

DOI: 10.19650/j.cnki.cjsi.J2513775

考虑动态因素影响的机器人磨削表面粗糙度预测*

郭万金^{1,2,3}, 郝钦磊¹, 徐明坤¹, 曹维清^{2,4}, 赵立军^{2,5}, 王力⁶

(1. 长安大学道路施工技术与装备教育部重点实验室 西安 710064; 2. 长三角哈特机器人产业技术研究院 芜湖 241007; 3. 埃夫特智能机器人股份有限公司 芜湖 241060; 4. 安徽工程大学计算机与信息学院 芜湖 241000; 5. 哈尔滨工业大学机器人研究所 哈尔滨 150001; 6. 北京理工大学机械与车辆学院 北京 100081)

摘要: 机器人磨削过程受到动态因素与静态因素的综合影响, 具有复杂耦合、高度时变非线性等动态特性。为解决动态因素特征选择困难与仅考虑静态因素致使表面粗糙度预测精度低的问题, 结合深度学习技术, 提出一种考虑动态因素影响的机器人磨削表面粗糙度预测方法。首先, 利用卷积神经网络自动提取磨削过程中动态因素的空间特征, 捕捉机器人磨削的复杂动态行为; 通过双向长短期记忆网络从获得的空间特征中提取时序特征, 表征机器人磨削的动态变化; 引入注意力机制实现空间特征、时序特征和静态因素的自动权重分配; 利用改进的鲸鱼优化算法自适应优化双向长短期记忆网络的超参数, 提高收敛速度和适应机器人磨削动态变化。其次, 根据所提预测方法, 构建一种考虑动态因素影响的 IWOA-CNN-BiLSTM-Attention 表面粗糙度预测模型。再次, 开展机器人磨削加工实验, 将提取的动态因素空间特征和时序特征、采集的静态因素和表面粗糙度测量值归一化处理, 构建实验数据集。最后, 将实验数据集输入预测模型进行模型训练, 实现同时考虑动态因素和静态因素的机器人磨削表面粗糙度预测; 并通过对比实验验证所提预测方法的有效性, 其对应预测模型的平均绝对百分比误差、均方根误差和决定系数分别为 0.027 6、0.029 5 和 0.998 8, 与对比预测模型相比, 预测精度分别提高 17.14%、13.65% 和 21.35%。

关键词: 机器人磨削; 表面粗糙度预测; 动态因素; 静态因素; 深度学习

中图分类号: TP242.2 TH161+.1 **文献标识码:** A **国家标准学科分类代码:** 460.5030

Dynamic factor-influenced surface roughness prediction in robotic grinding

Guo Wanjin^{1,2,3}, Hao Qinlei¹, Xu Mingkun¹, Cao Chuqing^{2,4}, Zhao Lijun^{2,5}, Wang Li⁶

(1. Key Laboratory of Road Construction Technology and Equipment, Ministry of Education, Chang'an University, Xi'an 710064, China; 2. Yangtze River Delta HIT Robot Technology Research Institute, Wuhu 241007, China; 3. EFORT Intelligent Robot, Co., Ltd., Wuhu 241060, China; 4. School of Computer and Information, Anhui Polytechnic University, Wuhu 241000, China; 5. Robotics Institute of Harbin Institute of Technology, Harbin 150001, China; 6. School of Mechanical Engineering, Beijing Institute of Technology, Beijing 100081, China)

Abstract: The robotic grinding process is affected by both dynamic and static factors and has dynamic characteristics such as complex coupling and high time-varying nonlinearity. To solve the problems of difficult feature selection of dynamic factors and low prediction accuracy of surface roughness caused by only considering static factors, a prediction method of surface roughness of robotic grinding considering the influence of dynamic factors is proposed by combining deep learning technology. Firstly, the convolutional neural network is used to automatically extract the spatial features of dynamic factors in the grinding process, and capture complex dynamic behaviors of robotic grinding. The temporal features are extracted from the obtained spatial features through the bidirectional long short-term memory network to characterize the dynamic changes of robotic grinding. The attention mechanism is introduced to realize the automatic weight distribution of spatial features, temporal features and static factors. The improved whale optimization algorithm is used to adaptively

收稿日期: 2025-02-26 Received Date: 2025-02-26

* 基金项目: 国家自然科学基金面上项目 (52275005)、中央高校基本科研业务费专项资金项目 (300102253201)、中国博士后科学基金项目 (2024M760002)、安徽博士后科研项目 (2023B675)、芜湖市重点研发与成果转化项目 (2023yf044) 资助

optimize the hyperparameters of the bidirectional long short-term memory network to improve the convergence speed and adapt to the dynamic changes of robotic grinding. Secondly, according to the proposed prediction method, an IWOA-CNN-BiLSTM-Attention surface roughness prediction model considering the influence of dynamic factors is formulated. Thirdly, the robotic grinding experiment is carried out. The spatial and temporal characteristics of the extracted dynamic factors, the collected static factors, and the measured values of surface roughness are normalized to construct the experiment dataset. Finally, the experimental dataset is input into the prediction model for model training, and the surface roughness prediction of robotic grinding considering both dynamic and static factors is realized. The effectiveness of the proposed method is evaluated by comparative experiments. The mean absolute percentage error, root mean square error, and coefficient of determination of the corresponding prediction model are 0.027 6, 0.029 5, and 0.998 8, respectively. Compared with the comparison prediction model, the prediction accuracy is improved by 17.14%, 13.65%, and 21.35%, respectively.

