3 和 1.4 节主要概括了应用于汽车零配件缺陷检测中的常见图像分割和特征提取算法,并对相关文献进行了分析。在几种图像分割方法中,基于阈值和边缘的方法检测速度快但精度较低,基于区域生长的方法执行效率较低,适合缺陷形状有规则的情况;在几种特征提取方法中,LBP 与 GLCM 提取缺陷的空域纹理特征,适用于背景干扰小的情况,傅里叶变换和小波变换提取缺陷的频域和变换域分量,适用于复杂背景,如果把多域特征进行融合识别效果更佳。

1.5 汽车零配件缺陷检测中的卷积神经网络

传统的视觉检测方法对不同的应用场景需要设计不同的视觉检测系统和图像处理算法,深度学习的出现很好地解决了这一问题,通过搭建深度网络模型,输入带有标注信息的原始图像数据集,经过训练后可以实现对其他图像的分类识别。常见的深度学习模型有:层叠自动去噪编码器(stacked denoising auto encoder, SDAE)、深度置信网络(deep belief networks, DBN)、卷积神经网络

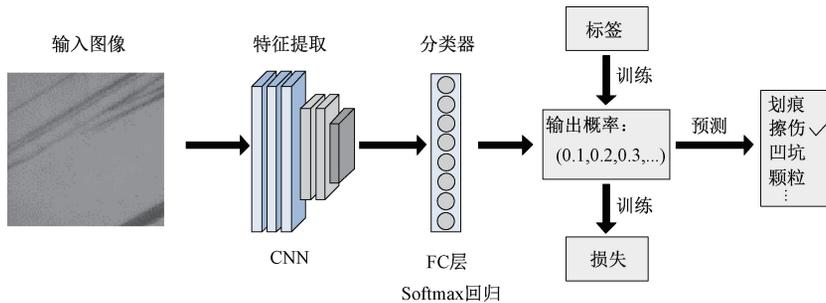


图 2 分类网络流程

Fig. 2 Flow chart of image classification

在基于深度学习的汽车零配件缺陷检测中,由于训练集的图像数量较少,通常会先将网络在已公开的大规模通用数据集上进行迁移训练,然后用预训练权重在目标数据集上继续微调训练,以提高训练精度。文献[32]在基础的卷积神经网络上,加入了残差结构、批标准化和可分离卷积,改进后的模型可实现汽车高度调节器缺陷检测,并与 VGG16 对比,该模型的检测准确度更高,模型参数更少,但是对复杂缺陷的识别能力欠缺。文献[33]搭建了一个 SF-VGG 模型,用于汽车零件的缺陷检测和分类,该模型基于 Inception V3 思路,在原来的 VGG16 中增加了融合层,经实验验证,与 GoogLeNet 模型和 VGG16 模型对比,SF-VGG 模型的平均准确率更高。分类网络随着网络深度加深特征提取能力增强,与此同时也容易出现梯度爆炸和过拟合现象,且只能获得图像的分类标签,无法定位到具体缺陷的位置,而在实际的车间生产中往往需要找到确切的缺陷位置以移除或修补。

(convolutional neural networks, CNN)、生成对抗网络(generative adversarial network, GAN)等。近年来,研究人员尝试将 CNN 应用于表面缺陷检测,可分为 3 类:图像分类、目标检测和图像分割,本节主要按照这 3 类进行总结。

1) 分类网络

分类网络的实现步骤主要是:输入图像、特征提取和回归分类,该类方法可以获得待检图像的分类标签,识别出图像是否具有缺陷并且识别具体的缺陷类型,如图 2 所示。2012 年, Krizhevsky 等^[27]提出的 AlexNet 在 ImageNet 竞赛上获得冠军,这使得图像识别领域有了新的突破,研究者在深度神经网络上看到了更多可能性。随着对神经网络结构研究的加深,一些新兴的分类网络模型也被相继提出,如 VGG^[28]、GoogLeNet^[29]、Inception V3、ResNet、Inception-ResNet^[30]、DenseNet^[31]等,提高了图像分类的准确率,这些经典分类网络也逐步被应用于汽车零配件的缺陷图像分类。

2) 检测网络

目标检测网络的实现步骤主要是:设置初始化(锚点框,角点等)、生成候选框、特征提取、特征融合、分类与回归(标签匹配,损失计算等),该类方法不仅具有分类网络的功能,还可以在识别缺陷类型的基础上通过外接矩形框确定缺陷的位置和大小。目标检测网络的常用分类为双阶段(two-stage)网络和单阶段(one-stage)网络,由有无候选框生成决定,这些网络常用于汽车零配件的缺陷检测。

双阶段检测网络的典型代表是 RCNN^[34]、Fast-RCNN^[35]、Faster-RCNN^[36]等。Faster R-CNN 网络使用 RPN 网络,将特征提取、区域提议、分类、边界框回归过程进行整合,进一步提高了目标检测精度,目前被较多地用于汽车轮毂缺陷检测。文献[37]使用 Faster-RCNN 与 ResNet101 作为物体检测算法,该模型能检测出轮毂任何部位的各种类型的缺陷,并获得缺陷区域的分类标签和矩形框,克服了复杂背景下轮毂缺陷难以检测的问

题。双阶段检测网络由于先给出基本的预选目标框再进行回归计算,具有精度高,速度慢的特点。

单阶段检测网络达到了更高的实时性,典型代表是 YOLO^[38]、SSD^[39] 和 CornerNet^[40] 等。2015 年 Redmon 等^[38] 提出了 YOLOv1,由于平衡了检测速度和检测精度的代价牺牲关系,YOLO 系列被广泛用于缺陷检测方面。文献[41]将具有不同曝光时间和不同照明方向的多组轮毂图像融合,使用 YOLOv5 检测汽车轮毂表面的缺陷,但是对光照条件要求高,且存在大量漏检情况。文献[42]使用改进的 YOLOv3-MC 模型对轮毂焊缝进行缺陷检测,使用完备交并比的计算方法提高算法的定位精度,但存在对小目标检测性能较差的问题。

2016 年,Liu 等^[39] 提出了 SSD 算法,采用 VGG16 作为基础模型,加入了多尺度特征映射,沿用 Faster R-CNN 中的 anchor 机制,直接生成一系列 default box,该方法既保留了 YOLO 的检测速度,也与 Faster R-CNN 的检测准确率相当,逐渐被用于汽车缺陷检测。文献[43]使用增强的 SSD 网络进行汽车后视镜非平面上的微小缺陷检测,在 SSD 深层中用 atrous 卷积代替最大池化操作,再通过融合块将浅层与深层连接起来,以提高小目标的缺陷检测能力,但是模型参数大,检测速度降低。此外,为了达到实际生产中的高召回率要求,文献[44]针对轮胎的 X 射线图像设计了一个自动检测模型 TireNet,使用 Siamese 网络作为下游分类器的一部分,并通过实验与 Fast R-CNN、SSD 和 YOLO 作对比,该方法具有更高的召回率,减少轮胎退换率约 20%。单阶段检测网络直接给出回归后的目标框,显示缺陷的大小和位置,具有检测速度快的特点,但是检测精度略低。

3) 分割网络

图像分割网络的实现步骤主要是输入图像、特征提取、金字塔池化、上采样和像素级分类,该类方法逐像素判断是否属于缺陷区域,可获得缺陷的精确形状、大小尺寸等信息。图像分割方法又分为语义分割与实例分割。

语义分割架构通常由编码器加解码器组成。编码器一般为经过预训练后的分类网络,解码器则将编码器分类后的特征语义属性转换到对应的像素位置上,即可让每个种类在图像中显示出各自的像素标签。2015 年 Long 等^[45] 提出了图像分割开山之作全卷积神经网络 (fully convolutional networks, FCN) 网络,采用反卷积层替代 CNN 中的最后一个全连接层,并且其输入图像的尺寸不受限制。文献[46]使用 FCN 网络进行轮毂缺陷分割,实现了对缺陷的目标检测和语义分割,还从分割结果中剔除了误检缺陷,从而根据分割出的像素点数量计算缺陷面积和长度等定级参数,但 FCN 训练较复杂,且作为最简单的分割网络精度不高。U-Net 网络将编码器的特征图拼接至每个阶段解码器的上采样特征图,这样使得

解码器能够学习在编码器池化中丢失的相关特征。文献[47]使用 U-Net 对轮毂缺陷进行检测与分割,针对复杂缺陷识别效果更好,但是网络运行效率很慢,对于每个邻域,网络都要运行一次,且对于邻域重叠部分,网络会进行重复运算。

在一般的深度学习神经网络中,通常会使用池化操作进行降采样,增大特征图感受野,但是通过上采样换算为原图时,难免会丢失一部分信息,为了改善这种情况,引入了空洞卷积^[48] (dilated/atrous convolution),在此基础上,Google 提出了 DeepLab 系列网络^[49],如 DeepLab v1&v2&v3&v3+,文献[50]将 DeepLab v3+模型用于汽车轮毂的缺陷检测,目前,基于空洞卷积的 DeepLab 系列在工业缺陷检测中表现极佳,但由于空洞卷积的计算方式与棋盘格类似,会造成某些像素信息不参与计算,导致提取的特征部分缺失,远距离的信息相关性差的问题。

