

基于 TCN-BiLSTM-UEER 的数控磨削轮廓误差预测*

王 静^{1,2}, 岳正凯¹, 孙中波³, 郭梦雪¹, 彭治国¹, 时亚东¹

(1. 河南理工大学电气工程与自动化学院 焦作, 454003)

(2. 河南省智能装备直驱技术与控制国际联合实验室 焦作, 454003)

(3. 长春工业大学电气与电子工程学院 长春, 130012)

摘要 针对现有时序预测方法在曲率突变区和高波动区间预测性能退化问题,提出了一种融合时间卷积网络(temporal convolutional network,简称 TCN)与双向长短期记忆(bidirectional long short-term memory,简称 BiLSTM)网络的误差预测方法,并引入基于不确定性约束的嵌入空间误差自校正机制(uncertainty-aware embedding-space error rectification,简称 UEER)。首先,利用 TCN 的膨胀卷积结构提取加工序列的多尺度局部时序特征,增强模型对高频波动与局部突变的表征能力;其次,引入 BiLSTM 建模轮廓误差的双向长期时间依赖关系,提升整体趋势拟合精度;最后,构建基于嵌入空间相似样本与不确定性约束的误差校正机制,通过蒙特卡洛量化预测不确定性,在嵌入空间检索相似历史样本,并利用其残差信息对预测结果进行加权校正,抑制高不确定性区域的预测偏移。为了说明本研究方法的优点,设计了包括卷积神经网络(convolutional neural network,简称 CNN)、长短期记忆(long short-term memory,简称 LSTM)神经网络和门控循环单元(gated recurrent unit,简称 GRU)在内的复合对比模型。基于实际数控凸轮磨削数据的对比实验与消融实验结果表明:所提出方法在轮廓误差预测任务上的均方根误差(root mean squared error,简称 RMSE)、平均绝对误差(mean absolute error,简称 MAE)以及决定系数 R^2 均优于对比模型;引入 UEER 校正后,模型预测性能和稳定性得到进一步提升。

关键词 轮廓误差预测;数控加工;时间卷积网络与双向长短期记忆网络;不确定性约束;深度学习

中图分类号 TP391.7;TH161.5

0 引言

随着高速高精度数控加工技术的发展,复杂轮廓零件在航空航天、汽车发动机及高端装备制造等领域得到广泛应用。加工精度要求的不断提高,使得廓误差逐渐成为衡量数控机床动态性能与加工质量的重要指标之一^[1]。针对机床加工误差问题,国内外学者围绕几何误差、热误差以及跟踪误差等开展了大量研究^[2-3]。为提升加工精度,交叉耦合控制、预测控制、迭代学习控制以及自适应控制等方法被广泛应用于轮廓误差抑制^[4-7],但这些方法通常依赖精确数学模型或重复加工轨迹,在复杂工况及非重复扰动条件下性能容易受到限制^[8-10]。

在数控凸轮磨削过程中,轮廓误差不仅受伺服跟踪性能影响,还与加工轨迹曲率变化、多轴耦合及随机扰动密切相关,特别是在推程廓线和曲率突变区域,误差序列呈现明显的非平稳性和局部波动特征。同时,不同加工周期之间既存在整体趋势相似

性,又包含局部不确定性,这对预测模型的时序特征提取能力和复杂动态建模能力提出了更高要求。

近年来,深度学习方法逐渐应用于机床加工误差预测领域^[11-12]。其中,LSTM 神经网络因具备良好的时间序列建模能力,被广泛用于热误差和跟踪误差预测^[6,11]。但传统 LSTM 仅能进行单向时序建模,难以充分利用全局时序依赖关系^[13]。BiLSTM 虽能同时学习正向与反向时序特征,但其性能仍易受到网络结构及超参数设置影响,在复杂工况下的泛化能力有限^[14]。此外,贝叶斯优化、灰狼优化及鲸鱼优化等方法虽可提升模型性能^[13-15],但对曲率突变及高动态区域的预测稳定性仍然有限。其原因在于,现有方法通常忽略了不同加工周期之间潜在的结构相似性与不确定性特征^[16-18]。

笔者以数控凸轮磨削加工为研究对象,提出一种融合 TCN 与 BiLSTM 的轮廓误差预测模型,并引入基于不确定性约束的嵌入空间误差自校正机制。首先,利用 TCN 提取多尺度局部时序特征;其

* 河南省教育厅科技攻关资助项目(252102220094)

收稿日期:2025-12-27;修回日期:2026-03-09

次,结合 BiLSTM 建模轮廓误差的双向时间依赖关系;最后,通过嵌入特征空间中相似历史样本的残差信息对预测结果进行自适应校正,从而提高复杂工况下轮廓误差预测的精度与鲁棒性。

