

基于机器视觉的划痕检测技术综述

杨乐淼, 周富强*

北京航空航天大学仪器科学与光电工程学院, 北京 100191

摘要 在现阶段的智能制造过程中,精密产品及仪器表面的零划痕质量要求不断提高,基于机器视觉的划痕检测方法因其无损高精度的特点具有重要的研究意义。综述了基于机器视觉的划痕检测技术的发展现状,将目前主流的划痕检测方法分为手工设计特征方法和深度学习方法。基于手工设计特征的划痕检测方法包括灰度分布统计法、变换域法和高低维空间映射法,基于深度学习的划痕检测方法包括有监督学习方法和无监督学习方法,总结了每种方法的优缺点和适用场景,阐述了基于机器视觉的划痕检测技术的发展趋势。

关键词 机器视觉; 划痕检测; 数字图像处理; 深度学习

中图分类号 TP391 文献标志码 A

DOI: 10.3788/LOP202259.1415009

Survey of Scratch Detection Technology Based on Machine Vision

Yang Lemiao, Zhou Fuqiang*

School of Instrumentation and Optoelectronic Engineering, Beihang University, Beijing 100191, China

Abstract In the current intelligent manufacturing process, the requirements for zero scratch quality of precision products and instrument surfaces are constantly improving. The scratch detection method based on machine vision shows important research significance because of its non-destructive and high-precision characteristics. This paper summarizes the development status of scratch detection technology based on machine vision and divides the current mainstream scratch detection methods into manual design features and deep learning methods. The scratch detection methods based on manual design features include gray distribution statistics, transform domain, and high- and low-dimensional space mapping methods. The scratch detection methods based on deep learning include supervised and unsupervised learning methods. The advantages of each method are summarized, disadvantages and application scenarios are described, and development trends of scratch detection technology based on machine vision are expounded.

Key words machine vision; scratch detection; digital image processing; deep learning

1 引言

表面划痕是衡量产品质量和性能的重要因素之一,一般出现在产品表面局部物理或化学性质不均匀的区域,有效检测表面划痕对确保产品质量和性能、减少残次品、保证使用安全具有重要意义。机器视觉技术作为一种无接触、无损伤的自动检测技术,具有安全可靠、光谱响应范围宽、可在恶劣环境下长时间工作等突出优点。近年来,基于机器视觉的划痕检测方法逐渐取代传统人工检测方法,并广泛应用于先进制造、航空航天、军事科技、智能交通等领域,如管道检测机器人、航天航空发动机检测、汽车发动机检测、建筑土木

结构检测等,涉及钢轨^[1]、轴承^[2-3]、输电线路^[4-5]、芯片^[6]、玻璃板^[7]、运输带^[8]、工件^[9]等与国计民生紧密相关的诸多产品。

传统的基于机器视觉的划痕检测方法,主要基于手工设计的图像特征和常规数字图像处理算法,如灰度变换、直方图均衡、空域滤波或频域滤波等图像预处理算法及阈值分割、边缘检测等图像分割算法,这类算法主要针对室内、光照均匀、无遮挡或较少反射的强约束场景,仅适用于特定条件下的划痕检测需求。近年来,国内外学者不断改进原有的图像处理算法,提出了许多适应性更强、准确率更高的划痕检测方法。Huang等^[10]设计了一种二维方向滤波器对划痕图像进

收稿日期: 2022-03-09; 修回日期: 2022-03-30; 录用日期: 2022-05-09

基金项目: 国家自然科学基金(52075027)

通信作者: *zfq@buaa.edu.cn

行滤波,并采用改进的自适应阈值法检测划痕边缘,该方法可对大曲率管道表面的划痕进行有效检测。Wang 等^[11]根据先验知识设计的特定缺陷特征,提出了一种实体稀疏追求(ESP)方法来识别表面缺陷。Liu 等^[12]用哈尔-韦布尔方差(HWV)模型描述图像中局部斑块的纹理分布,从而将钢表面划痕从背景中提取出来。张健浦等^[13]通过分析熔融石英元件亚表面缺陷图像的特点,提出了缺陷三维重建算法,并使用该算法定量获得了缺陷的完整三维信息。

随着机器学习技术的发展,将机器学习和机器视觉相结合的检测方法在划痕检测领域逐渐兴起。基于浅层学习技术的划痕检测方法包括特征提取和模式分类两个阶段,通过分析输入图像的特征,设计描述划痕信息的特征向量,将特征向量输入分类模型中进行模式分类。Xu 等^[14]提出了一种自适应多尺度几何分析(RNAMlet)方法,该方法可提取带钢表面不同尺度和方向的划痕特征。Hu 等^[15]将混合染色体遗传算法应用于大规模带钢图像采集中,建立了表面缺陷的实时分类模型。Mei 等^[16]利用卷积去噪自编码网络在多个高斯金字塔上重建图像块,将重建残差作为预测的指标,实现了对织物疵点的检测。浅层的学习技术在简单分类问题中,具有计算量小、检测速度快等优点。但随着识别种类的增加,样本的复杂性增强,浅层机器学习受到有限计算单元的制约,对复杂分类问题的泛化能力受限。

