

激光与光电子学进展

小样本问题下的铣削表面粗糙度测量

易怀安^{1*}, 方润基¹, 舒爱华², 路恩会³¹桂林理工大学机械与控制工程学院, 广西 桂林 541006;²桂林理工大学外国语学院, 广西 桂林 541006;³扬州大学机械工程学院, 江苏 扬州 225009

摘要 基于机器视觉的粗糙度测量方法大多是根据粗糙度关联指标建立预测模型,或者利用深度学习网络建立无指标预测模型,而这两类方法均存在着不足。一方面,人工设计指标的计算过程复杂,不利于在线检测。另一方面,深度学习模型则严重依赖大数据,数据量不足难以训练出有效的模型。针对以上问题,本文提出一种基于图神经网络的铣削表面粗糙度测量方法。该方法在训练阶段获取了自主学习的能力,而后仅需要少量铣削样本就能够完成铣削工件的粗糙度测量。试验结果表明,本文方法在铣削工件的粗糙度测量上不仅能够自动提取特征,而且表现出了较高的精度和良好的光照环境鲁棒性。

关键词 表面粗糙度测量; 图神经网络; 小样本问题; 特征自提取; 光照环境

中图分类号 TP399

文献标志码 A

DOI: 10.3788/LOP2022059.2324001

Milling Surface Roughness Measurement Under Few-Shot Problem

Yi Huaian^{1*}, Fang Runji¹, Shu Aihua², Lu Enhui³¹School of Mechanical and Control Engineering, Guilin University of Technology, Guilin 541006, Guangxi, China;²School of Foreign Languages, Guilin University of Technology, Guilin 541006, Guangxi, China;³School of Mechanical Engineering, Yangzhou University, Yangzhou 225009, Jiangsu, China

Abstract Most machine vision-based roughness measurement methods either build a prediction model based on roughness correlation indices or build an index-free prediction model using deep learning networks. However, both these models have disadvantages. The artificial designed index has a complicated calculation process, which is not conducive to inline detection. In comparison, deep learning models rely heavily on big data. It is difficult to train an effective model when the amount of data is insufficient. To address the above problems, this study proposes a graph neural network-based method for measuring the roughness of milling surfaces. This proposed approach acquired the ability to learn autonomously during the training phase. Thus, only a few milling samples were required to measure the roughness of the milling workpieces. The experimental results show that the proposed method can automatically extract features on roughness measurement of milling workpieces with high accuracy and good robustness of lighting environment.

Key words surface roughness measurement; graph neural networks; few-shot problem; extract features automatically; lighting environment

1 引言

在现代精密制造中,对零件的表面粗糙度测量不仅要求精度高,还希望能够实现在线检测。机器视觉检测是基于光学成像原理的检测方法,其过程不仅效率高、易于自动化,还不损伤工件,被广泛应用于高精度尺寸测量、工件表面质量评估、缺陷检测以及表面粗糙度测

量等领域^[1-2]。而当前机器视觉粗糙度检测方法大多是根据图像信息来设计粗糙度关联指标并建立预测模型,或者利用深度学习网络建立无指标预测模型。在指标设计方面,研究者从灰度信息到颜色信息进行了大量的研究。例如 Younis^[3]建立了灰度图像系数的平均值与粗糙度参数之间的线性关系模型。其中,灰度系数是表示图像灰度的一个参数:灰度系数越大,则黑色和白色

收稿日期: 2022-03-02; 修回日期: 2022-04-11; 录用日期: 2022-06-14

基金项目: 国家自然科学基金(52065016)、2021 广西研究生创新项目(YCSW2021204)、桂林理工大学博士启动基金(GLUTQD2017060)