1 模型框架与特征工程

1.1 模型框架

笔者采用多尺度 TCN 模块对加工数据中的局部时序特征进行并行提取,以增强对高频波动信息的表征能力。将提取的特征输入 BiLSTM 网络,对

轮廓误差序列的长期时间依赖关系进行建模,从而实现整体演化趋势的预测。

考虑到不同加工周期之间在误差演化方面具有一定相似性,且现有模型在局部不确定性较高区域仍可能存在预测偏差,笔者引入一种基于不确定性约束的相似性校正方法。该方法在嵌入特征空间中引入预测不确定性约束,引导模型在高风险区间自适应利用跨加工周期的相似误差信息,从机制层面弥补现有时序预测模型在高动态区间缺乏自校正能力的不足。笔者提出的预测模型框架与数据预处理流程如图 1 所示。




图1 预测模型框架与数据预处理流程

Fig.1 Framework of the prediction model and data preprocessing workflow

1.2 特征工程

笔者使用的加工数据来源于杭州机床集团长春第一机床厂的MK8312G数控凸轮轴磨床,设备结构与加工参数可参见文献[18]。所有数据均采集于实际凸轮磨削加工过程。通过内置编码器记录主轴旋转角度,同时由砂轮伺服系统采集砂轮进给轴的加工状态,采样频率为10 Hz。凸轮轮廓误差在一个加工周期完成后离线使用凸轮检测仪测得。图2为某规格凸轮片上下轮廓边界和加工轮廓曲线。需要指出的是,笔者所使用的数据并非来源于单一稳定工况,而是覆盖了多次加工及不同加工周期下的实际磨削过程。受砂轮磨损状态、进给参数微调以及切削载荷变化等因素影响,不同加工周期之间的




图2 凸轮片上下轮廓边界和加工轮廓曲线

Fig.2 Upper and lower contour boundaries of the cam lobe and the machined contour profile

轮廓误差信号在幅值水平、局部波动强度及动态演化趋势上均存在一定差异,体现了实际工程数据中普遍存在的分布不一致性与不确定性特征。

原始数据集包括多种规格凸轮毛坯的加工记

录,共计 18 000 条样本,每条样本包含 12 个原始特征。鉴于不同加工工况下误差曲线在局部区间可能出现异常波动或孤立噪声点,笔者采用“样本级筛选+特征级检测”的两阶段异常值处理流程,以避免异常数据对模型学习过程产生干扰,同时保证数据分布的代表性与一致性。

在样本层面,采用 K-中心点聚类方法基于误差曲线相似度对样本进行初步分组,并对异常点比例显著偏高的样本进行剔除。设样本集合 $G=\{g_1, g_2, \cdots, g_n\}$,则 K-中心点聚类方法的目标是最小化各样本到样本中心点的绝对距离之和。

K-中心点聚类的目标函数为

$$\min \sum_{i=1}^N \sum_{g_j \in P_i} \|g_j - m_i\|^2 \quad (1)$$

其中: g_j 为第 j 个样本向量; m_i 为第 i 个聚类中心; N 为聚类类别数; P_i 为第 i 个聚类簇。

式(1)主要用于消除明显偏离整体加工模式的异常样本。在样本级筛选完成后,对剩余数据进行主成分分析(principal component analysis,简称 PCA)以实现特征降维与筛选,通过保留累计贡献率达到 95% 的主成分来构建最优特征子集,从而保留主要方差信息并降低冗余特征干扰。经筛选得到的 6 个数据特征及其相关系数如表 1 所示。

对中心化后的特征矩阵 X ,通过特征分解得到协方差矩阵为

$$\Sigma = \frac{1}{n-1} X^T X = Q \Lambda Q^T \quad (2)$$

为了降低数据集中孤立噪声点对模型学习性能的影响,对各数据样本均使用基于马氏距离的多维异常点识别方法。设置信水平 $\alpha=0.997$,对特征计算马氏距离 D_M ,其表达式为

$$D_M(g) = \sqrt{(g - \mu)^T \Sigma^{-1} (g - \mu)} \quad (3)$$

其中: μ 为样本均值向量。

表 1 筛选出的 6 个数据特征及其相关系数

Tab.1 6 selected data features and their correlation coefficients

特征名称	相关系数
凸轮转角	0.295 8
凸轮升程	-0.765 3
相邻差	-0.738 8
砂轮进给量	0.310 1
砂轮进给速度	-0.764 8
砂轮进给加速度	0.278 1

