

控制与决策

Control and Decision

基于深度卷积神经网络的刀具寿命动态预测研究

郭宏, 任必聪, 闫献国, 田青, 任党阳

引用本文:

郭宏,任必聪,闫献国,田青,任党阳. 基于深度卷积神经网络的刀具寿命动态预测研究[J]. *控制与决策*, 2022, 37(8): 2119–2126.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.1530>

您可能感兴趣的其他文章

Articles you may be interested in

[基于偏差的图注意力神经网络推荐算法](#)

A bias-based graph attention neural network recommender algorithm

控制与决策. 2022, 37(7): 1705–1712 <https://doi.org/10.13195/j.kzyjc.2020.1626>

[一种并行LSTM-FCN模型在船舶航迹预测中的应用](#)

Parallel LSTM-FCN model applied to vessel trajectory prediction

控制与决策. 2022, 37(8): 1955–1961 <https://doi.org/10.13195/j.kzyjc.2020.1795>

[基于深度时序特征迁移的轴承剩余寿命预测方法](#)

Remaining useful life prediction of bearing based on deep temporal feature transfer

控制与决策. 2021, 36(7): 1699–1706 <https://doi.org/10.13195/j.kzyjc.2019.1809>

[考虑退化轨迹差异性与相似性的轴承RUL预测](#)

Prediction of bearing remaining useful life involving difference and similarity of degradation trajectories

控制与决策. 2021, 36(11): 2832–2840 <https://doi.org/10.13195/j.kzyjc.2020.1028>

[一种基于深度学习的时间序列预测方法](#)

A time series prediction method based on deep learning

控制与决策. 2021, 36(3): 645–652 <https://doi.org/10.13195/j.kzyjc.2019.0809>

基于深度卷积神经网络的刀具寿命动态预测研究

郭宏[†], 任必聪, 闫献国, 田青, 任党阳

(太原科技大学 机械工程学院, 太原 030024)

摘要: 刀具寿命预测对提高工件加工精度和生产加工效率具有重要意义. 同工况下同型号刀具监测信号数据分布不一致, 导致历史寿命预测模型对刀具寿命预测效果有限. 鉴于此, 提出一种基于深度卷积神经网络(DCNN)的刀具寿命动态预测方法. 首先, 利用DCNN挖掘历史刀具监测信号的退化趋势特征, 构建刀具寿命预测模型, 并加入注意力机制对DCNN输出进行加权, 加强对刀具寿命特征的学习, 提高寿命预测准确度; 然后, 通过基于KL散度对刀具监测信号数据分布不一致进行检测, 从而在已有刀具寿命预测模型的基础上进行更新迭代; 最后, 利用迭代后的模型再次进行刀具寿命预测. 所提出方法很好地体现了刀具实际加工过程对刀具寿命的影响, 以铣削数据集为例验证了所提出方法的有效性.

关键词: 刀具寿命预测; 特征提取; 深度学习; 卷积神经网络; 动态预测; 注意力机制

中图分类号: TP391.7

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.1530

开放科学(资源服务)标识码(OSID):



引用格式: 郭宏, 任必聪, 闫献国, 等. 基于深度卷积神经网络的刀具寿命动态预测研究[J]. 控制与决策, 2022, 37(8): 2119-2126.

Research on dynamic prediction of tool life based on deep convolutional neural network

GUO Hong[†], REN Bi-cong, YAN Xian-guo, TIAN Qing, REN Dang-yang

(School of Mechanical Engineering, Taiyuan University of Science and Technology, Taiyuan 030024, China)

Abstract: Tool life prediction is of great significance for improving the machining accuracy of workpieces and the processing efficiency of production. The data distribution of tool monitoring signals under the same working conditions and models is inconsistent, resulting in the limited effect of historical life prediction models on tool life prediction. This paper proposes a dynamic tool life prediction method based on the deep convolutional neural network (DCNN). Firstly, the DCNN is used to mine the degradation trend characteristics of historical tool monitoring signals, a tool life prediction model is built, and an attention mechanism is added to weight the DCNN output to strengthen the tool life characteristics learn to improve the accuracy of life prediction. Then, by detecting the inconsistency of the tool monitoring signal data distribution based on the KL divergence, iteration is performed on the basis of the existing tool life prediction model. Finally, the iterated model is used to perform tool life prediction again. The method better reflects the influence of the actual machining process of the tool on the tool life. Taking the milling data set as an example, the effectiveness of the method is verified.

Keywords: tool life prediction; feature extraction; deep learning; convolutional neural network; dynamic prediction; attention mechanism

0 引言

在刀具切削加工过程中, 由于刀具在生产加工中直接与工件接触, 刀具的加工状态严重影响着工件的加工精度和加工效率, 监测刀具的加工状态和预测刀具寿命不仅可以对加工过程中进行合理的换刀提供有力依据, 也可以提高加工效率, 保证加工精度. 随着

智能制造技术的快速发展, 机械设备故障诊断和寿命预测再次受到学术界和工业界的广泛关注^[1].

近年来, 刀具寿命和磨损监测均由传统的停机检测转换为在线实时监测刀具状态. 许多研究人员通过传感器获得刀具加工监测信号(如振动、切削力、声发射、切削热、主轴功率等^[2]), 将其中一个或多个信

收稿日期: 2020-11-05; 录用日期: 2021-06-03.

基金项目: 国家自然科学基金项目(51675363, 51275333); 山西省回国留学人员科研教研项目(HGKY2019079).

责任编辑: 胡清华.

[†]通讯作者. E-mail: hongguo1@tyust.edu.cn.