通信作者: *yihuaian@126.com

的差别越小,对比度越小;灰度系数越小,则黑色和白色的差别越大,对比度越大,照片亮部和暗部呈现强烈对比。易怀安等^[4-5]提出基于RGB颜色空间的平均色差算法与彩色图像清晰度算法来预测磨削工件的表面粗糙度。叶寒等^[6]引入了一种新的边界区域修正方法,该方法对表面弧度变化较大的零件也同样适用,能够准确提取物体的粗糙度轮廓。在无指标设计方面,Chen等^[7]利用深度卷积神经网络对表面粗糙度进行分类,实现了无指标设计的粗糙度检测。Rifai等^[8]提出了一种利用卷积神经网络评价粗糙度的方法,并评估了该方法在不同切削条件下对车削、槽铣和侧铣等典型加工工序表面粗糙度的预测性能。虽然以上方法为视觉粗糙度测量增添了切实有效的理论基础,但人为设计指标的计算过程复杂,对光源环境要求较高,并且深度学习网络依赖于大数据,而获取大量粗糙度数据需要花费大量的人力和物力。因此,一个视觉粗糙度测量模型怎么从少量数据中获取高效、精准的预测性能,是该领域亟待解决的问题。针对此类小样本问题,研究人员提出了Few-shot Learning,其目的是让机器学会以人类的方式进行学习,人类仅通过一个或几个示例就能够实现对新种类的识别^[9]。Snell等^[10]针对小样本分类问题,提出利用原型网络学习一个度量空间,并计算每个类别原型之间的距离,从而进行分类。Sung等^[11]通过计算查询图像与每个新类的少数示例之间的关系分数,直接对新类的图像进行分类,无需进一步更新网络。

结合粗糙度视觉测量与Few-shot Learning,本文

提出一种基于图神经网络(GNN)的铣削表面粗糙度测量方法。值得注意的是,在文献[7]和[8]的粗糙度测量方法中,如果要对新类进行识别,则需要获取新类的大量样本,然后将其添加到训练集中并重新训练模型。与之相比,本文的GNN模型在训练阶段能够学会如何在粗糙度等级变化的情况下对铣削样本进行识别。在测试阶段,即使待测铣削样本中包含新类,GNN模型也能够仅通过少量样本来完成所有待测样本的粗糙度测量,既不需要获取新类的大量样本,也不需要重新训练模型。此外,GNN模型还可以利用卷积神经网络实现特征自提取,避免了人为设计指标,提高了视觉粗糙度自动化检测的可行性。

2 模型预测机理

2.1 用于粗糙度测量的GNN网络结构

GNN模型将特征提取、特征变换和特征分类集于一体,在学习大量基类后,仅需要少量样本就能快速学习到新类。在铣削工件粗糙度等级检测任务中,GNN模型在面对新类时,仅需要少量铣削工件样本就能快速学习到新类,实现数据量较少情况下端到端的铣削工件粗糙度测量,并且不用重新训练模型。文献[12]提出一种基于图神经网络的小样本学习算法,将距离度量由欧氏空间转移到非欧空间中,其核心思想是将标注样本的标签信息传递到没有标签的样本中。在本文中,从一个有部分类别标签且服从独立同分布的铣削工件图像样本集合中提取输入-输出对 $(T_i, Y_i)_i$,表示为

$$\begin{cases} T = \{ \{ (x_1, l_1), \dots, (x_s, l_s) \}, \{ \bar{x}_1, \dots, \bar{x}_t \}; l_i \in \{ 1, K \}, x_i, \bar{x}_j \in P_l(R^N) \} \\ Y = (y_1, \dots, y_t) \in \{ 1, K \} \end{cases}, \quad (1)$$

式中: s 表示有类别标签样本的数量; t 表示要分类的铣削样本数量; K 表示类的数量。本文将关注 $t=1$ 的场景,即每一个任务 T 仅对一个铣削样本进行分类。 $P_l(R^N)$ 表示特定类别在 R^N 上的分布, Y_i 与没有类别标签的铣削工件图像样本 $\{ (\bar{x}_1, \dots, \bar{x}_t) \in T_i \}$ 的类别相关。给定一个训练集 $\{ (T_i, Y_i)_i \}_{i \leq L}$,其标准训练的监督学习目标如下,

$$\min_{\theta} \frac{1}{L} \sum_{i \leq L} \ell[\Phi(T_i; \theta), Y_i] + R(\theta), \quad (2)$$

式中: $\Phi(T_i; \theta) = p(Y|T)$ 是本文的模型; $R(\theta)$ 是一个标准的正则化目标。当 $t=1, s=C \times K$ 时,集合中只有一个具有未知类别标签的铣削工件图像。如果每个标签恰好出现 C 次,有 K 个类别,则整个设置被称为 K -way C -shot Learning。GNN网络工作流程如图1