实例分割的经典网络 Mask R-CNN 于 2017 年由 He 等^[51] 提出,它基于 Faster R-CNN 模型实现,在预测时加入 Mask 掩模分支,并且提出用 ROI Align 替换 ROI Pooling,使得提取的特征与输入良好对齐。文献[52]将 Mask R-CNN 应用于轮毂缺陷图像的识别,不仅可以分割不同种类的缺陷区域,同种类的不同个缺陷也可以分割,识别准确率高,但是检测加上分割的整体耗时较长。

1.5 节主要从分类、检测、分割 3 个角度分析了汽车缺陷检测中的深度卷积网络,具体对比如表 3 所示,由于文献中均采用自建数据集,因此性能指标一栏只能评价该模型的效果好坏,无法纵向对比;另外,比较了视觉缺陷检测中的传统图像处理方法和基于深度学习的方法,前者的检测精度和鲁棒性都有待提高,后者虽然识别准确率更高但需要依靠大量的训练数据,训练和推理时间更长,具体对比如表 4 所示。

2 主要汽车装配件的缺陷检测研究现状

本节选取了几个代表性装配件作详细介绍,目前针对汽车装配件的缺陷检测及分类识别研究主要集中在轮胎、车身、零件和发动机,主要方法有基于传统图像处理的视觉检测方法和基于深度学习的视觉检测方法。

2.1 轮胎及轮毂缺陷检测

轮胎由外胎、轮辋、轮毂等组成,其作为汽车装配件中不可或缺的一部分,直接决定了车辆的可靠性和平稳性,而轮毂对车辆的支撑和转向起到了关键作用,其质量好坏影响着驾驶人员的生命安全,因此对汽车轮胎及轮毂的缺陷检测至关重要。

1) 轮毂缺陷检测的研究现状

由于铸造时材料浇筑不均匀和气动打磨不足的问题,有时会产生轮毂表面的缺陷,目前对轮毂的缺陷分类

表 3 常用的卷积神经网络对比
Table 3 Comparison of commonly used convolutional neural networks

文献	具体方法	应用对象	优点	局限性	性能指标
[32]	加入残差网络结构和可分离卷积	汽车高度调节器	在深层网络提高精度的同时减少了参数计算量	分类网络,输出类别标签,无法定位缺陷	mAP: 99.46% 误检率: 0.6%
[33]	SF-VGG 模型	车辆零件	减少模型的计算量,可获得多尺度信息	分类网络,输出类别标签,无法定位缺陷	mAP: 98.36% 模糊数据准确率: 95.75%
[37]	使用 Faster-RCNN,选择 ResNet101 作为特征提取器	汽车轮毂	在复杂背景下,可检测到各种类型的轮毂任意部位的缺陷	双阶段检测网络,检测速度慢	mAP: 86.3% 召回率: 90%
[41]	基于 YOLOv5	汽车轮毂	对于小目标检测性能增强,检测速度快	对光照条件要求高,存在漏检	-
[42]	改进 YOLOv3-MC 模型	轮毂焊缝	使用完备交并比提高了定位精度	对小目标的检测能力较弱	mAP: 98.94% AvgIoU: 80.92%
[43]	基于 SSD 网络,加入多尺度特征模块	汽车后视镜	检测精度提升,对浅层特征提取能力增强	模型训练复杂,牺牲了检测速度	mAP: 76.5%
[44]	提出了 TireNet,使用 Siamese 网络作为下游分类器的一部分	汽车轮胎	达到可应用级的高召回率	对气泡等特定缺陷的召回率仍有待提高	加权召回率: 94.0%
[46]	使用 FCN 和 Faster R-CNN 实现对缺陷的目标定位和分割	轮毂	降低了轮毂缺陷检测中的漏检率和过检率	对图像细节不敏感,分割精度有待提高	漏检率: 2.94% 过检率: 2.22%
[47]	使用 U-Net 和模拟的人脑层次感知系统分割	轮毂	不易丢失细节特征,对复杂缺陷分割效果好	网络运行效率慢,重复计算量大	平均 Dice 系数: 0.9264
[50]	使用 DeepLab v3+模型	轮毂	图像分割效果好,可以对检测出的缺陷进行定量分析	使用空洞卷积,导致部分信息缺失,且计算复杂度更高	IoU: 60.3%
[52]	使用 Mask R-CNN 模型	轮毂	准确分割出缺陷的形状,方便后续的缺陷性质计算	网络参数量大,检测与分割并行速度慢	AvgIoU: 85.33%

表 4 传统图像处理方法与深度学习方法对比
Table 4 Comparison of traditional image processing methods and deep learning methods

方法	特征提取过程	分类器	优点	缺点
传统图像处理	人工设计特征并提取	基于传统机器学习的分类方法,如贝叶斯、支持向量机、决策树等	检测过程可解释性较强、检测速度较快	准确性相对较低、泛化能力和抗干扰能力差
深度学习	通过网络的卷积层自动提取特征	神经网络直接分类,使用 softmax 分类器	准确性高、泛化能力和鲁棒性强	需要大量的样本和训练时间、可解释性较差、检测速度较慢

可大致分为以下 3 类:凹坑类(凹坑、小孔眼)、线条类(裂缝、冷夹、裂纹和毛刺)和偏差类(齿套偏缺陷和磕碰缺陷),如图 3 所示^[53]。

由于传统无损检测技术有的造成环境污染,有的检

测步骤繁琐,因此,如何提高轮毂表面缺陷的检测效率和精确度值得研究。部分学者^[54-56]使用改进的 Faster-RCNN 算法对轮毂的划痕缺陷和点缺陷进行了检测,但检测精度仍有可提升空间。文献[57]提出了一种基于

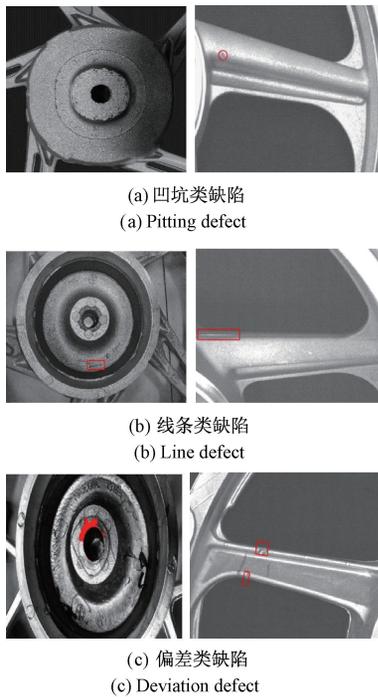
图3 轮毂缺陷示例^[53]

Fig. 3 Example of hub defect

DS-Cascade RCNN 的轮毂缺陷检测方法,增加了空间注意力机制和可变形卷积,实验表明该方法可有效检测6种轮毂缺陷,但是3个级联探测器使得模型参数量庞大。轮芯位于轮毂的中心,起着承重、抗压的重要作用,轮芯X射线图像的背景和缺陷样式比轮毂的其他部分更复杂,导致更难以识别,文献[58]使用改进的CNN进行轮芯缺陷检测,并基于骨架生长技术研究了缺陷样本自动生成的方法,解决了数据集样本不足的问题,但检测精度还有待提高。

另外,基于模糊模式的分类识别方法也在轮毂缺陷检测上得到应用,如文献[59]通过模糊模式分类对4种典型的轮毂缺陷进行分类识别,文献[60]通过山峰定位和数学形态学方法提取缺陷区域,并基于递进的模糊模式分类法来识别轮毂缺陷,但是模糊图像的相关数据集较少,需要进行大量的图像预处理工作。

尽管基于深度学习的方法已经取得了一些进展,但现有的监督学习策略依赖于大量的标记数据,此外,模型局限于识别训练时见过的类别。而针对轮毂缺陷图像特征不明显和数据集少的问题,研究者们也从不同角度提出了解决方案,如文献[61]通过形态学处理将原图像的缺陷特征增强,并使用双边滤波技术去除轮毂字符信息,以减少灰度图中的噪声干扰,但是需要合适的阈值选择,易把正常的图像信息也滤除。零样本学习也被应用到轮毂缺陷检测中,与传统的训练模式不同,零样本学习中引

入了语义空间用以存储样本的语义描述向量,通过建立特征空间与语义空间之间的映射,可识别出未知的类型,文献[62]构建了轮毂缺陷图像识别的广义零镜头学习框架,把6种轮毂缺陷的特征映射到语义空间中,包含16个属性,通过训练模型可识别出另外3种未知缺陷,由于训练样本数较少,准确率较低。

2) 轮胎缺陷检测的研究现状

基于视觉的轮胎缺陷检测主要步骤为X射线成像系统,缺陷检测,缺陷分类。文献[63]先通过线激光扫描获得轮胎图像,用灰色质心法提取激光条纹的中心以定位气泡型缺陷,但该方法对光照条件严格。文献[64]提出了HLU²-Net,该模型基于U-Net,使用混合损失函数和协调注意力模量,提高了检测精度,但是U-Net在更复杂的图像数据集上训练能力不足。