号采用人工神经网络^[3-4]、隐马尔可夫^[5-6]、贝叶斯模型^[7]、支持向量机^[8]等机器学习算法构建机械设备故障诊断和寿命预测模型。例如, Zhou等^[9]使用HHT方法从切削信号中提取刀具磨损特征,同时考虑了影响刀具磨损的因素,建立变工况条件下刀具磨损特征表示方法,建立了基于LSTM的模型,获得可变工作条件下刀具磨损过程的复杂时空关系。Aghazadeh等^[10]将卷积神经网络应用于刀具磨损的预测,分别对力、振动和电流信号进行小波变换,建立了时频域信号与刀具磨损量之间的映射关系。Kothuru等^[11]提供了一种可以使用声音信号检测齿轮铣刀在切削硬度变化的工件材料时磨损状况的方法。Huang等^[12]通过提取切削力和振动信号的时域、频域以及时频域特征,使用3层卷积神经网络建立起切削信号与3个刀面磨损量之间的关系。

上述方法均是根据先验知识或专家经验对刀具监测信号进行特征提取,在特征提取质量方面也都存在差异,严重影响了刀具剩余使用寿命(RUL)预测的准确性。而且刀具监测信号特征提取算法并不适合处理多维刀具监测信号。为了解决上述问题,自适应特征提取广泛应用于机械设备故障诊断和寿命预测等相关领域。深度学习^[13-14]可以对原始信号进行自适应特征提取,避免出现人工提取特征可能带来的特征质量差等问题。曹大理等^[15]通过卷积神经网络,自适应地对力、振动和声发射时域信号进行特征提取,建立了刀具磨损在线监测模型。An等^[16]使用CNN与LSTM的混合模型,其中CNN提取监测信号局部特征,LSTM获得局部特征之间的时间序列上的长期依赖关系,并对铣刀加工信号进行预测。这些都是假设数据独立同分布的情况下进行的研究,没有考虑到刀具寿命受诸多因素影响,刀具磨损过程通常被认为是模型常数不确定的随机过程^[17-18]。

近年来,迁移学习受到广泛关注和研究。迁移学习是运用已有知识对不同但相关领域问题进行求解的一种新的机器学习方法^[19]。在机械故障诊断领域,迁移学习已经被广泛应用。蔡伟立等^[20]对历史工艺条件下的刀具寿命预测模型通过动态对抗域适应的迁移学习方法,构建了新工艺条件下的刀具寿命预测模型。雷亚国等^[21]提出机械装备故障的深度迁移诊断方法,利用实验室环境中积累的故障诊断知识,解决了因数据稀缺而建立的智能诊断模型对装备健康状态识别精度低的问题。常规的数据挖掘及机器学习算法大多假设数据独立同分布,迁移学习则应用于数据分布不同的情况下对已有模型所含知识的迁移。

鉴于此,本文针对切削加工过程中存在诸多因素及复杂性,在同工况下同型号刀具监测信号数据分布不一致时刀具寿命预测效果不理想的情况,提出一种基于深度卷积神经网络(DCNN)的刀具寿命动态预测方法。该方法采用深度卷积神经网络及注意力机制(attention)构建刀具寿命预测模型对刀具寿命进行监测,并基于KL散度对刀具监测信号数据分布不一致进行检测,判断历史寿命预测模型是否适应当前刀具加工过程。借鉴迁移学习的思想,在历史寿命预测模型的基础上进行模型的更新迭代,完成已有模型所含知识的迁移,从而获得更可靠的刀具寿命预测模型。与传统的寿命预测方法相比,所提出方法可以从高维监测信号中自适应提取刀具寿命特征,不依赖于先验知识和专家经验,且不需要特征提取工程。在已有的刀具寿命预测模型基础上对模型进行更新,可以快速构建新的刀具寿命预测模型,并且能够适应刀具磨损过程中的不确定性。

1 问题描述

设同型号刀具进行重复实验,得到相同工况下的刀具监测信号。刀具整个生命周期监测信号为

$$S_i = \{x_n \mid n = 1, 2, \dots, N\}. \quad (1)$$

其中: $x_n^{i \times l}$ 为第 n 个样本, l 为样本 $x_n^{i \times l}$ 的时间步长。

样本 x_n 的RUL为

$$y_n = \Delta \times (N - n), \quad (2)$$

其中 Δ 为每个样本代表刀具的使用时间,刀具进行了 N 次切削。

存在多维监测信号 S_1 ,其样本 x_n^1 属于样本空间 χ^1 ,数据服从概率分布 $P(\chi^1)$;多维监测信号 S_2 ,其样本 x_n^2 属于样本空间 χ^2 ,数据服从概率分布 $P(\chi^2)$ 。受测量环境多样、操作条件差异等复杂因素的影响,相同工况下采集的数据分布存在一定差异,从统计分析角度可认为 $P(\chi^1) \neq P(\chi^2)$ 。

本文利用监测信号 S_1 建立刀具寿命预测模型。当 S_2 在基于 S_1 所建立的刀具寿命预测模型进行预测时, S_1 建立的预测模型便会失效。因此,有必要对同一切削参数下同型号刀具监测信号存在数据分布不一致的情况进行研究,以提高刀具寿命预测模型的准确度。

2 刀具寿命动态预测

2.1 刀具寿命预测模型

CNN可以仿造人类视觉感知机制构造,深层次地提取多维刀具监测信号内微小寿命特征,其包含卷积层、池化层以及全连接层。本文结合深度学习与刀

具寿命特征自身规律, 构建深层刀具寿命预测模型. 模型以刀具整个生命周期监测信号 S_i 的样本 x_n 为输入, 以同一时刻点所对应的RUL值 y_n 为输出, 采用深层卷积神经网络对多维刀具监测信号自适应特征提取, 通过全连接层增加输出的非线性, 并利用回归层生成刀具寿命. 刀具寿命预测模型如图1所示.

