

文章编号 1004-924X(2025)23-3765-19

基于改进 GRU 神经网络的刀具磨损状态预测

巢 渊^{1,2,3*}, 张俊杰¹, 谈齐峰¹, 张宜珺¹, 戴国洪¹, 夏志杰^{2,3}, 张志胜^{2,3*}

(1. 江苏理工学院 机械工程学院, 江苏 常州 213001;

2. 东南大学 机械工程学院, 江苏 南京 211189;

3. 江苏省高档数控机床及成套装备创新中心, 江苏 南京 211189)

摘要:针对传统智能监测方法中信号特征提取繁琐,以及铣削过程中刀具磨损对工件质量和生产效率的影响等问题,提出一种基于改进 GRU 神经网络的刀具磨损状态预测方法(BiGRU-1DCNN-CBAM)。利用统计量、时域分析、频域分析和小波变换等方法提取刀具信号的均值、峰度和功率谱密度等 24 个特征量,将多模态时间序列数据转换为刀具特征的时间序列图像;引入卷积神经网络挖掘信号数据的深层特征,结合卷积注意力机制模块增强模型对振动和切削力信号特征图的捕捉能力,将特征层展平拼接后输入 BiGRU 捕获长时依赖,通过全连接层回归刀具磨损量,实现数控加工过程中刀具磨损状态的剩余寿命预测。实验结果表明,该模型在 PHM2010 数据集上的均方根误差(RMSE)和平均绝对误差(MAE)分别为 2.17 μm 和 1.29 μm ,相比 Bayesian-MCMC-Prognostics, SBiLSTM, RIME-CNN-SVM, MobilenetV3, TDConvLSTM, ISABO-IBiLSTM, IWOA-IECA-BiLSTM, LSTM-CNN-CBAM 等模型,提升分别超过 40.5% 和 52.1%,相比同类模型耗时至少减少 2.8%。本文提出的模型能够有效表征刀具磨损程度,减小预测误差,取得了较好的预测效果。

关键词:刀具磨损;深度学习;卷积神经网络(CNN);门控循环单元(GRU);注意力模块;状态预测

中图分类号:TP391.4;TP183 **文献标识码:**A

doi:10.37188/OPE.20253323.3765

CSTR:32169.14.OPE.20253323.3765

Tool wear state prediction based on improved GRU neural network

CHAO Yuan^{1,2,3*}, ZHANG Junjie¹, TAN Qifeng¹, ZHANG Yijun¹, DAI Guohong¹,
XIA Zhijie^{2,3}, ZHANG Zhisheng^{2,3*}

(1. School of Mechanical Engineering, Jiangsu University of Technology, Changzhou 213001, China;

2. School of Mechanical Engineering, Southeast University, Nanjing 211189, China;

3. Jiangsu Nangao High-end CNC Machine Tools and Complete Equipment Manufacturing Industry
Innovation Center, Nanjing 211189, China)

* Corresponding author, E-mail: chaoyuan@jsut.edu.cn; oldbc@seu.edu.cn

Abstract: To address the challenges of cumbersome signal feature extraction in traditional intelligent monitoring methods and the adverse effects of tool wear on workpiece quality and production efficiency during milling, a tool wear state prediction method based on an improved GRU neural network (BiGRU-1DCNN-CBAM) is proposed. Using statistical methods, time-domain analysis, frequency-domain analy-

收稿日期:2025-08-10; **修订日期:**2025-09-08.

基金项目:国家自然科学基金资助项目(No. 51905235);江苏省自然科学基金资助项目(No. BK20191037);江苏高校“青蓝工程”项目(No. KYQ23002)

sis, and wavelet transform, 24 feature parameters of the tool signals-such as mean, kurtosis, and power spectral density-are extracted, and the resulting multimodal time-series data are converted into time-series images of tool features. A convolutional neural network (CNN) is then introduced to mine deep features of the signal data, and a convolutional block attention module (CBAM) is integrated to enhance the capability of the model to capture feature maps of vibration and cutting force signals. After flattening and concatenating the feature layers, the fused features are fed into a bidirectional GRU (BiGRU) to capture long-term dependencies, and the tool wear amount is predicted through a fully connected layer, thereby enabling remaining useful life prediction of the tool wear state during CNC machining. Experimental results on the PHM2010 dataset show that the RMSE and MAE of the proposed model are $2.17\text{ }\mu\text{m}$ and $1.29\text{ }\mu\text{m}$, respectively. Compared with Bayesian-MCMC-Prognostics, SBiLSTM, RIME-CNN-SVM, MobileNetV3, TDConvLSTM, ISABO-IBiLSTM, IWOA-IECA-BiLSTM, and LSTM-CNN-CBAM models, the prediction accuracy in terms of RMSE and MAE is improved by more than 40.5% and 52.1%, respectively, while the time consumption is reduced by at least 2.8% relative to similar models. These results demonstrate that the proposed model can effectively characterize tool wear, reduce prediction errors, and achieve superior prediction performance.

Key words: tool wear; deep learning; Convolutional Neural Network (CNN); Gate Recurrent Unit (GRU); attention module; state prediction

1 引言

随着现代工业自动化的发展,预测与健康管理技术在制造系统中得到广泛应用。在机械加工过程中,由于受到切削力、切削热和冲击振动的影响^[1],切削刀具会产生一定程度的磨损,影响工件表面质量^[2]和加工成本。据统计,刀具失效已成为导致机床停机的关键因素^[3]。因此,在加工过程中监测切削刀具的磨损状态意义重大。

根据监测方式的不同,刀具磨损状态监测方法可分为直接测量法和间接测量法两类。鉴于直接测量法难以实现在线监测,间接测量法在工业场景中更具优势^[4]。现有研究通过融合多传感器数据,结合混合域特征提取技术^[5]构建基于深度学习的预测模型^[6],有效解决了工序干扰问题。在金属切削过程中,工况条件包括刀具类型、切削宽度、进给量等切削工艺参数。单一定工况是指工况条件保持不变的工况;多种定工况是多种不同单一定工况的组合。本文将多种定工况称为复杂工况^[7]。

间接测量法研究难点集中于在复杂工况下的信号去噪、特征融合及模型实时性。根据建模机理差异,间接测量法可分为物理驱动与数据驱动^[8]。物理驱动模型通过构建退化过程的数学模

型^[9]实现磨损分析,如马尔可夫链^[10]、Wiener过程算法^[11]、高斯混合模型^[12]和伽马过程算法^[13]。文献[14]提出一种 Bayesian-MCMC-Prognostics 模型算法,通过整合振动、温度和声发射等多源传感器监测数据,结合贝叶斯方法动态更新刀具运行状态的概率分布,进而实现刀具剩余寿命的高精度预测。该方法的核心特点在于多源数据融合、概率推断及自适应学习,关键参数则涵盖传感器原始监测数据、刀具状态概率的先验与后验分布,以及多维度监测特征的提取结果。

基于数据驱动模型的算法,如卷积神经网络(Convolutional Neural Network, CNN)^[15]和长短时记忆网络(Long Short-Term Memory, LSTM)^[16]都展现出较好的特征学习和映射能力。文献[3]提出 LSTM-CNN-CBAM 刀具磨损监测方法,融合卷积神经网络,长短时记忆网络(Long Short-Term Memory network, LSTM)和卷积块注意力模块(Convolutional Block Attention Module, CBAM)注意力机制优势,提取局部突发异常或高频噪声的瞬时特征,增强状态敏感度,实现有效的刀具磨损预测。文献[15]提出一种轻量化 CNN 与时间序列模型融合的刀具磨损识别方法(MobilenetV3),将铣刀加工时产生的力信号与振动信号经格拉姆角场处理转化为图