若 $D_M(g) > \tau$,则该样本被视为异常点,并使用其他工况下同一特征样本点的均值进行替换,经异常值处理后,发现数据集中异常样本比例为 1.005 6%,数据清洗前后协方差变化比与相关矩阵变化比分别为 0.000 246 9% 和 0.077 017 7%。这说明该异常值处理流程在有效抑制噪声与异常扰动的同时,较好地保持特征间的相关结构与整体波动特性,未对数据统计分布产生显著影响。清洗前后的样本分布如图 3 所示。




图 3 清洗前后的样本分布

Fig.3 Samples before and after data cleaning

为了避免不同量纲差异对模型训练的影响,笔者对数据集进行了归一化处理,归一化公式为

$$\tilde{x}_{\text{norm}} = \frac{\tilde{x} - \tilde{x}_{\min}}{\tilde{x}_{\max} - \tilde{x}_{\min}} \quad (4)$$

其中: $\tilde{x}$ 为原始样本值; $\tilde{x}_{\min}$ 和 $\tilde{x}_{\max}$ 为该特征在训练集中的最小值与最大值; $\tilde{x}_{\text{norm}}$ 为归一化后的数据。

2 TCN-BiLSTM 轮廓误差预测方法

2.1 时间卷积神经网络

为有效提取多维加工数据中的时序特征,笔者在模型前端使用 TCN 在时间维度上进行多尺度卷积特征提取,其核心思想是通过膨胀卷积扩大时间感受野。图 4 为膨胀卷积网络结构示意图。

单层膨胀卷积定义为

$$(x *_d w)(t) = \sum_{k=0}^{K-1} w(k) x(t - dk) \quad (5)$$

其中: $x(t)$ 为输入序列在时刻 t 的值; $(x *_d w)(t)$ 为输入序列 $x(t)$ 与卷积核 w 在膨胀系数 d 下进行膨胀卷积后在时刻 t 的输出值; $w[t]$ 为卷积核权重; K 为卷积核大小。




图4 膨胀卷积网络结构示意图

Fig.4 Schematic diagram of the dilated convolutional network architecture

为保证感受野 Φ 覆盖输入滑动窗口长度 W_{win} , 需满足 $\Phi \geq W_{win}$, Φ 表示为

$$\Phi = 1 + (K - 1) \sum_{i=0}^{L-1} d_i = 1 + (K - 1)(2^L - 1) \quad (6)$$

膨胀卷积层数 L_{TCN} 的下界为

$$L_{TCN} \geq \left\lceil \log_2 \left(\frac{W_{win} - 1}{K - 1} + 1 \right) \right\rceil \quad (7)$$

为避免深层卷积堆叠导致的梯度消失问题, 每个TCN单元均采用残差连接结构, 即

$$\text{out} = \text{ReLU}(\text{ConvBlock}(x) + \text{Proj}(x)) \quad (8)$$

其中: $\text{ConvBlock}(x)$ 表示两层膨胀卷积与激活函数、随机失活组成的主分支; $\text{Proj}(x)$ 为 1×1 卷积的捷径分支。

TCN输出特征张量维度为 (B, Q_{out}, T) , 其中: B 为批量大小; Q_{out} 为卷积输出通道数; T 为时间步长。

2.2 Bi-LSTM神经网络

LSTM通过引入门控机制可有效缓解循环神经网络(recurrent neural network, 简称RNN)在长序列中容易出现的梯度消失和梯度爆炸问题。图5为LSTM单元结构图。其中: 遗忘门选择性遗忘上一时刻的细胞状态; 输入门控制输入信息对当前细胞状态的更新程度; 输出门决定数据状态输出。




图5 LSTM单元结构图

Fig.5 Structure of an LSTM unit

LSTM状态更新公式为

$$\begin{cases} f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \\ C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \\ o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \\ h_t = o_t \odot \tanh(C_t) \end{cases} \quad (9)$$

其中: x_t 为当前时刻的输入向量; h_{t-1} 为上一时刻的隐藏层状态; $\odot$ 表示按元素相乘的哈达玛积; C_t 为记忆单元状态。

考虑到实际加工中存在的周期性轨迹规划和时延耦合特性, 加工序列未来信息的统计特征包含了丰富的全局信息, 笔者在TCN后堆叠BiLSTM以建模双向时间信息。BiLSTM单元更新流程如图6所示。




图6 BiLSTM单元更新流程

Fig.6 Update process of the BiLSTM unit

BiLSTM更新公式为

$$\begin{cases} h_t^f = \text{LSTM}_f(x_t, h_{t-1}^f) \\ h_t^b = \text{LSTM}_b(x_t, h_{t+1}^b) \\ h_t^{\text{fb}} = [h_t^f; h_t^b] \\ y_t = W_a h_t^{\text{fb}} + b_a \end{cases} \quad (10)$$

