

# 利用改进卷积神经网络的螺杆砂带磨削表面粗糙度预测

杨赫然<sup>1,2</sup> 张培杰<sup>1,2</sup> 孙兴伟<sup>1,2\*</sup> 潘飞<sup>1,2</sup> 刘寅<sup>1,2</sup>

1.沈阳工业大学机械工程学院,沈阳,110870

2.辽宁省复杂曲面数控制造技术重点实验室,沈阳,110870

**摘要:**为便捷、准确地预测磨削后螺杆转子的表面粗糙度,提出了一种基于自注意力卷积神经网络(SA-CNN)的磨削曲面粗糙度测量方法。通过正交试验获得螺杆转子的表面粗糙度以及粗糙度数值对应位置的表面图像,图像经自适应直方图均衡化、反锐化掩蔽等预处理后作为训练样本输入SA-CNN模型中。采用SA-CNN模型对磨削后的螺杆转子表面粗糙度值进行预测,并与经典网络ResNet、AlexNet、VGG-16、基础CNN以及图神经网络GNN预测结果进行对比。试验结果表明,SA-CNN模型的平均预测精度达到95.24%,均方根误差(RMSE)为0.0706  $\mu\text{m}$ ,平均绝对百分比误差(MAPE)为7.4206%,均优于对比网络,且模型收敛较快,表现出较高的精度和良好的鲁棒性。

**关键词:**磨削;表面粗糙度;卷积神经网络;正交试验

**中图分类号:**TH161

**DOI:**10.3969/j.issn.1004-132X.2025.02.015

**开放科学(资源服务)标识码(OSID):**



## Surface Roughness Prediction for Screw Belt Grinding Based on Improved CNN

YANG Heran<sup>1,2</sup> ZHANG Peijie<sup>1,2</sup> SUN Xingwei<sup>1,2\*</sup> PAN Fei<sup>1,2</sup> LIU Yin<sup>1,2</sup>

1.College of Mechanical Engineering,Shenyang University of Technology,Shenyang,110870

2.Key Laboratory of Numerical Control Manufacturing Technology for Complex Surfaces of Liaoning Province,Shenyang,110870

**Abstract:** A grinding surface roughness measurement method was proposed based on SA-CNN for convenient and accurate prediction of roughness values on screw rotor surfaces after grinding. Through orthogonal experiments, the surface roughness values of screw rotors and corresponding surface images were obtained. After preprocessing including adaptive histogram equalization and unsharp masking, the images were used as training samples input into the SA-CNN model. The SA-CNN model was employed to predict the roughness values on the grinding surfaces of screw rotors and compared with the predictions of classical networks such as ResNet, AlexNet, VGG-16, basic CNN, and graph neural network (GNN). Experimental results show that the SA-CNN model achieves an average prediction accuracy of 95.24%, with an RMSE of 0.0706  $\mu\text{m}$  and an MAPE of 7.4206%, outperforming the compared networks. Furthermore, the SA-CNN model exhibits fast convergence, high accuracy, and good robustness.

**Key words:** grinding; surface roughness; convolutional neural network(CNN); orthogonal experiment

### 0 引言

螺杆作为一种重要的传动元件,在机械工程和交通运输等领域扮演着重要的角色<sup>[1-2]</sup>。表面质量直接影响螺杆转子的性能和可靠性,因此,螺杆表面粗糙度值测量的准确性、高效性、可靠性至

关重要<sup>[3-4]</sup>。直接简单的表面粗糙度测量方法有视觉比较法,工业上较多使用轮廓测量仪,通过接触探针记录表面的高度变化并生成表面的高度图像进而计算出表面粗糙度。触针轮廓仪测量方式为线采样,无法客观地表征某一区域的表面粗糙度值。此外,触控笔轮廓仪的测量精度受其触控笔半径的限制,在测量较小粗糙度表面(表面粗糙度小于2.5  $\mu\text{m}$ )时存在较大的系统误差<sup>[5-7]</sup>。为保证测量结果的准确性,通常在同一位置需要重