像数据集,有效减少了模型体积与刀具磨损识别的计算量。文献[17]提出了一种基于堆叠双向长短时记忆网络(Stacked Bidirectional LSTM, SBiLSTM),通过双向处理和多层堆叠结构,能够全面捕捉时间序列数据中的复杂模式和长期依赖关系,提供高精度的刀具状态剩余寿命预测。文献[18]提出基于雾凇算法 RIME 优化 VMD 参数并结合 EDO 增强突变识别的行波波头标定方法,通过精细化特征处理与关键信息强化,有效提升了故障定位精度与抗噪能力,其核心思路与数据驱动模型的特征学习逻辑具有内在一致性。基于该方法的设计启发,可进一步构建 RIME-CNN-SVM 模型,通过多阶段协同处理,引入 RIME 优化 CNN 以提取复杂工况下的特征表示,采用支持向量机(SVM)开展回归分析,用于刀具剩余寿命预测。文献[19]提出一种基于时间分布式卷积长短期记忆网络(Time-distributed Convolutional LSTM, TDConvLSTM)的方法,通过融合 Time-Distributed 层与 ConvLSTM 的深度学习架构,从多维传感器数据中自动提取局部特征和时间依赖关系,实现刀具磨损的有效预测。文献[20]提出一种改进减法优化器(SABO)优化改进双向长短时记忆网络(BiLSTM)模型参数的刀具磨损预测方法(ISABO-BiLSTM),规避参数随机化引发的预测结果大幅波动,有效降低预测结果的平均绝对误差与均方根误差,实现对刀具磨损的稳定预测。文献[21]提出一种基于 IWOA-IECA 优化 BiLSTM 的刀具磨损监测方法(IWOA-IECA-BiLSTM),建立融合改进鲸鱼优化算法(IWOA)与改进高效通道注意力机制(IECA)的双向长短期记忆网络(BiLSTM),实现了对刀具退化趋势的高精度追踪与早期预警。文献[22]提出的 CNN-LSTM 混合模型,整合 CNN 的局部特征提取与 LSTM 的时序建模优势,结合多维度特征提取减少信息丢失,提升了刀具剩余寿命预测准确性。但 LSTM 结构复杂、参数多,训练效率较低,且处理超长时序时对长时依赖的捕捉灵活性不足。文献[23]在 LSTM 的基础上进一步的创新,引入了门控循环网络(Gate Recurrent Unit, GRU),GRU 使用重置门和更新门替代了 LSTM 网络中的三个门控机制,这一改进使得模型在保持时序

数据处理能力的同时,能够有效提升运算效率,尤其适用于对实时性要求较高的生产预测场景,为平衡模型性能与计算成本提供了可行的优化思路。

针对现有模型在复杂工况下分析时存在信号噪声、特征选择、模型优化、实时处理能力和长期稳定性等局限性,本文提出了一种基于改进 GRU 神经网络的刀具磨损状态预测模型(BiGRU-1DCNN-CBAM)。该模型提出双向门控循环单元(BiGRU)与一维卷积神经网络(1DCNN)的深度融合架构,突破传统单向时序建模的局限性,通过双向信息流捕获更完整的时序依赖关系,并嵌入 CBAM^[24],构建了一个从通道到空间的顺序注意力结构,以最小化噪声对原始数据的影响。在数据集构建方面,设计了多传感器信号同步采集与特征融合策略,构建了包含振动、切削力、声发射等多模态信息的刀具磨损数据集。通过构建数据集开展多组对比实验,验证了所提方法在刀具磨损预测精度、抗干扰能力及计算效率方面的优势。

2 原 理

刀具磨损过程是一个包含复杂物理变化的长期动态过程,其磨损数据往往呈现出非线性、时变且夹杂噪声的特征;而在实际生产加工环境中,针对刀具磨损状态的预测算法不仅需要具备高度的准确性以应对这些复杂数据特征,还需要拥有高效率,以满足实时监控和快速响应的实际需求。GRU 算法能够自适应地保留刀具长期使用过程中的关键磨损信息并且灵活捕捉当前磨损阶段的显著特征。因此,本文基于 GRU 基础框架,研究并提出一种适用于工业生产环境中的刀具磨损状态预测算法,预测框架如图 1 所示。具体步骤如下:

(1)多通道传感器数据和刀具后刀面磨损值实时采集与存储,并将时间序列数据输入数据预处理模型;

(2)标准化处理时间序列数据,去除异常值后分割为多个子序列,各子序列作为特征向量表示特定时间段内的传感器读数变化;

(3)将若干个子序列数据输入主干网络进行特征提取,结合傅里叶变换(Fourier Transform,

FT)和小波变换(Wavelet Transform, WT)^[25]操作,从时域、频域和时频域三个维度对信号数据进行混合域特征提取;

(4)构建BiGRU-1DCNN-CBAM模型,使其能将振动信号、声发射信号和切削力信号等时间序列数据作为输入,输出对应的刀具磨损预测值,并与测量得到的刀具磨损值进行对比,计算出均方根误差、平均绝对误差和决定系数等能够代表模型的预测精度与拟合效果性能的评价指标。




图1 基于BiGRU-1DCNN-CBAM的刀具磨损预测框架
Fig.1 Schematic diagram of BiGRU-1DCNN-CBAM for tool wear prediction

3 算法描述

3.1 数据集制作

PHM2010 刀具磨损数据集^[26]在小样本预测场景下具有显著代表性,能同时契合工业实际与学术研究需求^[16-21]。该数据集包含 6 组铣削实验,每组实验具备 315 组多模态特征,且磨损标签通过高精度光学测量获取,为刀具状态评估提供了基准金标准。鉴于本文聚焦数控机床加工过程中刀具磨损状态预测问题,因此针对切削力、振动信号及声发射均方根值等多类测量参数,对 PHM2010 刀具磨损公开数据集开展数据缺失筛选、特征提取及时频域信号分析处理,最终构建用于刀具磨损状态预测的数据集。图 2~图 4 分别展示了具有代表性的刀具磨损关键特征数据。其中,图 2 反映了切削力的趋势、波动和分布变化,图 3 体现了切削过程的稳定性、频率成分和幅值变化,图 4 表征了微裂纹扩展、材料断裂、摩擦特性及早期预警特征。

本文为实现高精度刀具磨损状态预测,通过




图2 x 方向的切削力信号

Fig.2 Cutting force signal in x direction




图3 x 方向的加速度信号

Fig.3 Acceleration signal x direction




图4 声发射均方根值信号

Fig.4 Acoustic emission RMS signal

数据预处理获取刀具磨损的时域、频域和时频域特征,图 5 为数据预处理流程。针对 PHM2010

刀具磨损数据集中,用于刀具剩余寿命预测的选取样本,因实验传感器异常、信号干扰、物理规律偏差等原因,普遍存在数据缺失的问题^[3],采用基于局部时序相关性的随机填充策略。以缺失点为中心,取其前 5 个时间步与后 5 个时间步的时域特征数据,通过计算该局部窗口内数据的分布范围及波动特征,在该区间内生成符合原始数据分布特性的随机值进行填充。此方法既保障了数据完整性,又通过锚定缺失点前后的时序动态趋势,避免了填充值与原始信号规律的偏离。之后对每个样本开展时域分析,按照式(1)~式(6)依次计算绝对均值 y_1 、均方根值 y_2 、方根幅值 y_3 、峰值 y_4 、歪度值 y_5 和峭度值 y_6 6 项时域特征。波形因子 $y_7 = y_2/y_1$ 、峰值因子 $y_8 = y_5/y_2$ 、脉冲因子 $y_9 = y_5/y_1$ 、裕度因子 $y_{10} = y_4/y_3$ 、峭度因子 $y_{11} = y_6/y_2^4$ 和歪度因子 $y_{12} = y_5/y_2^3$ 可通过前 6 项时域特征计算获得。

$$y_1 = \frac{1}{N} \sum_{i=1}^N |x(i)|, \quad (1)$$

$$y_2 = \sqrt{\frac{1}{N} \sum_{i=1}^N x(i)^2}, \quad (2)$$

$$y_3 = \left(\frac{1}{N} \sum_{i=1}^N \sqrt{|x(i)|} \right)^2, \quad (3)$$

$$y_4 = \max(|x(i)|), \quad (4)$$

$$y_5 = \frac{\sum_{i=1}^N (|x(i)| - y_1)^3}{N}, \quad (5)$$

$$y_6 = \frac{\sum_{i=1}^N (x(i))^4}{N}, \quad (6)$$

其中: $x = [x_1, x_2, \dots, x_N]$ 为每个采样周期内采集的振动信号, N 表示单个采样周期内振动信号的采样点数。

如式(7)所示,通过快速傅里叶变换(Fast Fourier Transform, FFT)将时间序列数据转换为频域数据,提取关键特征评估刀具磨损状态。对时域信号 $x(t)$ 进行离散化处理,得到长度为 N 的时间序列数据 $x = [x_1, x_2, \dots, x_N]$ 。

$$X = FFT(x), \quad (7)$$

其中: X 是一个包含复数值的向量,每个元素代表了不同频率分量下的振幅和相位信息。

按照式(8)~式(11)分别计算频率的均值

F_1 、频率重心 F_2 、均方根频率 F_3 和标准差频率 F_4 这四项频域特征。 F_1 表示信号在频域内不同频率成分幅值的均值; F_2 表示信号频谱的重心位置,描述了频谱中分量较大的峰值对应的横坐标频率; F_3 能描述信号频域内整体能量分布情况; F_4 反映了信号频谱的离散程度或集中程度。

$$F_1 = \frac{\sum_{k=1}^K s(k)}{K}, \quad (8)$$

$$F_2 = \frac{\sum_{k=1}^K s(k) f_k}{\sum_{k=1}^K s(k)}, \quad (9)$$

$$F_3 = \sqrt{\frac{\sum_{k=1}^K s(k) f_k^2}{\sum_{k=1}^K s(k)}}, \quad (10)$$

$$F_4 = \frac{\sum_{k=1}^K s(k) \sqrt{|f_k - F_2|}}{K \sqrt{\frac{\sum_{k=1}^K s(k) (f_k - F_2)^2}{K}}}, \quad (11)$$