Keywords: robotic grinding; surface roughness prediction; dynamic factors; static factors; deep learning

0 引言

机器人磨削是现代先进制造领域的重要分支^[1-6],因其具有高柔性、高适应性、加工效率显著和自动化程度高等优势,在航空航天、汽车制造及精密模具等领域广泛应用。然而,与数控机床相比,机器人磨削受到主轴转速、进给速度、磨削深度、磨料粒度等静态因素^[7-8]和磨削力信号、振动信号等动态因素的综合影响,具有更为显著的复杂耦合、高度时变非线性等动态特性,极易发生机器人颤振^[9-10],影响加工过程的稳定性和工件表面加工质量,且其影响机制复杂,通常难以准确表述。

在机器人磨削中,表面粗糙度是衡量加工质量的重要指标^[11-12],直接影响工件的功能和使用寿命。由于磨削过程的复杂耦合时变非线性特性,表面粗糙度与磨削过程中的如磨削力信号、振动信号、噪声等动态因素密切相关。通常在加工质量研究中假设磨削工艺参数在整个过程中恒定,而忽略动态因素产生的动态变化对工件表面质量造成的波动性和非均匀性影响。分析动态因素对机器人磨削表面粗糙度的影响,并构建高精度的表面粗糙度预测模型,研究表面粗糙度预测方法,对提升机器人磨削质量具有重要作用。然而,机器人磨削动态因素具有复杂耦合、高度非线性特性,传统的经验公式和理论模型难以准确表征。基于人工智能技术的表面粗糙度预测^[13],挖掘表面粗糙度与关键磨削工艺参数的动态因素及静态因素之间的隐性关联,为优化机器人磨削工艺和实现高质量加工提供了新的解决方案。

专家学者基于人工智能技术对表面粗糙度预测开展了诸多研究。Yang等^[14]系统总结用于加工表面粗糙度预测的各种人工智能方法。Pan等^[15]引入批量标准化和Dropout提高表面粗糙度预测模型的泛化能力。Duan等^[16]提出一种混合注意力机制并行深度学习模型用于表面粗糙度预测。Boga等^[17]提出一种人工神经网络(artificial neural network, ANN)与遗传算法(genetic

algorithm, GA)分析不同加工参数对高强度碳纤维复合材料表面粗糙度的影响。Yang等^[18]提出一种基于图像修复和卷积神经网络模型的抗干扰表面粗糙度检测方法。Yao等^[19]提出一种基于极限学习机算法的叶片根部表面粗糙度预测方法。Wang等^[20]提出一种基于知识的人工神经网络(knowledge-based artificial neural networks, KBANN)和径向基函数(radial basis function, RBF)结合的预测方法开展球头铣削加工表面粗糙度预测。Wang等^[21]提出一种引入深珊瑚函数优化生成对抗网络(generative adversarial network, GAN)的数据增强方法,开展工件表面粗糙度预测研究。Lai等^[22]基于线性回归和多种结构的人工神经网络构建一种表面粗糙度预测模型。

路恩会等^[23]提出一种基于全参考彩色图像质量算法的粗糙度测量方法。惠记庄等^[24]提出一种基于麻雀算优化法(sparrow search algorithm, SSA)和双向长短期记忆网络结合(Bi-directional long short-term memory, BiLSTM)的表面粗糙度预测方法。李昌龙等^[25]通过全因素实验构建一种基于粒子群优化和极限学习机的模型,预测研磨表面粗糙度。辛明泽等^[26]利用改进的北方苍鹰搜索算法(improved northern goshawk search algorithm, INGO)优化反向传播(back propagation, BP)神经网络,用于螺杆转子表面粗糙度预测。杨赫然等^[27]提出一种基于自注意力卷积神经网络方法,用于预测螺杆砂带磨削后的表面粗糙度。陈佳琳等^[28]提出一种结合深度残差收缩网络和双向长短期记忆网络(BiLSTM)的方法,预测铣削加工表面粗糙度。陈超逸等^[29]提出一种双深度Q网络(double DQN, DDQN)和支持向量回归(support vector regression, SVR)结合的方法预测45钢表面粗糙度。柳想等^[30]利用响应面法(response surface methodology, RSM)和GA-BP-ANN模型研究铝棒表面机械滚压工艺参数优化及对表面粗糙度的影响。

尽管上述研究探讨了磨削工艺参数对表面粗糙度的影响,但文献[16, 19-21, 26-30]主要面向机床磨削研究,且

在一定程度上存在局限和不足;文献[17,21-22,26,30]只考虑静态因素对表面粗糙度预测的影响,忽略动态因素对表面粗糙度的影响,且未考虑各因素之间的交互作用,限制了模型的预测精度;文献[14,17]需要对光源和在线/离线进行设置,适用性和灵活性不高;文献[26,30]采用BP 神经网络算法对表面粗糙度进行预测,模型结构简单,特征自动提取能力较弱。这些研究处理复杂系统时存在局限性,在机器人磨削过程中仅考虑静态因素的影响,而忽略动态因素对表面粗糙度预测的影响,且在特征提取过程中往往依赖于人工提取特征,自适应能力不足,容易丢失重要信息,预测精度较低。深度学习能够处理高维数据,自动提取特征,减少人为干预,提高预测和优化的准确性,然而文献[17,24,28]指出许多深度学习模型需要调整大量的超参数,过程往往依赖于试错,效率低且难以获得最优解。

为解决动态因素特征选择困难与仅考虑静态因素致使表面粗糙度预测精度低的问题,提出一种考虑动态因素影响的机器人磨削表面粗糙度预测方法,提高机器人磨削表面粗糙度预测的准确性。首先,针对机器人磨削过程中动态因素特征提取困难、且动态因素对表面粗糙度预测影响较大的问题,采用卷积神经网络(convolutional neural networks, CNN)对磨削过程中的动态因素自动提取其空间特征,并采用 BiLSTM 从获得的空间特征进行时序特征提取,同时引入注意力机制(Attention)自动分配空间特征、时序特征和静态因素的权重,聚焦于重要特征;采用改进的鲸鱼优化算法(improved whale optimization algorithm, IWOA)自适应优化 BiLSTM 超参数,提高收敛速度和适应加工动态变化。其次,根据所提方法,构建一种考虑动态因素影响的 IWOA-CNN-BiLSTM-Attention 表面粗糙度预测模型。再次,选取磨削力信号和振动信号作为动态因素,主轴转速、进给速度、磨削深度、磨料粒度作为静态因素,开展机器人磨削实验,对动态因素所提取特征和采集的静态因素归一化处理,结合测量的表面粗糙度值构建实验数据集,将数据集按 80% 和 20% 划分为训练集和测试集,开展所构建表面粗糙度预测模型训练,实现同时考虑动态因素和静态因素的机器人磨削表面粗糙度预测。最后,对比其他预测方法,验证所提考虑动态因素影响的机器人磨削表面粗糙度预测方法的有效性。