**收稿日期:**2023-11-20

**基金项目:**辽宁省教育厅2022年度高等学校基本科研项目(LJKMZ20220459);辽宁省应用基础研究计划(2022JH2/101300214)

复测量多次并取均值作为测量结果。因此,对于轴向尺寸较长、曲率变化较大的螺杆转子,接触式测量方式工作量较大。

近年来,随着光学技术和计算机辅助技术的快速发展,非接触式测量逐渐成为测量粗糙度的重要手段<sup>[8-9]</sup>。非接触式测量中的白光干涉等方式,测量对象一般为尺寸较小的光学零部件,对长度在6~12 m的螺杆转子类零件显然不适合。基于机器视觉的粗糙度测量方法本质上基于光学原理<sup>[10]</sup>,首先利用工业相机捕捉光源在测量表面上的图像,并设计与粗糙度参数相关的图像特征指数,再利用相关模型对工件表面粗糙度进行预测。基于机器视觉的粗糙度测量方法的主流研究方向包括:基于粗糙度相关图像的特征指标设计、表面纹理参数标定、图像预处理算法设计、成像试验设计、预测模型设计、性能评价方法和试验参数鲁棒性分析等<sup>[11-14]</sup>。LU等<sup>[15]</sup>和FISCHER<sup>[16]</sup>通过研究不同光照条件对磨削表面照射的影响,得到相应的特征指标,进而预测磨削表面粗糙度。易怀安等<sup>[17]</sup>通过对少量图片样本进行扩增并训练图神经网络(graph neural network, GNN),能够对铣削样本进行粗糙度测量。LU等<sup>[18]</sup>通过设计近场电磁散射仿真试验,观察不同粗糙度表面的电磁波散射现象,结果表明选取适当的参数能获得更高的粗糙度测量精度。杨晨等<sup>[19]</sup>、CHEN等<sup>[20]</sup>和HUANG等<sup>[21]</sup>通过对磨削环境干扰以及磨削表面纹理特性的研究,建立与磨削表面粗糙度具有强相关性的特征指标,从而实现磨削表面的粗糙度测量。VASANTH等<sup>[22]</sup>通过提取金属热图像的图像参数,将参数输入回归建模并对金属表面粗糙度进行测量,提供了具有迁移率的金属的间接表面粗糙度测量方法,但测量结果受温度的影响较大。FANG等<sup>[23]</sup>和SU等<sup>[24]</sup>通过改进神经网络,构建了能够识别工件表面的监测系统,能够检测待测表面并预测其粗糙度。安倩楠<sup>[25]</sup>和陈丽<sup>[26]</sup>通过建立卷积神经网络分别实现对车削和铣削的粗糙度等级的分类识别。综上所述,虽然基于机器视觉的粗糙度测量方法的研究已经很深入,但大多是通过建立指数相关模型、提取相关特征等间接测量方法,且对图像进行回归预测的神经网络多为等级分类预测,较少直接通过表面图像对粗糙度进行预测。本文针对螺杆类曲面这类较小粗糙度范围的测量,提出一种基于自注意力的卷积神经网络直接测量方法。

卷积神经网络(convolutional neural network, CNN)具有自动学习、处理大规模图像数

据时能够并行计算等优点,在引入自注意力机制建立全局联系后可突出重要特征,使得网络加快收敛。本文通过基于自注意力卷积神经网络(SA-CNN)对磨削后的螺杆转子工件表面的图像进行深度学习训练,从而实现螺杆转子表面粗糙度值的预测。

## 1 基于自注意力卷积神经网络的表面粗糙度值模型

### 1.1 自注意力卷积神经网络

CNN能高效地处理图像等数据,在预测表面粗糙度的过程中,通过学习与其粗糙度值相对应的图像特征,直到输出与训练样本一致。而后通过网络模型前向传播可对未知数值的图像进行表面粗糙度值预测。通过搭建多个卷积层、池化层和全连接层等来组合构成深层网络,可以降低特征图尺寸,减少参数量,加快训练过程。通过反向传播算法,CNN能够自动学习特征表达,并在训练过程中优化网络参数以最小化损失函数。

自注意力(self-attention)是一种在自然语言处理和计算机视觉中广泛应用的注意力机制<sup>[27-28]</sup>。自注意力在CNN回归预测中可以根据像素间相互关系学习每个像素对预测结果的重要性,从而增强模型对预测结果有贡献像素的提取,加强全局中重要特征的体现。其计算原理如下:给定输入序列 $A=[a_1, a_2, \dots, a_n]$ ,  $i=1, 2, \dots, n$ ,其中 $a_i$ 表示输入序列中的第 $i$ 个元素。匹配其他单元、被其他单元匹配、需要被提取的信息分别用 $q$ (query)、 $k$ (key)和 $v$ (value)表示。则每个元素 $a_i$ 对其他元素的注意力分配程度按下式进行计算:

$$\left. \begin{aligned} q^i &= W^q \cdot a_i \\ k^i &= W^k \cdot a_i \\ v^i &= W^v \cdot a_i \end{aligned} \right\} \quad (1)$$

其中, $W^q$ 、 $W^k$ 和 $W^v$ 为权重矩阵,用于将输入序列 $A$ 映射到 $q$ 、 $k$ 和 $v$ 。通过每一个 $q^i$ 对每一个 $k^i$ 计算每个元素对其他元素的注意力分配程度,即注意力分数(attention scores)。计算公式如下:

$$a_{1,i} = \frac{\exp(\beta_{1,i})}{\sum_j \exp(\beta_{1,j})} \quad (2)$$

其中, $\beta_{1,i}$ 表示 $q^1$ 和 $k^i$ 的计算相似度。那么每个单元计算之后的综合信息就是这个单元对句子所有各个单元的 $a$ 与各个单元的信息 $v$ 的计算总和,即注意力加权值(attention weighted values)。其计算公式如下:

$$b^1 = \sum_i a_{1,i} v^i \quad (3)$$

基于上述自注意力的计算特点,在 CNN 中引入自注意力机制可以自动地对序列中的关键信息进行加权汇聚,突出重要的特征并抑制不相关的特征,这有助于提高模型对输入样本中 有用信息的提取能力,从而改善回归预测的准确性。