为了解决轮胎缺陷分类和随后的缺陷产品处理仍然需要人工观察的问题,文献[65]提出了一种基于监督特征嵌入深度学习的轮胎缺陷分类方法,使所有缺陷类别的整体分类准确率均达到96.51%,但是没有对原始图像进行预处理,噪声较多。随着图像分割技术的发展,逐像素检测缺陷能更精确的得到缺陷的定量特性,如面积、大小等,为此,文献[66]提出一种简洁的优化语义分割网络Concise-SSN,对轮胎缺陷进行像素级的检测和分类,mIoU得分为77.34%,平均准确率为96.5%,但是模型训练复杂,计算速度慢。文献[67]提出了一种新型的深度卷积稀疏编码网络(deep convolutional sparse coding network,DCScNet)用于轮胎缺陷分类,在DCScNet中,利用稀疏编码代替CNN的卷积核进行特征提取,与CNN相比,它依赖于无监督训练,降低了人为定义标签的主观性,分类准确率达到96.8%。

然而,在实际的检测任务中,收集的各种轮胎缺陷数据集往往是不平衡的。针对这一问题,文献[68]提出了一种Wasserstein生成对抗网络(wasserstein generative adversarial nets,WGAN)辅助图像分类方法用于轮胎X射线缺陷检测,实验验证了该方法对不平衡轮胎X射线缺陷检测的类型和等级分类是有效的,但还需要提高生成的虚拟缺陷的真实性。文献[69]基于生成对抗网络,设计了一个FMD-GAN图像重构模型,不仅可以增加缺陷数据集的图像数量,还可以有效识别无缺陷的图像,减少了对于无缺陷情况的误判。

2.2 车体外观缺陷检测

汽车的外观决定了消费者对这台汽车的第一印象,良好坚固的外观也能为驾驶员的行车过程提供安全保障。在汽车车体外观的制造过程中,可分为冲压、焊接和涂装3个工艺,形成不同的部件。

1) 汽车冲压中的缺陷检测

冲压是通过压力机和模具对板材等施加外力,从而

形成不同车型的工艺。而车身外板的冲压模具在开发过程中容易产生表面缺陷,例如凹痕、凸起、变形、褶皱、凹陷痕迹等,需要进行缺陷检测。

传统的检测方式通过目视检查,可以检测到较大的表面缺陷,但很难找到深度小于 $20\ \mu\text{m}$ 的微小表面缺陷。对于已绘制的面板,可以使用反射线方法,例如文献[70]将亮暗线性条纹投射到车身表面,这些条纹在缺陷附近变形,从而帮助操作员识别异常车身上的缺陷,文献[71]使用光流算法和偏转测量原理,检测镜面车表面的凹痕缺陷,但这种方法不适用于未绘制的面板。另外,还可以通过操作人员的触觉进行缺陷检测。但是上述两种方法都取决于人工的主观判断和专家经验,并不能做到完全的检测成功,且人工成本巨大,不利于大批量生产的情况。

随着机器视觉技术的发展,对车身面板外观的缺陷检测也有了更好的方法,如文献[72]使用了基于 VAR 对比度图像构建和 Sobel 边缘检测联合映射的自适应缺陷检测算法,对汽车的外观缺陷进行检测,但是基于传统特征的方法效率不高。文献[73]提出了一个全卷积神经网络框架 DeepInspection,用于镜面缺陷自动检测,如果用于测试的车身颜色未出现在训练集中,所提出的模型的缺陷分割性能可能会降低。为了检测车身接缝、样式线、棱角等复杂局部缺陷,文献[74]提出了一种基于局部定向模糊法的图像融合预处理和图像背景提取方法,但前提是要有良好的光照。对于大图像中边缘模糊、对比度低的微小缺陷等问题,文献[75]完成了光滑车身表面微小缺陷的自动检测,并提出了一种深度集成学习算法 TinyDefectNet,但是涉及硬件性能要求高,部署步骤复杂。

比较常见的还有三维图像处理方法,如文献[76]提出了一种基于三维图像的曲面变形自动检测方法。文献[77]从三维曲率图中查找缺陷区域,针对车身外板和车门把手周围的细微凹痕和凸起,能精准识别出缺陷区域。文献[78]使用三维扫描仪扫描并获得车身面板的三维图像,然后基于深度神经网络的方法识别凹凸不平的表面缺陷,三维图像包含待检目标的更多信息,但是在精确重构三维图像和数据处理方法上还有很多进步空间。

2) 汽车焊接中的缺陷检测

冲压阶段完成后,需要使用焊接工艺连接不同板块,最终形成完整的车体。由于激光焊接具有速度快、刚性强、普适性好等优点,逐渐成为车身焊接中的首选方法,一些学者也开始研究激光焊接的缺陷检测,部分激光焊接缺陷如图 4 所示^[79]。

文献[80]使用热成像无损技术对焊接缺陷进行检测,该方法对硬件设备依赖高,且只能检测裂纹等具有明显差异的缺陷。文献[81]使用滤波、自适应阈值、Canny



图 4 焊点缺陷示例^[79]

Fig. 4 Examples of solder joint defects

边缘检测等传统的数字图像处理技术对白车身的熔池焊接缺陷进行提取与识别,但是效率和精度较低,且处理复杂。文献[82]基于模型的方法,采用 WCSR 模型和 Fast-EM 算法对焊接表面轮廓进行动态拟合,得到了 DIC 模型,然后通过对 DIC 模型残差的多阈值分析,识别出轮廓的缺陷,该方法可实现全自动检测,能满足工厂的实时在线检测要求,但依赖于一定的模型先验知识。文献[79]针对汽车白车身焊接过程中的电阻电焊缺陷,设计了用于焊点外观识别的卷积神经网络 AcnNet,证明了深度卷积神经网络比传统机器学习在焊接缺陷检测上的优越性,但是通过提取单一的图像信息并不能达到很高的精度。因此,由于不同的焊接缺陷会表现出不同的物理信息,文献[83]提出一种基于混合注意力机制的三重伪暹罗网络,分别提取焊池图像、声音、电流和电压的有效特征,利用多模态信息融合 CNN 提高识别性能。

3) 汽车涂装中的缺陷检测

汽车涂装是车体外观生产中的最后工艺,好的漆膜表面可以增强汽车的外观精美性和车身防腐性。目前大多研究都集中于清漆和色漆面,可以根据漆面缺陷产生的原因把所有缺陷大致分为 10 类:

(1) 灰粒、纤维等异物附着;(2) 缩孔类缺陷;(3) 流挂类缺陷;(4) 针孔;(5) 气泡;(6) 沾污、斑点类缺陷;(7) 颜色缺陷,如发花、遮盖不良等;(8) 外观缺陷,如橘皮、失光等;(9) 打磨不良类缺陷,如打磨印等;(10) 划伤、磕碰伤等。部分缺陷示例如图 5 所示。

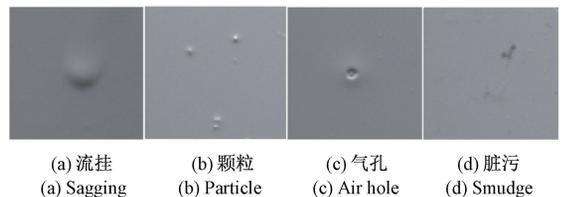


图 5 车漆缺陷示例^[12]

Fig. 5 Examples of car paint defects

使用局部方差 (variance, VAR) 算子的旋转不变性来定位缺陷区域是常用方法,如文献[84]开发了一种视觉检测系统,通过计算像素的 VAR 来定位缺陷,用于检

测和分类汽车工业中车身上的油漆缺陷。文献[85]结合LBP和VAR算子提取漆膜缺陷特征,选择贝叶斯分类器,但是分类速度较慢,文献[86]对上述定位算法进行优化,使用一对多支持向量机(one-vs-rest support vector machine, OAA-SVM)分类器代替贝叶斯分类器,提高了检测系统的实时性。另外,由于漆面的独特镜面反射效果,线光源会在有缺陷的地方,产生强烈的扭曲,易于识别,因此文献[87]设计了一种基于相位测量偏折算法的漆面缺陷检测系统,有利于识别微小缺陷,但在形变比较明显的棱线/筋线等区域条纹光大量堆积会造成识别困难。针对传统图像处理算法准确度低的弊端,文献[88]利用进化算法思想,在蚁群算法和粒子群算法的基础上,结合了车漆图像的传统特征特点,但此方法搜索速度慢,且效果好坏取决于初始种群的选择。在深度学习算法方面,文献[89]使用了基于CNN的涂层缺陷分类方法,并比较了5种卷积神经网络,其中Resnet50的检测效果最好,准确率为95.0%。文献[90]首先针对小样本数据引起的过拟合现象,提出了一种数据增强算法,然后在MobileNet-SSD网络的基础上,修改特征层,改进边界框匹配策略,实现了对6种车身漆膜缺陷的检测,但仍然难以实现实时检测效果。