相较于浅层机器学习,深度学习方法利用卷积神经网络(CNN)的多层深度网络自动提取图像特征,对复杂的数据结构具有更强的表达能力,广泛应用于划痕检测问题中。Tao 等^[17]将预训练的残差网络(ResNet)作为特征提取器,并结合注意机制和上下文融合,对工业弱划痕进行检测。Cha 等^[18]采用改进的快速 CNN 对混凝土表面裂缝进行识别,实现了对视频

的实时损伤检测。Chen 等^[19]提出了一种由粗到细的三级级联深度 CNN,并将其应用于检测铁路沿线接触网紧固件裂纹。Ren 等^[20]利用 CNN 对划痕图像进行识别,再利用热图方法进行划痕分割。常江等^[21]提出了一种基于改进生成对抗网络带钢缺陷分类方法,该方法实现了基于工业现场中小样本带钢缺陷实时检测。基于深度学习的划痕检测方法已经逐渐取代浅层机器学习方法,与数字图像处理方法共同成为划痕检测领域的主流方法。

本文总结了近年来基于机器视觉的划痕检测技术,将目前主流的划痕检测方法分为基于手工设计特征的划痕检测方法和基于深度学习的划痕检测方法,并对相关方法的研究现状进行了比较和总结。

2 基于手工设计特征的划痕检测方法

基于手工设计特征的划痕检测方法根据被测表面的性质,设计不同的图像特征提取算法,主要有灰度分布统计法、变换域法和高低维空间映射法。

2.1 灰度分布统计法

灰度分布统计法是对图像像素灰度的规律性和周期性分布进行统计分析的方法。阈值法是划痕检测灰度分布统计法中的常用方法,但是直接使用阈值法容易受到图像灰度分布不均、对比度低等因素的影响,因此关于多阈值、局部阈值和自适应阈值的研究是非常有必要的。Ma 等^[22]提出了一种基于多方向灰度波动的自适应划痕检测方法,并提取 $0^\circ, 45^\circ, 90^\circ, 135^\circ$ 方向上灰度波动情况,即一维方向上灰度最大值与灰度均值对应的像素之间的距离 L_a ,根据灰度波动情况自动改变局部灰度分割算法的阈值 G_a 和步长 J_a ,将不同灰度层的分割结果 $T_0, T_{45}, T_{90}, T_{135}$ 合并形成最终分割结果 T ,如图 1 所示,其中缺陷用黑色像素表示,背景用白色像素表示。

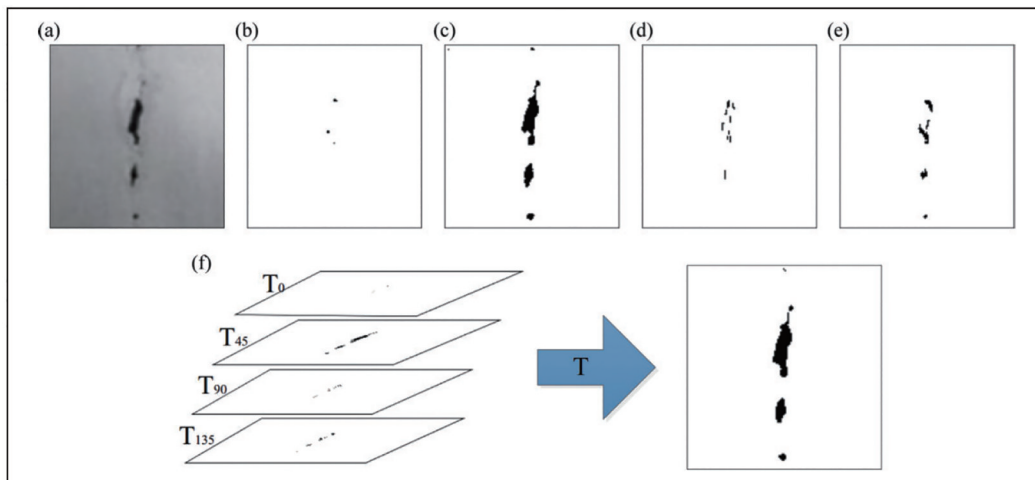


图1 不同灰度层的分割结果^[22]。(a)原始图像;(b)分割结果 T_0 ;(c)分割结果 T_{45} ;(d)分割结果 T_{90} ;(e)分割结果 T_{135} ;(f)最终结果 T
Fig. 1 Simulation experimental results of multi-frame iterative deconvolution algorithm^[22]. (a) Original image; (b) segmentation result T_0 ; (c) segmentation result T_{45} ; (d) segmentation result T_{90} ; (e) segmentation result T_{135} ; (f) final result T

