DOI: 10. 19650/j. cnki. cjsi. J2312030

# 基于 IDRSN-BiLSTM 的铣削加工表面粗糙度预测方法\*

陈佳琳1,尚志武1,张 雷2,3

(1.天津工业大学天津市现代机电装备技术重点实验室 天津 300387; 2.天津商业大学机械工程学院 天津 300134;3.天津市天森智能设备有限公司 天津 300300)

摘 要:针对传统的表面粗糙度预测方法过度依赖人工提取特征以及预测精度较低的问题,提出一种基于 Inception 模块改进 的深度残差收缩网络(IDRSN)和双向长短时记忆网络(BiLSTM)的表面粗糙度预测方法。首先,利用深度残差收缩网络 (DRSN)中软阈值化结构和注意力机制对输入信号进行降噪处理。其次,引入 Inception 模块构建 IDRSN 以提升网络的多尺度 信息获取能力,实现自适应多尺度特征提取。然后,引入反向长短期记忆(LSTM)构建 BiLSTM 预测网络,利用正反两个 LSTM 提高网络捕捉历史和未来完整信息的能力。最后,进行实验验证,分别对比 IDRSN、DRSN、BiLSTM 和人工提取特征 4 种方法的 提取特征效果,以及 BiLSTM、卷积神经网络(CNN)、DRSN 和 CNN-LSTM 4 种表面粗糙度预测模型的预测精度。结果表明所提 方法具有较高的预测精度,为铣削加工表面粗糙度预测奠定了方法基础。

关键词: 粗糙度预测;深度残差收缩网络;Inception 模块;自适应特征提取;双向长短时记忆网络

中图分类号: TH164 文献标识码: A 国家标准学科分类代码: 460.50

# Roughness prediction method of milling surface based on IDRSN-BiLSTM

Chen Jialin<sup>1</sup>, Shang Zhiwu<sup>1</sup>, Zhang Lei<sup>2,3</sup>

(1. Tianjin Key Laboratory of Modern Electromechanical Equipment Technology, Tiangong University, Tianjin 300387, China;
2. School of Mechanical Engineering, Tianjin University of Commerce, Tianjin 300134, China;

3. Tianjin Tianshen Intelligent Equipment Co., Ltd., Tianjin 300300, China)

Abstract: To address the problem that the traditional milling surface roughness prediction method relies excessively on signal processing knowledge to extract features and has low prediction accuracy, a surface roughness prediction method based on a deep residual shrinkage network improved by the inception module (IDRSN) and a bidirectional long-short-term memory network (BiLSTM) is proposed. Firstly, the input signal is noise reduced using the soft thresholding structure and attention mechanism in the deep residual shrinkage network. Secondly, the Inception module is introduced to build IDRSN to enhance the multiscale information acquisition capability of the network for adaptive multiscale feature extraction. Then, a bidirectional recurrent network structure is introduced to construct a BiLSTM prediction network, which utilizes both positive and negative LSTM to improve the network's ability to capture complete information about the past and the future. Finally, experiments verify the effects of four methods of extracting features, IDRSN, DRSN, BiLSTM and manually extract features, and the prediction accuracy of four surface roughness prediction models, BiLSTM, CNN, DRSN, and CNN-LSTM, are compared respectively. It is shown that the proposed method has a high prediction accuracy and establishes a method basis for surface roughness prediction of milling machining.

Keywords: surface roughness prediction; deep residual shrinkage network; inception module; adaptive feature extraction; idirectional long-term short-term memory network

收稿日期:2023-10-18 Received Date: 2023-10-18

<sup>\*</sup>基金项目:天津市高等学校科技发展基金(2021KJ176)、天津市自然科学基金重点项目(21JCZDJC00770)资助

# 0 引 言

在航空航天、精密制造等领域,表面质量对产品的可 靠性和使用寿命有着至关重要的影响<sup>[1]</sup>。其中,表面粗 糙度是衡量表面质量的重要指标之一<sup>[2]</sup>。传统粗糙度预 测方法很难高效地挖掘数据的特征信息,导致预测精度 较低。因此,进行预测方法研究对实现表面粗糙度的精 准预测具有重要意义。

在传统的表面粗糙度预测方法中,输入参数类别、特征提取方法和预测模型建立方式等都会影响粗糙度的预测效果<sup>[3]</sup>。国内外学者对粗糙度预测问题已进行大量研究,并取得了一系列成果。Lu等<sup>[4]</sup>、Agrawal等<sup>[5]</sup>和Alajmi等<sup>[6]</sup>以切削速度、进料速率和切削深度等参数作为输入,利用支持向量机、多元回归和随机森林等传统机器学习方法建立表面粗糙度预测模型。Chen等<sup>[7]</sup>、彭彬彬等<sup>[8]</sup>和Yeganefar等<sup>[9]</sup>以切削三要素为输入,利用误差反向传播算法(back propagation, BP)和径向基函数(radial basis function, RBF)经网络建模,从而实现粗糙度的预测。上述预测模型均研究静态因素对粗糙度的影响,忽略了动态因素的影响,例如工件振动和刀具磨损等,从而降低了表面粗糙度预测的准确性。