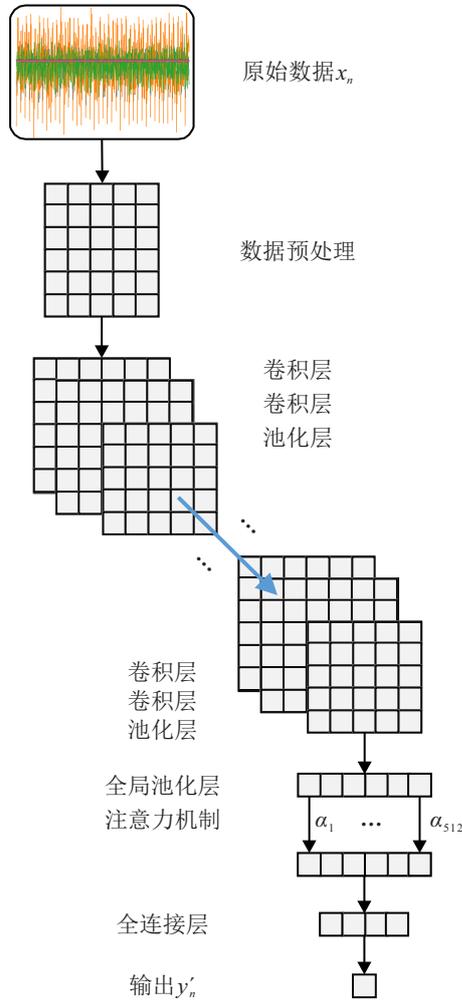


图1 刀具寿命预测模型

刀具寿命预测模型获取步骤如下.

step 1: 对原始刀具监测信号 x_n 进行数据预处理.

原始刀具监测信号(包括切削力信号 F_x 、 F_y 、 F_z , 振动加速度信号 a_x 、 a_y 、 a_z , 声发射信号 s) 经过平稳加工过程监测信号选取后获得 210 000 个采样点, 并将其组合成为 (210 000, 7) 的矩阵, 将 7 种时域信号各自进行数据归一化, 计算公式如下:

$$x_{\text{scaled}} = \frac{x - x_{\min}(\text{axis} = m)}{x_{\max}(\text{axis} = m) - x_{\min}(\text{axis} = m)}. \quad (3)$$

其中: $\text{axis} = m$ 为第 m 维时域信号, $m = 1, 2, \dots, 7$; x_{\max} 和 x_{\min} 分别为第 m 维时域信号中的采样点、最大值和最小值.

数据归一化后使不同来源的数据统一至同一纲量, 加快梯度下降求最优解的速度, 防止模型梯度爆

炸, 提高模型精度.

step 2: DCNN 自适应提取刀具寿命特征.

将数据预处理后的信号矩阵通过深度卷积神经网络自适应提取刀具寿命特征, 特征提取过程包括 4 部分, 每一部分包含 2 层卷积层和最大池化层. 信号矩阵经过卷积层、激活进行特征提取以及非线性映射, 池化层扩大下一部分卷积层特征提取的视野, 同时保留主要特征并减少数据计算量, 减小过拟合. 最后 (210 000, 7) 的矩阵经过特征提取成为长度 512 的特征向量.

采用一维卷积运算对多维矩阵进行滤波得到相应的特征图, 卷积运算可用下式表示:

$$h_{ij}^k = f((W^k x)_{ij} + b_k). \quad (4)$$

其中: x 为卷积层的输入矩阵, h_{ij}^k 为第 i 行、第 j 列卷积层输出向量, f 为激活函数, W^k 为第 k 个卷积核的权重矩阵, b_k 为该卷积核的偏置向量.

step 3: 经过全连接层输出刀具寿命预测值 y'_n .

注意力机制是一个相似性的度量, 当前的输入与目标状态越相似, 当前输入的权重越大, 表明当前的输出越依赖于当前的输入. 本文采用的注意力机制通过在全局池化后增加全连接层进行构造. 假设有 m 个 d 维特征向量 $h_i (i = 1, 2, \dots, m)$, 整合 k 个特征向量的信息得到向量 h^* , 合理的方法是加权平均, 即

$$h^* = \sum_{i=1}^k a_i h_i, \quad (5)$$

其中 a_i 为权重. 注意力机制就是获得一个合理的 a_i .

2.2 刀具寿命动态预测方法

2.2.1 刀具寿命动态预测模型构建

在前文所得到的刀具寿命预测模型的基础上构建刀具寿命动态预测模型, 如图2所示, 包含 3 个步骤.

step 1: 利用带剩余寿命标签的历史刀具加工监控信号 S_i , 训练历史刀具寿命预测模型 M_i , 使用刀具寿命预测模型 M_i 进行刀具寿命预测.

step 2: 当前刀具完成加工后, 计算当前加工刀具监测信号 S_j 与历史刀具加工监控信号 S_i 的数据分布相似度 δ . 若 $\delta \leq$ 阈值 τ , 则刀具监测信号 S_i 与 S_j 的数据分布相似, 继续在刀具寿命预测模型 M_i 上进行刀具寿命预测.

step 3: 若 $\delta >$ 阈值 τ , 则刀具监测信号 S_i 与 S_j 的数据分布不相似, 在刀具寿命预测模型 M_i 的基础上更新刀具寿命预测模型, 使用刀具寿命预测模型 M_j 再次进行刀具寿命预测.