1 机器人磨削表面粗糙度预测方法

为解决机器人磨削过程中动态因素特征选择困难与仅考虑静态因素致使表面粗糙度预测精度低的问题,提出一种考虑动态因素影响的机器人磨削表面粗糙度预测方法,结合深度学习技术(包括 CNN、BiLSTM、Attention

与 IWOA),充分利用动态因素的空间特征和时序特征及静态因素信息,实现同时考虑动态因素和静态因素的机器人磨削表面粗糙度高精度预测。

1.1 磨削过程动态因素的空间特征自提取

在机器人磨削过程中,针对动态因素具有复杂耦合、高度非线性特征,采用人工特征提取和 CNN 进行动态因素的空间特征自提取,提高表面粗糙度预测的精度。

常见的人工特征提取包括选取信号的均值、标准差、均方根、峭度、偏度、能量熵和功率谱密度等,这些人工特征通常能够反映信号的一些基本统计特性与时域和频域特征(如表 1 所示),然而它们仍然无法全面捕捉到动态信号中的复杂耦合时变特性和深层次的非线性关系。

表 1 人工特征提取计算
Table 1 Artificial feature extraction calculation

特征参数	计算公式
均值	$y_1 = \frac{1}{N} \sum_{i=1}^N x(i)$
标准差	$y_2 = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x(i) - y_1)^2}$
均方根	$y_3 = \sqrt{\frac{1}{N} \sum_{i=1}^N x(i)^2}$
峭度	$y_4 = \frac{\sum_{i=1}^N (x(i) - y_1)^4}{(N-1)y_2^4}$
偏度	$y_5 = \frac{\sum_{i=1}^N (x(i) - y_1)^3}{(N-1)y_2^3}$

采用中值滤波对信号降噪处理,保留信号本质特征使特征提取过程更精确。结合信噪比(signal-to-noise ratio, SNR),确定最佳窗口大小,实现高效降噪,信号预处理如图 1 所示。信噪比与窗口大小关系如图 1(a)所示,当窗口大小为 19 时,信噪比为最大值 13 dB,此窗口大小时中值滤波效果如图 1(b)所示,此时信号更强,噪声的影响更小,能更精确还原原始信号,原始信号如图 1(c)所示。

采用改进的鲸鱼优化算法,优化 2 层卷积核大小和滤波器数量,提升卷积神经网络在动态因素特征提取任务中的性能,减少人工干预。卷积核和滤波器上界分别设为 9 和 512,下界分别设为 1 和 16;优化过程中以动态因素最小信息熵作为适应度函数,信息熵越小,信号的特征越集中。优化后的 2 层卷积核大小分别为 5 和 3,滤波器数量分别为 32 和 64。




图 1 信号预处理
Fig.1 Signal preprocessing

利用 CNN 对经过中值滤波处理后的信号进行空间特征提取,将人工提取的特征作为 CNN 额外的通道输入,使所提取特征包含信号在磨削过程中的分布特性和复杂非线性关系。CNN 动态因素特征提取流程如图 2 所示,包含 2 层卷积层、2 层最大池化层 (max pooling)、1 层 Dropout 层和 2 层全连接层。卷积核在时间维度和特征维度的大小分别为 2 和 1。2 层最大池化层 (max pooling),pool_size 均为 2。采用 ReLU 激活函数,捕捉信号中的非线性关系。Dropout 层丢弃概率设置为 0.5,在训练过程中随机丢弃一些神经元,以防止过拟合,提高模型的泛化能力。CNN 网络参数设置如表 2 所示。

表 2 卷积神经网络参数						
Table 2 Convolutional neural network parameters						
网络结构	核大小	步长	核数目	输出	激活函数	填充
卷积层	5	2	32	256×32	ReLU	same
池化层	2	1	32	128×32		无
卷积层	3	1	64	32×64	ReLU	无
池化层	2	1	64	16×64		same
第 1 层全连接层	512	1	1	512×1	ReLU	无
第 2 层全连接层	256	1	1	256×1	ReLU	无

为进一步提升特征提取的准确性,引入注意力机制 (Attention),有效捕捉机器人磨削过程中突然的负载变化、振动幅度的异常波动等对表面粗糙度预测影响较大




图 2 动态因素特征提取
Fig.2 Dynamic factor feature extraction

因素,为不同特征分配不同的权重,使 CNN 更加精确地表达信号中的复杂关系。

1.2 磨削过程动态因素的时序特征提取

采用 BiLSTM 对机器人磨削中复杂动态因素提取时序特征,然而,其超参数的设置对其性能有较大影响。通常方法如网格搜索效率低且易陷局部最优,采用改进的 IWOA^[31] 自适应优化 BiLSTM 超参数,提升预测精度。

通过对鲸鱼优化算法 (whale optimization algorithm, WOA) 引入改进的 Tent 混沌映射初始化种群策略,增强初始种群多样性,采用精英反向学习策略保留最优解,并

引入自适应权重因子动态调整搜索能力,其综合性能尤其适用于高维、多峰、含噪声的复杂优化场景,增强对磨削过程的整体预测能力,使表面粗糙度预测能更好地适应磨削中的动态变化,提升预测精度。

通过 IWOA 对 BiLSTM 进行超参数自适应优化,获得最优的学习率、隐藏层节点和 L2 正则化系数超参数组合,具体流程如下。

1) 种群初始化与优化策略:利用改进的 Tent 混沌映射初始化种群策略和引入自适应权重因子,动态调整个体位置 X ,以更好地探索全局最优解。

改进的 Tent 混沌映射初始化种群策略表达为 z_{k+1} , 即:

$$z_{k+1} = \begin{cases} 2(z_k + 0.1 \text{rand}(0,1)), & 0 \leq z_k < 1 \\ 2 - 2(z_k + 0.1 \text{rand}(0,1)), & 0.5 \leq z_k \leq 1 \end{cases} \quad (1)$$

式中: k 为映射次数; z_k 为第 k 次的函数值。

自适应权重因子 ω 表达为:

$$\omega = \sin\left(\frac{\pi t}{2T_{\max}} + \pi\right) + 1 \quad (2)$$

式中: $T_{\max}$ 为最大迭代次数; t 为当前迭代次数。

2) 个体位置更新: 根据随机生成的 p 值与预定阈值 $|A|$ 的比较结果, 更新优化个体位置, 更新后的个体位置 $X(t+1)$ 表示为:

$$X(t+1) = \omega X^*(t) - A \cdot D, \quad |A| \leq 1, p < 0.5 \quad (3)$$

$$X(t+1) = \cos(2\pi l) e^{bl} D' + \omega X^*(t), \quad p \geq 0.5 \quad (4)$$

$$X(t+1) = \omega X_{\text{rand}} - A \cdot D, \quad |A| > 1, p < 0.5 \quad (5)$$