随着传感器技术的发展,研究人员引入振动、力等动 态数据来提升粗糙度预测模型的精度。Pan 等<sup>[10]</sup>利用切 削参数和振动信号进行机械加工表面粗糙度预测。Wu 等[11] 对振动信号进行分析,并利用切削速度、进料速率 和切削深度等参数进行人工神经网络(artificial neural network,ANN)建模,预测铣削过程中的表面粗糙度。 Hessainia 等<sup>[12]</sup>将振动信号作为输入参数,进行表面粗糙 度的在线预测。Upadhyay 等<sup>[13]</sup>和 Kumar 等<sup>[14]</sup>利用切削 参数和振动信号对 Ti-6Al-4V 合金车削过程中的粗糙度 进行预测。Asiltürk 等<sup>[15]</sup>以切削速度、进给速率、切削 深度和刀具半径作为输入,提出了利用 ANN 预测 AISI1040钢材表面粗糙度的方法。由上述研究可知, 影响粗糙度的因素有很多,如主轴转速、进给速度、切 削深度、刀具磨损和振动等。这些因素对表面粗糙度 的影响具有复杂、非线性的特点。但上述研究只考虑 了部分因素,限制了表面粗糙度预测模型的泛化性与 准确性。此外,用于粗糙度预测的方法主要为支持向 量机、多元回归和 ANN 等浅层学习方法。这些方法在 提取输入信息特征时多采用人工方式提取特征,但实 际加工过程中工作条件多变,外界干扰因素多,人工提 取的特征鲁棒性欠佳,同时会丢失传感器信号中的重 要信息,限制了表面粗糙度预测精度的提高。同时,振 动和切削力等动态数据中蕴含着丰富的数控铣削信 息,实验数据量巨大,人工提取特征方式无法很好地处

理海量实验数据,因此浅层学习模型无法很好地适应 当前加工环境。

近年来,随着人工智能技术的快速发展,深度学习因 其强大的特征提取能力和海量数据处理能力,被广泛应 用于工件加工表面粗糙度预测领域。李聪波等[16]针对 传统数控铣削表面粗糙度预测模型泛化性差、精度较低 等问题,提出了一种基于多源异构数据的数控铣削表面 粗糙度预测方法。Lin 等<sup>[17]</sup>采用快速傅里叶变换-深度 神经网络、快速傅里叶变换-长短时记忆网络(LSTM)和 一维卷积神经网络3种模型来研究其训练和预测性能。 Lee 等<sup>[18]</sup>采用深度置信神经网络预测模型,准确预测了 旋转电磁精加工表面粗糙度的变化。上述方法采用深度 学习的方法自适应提取信号特征,有效保存了重要信息, 但需要人工对信号进行降噪处理,操作过程繁琐。Zhao 等<sup>[19]</sup>提出了一种新的深度学习方法—深度残差收缩网 络(deep residual shrinkage network, DRSN), 以提高对高 噪声振动信号的特征学习能力,并成功运用于故障诊断 领域。Zhang 等<sup>[20]</sup> 和文井辉等<sup>[21]</sup> 用 DRSN 提取轴承退 化特征并实现轴承剩余寿命预测。Tong 等<sup>[22]</sup>结合注意 力机制和深度残差收缩网络提出了一种新型故障诊断方 法。Yang 等<sup>[23]</sup>提出一种基于宽维卷积层的深度残差收 缩网络的旋转机械故障诊断方法。目前, DRSN 已广泛 应用于信号降噪和特征提取过程并取得良好的效果。但 DRSN 中卷积层的卷积核尺寸单一,网络的深度和宽度 受限,难以充分提取有效特征信息。Szegedy 等<sup>[24]</sup>提出 的 Inception 结构,可以对输入信息进行多尺度特征提取。

综上所述,关于表面粗糙度预测研究中主要存在 3 个问题:1)考虑的粗糙度影响因素较少,大多只考虑切削 三要素对粗糙度的影响,无法反映机械加工的实际情况; 2)对输入信号进行降噪时操作繁琐且降噪效果不佳;3) 对输入信息提取的特征尺度单一,影响预测模型的精度。