两组监测信号数据分布之间的差异可以通过 KL 散度衡量, 两个分布差异越大, KL 散度越大. KL

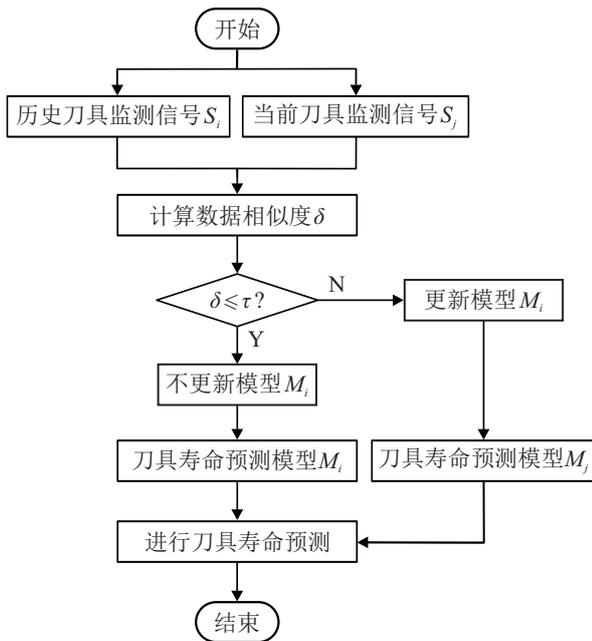


图2 刀具寿命动态预测模型构建

散度是恒大于等于零的,等于零时说明两个分布一样。

对于历史监测信号 $S_i = \{S_i^1, S_i^2, \dots, S_i^N\}$, S_i 包含 N 把刀具监测信号, S_i 的阈值为

$$\tau_i = \frac{D_{KL}(S_i^1 \parallel \bar{S}_i) + D_{KL}(S_i^2 \parallel \bar{S}_i) + \dots + D_{KL}(S_i^N \parallel \bar{S}_i)}{N}, \quad (6)$$

其中 $D_{KL}(S_i^1 \parallel \bar{S}_i)$ 为

$$D_{KL}(S_i^1 \parallel \bar{S}_i) = \frac{1}{2} \left\{ \log \frac{|\bar{\Sigma}_i|}{|\Sigma_i^1|} - n + \text{tr}(\bar{\Sigma}_i^{-1} \Sigma_i^1) + (\bar{U}_i - U_i^1)^T \bar{\Sigma}_i^{-1} (\bar{U}_i - U_i^1) \right\}. \quad (7)$$

式(7)中,第1把刀具监测信号 S_i^1 各个维度的均值 U_i^1 和方差 σ_i^1 分别为

$$U_i^1 = [\mu_{i1}^1, \mu_{i2}^1, \dots, \mu_{i7}^1]^T, \\ \sigma_i^1 = [\sigma_{i1}^1, \sigma_{i2}^1, \dots, \sigma_{i7}^1]^T.$$

$\bar{\Sigma}_i$ 、 Σ_i^1 分别为 \bar{S}_i 、 S_i^1 变量 X 的协方差矩阵。

当前监测信号 S_j^1 与历史刀具监测信号 S_i 的数据分布相似度为

$$\delta = D_{KL}(S_j^1 \parallel \bar{S}_i). \quad (8)$$

式(7)和(8)中 \bar{S}_i 各个维度的均值 \bar{U}_i 和方差 $\bar{\sigma}_i$ 分别为

$$\bar{U}_i = [\bar{\mu}_{i1}, \bar{\mu}_{i2}, \dots, \bar{\mu}_{i7}]^T = \frac{U_i^1 + U_i^2 + \dots + U_i^N}{N}, \\ \bar{\sigma}_i = [\bar{\sigma}_{i1}, \bar{\sigma}_{i2}, \dots, \bar{\sigma}_{i7}]^T = \frac{\sigma_i^1 + \sigma_i^2 + \dots + \sigma_i^N}{N}.$$

2.2.2 模型更新

所提出的刀具寿命动态预测模型是在历史刀具寿命预测模型 M_i 的基础上进行更新,刀具监测信号

S_i 和 S_j 是在同工况下产生的数据,尽管数据分布存在差异,但其主要刀具磨损特征依旧不变,因此保留历史刀具寿命预测模型 M_i 的自适应特征提取 CNN 层的权重参数.为了防止模型在更新过程中训练速度慢,损失函数达不到最优,采用初始化非线性映射全连接层参数更新刀具寿命预测模型。

当产生的监测信号 S_j 与历史监测信号数据分布不相似时,对监测信号 S_j 进行保存,同时计算监测信号 S_j 的阈值 τ_j . 随着加工过程逐步进行,历史监测信号中会存在多组不同数据分布的刀具监测信号 S_1, S_2, \dots, S_m 和各自的阈值 $\tau_1, \tau_2, \dots, \tau_m$. 若新产生的刀具监测信号 S_k 与历史监测信号的相似度大于阈值 $\tau_1, \tau_2, \dots, \tau_m$, 则表明 S_k 与历史监测信号不相似,对 S_1, S_2, \dots, S_m 所建立的刀具寿命预测模型进行更新,并将 S_k 增加到历史监测信号中。