其中: $s(k)$ 表示第 k 个频率分量的幅值, f_k 是第 k 个离散频率值, K 为频域分析中离散频率点的总个数。

通过小波包变换(Wavelet Packet Transform, WPT)对时间序列数据进行多分辨率分析,捕捉信号中的瞬态信息和频率成分变化。利用WPT结合时频域分析的优点,提取综合特征来评估刀具磨损状态,从而提高机械系统健康监测的精度和有效性。

为了深入分析非平稳信号的局部特征,采用三层小波包分解技术。利用小波基函数对原始的时间序列数据 $x(t)$ 进行小波包变换。通过三层小波包分解,可以得到8个不同子带的近似(A)和细节(D)系数。每个子带的系数可以通过访问相应的节点获得,为了量化各个子带的能量分布情况,计算每个子带系数的L2范数,得到:

$$ret_i = \|subband_i\|_2 \quad i = 1, 2, \dots, 8, \quad (12)$$

其中: $subband_i$ 表示第 i 个子带的系数, $\|\dots\|_2$ 表示L2范数运算。

综上,首先对数据点缺失信息进行随机填充以保障数据完整性;接着开展时域特征提取,计




图5 刀具磨损状态预测数据预处理流程

Fig. 5 Flow chart of data pre-processing for tool wear state prediction

算得到 12 项时域特征;随后通过 FFT 转换实施频域特征提取,得到 4 项频域特征;再进行三层小波包分解分析,计算子带 L2 范数,在特定子带能量占比提升至 15%,实现弱特征强化;之后对各维度特征进行整合形成特征集,同时通过 Pearson 相关性分析(以阈值 $|r| < 0.6$ 为标准)^[27],构建出包含 315 组有效样本、24 维混合域特征的刀具磨损预测数据集。

3.2 主干网络改进

3.2.1 激活函数

传统 GRU 采用 Sigmoid 和 Tanh 激活函数以确保门控单元的概率特性,如式(13)~式(16)所示,但其饱和特性限制了模型对非线性特征的捕捉能力,刀具磨损过程往往呈现强非线性和突变特征,导致传统 Sigmoid 函数难以有效捕捉这些特征。

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]), \quad (13)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]), \quad (14)$$

$$\tilde{h}_t = \tanh(W \cdot [r_t * h_{t-1}, x_t]), \quad (15)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t, \quad (16)$$

其中: x_t , h_{t-1} , h_t , $\tilde{h}_t$, r_t 和 z_t 分别表示当前时刻输入信息、上一时刻的隐藏状态、下一时刻的隐藏状态、候选隐藏状态、重置门和更新门。

Sigmoid 函数的导数在饱和区趋近零,网络训练中容易出现梯度衰减问题,降低了模型对长序列数据的建模能力。此外, Sigmoid 和 Tanh 激活函数涉及指数运算,尤其是在处理高维传感器数据时,计算复杂度较高,影响模型的训练效率。

因此,本文针对 GRU 模型在刀具磨损预测中存在非线性特征建模能力不足和计算复杂度高等问题,将原始模型中使用的 Sigmoid 函数替换为 ReLU 函数,旨在增强模型对非线性特征的捕捉能力,缓解梯度消失问题,并优化梯度更新的动态性能。

在更新门和重置门状态计算中引入 ReLU 激活函数,利用其非饱和特性缓解梯度衰减问题,同时增强模型对磨损突变特征的捕捉能力,如式(17)~式(18)所示。上述改进方案从非线性建模、特征提取和注意力机制优化三个维度提升了模型的性能,为刀具磨损监测提供了更高效、更准确的解决方案。

$$z_t = \text{ReLU}(W_z \cdot [h_{t-1}, x_t]), \quad (17)$$

$$r_t = \text{ReLU}(W_r \cdot [h_{t-1}, x_t]), \quad (18)$$

其中: W_z 和 W_r 分别表示更新门的相关权重矩阵和重置门的相关权重矩阵。

ReLU 的引入具备三重理论优势^[28]:在梯度传播层面,正区间导数值恒为 1 的特性有效缓解了深层网络中的梯度消失问题;在非线性表达能力层面,线性区域的非饱和性突破了传统激活函数的有界限制,为金属磨损多模态特征的函数逼近提供了更大的解空间;在计算效率层面,相较于 Sigmoid 和 Tanh 等激活函数,其无需指数运算的简化结构大幅提升了模型训练速度,ReLU 的单侧抑制特性产生隐式正则化效果,在有限样本条件下降低过拟合风险,计算公式如下:

$$y = \text{ReLU}(W * x + b). \quad (19)$$

3.2.2 双向门控循环网络模型

GRU 模型通过重置门和更新门实现对序列信息的处理,利用上一时刻状态与当前输入计算门控信号,经重置门处理并激活后得到当前时刻的候选状态,再通过更新门融合历史状态与候选状态以输出最终隐藏状态,如图 6 所示。相较于 LSTM 模型减少一个门控单元,通过单一门控兼顾遗忘与记忆功能,降低了计算成本,但仅能单向处理序列,难以全面捕捉刀具磨损数据中前后关联的特征信息。

为了在保留 GRU 模型高效性的同时提升特征提取能力,本文以 BiGRU 为核心构建主干网络,针对振动信号的时序关联性与双向动态特征,有针对性地设计与优化网络结构,具体结构




图 6 GRU 网络结构示意图

Fig. 6 Schematic diagram of GRU network

如图 7 所示。考虑到振动信号在时间维度上的前后依赖关系,通过调整 BiGRU 的隐藏层维度、堆叠深度及双向信息融合机制,使其能够更精准地捕捉信号中正向与反向的时序关联特征;通过引入自适应门控权重,强化对关键故障时刻振动模态的关注,同时抑制无关噪声的干扰。该结构设计延续 GRU 降低算力消耗与运算时长的核心思想,既保留 GRU 对长时序依赖的高效建模优势,又以正向和反向双序信息融合,突破传统 GRU 仅单向关注时序、对刀具磨损这类特定领域信号适配性不足的局限。改进后,网络不仅能敏锐捕捉刀具磨损序列的动态特征,更强化了对磨损特征的精准提取能力。将 BiGRU 时序建模特性与刀具磨损信号物理规律深度耦合的设计,构建出更贴合工程场景的特征提取框架。




图 7 BiGRU 网络结构

Fig. 7 Structure of BiGRU network

BiGRU 由两个独立的 GRU 组成,一个按照正向顺序处理刀具磨损序列信息,另一个按照反向顺序处理序列。在得到正向和反向的隐藏状态序列后,BiGRU 将每个时间步的正向隐藏状态和反向隐藏状态进行拼接,得到最终的隐藏状态表示。即对于时间步 t ,最终的隐藏状态 h_t^{BiGRU} ,如下:

$$h_t^{\text{BiGRU}} = [\vec{h}_t, \overleftarrow{h}_t], \quad (20)$$

其中: $\vec{h}_t$ 代表正向(从序列起始到末尾方向)GRU

在时间步 t 时的隐藏状态, $\overleftarrow{h}_t$ 代表反向(从序列末尾到起始方向)GRU 在时间步 t 时的隐藏状态。

这种双向处理的方式使得 BiGRU 能够同时捕捉到刀具磨损数据时间序列的前后特征信息,能够提供更全面、更准确的特征信息,从而提升模型的预测精度。

3.3 注意力模块

刀具磨损状态预测面临多传感器数据融合复杂、磨损初期特征微弱以及工业场景数据稀缺等关键性难题。多传感器时序数据存在量纲差异与信息冗余,1DCNN 易受高频噪声干扰,难以自主识别关键物理量。磨损初期微米级特征仅占原始信号的 3%~5%,常规卷积层难以动态聚焦突变点。实际工业场景中,刀具全寿命数据获取成本高且磨损曲线呈现非线性突变,普通数据增强方法难以模拟真实物理的退化过程。针对上述问题,本文引入 CBAM, CBAM 由两个子模块组成分别是通道注意力模块(Channel Attention Module, CAM)^[29]和空间注意力模块(Spatial Attention Module, SAM)^[30],如图 8 所示。具体实施中,CBAM 模块在每个卷积层之后应用,从而显著提高模型的预测精度和稳定性。