边缘检测算法也是常用的灰度分布统计法,该算法通过微分检测边缘处像素的灰度值不连续性。Sobel算子对模糊边缘的检测能力很强,但对不均匀的光照很敏感,容易导致假边缘检测,Shi等^[23]提出了一种更有效、更精确的改进Sobel算法,该算法在原始的水平垂直两个方向的基础上增加了6个方向模板,如图2所示,利用8个模板分别与对应的图像数据进行卷积运算,输出灰度最大值对应的像素。Canny算子对图像中的细微边缘检测效果更好,邓捷等^[24]根据图像局部灰度特征利用Canny算子获取微晶玻璃缺陷轮廓,再基于缺陷几何特征进行筛选和剔除,得到真实缺陷信息。林磊等^[25]提出了一种基于局部窗口阈值的改进Canny边缘检测算法,该算法选取局部最佳分割阈值,对树脂镜片表面疵病实现了精确分割。

有学者通过聚类方法对图像像素间的相似性进行统计,挖掘像素分布中的隐含信息。Zhao等^[26]提出了一种基于超像素的两级标记技术来检测冷轧带材表面的划痕,原理如图3所示。第1级标记以简单线性迭代聚类(SLIC)算法输出的划痕边界作为初始超像素,记为 R^1 ;第2级标记根据超像素中心与相邻像素之间的

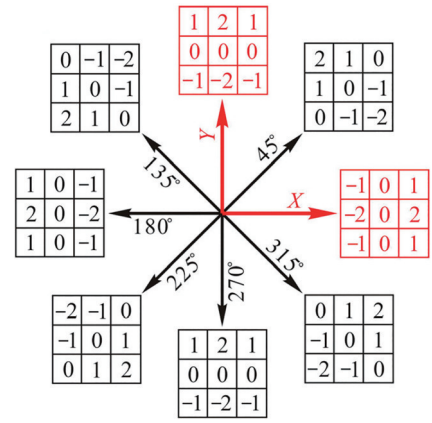


图 2 45°, 135°, 180°, 225°, 270°, 315°, 水平和垂直方向的算子模板^[23]
Fig. 2 Operator templates in 45°, 135°, 180°, 225°, 270°, 315°, horizontal, and vertical directions^[23]

差异,迭代更新超像素边界,直到具有相似视觉特征的像素聚类为同一个超像素,记为 R^2 ;对超像素经过多次区域生长划分出不同的子区域,从而提取出划痕像素,该方法可以有效地检测存在工业液体干扰的划痕,且平均正确检出率达到91%。

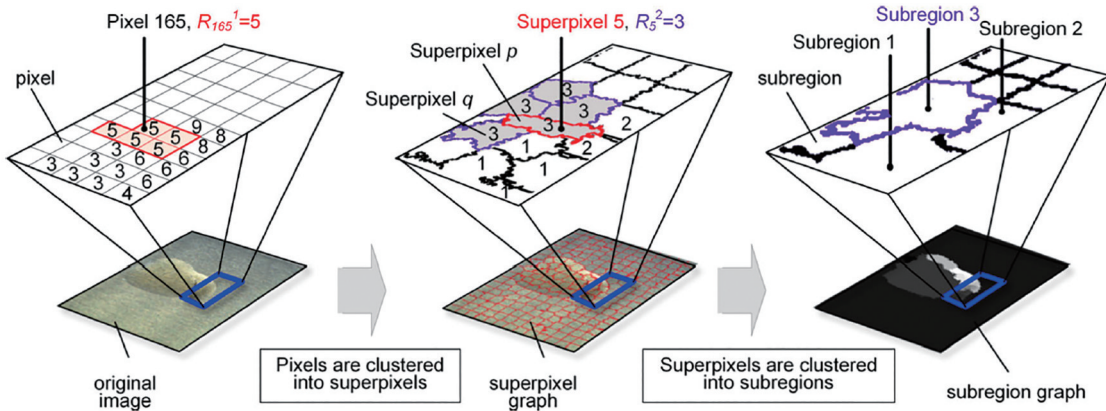


图 3 两级标记技术原理图^[26]
Fig. 3 Schematic of two-level labeling technique^[26]

2.2 变换域法

变换域法用傅里叶变换、Gabor滤波器、小波变换等滤波方法将图像从像素域转到频域,是划痕检测中应用最广泛的方法^[27-28]。傅里叶变换对平移、膨胀和旋转具有不变性,Ai等^[29]利用曲波变换将样本图像分解为三个层次,对所有子图像进行傅里叶变换,计算每个子带的傅里叶振幅谱,得到平移不变性特征,并对特征进行分类,在连铸板坯生产线上进行纵裂纹实时检测。

傅里叶变换通过在频域获取全局特征来描述图像,因此忽略了大部分空间域的局部特征,Gabor滤波器在频域和空间域通过特定的高斯函数对正弦波进行调制,同时获取图像的全局特征和局部特征。Gabor

滤波器的高斯核中心一般在频域坐标原点,Hu^[30]提出了一种中心、频率、方向均可自由调节的优化椭圆Gabor滤波器,如图4所示。图4充分说明了优化的椭圆Gabor滤波器是高度灵活的,可以调节为不同类型的过滤器。