式中: A 为系数向量; D 和 D' 为距离向量, 表示当前个体与最优个体之间的距离; $X^*(t)$ 为当前最优解的位置向量, 在每次计算过程中出现最优解时都需要更新 X^* ; b 用于定义对数螺旋形状; l 为 $[0, 1]$ 的随机数; X_{rand} 表示随机选中的鲸鱼个数位置。

3) 精英个体选择与反向学习: 利用精英反向学习策略从种群中选择精英个体, 并生成其反向位置 r_p , 将精英个体和反向位置结合, 生成新种群, 评估并更新最佳位置及其适应度值, 确保算法在搜索过程中始终保留最优解, 反向位置 r_p 表示为:

$$r_p = -e_p + 2 \times \text{rand}(n_e, \text{dim}) \times (u_b - l_b) \quad (6)$$

式中: e_p 为从初始种群中每个精英个体的位置; n_e 为初始种群中精英个体数量; u_b 和 l_b 分别为参数优化的上界和下界。

在 BiLSTM 初期, 以预测值和实际值之间的均方根误差 (root mean square error, RMSE) 作为适应度函数; 学习率、隐藏层节点数和 L2 正则化系数的上界分别设置为 0.1、80 和 0.1, 下界分别设置为 0.001、70 和 1×10^{-5} 。利用改进的 IWOA 更新种群中个体的位置, 调整 BiLSTM 的超参数组合。设定最大迭代次数 (MaxEpochs) 为 100, 批处理大小 (MiniBatchSize) 为 32, 学习率衰减因子 (LearnRateDropFactor) 为 0.5, 通过评估个体的 RMSE 值, IWOA 能够选择最优个体, 并引导其他个体向最优解收敛, 直到达到最大迭代次数或适应度函数收敛。

通过上述自适应优化, 最终得到双向长短期记忆网络 (BiLSTM) 的最佳超参数组合, 优化后的超参数如表 3 所示。

通过自适应优化策略, 增强双向长短期记忆网络 (BiLSTM) 对动态因素的处理能力, 增强对不同磨削条件的适应性, 提升表面粗糙度预测精度。

表 3 BiLSTM 优化后超参数

Table 3 Optimized BiLSTM hyperparameters

超参数	最佳参数
学习率	0.01
隐藏层节点	78
L2 正则化系数	0.000 3

1.3 预测方法评价指标设定

在评估表面粗糙度预测模型性能时, 采用 3 种常用的评价指标, 平均绝对百分比误差 (mean absolute percentage error, MAPE)、均方根误差 (root mean square error, RMSE) 和决定系数 (coefficient of determination, R^2)。其中, 前两者用于评价模型预测值与实际值之间的差异。

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}}{y_i} \right| \times 100\% \quad (7)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y})^2} \quad (8)$$

$$R^2 = 1 - \sum_{i=1}^n (y_i - \hat{y}_i)^2 / \sum_{i=1}^n (\bar{y}_i - \hat{y}_i)^2 \quad (9)$$

式中: y_i 表示测试集, 即该时刻输出的实际值; $\hat{y}$ 表示预测值; n 为测试集的测试样本数; $\bar{y}$ 表示预测样本与实际值的平均值, 其中 $i = 1, 2, \dots, n$ 。

MAPE 和 RMSE 用于评价模型预测值与实际值之间的差异, 其值越小, 表示预测误差越小, 模型的预测精度越高。 R^2 用于评估模型对数据的拟合程度, 其值越接近 1, 表明模型对数据的解释能力越强, 拟合效果越好。

1.4 表面粗糙度预测方法与预测模型构建

为解决机器人磨削过程中动态因素特征选择困难与仅考虑静态因素致使表面粗糙度预测精度低的问题, 结合深度学习技术与 IWOA, 并充分考虑机器人磨削过程中动态因素与静态因素的影响, 提出一种考虑动态因素影响的机器人磨削表面粗糙度预测方法。

将所提考虑动态因素影响的机器人磨削表面粗糙度预测方法构建为一种 IWOA-CNN-BiLSTM-Attention 表面粗糙度预测模型。该模型可有效表征机器人磨削过程中复杂耦合、高度时变非线性特性, 特别是在动态因素和静态因素的动态性和复杂性综合影响下, 能够充分挖掘并利用这些信息, 提高表面粗糙度预测的准确性。

所构建预测模型由动态因素降噪处理、动态因素空间特征提取、动态因素时序特征提取、表面粗糙度预测 4 个核心模块组成, 预测模型构成示意图如图 3 所示。该预测模型具体包括 2 层卷积层、4 层 BiLSTM 层、1 个注意力机制层、1 个 Dropout 层和 2 个全连接层。首层卷积层配置 [5, 1] 卷积核和 32 个滤波器, 次层卷积层配置

[3, 1] 卷积核和 64 个滤波器,均采用 RuLU 激活函数。BiLSTM 模型由 4 个单元层组成,单元数分别设置为 100、110、90 和 90,时间步长设置为 50,用于捕捉动态因素的宏观波动,提高特征提取能力。连接注意力机制层,向全局特征分配权重,聚焦于对表面粗糙度预测影响较大的特征信息。最终通过首层为 512 节点 (ReLU 激活),次层 256 节点 (ReLU 激活) 的 2 层全连接层输出表面粗糙度预测值。




图 3 预测模型构成示意图
Fig.3 Diagram of the prediction model

所构建的 IWOA-CNN-BiLSTM-Attention 表面粗糙度预测模型对应流程如图 4 所示。

- 1) 数据预处理:在模型训练之前,将测量数据进行降噪和归一化处理,确保模型能够准确捕捉到关键信息和特征。
- 2) 动态因素特征提取:采用 CNN 进行空间特征提取,将人工提取特征作为卷积神经网络额外输入通道,进行动态因素空间特征提取;采用 IWOA 自适应优化 BiLSTM 的超参数,将空间特征经过 4 层 BiLSTM 层,深层次提取时序特征,捕捉数据中短期和长期波动变化,增强对磨削过程动态特性的理解,提高模型处理效率和预测精度。
- 3) 动态因素所提取的空间特征和时序特征与静态因素融合:引入注意力机制,动态调整空间特征、时序特征和静态因素的权重分配,聚焦于对表面粗糙度预测影响