### 1.2 SA-CNN 网络结构

基于 CNN 卷积层的自动提取特征能力与自注意力机制对关键信息的加权汇聚能力,建立了 SA-CNN 表面粗糙度预测模型,其结构如图 1 所

示,包含 5 层卷积层、一个 Dropout 层、两个全连接层、一个自注意力机制层。每层卷积层后添加了最大池化层、归一化层、Gule 激活函数,以加速训练并提高网络的稳定性。Dropout 层用于在训练过程中随机使一部分神经元失活,以防止过拟合;全连接层用于对展平后的特征进行进一步的抽象和学习;在两个全连接层之间添加一个自注意力机制层;在第二个全连接层后添加 LeakyReLU 激活函数,引入一定的负值响应,增强网络的非线性建模能力。




图 1 自注意力卷积神经网络结构

Fig.1 Structure of SA-CNN neural network

## 2 砂带磨削试验

磨削试验通过自主研制的砂带螺杆磨削装置实现,该装置安装于数控车床溜板上,如图 2 所示。磨削装置的主电机带动主动轮旋转,最终带动砂带相对于工件做高速直线运动,从而实现磨削去除。为保证砂带与工件相对运动轨迹与螺杆转子型面贴合,加工过程中工件自转速度与机床溜板沿工件的轴向运动速度需保证一定的比例关系。在此基础上,分别采用自由式装置和接触轮式装置对螺杆转子的凸面和凹面进行磨削。试验工件为经过铣削的 5 头螺杆转子(材料为 45 钢),砂带磨粒材料为锆刚玉。根据前期工作基础,影响砂带磨削质量的加工参数分别为进给速度  $v_g$ 、砂带线速度  $v_s$ 、砂带张紧力  $F_s$ 、磨削压力  $F_m$  与砂带粒度  $S$ 。采用两个气缸分别控制磨削压力和砂带张紧力,气缸压力变动范围均为 0~0.5 MPa。为保证磨削过程中砂带与工件表面具有合适的接触范围,选用主气缸压力至少大于张紧气缸压力 0.1 MPa,选定压力范围分别为主动气缸 0.4~0.5 MPa,张紧气缸 0.2~0.3 MPa。

砂带线速度通过主电机控制,考虑磨削质量和效率,将砂带线速度控制在 5~15 m/s。磨削装置轴向进给速度需要配合磨削线速度和磨削压




图 2 磨削试验现场

Fig.2 The scene of grinding experiment

力,选定范围为 100~300 mm/min。砂带粒度根据螺杆磨削质量要求,选择 80~240 目之间的 5 种目数。采用水平正交试验,考虑砂带磨损影响,每组试验磨削 20 min,每 2 min 测量一次粗糙度数值,并在相应位置拍摄螺杆表面图像。具体试验参数见表 1。

磨削工件图像的采集在图 3 所示的图像采集系统下进行。图像采集系统由计算机、分辨率为 1280×960 的灰度 CCD 相机 MV-EM120M/C(带有工业变倍镜头 MACRO ZOOM 0.3X-1X 1:4.5)、三轴位移平台、光源控制器和聚光光源组成。拍摄过程中 CCD 相机的光轴始终保持水平

表 1 试验参数

Tab.1 Experimental parameters

$F_m/\text{MPa}$	$F_s/\text{MPa}$	$v_s/(\text{m} \cdot \text{s}^{-1})$	$v_g/(\text{mm} \cdot \text{min}^{-1})$	$S$
0.4	0.2	5	100	80
0.425	0.225	7.5	150	100
0.45	0.25	10	200	120
0.475	0.275	12.5	250	180
0.5	0.3	15	300	240

并垂直于工件表面,光源固定在相机镜头。在图像采集过程中,工件与相机距离保持在 60 ~ 100 mm,光强由光源控制器对聚光光源进行控制。图像采集时,通过调整相机的曝光时间和感光度以及光照强度,使得采集界面磨削痕迹纹理清晰。利用 CCD 相机对螺杆表面进行拍摄,得到磨削表面的数据集。