3 实验案例

3.1 实验条件

为了验证所提出方法的有效性并评估其性能,采用 PHM 2010 大赛中铣削数据集,切削参数如表 1 所示。

表1 PHM 2010实验切削参数

主轴转速 (RPM)	进给速度 (mm/min)	径向切深 (mm)	轴向切深 (mm)	铣削方式
10400	1555	0.125	0.2	顺铣

表 1 中:实验机床为 RFM 760 数控机床,实验刀具为三刃碳化钨球头铣刀,切削材料为不锈钢(HRC-52). 通过测力仪、加速度传感器、声发射传感器采集铣刀在加工过程中的切削力、振动和声发射原始时域信号. 信号采样频率为 50 kHz,每次走刀沿 X 方向切削 108 mm,共实验 5 把刀具,每把刀具走刀 315 次,采集每次切削监测信号。

实验平台采用 Tensorflow 2.1 搭建神经网络模型,Python 编程语言,Ubuntu 操作系统,Inter Xeon 处理器,30 G 内存,NVIDIA GTX 1080 Ti 图形处理器。

3.2 实验结果

将 5 组监测信号进行数据处理,并获得每个样本 x_n 所对应的刀具剩余寿命标签 y_n . 通过比较 5 组数据的数据分布,将数据分为两组, C_1 、 C_3 以及 C_4 服从概率分布 $P(\chi^1)$, C_2 和 C_5 服从概率分布 $P(\chi^2)$, 且 $P(\chi^1) \neq P(\chi^2)$. 在此基础上进行对比实验。

3.2.1 刀具寿命预测模型对比

本文使用的深度卷积神经网络刀具寿命预测模型(DCNN+Attention)与基于 CNN+LSTM、CNN 以及 DCNN 的刀具寿命预测模型进行比较。

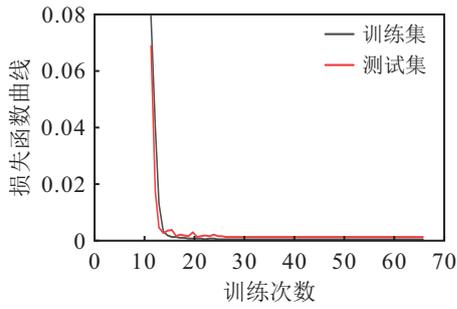


图3 DCNN+Attention模型的训练损失函数曲线

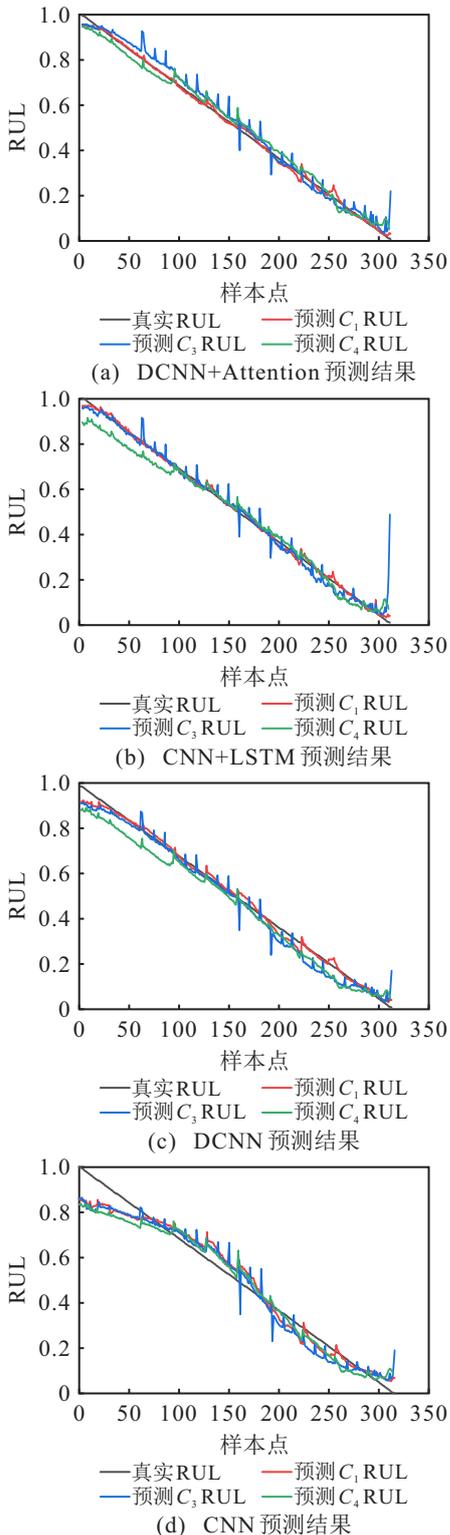


图4 各种预测模型对 C_1 、 C_3 、 C_4 预测结果

在刀具寿命预测模型对比实验中,使用服从概率分布 $P(\chi^1)$ 的 C_1 、 C_3 以及 C_4 监测信号进行验证,使用 C_1 作为训练集,预测 C_3 、 C_4 作为验证集。

将训练集输入各寿命预测模型进行训练,训练过程中所采用的深度卷积神经网络(DCNN+Attention)模型在训练集和验证集的损失函数变化曲线如图3所示。

由图3可见,随着训练时间的逐渐增加,刀具寿命预测模型的损失函数越来越小,最终收敛。表明所提出方法可以很好地挖掘监测信号中的刀具寿命特征,准确地对刀具寿命进行预测。所提出的深度学习模型在验证集上有良好的泛化能力。