其中: LSTM_f 与 LSTM_b 分别为正向与反向LSTM层; $[\cdot; \cdot]$ 为向量拼接; h_t^f 和 h_t^b 分别为正向和反向LSTM在时刻 t 的隐含状态输出; h_t^{fb} 为双向LSTM的融合隐含状态, 由前向与后向隐含状态拼接得到。

3 基于不确定性约束的嵌入空间误差自校正机制

考虑到在数控凸轮磨削等复杂加工过程中, 轮廓误差在曲率突变区及多轴强耦合区间呈现显著的非平稳性, 单一预测模型在局部区间易产生系统性偏差。然而, 实际加工过程中积累的大量历史误差序列中, 部分样本在加工机理与误差演化趋势上表现出高度一致性, 这为基于统计规律的局部残差修正提供了理论基础。基于此, 笔者提出一种基于

不确定性约束的嵌入空间误差自校正机制,用于对主预测模型的输出结果进行二次修正。

通过主模型特征提取层可获取样本的深层表示及其池化表示向量 $Z_i \in \mathbb{R}^d$,该向量表达了模型学习的加工机理。使用余弦相似度衡量样本在嵌入空间中的方向一致性,其定义为

$$S_{ij} = \frac{Z_i^T Z_j}{\|Z_i\| \|Z_j\|} \quad (11)$$

对于待修正样本 q ,从训练集中选取相似度最高的 k 个邻居构成邻域集合。设训练集中第 j 个样本的预测值为 $\hat{y}_j$,真实值为 y_j ,则该样本残差定义为

$$r_j = y_j - \hat{y}_j \quad (12)$$

基于高斯核函数对邻居残差进行加权求和,局部加权残差先验为

$$\tilde{r}_q = \sum_{j \in N_q} w_{qj} r_j \quad (13)$$

其中: w_{qj} 为权重。

权重 w_{qj} 的计算公式为

$$w_{qj} = \frac{\exp\left(-\frac{(1 - S_{qj})^2}{2\gamma^2}\right)}{\sum_{j \in N_q} \exp\left(-\frac{(1 - S_{qj'})^2}{2\gamma^2}\right)} \quad (14)$$

其中: γ 为相似性核带宽。

此过程从统计学习角度说明,在相似加工条件下残差存在可利用的规律性。

采用蒙特卡洛正则化方法在推理阶段进行 M 次前向传播,预测均值和方差分别为

$$\hat{\bar{y}} = \frac{1}{M} \sum_{m=1}^M \hat{y}_q^{(m)} \quad (15)$$

$$\sigma^2 = \frac{1}{M} \sum_{m=1}^M (\hat{y}_q^{(m)} - \hat{\bar{y}})^2 \quad (16)$$

将预测方差 σ^2 作为模型不确定性的代理指标输入修正模块,在高不确定性区间抑制过度修正,从不确定性传播角度保证修正稳健性。

考虑到嵌入空间中的样本关系通常呈现非欧氏结构,邻域内可能形成局部子簇,笔者引入图注意力网络(graph attention network,简称 GAT)对目标样本与其邻域样本进行关系建模。

对节点特征进行线性变换,即

$$\xi_i = W^{(g)} z_i \quad (17)$$

其中: $W^{(g)}$ 为节点特征变换权重矩阵。

节点间的注意力得分为

$$e_{ij} = \text{LeakyReLU}(a^T [|\xi_i| |\xi_j|]) \quad (18)$$

通过 softmax 函数归一化得到注意力权重为

$$\alpha_{ij} = \exp(e_{ij}) / \sum_j \exp(e_{ij'}) \quad (19)$$

节点 i 的聚合特征表示为

$$\xi'_i = \sum_j \alpha_{ij} W^{(g)} z_j \quad (20)$$

融合后的特征 $[\xi_i, \xi'_i]$ 与原始特征拼接后,一同输入轻量级图注意力网络,用于同时预测残差 $\hat{r}_i$ 和残差差分 $\Delta \hat{r}_i$,并捕捉残差幅值与局部变化趋势,实现对局部振荡与整体趋势一致性的联合控制。为保证误差修正过程中的趋势一致性,笔者设计的复合损失函数 $\mathcal{L}$ 为

$$\mathcal{L} = E[w_i(\hat{r}_i - r_i)^2] + \lambda E[(\Delta \hat{r}_i - \Delta r_i)^2] \quad (21)$$