图 3 图像采集系统

Fig.3 Image acquisition system

### 3 试验与结果分析

#### 3.1 数据集增强

试验后得到 500 组粗糙度数值和对应表面图片,就深度学习的回归预测而言,该数据集较小,模型容易过拟合,还会过分依赖于训练集中的少量样本,无法很好地泛化到整个数据分布区域。为增加模型的泛化能力和鲁棒性,对数据集进行数据增强。考虑 CNN 通过学习表面纹理特征实现粗糙度预测,数据增强采用旋转、缩放、裁剪、翻转,示例如图 4 所示。共得到 7500 个数量的数据集,将其按照 8 : 2 的比例随机分为训练集和测试集。

#### 3.2 图像预处理

为了让网络能够更高效、更专注地提取图像中的有用特征,对原始图像进行预处理操作,优化输入数据,消除干扰和冗余信息,增强图像的特征,为网络提供更好的输入,提高网络性能、减少




图 4 数据增强示例

Fig.4 Data enhancement examples

过拟合现象。考虑到主要提取特征为图像内纹理特征,且为适应网络整体训练效率,对图像进行增强对比度、增强清晰度和图像尺寸缩小的预处理操作。

考虑自适应直方图均衡化算法 (adaptive histogram equalization, AHE) 在提供较好对比度增强效果的同时,能够保留图像的细节和特征,采用该算法进行对比度增强。AHE 算法通过将图像划分为多个块,并在每个块内进行直方图均衡化操作来实现对比度增强。通过调整块大小和均衡化程度 (ClipLimit) 参数,可以控制均衡化的程度和处理效果,其计算公式如下。

计算每个块的累积直方图:

$$H(k) = \sum_{i=0}^k h(i) \quad (4)$$

计算直方图均衡化变换函数:

$$T(k) = \frac{L-1}{MN} H(k) \quad (5)$$

应用直方图均衡化变换函数:

$$b_{eq}(x, y) = T(f(x, y)) \quad (6)$$

其中,  $k$  表示当前灰度级别,  $h(i)$  表示灰度级别  $i$  的像素数量。  $L$  表示灰度级别的数量,  $M$  和  $N$  分别表示块的宽度和高度。  $b_{eq}(x, y)$  表示块中像素  $(x, y)$  增强后的像素值,  $f(x, y)$  表示块中像素  $(x, y)$  的原始像素值。通过式 (4) ~ 式 (6) 对每个块独立进行直方图均衡化操作,实现对图像的局部对比度增强。

由于拍摄工件为螺杆曲面,相机无法实现对整个拍摄区域的理想对焦,导致边缘区域较中心区域模糊。使用反锐化掩蔽 (unsharp masking) 对图像进行锐化处理,其原理是通过高斯滤波对原始图像进行模糊处理,创建一个模糊图像,根据模糊图像和原始图像之间的差异,增强边缘的对比度,提高图像的清晰度,计算公式如下:

$$y(n, m) = x(n, m) + \lambda z(n, m) \quad (7)$$

式中:  $x(n, m)$  为输入图像;  $y(n, m)$  为输出图像;  $z(n, m)$

为校正信号; $\lambda$  为控制增强效果的缩放因子。

为提高模型训练的收敛速度和结果的稳定性,将数值特征归一化到一个特定范围,采用最大最小缩放(minmax scaling)进行图像归一化处理,保留原始图像的信息,只将像素值从原始范围(0~255)映射到新的值范围(0~1)内,计算公式如下:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (8)$$

其中, $X_{norm}$  为归一化后的数据; $X$  为原始数据; $X_{max}$  为原始数据中的最大值; $X_{min}$  为原始数据中的最小值。

### 3.3 回归评价指标与超参数

权衡考虑网络训练精度和训练速度后,使用双线性插值法将分辨率 1280×960 的输入图片统一大小到 256×256,以保证不造成图像失真或丢失重要特征的同时缩短训练时间。基于 SA-CNN 网络的粗糙度预测为数值回归预测,通过衡量实际数值与预测值之间的误差大小,即通过损失函数来评估预测回归模型的准确性。

开始训练之前,需要设置网络超参数,合适的超参数能够提高模型预测精度,减少训练时间。模型的主要超参数如下:学习率决定了模型在训练过程中参数更新的步长;批量大小决定每次迭代训练时所使用的图像数量;正则化参数用于控制模型的复杂度;权重衰减系数影响模型的过拟合程度。经过试验调整确定超参数设置:优化器选用自适应梯度下降算法(adam);若批量大小(minibatchsize)较大可以提高训练速度,但占用计算内存资源较大,且容易过拟合;若批量大小较小则会增加训练时间且泛化性较差,权衡后设置为 32;初始学习率设置为 0.0001,最大迭代次数设置为 26 000;正则化参数(dropout)为 0.4,即训练过程中随机丢弃神经元个数比例。

### 3.4 预测结果分析

通过 SA-CNN 模型对螺杆粗糙度进行预测,按照 8:2 划分训练集和测试集,测试集共 1500 组数据,部分训练结果见表 2。表中测量值采用以下方式进行处理,在标定间隔磨削 2 min 位置进行粗糙度测量,采用 TR200 表面粗糙度测量仪(测量范围为 0.025~12.5  $\mu\text{m}$ ,最高显示分辨率为 0.001  $\mu\text{m}$ ),为了提高测量结果的稳定性和准确性,每个位置测量 3 次取平均值作为最终结果。