图 8 CBAM 注意力模块

Fig. 8 CBAM attention module

3.3.1 通道注意力模块

由于特征图中的每个通道可以被视作一个独立的特征检测器,CAM 捕捉输入数据的主要特征。通过自适应地调整每个通道的重要性,CAM 能够增强对关键特征的关注,并抑制冗余的信息。这一过程不仅有助于提高模型的表达能力,还能增强其对输入数据的理解能力。

为了能够有效提高通道注意力模块效率,本文采用一种压缩输入特征映射空间维度的方法。通道注意力权重 $M_c(F)$ 可以表示为:

$$M_c(F) = \sigma \left(W_1 \left(W_0 \left(F_{\text{avg}}^c \right) \right) + W_1 \left(W_0 \left(F_{\text{max}}^c \right) \right) \right), \quad (21)$$

其中: F 是输入的特征图; σ 表示 Sigmoid 函数; W_0 和 W_1 是两层神经网络(MLP)的权重矩阵; F_{avg}^c 和 F_{max}^c 分别表示通道注意力模块特征图的平均池化层和最大池化层。

3.3.2 空间注意力模块

SAM 侧重于特征图中不同区域的重要性,是对 CAM 模块的补充。将由 CAM 生成的 F' ($H \times W \times C$)作为 SAM 的输入特征图,先基于通道的最大池化层和平均池化层生成两个特征为 $H \times W \times 1$ 的特征图,将这两个特征图进行通道拼接,之后经过一个 7×7 的卷积操作降维成新的 $H \times W \times 1$ 特征图,再经过 Sigmoid 生成空间注意力特征 M_s 。

空间注意力 $M_s(F)$ 的表达式如下:

$$M_s(F) = \sigma\left(f^{n \times n}\left([F_{avg}^s; F_{max}^s]\right)\right), \quad (22)$$

其中: F 是 CAM 的特征图, $f^{n \times n}$ 是大小为 n 的卷积核; F_{avg}^s 和 F_{max}^s 分别表示空间注意力模块特征图的平均池化层和最大池化层。

通过 CAM 和 SAM 的双重设计,自适应地增强关键特征并抑制冗余信息,有效提升模型对复杂磨损模式的捕捉能力。本文先对 1DCNN 主干网络提取的时序特征进行多尺度特征融合与降维处理,随后引入 CBAM 优化关键特征权重。在此过程中,主干网络特征提取层包含 6 级 1D 卷积-池化堆叠,特征层 1 由初始输入通过 3 层卷积与 3 次池化生成,输出形状为(batch, 16, 3)。特征层 2 在特征层 1 基础上追加 2 层卷积与 2 次池化,输出形状为(batch, 16, 1)。特征层 3 通过跳跃连接融合浅层高分辨率特征与深层抽象特征,保留多尺度时序信息。在特征层 1 后嵌入 CBAM 模块,通过 CAM 计算 24 个特征通道的贡献度,并沿时间维度对关键磨损阶段进行 SAM

加权,输出优化后的特征图。将 3 个特征层展平拼接后输入双层 GRU 捕获长时依赖,最终通过全连接层回归刀具磨损量。

3.4 整体方法框架

现代制造中,铣刀动态磨损预测对保障加工质量、提升生产效率至关重要。在刀具磨损预测时序建模中,传统 GRU 虽可处理时序数据,但因单向传播仅能捕捉正向时序关联,易丢失关键依赖,导致小样本、复杂工况下预测精度欠佳。因此引入 BiGRU,通过前向与后向 GRU 并行结构同步学习双向时序特征,弥补传统 GRU 单向信息捕捉缺陷。然而,BiGRU 对磨损敏感的局部特征提取能力弱,易导致磨损状态跃迁响应滞后,故进一步融入 1DCNN,凭借其局部感知野与权值共享特性高效提取局部特征,与 BiGRU 全局时序特征互补,完善特征表征。此外,BiGRU-1DCNN 模型存在特征权重失衡问题,冗余特征会增加计算开销、干扰决策。因此引入 CBAM,通过通道与空间注意力机制自适应强化关键特征、抑制冗余,兼顾预测精度与实时性。

基于 BiGRU-1DCNN-CBAM 的刀具磨损预测模型如图 9 所示,该模型的核心架构包括 1DCNN, CBAM, BiGRU 三部分。图中,左侧为多模态特征输入层,经自适应分布校准后进入核心学习模块;该模块创新性串联多域特征融合单元及时序与空间协同学习单元,前者依托特征拼接整合多源信息,后者采用 BiGRU 捕捉时序依赖关系,借助 1DCNN 提取局部关键特征,且嵌入 CBAM 注意力机制对重要特征实施动态加权,最终通过全连接层输出刀具磨损量预测结果。图 10 展示了模型的整体工作流程,具体步骤如下:

步骤 1:以 PHM2010 刀具磨损数据集为基




图 9 刀具磨损预测模型结构

Fig. 9 Structure diagram of tool wear prediction model




图 10 BiGRU-CNN-CBAM 方法的整体工作流程

Fig. 10 Overall workflow of BiGRU-CNN-CBAM method

础,整合多源传感器信号并关联刀具磨损量标签,构建输入特征与预测目标的对应关系;对各传感器通道信号依次提取时域、频域及时频域特征以形成高维特征集,针对多源传感器信号存在的分布异质性问题,采用自适应分布校准的归一化方法,削弱噪声干扰与分布差异对后续建模的影响,并结合 Pearson 相关性分析开展特征冗余性判别以优化特征质量;采用 3 折交叉验证方法对数据集进行划分,为后续模型训练与性能评估提供可靠的数据支撑。

步骤 2:输入数据通过 1DCNN 提取局部特征,逐步降维并增强关键特征,输出特征图的形状。

步骤 3:1DCNN 提取的特征图输入 CBAM,通过 CAM 和 SAM 分别计算权重,增强重要通道和关键空间位置的特征,输出形状不变但关键特征增强的特征图。

步骤 4:将 CBAM 处理后的特征图转换为序列格式,输入 BiGRU 网络;利用双向门控循环结构捕获时序数据双向依赖,深度挖掘长期磨损趋势特征,输出包含完整时序信息的隐藏状态。

步骤 5:利用最后一个时间步的隐藏状态作

为时序特征的紧凑表示,为后续任务提供高层次的特征表达。

步骤 6:将 BiGRU 最后一个时间步的输出通过全连接层映射到一维输出,最终输出刀具磨损预测值。

步骤 7:计算所有样本预测值与实际值的平均绝对误差(Mean Absolute Error, MAE),均方根误差(Root Mean Square Error, RMSE)和决定系数,分析刀具磨损状态预测的质量。

4 实验及结果分析

4.1 实验环境与平台

本文实验平台数据处理单元采用 CPU 型号为 13th Gen Intel(R) Core(TM) i7-13700H,频率为 2.4 GHz,显卡型号为 NVIDIA GeForce RTX 4060 Laptop,显存为 8 GB,系统内存为 16 GB,操作系统为 Windows 11,深度学习框架为 Python 3.8,GPU 加速工具为 CUDA 12.2。

PHM2010 数据集含 6 组铣削实验子数据集,其中仅 C_1 , C_4 和 C_6 这 3 组附带经高精度显微镜测量的刀具磨损标签,其余 3 组无标签。带标签子数据集具有显著应用价值,其特性体现在可通过差异化切削参数模拟不同工况下的刀具磨损异质性,为模型泛化性验证提供多样本支撑,还能覆盖刀具全生命周期助力开展特征敏感性与预测稳定性分析,同时高精度磨损标签可作为监督学习的基准真值,为构建多模态监测信号与磨损量的映射关系提供依据,直接服务于数据驱动模型的训练与验证。然而,这 3 组带标签子数据集的原始样本数据也存在一定局限性,主要体现在单组数据磨损历程样本点有限、切削参数组合维度较窄、受控实验环境干扰因素单一,以及与其余无标签数据协同性弱,难以通过半监督学习等方法高效利用无标签数据带来的数据资源利用率低。因此,本文重点研究如何充分发挥 PHM2010 带标签子集的多工况差异、全生命周期覆盖及高精度真值优势,利用振动与切削力特征建立混合域特征刀具磨损预测数据集,进而构建小样本下的刀具磨损预测模型。