其中: $E[w_i(\hat{r}_i - r_i)^2]$ 为残差回归项; $\lambda E[(\Delta \hat{r}_i - \Delta r_i)^2]$ 为差分约束项; λ 为趋势约束系数; w_i 为自适应样本权重,用于强化高幅值残差的影响,并抑制局部振荡。

w_i 定义为

$$w_i = 1 + \gamma \frac{|r_i|}{E[|r|] + \epsilon} \quad (22)$$

其中: γ 为不确定自适应权重,通过贝叶斯优化搜索得到最优值。

修正头输出一个经过 sigmoid 映射的置信系数 g_i ,且 $g_i \in [0, 1]$,则最终修正预测为

$$\hat{y}_i^{\text{corr}} = \hat{y}_i + g_i \hat{r}_i \quad (23)$$

该机制使模型能够在预测不确定性较高时调整修正幅度,从而达到提升整体预测稳定性的目的。

4 实验验证

4.1 实验环境配置

各实验模型使用的损失函数为 Huber 函数,该函数融合了均方误差(mean squared error,简称 MSE)和 MAE 的优势,能够在保持高拟合精度的同时,抑制异常值点对模型学习能力的影响。Huber 函数的表达式为

$$L_\delta(y, \hat{y}) = \begin{cases} \frac{1}{2} (y - \hat{y})^2 & (|y - \hat{y}| \leq \delta) \\ \delta |y - \hat{y}| - \frac{1}{2} \delta^2 & \text{其他} \end{cases} \quad (24)$$

笔者使用的模型评价指标为 RMSE、MAE 和决定系数,其表达式分别为

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (25)$$

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (26)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (27)$$

其中: y_i 为真实值; $\hat{y}_i$ 为模型预测值; n 为样本总数; $\bar{y}$ 为真实值均值。

可以看出, RMSE 和 MAE 越小, R^2 越大, 说明模型的预测精度越高, 预测结果越贴近真实值。训练集、验证集和测试集按 8:1:1 的比例划分。实验所用 Python 版本为 3.12; 实验计算机配置为 Intel Core i5-14600KF 处理器及 NVIDIA GeForce RTX 5060 显卡。

4.2 对比实验

为系统评估不同时序建模结构在轮廓误差预测任务中的性能差异, 笔者构建了 CNN-LSTM、CNN-BiLSTM、CNN-GRU、TCN-LSTM、TCN-BiLSTM 及 TCN-GRU 共 6 种混合模型作为对比模型。为保证不同模型在对比实验中的公平性与结果可复现性, 笔者对所有对比模型采用统一的超参数搜索策略与训练配置。超参数搜索空间主要包括学习率、随机失活率、隐藏层单元数以及全连接层尺寸。其中: 学习率搜索范围设为 $[10^{-4}, 10^{-2}]$; 随机失活率设为 $[0.1, 0.3]$; 隐藏层单元数与全连接层尺寸分别在合理的整数区间内进行搜索。


采用贝叶斯优化方法对上述超参数进行联合搜索, 其优势在于能够在有限搜索次数下高效逼近最优解, 从而降低人工经验设定对模型性能评估的影响。实验通过对验证集损失函数的收敛情况进行监控, 发现当迭代次数达到约 400 次后, 各模型的验证损失趋于稳定, 继续增加搜索次数对性能提升已不再显著。因此, 选取 400 次作为统一的搜索迭代次数, 最终得到的各模型搜索最佳参数如表 2 所示。

表 2 各模型搜索最佳参数

Tab.2 Optimal parameters identified for each model


模型	学习率	随机失活率	隐藏层单元数	全连接层
CNN-LSTM	0.004 9	0.104 4	117	35
CNN-BiLSTM	0.003 5	0.215 2	99	40
CNN-GRU	0.003 9	0.105 5	96	33
TCN-LSTM	0.005 3	0.280 8	154	60
TCN-BiLSTM	0.006 7	0.100 3	154	60
TCN-GRU	0.005 3	0.195 9	101	71