预测结果表明,模型平均预测误差为 4.76%,其中最小绝对误差为 0.0003  $\mu\text{m}$ ,最大绝对误差为 0.378  $\mu\text{m}$ ,绝对误差在 0.1  $\mu\text{m}$  以内的预测值占 85.4%,0.2  $\mu\text{m}$  以上的误差占 0.82%,均方根

表 2 表面粗糙度值预测误差

Tab.2 Error of surface roughness value prediction

编号	测量值/ $\mu\text{m}$	预测值/ $\mu\text{m}$	平均绝对误差 MAE/ $\mu\text{m}$	平均绝对 百分比误差 MAPE(%)
1	0.606	0.613	0.007	1.118
2	0.935	0.934	0.001	0.127
3	0.744	0.766	0.022	2.904
4	0.461	0.479	0.018	3.856
5	0.669	0.731	0.062	9.199
6	0.385	0.397	0.012	3.149
7	1.497	1.366	0.131	8.76
8	0.608	0.65	0.042	6.876
9	1.079	1.012	0.067	6.164
10	0.878	0.861	0.017	1.913
11	0.946	0.767	0.179	18.908
12	0.368	0.415	0.047	12.839
13	0.845	0.746	0.099	11.7
14	0.531	0.535	0.004	0.72
15	0.711	0.656	0.055	7.765
⋮	⋮	⋮	⋮	⋮
1486	0.543	0.688	0.145	26.634
1487	1.512	1.469	0.043	2.857
1488	0.368	0.431	0.063	17.203
1489	0.792	0.821	0.029	3.657
1490	1.039	0.878	0.161	15.497
1491	0.443	0.422	0.021	4.667
1492	0.508	0.563	0.055	10.888
1493	0.519	0.521	0.002	0.309
1494	0.511	0.507	0.004	0.698
1495	0.64	0.634	0.006	0.947
1496	0.865	0.853	0.012	1.439
1497	1.328	1.182	0.146	11.016
1498	0.616	0.711	0.095	15.408
1499	1.231	1.189	0.042	3.429
1500	0.537	0.58	0.043	7.916

误差(RMSE)为 0.0706,平均绝对百分比误差(MAPE)达到 7.4206%,总体预测误差较小。其预测误差范围的分布如图 5 所示。




图 5 表面粗糙度值预测误差分布

Fig.5 Distribution of error for the prediction of surface roughness value

为验证本文模型的准确性以及自注意力机制对 CNN 网络的影响,将数据集输入经典网络 ResNet、AlexNet、VGG-16、图神经网络 GNN 以

及未加入自注意力机制的基础 CNN 进行预测对比,部分预测结果如图 6 所示。预测精度分别为 85.6%、82.6%、88.9%、81.0% 和 83.5%,且最大绝对误差分别达到  $0.8235 \mu\text{m}$ 、 $0.6951 \mu\text{m}$ 、 $0.5391 \mu\text{m}$ 、 $1.0718 \mu\text{m}$  和  $0.7152 \mu\text{m}$ ,预测结果损失值见表 3,对比本文提出的 SA-CNN 模型,后者预测精度更高。

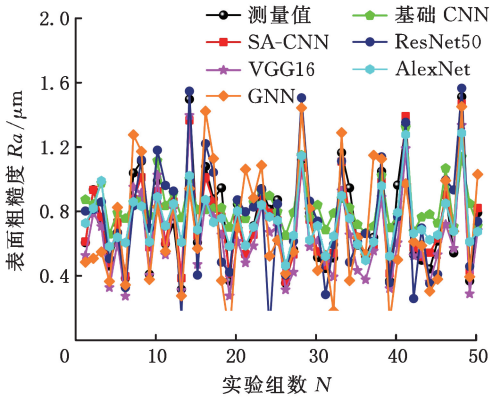


图 6 表面粗糙度值预测误差

Fig.6 Prediction error of surface roughness value

表 3 预测结果损失值对比

Tab.3 Comparison of prediction results of three methods

模型	平均绝对误差 MAE/ $\mu\text{m}$	平均绝对百分比误差 MAPE/%	均方根误差 RMSE/ $\mu\text{m}$
ResNet	0.143 38	26.3625	0.206 41
AlexNet	0.1736	32.7021	0.2376
VGG-16	0.1117	14.4198	0.1362
基础 CNN	0.1651	29.5025	0.2036
GNN	0.189 83	40.3244	0.280 34
SA-CNN	0.0476	7.4206	0.0706