针对以上问题,本文将切削三要素、刀具磨损、虎钳 力矩和振动信号作为输入,提出一种基于 Inception 模块 改进的深度残差收缩网络(inception deep residual shrinkage network, IDRSN)和双向长短时记忆网络 (bidirectional long-short-term memory, BiLSTM)的表面粗 糙度预测方法。首先,利用 DRSN 中软阈值化结构和注 意力机制对输入信号进行降噪处理,其次,引入 Inception 模块构建 IDRSN 提升网络的多尺度信息获取能力,以实 现自适应多尺度特征提取。最后,建立变工艺条件下的 表面粗糙度预测模型,在 LSTM 网络的基础上,引入反向 LSTM 构建 BiLSTM 预测网络,将提取的特征输入到 BiLSTM 以充分获取时序数据信息。采用公开数据集 S45C,通过多组对比实验验证本文提出的表面粗糙度预 测方法的有效性。

# 1 基于 IDRSN-BiLSTM 的粗糙度预测方法

基于 IDRSN-BiLSTM 的粗糙度预测方法流程如图 1 所示,主要分为特征提取模块和预测模块两部分。在特 征提取模块,首先利用 DRSN 中软阈值化结构和注意力 机制对输入信号进行降噪处理。其次,引入 Inception 模 块以提升 DRSN 的多尺度信息获取能力,实现自适应多 尺度特征提取。在预测模块,鉴于 LSTM 优秀的时序建 模能力,引入反向 LSTM 构建 BiLSTM 预测网络,利用隐 藏层中正反两个 LSTM 结构,提高网络捕捉历史和未来 完整信息的能力,实现表面粗糙度的高精度预测。



图 1 预测流程图 Fig. 1 Prediction flow chart

#### 1.1 基于 IDRSN 的特征提取方法

常用特征提取方式主要是基于信号分析的方法,对 信号进行降噪处理、提取特征,再从中筛选出敏感特征。 该方式手动提取时域和频域特征,依赖于先验知识,缺乏 自适应性且去噪过程复杂。DRSN 是在残差网络的基础 上引入软阈值函数和注意力机制,在注意力机制的作用 下实现软阈值化。在特征学习的过程中,不需要信号处 理知识就可以剔除冗余信息,实现对输入信号的降噪,进 而自适应提取特征。

在 DRSN 的基础上引入 Inception 模块,并构建 IDRSN,提升网络的多尺度信息获取能力,以实现自适应 多尺度特征提取。再将静态因素和振动信号共同作为输入,将制作好的数据样本输入至 IDRSN 网络进行特征提取。IDRSN 结构如图 2 所示。首先通过 Inception 模块、批量标准化和 ReLU 激活函数提取输入信号  $U_1$  的多尺度特征得到  $U_2$ 。随后通过注意力机制子网络获取合适的阈值,对  $U_2$  进行取绝对值和全局平均池化操作得到一维向量  $\beta$ 。然后通过全连接层和 Sigmoid 激活函数,得到输出范围为[0,1]的一维缩放参数向量  $\alpha$ 。 $\alpha$  和 $\beta$  相乘可得  $U_2$  通道阈值的组合  $\tau$ 。将  $U_2$  和 $\tau$ 输入软阈值函数进行特征选择,得到特征  $U_3$ 。经 IDRSN 重构后得到特征  $U_4$ 。



图 2 Inception 结构 Fig. 2 Inception structure

软阈值化是信号降噪的关键步骤,通过引入软阈值 函数可以有效去除噪声,通过如下公式实现:

$$y = \begin{cases} x - \tau, & x > \tau \\ 0, & -\tau \leq x \leq \tau \\ x + \tau, & x < -\tau \end{cases}$$
(1)  
其导数为:

$$\frac{\partial_{y}}{\partial_{x}} = \begin{cases} 1, & x > \tau \\ 0, & -\tau \le x \le \tau \\ 1, & x < -\tau \end{cases}$$
(2)

式中:x表示输入特征;y表示输出特征; 无示阈值。

由式(1)和(2)可知,当输入特征的绝对值小于等于 阈值时将其删除;当输入特征的绝对值大于阈值时,将其 朝着零的方向进行收缩。其中阈值设定较为困难,一般 需要信号处理方面专业人员设置,具有很大局限性。针 对这一问题,残差收缩网络变换了传统的残差模块,以注 意力机制作为其网络结构,在深层网络中实现阈值反向 传播过程中的自我更新。

# 1.2 基于 BiLSTM 的预测模型

Hochreiter 等<sup>[25]</sup> 基于递归神经网络(recursive neural network, RNN),提出了 LSTM,通过使用门控单元和记忆 机制,减轻了 RNN 模型训练过程中的梯度消失和梯度爆 炸问题。LSTM 只能通过上一时刻的时序信息预测得到 下一时刻的信息,不能挖掘信息间的长期依赖关系。BiLSTM 由两个传播方向相反且独立的 LSTM 构成,可以 充分获得前后时刻数据的信息,已经被成功应用于故障 诊断<sup>[26-27]</sup> 和刀具磨损预测领域<sup>[28-29]</sup>。BiLSTM 学习时序 信息间关系的能力优于单个 LSTM 结构模型,充分提取时 间序列的关系可以更好的建立输入与输出间的联系。因此,BiLSTM 具有双向传播能力,弥补了 LSTM 的不足。所 以引入 BiLSTM 对粗糙度进行预测,结构如图 3 所示, $\vec{h}_i$ 、