按照视觉系统的装置进行分类,可分为隧道式检测和机器人式检测,如图6所示。

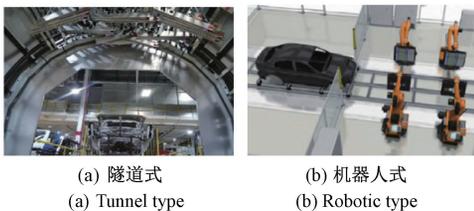


图 6 车漆自动检测装置^[87]

Fig. 6 Auto paint detection device

隧道式检测系统在车身周围的钢制框架上部署光源和CCD相机,例如文献[91]等设计了1个自动检测系统(automated identification system, AIS),使用5个CCD摄像头收集汽车5个侧面的图像。此结构优点是安装便利,图像采集速度快。缺点是通用性差,外观差异大的不同车型需要重新部署。机器人式检测系统在车身两侧作业的机械臂末端部署光源和CCD相机,例如文献[92]通过机械臂带动视觉系统采集完整引擎盖漆面表面图像。此结构优点是几乎没有拍摄死角,通用性高,不同车型可使用同套设备。缺点是结构复杂,图像采集速度慢。

2.3 汽车零件缺陷检测

据估计,一辆普通汽车约含 2×10^4 个零件,常见的零件缺陷有磕伤、裂纹、划痕、表面污染、点状缺陷、擦伤和凸坑等,部分示例如图7所示。

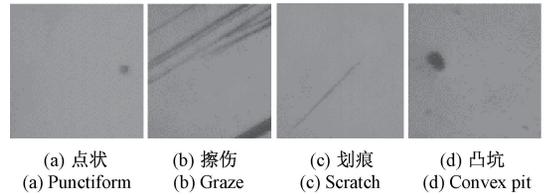


图 7 汽车零件缺陷示例^[93]

Fig. 7 Examples of defects in automotive parts

在汽车零件缺陷检测中,基于图像处理的检测方法被广泛应用,如文献[94]提出了基于平滑带通滤波器的车身零件划痕检测算法,文献[95]采用中值滤波等传统图像处理方法,但是传统图像处理方法大多利用图像的表层信息,无法应对复杂背景下的检测。文献[96]基于汽车伞齿轮表面的纹理特征,使用一种邻域均差缺陷提取算法,但是对对比度较差的表面缺陷检测效果不太理想。随着深度学习的发展,为了进一步提高检测精度,文献[97]提出使用特征金字塔网络(feature pyramid networks, FPN)对铸铝零件的X射线图像进行缺陷检测,经验证,检测精度比Faster R-CNN高约12%,但是实时性较差。另外,为了解决缺陷样本数量不足的问题,文献[98]提出了一种数据增强方法,利用深度卷积生成对抗网络(deep convolutional generative adversarial networks, DCGAN)生成虚拟缺陷样本,用于汽车转向节零件荧光穿透检测图像中的裂纹识别。文献[99]引入小样本训练的思想,采用指导框结构和聚焦式损失函数改进生成建议框固定宽高比及正负样本不均衡的问题,最后通过组合特征关系检测器寻找同一个类之间的相似性,有利于提高在样本不足情况下的缺陷检测精度。

2.4 发动机及配件缺陷检测

发动机是汽车的动力核心部件,对汽车的驾驶性能和安全性起着至关重要的作用,对发动机的缺陷检测是很有必要的。

目前已有许多学者对发动机的缺陷检测进行了研究,文献[100]基于Hough变换,提出了一种快速检测圆算法,进行汽车发动机缸孔内表面缺陷自动测量技术的研究,不过此方法耗时长,且精度较低。文献[101]使用Sobel边缘检测算法来确定连杆缺陷的图形边界,开发了汽车发动机连杆表面缺陷检测系统,并集成到嵌入式系统中,但是Sobel算子对灰度变化不敏感,复杂情况下不适用。文献[102]使用自建的发动机缸体和缸盖缺陷数据集,验证了改进后的Faster R-CNN算法的有效性,但模型参数过大。而对于Mask R-CNN用于小缺陷检测时精度不足的缺点,文献[103]设计了IA-Mask R-CNN,改进了锚标设计,在汽车发动机零件表面图像上进行实验,提高了小缺陷的检测准确率。

本节综述了轮毂轮胎、车体外观、零件、发动机等主要装配件缺陷检测现状,根据不同部件的特性分析了相关的检测方法,目前多采用基于深度学习的检测网络,也有不少研究者陆续提出了使用生成对抗网络,少样本或零样本学习来减轻对大数据集的依赖,但还有很多可改进的地方。

3 数据集及评估指标

3.1 数据集

汽车装配件的缺陷图像采集周期长,采集质量不佳,所以公开的相关装配件数据集并不多。研究者们通常进行自建数据集的采集和标注,或是由合作的汽车公司提

供生产过程中拍摄的装配件图像,因此目前没有在同一个特定数据集上进行装配件缺陷检测的定量评价结果。表 5 列出了 10 个与汽车工业有关的数据集,包含铸件、零件、漆面、焊缝、钢材、铝材和金属表面等,以供参考。

3.2 评估指标

1) 图像分类

以二分类为例,首先介绍几个分类评估指标的符号定义,用 0,1 表示二分类的两个状态,0 为负样本,1 为正样本,真阳性(true positive, TP)表示将正样本预测为正样本的数量,假阴性(false negative, FN)表示将负样本预测为负样本的数量,假阳性(false positive, FP)表示将负样本预测成正样本的数量,真阴性(true negative, TN)表示将正样本预测成负样本的数量,如表 6 所示。

表 5 汽车工业相关数据集
Table 5 Automobile industry related datasets

数据集	检测对象	来源	缺陷类别	性质	获取地址
GDXray+	轻合金铸件(铝轮,转向器),焊缝	2015 年发布于 GitHub	-	47 520 张,部分有矩形框标签,用于分类和目标检测	http://dmery.ing.puc.cl/index.php/material/
Car-Brake	汽车制动支架铸件	2020 年发布于论文自建数据集	6 类(黑洞、浅坑、裂纹、切口、凸起、凹坑)	9 600 张,无矩形框标签,用于分类	https://ieeexplore.ieee.org/document/9311501 ^[104]
HWSZ-Data	汽车零件	2021 年发布于华为云竞赛	轴承缺陷 4 种,火花塞缺陷 3 种,摇把 3 种	-	https://competition.huaweicloud.com/information/1000041490/circumstance?track=107
Paint-Data	车身漆面	2020 年发布于论文自建数据集	6 类(鼓包,缩孔,脏颗粒,划痕,漆渣,漆板)	500 张,有矩形框标签,用于分类和目标检测	https://link.springer.com/article/10.1007/s11042-020-09152-6 ^[90]
WDXI	焊缝	2018 年发布于论文自建数据集	7 类(夹渣,气体毛孔,裂缝,未焊透,未熔合,圆形缺陷,条纹缺陷)	16 950 张,有矩形框标签,用于分类和目标检测	https://ieeexplore.ieee.org/document/8686975 ^[105]
NEU-DET	带钢表面	发布于东北大学	6 类(轧制氧化皮,斑块,开裂,点蚀表面,内含物,划痕)	1 800 张,每类 300 张,有矩形框标签,用于分类和目标检测	http://faculty.neu.edu.cn/songkechen/zh_CN/zdylm/263270/list/ ^[106]
UCI	带钢表面	发布于美国加州大学欧文分校	7 类(装饰、Z_划痕、K_划痕、污渍、肮脏、颠簸、其他故障)	1 941 张,27 个特征属性,无矩形框标签,用于分类	https://archive.ics.uci.edu/ml/datasets/Steel+Plates+Faults
Severstal	钢板表面	2019 年发布于 Kaggle 竞赛	3 类(斑块,划痕,裂缝)	12 568 张,有分割标签,用于分类和语义分割	https://www.kaggle.com/competitions/severstal-steel-defect-detection/data
APDDD	铝材表面	2018 年发布于天池竞赛	10 类(不导电,擦花,角位漏底,桔皮,漏底,喷流,漆泡,起坑,杂色,脏点)	5 000 张,有矩形框标签,用于分类和目标检测	https://tianchi.aliyun.com/dataset/148297
BSData	金属工件	2020 年发布于 GitHub	点蚀	1 104 张,无矩形框标签,用于分类	https://github.com/20be/BSData

表6 二分类评估符号

Table 6 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

常用的评价指标有精确率 (precision)、召回率 (recall)、准确率 (accuracy)、错误率 (error rate) 和 $F1$ 函数等,具体定义如表7所示。