与Gabor滤波器相比,小波变换不仅可以移动频域窗口中心,还可以随着窗口中心的移动自动调整窗口大小,所以小波变换可以通过缩放和移位操作对图像数据进行多尺度分析。Ji等^[31]在钢表面缺陷数据集上对5种小波特征进行了评估,包括Haar、DB2、DB4、双正交样条及连续像素块中提取的不同分解层次的多小波,实验结果表明,上述5种小波特征中Haar特征对于钢表面特征提取是最有效的。

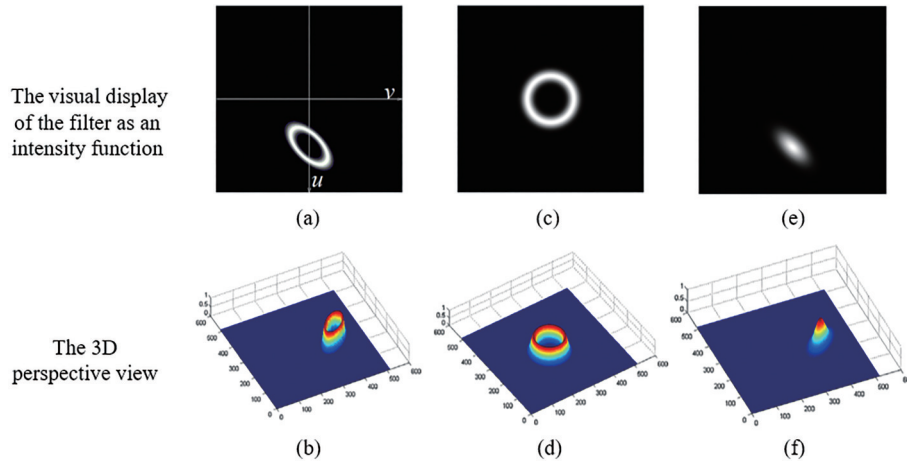


图 4 优化的椭圆 Gabor 滤波器及其调节^[30]。(a)(b)优化的椭圆 Gabor 滤波器；(c)(d)调节为环形 Gabor 滤波器；(e)(f)调节为 Gabor 滤波器
 Fig. 4 Optimized elliptical Gabor filter and its adjustments^[30]. (a) (b) Optimized elliptical Gabor filter; (c) (d) adjusting to ring Gabor filter; (e) (f) adjusting to ring Gabor filter

2.3 高低维空间映射法

高低维空间映射法利用特殊的模型结构,将图像投影到低维空间,再对划痕进行检测。Song 等^[32]提出了一种基于显著凸主动轮廓模型的检测方法,该方法将图像的高维特征映射为低维显著性图,将显著性图作为特征融合到局部活动轮廓的凸能量最小化函数中,利用数值最小化算法从杂波背景中分离出带钢表面微划痕。Huangpeng 等^[33]设计了一种引入纹理先验知识的加权低秩重建模型,该模型通过构造纹理先验图预测图像异常值,通过低秩分解图像异常值来检测表面划痕。高低维空间映射法克服了统计法易受噪声干扰和光谱法缺乏局部信息的缺点,如何从理论上验证解释、如何减小运算量、如何提高算法的自适应性是进一步研究的方向。

2.4 小结

表 1 对上述 3 种基于手工设计特征的划痕检测方法

法进行了总结,并分析了各方法的优缺点。灰度分布统计法可以有效地反应图像像素灰度的规律性和周期性,但该方法对图像局部特征的着重表征,导致其容易受噪声干扰,因此灰度分布统计法适用于分辨率较低或划痕检测精度要求不高的图像。不同于灰度分布统计法在像素域对图像的运算和操作,变换域法主要利用图像的频域特性,因此该方法抵抗噪声和变化光照等干扰因素的能力更强,但该方法缺乏对局部信息的详细表述,而且划痕检测准确度易受到特征相关性的影响。高低维空间映射法对图像的维度空间进行映射变换,其抗噪声干扰能力较强,对不同环境的适应性较高,但是对低对比度或细微划痕的检测精度较差。综上所述,基于手工设计特征的划痕检测方法具有易于实现、灵活性强等优点,但是需要依据实际检测需求和应用场景对算法进行优化设计,结合不同的方法对划痕进行融合提取是未来研究的方向。

表 1 不同手工设计特征划痕检测方法的优缺点

Table 1 Advantages and disadvantages of different scratch detection methods based on manual design feature

Taxonomy	Method	Advantage	Disadvantage
Manual design feature	Gray distribution statistics	Reflect the regularity and local features of the image	Sensitive to noise, suitable for low resolution images
	Transform domain methods	Strong anti-interference ability to noise and changing illumination	Lack of local information, susceptible to feature correlation
	High- and low-dimensional space mapping methods	Strong anti-interference ability to noise, strong adaptability	Poor detection for low contrast or fine scratches