图1 GNN网络结构图

Fig. 1 GNN network structure diagram

所示。

GNN 网络由许多节点和边构成, 对于一个有类别标签的铣削样本, 将其特征向量与已有的标签信息连接在一起作为图的一个节点。对于无标签的铣削样本, 将其特征向量与零向量连接在一起作为图的节点。在本文中, 每个节点都代表一幅铣削图像, 而每个边上的权重则表示两个铣削图像之间的关系 (可以理解为距离或者相似程度)。从图 1 中还可以看到, 在每个卷积层之前需要计算邻接矩阵 $\tilde{A}^{(k)}$ 。其中, φ_i 是一个多层感知机 (MLP), 输入两个节点之间的差的绝对值, 输出对应的权重值, 而 $\tilde{A}^{(k)}$ 的计算会更新两个节点之间的连接权重, 从而改变 GNN 模型的结构。同时, 图卷积层并不会改变 GNN 模型的结构, 只改变节点上向量的值 (由不同颜色表示)。

2.2 模型评价标准

小样本图像分类算法的试验评价标准通常使用 K -way C -shot^[13], 其含义是从数据集中选取 K 类图像样本, 每类图像选取 C 个样本, 一般地, $C \in \{5, 10, 15, 20\}$, $K \in \{1, 5\}$ 。在本文中, 取 $C=5, K=5$, 即 5-way

5-shot。在训练阶段, 每次选取 5 个类中的 5 个铣削样本在构建好的 GNN 模型上进行训练, 共 5×5 个样本。在验证和测试阶段, 选取 5 个类中的 5 个铣削样本, 执行 5-way 5-shot 分类任务, 然后输出预测结果。所有试验均使用 5-way 5-shot 评价标准来进行训练和测试。

2.3 数据增强

小样本学习模型能够借助训练集学会自主学习, 从而在面对新的类别时模型也能通过几个样本获取对新类的识别能力, 即训练集是此类模型获取自主学习能力的根本。从理论上说, 训练集包含的数据量越大, 类别越多, 模型从中获取到的自主学习能力越强。因此, 为了增强 GNN 模型对铣削工件的自主学习能力, 试验采用数据增强算法来对训练集进行量级扩增和模式扩增^[14]。数据增强方法有平移、调整对比度、调整色相、调整饱和度等 (图 2)。其中, 色相是指物体反射的光线中以哪种波长占优势来决定的, 不同波长产生不同颜色的视觉, 如红色、绿色、紫色等, 它决定了颜色本质的根本特征。




图 2 数据增强部分效果图。(a) 原始图像; (b) 调整对比度; (c) 调整饱和度; (d) 调整色调; (e) 平移

Fig. 2 Partial effect of data enhancement. (a) Original image; (b) adjusting contrast; (c) adjusting saturation; (d) adjusting hue; (e) translation

3 试验设计

试验设计流程如图 3 所示。




图 3 试验设计流程

Fig. 3 Experimental design flow

3.1 铣削试样制备

图 4 为加工机床与刀具图。本试验中的铣削试样的加工材料、设备、参数如表 1 所示。

3.2 试验装置设计

铣削工件图像采集装置如图 5 所示, 它由 1 台配备工业镜头 VS-2514H1 的 Basler 彩色 CCD 相机 (900 万像素)、2 个白色条形光源 OPT-LI14030、1 个数字电流控制器 OPT-DPA1024E-4、1 个数字式照度计 TES-1332A 以及 1 个试验架组成。为了获取更多的铣削表




图 4 加工机床与刀具

Fig. 4 Machining machine and tool

表 1 材料和加工参数

Table 1 Material and processing parameters

Material	Size / (mm×mm)	Roughness range / μm	Roughness measuring instrument	Numerical control machine
45#steel	60×40	0.6-5.0	Mitutoyo SJ-301	XHS7145
Milling cutter	Milling cutter blade	Cutting depth / mm	Feed rate / (mm·min ⁻¹)	Spindle speed / (r·min ⁻¹)
TAP400R100-32-6T	APMT1604PDER TR330	0.05-0.20	100-2200	700