2) 目标检测

大多评价指标与分类问题相同,此外,目标检测的特殊评价指标有交并比 IOU ,即输出图像的目标矩形框

表7 图像分类的评估指标

Table 7 Evaluation index of image classification

指标	含义	公式
准确率 (Acc)	预测正确的所有数据占总数据的比例	$Acc = \frac{TP + TN}{TP + FP + FN + TN}$
精确率 ($Precision$)	预测正确的正例数据占预测为正例数据的比例	$Precision = \frac{TP}{TP + FP}$
召回率 ($Recall$)	预测正确的正例数据占实际为正例数据的比例	$Recall = \frac{TP}{TP + FN}$
$F1$ 值	模型精确率和召回率的调和平均 ($0 < F1 < 1$), 值越大越好	$F1 = 2 \frac{precision \times recall}{precision + recall}$
误报率 (FPR)	误检测为负样本的数量比例	$FPR = \frac{FP}{FP + TN}$
漏检率 (FNR)	误检测为正样本的数量比例	$FNR = \frac{FN}{FN + TP}$
平均准确率 (AP)	每个类别不同召回率点上的准确率的均值	$AP = \sum_{i=1}^{n-1} (r_{i+1} - r_i) P_{inter}(r_i + 1)$
平均精度均值 (mAP)	多个类别的 AP 值的均值 ($0 < mAP < 1$), 值越大越好	$mAP = \frac{\sum_{i=1}^k AP_i}{k}$
马修斯相关系数 (MCC)	同时考虑了真假阳性和阴性,适用于样本不平衡的情况	$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$
帧率 (FPS)	每秒计算机可以处理的帧数	-

与数据集标注的目标矩形框的交集与并集的比值,公式如下:

$$IoU = \frac{A \cap B}{A \cup B} \quad (1)$$

IoU 的值越大,说明预测结果框与初始标注框越接近,值小说明预测效果越差,根据不同的检测任务,可以调节不同的 IoU 阈值,例如当 IoU 阈值为 0.6 时,大于此阈值的预测框被识别成 TP ,小于等于此阈值的预测框被识别成 FP 。

3) 图像分割

除了 IoU ,还有一些常用的评价指标,如表8所示。

4 面临的技术挑战及展望

基于视觉的缺陷检测技术已经在汽车的装配件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

表8 图像分割的评估指标

Table 8 Evaluation index of image segmentation

名称	含义	公式
像素准确率	预测类别正确的像素数占总像素数的比例	$PA = \frac{\sum_{i=0}^k P_{ii}}{\sum_{i=0}^k \sum_{j=0}^k P_{ij}}$
平均像素准确率	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 系数	计算预测样本与标准样本的相似度	$Dice = \frac{\frac{2}{k+1} \sum_{i=1}^{k+1} P_i \times \frac{1}{k+1} \sum_{i=1}^{k+1} R_i}{\frac{1}{k+1} \sum_{i=1}^{k+1} P_i + \frac{1}{k+1} \sum_{i=1}^{k+1} R_i}$
豪斯多夫距离	两组点集之间相似程度的一种量度	$H(A, B) = \max(h(A, B), h(B, A))$ $h(A, B) = \max_{a \in A} \{ \min_{b \in B} \ a - b \ \}$

精度和检测效率也逐渐提高,但仍然存在诸多技术难点,本节将总结相关的技术挑战及其对应的技术展望。

4.1 技术挑战

1) 数据集匮乏与类别不平衡挑战

深度学习离不开海量数据的支撑,其本质在于训练计算机自动学习图像中的有用信息,而在实际的生产中正常样本数量较多,有缺陷的样本或者某些特定的缺陷类型非常稀少,导致收集到的数据集也依然存在少样本和类别不平衡的问题。

2) 小目标部件的缺陷检测挑战

对于小目标部件如精密零件等的研究还较少,且小目标部件的微小缺陷区域相比汽车的其他部件尺度更小、分辨率更低,导致样本特征不明显,难以检测。使用高分辨率相机可以提供更细微的缺陷细节,但高性能的CCD感光设备,其硬件性能与硬件价格成正比,后续的清洁与维护工作也需要人力成本。现有的算法如YOLO、Faster R-CNN等一直存在小目标检测的技术瓶颈,如何解决此类问题值得我们探究。

3) 实时性挑战

实时性是体现在线缺陷检测系统检测效率的重要指标,而在使用深度学习方法时模型计算推理时间较长,随着网络深度加深,模型的参数量和计算时间复杂度都会增加。尤其是检测小目标对象时,为了保留更多图片信息,往往会使用高分辨率设备采集图像,导致输入数据量过大,虽然能提高检测精度,但大大牺牲了时间成本。

4) 复杂背景挑战

复杂背景下的缺陷检测是一直以来的难点问题,在复杂的生产背景下,光照条件、设备成像条件有限,样本采集较难,高质量的样本图片较少,并且由于背景复杂,当缺陷区域与背景灰度级相似时,更容易产生错误,因此,如何成功提取有用的特征亟待解决。

5) 模型泛化能力不足挑战

无论是传统视觉检测方法还是深度学习检测方法,都存在泛化能力不足的问题,即通用性较差,使用传统视觉检测时,需要根据不同的检测目标部署不同的检测设备,在不同检测任务时需要设计不同的特征提取方式和处理算法,使用深度学习方法时,需要导入不同的数据集重新训练,且对未在数据集里的缺陷识别能力低。

4.2 技术展望

虽然基于视觉的汽车装配件缺陷检测在国内外得到了多年的研究,取得了一系列研究成果,但是考虑到汽车工业图像的复杂性,及汽车工业现场对于实时性和准确率的高要求,汽车装配件的缺陷检测技术还需要进一步改进。针对4.1节中提到的5个技术挑战,可以从如下

6个方面进行技术展望:

1) 扩大样本数据集,减缓数据依赖

针对汽车工业领域通常没有足够的标记样本的情况,可以使用数据增强技术或者生成对抗网络GAN生成模拟的样本图像,以扩大训练集,但由于汽车装配件繁多且工件结构复杂,如何更好地使用GAN生成大量准确逼真的样本数据还有待思考。另一种解决思路则是通过迁移学习,先让模型在一些公共大数据集上训练权重,如COCO、ImageNet等,再根据特定的任务在目标数据集上进行针对性的微调训练,或者采用改进的零样本学习模型对汽车装配件样本进行识别,从而减少需要的训练集数量,也能利用现有网络在不同识别任务上的兼容性。

2) 多尺度检测,改善小目标难点

针对小目标难以检测的问题,通过设置更适合的原始anchor和切片图片等预处理可以提高模型的输入分辨率。链接不同层级的特征图来引入多尺度的上下文信息,扩大感受野也是有效的方法。另外,增加注意力机制可以关注更小的细节,改进预测框和标注框的匹配策略也能提高模型的检测准确率。

3) 减少模型参量,提高实时性

为了提高检测速度,现有的深度网络模型被不断改进,许多轻量级网络被提出,如MobileNet、ShuffleNet、EfficientNet等,但是在汽车装配件的缺陷检测中应用较少,如何平衡实时性与检测精度的问题,还有很大发展空间。

4) 扩展三维数据,减少背景干扰

目前的缺陷检测方法主要借助于物体的二维平面图像,对于简单的划痕、污点等缺陷已有很多成熟的检测方法,但是汽车装配件的结构都较复杂,缺陷容易遮挡,在多样背景条件下,二维图像能提供的信息非常有限,难以仅凭图像准确识别出缺陷区域。如果引入三维图像视角,则可以在第三个维度上描述物理信息,从而更清楚地获取缺陷的特征,进而提高缺陷检测的精确度。

5) 多特征融合,提高泛化能力

传统的图像处理方法可以对底层特征进行针对性提取,而深度学习的方法随着网络深度的加深,不可避免地会损失部分浅层信息,将两种方法有效结合,既能利用深度学习强大的特征提取能力也能保留底层的重要信息。另外,可以进行多模态融合,如X射线图信息、超声信息、红外图信息等,不再局限于相机直接拍摄的图片,以提高模型的泛化能力。

6) 新方法:异常检测和视觉Transformer

深度卷积神经网络在训练时要求输入负样本(即含有缺陷的样本),然而,在实际生产中,缺陷样本出现的概率很低,因此可以使用异常检测方法,即输入训练的图像为正样本(无缺陷样本),使网络记住正常样本的特征分布特性。在检测时,当输入缺陷样本,网络会输出与正常

样本具有较大差异的结果,由此实现异常样本(即缺陷样本)的检测与识别。

Transformer 基于自注意力机制实现,近年来已有部分研究者将其引入计算机视觉的任务中,如图像分类 Vision Transformer、目标检测 DETR 等。视觉分类 Transformer 的基本处理过程为把图片切分为图像序列,形成序列向量,再加入位置编码作为 Transformer 的编码器输入,并去掉解码器直接进行分类预测。视觉检测 Transformer 的基本思想为把经过 CNN 提取的特征变成特征序列输入编解码器中,输出指定长度为 N 的无序集合,集合中每个元素包含物体类别和坐标。与卷积神经网络相比,Transformer 不局限于提取局部特征,而是聚焦于全局,与循环网络相比,Transformer 在处理序列时具有更高的效率,因此将视觉 Transformer 引入汽车装配件的缺陷检测是可行的,也会成为未来的研究趋势之一。

5 结 论

汽车生产中的装配件缺陷检测近年来已成为广大学者和企业的研究热点之一。本文针对汽车工业中汽车的装配件缺陷检测现状进行了综述,从方法和部件两个角度进行分类整理,并对比了各种方法的优缺点,传统的机器视觉方法是通过提取缺陷区域的纹理等特征,再结合分类器进行缺陷分类,这种方法针对单一背景下的缺陷图像有良好的识别效果,但是很难在不同的场景任务中应用。随着深度学习的发展,深度神经网络表现出了强大的特征提取能力,在缺陷检测的精确度和检测速度上有了很大提升,并具有良好的鲁棒性和泛化能力。同时,从检测精度、鲁棒性、泛化能力和实时性的角度出发,指出了汽车装配件的缺陷检测领域内目前的技术挑战和未来可以深入研究的方向,这些挑战的攻克将推动缺陷检测技术的进一步发展。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] 许善燎. 汽车轴类零件缺陷分布式超声无损检测研究及软件开发[D]. 武汉: 武汉理工大学, 2017.
- XU SH L. Research and software development of distributed ultrasonic nondestructive testing for defects of automobile axle parts[D]. Wuhan: Wuhan University of Technology, 2017.
- [2] 吕金旗. 低压铸造轮毂缺陷 X 射线检测系统的原理及应用[J]. 特种铸造及有色合金, 2013, 33(2): 155-156.
- LYU J Q. Principle and application of X-ray detection system for low pressure casting wheel hub defects[J].