3 基于深度学习的划痕检测方法

基于深度学习的划痕检测方法主要将划痕检测作为分类问题来处理,其中 CNN 被广泛应用于划痕检测任务中^[34]。典型的 CNN 架构可表示为

$$\text{Input} \rightarrow \left[(\text{Conv} \rightarrow \text{ReLU})^p \rightarrow \text{Pool} \right]^q \rightarrow \left[\text{FC} \rightarrow \text{ReLU} \right]^m \rightarrow \text{FC}, \quad (1)$$

式中:Input 为输入,一般是 3 通道彩色图像或 1 通道灰度图像矩阵,其中每个位置都包含强度值;Conv 为卷

积,将输入图像的每个位置与设定的特征进行卷积,得到每个特征的特征图;ReLU为激活函数,通过特定的激活函数形式对特征图中特定的元素进行运算; p 为卷积和激活函数的操作次数;Pool为池化,将卷积层输出并经过激活函数运算的特征图沿两个空间维度执行非线性下采样,从而缩小输入图像,减少像素信息,只保留重要信息,目的是减少网络参数的数量并降低计算成本; q 为 p 次卷积和激活函数及1次池化的操作次

数;FC为全连接,对特征进行整合和分类; m 为全连接和激活函数的操作次数。

典型CNN架构示例如图5所示。首先对输入图像进行卷积并对激活函数进行运算得到卷积层1;然后对卷积层1进行池化,特征图尺寸缩小得到下采样层1;重复卷积、池化操作分别得到卷积层2和下采样层2;输入全连接层将经过卷积层和池化层提取的特征整合在一起,根据所有提取的特征完成分类。

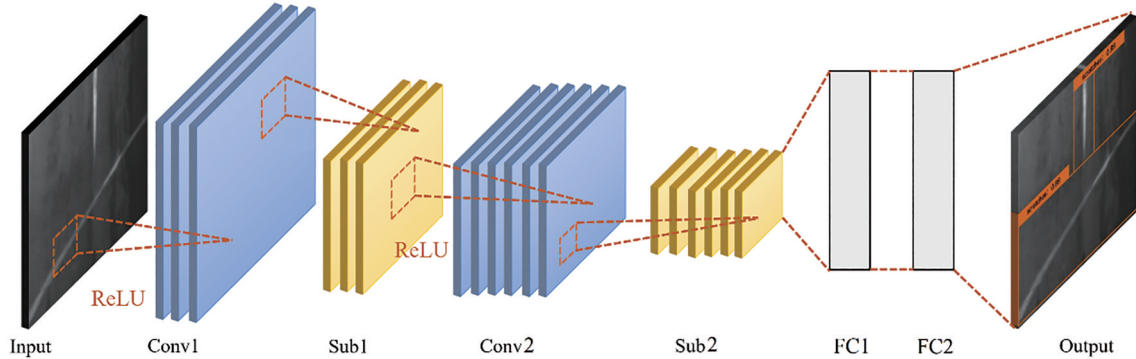


图5 典型CNN架构示例

Fig. 5 Example of a typical CNN architecture

基于深度学习的划痕检测方法按照实现方式可以分为有监督学习和无监督学习。有监督学习在已知类别标签的特征集的基础上训练深度网络,利用训练过的网络检测划痕;无监督学习不需要已知类别的训练集,直接根据特征向量之间的相似性,对特征进行分类和检测。

3.1 有监督学习方法

目前,大量基于深度学习的划痕检测方法是以有监督学习为研究方向的。将划痕检测作为分类任务,应用CNN对划痕进行分类是最常用的手段。He等^[35]通过训练多组CNN提取不同类型缺陷的特征映射组,检测钢表面划痕。He等^[36]采用基线CNN生成特征图,再通过多级特征融合网络合成特征,实现对划痕的细节定位。Cha等^[37]将CNN与滑动窗口技术结合,识别和检测混凝土表面裂纹,并证明了该方法比Canny和Sobel边缘检测算法的检测效果好。

目标检测是深度学习领域的研究热点,将划痕检测作为目标检测任务也是一个重要的研究方向。目标检测网络从结构上可以划分为基于候选区域的网络和基于回归方法的网络。罗晖等^[38]改进了基于候选区域的网络Cascade R-CNN,解决了钢轨表面图像存在背景不均匀、划痕尺度变化大且样本数据不足导致检测困难的问题。这种基于候选区域的划痕检测算法的检测准确度可以达到很高的水平,但由于网络结构相对复杂、候选框数量多、计算量大,导致其检测速度不高。

基于回归方法的网络检测速度更快,更易于满足工业检测的实时性要求^[39-40],基于回归方法的划痕检测算法主要有YOLO和SSD。Chen等^[41]对SSD、

YOLO等方法进行了改进,构建了级联型的检测网络。周天宇等^[42]针对载波芯片缺陷目标较小,且不同类型缺陷之间尺度变化较大的问题,设计了多尺度特征融合模块对YOLOv3进行改进,实现了对载波芯片缺陷的检测。孙连山等^[43]设计了注意力引导模块和多个特征预测尺度对YOLOv3进行改进,实现了铝型材表面划痕的多尺度特征提取。有监督学习需要大量标记图像作为训练数据集,在实际工业生产中,采集和标记图像样本是一项庞大且繁琐的工作,因此有监督学习的应用场景受到数据集的限制。