本文模型与对比网络模型的损失曲线如图 7 所示。SA-CNN 的损失指数在约 100 次迭代后收敛到 0.3 以内,表明模型能够有效地学习数据特征,且损失值在训练过程中下降平稳,网络的学习可靠性和稳定性较高。在后续迭代稳定下降后最终损失值稳定在 0.05 以内。相比于基础 CNN 网络、经典网络和 GNN 网络,本文构建的预测模

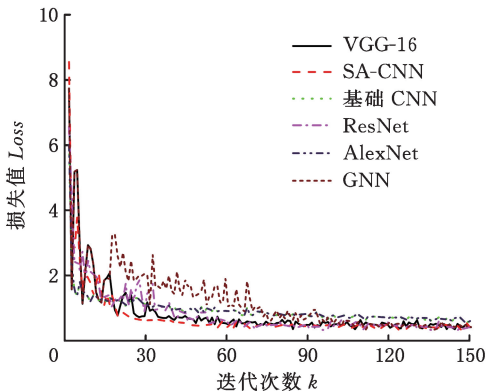


图 7 模型训练过程

Fig.7 Process of model training

型损失下降曲线收敛速度更快,收敛值更小,证明其具有较好的稳定性和泛化能力,能够准确实现表面粗糙度的预测。

## 4 结语

为准确便捷地测量复杂曲面类零件,本文使用 SA-CNN 预测模型对磨削表面粗糙度值进行预测,该模型以预处理后的工件表面图像为输入,以图像区域的表面粗糙度值作为预测结果输出。

通过螺杆转子磨削试验进行验证,本文预测模型的平均预测误差为 4.76%,其中最小绝对误差为  $0.0003 \mu\text{m}$ ,最大绝对误差为  $0.378 \mu\text{m}$ ,RMSE 值为  $0.0706 \mu\text{m}$ ,MAPE 值达到 7.4206%。为进一步验证本文模型的准确性,将模型预测结果与基础 CNN 网络、经典网络及 GNN 网络预测结果进行对比。其他模型的预测精度和最大绝对误差均逊于本文模型,且迭代收敛速度也低于本文模型,说明本文模型的预测精度更高。因此,本文构建的预测模型能够有效应用于工件表面粗糙度值预测,且简化了测量过程,可为其他复杂表面工件的表面粗糙度值测量提供参考。

## 参考文献:

- [1] 黄云,刘帅,黄涛,等. 钛合金材料砂带磨削表面残余应力形成模型及其实验研究[J]. 表面技术, 2020, 49(4):30-37.  
HUANG Yun, LIU Shuai, HUANG Tao, et al. Model of Residual Stress Formation on Belt Grinding Surface of Titanium Alloy and Experimental Research[J]. Surface Technology, 2020, 49(4):30-37.
- [2] 王军利,陆正午,李庆庆,等. 基于热分析的双螺杆压缩机转子的应力疲劳研究[J]. 机械强度, 2021, 43(4):928-935.  
WANG Junli, LU Zhengwu, LI Qingqing, et al. Research on Stress Fatigue of Twin Screw Compressor Rotor Based on Thermal Analysis[J]. Journal of Mechanical Strength, 2021, 43(4):928-935.
- [3] 路恩会,刘坚,王卫芳,等. 粗糙度关联的图像特征指标性能评价方法研究[J]. 仪器仪表学报, 2017, 38(8):2022-2029.  
LU Enhui, LIU Jian, WANG Weifang, et al. Study on the Performance Assessment Method of Image Indices Associated with Roughness [J]. Chinese Journal of Scientific Instrument, 2017, 38(8):2022-2029.
- [4] 杨赫然,孙兴伟,戚朋,等. 基于改进 BP 神经网络的螺杆转子铣削表面粗糙度预测[J]. 电子测量与仪器学报, 2022, 36(10):189-196.