Special Casting & Nonferrous Alloys, 2013, 33(2): 155-156.

- [3] 冯顺利. X 射线无损检测在汽车有色金属零件生产中的应用[J]. 有色金属工程, 2022, 12(8): 206.
- FENG SH L. Application of X-ray nondestructive testing in the production of non-ferrous metal parts in automobiles[J]. Nonferrous Metals Engineering, 2022, 12(8): 206.
- [4] 尹仕斌, 任永杰, 刘涛, 等. 机器视觉技术在现代汽车制造中的应用综述[J]. 光学学报, 2018, 38(8): 0815001.
- YIN SH B, REN Y J, LIU T, et al. Overview of the application of machine vision technology in modern automobile manufacturing [J]. Acta Optica Sinica, 2018, 38(8): 0815001.
- [5] 吴东东. 无损检测技术及其在汽车零部件制造过程中的应用[J]. 现代制造技术与装备, 2021, 57(9): 149-150.
- WU D D. Non-destructive testing technology and its application in the manufacturing process of auto parts[J]. Modern Manufacturing Technology and Equipment, 2021, 57(9): 149-150.
- [6] 朱正德. 谈“机器视觉”在汽车制造业中的应用[J]. 中国测试技术, 2006, 32(5): 22-25.
- ZHU ZH D. The application of “machine vision” in automobile manufacturing industry [J]. China Measurement & Test, 2006, 32(5): 22-25.
- [7] 逢增治, 郑修楠, 李金屏. 全钢子午线轮胎 X 光图像的缺陷检测研究现状[J]. 智能系统学报, 2019, 14(4): 793-803.
- PANG Z ZH, ZHENG X N, LI J P. Research status of defect detection in X-ray images of all-steel radial tires[J]. CAAI Transactions on Intelligent Systems, 2019, 14(4): 793-803.
- [8] 武博, 计效园, 孙晓龙, 等. 基于 X 射线图像的铸件缺陷智能检测与识别方法研究进展[J]. 铸造, 2022, 71(6): 709-718.
- WU B, JI X Y, SUN X L, et al. Research progress of intelligent detection and identification of casting defects based on X-ray images[J]. Foundry, 2022, 71(6): 709-718.
- [9] 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 review of surface defect detection methods based on deep learning [J]. *Acta Automatica Sinica*, 2021, 47(5): 1017-1034.
- [10] 李少波, 杨静, 王铮, 等. 缺陷检测技术的发展与应用研究综述[J]. 自动化学报, 2020, 46(11): 2319-2336.
- LI SH B, YANG J, WANG ZH, et al. Review on the development and application of defect detection technology[J]. *Acta Automatica Sinica*, 2020, 46(11): 2319-2336.
- [11] 楼国红, 张俊生, 郭晋秦. 铝合金轮毂内部缺陷的定量分析[J]. 特种铸造及有色合金, 2018, 38(7): 787-789.
- LOU G H, ZHANG J SH, GUO J Q. Quantitative analysis of internal defects in aluminum alloy wheels[J]. *Special Casting & Nonferrous Alloys*, 2018, 38(7): 787-789.
- [12] 陈东祥, 刘磊, 韩鸿志. 汽车车身涂膜缺陷的计算机视觉检测方法[J]. 天津大学学报, 2009, 42(12): 1130-1134.
- CHEN D X, LIU L, HAN H ZH. Detection method of car body painting defects based on computer vision technology [J]. *Journal of Tianjin University*, 2009, 42(12): 1130-1134.
- [13] 杨泽青, 李超, 黄凤荣, 等. 小波与中值滤波相结合的汽车管路连接件表面缺陷图像去噪[J]. 现代制造工程, 2019(11): 1-8.
- YANG Z Q, LI CH, HUANG F R, et al. Surface defect image denoising of automotive pipeline connectors by combining wavelet and median filter [J]. *Modern Manufacturing Engineering*, 2019(11): 1-8.
- [14] 李高亮, 王明泉, 张俊生, 等. 基于X射线的汽车方向盘缺陷检测与识别技术[J]. 核电子学与探测技术, 2012, 32(8): 964-967.
- LI G L, WANG M Q, ZHANG J SH, et al. Detection and identification of automobile steering wheel defects based on X-ray [J]. *Nuclear Electronics & Detection Technology*, 2012, 32(8): 964-967.
- [15] 李克斌. 基于机器视觉的汽车涡轮增压零件表面缺陷检测[D]. 南京: 南京航空航天大学, 2019.
- LI K B. Surface defect detection of automobile turbine shell parts based on machine vision [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2019.
- [16] 王姣. 基于机器视觉的汽车水箱钎焊表面缺陷检测方法研究[D]. 天津: 天津工业大学, 2021.
- WANG J. Research on detection method of brazing surface defects of automobile water tank based on machine vision [D]. Tianjin: Tiangong University, 2021.
- [17] HVARINEN J. Surface detection with histogram-based texture features [J]. In *SPIE Intelligent Robots and Computer Vision XIX: Algorithms, Techniques, and Active Vision*, 2000, 4197: 140-145.
- [18] 陈金贵, 刁福林, 陈昊. 汽车卡钳表面缺陷检测方法研究[J]. 中国科技论文, 2018, 13(16): 1854-1858.
- CHEN J G, DIAO F L, CHEN H. A surface defect detection method for the automobile caliper [J]. *China Sciencepaper*, 2018, 13(16): 1854-1858.
- [19] LIU H, JIA X, SU C, et al. Tire appearance defect detection method via combining HOG and LBP features[J]. *Frontiers in Physics*, 2022, 10: 1099261.
- [20] TAN X, TRIGGS B. Enhanced local texture feature sets for face recognition under difficult lighting conditions[J]. *IEEE Transactions on Image Processing*, 2010, 19(6): 1635-1650.
- [21] GUO Z, ZHANG L, ZHANG D. A completed modeling of local binary pattern operator for texture classification[J]. *IEEE Transactions on Image Processing*, 2010, 19(6): 1657-1663.
- [22] 马丽萍, 崔明, 朱培逸. 基于机器视觉的汽车安全带的表面缺陷检测系统[J]. 机床与液压, 2018, 46(2): 134-138.
- MA L P, CUI M, ZHU P Y. Surface defect detection system for seat belt based on machine vision [J]. *Machine Tool & Hydraulics*, 2018, 46(2): 134-138.
- [23] 杜超, 刘桂华. 一种基于频域变换的无监督车身漆膜缺陷检测算法[J]. 电镀与涂饰, 2020, 39(6): 344-351.
- DU CH, LIU G H. An algorithm for unsupervised defect detection in car body coating based on frequency domain transform [J]. *Electroplating & Finishing*, 2020, 39(6): 344-351.