在统一训练策略下, 各模型均输出 240 个采样点的预测结果。各模型真实值与预测值对比曲线以及各模型预测残差对比曲线分别如图 7、8 所示。



(a) CNN系列模型真实值与预测值对比曲线

(a) Comparison curves of the true and predicted values for the CNN-based models




(b) TCN系列模型真实值与预测值对比曲线

(b) Comparison curves of the true and predicted values for the TCN-based models


图 7 各模型真实值与预测值对比曲线

Fig.7 Comparison curves of the true values and predicted values for each mode



(a) CNN系列各模型预测残差对比曲线

(a) Comparison curves of prediction residuals for the CNN-based model



(b) TCN系列各模型预测残差对比曲线

(b) Comparison curves of prediction residuals for the TCN-based models

图 8 各模型预测残差对比曲线

Fig.8 Comparison curves of prediction residuals for each model

从图 7 可知,CNN-LSTM、CNN-BiLSTM 与 CNN-GRU 模型在多个区间内均存在较为明显的预测偏移,尤其在采样点 50~100 的误差累积阶段,其预测曲线波动幅度显著增大,并在采样点个数约为 150 处出现突变性偏离。这表明仅依赖 CNN 与单向或双向循环结构的模型在应对长期误差积累与局部突变并存的复杂误差模式时存在明显局限。相比之下,TCN-BiLSTM 模型的预测曲线在全区间内与真实值保持高度重合,尤其在误差累积区间(采样点个数为 50~100)内,其能够持续维持较小的预测偏差,体现出其在多尺度时序特征提取与前后时序依赖建模方面的协同优势。

从图 8 可以看出,TCN-BiLSTM 模型在关键误差累积区间内的残差幅值显著低于其他模型,且整体残差分布更为平稳,未出现明显的结构性偏移。

各模型评价指标如表 3 所示。可以看出,在相同训练与优化条件下,各模型呈现出稳定且清晰的性能梯度分布,其中 TCN-BiLSTM 模型的所有评价指标均表现最优。具体而言:①其 RMSE 为 0.234 098 μm ,较 TCN-GRU 降低约 19.1%,较 CNN-LSTM 模型降低约 52%,表明该模型在抑制整体预测偏差方面具有显著优势;②其 MAE 为 0.146 243 μm ,较 TCN-LSTM 降低 58.2%,说明 TCN-BiLSTM 在刻画轮廓误差峰值及局部剧烈波动方面具备更强的拟合能力;③该模型的决定系数达到 0.998 08,在所有对比模型中最高,反映出其对轮廓误差整体变化趋势具有高度一致性。

表 3 各模型评价指标

Tab.3 Evaluation metrics of each model			
模型	$E_{\text{RMSE}}/\mu\text{m}$	$E_{\text{MAE}}/\mu\text{m}$	R^2
TCN-BiLSTM	0.234 098	0.146 243	0.998 08
TCN-GRU	0.289 274	0.172 351	0.997 05
TCN-LSTM	0.422 573	0.349 705	0.993 85
CNN-BiLSTM	0.499 675	0.356 532	0.991 37
CNN-GRU	0.392 352	0.266 955	0.994 71
CNN-LSTM	0.493 786	0.339 775	0.991 60

图 9 为对比模型残差分布箱线图。可以发现:TCN-BiLSTM 的残差中位数最接近 0,且箱体高度最小,说明其预测误差的整体离散性最低;其余模型在中位误差及四分位距方面均有不同程度的增大,表明双向时序建模与多尺度卷积结构的协同设计对预测不稳定性具有明显抑制作用。

图 10 为对比模型预测残差核密度分布图。TCN-BiLSTM 的误差概率密度在零值附近形成最为集中且尖锐的主峰,同时分布宽度最小,进一步验证了该模型在预测稳定性方面的优势。




图 9 对比模型残差分布箱线图

Fig.9 Box plots of residual distributions for the benchmark models




图 10 对比模型预测残差核密度分布图

Fig.10 Kernel density plots of prediction residuals for the benchmark models

图 11 为对比模型性能雷达图。可以看出,TCN-BiLSTM 模型的整体性能显著优于其余对比模型,验证了所选网络结构在轮廓误差预测任务中的合理性与有效性。




图 11 对比模型性能雷达图

Fig.11 Radar chart of performance for the benchmark models

4.3 消融实验

为了验证各个模块与笔者所提方法的有效性,对 TCN、BiLSTM、TCN-BiLSTM 和 TCN-BiLSTM-UEER 模型进行了比较。各消融模型的性能指标如表 4 所示。可以看出,各模型性能差异显著。TCN-BiLSTM-UEER 在 3 项评价指标上均取得最优结果,其 RMSE 为 0.228 17 μm ,相较未引入 UEER 的 TCN-BiLSTM 进一步降低约 2.5%;其

MAE 由 0.146 243 μm 降至 0.141 32 μm , 降幅约 3.4%; 其 R^2 由 0.998 08 提升至 0.998 88。以上结果表明, UEER 机制能够在不破坏原模型结构优势的前提下, 同时提升预测精度与稳定性。

Tab.4 Performance metrics of the ablation models			
模型	$E_{\text{RMSE}}/\mu\text{m}$	$E_{\text{MAE}}/\mu\text{m}$	R^2
TCN-BiLSTM-UEER	0.228 170	0.141 320	0.998 88
TCN-BiLSTM	0.234 098	0.146 243	0.998 08
BiLSTM	0.468 953	0.335 059	0.992 45
TCN	0.485 446	0.296 904	0.991 72