在 3.1 节建立的包含有后刀面磨损量的 C_1 , C_4 和 C_6 3 组信号数据集的基础上,进行模型训练。具体训练过程如下:

(1)通过将多个特征数组和标签数组沿样本数量轴拼接并进行归一化处理,构建高效的训练数据集;

(2)采用学习率动态衰减策略,设置初始学习率为 0.001,并在连续 10 个迭代后模型性能未提升时将学习率减少一半,防止过拟合;

(3)构建双层训练循环,外层控制训练轮次,内层控制批次,并在每轮结束时切换至评估模式,验证模型性能并记录关键指标。

4.2 模型评价指标

为较为正确地评价算法性能的优劣,本文引入的主要评价指标包括 RMSE, MAE 和决定系数 R^2 。其中, RMSE 对于预测值中预测误差较大的值更敏感,易受极端值的影响,反映离群点; MAE 反映的是真实误差,不易受极端值的影响,综合反映整体误差; R^2 是一种去量纲的评价指标,反映预测值对实际值的拟合程度,越接近 1 证明模型效果越好。其表达式分别为:

$$RMSE = \sqrt{\frac{1}{N_T} \sum_{i=1}^{N_T} (y_T^i - \hat{y}_T^i)^2}, \quad (23)$$

$$MAE = \frac{1}{N_T} \sum_{i=1}^{N_T} |y_T^i - \hat{y}_T^i|, \quad (24)$$

$$R^2 = 1 - \frac{\sum_{i=1}^{N_T} (y_T^i - \hat{y}_T^i)^2}{\sum_{i=1}^{N_T} (y_T^i - \bar{y})^2}, \quad (25)$$

式中: y_T^i 为实际值; $\hat{y}_T^i$ 为预测值; i 为走刀次数; y 为测试集所有实际值的平均值。

4.3 消融实验

为了能够系统评估本文所提各改进策略对 BiGRU 模型整体性能的贡献,设计了针对刀具磨损预测性能的消融实验,逐步将不同改进模块包括 1DCNN 网络结构、CBAM 及其组合引入 BiGRU 模型,通过比较实验结果可观察到每个改进均对模型性能产生积极影响。为确保实验的公平性并保持一致的训练参数,并按表 1 设置各自的超参数。本文将三把刀具的数据利用 3 折交叉验证进行整合重组作为数据集,将两把刀具的数据用作训练集,使用该模型预测剩余的一把刀具的磨损值,每组实验进行三次训练与预测,取评价指标的平均值作为最终结果。

不同改进策略的模型训练指标如图 11~13 所示。由柱状图 11 可知, BiGRU, 1DCNN, BiG-

表 1 模型超参数设置

Tab. 1 Model hyperparameter settings

超参数(Hyperparameter)	值
轮次数(Epoch)	200
批次数(Batch size)	32
学习率(Learning rate)	0.001
优化函数(Optimization function)	Adam
激活函数(Activation function)	ReLU
时序长度(t)	315

RU+CBAM, 1DCNN+CBAM 和 BiGRU+1DCNN 模型在三把刀具数据集上的 RMSE 平均值分别为 13.2, 9.99, 11.95, 5.56 和 5.22 μm 。本文模型的 RMSE 值进一步优化至 2.17 μm , 表明混合模型对磨损量的预测精度更优。




图 11 RMSE 指标统计

Fig. 11 Statistics of RMSE index

由柱状图 12 可知, BiGRU, 1DCNN, BiGRU+CBAM, 1DCNN+CBAM 和 BiGRU+1DCNN 模型在三把刀具数据集上的 MAE 平均值分别为 10.22, 8.34, 8.63, 4.02 和 3.9 μm 。本文模型的 MAE 值进一步优化至 1.29 μm , 表明混合模型对磨损量的预测精度更优, 验证了混合模型在误差控制方面的优势。

由柱状图 13 可知, BiGRU, 1DCNN, BiGRU+CBAM, 1DCNN+CBAM 和 BiGRU+1DCNN 模型在三把刀具数据集上的 R^2 值分别





图 12 MAE 指标统计

Fig. 12 Statistics of MAE index

图 13 各模型在 PHM2010 上的 R^2 指标统计Fig. 13 Statistics of R^2 index of each model on PHM2010

为 0.855, 0.897, 0.881, 0.967 和 0.973。本文模型的 R^2 值进一步优化至 0.995, 说明 BiGRU+IDCNN+CBAM 的协同机制, 可最大程度挖掘多模态信号与刀具磨损的关联规律。从实验结果可见: BiGRU 或 IDCNN 模型因仅能捕时序依赖或空间特征, 预测性能存在明显局限; 引入 CBAM 注意力的模型, 特征表征能力得到针对性

增强, 但受限于单一骨干网络的表达瓶颈, 整体性能未实现突破性提升; BiGRU 与 IDCNN 的基础融合已能通过时序-空间特征互补提升预测精度; 本文所提 BiGRU-IDCNN-CBAM 模型, 通过 CBAM 对 BiGRU 提取的时序特征与 IDCNN 提取的空间特征进行动态加权, 进一步强化了多模态信息的融合效率, 最终在 R^2 , MAE 和 RMSE 3 项指标上均实现最优表现, 验证了 BiGRU+IDCNN+CBAM 融合策略的协同有效性。

4.4 对比实验结果与分析

为验证本文所提出模型的竞争性, 选取具有代表性的预测模型对相同的数据集进行刀具磨损状态预测, 按表 1 设置各自的超参数, 将其性能与本文提出的方法进行比较。对比预测模型分为物理驱动模型 (Bayesian-MCMC-Prognostics^[14]) 和深度学习驱动模型 (SBiLSTM^[17], RIME-CNN-SVM^[18], MobilenetV3^[15], TDConvLSTM^[19], ISABO-IBiLSTM^[20], IWOA-IECA-BiLSTM^[21] 和 LSTM-CNN-CBAM^[3])。

图 15~图 17 为刀具磨损值与走刀次数的关系曲线, 清晰展示出本文提出 BiGRU-IDCNN-CBAM 模型经训练后得到的预测结果。当模型在某一走刀次数下的预测值与实际值越接近时, 这两条曲线也会越贴近。在预测开始和结束的时段, 观测数据较少, 模型未能达到最佳预测效果, 导致预测值与实际值之间存在一定的偏差, 而当切削过程进行到 50 次之后, 随着数据量的积累, 模型预测值逐渐与磨损实际值贴合。这一现象在其他模型的对比图中也同样存在, 说明对于深度学习驱动模型而言, 充足的信号数据量是实现刀具磨损高精度预测的关键支撑。

各模型上述评价指标平均值统计如表 2 所示。可以看出, 本文提出模型在 PHM2010 数据集上表现优异, 其 RMSE 和 MAE 分别为 $2.17 \mu\text{m}$ 和 $1.29 \mu\text{m}$ 。与 SBiLSTM, RIME-CNN-SVM, MobilenetV3, TDConvLSTM, ISABO-IBiLSTM, IWOA-IECA-BiLSTM, LSTM-CNN-CBAM 模型相比, 本文模型的 RMSE 指标分别提高了 91.1%, 74.7%, 80.4%, 58.3%, 75.8%, 57.3% 和 40.5%, MAE 指标分别提高了 93.5%, 79.9%, 81.8%, 66.4%, 80.1%, 64.6% 和 52.1%。




图 14 各模型在 PHM2010 上的刀具磨损预测指标

Fig. 14 Index of tool wear prediction for each model on PHM2010

表 2 各模型性能评估平均指标

Tab. 2 Average performance evaluation indexes of each model

预测算法	RMSE	MAE	R ²
SBiLSTM(2022) ^[17]	24.28	19.98	0.494
RIME-CNN-SVM(2024) ^[18]	8.59	6.43	0.935
MobilenetV3(2024) ^[15]	11.09	7.08	0.854
TDConvLSTM(2024) ^[19]	5.21	3.84	0.975
ISABO-IBiLSTM(2024) ^[20]	8.96	6.57	0.932
IWOA-IECA-BiLSTM(2025) ^[21]	5.08	3.65	0.977
LSTM-CNN-CBAM(2025) ^[3]	3.65	2.69	0.988
BiGRU-IDCNN-CBAM	2.17	1.29	0.995