- [24] 宋开勇, 王传旭, 董向鹏. 轮胎纹理提取与缺陷检测方法[J]. 计算机工程, 2012, 38(18): 291-293.
SONG K Y, WANG CH X, DONG X P. Tire texture extraction and defect detection method [J]. Computer Engineering, 2012, 38(18): 291-293.
- [25] CROSS G R, JAIN A K. Markov random field texture models[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1983, PAMI-5(1): 25-39.
- [26] 张辉, 金侠挺, JONATHAN W Q M, 等. 基于曲率滤波和改进 GMM 的钢轨缺陷自动视觉检测方法[J]. 仪器仪表学报, 2018, 39(4): 181-194.
ZHANG H, JIN X T, JONATHAN Q M W, et al. Research progress of surface defect detection methods based on machine vision [J]. Chinese Journal of Scientific Instrument, 2018, 39(4): 181-194.
- [27] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks [J]. Neural Information Processing Systems, 2012, 25: 1097-1105.
- [28] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [C]. 2015 International Conference on Learning Representations, 2015: 1-14.
- [29] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015: 1-9.
- [30] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, Inception-ResNet and the impact of residual connections on learning[C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2017, 31(1): 4278-4284.
- [31] HUANG G, LIU Z, VAN D M L, et al. Densely connected convolutional networks [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 2261-2269.
- [32] 鲍光海, 林善银, 徐林森. 基于改进型卷积网络的汽车高度调节器缺陷检测方法[J]. 仪器仪表学报, 2020, 41(2): 157-165.
BAO G H, LIN SH Y, XU L S. Defect detection method for automobile height regulator based on improved convolution network [J]. Chinese Journal of Scientific Instrument, 2020, 41(2): 157-165.
- [33] 王立群, 吴建胜. 基于深度学习的车辆零件缺陷检测方法[J]. 辽宁科技大学学报, 2020, 43(1): 58-64, 80.
WANG L Q, WU J SH. A detection method based on deep learning for vehicle part defects [J]. Journal of University of Science and Technology Liaoning, 2020, 43(1): 58-64, 80.
- [34] 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, 2014: 580-587.
- [35] GIRSHICK R. Fast R-CNN [C]. 2015 IEEE International Conference on Computer Vision (ICCV), 2015: 1440-1448.
- [36] REN S, HE K, 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, 2017, 39(6): 1137-1149.
- [37] HAN K, SUN M, ZHOU X, et al. A new method in wheel hub surface defect detection: Object detection algorithm based on deep learning[C]. 2017 International Conference on Advanced Mechatronic Systems (ICAMechS), 2017: 335-338.
- [38] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 779-788.
- [39] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]. 2016 European Conference on Computer Vision (ECCV), 2016: 21-37.
- [40] LAW H, DENG J. CornerNet: Detecting objects as paired keypoints[J]. International Journal of Computer Vision, 2020, 128(3): 642-656.
- [41] YU H, YIN W. The defect detection method for automobile surfaces based on a lighting system with light fields[J]. Optical Metrology and Inspection for Industrial Applications IX, 2022, 12319: 236-240.
- [42] 王宸, 张秀峰, 刘超, 等. 改进 YOLOv3 的轮毂焊缝缺陷检测 [J]. 光学精密工程, 2021, 29(8): 1942-1954.
WANG CH, ZHANG X F, LIU CH, et al. Detection

- method of wheel hub weld defects based on the improved YOLOv3[J]. *Optics and Precision Engineering*, 2021, 29(8): 1942-1954.
- [43] LI C, CUI G, ZHANG W, et al. Defect detection in vehicle mirror nonplanar surfaces with multi-scale atrous single-shot detect mechanism[J]. *AIP Advances*, 2021, 11(7): 075202.
- [44] LI Y, FAN B, ZHANG W, et al. TireNet: A high recall rate method for practical application of tire defect type classification[J]. *Future Generation Computer Systems*, 2021, 125: 1-9.
- [45] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015: 3431-3440.
- [46] 王尔琪. 轮毂铸造缺陷检测的关键技术研究[D]. 广州: 华南理工大学, 2019.
- WANG ER Q. Research on the key technology of wheel hub casting defect detection [D]. Guangzhou: South China University of Technology, 2019.
- [47] 郭瑞琦, 王明泉, 张俊生, 等. 基于深度学习的汽车轮毂缺陷自动分割技术[J]. *科学技术与工程*, 2020, 20(24): 9976-9981.
- GUO R Q, WANG M Q, ZHANG J SH, et al. Automatic segmentation technology of automobile wheel hub defects based on deep learning [J]. *Science Technology and Engineering*, 2020, 20 (24): 9976-9981.
- [48] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions [C]. 2016 International Conference on Learning Representations, 2016: 1-13.
- [49] CHEN L C, 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*, 2018, 40 (4): 834-848.
- [50] 崔浩. 轮毂图像分割与缺陷识别算法的研究与实现[D]. 北京: 北京邮电大学, 2020.
- CUI H. Research and implementation of wheel image segmentation and defect recognition algorithm [D]. Beijing: Beijing University of Posts and Telecommunications, 2020.
- [51] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN [C]. 2017 IEEE International Conference on Computer Vision (ICCV), 2017: 2980-2988.
- [52] 王陶然, 王明泉, 张俊生, 等. 基于 Mask R-CNN 的轮毂缺陷分割技术[J]. *国外电子测量技术*, 2021, 40(2): 1-5.
- WANG T R, WANG M Q, ZHANG J SH, et al. Automatic instance segmentation technology of automobile wheel hub defects based on Mask R-CNN [J]. *Foreign Electronic Measurement Technology*, 2021, 40(2): 1-5.
- [53] 王一妍. 基于机器视觉的轮毂铸造面质量检测研究[D]. 沈阳: 沈阳工业大学, 2019.
- WANG Y Y. Research on quality inspection of wheel casting surface based on machine vision [D]. Shenyang: Shenyang University of Technology, 2019.
- [54] 韩凯. 基于深度学习的汽车轮毂表面缺陷在线检测算法[D]. 北京: 北京邮电大学, 2019.
- HAN K. The online detection algorithm for surface defects of automobile hubs based on deep learning [D]. Beijing: Beijing University of Posts and Telecommunications, 2019.
- [55] 朱超平, 杨永斌. 基于改进的 Faster-RCNN 模型的汽车轮毂表面缺陷在线检测算法研究[J]. *表面技术*, 2020, 49(6): 359-365.
- ZHU CH P, YANG Y B. Online detection algorithm of automobile wheel surface defects based on improved Faster-RCNN model [J]. *Surface Technology*, 2020, 49(6): 359-365.
- [56] SUN X, GU J, HUANG R, et al. Surface defects recognition of wheel hub based on improved Faster R-CNN [J]. *Electronics*, 2019, 8(5): 481.
- [57] CHENG S, LU J, YANG M, et al. Wheel hub defect detection based on the DS-Cascade RCNN [J]. *Measurement*, 2023, 206: 112208.
- [58] 周洲. 轮芯缺陷检测及缺陷样本生成技术[D]. 广州: 华南理工大学, 2019.
- ZHOU ZH. Technology of wheel core defects detection and defect samples generation [D]. Guangzhou: South China University of Technology, 2019.
- [59] 王琦, 张超. 模式识别的汽车轮毂铸件缺陷检测技术研究[J]. *铸造技术*, 2017, 38(12): 2889-2891,

- 2899.
- WANG Q, ZHANG CH. Research on defects detection technology of automobile hub casting based on pattern recognition[J]. *Foundry Technology*, 2017, 38(12): 2889-2891, 2899.
- [60] 何再兴. 基于目标提取与匹配的汽车轮毂铸件缺陷检测技术研究[D]. 杭州: 浙江大学, 2008.
- HE Z X. Research on the technology of flaw detection in castings of automobile wheels based on aim extraction and match[D]. Hangzhou: Zhejiang University, 2008.
- [61] 丁杰, 王明泉, 张俊生, 等. 汽车轮毂缺陷检测中的缺陷增强与字符去除技术[J]. *科学技术与工程*, 2017, 17(35): 76-81.
- DING J, WANG M Q, ZHANG J SH, et al. Defect enhancement and character removal technology of defect detection of automobile hub[J]. *Science Technology and Engineering*, 2017, 17(35): 76-81.
- [62] SUN X, GU J, WANG M, et al. Wheel hub defects image recognition base on zero-shot learning[J]. *Applied Sciences-Basel*, 2021, 11(4): 1529.
- [63] YANG H, JIANG Y, DENG F, et al. Detection of bubble defects on tire surface based on line laser and machine vision[J]. *Processes*, 2022, 10(2): 255.
- [64] ZHENG Z, YANG H, ZHOU L, et al. HLU2-Net: A residual U-structure embedded U-Net with hybrid loss for tire defect inspection [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 3527511.
- [65] ZHANG Y, CUI X, LIU Y, et al. Tire defects classification using convolution architecture for fast feature embedding [J]. *International Journal of Computational Intelligence Systems*, 2018, 11(1): 1056-1066.
- [66] ZHENG Z, ZHANG S, YU B, et al. Defect inspection in tire radiographic image using concise semantic segmentation[J]. *IEEE Access*, 2020, 8: 112674-112687.
- [67] ZHENG Z, SHEN J, SHAO Y, et al. Tire defect classification using a deep convolutional sparse-coding network [J]. *Measurement Science and Technology*, 2021, 32(5): 055401.
- [68] GAO S, DAI Y, XU Y, et al. Generative adversarial network-assisted image classification for imbalanced tire X-ray defect detection[J]. *Transactions of the Institute of Measurement and Control*, 2023, 45(8): 1492-1504.
- [69] 殷列栋. 基于重构残差的轮胎缺陷 X 光图像异常检测算法研究[D]. 杭州: 浙江大学, 2021.
- YIN L D. Research on anomaly detection algorithm of tire defect based on X-ray image reconstruction residual[D]. Hangzhou: Zhejiang University, 2021.
- [70] TJOLLENG A, CHANG J, PARK J, et al. Development of a human-friendly visual inspection method for painted vehicle bodies [J]. *Applied Ergonomics*, 2023, 106: 103911.
- [71] ARNAL L, SOLANES J E, MOLINA J, et al. Detecting dings and dents on specular car body surfaces based on optical flow [J]. *Journal of Manufacturing Systems*, 2017, 45: 306-321.
- [72] XIE F, CHEN R, ZHOU Q, et al. An adaptive defect detection technology for car-bodies surfaces [C]. 2019 Chinese Automation Congress (CAC), 2019: 1023-1028.
- [73] ZHOU Q, CHEN R, HUANG B, et al. DeepInspection: Deep learning based hierarchical network for specular surface inspection [J]. *Measurement*, 2020, 160: 107834.
- [74] MOMINA J, SOLANES J E, ARNAL L, et al. On the detection of defects on specular car body surfaces [J]. *Robotics and Computer-Integrated Manufacturing*, 2017, 48: 263-278.
- [75] CHANG F, LIU M, DONG M, et al. A mobile vision inspection system for tiny defect detection on smooth car-body surfaces based on deep ensemble learning [J]. *Measurement Science and Technology*, 2019, 30(12): 125905.
- [76] BORSU V, YOGESWARAN A, PAYEUR P. Automated surface deformations detection and marking on automotive body panels[C]. 2010 IEEE International Conference on Automation Science and Engineering, 2010: 551-556.
- [77] CHUNG Y C, CHANG M. Visualization of subtle defects of car body outer panels [C]. 2006 SICE-ICASE International Joint Conference, 2006: 4639-4642.
- [78] EDRIS M Z B, JAWAD M S, ZAKARIA Z. Surface defect detection and neural network recognition of automotive body panels [C]. *Proceedings 5th IEEE International Conference on Control System, Computing*