- 较大的特征信息。
- 4) 构建 IWOA-CNN-BiLSTM-Attention 表面粗糙度预测模型:根据所提预测方法,构建 IWOA-CNN-BiLSTM-Attention 表面粗糙度预测模型,输入实验数据集,输出表面粗糙度预测值,完成表面粗糙度预测。
 - 5) 预测模型评估与验证:采用 MAPE、RMSE 和 R^2 对模型进行评估,验证所构建预测模型的有效性和准确性。
- 表面粗糙度作为衡量磨削质量的核心指标,受动态因素和静态因素的综合影响。所构建的 IWOA-CNN-BiLSTM-Attention 预测模型,可有效解决动态因素特征选择困难与仅考虑静态因素致使表面粗糙度预测精度低的问题,避免人工特征提取可能造成的信息丢失,可提高机器人磨削表面粗糙度预测的精度。




图4 机器人磨削表面粗糙度预测模型流程

Fig. 4 Flow chart of the robotic grinding surface roughness prediction model

2 机器人磨削实验与工艺参数分析

通过搭建机器人磨削实验平台,选定磨削工艺参数范围,利用 ABB-IRB4600 六自由度工业机器人对 C45 钢进行磨削实验,采集机器人磨削过程中的动态因素和静态因素,将动态因素提取的动态因素空间特征和时序特征、采集的静态因素和测量的表面粗糙度值构建为实验数据集,并将实验数据集乱序处理,按 80% 和 20% 划分为训练集和测试集。

2.1 机器人实验平台

为获得预测模型所需实验数据集,搭建如图 5 所示机器人磨削实验平台。实验平台主要由 ABB-IRB4600 六自由度工业机器人、GDZ-14 电主轴、ATI IP-65 六轴力/力矩传感器(采集磨削力信号)、YDI 621-2 振动加速度传感器(采集振动信号)、VK701 H+数据采集卡(采样频率为 10 000 Hz)、TR200 表面粗糙度仪、纤维抛光轮(125 mm×16 mm×12.7 mm)组成。YDI 621-2 振动加速度传感器安装时,X 轴垂直于进给速度方向(方向向上),Y 轴沿进给速度方向,Z 轴沿工件表面外法线方向。




图5 机器人磨削实验平台

Fig. 5 Robotic grinding experimental platform

选用 C45 钢板作为实验工件,在 400 mm×350 mm 平面上开展机器人磨削实验。表 4 为实验用 C45 钢的综合性能。

表 4 C45 钢综合性能

Table 4 Comprehensive properties of C45 steel

抗拉强度/ MPa	屈服强度/ MPa	伸长率/ %	截面收缩率/ %	冲击能/ J
600	355	16	40	39

2.2 机器人磨削实验设计与分析

机器人磨削实验中,分析不同主轴转速 n 、进给速度 V_w 、磨削深度 a_p 和磨料粒度 Q 对 C45 钢板实验工件磨削表面粗糙度的影响。依据机器人磨削行业内常用的磨削参数水平,选取机器人磨削实验工艺参数如表 5 所示,共构成 256 个磨削工艺参数组合,在 C45 钢板实验工件上每个磨削区域段尺寸为 20 mm×16 mm,工件磨削效果如图 6 所示,图 6(a) 和 (b) 分别为第 1~56 组磨削效果和第 201~256 组磨削效果。

表 5 磨削实验工艺参数

Table 5 Experimental process parameters

磨削工艺参数	数值
主轴转速 $n/(\text{r}\cdot\text{min}^{-1})$	1 800、2 100、2 400、2 700
进给速度 $V_w/(\text{mm}\cdot\text{s}^{-1})$	0.08、0.16、0.24、0.32
磨削深度 a_p/mm	0.01、0.02、0.03、0.04
磨料粒度 Q	320 [#] 、600 [#] 、800 [#] 、1 000 [#]




图 6 工件磨削效果

Fig. 6 Grinding effect drawing of workpiece

使用 TR200 表面粗糙度仪对每个磨削区域均匀取 5 个测量点,取平均值作为该磨削区域的表面粗糙度测量值,不同实验因素组合下表面粗糙度测量值如表 6 所示。

表 6 实验因素综合表

Table 6 Comprehensive table of experimental factors

组号	主轴转速 $n/(\text{r}\cdot\text{min}^{-1})$	进给速度 $V_w/(\text{mm}\cdot\text{s}^{-1})$	磨削深度 a_p/mm	磨料粒度 Q	表面粗糙度 $Ra/\mu\text{m}$
1	1 800	0.08	0.01	320 [#]	0.61 042
2	2 100	0.08	0.01	320 [#]	0.593 43
3	2 400	0.08	0.01	320 [#]	0.617 64
4	2 700	0.08	0.01	320 [#]	0.662 42
⋮	⋮	⋮	⋮	⋮	⋮
253	1 800	0.32	0.04	1 000 [#]	1.294 62
254	2 100	0.32	0.04	1 000 [#]	1.210 41
255	2 400	0.32	0.04	1 000 [#]	1.318 80
256	2 700	0.32	0.04	1 000 [#]	1.421 63

为降低噪声对信号的干扰,对所有信号数据中值滤波处理,减小磨削过程中的信号波动,保留数据的关键特征。并对所有采集到的数据归一化处理,确保输入数据的一致性,避免量纲差异对模型训练的影响。动态因素根据采用频率设置特征采样点,将其作为一维特征向量输入到 CNN 一个分支,将信号 X 、 Y 和 Z 方向根据表 1 人工提取的时域、频域和时频域共 18 个特征输入 CNN 另一分支,通过 CNN 模型对两个分支进行空间特征提取,然后输入 BiLSTM 模型进行时序特征提取。将处理后的数据用于构建实验数据集,并将数据按 80% 和 20% 划分为训练集和测试集。

