

引文格式:辛军博,黄华,任亚鹏,等.基于动态域适应网络的刀具磨损预测模型在线更新方法[J].航空制造技术,2026,69(8):25010201.

XIN Junbo, HUANG Hua, REN Yapeng, et al. Online updating method for tool wear predicting model based on dynamic domain adaptation network[J]. Aeronautical Manufacturing Technology, 2026, 69(8): 25010201.

# 基于动态域适应网络的刀具磨损预测模型 在线更新方法

辛军博,黄华,任亚鹏,王柯人,连国党

(兰州理工大学机电工程学院,兰州 730000)

[摘要] 传统刀具磨损预测方法多基于经验模型或静态优化策略,在多变量耦合、工况动态演变的复杂加工环境中适应性差,极易引发数据分布偏移,进而导致模型预测失准、泛化能力衰减。为此,本文提出一种基于动态域适应网络的刀具磨损预测模型在线更新方法。通过引入动态分布自适应机制,实时量化边缘分布与条件分布对域偏移的贡献占比,动态调整特征对齐权重,实现模型的持续精准校准。以铣削刀具磨损监测为应用场景,从特征选择与分布适配两个层面增强模型的跨工况适应性。首先,构建基于SE-CNN-BiLSTM的特征提取器,强化多通道关键工况特征的筛选能力;其次,融合动态分布自适应算法(Dynamic domain adptation, DDA),提出SCBDA-Net(SE-CNN-BiLSTM-DDA-Net)自适应框架,完成变工况下模型的跨域迁移与更新。试验结果表明,所提方法可显著提升模型的跨工况泛化性能与预测精度。

关键词:刀具磨损;迁移学习;动态域适应;变工况;注意力机制

中图分类号:V261.2; TH164; TG506

文献标志码:A

DOI: 10.16080/j.issn1671-833x.25010201



辛军博

博士研究生,研究方向为刀具状态智能监测技术。

在航空航天、汽车制造等高端装备领域,零件结构日益复杂,对材料性能和加工精度提出了更高要求<sup>[1]</sup>。刀具作为数控加工中的关键部件,其磨损状态直接影响加工精度、表面质量和工艺稳定性<sup>[2]</sup>。据统计,刀具磨损导致的停机时间占数控铣削系统总停机时间的20%,严重影响了生产效率<sup>[3-4]</sup>。在切削过程中,刀具磨损不可避免,不仅会导致工件尺寸超差、表面质量恶化,还可能引发刀具断裂、机床故障等严重后果<sup>[5]</sup>。尤其在航空航天领域,钛合金等难加工材料应用广泛,且常涉及薄壁件加工,即使刀具轻微磨损也可能引起工件

颤振或表面损伤。因此,开发高精度、高稳定性的刀具磨损预测方法,实现对刀具状态的准确预测,对于保障加工质量、提升生产效率具有重要价值。

刀具磨损预测技术主要分为直接法与间接法。直接法可通过直接观测刀具磨损区域并进行评估状态,但需停机检测,不利于连续生产<sup>[6]</sup>。间接法则是通过分析切削过程中振动、声发射、切削力等传感信号特征评估刀具状态,具备在线监测潜力<sup>[7]</sup>。近年来,随着深度学习技术发展,基于数据驱动的间接监测方法凭借强大的特征自动提取与非线性建

收稿日期:2025-12-25; 退修日期:2026-01-06; 录用日期:2026-01-21

基金项目:国家自然科学基金(52365057); 甘肃省科技重大专项(23ZDGE002); 2026年甘肃省高校研究生“创新之星”项目(2026CXZX-498)

通信作者:黄华,教授,博士生导师,研究方向为先进制造与智能运维、数控装备与技术。

模能力,在刀具磨损预测中取得显著进展<sup>[8]</sup>。例如,Zhang等<sup>[9]</sup>构建了融合并行残差、多头注意力机制与双向LSTM的预测模型,实现了磨损量的高精度预测。Liu等<sup>[10]</sup>设计了PRes-SBiLSTM模型,通过平滑校正提升了输出稳定性。包振科等<sup>[11]</sup>引入改进鲸鱼优化算法与通道注意力机制,强化了模型的特征表征能力。此外,聂鹏等<sup>[12]</sup>采用了改进粒子群算法优化最小二乘支持向量机,结合经验模态分解与主成分分析实现了高效监测;Xie等<sup>[13]</sup>通过粒子群算法实现参数自适应优化,减少了人工调参的盲目性;Che等<sup>[14]</sup>提出融合邻域成分分析、黏菌算法与门控循环单元的三段式混合模型,实现了模型的多超参数同步优化。然而,这些方法大多基于静态数据训练,难以适应实际加工中因工况变化导致的数据分布变化,致使模型在未知条件下的泛化能力与可靠性下降。因此,如何使预测模型具备跨工况的自适应能力,已成为当前研究需要迫切解决的关键问题。