- and Engineering (ICCSCE 2015), 2015: 117-122.
- [79] XIAO M, YANG B, WANG S, et al. A feature fusion enhanced multiscale CNN with attention mechanism for spot-welding surface appearance recognition [J]. Computers in Industry, 2022, 135: 103583.
- [80] BROBERG P. Surface crack detection in welds using thermography [J]. Ndt & E International, 2013, 57: 69-73.
- [81] 宋宏伟, 王龙, 张秋花, 等. 白车身激光扫描焊熔池边界提取与缺陷识别的研究 [J]. 汽车工程, 2020, 42(3): 401-405.
- SONG H W, WANG L, ZHANG Q H, et al. Study on boundary extraction and defect identification of molten pool in laser scanning welding of body-in-white [J]. Automotive Engineering, 2020, 42(3): 401-405.
- [82] HUA S, LI B, SHU L, et al. Defect detection method using laser vision with model-based segmentation for laser brazing welds on car body surface [J]. Measurement: Journal of the International Measurement Confederation, 2021, 178: 109370.
- [83] LI Z, CHEN H, MA X, et al. Triple pseudo-siamese network with hybrid attention mechanism for welding defect detection [J]. Materials & Design, 2022, 217: 110645.
- [84] KIESELBACH K K, NOTHEN M, HEUER H. Development of a visual inspection system and the corresponding algorithm for the detection and subsequent classification of paint defects on car bodies in the automotive industry [J]. Journal of Coatings Technology and Research, 2019, 16(4): 1033-1042.
- [85] DORING C, EICHHORN A, WANG X, et al. Improved classification of surface defects for quality control of car body panels [C]. 2006 IEEE International Conference on Fuzzy Systems, 2006: 1476-1481.
- [86] KAMANI P, NOURSADEGHI E, AASHAR A, et al. Automatic paint defect detection and classification of car body [C]. 2011 7th Iranian Conference on Machine Vision and Image Processing, 2011: 1-6.
- [87] 钱玮. 基于相位测量偏折算法的油漆缺陷检测系统的应用 [J]. 涂料工业, 2022, 52(3): 78-82.
- QIAN W. Application of coating defect detection system based on phase measuring deflectometry [J]. Paint & Coatings Industry, 2022, 52(3): 78-82.
- [88] 徐嘉斌. 基于进化算法的车漆缺陷检测方法研究 [D]. 长春: 吉林大学, 2021.
- XU J B. Evolutionary algorithm for automatic defect detection on vehicle body paint [D]. Changchun: Jilin University, 2021.
- [89] ZHAO H, LV Y, SHA J, et al. Research on detection method of coating defects based on machine vision [C]. 2021 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA), 2021: 519-524.
- [90] ZHANG J, XU J, ZHU L, et al. An improved MobileNet-SSD algorithm for automatic defect detection on vehicle body paint [J]. Multimedia Tools and Applications, 2020, 79(31-32): 23367-23385.
- [91] ZHOU Q, CHEN R, HUANG B, et al. An automatic surface defect inspection system for automobiles using machine vision methods [J]. Sensors, 2019, 19(3): 644.
- [92] 胡玉坤. 漆面表面缺陷检测技术研究 [D]. 南京: 东南大学, 2021.
- HU Y K. Research on the detection technology of paint surface defects [D]. Nanjing: Southeast University, 2021.
- [93] 刘瑞媛, 茅健, 陆文超. 汽车精密零件外观缺陷视觉检测方法研究 [J]. 计算机与数字工程, 2021, 49(2): 383-387.
- LIU R Y, MAO J, LU W CH. Research on visual inspection method for appearance defects of automotive precision parts [J]. Computer & Digital Engineering, 2021, 49(2): 383-387.
- [94] 范伟. 基于机器视觉的汽车车身零部件表面划痕检测的研究 [D]. 南京: 南京理工大学, 2016.
- FAN W. Research on surface scratch detection of auto body parts based on machine vision [D]. Nanjing: Nanjing University of Science & Technology, 2016.
- [95] 厉晓飞. 基于机器视觉的汽车零件缺陷检测技术研究 [D]. 武汉: 武汉理工大学, 2012.
- LI X F. Research of auto parts defects detection technology based on machine vision [D]. Wuhan: Wuhan University of Technology, 2012.
- [96] 刘瑞玲, 钟德星, 韩九强. 汽车伞齿轮多目视觉检测

- 系统与算法[J]. 西安交通大学学报, 2014, 48(4): 1-7.
- LIU R L, ZHONG D X, HAN J Q. Bevel gear detection system with multi-camera vision [J]. Journal of Xi'an Jiaotong University, 2014, 48(4): 1-7.
- [97] DU W, SHEN H, FU J, et al. Approaches for improvement of the X-ray image defect detection of automobile casting aluminum parts based on deep learning[J]. Ndt & E International, 2019, 107: 102144.
- [98] YANG Y, MIN Z, ZUO J, et al. Crack identification of automobile steering knuckle fluorescent penetrant inspection based on deep convolutional generative adversarial networks data enhancement[J]. Frontiers in Physics, 2022, 10: 1081805.
- [99] 佟鑫, 郑彤, 于重重, 等. 基于机器视觉的小样本零部件表面 DD [J]. 计算机仿真, 2023, 40(4): 160-164.
- TONG X, ZHENG T, YU CH CH, et al. Surface defect detection of few-shot parts based on machine vision[J]. Computer Simulation, 2023, 40(4): 160-164.
- [100] 季进军, 叶畅, 殷红梅. 汽车发动机缸孔内表面缺陷的自动检测技术研究[J]. 现代制造工程, 2014(3): 109-113.
- Ji J J, YE CH, YIN H M. Research on automatic detection technology for cylinder surface defects [J]. Modern Manufacturing Engineering, 2014 (3): 109-113.
- [101] 周龙. 汽车发动机连杆表面缺陷机器视觉检测系统[D]. 杭州: 浙江工业大学, 2005.
- ZHOU L. Machine vision detection system for surface-defection measurement of engine rod [D]. Hangzhou: Zhejiang University of Technology, 2005.
- [102] LIYUN X, BOYU L, HONG M, et al. Improved Faster R-CNN algorithm for defect detection in powertrain assembly line [J]. Procedia CIRP, 2020, 93: 479-484.
- [103] ZHU H, WANG Y, FAN J. IA-Mask R-CNN: Improved anchor design Mask R-CNN for surface defect detection of automotive engine parts [J]. Applied Sciences Basel, 2022, 12(13): 6633.
- [104] DUAN L, YANG K, RUAN L. Research on automatic recognition of casting defects based on deep learning[J]. IEEE Access, 2021, 9: 12209-12216.
- [105] GUO W, QU H, LIANG L. WDXI: The dataset of X-Ray image for weld defects[C]. 2018 14th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD), 2018: 1051-1055.
- [106] HE Y, SONG K, MENG Q, et al. An end-to-end steel surface defect detection approach via fusing multiple hierarchical features [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1493-1504.

作者简介



张瀚丹, 2022 年于浙江工业大学获得学士学位, 现为南京航空航天大学硕士研究生, 主要研究方向为图像处理与机器视觉。

E-mail: handan_z@163.com

Zhang Handan received her B. Sc. degree from Zhejiang University of Technology (ZJUT) in 2022. She is currently a master student at Nanjing University of Aeronautics and Astronautics. Her current 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。

E-mail: nuaaimage@163.com

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 remote sensing image processing and understanding, infrared target detection and recognition, visual detection and image measurement, video processing and intelligent analysis, et al.