图 5 试验装置

Fig. 5 Experimental setup




图 6 纹理方向。(a)左侧;(b)右侧

Fig. 6 Texture orientation. (a) Left; (b) right

从图 6 可以看出,纹理的方向对光的反射有着明显的影响。为了增加数据的多样性并提高模型对铣削纹理方向的鲁棒性,试验在拍摄过程中会根据需要适当调整工件的位置,例如工件的摆放方向。此外,从图 7 可以看到,工件的图像质量不仅受光照条件影响,

面粗糙度细节,铣削工件平放于测量平台上,相机光轴与被测表面垂直,白色条形光源以合适的角度固定在试验架上。在试验过程中,CCD 相机与光源的相对位置保持不变,以数字电流控制器调节环境亮度,使用照度计测量环境光照度。

为了检验 GNN 模型对复杂光源环境的鲁棒性,试验设计了两种光源环境:1)光源环境 A 代表在黑暗环境中仅使用白色定制光源作为照明工具,光照强度为 7710 lx。2)光源环境 B 代表在明亮环境中,使用白色定制光源、日光灯以及自然光作为照明光源,光照强度为 9340~13050 lx。

机器视觉检测的理论基础是光在工件表面反射成像,而表面对光的反射又取决于表面形貌。铣削加工由于刀具刃口的一致性、机床的规律振动以及刀具的进给运动会在工件表面形成规律纹理(图 6)。

还与表面形貌有关,呈现出明暗分布不均和反光现象。虽然这些干扰因素给粗糙度测量模型的搭建增加了不小的难度,但同时也提高了模型在可变成像环境中部署的可行性。




图 7 明暗分布不均与反光现象

Fig. 7 Light and dark uneven distribution and reflection phenomenon

3.3 数据预处理与数据集划分

此外,在同一张铣削工件图像中,工件表面虽然都

属于同一粗糙度,但表面各处存在着细微的差别,故可以对图像进行裁剪,达到增加工件图像的数量以提高

模型的性能的目的。因此,试验截取每张图像中铣削试样所在的区域(1650 pixel \times 1100 pixel)并裁剪为 6 个尺寸相等且互不重叠的区域,再将图片压缩为




图 8 图像预处理。(a)裁剪;(b)压缩

Fig. 8 Image pre-processing. (a) Clipping; (b) compression

在国际标准化组织(ISO)中,把工业生产中常用的粗糙度等级分为 0.4、0.8、1.6、3.2、6.3 μm 等,即把粗糙度等级划分为 0~0.4 μm 、0.4~0.8 μm 、0.8~1.6 μm 、1.6~3.2 μm 、3.2~6.3 μm 等 5 类。故本文仿照 ISO 划分方法,将 0.6~5.0 μm 划分为 10 类,即 [0.6~1.2)、[1.2~1.8)、[1.8~2.2)、[2.2~2.6)、[2.6~3.0)、[3.0~3.4)、[3.4~3.8)、[3.8~4.2)、[4.2~4.6)、[4.6~5.0) μm 。然后将数据集划分为训练集、验证集和测试集,并对训练集进行数据增强,具体的样本分类与数量统计见表 3。

表 3 预处理后的样本分类与数量统计

Table 3 Sample classification and number statistics after data pre-processing

Set	Number of samples	Data enhancement	Number of samples
Training set	984	Yes	9840
Validation set	288	No	
Test set	432	No	

3.4 GNN 模型参数设置

通过一系列预试验,确定 GNN 模型的超参数。其中,学习率设为 0.005, batch size 设为 10, 迭代次数为 15000, 选取随机梯度下降(SGD)优化器更新模型网络参数。

3.5 试验方案设计

试验一:模型的粗糙度测量性能评估。现有基于小样本学习的图像分类算法被归纳为传统神经网络和图神经网络两类,而本文方法属于图神经网络。因此,为评估 GNN 模型的检测性能,本文使用在光照环境 A 下获取的铣削表面粗糙度数据集 A, 选取传统神经网络模型 MAML^[15]进行对比试验。

试验二:复杂光照环境的鲁棒性评估。为评估 GNN 模型对复杂光照环境的鲁棒性,结合表 2 设计了以下两组跨域检测任务:1)训练集 A 用于训练,将验证集 B 与测试集 B 用于验证和测试。2)训练集 B 用于训