#### 1.3 预测流程

步骤 1)制作数据样本,收集各加工实验下铣削的工 艺参数、刀具磨损等静态数据和振动信号等动态数据。 通过 python 中 hstack 函数将动态数据和静态数据横向合 并,再与粗糙度进行对应,得到包含完整信息的数据样 本,从而实现动态因素和静态因素的联合分析。

步骤 2)将数据样本进行归一化处理,然后划分为训 练集和测试集。采用 Min-max 标准化方法,对原始数据 进行数据变换,将数据值映射到[0,1]。

$$x'_{i} = \frac{x_{i} - x_{\min}}{x_{\max} - x_{\min}}$$
(4)

式中:x 表示原始数据样本;x'表示归一化后的数据样本; x<sub>min</sub> 表示数据样本的最小值;x<sub>max</sub> 表示数据样本最大值。

步骤3)利用 DRSN 对输入信号进行降噪,引入 Inception 模块提升 DRSN 多尺度信息获取能力,得到 IDRSN。

步骤 4) 在 LSTM 的基础上引入反向 LSTM,并构建 BiLSTM,使用训练集样本对 BiLSTM 模型进行训练,直至 得到满足要求的模型,记为模型 M。

步骤 5)利用测试集的样本验证模型 M 对表面粗糙 度的预测效果。

## 2 实验验证

#### 2.1 实验装置

本文采用公开数据集 S45C 对所提方法进行验证<sup>[11]</sup>。实验采用碳化钨铣刀对 S45C 钢进行平面铣削,刀 具参数如表 1 所示。如图 4(a)和(b)所示,将加速度计 (Wilcoxon Research 785A)分别安装在主轴(1~3)和虎钳 (4~6),测量铣削过程中的振动加速度。测量的振动信号 由数据采集装置(DAQ NI 9234)记录,采样频率为 10 kHz。

工件铣削顺序和方向如图 5 所示,对长方体钢块进 行直线轨迹铣削。利用刀具累积去除体积(RVA)来简 化表示刀具的磨损情况,详细的切削参数和积累去除体 积如表 2 所示。

表 1 碳化钨刀具参数 <sup>[11]</sup>				
Table 1	Tungsten ca	rbide tool paramet	ers <sup>[11]</sup>	
刀具参数	设定值	刀具参数	设定值	
刀具直径	10 mm	切刀铰链直径	10 mm	
刀片长度	30 mm	刀片数量	4	
刀具总长度	75 mm	螺旋角	35°	





(a) 主轴加速度计 (b) 虎钳加速度计 (a) Accelerometer installation on spindle (b) Accelerometer installation on vise

图4 实验设备[11] Fig. 4 Experimental equipment<sup>[11]</sup>



图 5 铣削路径图<sup>[11]</sup> Fig. 5 Milling path diagram<sup>[11]</sup>

衣 4 切削参数和标条去防冲标值***	表 2	切削参数和积累去除体积值 <sup>[11]</sup>
---------------------	-----	------------------------------

Table 2 Cutting parameters and accumulated removal volume<sup>[11]</sup>

切削参数	设定值
主轴转速/(r·min <sup>-1</sup> )	900 \1 000 \1 800 \1 900 \2 000 \2 100 \ 2 700 \3 000
进给速度/(mm·min <sup>-1</sup> )	228、240、252、320、400、420、532、 560、588
每齿进给量/(mm/tooth)	0.02~0.09(共十个等级)
切削深度/mm	0.5,0.6,0.7,0.8,0.9,1
虎钳夹紧力矩/(N•m)	18、30、75
积累去除体积/mm <sup>3</sup>	估计值 0~74.8

本文实验每把刀具只用于一块工件(共9道)的铣 削加工。根据切削参数的不同组合,一块工件铣削加工 完成后,通过仪器 Mitutoyo SV-C3200S4 测量工件表面粗 糙度,并用平均粗糙度 Ra 表示。

#### 2.2 预测方法应用

预测方法的具体应用如图 6 所示。首先,对 S45C 钢 进行铣削加工,在变工艺条件下采集主轴转速、进给速 度、每齿进给量、切削深度、虎钳加紧力矩和刀具磨损(累 计去除体积)等静态数据以及振动信号等动态数据。采 用 Min-max 标准化方法对数据进行归一化处理,将其缩 放到 0~1,按照训练集和测试集 4:1进行数据划分。其 次,通过 Keras 搭建 IDRSN 模型,利用 DRSN 对输入信号 进行降噪,引入 Inception 模块提升 DRSN 多尺度信息获 取能力,得到 IDRSN 模型。再次,在 LSTM 的基础上,引 入反向 LSTM 构建 BiLSTM, 与 IDRSN 构成 IDRSN-BiLSTM 模型。随机初始化 IDRSN-BiLSTM 模型的参数. 将训练集样本输入模型进行训练,得到预测粗糙度值,计