处理后的数据用于构建实验数据集,为验证所提表面粗糙度预测方法的有效性和对比实验分析的开展提供可靠的实验数据基础。

3 表面粗糙度预测方法验证

为验证所提方法构建的 IWOA-CNN-BiLSTM-Attention 表面粗糙度预测模型的预测性能,将其与 WOA-CNN-BiLSTM-Attention、冠豪猪优化算法 (crested porcupine optimizer, CPO) 优化 BiLSTM 模型构建的 CPO-CNN-BiLSTM-Attention 和 GA-BP 3 种预测方法进行对比,将 4 种预测模型分别简称为预测模型 A、B、C 和 D。在训练阶段,所有模型均使用包含动态因素和静态因素的相同数据集,并以 80% 和 20% 划分为相同的训练集和测试集,开展表面粗糙度预测。

预测结果对比分析中,将绝对误差表示为 E_a ,其最大值表示为 $E_{a\max}$;相对误差表示为 E_r ,其最大值表示为 $E_{r\max}$ 。预测模型 A、B、C 和 D 的预测值与实际值如表 7 所示,预测模型 A、B、C 和 D 的预测效果对比如图 7 所示。

表 7 预测模型 A、B、C 和 D 的预测值与实际值

Table 7 Predicted values and actual values for prediction models A, B, C and D (μm)

序号	模型 A 预测值	模型 B 预测值	模型 C 预测值	模型 D 预测值	实际值
1	0.618 18	0.649 17	0.634 04	0.675 85	0.644 60
2	1.217 44	1.131 83	1.172 67	1.155 02	1.267 62
3	0.583 47	0.566 10	0.613 03	0.596 31	0.608 24
4	1.061 77	1.102 09	1.074 10	1.125 87	1.071 42
⋮	⋮	⋮	⋮	⋮	⋮
48	0.677 17	0.634 66	0.690 29	0.655 52	0.641 21
49	0.571 31	0.578 03	0.560 46	0.600 42	0.567 40
50	0.637 68	0.554 21	0.639 15	0.568 01	0.624 25
51	0.542 57	0.561 62	0.543 28	0.585 40	0.534 81






图7 预测模型A、B、C和D的预测效果对比
Fig. 7 Comparison of prediction effects of prediction models A, B, C and D

预测模型的预测效果及误差如图8所示,其中图8(a)~(d)分别表示预测模型A、B、C和D的预测效果及误差,预测模型A、B、C和D的评价指标值如图9所示,预测模型A、B、C和D的预测精度如表8所示。




(c) 预测模型C预测效果及误差
(c) Prediction effect and error of prediction model C




(d) 预测模型D预测效果及误差
(d) Prediction effect and error of prediction model D

图8 预测模型A、B、C和D的预测效果及误差
Fig. 8 Prediction effects and errors of prediction models A, B, C and D



(a) 预测模型A预测效果及误差
(a) Prediction effect and error of prediction model A



(b) 预测模型B预测效果及误差
(b) Prediction effect and error of prediction model B




图9 预测模型A、B、C和D的评价指标值
Fig. 9 Evaluation index values for prediction models A, B, C and D

表 8 预测模型 A、B、C 和 D 的预测精度

Table 8 Prediction accuracy of prediction models A, B, C and D

预测模型	MAPE/ %	RMSE/ μm	R ²	E _{amax} / μm	E _{rmax} / %
A	0.025 5	0.030 1	0.998 8	0.070	7.66
B	0.057 0	0.072 0	0.983 0	0.160	17.14
C	0.032 6	0.046 0	0.991 2	0.158	13.65
D	0.056 7	0.070 1	0.971 0	0.164	21.35

由图 7~9 和表 7、8 可知,预测模型 A 相较于预测模型 B、C 和 D, MAPE 值分别减小 55.26%、21.78% 和 55.03%, RMSE 值分别减小 55.03%、34.59% 和 57.06%, 决定系数 R^2 值分别提高 1.58%、0.76% 和 2.78% (预测模型 A、B、C 和 D 的决定系数 R^2 值分别为 0.998 8、0.983 0、0.991 2 和 0.971 0)。此外,预测模型 A、B、C 和 D 的 E_{amax} 分别为 0.070、0.160、0.158 和 0.164 μm , E_{rmax} 分别为 7.66%、17.14%、13.65% 和 21.35%, 预测模型 A 的误差波动更加平缓,拟合效果更优。

预测模型 A、B、C 和 D 在训练过程中迭代 100 次,对应的适应度值如图 10 所示,预测模型 B、C 和 D 分别在迭代 49、45 和 48 次后收敛,适应度值分别为 0.032 01、0.027 81 和 0.046 89,预测模型 A 在迭代 40 次后收敛且适应度值更小,为 0.022 54。较小的适应度值代表着预测模型在不同数据点上的预测效果更加稳定和可靠。




图 10 预测模型 A、B、C 和 D 的适应度值

Fig. 10 Adaptation values for prediction models A, B, C and D

通过预测模型 A、B、C 和 D 的预测性能对比,表明所提方法构建的 IWOA-CNN-BiLSTM-Attention 预测模型具有较好的模型预测能力,验证了所提方法的有效性。

4 结 论

为解决机器人磨削过程复杂耦合、高度时变非线性等动态特性导致动态因素特征选择困难与仅考虑静态因素致使表面粗糙度预测精度低的问题,结合深度学习技术,提出一种考虑动态因素影响的机器人磨削表面粗糙度预测方法并构建 IWOA-CNN-BiLSTM-Attention 表面粗糙度预测模型,通过动态因素和静态因素影响实验分析和不同表面粗糙度预测方法分析,验证所提方法和所构建预测模型的有效性。通过上述研究得到的结论为:

根据所提方法构建的 IWOA-CNN-BiLSTM-Attention 预测模型与 WOA-CNN-BiLSTM-Attention 预测模型、CPO-CNN-BiLSTM-Attention 预测模型和 GA-BP 预测模型对比分析,所构建预测模型较后三者的 MAPE 分别减小 55.26%、21.78% 和 55.03%, RMSE 分别减小 55.03%、34.59% 和 57.06%, R^2 分别提高 1.58%、0.76% 和 2.78%,预测精度提高 17.14%、13.65% 和 21.35%,所构建预测模型均优于对比预测模型,表明采用所提考虑动态因素影响的机器人磨削表面粗糙度预测方法的预测效果精度更高,验证了所提方法的有效性。

在后续研究中,将进一步探讨动态因素对机器人磨削过程中机器人磨削颤振的影响,并结合颤振稳定性分析,优化机器人磨削工艺参数,提高机器人磨削质量。

参考文献

[1] KE X L, YU Y H, LI K S, et al. Review on robot-assisted polishing: Status and future trends[J]. Robotics and Computer-Integrated Manufacturing, 2023, 80: 102482.