100 pixel \times 100 pixel(图 8),得到一个包含了 1704 张铣削表面粗糙度图像的数据集。

练,将验证集 A 与测试集 A 用于验证和测试(表 4)。

表 4 跨域检测任务

Table 4 Cross-domain detection tasks

Name	Training set	Validation set	Test set
A to B	A	B	B
B to A	B	A	A

4 试验结果与分析

4.1 试验一

为了能够清晰直观地看到 MAML 与 GNN 在训练过程中铣削表面粗糙度检测性能的变化过程,将两者的训练集损失值、训练集准确率和验证集准确率(表 5)的变化分别绘制在图 9 中。

表 5 MAML 和 GNN 的测试准确率

Table 5 Test accuracy of MAML and GNN unit: %

Model	1	2	3	4	5	Average
MAML	95.8	95.6	95.9	95.7	96.0	95.8
GNN	97.0	96.9	97.1	97.4	97.0	97.1

从图 9 可以看出, MAML 模型收敛后的损失曲线有着较为明显的波动,与之相比, GNN 模型的损失曲线较为平稳。此外, MAML 模型和 GNN 模型的训练集准确率都达到了极高的水平,接近 100%。然而, MAML 模型的验证集准确率相比 GNN 模型有着一定的差距,前者的曲线在 90% 以上波动且幅度较大,而后的曲线在 95% 以上波动且幅度较小,这表明 GNN 模型的收敛效果和精度均优于 MAML 模型。同时,通过观察表 5 可以发现, MAML 模型的平均准确率为 95.8%, GNN 模型的平均准确率为 97.1%, 这表明了 GNN 模型有着比 MAML 模型更好的泛化性能。试验结果表明, GNN 模型满足 ISO 粗糙度等级划分标准,能够满足实际工业生产的需求。此外,模型还可通过增加数据量来进一步提高模型的测量精度,以及继续细分粗糙度等级。

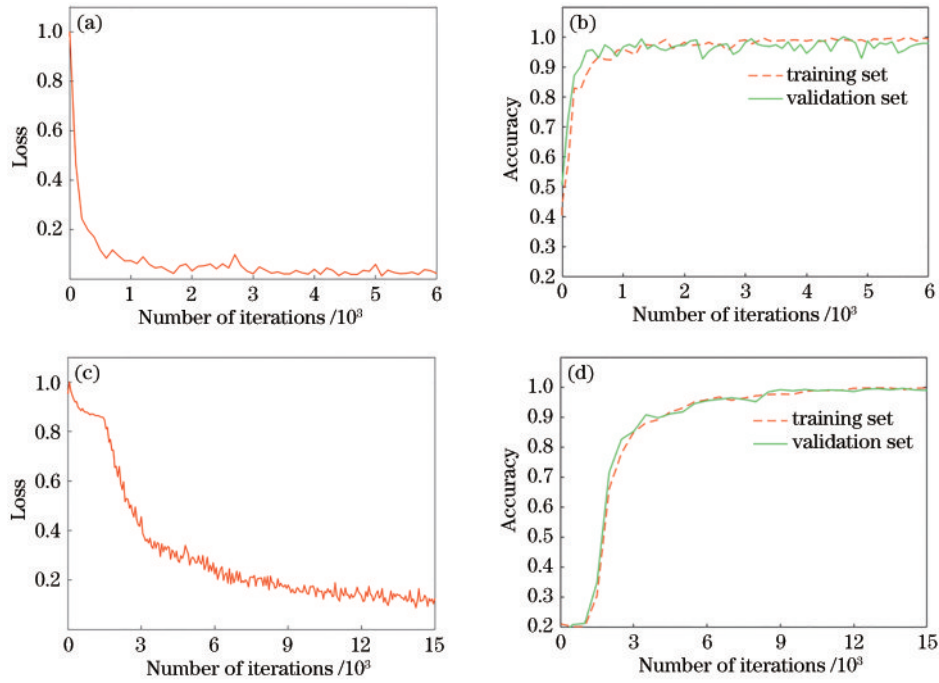


图 9 试验结果。(a) (b) MAML 和 (c) (d) GNN 的损失函数曲线与准确率曲线

Fig. 9 Experimental results. Loss function curves and accuracy curves of (a) (b) MAML and (c) (d) GNN