- YANG Heran, SUN Xingwei, QI Peng, et al. Roughness Prediction of Spiral Surface Milling Based on Improved BP Neural Network[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(10):189-196.
- [5] 韩晓芹, 宋永锋, 刘雨, 等. 基于超声无损评价的表面粗糙度测量方法[J]. 中国机械工程, 2019, 30(8):883-889.
- HAN Xiaoqin, SONG Yongfeng, LIU Yu, et al. A Surface Roughness Measurement Method Based on Ultrasonic Nondestructive Evaluations [J]. China Mechanical Engineering, 2019, 30(8):883-889.
- [6] 袁尚勇, 陈根余, 戴隆州, 等. 电火花机械磨削修整粗粒度成形砂轮试验研究[J]. 中国机械工程, 2023, 34(10):1164-1171.
- YUAN Shangyong, CHEN Genyu, DAI Longzhou, et al. Experimental Research of Coarse-grained Forming Grinding Wheel Dressed by EDDG [J]. China Mechanical Engineering, 2023, 34(10):1164-1171.
- [7] 时强胜, 张小俭, 陈巍, 等. 基于灰色关联度分析-响应面法的橡胶软模端面抛磨表面粗糙度预测[J]. 中国机械工程, 2021, 32(24):2967-2974.
- SHI Qiangsheng, ZHANG Xiaojian, CHEN Wei, et al. Prediction of Surface Roughness of Rubber Soft Die End Face Polishing Based on GRA-RSM [J]. China Mechanical Engineering, 2021, 32(24):2967-2974.
- [8] 徐哲壮, 黄平, 陈丹, 等. 融合机器视觉与邻近度估计的相似工业设备识别策略研究[J]. 仪器仪表学报, 2023, 44(1):283-290.
- XU Zhezhuang, HUANG Ping, CHEN Dan, et al. Research on Similar Industrial Devices Recognition Strategy Based on Machine Vision and Proximity Estimation[J]. Chinese Journal of Scientific Instrument, 2023, 44(1):283-290.
- [9] 李聪波, 龙云, 崔佳斌, 等. 基于多源异构数据的数控铣削表面粗糙度预测方法[J]. 中国机械工程, 2022, 33(3):318-328.
- LI Congbo, LONG Yun, CUI Jiabin, et al. Surface Roughness Prediction Method of CNC Milling Based on Multi-source Heterogeneous Data[J]. China Mechanical Engineering, 2022, 33(3):318-328.
- [10] 刘桂雄, 廖普, 杨宁祥. 基于深度学习主动视觉压力容器焊缝质量参数检测方法[J]. 仪器仪表学报, 2023, 44(5):1-9.
- LIU Guixiong, LIAO Pu, YANG Ningxiang. Active Vision Pressure Vessel Weld Quality Parameter Detection Method Based on Deep Learning[J]. Chinese Journal of Scientific Instrument, 2023, 44(5):1-9.
- [11] LU Enhui, ZHANG Ruting, LIU Jian, et al. Observation of Ground Surface Roughness Values Obtained by Stylus Profilometer and White Light Interferometer for Common Metal Materials [J]. Surface and Interface Analysis, 2022, 54(6):587-599.
- [12] KARTHIKEYAN S, SUBBARAYAN M R, MATHAN K P, et al. Computer Vision-based Surface Roughness Measurement Using Artificial Neural Network [J]. Materials Today: Proceedings, 2022, 60:1325-1328.
- [13] XIA Chunyang, PAN Zengxi, POLDEN J, et al. Modelling and Prediction of Surface Roughness in Wire Arc Additive Manufacturing Using Machine Learning[J]. Journal of Intelligent Manufacturing, 2022, 33(5):1467-1482.
- [14] LU Enhui, LIU Jian, GAO Rongyu, et al. Designing Indices to Measure Surface Roughness Based on the Color Distribution Statistical Matrix (CDSM)[J]. Tribology International, 2018, 122:96-107.
- [15] LU Enhui, GUO Yaocun, ZHU Xinglong, et al. A New Grinding Surface Roughness Measurement Method Based on Image Quality Algorithm and BP Neural Network[J]. Surface Topography: Metrology and Properties, 2022, 10(4):045024.
- [16] FISCHER A. Capabilities and Limits of Surface Roughness Measurements with Monochromatic Speckles[J]. Applied Optics, 2023, 62(14):3724.
- [17] 易怀安, 方润基, 舒爱华, 等. 小样本问题下的铣削表面粗糙度测量[J]. 激光与光电子学进展, 2022, 59(23):2324001.
- YI Huaian, FANG Runji, SHU Aihua, et al. Milling Surface Roughness Measurement under Few-shot Problem [J]. Laser & Optoelectronics Progress, 2022, 59(23):2324001.
- [18] LU Enhui, REN Wenxiang, DAI Hongqing, et al. Investigations on Electromagnetic Wave Scattering Simulation from Rough Surface: Some Instructions for Surface Roughness Measurement Based on Machine Vision[J]. Precision Engineering, 2023, 82:156-168.
- [19] 杨晨, 方红萍, 邹凌云, 等. 基于色彩均匀敏感度的磨削表面粗糙度测量[J]. 机电工程, 2021, 38(6):755-761.
- YANG Chen, FANG Hongping, ZOU Lingyun, et al. Grinding Surface Roughness Measurement Based on Color Uniformity Sensitivity[J]. Journal of Mechanical & Electrical Engineering, 2021, 38(6):755-761.
- [20] CHEN Wei, ZOU Bin, ZHENG Qinbing, et al.

Research on the Sustainable Measurement of Machined Surface Roughness under the Influence of Cutting Environment[J]. The International Journal of Advanced Manufacturing Technology, 2023, 127(9):4697-4711.