图 14 采用差异化色彩标识的柱状数据,分别呈现各模型在 C₁, C₄, C₆ 3 组刀具样本数据集下的 RMSE, MAE 和 R² 指标结果。其目的是对比各模型与本文模型的性能差异,通过柱状高度直观展现不同模型在指标上的数值表现,辅助分析模型精度与拟合效果,为评估模型优劣提供依据。结合图 14 及表 2 数据可知:在对一号、四号、六号刀具的预测实验中,本文模型 RMSE 值均低于 2.5 μm, MAE 值均低于 1.5 μm,且决定系数 R² 达 0.995。对比表 2 中其他模型指标,本文模型预测值更优,体现出良好的预测精度与拟合效果。这表明模型能有效捕捉刀具磨损的真实变

化趋势,在刀具磨损状态预测任务中具备更高的准确性与可靠性。

图 15~图 17 依次展示了以这 3 把刀具作为验证集时部分模型的预测结果,如图 15(a)所示,在刀具剩余寿命预测的研究对比中, Bayesian-MCMC-Prognostics 模型在初始阶段由于数据量不足而未能提供准确的预测结果,随着数据积累和模型训练的深入,该模型在预测结束时表现出过拟合与欠拟合的问题,导致提前预测刀具进入报废状态,预测能力不足。

进一步分析基于深度学习方法得到的结果,如图 15(b)和 15(d)所示,可以看到使用 SBiLSTM 和 MobilenetV3 两种不同架构进行预测时预测值相较于实际磨损值存在显著偏差。图 15(c)和图 15(f)分别代表的 RIME-CNN-SVM 和 ISABO-IBiLSTM 模型预测效果优于 SBiLSTM 和 MobilenetV3 这两个单一模型。

图 15(e)、图 15(g)、图 15(h)和本文提出的模型在以 C₁ 为测试集的实验中效果较好。图 15(e)和图 15(h)中预测值曲线与实际值曲线虽整体随走刀次数上升呈增长趋势,但在中后段 200~300 次走刀区间,预测曲线振荡幅度较大,与实际曲线存在明显分离,对实际磨损的细微波动追踪不够精准;而本文模型曲线(图 15(i))中,




图 15 第一组刀具磨损预测结果

Fig. 15 Tool wear prediction results for first group

预测值在走刀次数推进过程中,与实际值的贴合度持续提升,波动同步性较强,直观体现出对实际磨损趋势的精准捕捉能力。结合柱状图 14 中 RMSE 和 MAE 的具体数据可知,本文模型的 RMSE 和 MAE 值为 $2.48 \mu\text{m}$ 和 $1.33 \mu\text{m}$,优于 SBiLSTM, RIME-CNN-SVM, MobilenetV3, TDConvLSTM, ISABO-IBiLSTM, IWOA-IECA-BiLSTM 和 LSTM-CNN-CBAM 模型。

如图 16(a) 所示,在刀具剩余寿命预测的研究对比中, Bayesian-MCMC-Prognostics 的模型在初始阶段由于数据量不足而未能提供准确的预测结果,但在走刀次数超过 200 次后模型的预测效果好,证明该模型的预测需要依靠大量的数据支撑。

结合图 16(b)~图 16(d) 的可视化结果与图 10 柱状图数据,可进一步发现不同深度学习模型在刀具磨损预测任务中的性能差异显著。从预

测趋势上, SBiLSTM, RIME-CNN-SVM 及 MobilenetV3 这 4 类模型在预测末期均出现预测值小于实际磨损值的现象,这一特征揭示了模型存在过拟合问题,导致泛化能力受限。从柱状图 14 显示的误差指标来看,这些模型的 RMSE 均高于 $8.61 \mu\text{m}$, MAE 均超过 $6.53 \mu\text{m}$,表明预测结果与实际值的偏差较大且离散程度高,拟合精度不足。这种表现若应用于实际生产,将会直接导致刀具无法按实际磨损状态正常报废,可能引发加工精度下降、产品不合格甚至设备损坏等风险。

图 16(e)~图 16(h) 中,中前期预测曲线与实际曲线贴合度欠佳,局部波动明显偏离实际细微变化;而本文模型曲线(图 16(i))初期即紧密追随实际曲线,在刀具磨损增速变化的关键区间几乎与实际曲线重叠,能精准捕捉小幅波动,展现出更强的趋势拟合韧性。结合柱状图 14 的量化数据可得,本文模型的 RMSE 和 MAE 值为




图 16 第二组刀具磨损预测结果

Fig. 16 Tool wear prediction results for second group

1.97 μm 和 1.11 μm , 优于其他对比模型。

如图 17(a) 所示, 在刀具剩余寿命预测的研究对比中, Bayesian-MCMC-Prognostics 模型在初始阶段依旧存在较大的预测误差。

结合图 17(b)~图 17(d) 的可视化结果可进一步发现, 不同深度学习模型在刀具磨损预测任务中的性能差异显著。图 17(b) 中(彩图见期刊电子版), 预测值曲线与实际值曲线贴合度较差。走刀全程里, 橙色曲线频繁出现大幅振荡, 尤其在中后期走刀次数段, 预测趋势与真实过程严重错位。图 17(c) 和图 17(d) 中, 初期因数据稀疏, 预测值陡升急坠, 中期面对动态波动或过度振荡放大噪声, 难以精准捕捉磨损细微变化。从柱状图 14 显示的误差指标来看, 这些模型的 RMSE 均高于 8.58 μm , MAE 均超过 6.54 μm , 表明预测结果与实际值的偏差较大且离散程度高, 拟合精度不足。如图 17(e)~图 17(i) 所示, 这几种模

型在以 C_6 为测试集的实验中效果较好, 而且本文模型曲线(图 17(i))从走刀初期便紧密贴近实际值曲线。结合柱状图 14 的量化数据可以进一步验证, 本文模型的 RMSE 和 MAE 值为 2.06 μm 和 1.44 μm , 优于其他模型。

针对 C_1 刀具样本数据集给出部分示意性案例, 以体现刀具磨损的状态和对应的预测结果, 如表 3 所示。走刀次数为 50, 150 和 250 的 3 个点分别代表刀具的初期磨损、正常磨损和剧烈磨损 3 个阶段, 其中各阶段点的磨损实际值分别为 87.7, 99.9 和 134.5 μm 。

由表 3 可知, 本文方法在各阶段均取得了最小预测偏差。其中, 在刀具正常磨损阶段(走刀次数为 150 次), 各模型预测值与实际磨损量偏差较小: IWOA-IECA-BiLSTM 为 101.2 μm , LSTM-CNN-CBAM 预测值 101.9 μm , BiGRU-IDCNN-CBAM 为 100.7 μm , 均与实际值(99.9




图 17 第三组刀具磨损预测结果

Fig. 17 Third group of tool wear prediction results

表 3 各模型的各阶段磨损量

预测算法	预测磨损值(偏差)		
	走刀 50 次	走刀 150 次	走刀 250 次
SBiLSTM(2022) ^[17]	69.2(−18.5)	96.3(−3.6)	162.3(+27.8)
RIME-CNN-SVM(2024) ^[18]	85.2(−2.5)	99.5(−0.4)	137.6(+3.1)
MobilenetV3(2024) ^[15]	75.8(−11.9)	82.5(−17.4)	109.4(−25.1)
TDConvLSTM(2024) ^[19]	84.3(−3.4)	102.8(+2.9)	125.5(−9.0)
ISABO-IBiLSTM(2024) ^[20]	78.5(−9.2)	93.9(−6.0)	138.6(+4.1)
IWOA-IECA-BiLSTM(2025) ^[21]	85.6(−2.1)	101.2(+1.3)	131.6(−2.9)
LSTM-CNN-CBAM(2025) ^[3]	89.9(+2.2)	101.9(+2.0)	138.4(+3.9)
本文方法	88.7(+1.0)	100.7(+0.8)	135.6(+1.1)

μm)接近;而在初期磨损(50次)和剧烈磨损(250次)阶段,部分模型(如SBiLSTM,MobilenetV3,ISABO-IBiLSTM)的预测偏差相对略大,这也反映出不同磨损阶段下模型预测稳定性的差异,进