3.2 无监督学习方法

无监督学习不需要依靠标记的数据集,而是根据输入的正样本之间的相似程度对图像进行重建和判别,通常采用的网络模型是自编码器(AE)和生成对抗网络(GAN)。Zhao等^[44]将GAN与AE相结合建立了一个重建网络,并利用重建网络对输入样本中的缺陷区域进行修复,利用局部二值模式(LBP)对输入样本与修复样本进行比较,得出了准确的缺陷区域。Youkachen等^[45]通过卷积自动编码器(CAE)和锐化处理提取输入图像中的缺陷特征,实现了带钢表面缺陷的分割。Mei等^[27]采用CAE在不同高斯金字塔层上重建图像块,将各层图像块的重构残差相结合作为缺陷预测的指标,该方法能够有效地检测表面缺陷,且在整个检测过程中不需要人工干预。孟奇等^[46]针对小样本条件下深度学习缺陷检测算法识别率较低的问题,提出了一种基于双通道GAN的数据增强方法,该方法可对镜片缺陷图像全局信息的多样性和细节特征的质量进行有效增强。无监督学习可以避免繁琐的数据

集标记工作,但是容易受到光照和噪声的影响,如何提高无监督学习网络的抗干扰能力是进一步研究的方向。

3.3 小结

表 2 对基于深度学习的划痕检测方法进行了总结,并分析了各方法的优缺点。有监督学习的划痕检测方法精度高,不易受光线和噪声的影响,但是需要大量标记图像作为训练数据集,图像的获取和人工标注

工作较为繁琐。无监督学习的划痕检测方法不需要标记数据集,可以有效解决真实工业环境中划痕图像样本数量少的问题,但是容易受到变化的光照、环境噪声及网络参数初值设置的影响,划痕检测精度普遍低于有监督学习方法的划痕检测精度。相较于基于手工设计特征的划痕检测方法,深度学习方法可以从大量数据中自动学习划痕图像的特征,可以更智能地进行检测,减少了人工干预和特征设计的工作。

表 2 不同深度学习划痕检测方法的优缺点

Table 2 Advantages and disadvantages of different deep learning scratch detection methods

Taxonomy	Method	Advantage	Disadvantage
Deep learning	Supervised learning	Has high detection accuracy, less susceptible to light and noise	Requires a large number of labeled images as training data sets
	Unsupervised learning	Does not require tagging data sets and human intervention	Susceptible to light, noise and initial values of network parameters

4 结 论

对基于数字图像处理和深度学习等机器视觉方法的划痕检测技术进行了分析,从各种技术的优缺点及当前各领域的应用需求来看,基于手工设计特征的划痕检测技术在很多特定场景下具有易于实现、灵活性强等优点,但是对图像对比度和环境噪声要求较为严苛,需要根据实际场景进行相应的算法优化;随着人工智能技术的发展,深度学习划痕检测方法在很多工业场景下可以解决传统手工设计特征方法无法解决的难题,能够应对一定的工业检测环境变化。总体上,基于机器视觉的划痕检测技术不断向自动化和智能化方向发展,在今后的研究中,更好地平衡检测精度和速度,提高算法的抗干扰能力,建立更全面的划痕检测评价机制等是需要进一步研究的方向。