刀具寿命预测模型对比实验中各种刀具寿命预测模型对 C_1 、 C_3 、 C_4 预测结果如图4所示。采用均方误差(MSE)、平均绝对误差(MAE)和决定系数(R^2)作为模型的判别标准。刀具监测信号 C_1 、 C_3 、 C_4 在各种刀具寿命预测模型的RUL预测性能对比结果分别如表2~表4所示,最高性能指标以粗体显示。由表2~表4可见,所提出方法(DCNN+Attention)与其他代表性方法相比,对刀具寿命预测更为精准。本文采用的深度学习方法相比CNN模型的刀具寿命预测精度有大幅度提升,传统浅层CNN模型的预测误差保持在较高水平,且变化很大。原因在于深度神经网络能够对刀具监测信号自适应特征提取,深度挖掘刀具寿命特征,所以所提出模型具有更好的特征提取能力和更高的预测准确性。

表2 C_1 、 C_3 、 C_4 在各预测模型MSE实验结果

刀具寿命预测模型	MSE / 10^{-4}		
	C_1	C_3	C_4
DCNN+Attention	1.726	7.832	8.459
CNN+LSTM	1.763	16.58	20.04
DCNN	4.187	17.63	27.92
CNN	32.57	39.82	41.71

表3 C_1 、 C_3 、 C_4 在各预测模型MAE实验结果

刀具寿命预测模型	MAE		
	C_1	C_3	C_4
DCNN+Attention	0.0094	0.0284	0.0278
CNN+LSTM	0.0101	0.0201	0.0345
DCNN	0.0154	0.0317	0.0435
CNN	0.0456	0.0504	0.0490

表4 C_1 、 C_3 、 C_4 在各预测模型 R^2 实验结果

刀具寿命预测模型	R^2		
	C_1	C_3	C_4
DCNN+Attention	0.9978	0.9843	0.9886
CNN+LSTM	0.9967	0.9813	0.9774
DCNN	0.9951	0.9794	0.9695
CNN	0.9623	0.9531	0.9525

所提出模型相比DCNN和CNN+LSTM模型,刀具寿命预测精度提升幅度较小,但DCNN和CNN+LSTM模型在验证集上的泛化能力相对较弱.原因主要在于所提出方法引入注意力机制强化了对刀具寿命重要特征的提取,使刀具寿命预测的精度得到进一步提升.

3.2.2 刀具寿命动态预测结果

首先,使用所提出的刀具寿命预测模型与线性回归方法中偏最小二乘法(PLS)以及支持向量回归(SVR)进行比较,各种预测方法在各刀具上的预测结果如图5~图7所示.各预测方法的刀具寿命预测MSE结果如表5所示.

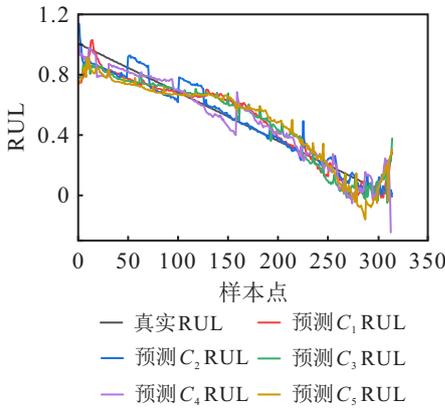


图5 偏最小二乘法预测各刀具寿命

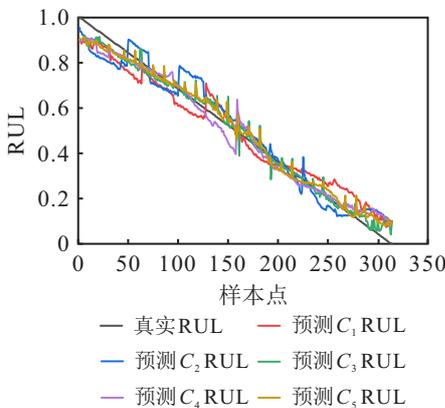


图6 支持向量回归预测各刀具寿命

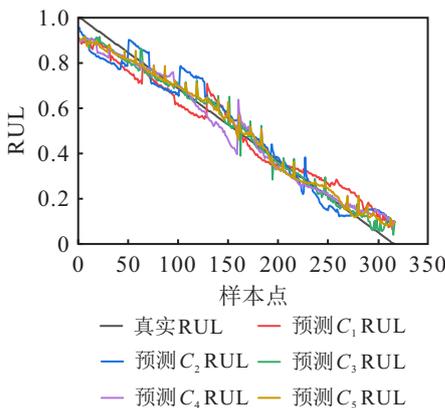


图7 DCNN+Attention预测各刀具寿命

表5 各寿命预测模型MSE实验结果

刀具	MSE / 10 ⁻⁴		
	DCNN+Attention	PLS	SVR
C ₁	1.726	63.13	39.96
C ₂	263.0	33.24	41.69
C ₃	7.832	79.15	14.25
C ₄	8.459	48.52	22.41
C ₅	97.53	114.9	15.71

通过小波包分解提取刀具监测信号中的刀具寿命特征,将提取出来的刀具寿命特征分别用于偏最小二乘法(PLS)及支持向量回归(SVR)建立刀具寿命预测模型.

由图5~图7和表5可见,使用深度学习的刀具寿命预测模型其预测精度明显优于PLS和SVR.主要原因是这两种方法的预测精度过度依赖特征提取工程所提取特征的质量,并且采用特征提取方法会造成刀具寿命特征的丢失,预测模型精度不高.

刀具寿命动态预测实验使用服从概率分布P(χ¹)的C₁、C₃以及C₄和服从概率分布P(χ²)的C₂、C₅刀具监测信号进行验证.利用刀具C₁监测信号建立寿命预测模型M₁,使用M₁对所有刀具监测信号进行预测.预测结果如图7所示.