一步体现出本文模型在正常磨损阶段的预测精度优势。

图 18 所示柱状图统计了 8 类深度学习模型的推理耗时。经计算,其他 7 类模型的推理时间

平均为 163.44 s, 本文模型耗时 136.8 s, 展现出效率优势, 与耗时峰值的 ISABO-IBiLSTM 相比耗时降低约 35.6%, 对比同属多模块复合的 LSTM-CNN-CBAM 耗时减少 2.8%。由此可见, BiGRU-1DCNN-CBAM 模型在集成特征交互、注意力机制等模块以强化预测性能的同时, 通过架构精简实现功能和效率的平衡, 显著优于传统复杂模型的耗时表现, 更适配工程场景中刀具磨损预测的高效计算需求。




图 18 各模型的运行时间

Fig. 18 Running time of each model

通过图 15~图 17 和表 2 可知, 在相同迭代次数的情况下, 本文提出的模型相比 Bayesian-MCMC-Prognostics, MobilenetV3, SBiLSTM 等模型, 在预测的开始阶段和结束阶段均未出现对寿命的误判情况, 具有更精准的拟合能力, 能够为寿命评估提供可靠依据, 而与混合模型 RIME-CNN-SVM, TDConvLSTM, ISABO-IBiLSTM 和 IWOA-IECA-BiLSTM 相比, 通过加入注意力机制 CBAM 的动态特征聚焦, 模型能够减少早期微弱信号漏检和末期突变过拟合的问题。

综上, 针对复杂工况下预测精度不足、模型

特征提取能力有限等问题, 本文在 PHM2010 数据集基础上, 对该数据集的多模态监测信号进行特色化预处理, 并以预处理后的信号特征为依据, 开展刀具磨损状态预测研究。实验结果表明, 本文方法在预测精度、稳定性和工程适用性等方面均体现出显著的优势。因此, 本文提出的 1DCNN 与 BiGRU 融合架构, 通过“局部空间特征瞬时捕获(1DCNN)-长时序依赖深度建模(BiGRU)”的双模态协同机制, 针对性克服传统 LSTM 特征筛选冗余、CNN 时序关联捕捉薄弱的缺陷, 兼具低计算复杂度、强序列建模能力及复杂工况下的稳定预测性能。

5 结 论

本文提出一种基于 BiGRU-1DCNN-CBAM 的刀具磨损状态预测方法, 针对多传感器信号数据制作数据集, 通过引入 1DCNN 挖掘待检测信号图像数据中的深层特征, 利用 CBAM 提升模型捕捉振动信号和切削力信号特征图的能力, 采用 BiGRU 结构以降低对硬件计算能力的依赖, 减少模型的计算资源消耗及时间成本, 实现数控加工过程中的刀具磨损状态在线监测与剩余寿命预测。该架构中, BiGRU 负责时序依赖建模、1DCNN 进行局部与空间特征提取、CBAM 实现关键特征动态加权, 三者协同本质是对信号“时序动态性-局部形态特异性-关键信息显著性”的通用建模, 不依赖特定刀具的专属信号模式。该模型在本文建立的 PHM2010 铣刀磨损数据集上的 RMSE 和 MAE 分别为 $2.17 \mu\text{m}$ 和 $1.29 \mu\text{m}$, 与其他经典模型以及相关的研究相比具有较大的提升, RMSE 和 MAE 值的预测精度分别提升超过 40.5% 和 52.1%。在模型处理效率方面, 实验结果表明, 该模型展现出更优的运算速度, 相比同类模型耗时减少至少 2.8%。因此, 基于 BiGRU-1DCNN-CBAM 的刀具磨损预测方法适用于高精度数控加工场景的刀具健康管理, 具有预测可靠性强和预测精度高的优势, 为智能制造的预测性维护提供了可靠技术支撑。

本文主要围绕 PHM2010 数据集, 开展混合域特征刀具磨损预测数据集建立, 及 BiGRU-1DCNN-CBAM 刀具磨损预测模型构建工作。而 PHM2010 数据集也面临着一定的局限性, 主

要体现在带标签子数据集仅 3 组,样本量有限且切削参数组合维度较窄、受控实验环境干扰因素单一、复杂模型训练易过拟合、数据资源利用率低,且数据未包含刀具崩刃、刃口微裂纹扩展等突发异常工况,暂难以支撑模型对异常磨损的稳定性验证。随着科技发展与实际需求,未来研究将进一步拓展模型应用边界,针对车削、磨削等不同加工工艺及高速钢、陶瓷等不同刀具类型的实际场景,采集振动、声发射、切削力、温度等多维度刀具磨损监测信号;同时突破单一数据集局限,在 PHM2010 数据基础上,融合其他工业场景中机床主轴电流传感器、刀具磨损图像采集设备等多传感器产生的异构数据,构建跨工况、跨设备的多源信号融合框架。其中,对于其他刀具(如车刀)采用“切削力+振动+声发射”多模态传感且磨损特征分布于多域空间的情况,特征预处理流程(多域特征提取、相关性精简等)可直接复用;若刀具加工工艺、磨损机制存在差异(如钻头以轴向力为主,铣刀为多刃断续切削),则需在特征提取参数(小波包

分解层数、频域特征频段范围)与模型超参数(BiGRU 隐藏层维度、1DCNN 卷积核大小)方面进行适配性调优,以匹配信号时序模式与频率成分差异。通过优化提升模型对不同类型信号的特征适配能力与异构数据融合机制,增强模型延展性,使模型可自适应处理多源、异构的刀具磨损监测数据,更贴合复杂多变的实际工业生产需求。并且,结合边缘计算平台优化模型轻量化设计,增强算法在实际工业系统中的部署效率与实时响应能力。

作者贡献声明:

巢渊:论文写作,方法提出,技术路线设计;
张俊杰:论文写作,方法实现与实验对比分析;
谈齐峰:方法与模型优化支持;
张宜珺:实验数据分析与论文可视化呈现;
戴国洪:论文方法与实验指导;
夏志杰:论文方法指导;
张志胜:项目管理与实验资源提供。


参考文献:

- [1] 邹吉才,段云乾,李新,等. 刀具磨损和变摩擦系数对切削力的影响[J]. 光学精密工程, 2024, 32(14): 2211-2224.
KUAIJ C, DUAN Y Q, LI X, *et al.* Effect of tool wear and variable friction coefficient on cutting force [J]. *Opt. Precision Eng.*, 2024, 32(14): 2211-2224. (in Chinese)
- [2] 张昌娟,焦锋,赵波,等. 激光超声复合切削硬质合金的刀具磨损及其对工件表面质量的影响[J]. 光学精密工程, 2016, 24(6): 1413-1423.
ZHANG CH J, JIAO F, ZHAO B, *et al.* Tool wear in laser ultrasonically assisted cutting cemented carbide and its effect on surface quality[J]. *Opt. Precision Eng.*, 2016, 24(6): 1413-1423. (in Chinese)
- [3] 张贺,邵琪越,薄翠梅. 基于注意力机制混合网络模型的刀具磨损监测[J/OL]. 控制工程, 2024: 1-8. (2024-12-04). <https://link.cnki.net/doi/10.14107/j.cnki.kzgc.20240553>.
ZHANG H, SHAO Q Y, BO C M. Tool wear monitoring based on a hybrid network model with attention mechanism[J/OL]. *Control Engineering of China*, 2024: 1-8. (2024-12-04). <https://link.cnki.net/doi/10.14107/j.cnki.kzgc.20240553>. (in Chinese)
- [4] BHATTACHARYYA P, SENGUPTA D, MUKHOPADHYAY S. Cutting force-based real-time estimation of tool wear in face milling using a combination of signal processing techniques[J]. *Mechanical Systems and Signal Processing*, 2007, 21(6): 2665-2683.
- [5] 尹晨,周世超,何建樑,等. 基于多源同步信号与深度学习的刀具磨损在线识别方法[J]. 中国机械工程, 2021, 32(20): 2482-2491.
YIN CH, ZHOU SH CH, HE J L, *et al.* Tool wear online recognition method based on multi-source synchronous signals and deep learning[J]. *China Mechanical Engineering*, 2021, 32(20): 2482-2491. (in Chinese)
- [6] GAO K P, XU X X, JIAO S J. Measurement and prediction of wear volume of the tool in nonlinear degradation process based on multi-sensor information fusion [J]. *Engineering Failure Analysis*, 2022, 136: 106164.
- [7] 王民,车昌家,高相胜,等. 复杂工况条件下刀具磨损状态监测与剩余寿命预测研究进展[J/OL].