图 6 预测方法应用

Fig. 6 Application block diagram of prediction method

[23]

算预测粗糙度值与实际粗糙度值的误差。通过计算损失 函数不断更新模型参数,经过训练样本不断迭代得到性 能最优的 IDRSN-BiLSTM 模型,保存该模型参数。最后, 将测试集输入到训练后的 IDRSN-BiLSTM 模型中获得预 测粗糙度值,将其与实际粗糙度值进行均方根误差(root mean squared error, RMSE)、平均绝对百分比误差(mean absolute percentage error, MAPE)和决定系数(coefficient of determination,  $R^2$ )计算,分析 IDRSN-BiLSTM 模型预测 粗糙度的性能。

#### 2.3 评价指标

使用 RMSE、MAPE 和 R<sup>2</sup> 3 种指标对预测模型进行 评价, RMSE 和 MAPE 用来量化预测值与真实值的偏离 程度, R<sup>2</sup> 用来评价模型的可靠度, 取值范围为[0,1], 公 式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^{n} (y_i - \tilde{y}_i)^2}$$
(5)

$$MAPE = \frac{1}{n} \sum_{i=1}^{n} \left| \frac{y_i - \tilde{y}_i}{y_i} \right|$$
(6)

$$R^{2} = \frac{\left(n\sum_{i=1}^{n} \tilde{y}_{i}y_{i} - \sum_{i=1}^{n} \tilde{y}_{i}\sum_{i=1}^{n} y_{i}\right)^{2}}{\left(n\sum_{i=1}^{n} \tilde{y}_{i}^{2} - \left(\sum_{i=1}^{n} \tilde{y}_{i}\right)^{2}\right)\left(n\sum_{i=1}^{n} y_{i}^{2} - \left(\sum_{i=1}^{n} y_{i}\right)^{2}\right)}$$
(7)

式中: $y_i$  为实际测量的 Ra 值; $\tilde{y}_i$  为预测值;n 为实验案例 总数。

Lewis<sup>[30]</sup>研究表明,不同的 MAPE 值揭示了不同的预 测性能水平,如表 3 所示。

Table 3 MAPE value vs.	levels of prediction performance
MAPE	预测水平
<10%	高度准确
10% ~20%	准确
20% ~ 50%	合理
>50%	不准确

## 表 3 MAPE 值与预测水平的关系<sup>[23]</sup>

2.4 对比分析

本文通过 IDRSN 对输入信号进行自适应特征提取, 由 BiLSTM 训练得到表面粗糙度预测模型(模型 M),在 测试集上测试模型 M 的预测效果。为验证本文所建立 模型 M 的预测效果,通过如下 3 组实验进行对比分析。

1) 实验1

为证明所提 IDRSN 的降噪和特征提取能力,将其与 其他特征提取方式进行对比。

方案 1,采用 IDRSN 提取特征,建立预测模型 M。 方案 2,采用 DRSN 提取特征,建立预测模型 A。 方案 3,采用 BiLSTM 提取特征,建立预测模型 B。

方案4,人工提取均值、标准差、方差、均方根、偏度、 峭度、波形因子等特征,建立预测模型C。

将上述 4 种方案提取到的特征分别输入到 BiLSTM 神经网络中,预测结果如图 7 所示。由图 7 可知,模型 M 相对于其他模型, MAPE 分别降低了 5.44%、7.25% 和 9.56%, RMSE 分别降低了 7.82%、10.31% 和 12.73%, R<sup>2</sup> 分别升高了 8.97%、10.26% 和 15.62%。此外,模型 M 的 相对误差均小于 9.48%,误差波动更加平缓,拟合效果明 显优于其他模型,说明本文提出的 IDRSN 自适应多尺度 特征提取方法具有良好的降噪能力和特征提取能力,避 免了传统方法对专业知识的依赖。







Fig. 7 Comparison of the prediction effect of each model

#### 2) 实验 2

为验证本文所提训练模型的优势,将工艺参数等静态因素和振动信号共同输入 IDRSN 提取到特征,用不同神经网络(BiLSTM、CNN、DRSN 和 CNN-LSTM)分别建立预测模型 M、D、E、F。

如图 8 所示,模型 M 相对于其他模型, MAPE 分别降 低了 10.67%、3.89% 和 4.80%, RMSE 分 别 降 低 了 8.34%、4.22%和4.06%, R<sup>2</sup>分别升高了 17.56%、6.51% 和 6.17%。可见模型 M 评价指标更好,采用 BiLSTM 建 立的预测模型具有更好的预测效果。