参 考 文 献

- [1] Gibert X, Patel V M, Chellappa R. Deep multitask learning for railway track inspection[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(1): 153-164.
- [2] 冯超, 蒋毅, 赵晓梦. 基于空间全角度光源的钢球表面微缺陷检测[J]. 激光与光电子学进展, 2022, 59(2): 0212002.
Feng C, Jiang Y, Zhao X M. Micro defect detection of steel ball surface based on spatial omni-directional light source[J]. Laser & Optoelectronics Progress, 2022, 59(2): 0212002.
- [3] Mao W T, He J L, Zuo M J. Predicting remaining useful life of rolling bearings based on deep feature representation and transfer learning[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1594-1608.
- [4] Miao X R, Liu X Y, Chen J, et al. Insulator detection in aerial images for transmission line inspection using single shot multibox detector[J]. IEEE Access, 2019, 7: 9945-9956.
- [5] Prates R M, Cruz R, Marotta A P, et al. Insulator visual non-conformity detection in overhead power distribution lines using deep learning[J]. Computers & Electrical Engineering, 2019, 78: 343-355.
- [6] Shu Y F, Li B, Lin H. Quality safety monitoring of LED chips using deep learning-based vision inspection methods[J]. Measurement, 2021, 168: 108123.
- [7] Pan Z F, Yang J, Wang X E, et al. Image-based surface scratch detection on architectural glass panels using deep learning approach[J]. Construction and Building Materials, 2021, 282: 122717.
- [8] Zhang M C, Shi H, Zhang Y, et al. Deep learning-based damage detection of mining conveyor belt[J]. Measurement, 2021, 175: 109130.
- [9] 闫河, 赵其峰, 谢敏, 等. 自适应 Canny 算子 PCBA 元器件边缘检测及修复[J]. 光学学报, 2021, 41(5): 0515003.
Yan H, Zhao Q F, Xie M, et al. Edge detection and repair of PCBA components based on adaptive canny operator[J]. Acta Optica Sinica, 2021, 41(5): 0515003.
- [10] Huang D P, Liao S P, Sunny A I, et al. A novel automatic surface scratch defect detection for fluid-conveying tube of Coriolis mass flow-meter based on 2D-direction filter[J]. Measurement, 2018, 126: 332-341.
- [11] Wang J Z, Li Q Y, Gan J R, et al. Surface defect detection via entity sparsity pursuit with intrinsic priors[J]. IEEE Transactions on Industrial Informatics, 2020, 16(1): 141-150.
- [12] Liu K, Wang H Y, Chen H Y, et al. Steel surface defect detection using a new Haar - Weibull-variance model in unsupervised manner[J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66(10): 2585-2596.
- [13] 张健浦, 孙焕宇, 王狮凌, 等. 熔融石英光学元件亚表面缺陷三维重构技术[J]. 光学学报, 2020, 40(2): 0216001.
Zhang J P, Sun H Y, Wang S L, et al. Three-dimensional reconstruction technology of subsurface

- defects in fused silica optical components[J]. *Acta Optica Sinica*, 2020, 40(2): 0216001.
- [14] Xu K, Xu Y, Zhou P, et al. Application of RNAMlet to surface defect identification of steels[J]. *Optics and Lasers in Engineering*, 2018, 105: 110-117.
- [15] Hu H J, Liu Y, Liu M F, et al. Surface defect classification in large-scale strip steel image collection via hybrid chromosome genetic algorithm[J]. *Neurocomputing*, 2016, 181: 86-95.
- [16] Mei S, Wang Y D, Wen G J. Automatic fabric defect detection with a multi-scale convolutional denoising autoencoder network model[J]. *Sensors*, 2018, 18(4): 1064.
- [17] Tao X, Zhang D P, Hou W, et al. Industrial weak scratches inspection based on multifeature fusion network [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 5000514.
- [18] Cha Y J, Choi W, Suh G, et al. Autonomous structural visual inspection using region-based deep learning for detecting multiple damage types[J]. *Computer-Aided Civil and Infrastructure Engineering*, 2017, 33(9): 731-747.
- [19] Chen J W, Liu Z G, Wang H R, et al. Automatic defect detection of fasteners on the catenary support device using deep convolutional neural network[J]. *IEEE Transactions on Instrumentation and Measurement*, 2018, 67(2): 257-269.
- [20] Ren R X, Hung T, Tan K C. A generic deep-learning-based approach for automated surface inspection[J]. *IEEE Transactions on Cybernetics*, 2018, 48(3): 929-940.
- [21] 常江, 管声启, 师红宇, 等. 基于改进生成对抗网络和 MobileNetV3 的带钢缺陷分类[J]. *激光与光电子学进展*, 2021, 58(4): 0410016.
Chang J, Guan S Q, Shi H Y, et al. Strip defect classification based on improved generative adversarial networks and MobileNetV3[J]. *Laser & Optoelectronics Progress*, 2021, 58(4): 0410016.
- [22] Ma Y P, Li Q W, Zhou Y Q, et al. A surface defects inspection method based on multidirectional gray-level fluctuation[J]. *International Journal of Advanced Robotic Systems*, 2017, 14(3): 1-17.
- [23] Shi T, Kong J Y, Wang X D, et al. Improved Sobel algorithm for defect detection of rail surfaces with enhanced efficiency and accuracy[J]. *Journal of Central South University*, 2016, 23(11): 2867-2875.
- [24] 邓捷, 李伟仙, 吴思进. 基于灰度及几何特征的微晶玻璃缺陷检测[J]. *光学技术*, 2021, 47(4): 428-431.
Deng J, Li W X, Wu S J. Detection of defects in glass-ceramics based on grayscale and geometric features[J]. *Optical Technique*, 2021, 47(4): 428-431.
- [25] 林磊, 臧铁钢. 基于机器视觉的树脂镜片表面疵病边缘检测[J]. *机械制造与自动化*, 2021, 50(2): 230-232, 240.
Lin L, Zang T G. Edge detection of defect for resin lenses based on machine vision[J]. *Machine Building & Automation*, 2021, 50(2): 230-232, 240.
- [26] Zhao Y J, Yan Y H, Song K C. Vision-based automatic detection of steel surface defects in the cold rolling process: considering the influence of industrial liquids and surface textures[J]. *The International Journal of Advanced Manufacturing Technology*, 2017, 90(5/6/7/8): 1665-1678.
- [27] Mei S, Yang H, Yin Z P. An unsupervised-learning-based approach for automated defect inspection on textured surfaces[J]. *IEEE Transactions on Instrumentation and Measurement*, 2018, 67(6): 1266-1277.
- [28] Fathabadi H. Novel filter based ANN approach for short-circuit faults detection, classification and location in power transmission lines[J]. *International Journal of Electrical Power & Energy Systems*, 2016, 74: 374-383.
- [29] Ai Y H, Xu K. Surface detection of continuous casting slabs based on curvelet transform and kernel locality preserving projections[J]. *Journal of Iron and Steel Research, International*, 2013, 20(5): 80-86.
- [30] Hu G H. Automated defect detection in textured surfaces using optimal elliptical Gabor filters[J]. *Optik*, 2015, 126(14): 1331-1340.
- [31] Ji H, Yang X, Ling H B, et al. Wavelet domain multifractal analysis for static and dynamic texture classification[J]. *IEEE Transactions on Image Processing*, 2013, 22(1): 286-299.
- [32] Song K C, Yan Y H. Micro surface defect detection method for silicon steel strip based on saliency convex active contour model[J]. *Mathematical Problems in Engineering*, 2013, 2013: 429094.
- [33] Huangpeng Q Z, Zhang H, Zeng X R, et al. Automatic visual defect detection using texture prior and low-rank representation[J]. *IEEE Access*, 2018, 6: 37965-37976.
- [34] Kang G Q, Gao S B, Yu L, et al. Deep architecture for high-speed railway insulator surface defect detection: denoising autoencoder with multitask learning[J]. *IEEE Transactions on Instrumentation and Measurement*, 2019, 68(8): 2679-2690.
- [35] He D, Xu K, Zhou P. Defect detection of hot rolled steels with a new object detection framework called classification priority network[J]. *Computers & Industrial Engineering*, 2019, 128: 290-297.
- [36] He Y, Song K C, Meng Q G, 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.
- [37] Cha Y J, Choi W, Büyüköztürk O. Deep learning-based crack damage detection using convolutional neural networks[J]. *Computer-Aided Civil and Infrastructure Engineering*, 2017, 32(5): 361-378.
- [38] 罗晖, 李健, 贾晨. 基于图像增强与改进 Cascade R-CNN 的钢轨表面缺陷检测[J]. *激光与光电子学进展*, 2021, 58(22): 2212001.
Luo H, Li J, Jia C. Rail surface defect detection based on image enhancement and improved cascade R-CNN[J]. *Laser & Optoelectronics Progress*, 2021, 58(22): 2212001.
- [39] Lu X C, Ji J, Xing Z Q, et al. Attention and feature fusion SSD for remote sensing object detection[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 5501309.
- [40] Du L, Li L, Wei D, et al. Saliency-guided single shot