- 机械工 程学报, 2024: 1-28. (2024-12-13). <https://kns.cnki.net/kcms/detail/11.2187.TH.20241212.1305.051.html>.
- WANG M, CHE CH J, GAO X SH, *et al.* Tool wear condition monitoring and remaining life prediction under complex working conditions: a review[J/OL]. *Journal of Mechanical Engineering*, 2024: 1-28. (2024-12-13). <https://kns.cnki.net/kcms/detail/11.2187.TH.20241212.1305.051.html>. (in Chinese)
- [8] ZHANG X D, HAN C, LUO M, *et al.* Tool wear monitoring for complex part milling based on deep learning [J]. *Applied Sciences*, 2020, 10 (19) : 6916.
- [9] LEI Y G, LI N P, GONTARZ S, *et al.* A model-based method for remaining useful life prediction of machinery [J]. *IEEE Transactions on Reliability*, 2016, 65(3) : 1314-1326.
- [10] CHIACHÍO J, JALÓN M L, CHIACHÍO M, *et al.* A Markov chains prognostics framework for complex degradation processes[J]. *Reliability Engineering & System Safety*, 2020, 195: 106621.
- [11] 周建民, 高森, 张龙, 等. 基于 RBF 和优化 Wiener 模型的轴承剩余寿命预测[J]. 控制工程, 2022, 29(2) : 246-253.
- ZHOU J M, GAO S, ZHANG L, *et al.* Remaining life prediction of bearings based on RBF and optimized Wiener model[J]. *Control Engineering of China*, 2022, 29(2) : 246-253. (in Chinese)
- [12] 王晓博. 基于数据重构与高斯混合模型的高铁滚动轴承性能退化研究[D]. 南昌: 华东交通大学, 2022.
- WANG X B. *Research on Performance Degradation of High-Speed Rail Rolling Bearing Based on Data Reconstruction and Gaussian Mixture Model* [D]. Nanchang: East China Jiaotong University, 2022. (in Chinese)
- [13] EQUETER L, LETOT C, SERRA R, *et al.* Estimate of cutting tool lifespan through cox proportional hazards model [J]. *IFAC-PapersOnLine*, 2016, 49(28) : 238-243.
- [14] 颜丙乾, 任奋华, 蔡美峰, 等. 基于 PCA 和 MC-MC 的贝叶斯方法的海下矿山水害源识别分析[J]. 工程科学学报, 2019, 41(11) : 1412-1421.
- YAN B Q, REN F H, CAI M F, *et al.* Application of PCA and Bayesian MCMC to discriminate between water sources in seabed gold mines [J]. *Chinese Journal of Engineering*, 2019, 41 (11) : 1412-1421. (in Chinese)
- [15] 孔繁星, 何腾飞, 孙皓章. 轻量化 CNN 与时间序列融合识别刀具磨损方法[J]. 机床与液压, 2024, 52(17) : 235-239.
- KONG F X, HE T F, SUN H ZH. Tool wear detection method for lightweight convolutional neural network combined with time series fusion[J]. *Machine Tool & Hydraulics*, 2024, 52 (17) : 235-239. (in Chinese)
- [16] CHAN Y W, KANG T C, YANG C T, *et al.* Tool wear prediction using convolutional bidirectional LSTM networks[J]. *The Journal of Supercomputing*, 2022, 78(1) : 810-832.
- [17] KONG W L, LI H. Combining adaptive time-series feature window and stacked bidirectional LSTM for predicting tool remaining useful life without failure data[J]. *The International Journal of Advanced Manufacturing Technology*, 2022, 121(11) : 7509-7526.
- [18] 史振兴, 沈东明, 邱辉, 等. 基于 RIME-VMD 与 EDO 的行波波头标定算法研究[J/OL]. 自动化技术与应用, 2024: 1-7. (2024-12-30). <https://kns.cnki.net/kcms/detail/23.1474.TP.20241230.1030.109.html>.
- SHI ZH X, SHEN D M, QIU H, *et al.* Research on traveling wave head calibration algorithm based on RIME-VMD and EDO [J/OL]. *Techniques of Automation and Applications*, 2024: 1-7. (2024-12-30). <https://kns.cnki.net/kcms/detail/23.1474.TP.20241230.1030.109.html>. (in Chinese)
- [19] LIU R L, ZENG Y F, LIU X F. Tool wear monitoring based on multi-sensor data fusion and deep learning[C]. *Proceedings of International Conference on Image, Vision and Intelligent Systems 2024 (ICIVIS 2024)*. Singapore: Springer Nature Singapore, 2025: 337-346.
- [20] 曾浩, 曹华军, 董俭雄. 基于 ISABO-IBiLSTM 模型的刀具磨损预测方法[J]. 中国机械工程, 2024, 35(11) : 1995-2006.
- ZENG H, CAO H J, DONG J X. Tool wear prediction method based on ISABO-IBiLSTM model [J]. *China Mechanical Engineering*, 2024, 35 (11) : 1995-2006. (in Chinese)
- [21] 包振科, 曹华军, 秦逢泽, 等. 基于 IWOA-IECA-BiLSTM 模型的刀具磨损量监测[J/OL]. 中国机械工程, 2025: 1-12. (2025-05-29).

- <https://kns.cnki.net/kcms/detail/42.1294.th.20250528.1512.014.html>.
- BAO ZH K, CAO H J, QIN F Z, *et al.* Tool wear monitoring based on IWOA-IECA-BiLSTM model [J/OL]. *China Mechanical Engineering*, 2025: 1-12. (2025-05-29). <https://kns.cnki.net/kcms/detail/42.1294.th.20250528.1512.014.html>. (in Chinese)
- [22] ZHANG X Y, LU X, LI W D, *et al.* Prediction of the remaining useful life of cutting tool using the Hurst exponent and CNN-LSTM[J]. *The International Journal of Advanced Manufacturing Technology*, 2021, 112(7): 2277-2299.
- [23] LI X C, MA X F, XIAO F C, *et al.* Application of gated recurrent unit (GRU) neural network for smart batch production prediction [J]. *Energies*, 2020, 13(22): 6121.
- [24] WOO S, PARK J, LEE J Y, *et al.* CBAM: convolutional block attention module[C]. *Computer Vision-ECCV 2018*. Cham: Springer, 2018: 3-19.
- [25] 聂鹏, 马尧, 郭勇翼, 等. 基于 IPSO 优化 LS-SVM 的铣削刀具磨损状态监测方法研究[J]. *振动与冲击*, 2022, 41(22): 137-143.
- NIE P, MA Y, GUO Y Y, *et al.* Monitoring method of milling tool wear status based on IPSO optimized LS-SVM[J]. *Journal of Vibration and Shock*, 2022, 41(22): 137-143. (in Chinese)
- [26] LI Y X, HUANG X Z, TANG J W, *et al.* A steps-ahead tool wear prediction method based on support vector regression and particle filtering[J]. *Measurement*, 2023, 218: 113237.
- [27] 黄智坤, 刘丽冰, 张晶, 等. 视听信息融合的 CNC 铣刀磨损状态监测方法[J]. *现代制造工程*, 2022(8): 93-100.
- HUANG ZH K, LIU L B, ZHANG J, *et al.* A CNC tool wear monitoring method based on audio-visual information fusion[J]. *Modern Manufacturing Engineering*, 2022(8): 93-100. (in Chinese)
- [28] 刘晶晶, 刘业峰. 一种新型激活函数的机床能耗预测神经网络研究[J]. *控制工程*, 2025, 32(3): 492-499.
- LIU J J, LIU Y F. Research on neural network with a new activation function for energy consumption prediction of machine tools[J]. *Control Engineering of China*, 2025, 32(3): 492-499. (in Chinese)
- [29] ZHOU J Q, YUE C X, LIU X L, *et al.* Classification of tool wear state based on dual attention mechanism network[J]. *Robotics and Computer-Integrated Manufacturing*, 2023, 83: 102575.
- [30] HE J L, XU Y D, PAN Y, *et al.* Adaptive weighted generative adversarial network with attention mechanism: a transfer data augmentation method for tool wear prediction[J]. *Mechanical Systems and Signal Processing*, 2024, 212: 111288.

作者简介:



巢 渊(1988—),男,江苏常州人,博士,副教授,硕士研究生导师,2011年于东南大学获学士学位,2017年于东南大学获博士学位,主要从事机器视觉测量与检测、机电一体化装备智能控制技术等研究。E-mail: chaoyuan@jsut.edu.cn

通讯作者:



张志胜(1974—),男,江苏泰兴人,博士,教授,博士研究生导师,1995年于东南大学获学士学位,2004年于东南大学获博士学位,主要从事多工步制造过程质量控制、机器视觉理论与应用、机电系统工程与一体化技术等研究。E-mail: oldbc@seu.edu.cn