3) 实验 3

为证明动态因素在特征提取中的作用,以及动态、 静态因素联合分析的优势,对影响因素类别进行对比 实验。





图 8 各模型在测试集的评价指标对比 Fig. 8 Comparison of evaluation indexes of each model in the test set

方案1,将动态因素输入IDRSN-BiLSTM 模型,对粗 糙度进行预测。

方案 2,将静态因素输入 IDRSN-BiLSTM 模型,对粗糙度进行预测。

方案 3,将全因素(静态因素和动态因素)输入 IDRSN-BiLSTM 模型,对粗糙度进行预测。

输入不同种类影响因素的预测效果如图 9 所示。 图 9(a)将方案 1 和方案 3 进行对比,只考虑动态因素相 比于考虑全因素进行预测,MAPE 升高了 12.68%,RMSE 升高了 8.90%, R<sup>2</sup> 降低了 19.41%。虽然静态因素数据



图 9 不同输入因素预测效果对比

Fig. 9 Comparison of prediction effects of different input factors

量小,但引入后对预测效果有显著提升,说明在模型特征 提取过程中静态因素占据一定比重,动态因素并未占据 绝对主导地位;图9(b)将方案2和方案3进行对比,只 考虑静态因素相比于考虑全因素进行预测,MAPE升高 了10.82%,RMSE升高了7.71%,R<sup>2</sup>降低了15.55%。由 以上两组对比实验可知,考虑全因素得到的粗糙度预测 值更加接近真实值,说明静态因素和动态因素都包含了 部分特征信息,同时考虑铣削过程的静态、动态因素有更 好的预测效果。

4) 实验 4

与文献[11]所提 ANN 方法进行对比。文献[11]采 用随机抽选的方式划分数据集,为充分验证本文所提模型 M 的优势,也采用随机抽选的方式进行数据集划分。

1.75

1.50

0

5

町 1.00 「 」 観 製 0.75 0.50 0.25 并通过抽选3次的方式进行综合对比,以避免随机抽选的偶然性,结果如表4所示。

表 4 随机抽选实验 MAPE 值 Table 4 Randomly selected experimental MAPE values in the test set

模型	ANN	M-抽选 1	M-抽选 2	M-抽选 3
MAPE/%	18	14. 28	13.65	14.67

由表 4 可知,3 次随机抽选实验的 MAPE 值均低于 模型 ANN,说明模型 M 预测误差更小,具有更好的预测 能力。其中,第 3 次抽选的预测效果如图 10 所示,其 MAPE 为 14.67%。

- 直 实 伯

70

75



Fig. 10 M-select 3 prediction effect diagram

此外,对以上4组对比实验的训练和预测时间分别 进行记录,每组进行10次实验,对运算时间取平均值以 提高数据可靠性,部分模型的运算时间如表5所示。由 数据对比可知,采用IDRSN-BiLSTM模型进行训练及预 测时,运算时间略有延长,这是由于其模型结构更加复 杂,运算层次更深,需要提取更深层次的特征信息。

表 5 各模型运算时间

Table 5 computational time of each methods (s)

模型	训练时间	测试时间	总时间
IDRSN-BiLSTM	737.41	0.89	738. 32
DRSN	489.55	0.65	490. 23
BiLSTM	212.36	0.34	212.67

综上所述,本文提出方法能够实现较高精度的预测。 首先,所提方法通过与其他先进特征提取方法对比,验证 了提出模型特征提取的有效性。此外,通过与其他预测 模型建立方法对比,并用 RMSE、MAPE 和 R<sup>2</sup> 进行衡量, 说明了该方法预测结果的准确性。通过以上实验分析, 表明该方法能有效解决传统表面粗糙度预测模型过度依赖人工提取特征以及预测精度较低的问题,从而捕获高质量的特征以及提高特征提取过程的自适应性,实现高精度的粗糙度预测。

# 3 结 论

本文提出了一种基于 Inception 模块改进的 IDRSN 和 BiLSTM 的表面粗糙度预测方法。利用 DRSN 的软阈 值化结构和注意力机制有效减弱噪声信息的影响。引入 Inception 模块,并构建 IDRSN,以提升网络的多尺度信息 获取能力,实现自适应多尺度特征提取。建立变工艺条 件下的表面粗糙度预测模型,引入反向 LSTM,并构建 BiLSTM 预测网络,以提高网络捕捉过去和未来完整信息 的能力,从而提高表面粗糙度预测模型的预测精度。通 过上述研究得到如下结论。