图 12 为校正前后的残差曲线对比。可以看到, 经 UEER 修正后的预测残差峰值显著降低, 在采样点个数 140~160 的高不确定性区间内, 最大残差由 0.972 μm 降至 0.789 μm 。这说明该机制能够在局部不确定性增强区域内自适应提高约束强度, 从而有效抑制极端预测偏差。




图 12 校正前后的残差曲线对比
Fig.12 Comparison of residual curves before and after correction

图 13 为消融模型残差分布箱线图。TCN-BiLSTM-UEER 模型的残差中位数最接近 0, 四分位距最小, 且上下须长度明显短于其余对比模型, 表明该模型在整体预测过程中具有更小的误差波动范围与更强的一致性。同时, 其离群点数量与幅值均显著减少, 进一步验证了 UEER 机制在抑制极端预测误差方面的有效性。




图 13 消融模型残差分布箱线图
Fig.13 Box plots of residual distributions for the ablation models

图 14 为消融模型预测残差核密度分布图。可以看出, TCN-BiLSTM-UEER 的误差概率密度在零值附近形成最尖锐且集中的主峰, 且两侧尾部快速收敛。这说明其预测残差主要集中分布在零附近, 极端误差发生概率显著降低。相比之下, 其余消融模型的概率密度曲线均表现出不同程度的分布展宽与峰值降低, 反映出预测不确定性的增加。




图 14 消融模型预测残差核密度分布图
Fig.14 Kernel density plots of prediction residuals for the ablation models

综上所述, 消融实验结果充分验证了笔者所提出方法中各功能模块的有效性。TCN 与 BiLSTM 的结构协同作用, 显著提升了模型对复杂轮廓误差模式的建模能力, 引入 UEER 机制进一步增强了模型在高不确定性区域内的预测稳定性与鲁棒性, 使整体预测精度得到持续提升。

5 结 论

1) 笔者以凸轮磨削加工过程为研究对象, 提出了一种融合 TCN-BiLSTM-UEER 的机床加工误差预测方法。该方法融合了 TCN 的局部短时特征提取效率与 BiLSTM 双向长期时序依赖建模的优势, 相似性修正模块进一步对主模型输出的预测值进行自适应校正, 并通过贝叶斯优化算法搜索得到最佳超参数组合, 进一步提高了模型的鲁棒性。

2) 在对比实验中, 笔者所提出的模型在 RMSE、MAE 和 R^2 这 3 项指标上均优于其他模型, 数值分别为 0.234 098 μm 、0.146 243 μm 和 0.998 08, 均与真实值的拟合效果最佳。在消融实验中, 所提出方法在各模块的协同作用下各项性能指标达到最佳。引入 UEER 后, 模型性能进一步提升: RMSE 降低 2.53%, MAE 降低 3.37%, 决定系数 R^2 达到了 0.998 88, 表明该模块能有效提升模型的拟合效果。