- [21] HUANG Jiefeng, YI Huaian, SHU Aihua, et al. Visual Measurement of Grinding Surface Roughness Based on Feature Fusion[J]. Measurement Science and Technology, 2023, 34(10):105019.
- [22] VASANTH K, ELANANGAI V, ARULANANTH T S, et al. Machine Learning Based Metal Surface Roughness Estimation in Infrared Images[J]. Materials Today:Proceedings, 2023:1-8. <https://doi.org/10.1016/j.matpr.2023.03.394>.
- [23] FANG Runji, YI Huaian, WANG Shuai, et al. Classification and Inspection of Milling Surface Roughness Based on a Broad Learning System[J]. Metrology and Measurement Systems, 2022:483-503.
- [24] SU Jinzhao, YI Huaian, LING Lin, et al. Multi-object Surface Roughness Grade Detection Based on Faster R-CNN[J]. Measurement Science and Technology, 2023, 34(1):015012.
- [25] 安情楠. 基于加工表面显微图像的卷积神经网络粗糙度识别技术研究[D]. 西安:西安理工大学, 2019.
- AN Qiannan. Research on Roughness Recognition Technology of Convolutional Neural Network Based on Microscopic Image of Machining Surface [D]. Xi'an:Xi'an University of Technology, 2019.
- [26] 陈丽. 基于特征提取和卷积神经网络的铣削表面粗糙度检测方法研究[D]. 武汉:华中科技大学, 2019.

- CHEN Li. Research on Milling Surface Roughness Detection Method Based on Feature Extraction and Convolutional Neural Network[D]. Wuhan: Huazhong University of Science and Technology, 2019.
- [27] 陈仁祥, 詹赞, 胡小林, 等. 基于多注意力 Faster RCNN 的噪声干扰下印刷电路板缺陷检测[J]. 仪器仪表学报, 2021, 42(12):167-174.
- CHEN Renxiang, ZHAN Zan, HU Xiaolin, et al. Printed Circuit Board Defect Detection Based on the Multi-attentive Faster RCNN under Noise Interference[J]. Chinese Journal of Scientific Instrument, 2021, 42(12):167-174.
- [28] 杨东儒, 魏建文, 林雄威, 等. 基于自注意力机制的深度模拟电路故障诊断[J]. 仪器仪表学报, 2023, 44(3):128-136.
- YANG Dongru, WEI Jianwen, LIN Xiongwei, et al. A Fault Diagnosis Algorithm for Analog Circuits Based on Self-attention Mechanism Deep Learning[J]. Chinese Journal of Scientific Instrument, 2023, 44(3):128-136.

(编辑 陈 勇)

**作者简介:** 杨赫然, 男, 1983年生, 副教授、博士。研究方向为复杂曲面精密制造。E-mail: yangheran@sut.edu.cn。孙兴伟\* (通信作者), 女, 1970年生, 教授、博士研究生导师。研究方向为数控装备及理论。E-mail: sunxingw@126.com。

**本文引用格式:**

杨赫然, 张培杰, 孙兴伟, 等. 利用改进卷积神经网络的螺杆砂带磨削表面粗糙度预测[J]. 中国机械工程, 2025, 36(2):325-332.

YANG Heran, ZHANG Peijie, SUN Xingwei, et al. Surface Roughness Prediction for Screw Belt Grinding Based on Improved CNN[J]. China Mechanical Engineering, 2025, 36(2):325-332.

(上接第 324 页)

- [28] ZHU Yaguang, ZHOU Shuangjie, GAO Dongxiao, et al. Synchronization of Non-linear Oscillators for Neurobiologically Inspired Control on a Bionic Parallel Waist of Legged Robot[J]. Frontiers in Neurorobotics, 2019, 13:59.
- [29] GIBSON G, DOSUNMU-OGUNBI O, GONG Yukai, et al. Terrain-Adaptive, ALIP-based Bipedal Locomotion Controller via Model Predictive Control and Virtual Constraints[C]// 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems(IROS). Kyoto, 2022:6724-6731.
- [30] SUN Yu, UBELLACKER W L, MA W L, et al. Online Learning of Unknown Dynamics for Model-based Controllers in Legged Locomotion[J]. IEEE Robotics and Automation Letters, 2021, 6(4):

8442-8449.

(编辑 陈 勇)

**作者简介:** 刘春潮, 男, 1998年生, 博士研究生。研究方向为仿生机器人、控制理论。E-mail: liuchunchao@chd.edu.cn。朱雅光\* (通信作者), 男, 1986年生, 教授、博士研究生导师。研究方向为控制理论、机器人技术、智能检测与模式识别、机电系统开发与信号分析、嵌入式系统开发与系统集成、人工智能技术。E-mail: zhuyaguang@chd.edu.cn。

**本文引用格式:**

刘春潮, 朱雅光, 周亚婷, 等. 基于虚拟运动神经系统的六足机器人自适应运动控制[J]. 中国机械工程, 2025, 36(2):315-324.

LIU Chunchao, ZHU Yaguang, ZHOU Yating, et al. Adaptive Impedance Control of Hexapod Robots Based on Virtual Motoneuron System[J]. China Mechanical Engineering, 2025, 36(2):315-324.