1)分别采用 IDRSN 方法与基于 DRSN、BiLSTM 和传统信号处理方式的方法提取特征,并将提取的特征输入 到 BiLSTM 进行模型训练及预测,结果表明, IDRSN 方法 在 MAPE、RMSE、R<sup>2</sup> 上均优于其他方法,而且相对误差小于 9.48%,误差波动更加平缓,拟合效果明显优于其他模型。说明 IDRSN 方法具有较好的特征提取能力。

2) 粗糙度预测实验针对 BiLSTM、CNN、DRSN 和 CNN-LSTM 4 种预测模型进行分析,本文所提方法在 MAPE、RMSE、R<sup>2</sup>上均优于其他方法,说明采用所提方法 建立的模型预测效果更好,验证了本文所提方法的可行 性与有效性。

3)不同输入因素对比实验分别采用静态因素、动态 因素和全因素进行对比分析,本文将两种因素同时考虑 进行预测效果优于单一因素情况,说明在粗糙度预测研 究中需要全面考虑影响工件表面粗糙度的因素。

尽管本文提出的方法在工件表面粗糙度预测上取得 良好效果,但是神经网络算法复杂度大,未来将重点进一 步优化模型结构,在保证预测精度的前提下缩减训练时 间,从而提高预测模型的实时性。

### 参考文献

[1] 张蕾涛,刘德鑫,张伟樯,等. 钛合金表面激光熔覆 涂层的研究进展[J]. 表面技术,2020,49(8): 97-104.

ZHANG L T, LIU D X, ZHANG W Q, et al. Research progress of laser cladding coating on titanium alloy [J]. Surface Technology, 2020, 49(8): 97-104.

- [2] 陈涛. 切削加工表面完整性的理论和方法[M]. 北京:科学出版社, 2016.
   CHEN T. Theory and Method of Surface Integrity in Machining[M]. Beijing: Science Press, 2016.
- [3] BENARDOS P G, VOSNIAKOS G C. Predicting surface roughness in machining: A review [J]. International Journal of Machine Tools and Manufacture, 2003, 43(8):833-844.
- [4] LU J, LIAO X, LI S, et al. An effective ABC-SVM approach for surface roughness prediction in manufacturing processes [J]. Complexity, 2019 (8): 1-13.
- [5] AGRAWAL A, GOEL S, RASHID W B, et al. Prediction of surface roughness during hard turning of AISI 4340 steel (69 HRC) [J]. Applied Soft Computing, 2015, 30: 279-286.
- [6] ALAJMI M S, ALMESHAL A M. Prediction and optimization of surface roughness in a turning process using the ANFIS-QPSO method [J]. Materials, 2020, 13(13):2986.
- [7] CHEN Y, SUN R, GAO Y, et al. A nested-ANN prediction model for surface roughness considering the effects of cutting forces and tool vibrations [J]. Measurement, 2017, 98: 25-34.

[8] 彭彬彬, 闫献国, 杜娟. 基于 BP 和 RBF 神经网络的 表面质量预测研究[J]. 表面技术, 2020, 49(10): 324-328.
 PENG B B, YAN X G, DU J. Prediction of surface

quality based on BP and RBF neural network [J]. Surface Technology, 2020, 49(10): 324-328.

- [9] YEGANEFAR A, NIKNAM S A, ASADI R. The use of support vector machine, neural network, and regression analysis to predict and optimize surface roughness and cutting forces in milling[J]. The International Journal of Advanced Manufacturing Technology, 2019, 105 (1): 951-965.
- [10] PAN Y, KANG R, DONG Z, 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): 1-11.
- [11] WU T Y, LEI K W. Prediction of surface roughness in milling process using vibration signal analysis and artificial neural network [J]. The International Journal of Advanced Manufacturing Technology, 2019, 102(1-4): 305-314.
- [12] HESSAINIA Z, BELBAH A, YALLESE M A, et al. On the prediction of surface roughness in the hard turning based on cutting parameters and tool vibrations [J]. Measurement Journal of the International Measurement Confederation, 2013, 46(5):1671-1681.
- [13] UPADHYAY V, JAIN P K, MEHTA N K. In-process prediction of surface roughness in turning of Ti-6Al-4V alloy using cutting parameters and vibration signals [J]. Measurement, 2013, 46(1): 154-160.
- [14] KUMAR S N, ANDHARE A B, SANDIP A, et al. Prediction of surface roughness in turning of Ti-6Al-4V using cutting parameters, forces and tool vibration [C]. IOP Conference, 2018, 346:012-037.
- [15] ASILTÜRK I. Application of artificial intelligent to predict surface roughness[J]. Experimental Techniques, 2014, 38(4): 54-60.
- [16] 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.
  LICB,LONGY,CUIJB, et al. Prediction method of surface roughness of CNC milling based on multi-source heterogeneous data[J]. China Mechanical Engineering, 2022,33(3):318-328.