4.2 试验二

传统的机器视觉检测粗糙度方法不仅在预测的准确率上波动较大,而且对光照环境严重依赖。例如易怀安等^[4-5]通过红绿定制光源建立了平均色差指标与磨削表面粗糙度之间的关系模型,Zhang 等^[16]在黑暗环境中利用白色光源获取的粗糙度图片结合迁移核学习与仿真数据建立粗糙度预测模型,两者都是为了减小复杂光照环境对预测准确率的影响。因此,本文通

过在两种光源环境下分别获取的两个铣削粗糙度数据集设计了两个跨域检测任务,试验结果如图 10 和表 6 所示。

从图 10 和表 6 可以看出,任务 A to B 和 B to A 有三个共同点:1)损失函数曲线和准确率曲线在模型收敛后基本平稳,过拟合现象轻微,拟合效果良好;2)跨域检测精度较高,训练集准确率接近 100%,验证集准确率达到 95% 以上;3)两个任务的 5 次测试准确率

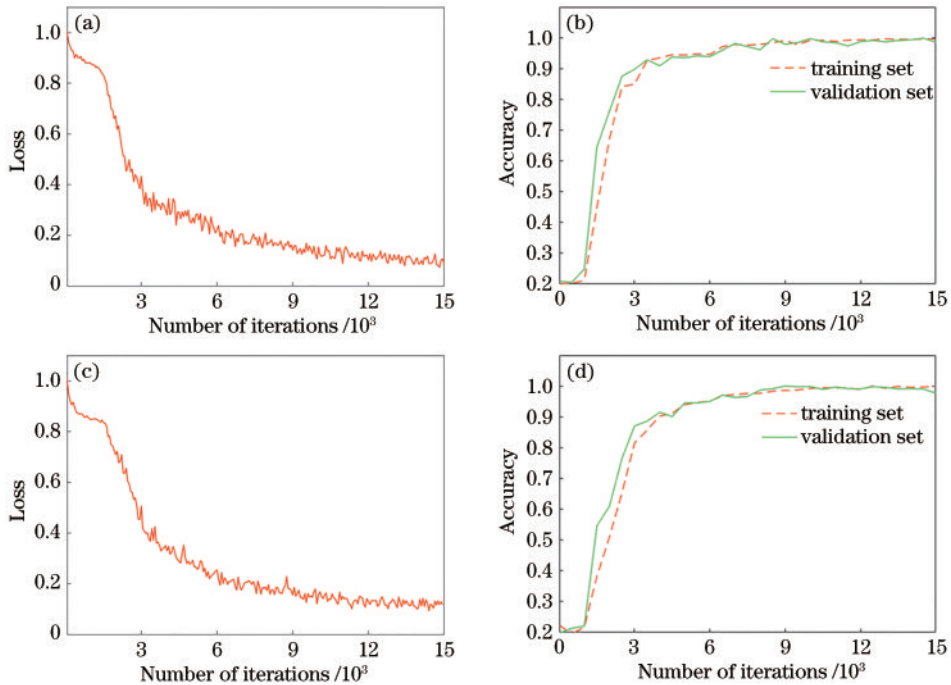


图 10 试验结果。跨域检测任务 (a) (b) A to B 和 (c) (d) B to A 的损失函数曲线和准确率曲线

Fig. 10 Experimental results. Loss function curves and accuracy curves for cross-domain detection tasks (a) (b) A to B and (c) (d) B to A

表 6 跨域检测任务 A to B 和 B to A 的测试准确率

Table 6 Test accuracy of cross-domain detection tasks A to B and B to A unit: %

Name	1	2	3	4	5	Average
A to B	96.7	96.8	96.6	96.6	96.8	96.7
B to A	96.4	96.1	96.7	96.3	96.4	96.4

均达到了 96% 以上,前者平均准确率为 96.7%,后者平均准确率为 96.4%,且两者相差不大。以上三点表明了即使光照环境改变,甚至有日光灯与自然光的干涉,GNN 模型仍有着较高的检测精度以及较好的鲁棒性。

5 结 论

在本文的对比试验中,GNN 模型的测试集的平均准确率超过了 97%(比 MAML 模型高出了 1.3%),这表明了 GNN 模型有着较高的检测精度,其稳定性与泛化性也优于 MAML 模型。在光照环境的鲁棒性评估试验中,GNN 在跨域检测任务的测试集平均准确率均超过了 96%,这表明了 GNN 模型有着良好的光照环境鲁棒性。GNN 模型弥补了基于指标设计方法和传统深度学习方法在铣削工件粗糙度检测实际应用中的不足,为机器视觉粗糙度自动化检测提供了一种新的改进策略。但它对于不同加工工艺、不同材料、不同拍摄角度和油污污染的工件等是否也能保持较高的跨域检测精度,还需要进行进一步研究。