[2] HSUEH I C, LAN Y H, LIN D H, et al. A compact compliant robot for the grinding of spherical workpieces with high force control accuracy [J]. Robotics and Computer-Integrated Manufacturing, 2025, 91: 102856.

[3] ZHANG B X, WU SH J, WANG D ZH, et al. A review of surface quality control technology for robotic abrasive belt grinding of aero-engine blades [J]. Measurement, 2023, 220: 113381.

[4] 郭文婷, 陈东生, 程思博, 等. 面向工件自动化装配的空间位姿柔性接触式测量方法研究[J]. 仪器仪表学报, 2024, 45(4): 75-83.

GUO W T, CHEN D SH, CHENG S B, et al. Research on the flexible contact measurement method for spatial pose in automated assembly of workpieces [J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 75-83.

- [5] 李特, 葛宇航, 艾靖超, 等. 锥形薄壁筒内轮式加工机器人自适应运动控制[J]. 仪器仪表学报, 2023, 44(5): 90-99.
LI T, GE Y H, AI J CH, et al. Adaptive motion control of wheeled machining robot in conical thin-walled cylinder[J]. Chinese Journal of Scientific Instrument, 2023, 44(5): 90-99.
- [6] 刘运忠, 姜宏, 章翔峰. 基于 PSO 优化的模糊 PID 恒力控制研究[J]. 电子测量技术, 2023, 46(9): 16-22.
LIU Y ZH, JIANG H, ZHANG X F. Fuzzy PID constant force control based on PSO optimization[J]. Electronic Measurement Technology, 2023, 46(9): 16-22.
- [7] KONG D D, ZHU J J, DUAN CH Q, et al. Bayesian linear regression for surface roughness prediction[J]. Mechanical Systems and Signal Processing, 2020, 142: 106770.
- [8] LIU L L, ZHANG X Y, WAN X, et al. Digital twin-driven surface roughness prediction and process parameter adaptive optimization [J]. Advanced Engineering Informatics, 2022, 51: 101470.
- [9] YANG Z Y, XU X H, KUANG M X, et al. Dynamic compliant force control strategy for suppressing vibrations and over-grinding of robotic belt grinding system[J]. IEEE Transactions on Automation Science and Engineering, 2023, 21(3): 4536-4547.
- [10] WANG Q L, WANG W, ZHENG L Y, et al. Force control-based vibration suppression in robotic grinding of large thin-wall shells [J]. Robotics and Computer-Integrated Manufacturing, 2021, 67: 102031.
- [11] WANG X F, YAN J H. Deep learning based multi-source heterogeneous information fusion framework for online monitoring of surface quality in milling process[J]. Engineering Applications of Artificial Intelligence, 2024, 133: 108043.
- [12] LIU N C, LIU B L, JIANG H, et al. Study on vibration and surface roughness in MQCL turning of stainless steel[J]. Journal of Manufacturing Processes, 2021, 65: 343-353.
- [13] ROSS N S, MASHININI P M, SHIBI C S, et al. A new intelligent approach of surface roughness measurement in sustainable machining of AM-316L stainless steel with deep learning models[J]. Measurement, 2024, 230: 114515.
- [14] YANG H G, ZHENG H, ZHANG T H. A review of artificial intelligent methods for machined surface roughness prediction[J]. Tribology International, 2024, 199: 109935.
- [15] PAN Y N, KANG R K, DONG ZH G, et al. On-line prediction of ultrasonic elliptical vibration cutting surface roughness of tungsten heavy alloy based on deep learning[J]. Journal of Intelligent Manufacturing, 2022, 33(3): 675-685.
- [16] DUAN J, ZHANG X, SHI T L. A hybrid attention-based paralleled deep learning model for tool wear prediction[J]. Expert Systems with Applications, 2023, 211: 118548.
- [17] BOGA C, KOROGLU T. Proper estimation of surface roughness using hybrid intelligence based on artificial neural network and genetic algorithm [J]. Journal of Manufacturing Processes, 2021, 70: 560-569.
- [18] YANG J ZH, ZOU B, GUO G Q, et al. A study on the roughness detection for machined surface covered with chips based on deep learning [J]. Journal of Manufacturing Processes, 2022, 84: 77-87.
- [19] YAO Z Q, SHEN J Y, WU M, et al. Position-dependent milling process monitoring and surface roughness prediction for complex thin-walled blade component[J]. Mechanical Systems and Signal Processing, 2023, 198: 110439.
- [20] WANG J SH, CHEN T, KONG D D. Knowledge-based neural network for surface roughness prediction of ball-end milling [J]. Mechanical Systems and Signal Processing, 2023, 194: 110282.
- [21] WANG Y Q, NIU M M, LIU K, et al. A novel data augmentation method based on CoralGAN for prediction of part surface roughness[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 34(10): 7024-7033.
- [22] LAI J Y, LIN P CH. Grinded surface roughness prediction using data-driven models with contact force information [C]. 2022 IEEE/ASME International Conference on Advanced Intelligent Mechatronics, 2022: 983-989.
- [23] 路恩会, 郭耀村, 李世雯, 等. 基于全参考彩色图像质量算法的磨削表面粗糙度测量[J]. 仪器仪表学报, 2023, 44(7): 252-259.
LU EN H, GUO Y C, LI SH W, et al. Measurement of grinding surface roughness based on the full-reference color image quality algorithm [J]. Chinese Journal of Scientific Instrument, 2023, 44(7): 252-259.
- [24] 惠记庄, 骆伟, 阎志强, 等. AlSi10Mg 选区激光熔化