3) 笔者将致力于把模型部署到实际加工场景或仿真平台, 通过预测模型与前馈补偿的闭环协同, 以实现提高机床加工精度的目的。

参 考 文 献

- [1] 田海龙, 孙雨治, 杨兆军, 等. 数控机床可靠性的故障模式、影响及危害分析研究现状及发展趋势[J]. 中国机械工程, 2025, 36(7): 1430-1441.
TIAN Hailong, SUN Yuzhi, YANG Zhaojun, et al. Research status and development trends of failure modes, effects, and criticality analysis for CNC machine Tool reliability[J]. China Mechanical Engineering, 2025, 36(7): 1430-1441. (in Chinese)
- [2] CHEN G C, DING S, XU G C. Novel method for identifying sensitive geometric errors of CNC machine tools oriented to cylindricity in flank milling[J]. Journal of Manufacturing Processes, 2024, 126: 370-381.
- [3] ZHANG C J, LIU H L, ZHOU Q L, et al. A support vector regression-based method for modeling geometric errors in CNC machine tools[J]. The International Journal of Advanced Manufacturing Technology, 2024, 131(5): 2691-2705.
- [4] AN J F, CHAO Y C, ZHAO Y W, et al. An innovative load forecasting model for ground source heat pump systems integrating mechanistic constraints and CNN-ATT-LSTM framework[J]. Energy, 2026, 348: 140546.
- [5] ZHU X F, JI S, ZHANG Y B, et al. Adaptive iterative learning control for MIMO systems with nonuniform trial lengths and alignment constraints[J]. IAENG International Journal of Applied Mathematics, 2026, 56(3): 1041-1050.
- [6] 梁天添, 刘健, 梁贺焱, 等. 轴承剩余使用寿命预测的 IDSA-LSTMNN[J]. 振动、测试与诊断, 2025, 45(2): 273-280.
LIANG Tiantian, LIU Jian, LIANG Heyan, et al. IDSA-LSTMNN for prediction of bearing remaining useful life[J]. Journal of Vibration, Measurement & Diagnosis, 2025, 45(2): 273-280. (in Chinese)
- [7] HODGINS L, FREEMAN C T. Robust iterative learning control for unstable MIMO systems[J]. International Journal of Robust and Nonlinear Control, 2025, 35(10): 503141.
- [8] CHEN X H, CHEN G S, SUN Y S. Research on thermal error modeling of machine tool electric spindle based on SSA-NAR-LSTM[J]. Journal of Mechanical Engineering Science, 2026, 240(6): 2052-2063.
- [9] XU H J, HINZE C, XU L H, et al. Time-optimal feedrate planning for real-time CNC machining via transformation between parametric and time spaces[J]. Journal of Manufacturing Processes, 2026, 158: 401-413.
- [10] WANG J, ZHANG J, ZHANG F W, et al. Measurement-based two-layer optimization scheme for machining system with repetitive and batch characteristics[J]. The International Journal of Advanced Manufacturing Technology, 2022, 121(3): 2553-2563.
- [11] WANG J W. Life prediction of NC machine tools based on DT technology and LSTM technology[J]. Frontiers in Mechanical Engineering, 2025, 11: 1727068.
- [12] 李帅杰, 陈光胜. 基于 GA-BP 网络的数控机床动态误差预测研究[J]. 机电工程, 2024, 41(10): 1747-1758.
LI Shuaijie, CHEN Guangsheng. Dynamic error prediction of CNC machine tools based on a GA-BP neural network[J]. Journal of Mechanical & Electrical Engineering, 2024, 41(10): 1747-1758. (in Chinese)
- [13] 李国龙, 陈孝勇, 李喆裕, 等. 采用天鹰优化卷积神经网络的精密数控机床主轴热误差建模[J]. 西安交通大学学报, 2022, 56(8): 51-61.
LI Guolong, CHEN Xiaoyong, LI Zheyu, et al. Thermal error modeling of spindle for precision CNC machine tool based on AO-CNN[J]. Journal of Xi'an Jiaotong University, 2022, 56(8): 51-61. (in Chinese)
- [14] XU Z C, FAN L L, YIP W S, et al. Intelligent contour error compensation of ultraprecision machining using hybrid mechanism-data-driven model assisted with IoT framework[J]. IEEE Transactions on Industrial Informatics, 2024, 20(10): 11815-11824.
- [15] 梁佳鑫, 马志赛, 丁千, 等. 数据驱动的发动机剩余使用寿命直接预测[J]. 振动、测试与诊断, 2026, 46(1): 55-62.
LIANG Jiaxin, MA Zhisai, DING Qian, et al. Direct prediction of remaining useful life for engines by using data-driven approaches[J]. Journal of Vibration, Measurement & Diagnosis, 2026, 46(1): 55-62. (in Chinese)
- [16] WANG L, HAN J, TANG Z, et al. Geometric accuracy design of high performance CNC machine tools: modeling, analysis, and optimization[J]. Journal of Mechanical Engineering, 2025, 38: 87.
- [17] 王静, 寇梓良, 张西宁, 等. 基于多模态数据融合与改进 CNN 的轴承故障诊断[J]. 振动、测试与诊断, 2025, 45(6): 1082-1089.
WANG Jing, KOU Ziliang, ZHANG Xining, et al. Bearing fault diagnosis based on multimodal data fusion and improved CNN[J]. Journal of Vibration, Measurement & Diagnosis, 2025, 45(6): 1082-1089. (in Chinese)
- [18] 朱岸锋, 赵前程, 周凌, 等. 基于 CNN-LSTM-Attention 的风电机组状态监测与健康评估[J]. 振动、测试与诊断, 2025, 45(2): 256-263.
ZHU Anfeng, ZHAO Qiancheng, ZHOU Ling, et al. Condition monitoring and health assessment of wind turbine based on CNN-LSTM with attention[J]. Journal of Vibration, Measurement & Diagnosis, 2025, 45(2): 256-263. (in Chinese)



第一作者简介:王静,女,1990年3月生,博士、副教授。主要研究方向为高精度数控凸轮磨削技术。曾发表《Measurement-based two-layer optimization scheme for machining system with repetitive and batch characteristics》(《The International Journal of Advanced Manufacturing Technology》2022, Vol.118, No.3)等论文。
E-mail: wjing@hpu.edu.cn