参 考 文 献

- [1] 徐美芳,石云波,高文宏,等.激光投影显示屏表面粗糙度的测量[J].中国激光,2014,41(1):108005.
Xu M F, Shi Y B, Gao W H, et al. Surface roughness measurement of screen for laser projection display[J]. Chinese Journal of Lasers, 2014, 41(1): 108005.
- [2] 叶结和,刘勇,徐国成,等.基于非接触测量的搭接激光焊缝表面质量评估[J].中国激光,2019,46(10):1002008.
Ye J H, Liu Y, Xu G C, et al. Evaluation of surface quality of lap laser weld joints based on noncontact measurement[J]. Chinese Journal of Lasers, 2019, 46(10): 1002008.
- [3] Younis M A. On line surface roughness measurements using image processing towards an adaptive control[J]. Computers & Industrial Engineering, 1998, 35(1/2): 49-52.
- [4] 易怀安,刘坚,路恩会.基于图像清晰度评价的磨削表面粗糙度检测方法[J].机械工程学报,2016,52(16):15-21.
Yi H A, Liu J, Lu E H. Detection method of grinding

- surface roughness based on image definition evaluation[J]. Journal of Mechanical Engineering, 2016, 52(16): 15-21.
- [5] Yi H A, Liu J, Ao P, et al. Visual method for measuring the roughness of a grinding piece based on color indices [J]. Optics Express, 2016, 24(15): 17215-17233.
- [6] 叶寒,翁祖昕,张运海,等.修正边界区域误差的共聚焦显微成像粗糙度测量[J].激光与光电子学进展,2020,57(21):211203.
Ye H, Weng Z X, Zhang Y H, et al. Surface roughness measurement using laser confocal microscope with boundary area correction[J]. Laser & Optoelectronics Progress, 2020, 57(21): 211203.
- [7] Chen Y L, Yi H A, Liao C, et al. Visual measurement of milling surface roughness based on Xception model with convolutional neural network[J]. Measurement, 2021, 186: 110217.
- [8] Rifai A P, Aoyama H, Tho N H, et al. Evaluation of turned and milled surfaces roughness using convolutional neural network[J]. Measurement, 2020, 161: 107860.
- [9] Ravi S, Larochelle H. Optimization as a model for few-shot learning[EB/OL]. [2022-04-02]. <https://openreview.net/pdf?id=rJY0-Kcll>.
- [10] Snell J, Swersky K, Zemel R S. Prototypical networks for few-shot learning[EB/OL]. (2017-03-15) [2022-02-04]. <https://arxiv.org/abs/1703.05175>.
- [11] Sung F, Yang Y X, Zhang L, et al. Learning to compare: relation network for few-shot learning[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 1199-1208.
- [12] Garcia V, Bruna J. Few-shot learning with graph neural networks[EB/OL]. (2017-11-10) [2022-02-04]. <https://arxiv.org/abs/1711.04043>.
- [13] 刘颖,雷研博,范九伦,等.基于小样本学习的图像分类技术综述[J].自动化学报,2021,47(2):297-315.
Liu Y, Lei Y B, Fan J L, et al. Survey on image classification technology based on small sample learning [J]. Acta Automatica Sinica, 2021, 47(2): 297-315.
- [14] Shorten C, Khoshgoftaar T M. A survey on image data augmentation for deep learning[J]. Journal of Big Data, 2019, 6(1): 1-48.
- [15] Finn C, Abbeel P, Levine S. Model-agnostic meta-learning for fast adaptation of deep networks[C]// ICML'17: Proceedings of the 34th International Conference on Machine Learning, August 6-11, 2017, Sydney, NSW, Australia. New York: ACM Press, 2017: 1126-1135.
- [16] Zhang H, Liu J, Chen S F, et al. Novel roughness measurement for grinding surfaces using simulated data by transfer kernel learning[J]. Applied Soft Computing, 2018, 73: 508-519.