- multibox detector for target detection in SAR images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(5): 3366-3376.
- [41] Chen P H, Ho S S. Is overfeat useful for image-based surface defect classification tasks? [C]//2016 IEEE International Conference on Image Processing, September 25-28, 2016, Phoenix, AZ, USA. New York: IEEE Press, 2016: 749-753.
- [42] 周天宇, 朱启兵, 黄敏, 等. 基于改进 YOLOV3 的载波芯片缺陷检测[J]. 激光与光电子学进展, 2021, 58(12): 1210002.
Zhou T Y, Zhu Q B, Huang M, et al. Defect detection of chip on carrier based on improved YOLOV₃[J]. Laser & Optoelectronics Progress, 2021, 58(12): 1210002.
- [43] 孙连山, 魏婧雪, 朱登明, 等. 基于 AM-YOLOv3 模型的铝型材表面缺陷检测算法[J]. 激光与光电子学进展, 2021, 58(24): 2415007.
Sun L S, Wei J X, Zhu D M, et al. Surface defect detection algorithm of aluminum profile based on AM-YOLOv3 model[J]. Laser & Optoelectronics Progress, 2021, 58(24): 2415007.
- [44] Zhao Z X, Li B, Dong R, et al. A surface defect detection method based on positive samples[C]//Geng X, Kang B H. PRICAI 2018: trends in artificial intelligence. Lecture notes in computer science. Cham: Springer, 2018, 11013: 473-481.
- [45] Youkachen S, Ruchanurucks M, Phatrapomnant T, et al. Defect Segmentation of Hot-rolled Steel Strip Surface by using Convolutional Auto-Encoder and Conventional Image processing[C]//2019 10th International Conference of Information and Communication Technology for Embedded Systems (IC-ICTES), March 25-27, 2019, Bangkok, Thailand. New York: IEEE Press, 2019.
- [46] 孟奇, 苗华, 李琳, 等. 基于双通道生成对抗网络的镜片缺陷数据增强[J]. 激光与光电子学进展, 2021, 58(20): 2015001.
Meng Q, Miao H, Li L, et al. Data enhancement of lens defect based on dual channel generative adversarial networks[J]. Laser & Optoelectronics Progress, 2021, 58(20): 2015001.