[17] LIN W J, LO S H, YOUNG H T, et al. Evaluation of deep learning neural networks for surface roughness prediction using vibration signal analysis [J]. Applied Sciences, 2019, 9(7): 1462.

- [18] LEE J H, SEO Y S, KWAK J S. Surface roughness prediction and optimization in the REMF process using an integrated DBN-GA approach [J]. The International Journal of Advanced Manufacturing Technology, 2022, 121(9-10): 5931-5942.
- [19] ZHAO M, ZHONG S, FU X, et al. Deep residual shrinkage networks for fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2019, 16(7): 4681-4690.
- [20] ZHANG Z, CHEN L, ZHANG C, et al. GMA-DRSNs: A novel fault diagnosis method with global multi-attention deep residual shrinkage networks [J]. Measurement, 2022, 196(5):111203.
- [21] 文井辉,伍荣森,李帅永,等.基于 DRSN 和优化 BiLSTM 的轴承剩余寿命预测方法[J/OL]. 计算机集 成制造系统,1-18[2024-04-07]. http://kns. cnki. net/ kcms/detail/11. 5946. TP. 20220826. 1702. 002. html.
  WEN J H, WU R S, LI SH Y, et al. Bearing residual life prediction method based on DRSN and optimized BiLSTM [J/OL]. Computer Integrated Manufacturing System,1-18[2024-04-07]. http://kns. cnki. net/kcms/ detail/11. 5946. TP. 20220826. 1702. 002. html.
- [22] TONG J Y, TANG S Y, WU Y, et al. A fault diagnosis method of rolling bearing based on improved deep residual shrinkage networks [J]. Measurement, 2023, 206(6): 112282.
- [23] YANG J, GAO T, JIANG S, et al. Fault diagnosis of rotating machinery based on one-dimensional deep residual shrinkage network with a wide convolution layer[J]. Shock and Vibration, 2020(4):1-12.
- [24] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016:2818-2826.
- [25] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735-1780.
- [26] HAN L, DENG Y, CHEN H, et al. A robust VRF fault diagnosis method based on ensemble BiLSTM with attention mechanism: Considering uncertainties and generalization [J]. Energy and Buildings, 2022, 269(1):112243.
- [27] 王雨虹,王志中,付华,等. 多策略改进麻雀算法与 BiLSTM 的变压器故障诊断研究[J]. 仪器仪表学报, 2022,43(3):87-97.

WANG YUHONG, WANG ZHIZHONG, FU HUA, et al. Research on transformer fault diagnosis based on

multi-strategy improved sparrow algorithm and BiLSTM[J]. Instruments Journal, 2022,43 (3):87-97.

- [28] CHENG M, JIAO L, YAN P, et al. Intelligent tool wear monitoring and multi-step prediction based on deep learning model [J]. Journal of Manufacturing Systems, 2022, 62(1-4):286-300.
- [29] DUAN J, ZHANG X, SHI T. A hybrid attention-based paralleled deep learning model for tool wear prediction[J]. Expert Systems with Application, 2023: 118548.
- [30] LEWIS C D, BOROUGH GREEN, SEVENOAKS. Industrial and business forecasting methods [M]. Kent: Butterworth Scientific, 1982.

## 作者简介



**陈佳琳**,2021 年于河北农业大学获得学 士学位,现为天津工业大学硕士研究生,主 要研究方向为动态测控。

E-mail: chenjialin\_1998@163.com

**Chen Jialin** received his B. Sc. degree from Hebei Agricultural University in 2021. He is

currently a M. Sc. candidate at Tiangong University. His main research interests include dynamic measuring and control.



尚志武,分别 1997 年和 2000 年于武汉大 学获得学士学位和硕士学位,2003 年于天津大 学获得博士学位,现为天津工业大学教授,主 要研究方向为装备故障诊断与智能运维。

E-mail: shangzhiwu@ 126.com

Shang Zhiwu received his B. Sc. degree and

M. Sc. degree from Wuhan University in 1997 and 2000, respectively, and received his Ph. D. degree from Tianjin University in 2003. He is currently a professor at Tiangong University. His main research interests include equipment fault diagnosis and intelligent operation maintenance.



**张雷**(通信作者),2010年于河北科技 师范学院获得学士学位,2013年于燕山大学 获得硕士学位,2018年于天津大学获得博士 学位,现为天津商业大学讲师,主要研究方 向为数字孪生技术与制造过程监控技术。

E-mail: zhgraceli@tjcu.edu.cn

**Zhang Lei** (Corresponding author) received his B. Sc. degree from Hebei Normal University of Science and Technology in 2010, M. Sc. degree from Yanshan University in 2013, and Ph. D. degree from Tianjin University in 2018. He is currently a lecturer at Tianjin University of Commerce. His main research interests include digital twin technology and manufacturing process monitoring technology.