- 表面粗糙度预测、优化及表面形貌分析[J]. 表面技术, 2024, 53(15): 129-140, 151.
- HUI J ZH, LUO W, YAN ZH Q, et al. Surface roughness prediction, optimisation and surface morphology analysis of AlSi10Mg by selective laser melting[J]. Surface Technology, 2024, 53(15): 129-140, 151.
- [25] 李昌龙, 陈松, 吴炫炫, 等. 基于 PSO-ELM 的 316L 不锈钢细长管磁粒研磨内表面粗糙度预测模型[J]. 中国表面工程, 2023, 36(2): 212-221.
- LI CH L, CHEN S, WU X X, et al. Inner surface roughness prediction model of 316L stainless steel slender tube by magnetic abrasive finishing based on PSO-ELM[J]. China Surface Engineering, 2023, 36(2): 212-221.
- [26] 辛明泽, 孙兴伟, 张维锋, 等. 螺杆转子盘铣刀铣削表面粗糙度预测[J]. 电子测量与仪器学报, 2023, 37(12): 204-212.
- XIN M Z, SUN X W, ZHANG W F, et al. Prediction of surface roughness of screw rotor disc milling cutter[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(12): 204-212.
- [27] 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 H R, ZHANG P J, SUN X W, et al. Surface roughness prediction for screw belt grinding based on improved convolutional neural network [J]. China Mechanical Engineering, 2025, 36(2): 325-332.
- [28] 陈佳琳, 尚志武, 张雷. 基于 IDRSN-BiLSTM 的铣削加工表面粗糙度预测方法[J]. 仪器仪表学报, 2024, 45(4): 27-36.
- CHEN J L, SHANG ZH W, ZHANG L. Roughness prediction method of milling surface based on IDRSN-BiLSTM[J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 27-36.
- [29] 陈超逸, 鲁娟, 陈楷, 等. 车削表面粗糙度解析模型与 DDQN-SVR 预测模型研究[J]. 机械工程学报, 2021, 57(13): 262-272.
- CHEN CH Y, LU J, CHEN K, et al. Research on analytical model and DDQN-SVR prediction model of turning surface roughness [J]. Journal of Mechanical Engineering, 2021, 57(13): 262-272.
- [30] 柳想, 王成, 汪森辉, 等. GA-BP-ANN 耦合 RSM 优化表面机械滚压 1060 铝表面粗糙度[J]. 表面技术, 2024, 53(24): 154-164.
- LIU X, WANG CH, WANG S H, et al. Optimization of surface roughness resulting from surface mechanical rolling of 1060 aluminum by coupling GA-BP-ANN with RSM[J]. Surface Technology, 2024, 53(24): 154-164.
- [31] GHAREHCHOPOAH F S, GHOLIZADEH H. A comprehensive survey: Whale optimization algorithm and its applications [J]. Swarm and Evolutionary Computation, 2019, 48: 1-24.

作者简介



郭万金, 2007 年于长安大学获得学士学位, 2010 年于西安电子科技大学获得硕士学位, 2017 年于哈尔滨工业大学获得博士学位, 现为长安大学副教授、博士生导师, 主要研究方向为机器人智能控制与标定技术、机器人打磨及应用。

E-mail: guowanjin@chd.edu.cn

Guo Wanjin received his B.Sc. degree from Chang'an University in 2007, M.Sc. degree from Xidian University in 2010, and Ph.D. degree from Harbin Institute of Technology in 2017. He is currently an associate professor and a Ph.D. advisor at Chang'an University. His main research interests include robot intelligent control and calibration technology, robot grinding and robotic applications.



郝钦磊, 2022 年于长安大学获得学士学位, 现为长安大学硕士研究生, 主要研究方向为机器人磨削表面完整性和工艺参数优化。

E-mail: 13935820961@163.com

Hao Qinglei received his B.Sc. degree from Chang'an University in 2022. He is currently a graduate student at Chang'an University. His main research interests include surface integrity and process parameter optimization of robotic grinding.



曹维清, 2004 年于南京理工大学获得学士学位, 2008 年于重庆大学获得硕士学位, 2012 年于哈尔滨工业大学获得博士学位, 现为安徽工程大学高级工程师、博士生导师, 主要研究方向为智能机器人视觉感知、人机交互技术、机器人智能技术。

E-mail: caochuqing@hitrobot.com.cn

Cao Chuqing received his B.Sc. degree from Nanjing University of Science and Technology in 2004, M.Sc. degree from Chongqing University in 2008, and Ph.D. degree from Harbin Institute of Technology in 2012. He is currently a senior engineer and Ph.D. supervisor at Anhui Polytechnic University. His main research interests include intelligent robot vision

perception, human-computer interaction technology and machine crowd intelligence technology.



赵立军, 1996 年于北京理工大学获得学士学位, 2002 年于哈尔滨工业大学获得硕士学位, 2009 年于哈尔滨工业大学获得博士学位, 现为哈尔滨工业大学教授级高工、研究员、博士生导师, 主要研究方向为移动机器人环境层次化感知技术 (SLAM)、动态环境下交互式服务机器人导航方法、基于具身智能的特种机器人作业方法。

E-mail: zhaolj@hit.edu.cn

Zhao Lijun received his B. Sc. degree from Beijing Institute of Technology in 1996, M. Sc. degree from Harbin Institute of Technology in 2002, and Ph. D. degree from Harbin Institute of Technology in 2009. He is currently a professor-level senior engineer, researcher and Ph. D. supervisor at Harbin Institute of Technology. His main research interests include mobile robot environment hierarchical perception technology (SLAM),

interactive service robot navigation method in dynamic environment and special robot operation method based on embodied intelligence.



王力(通信作者), 2012 年于中国民航大学获得学士学位, 2015 年于中国民航大学获得硕士学位, 2020 年于哈尔滨工业大学获得博士学位, 现为北京理工大学副研究员、硕士生导师, 主要研究方向为机器人具身智能、自动驾驶感知。

E-mail: wangli_bit@bit.edu.cn

Wang Li (Corresponding author) received his B. Sc. degree from Civil Aviation University of China in 2012, M. Sc. degree from Civil Aviation University of China in 2015, and Ph. D. degree from Harbin Institute of Technology in 2020. He is currently an associate researcher and a master advisor at Beijing Institute of Technology. His main research interests include robot embodied intelligence and autonomous driving perception.