由图7和表5可见,与C₁数据分布相似的C₃、C₄预测结果均匀分布在真实RUL曲线附近,而与C₁数据分布存在差异的C₂和C₅预测结果则与真实RUL曲线有较大偏差,表明C₂和C₅在C₁所建立预测模型上存在模型失效问题,有必要对刀具寿命预测模型进行更新,以适应新的数据分布.

在刀具寿命预测模型更新实验中阈值τ₁和相似度确定过程如下.

刀具监测信号的数据分布分别如表6~表10所示.将C₁、C₃以及C₄作为历史监测信号,根据式(6),阈值τ₁为

$$\tau_1 = \frac{D_{KL}(S_1^1 || \bar{S}_1) + D_{KL}(S_1^2 || \bar{S}_1) + D_{KL}(S_1^3 || \bar{S}_1)}{3} \quad (9)$$

其中:S₁¹、S₁²、S₁³分别为C₁、C₃、C₄的数据分布,̄S₁为C₁、C₃、C₄的平均数据分布.将数据代入式(9)得到阈值τ₁ = 0.090 1.

表6 C₁数据分布

	F _x	F _y	F _z	a _x	a _y	a _z	s
μ	16.08	5.72	6.70	1.72e-4	-3.18e-3	-3.74e-3	0.121
σ	30.78	11.5	18.9	0.131	0.125	0.144	0.037

表7 C₂数据分布

	F _x	F _y	F _z	a _x	a _y	a _z	s
μ	11.79	3.26	8.03	7.10e-4	-2.52e-3	-3.02e-3	0.110
σ	23.13	8.66	16.0	0.194	0.272	0.267	0.040

表8 C_3 数据分布

	F_x	F_y	F_z	a_x	a_y	a_z	s
μ	11.74	6.37	7.0	2.05e-4	-3.16e-3	-3.81e-3	0.131
σ	25.89	11.3	19.7	0.124	0.117	0.135	0.038

表9 C_4 数据分布

	F_x	F_y	F_z	a_x	a_y	a_z	s
μ	11.37	6.04	6.92	-0.2e-4	-3.48e-3	-3.93e-3	0.114
σ	26.18	1.06	19.4	0.132	0.119	0.144	0.040

表10 C_5 数据分布

	F_x	F_y	F_z	a_x	a_y	a_z	s
μ	11.38	6.39	6.81	1.35e-4	-3.32e-3	-3.72e-3	0.112
σ	25.45	9.09	18.3	0.212	0.301	0.295	0.034

通过式(8)计算 C_2 、 C_5 与 \bar{S}_1 的相似度分别为0.8371, 0.6159, 将其与阈值 τ_1 进行比较可知: C_2 、 C_5 与历史监测信号 C_1 、 C_3 和 C_4 数据分布存在差异,将寿命预测模型 M_1 进行更新迭代。

通过对刀具监测信号的数据分布进行检测,以 C_1 和 C_2 刀具监测信号为训练集进行模型更新迭代得到 M_2 ,并对所有刀具寿命进行预测,预测结果如图8所示。

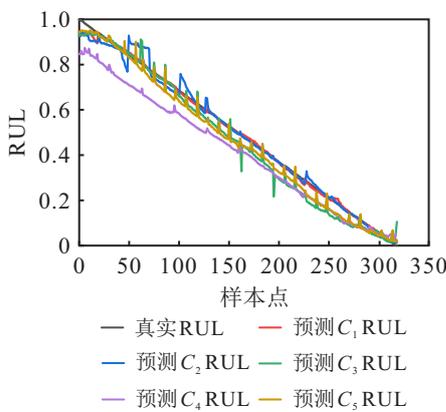


图8 刀具动态寿命预测模型更新后预测各刀具寿命

由图7和图8可见,在进行刀具寿命预测模型更新后,刀具 C_2 和 C_5 的预测结果都均匀分布在真实RUL曲线附近,表明更新后的刀具寿命预测模型 M_2 对刀具 C_1 和 C_2 两种不同数据分布的监测信号有很好的适应能力,同时验证了所提出刀具寿命动态预测方法的有效性。

4 结论

本文针对传统的刀具寿命预测模型不能适应刀具磨损过程中的不确定性,提出了一种基于DCNN的刀具寿命动态预测方法. 通过利用深度卷积神经网络和注意力机制可以自适应地挖掘刀具监测信号与刀具寿命之间的关系,避免传统特征提取方法不适

用于高维数据和提取特征质量差等问题;基于KL散度对刀具监测信号数据分布不一致进行检测,在已有的刀具寿命预测模型上进行更新迭代,使刀具动态寿命预测模型可以较好地适应刀具加工过程中的不确定性. 但是,所提出模型依然存在某些刀具监测信号样本点的预测结果不理想的情况,在以后的研究中将针对监测模型的准确性进行优化研究。

参考文献(References)

- [1] 陈佳鲜, 毛文涛, 刘京, 等. 基于深度时序特征迁移的轴承剩余寿命预测方法[J]. 控制与决策, 2021, 36(7): 1699-1706.
(Chen J X, Mao W T, Liu J, et al. Remaining useful life prediction of bearing based on deep temporal feature transfer[J]. Control and Decision, 2021, 36(7): 1699-1706.)
- [2] Zhang C J, Yao X F, Zhang J M, et al. Tool condition monitoring and remaining useful life prognostic based on a wireless sensor in dry milling operations[J]. Sensors, 2016, 16(6): 795.
- [3] Drouillet C, Karandikar J, Nath C, et al. Tool life predictions in milling using spindle power with the neural network technique[J]. Journal of Manufacturing Processes, 2016, 22: 161-168.
- [4] Zhao R, Yan R Q, Wang J J, et al. Learning to monitor machine health with convolutional Bi-directional LSTM networks[J]. Sensors, 2017, 17(2): 273.
- [5] Li W J, Liu T S. Time varying and condition adaptive hidden Markov model for tool wear state estimation and remaining useful life prediction in micro-milling[J]. Mechanical Systems and Signal Processing, 2019, 131: 689-702.
- [6] 孙志娟. 基于扩展隐马尔可夫模型的刀具磨损识别与寿命预测研究[D]. 武汉: 华中科技大学, 2019.
(Sun Z J. Research on wear recognition and life prediction of tool based on extend hidden Markov models[D]. Wuhan: Huazhong University of Science and Technology, 2019.)
- [7] Sun H B, Pan J L, Zhang J D, et al. Non-linear wiener process-based cutting tool remaining useful life prediction considering measurement variability[J]. The International Journal of Advanced Manufacturing Technology, 2020, 107(11/12): 4493-4502.
- [8] Benkedjough T, Medjaher K, Zerhouni N, et al. Health assessment and life prediction of cutting tools based on support vector regression[J]. Journal of Intelligent Manufacturing, 2015, 26(2): 213-223.
- [9] Zhou J T, Zhao X, Gao J. Tool remaining useful life prediction method based on LSTM

- under variable working conditions[J]. The International Journal of Advanced Manufacturing Technology, 2019, 104(9/10/11/12): 4715-4726.
- [10] Aghazadeh F, Tahan A, Thomas M. Tool condition monitoring using spectral subtraction and convolutional neural networks in milling process[J]. The International Journal of Advanced Manufacturing Technology, 2018, 98(9/10/11/12): 3217-3227.
- [11] Kothuru A, Nooka S P, Liu R. Application of audible sound signals for tool wear monitoring using machine learning techniques in end milling[J]. The International Journal of Advanced Manufacturing Technology, 2018, 95(9/10/11/12): 3797-3808.
- [12] Huang Z W, Zhu J M, Lei J T, et al. Tool wear predicting based on multi-domain feature fusion by deep convolutional neural network in milling operations[J]. Journal of Intelligent Manufacturing, 2020, 31(4): 953-966.
- [13] 任浩, 屈剑锋, 柴毅, 等. 深度学习在故障诊断领域中的研究现状与挑战[J]. 控制与决策, 2017, 32(8): 1345-1358.
(Ren H, Qu J F, Chai Y, et al. Deep learning for fault diagnosis: The state of the art and challenge[J]. Control and Decision, 2017, 32(8): 1345-1358.)
- [14] 王强. 基于深度学习的数控加工刀具寿命动态评估方法[D]. 南京: 南京航空航天大学, 2019.
(Wang Q. A dynamic method for tool life evaluation in nc machining based on deep learning[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2019.)
- [15] 曹大理, 孙惠斌, 张纪铎, 等. 基于卷积神经网络的刀具磨损在线监测[J]. 计算机集成制造系统, 2020, 26(1): 74-80.
(Cao D L, Sun H B, Zhang J D, et al. In-process tool condition monitoring based on convolution neural network[J]. Computer Integrated Manufacturing System, 2020, 26(1): 74-80.)
- [16] An Q L, Tao Z R, Xu X W, et al. A data-driven model for milling tool remaining useful life prediction with convolutional and stacked LSTM network[J]. Measurement, 2020, 154: 107461.
- [17] Wang J J, Wang P, Gao R X. Enhanced particle filter for tool wear prediction[J]. Journal of Manufacturing Systems, 2015, 36: 35-45.
- [18] Karandikar J M, Abbas A E, Schmitz T L. Tool life prediction using random walk Bayesian updating[J]. Machining Science and Technology, 2013, 17(3): 410-442.
- [19] 中国人工智能学会. 中国机器学习白皮书[EB/OL] (2016-01-09)[2020-11-05]. <http://www.caai.cn/index.php?s=/Home/File/download/id/24.html>.
- [20] 蔡伟立, 胡小锋, 刘梦湘. 基于迁移学习的刀具剩余寿命预测方法研究[J]. 计算机集成制造系统, 2021, 27(6): 1541-1549.
(Cai W L, Hu X F, Liu M X. Research on prediction method of tool remaining useful life based on transfer learning[J]. Computer Integrated Manufacturing System, 2021, 27(6): 1541-1549.)
- [21] 雷亚国, 杨彬, 杜兆钧, 等. 大数据下机械装备故障的深度迁移诊断方法[J]. 机械工程学报, 2019, 55(7): 1-8.
(Lei Y G, Yang B, Du Z J, et al. Deep transfer diagnosis method for machinery in big data era[J]. Journal of Mechanical Engineering, 2019, 55(7): 1-8.)

作者简介

郭宏(1975—), 女, 教授, 博士, 从事智能制造、工业互联网及信息系统等研究, E-mail: hongguo1@tyust.edu.cn;

任必聪(1995—), 男, 硕士生, 从事数据清洗、数据挖掘与离群检测的研究, E-mail: S20180260@stu.tyust.edu.cn;

闫献国(1963—), 男, 教授, 博士生导师, 从事先进制造技术、信息系统等研究, E-mail: yanxianguo@tyust.edu.cn;

田青(1991—), 男, 硕士生, 从事知识工程、案例推理的研究, E-mail: S20180172@stu.tyust.edu.cn;

任党阳(1996—), 男, 硕士生, 从事机器视觉、刀具磨损监测的研究, E-mail: S20180287@stu.tyust.edu.cn.

(责任编辑: 魏冰)