为提升模型在变工况下的适应能力,当前研究主要围绕迁移学习方法展开,可归纳为以下3类:第1类为模型迁移与微调,即利用目标域有限数据对预训练模型参数进行调整。例如,Zhang等<sup>[15]</sup>提出基于深度迁移学习的变工况刀具磨损监测方法,通过微调少量多通道信息显著提升了模型的预测精度。Wang等<sup>[16]</sup>通过在目标数据上微调预训练模型参数,实现了变工况下磨损状态的准确识别。孙安东等<sup>[17]</sup>则提出一种基于域泛化与元学习的小样本刀具磨损预测方法,有效解决了变工况下的磨损预测问题。第2类为基于样本的迁移,通过调整源域样本权重以增强其与目标域特征分布的相似性。例如,强碧瑶等<sup>[18]</sup>采用Two-stage TrAdaBoost.R2从源域迁移有效知识以提升预测模型泛化能力,并结合递归高斯过

程回归进一步优化性能,实现了变工况下的准确磨损预测。第3类为基于域适应的迁移,通过构建新特征空间或筛选特征以减少不同领域间的特征差异。例如,Wang等<sup>[19]</sup>将领域自适应理论引入刀具磨损监测,有效抑制了因工件刚度变化引起的随机振动干扰。Marei等<sup>[20]</sup>提出了融合最大均值差异(Maximum mean discrepancy, MMD)的混合CNN-LSTM模型,显著降低了小样本条件下的磨损预测误差。进一步的,Li等<sup>[21]</sup>通过MMD方法拉近历史刀具与当前刀具在关键传感器特征空间中的分布差异,实现了高精度磨损预测。此外,张春霖等<sup>[22]</sup>将深度迁移学习策略融入数字孪生模型,增强了变工况下监测系统的适应性与预测精度。Gao等<sup>[23]</sup>借助MMD与余弦度量学习强化特征对齐与集成效果,为复杂工况下的刀具磨损监控提供了可行的多源迁移学习方案。Li等<sup>[24]</sup>则提出了基于动态域适应网络的迁移学习方法,进一步提升了模型的泛化能力。总体而言,前两类方法在特定场景下虽能提升泛化性能,但通常未能区分并动态评估边缘分布与条件分布对域偏移的不同影响,第3类方法通过域适应技术缩小了域间差异,增强了模型泛化能力。然而,这些方法大多采用固定的权重来平衡两类分布的对齐。在实际复杂多变的工况中,两种分布的影响程度是动态变化的,固定的对齐策略难以实现精准适配,从而制约了模型在多变环境中的稳定表现。

基于此,本文提出一种基于动态域适应网络的刀具磨损预测模型自适应进化方法,重点解决工况变化下模型性能衰退、自适应重构及跨域数据分布差异精准度量等关键问题。通过引入动态分布自适应(Dynamic distribution adaptation, DDA)算法<sup>[25]</sup>,实时量化边缘分布与条件分布对域偏移的贡献率,动态调节自

适应权重系数,完成模型的迁移更新与参数优化。在此基础上,构建SCBDA动态自适应分布网络,并在NASA铣削系统中设计6种典型变工况场景开展仿真验证,结果表明所提方法可显著提升模型的跨域迁移性能与泛化能力。

## 1 变工况下刀具磨损预测模型动态更新框架

在复杂多变的加工场景中,刀具磨损预测模型的自适应更新对于实现高精度状态感知与预测性维护具有重要意义。传统磨损预测模型虽能反映特定工况下的磨损规律,但难以捕捉由工况变化引起的非线性扰动与分布偏移,导致其在新工况下的预测精度下降。为提升模型的适应性与泛化能力,本文提出了一种面向变工况的刀具磨损预测模型动态更新框架,如图1所示。该框架主要由刀具磨损预测模型和模型迁移更新机制两部分组成。

刀具磨损预测模型由物理空间和数据空间构成。物理空间包含刀具系统、工件、加工参数以及多模态传感器网络,负责实时采集切削力、振动、声发射等多维度时序信号。数据空间则包括信号预处理、特征提取与磨损预测模型等模块。模型迁移更新部分引入动态分布自适应网络,利用深度迁移学习对跨工况时序特征进行动态对齐与权重调整,实现模型的持续校准与在线更新。该机制能够确保模型始终跟踪刀具状态的实际演变,提升模型在变工况下的预测精度与稳定性,为动态加工场景中的刀具健康管理提供可靠决策支持。

## 2 基本理论

### 2.1 动态分布自适应

在迁移学习中,基于特征的迁移是对数据进行自适应变换,拉近目标域与源域数据分布的距离,实现域间的特征对齐。常见的方

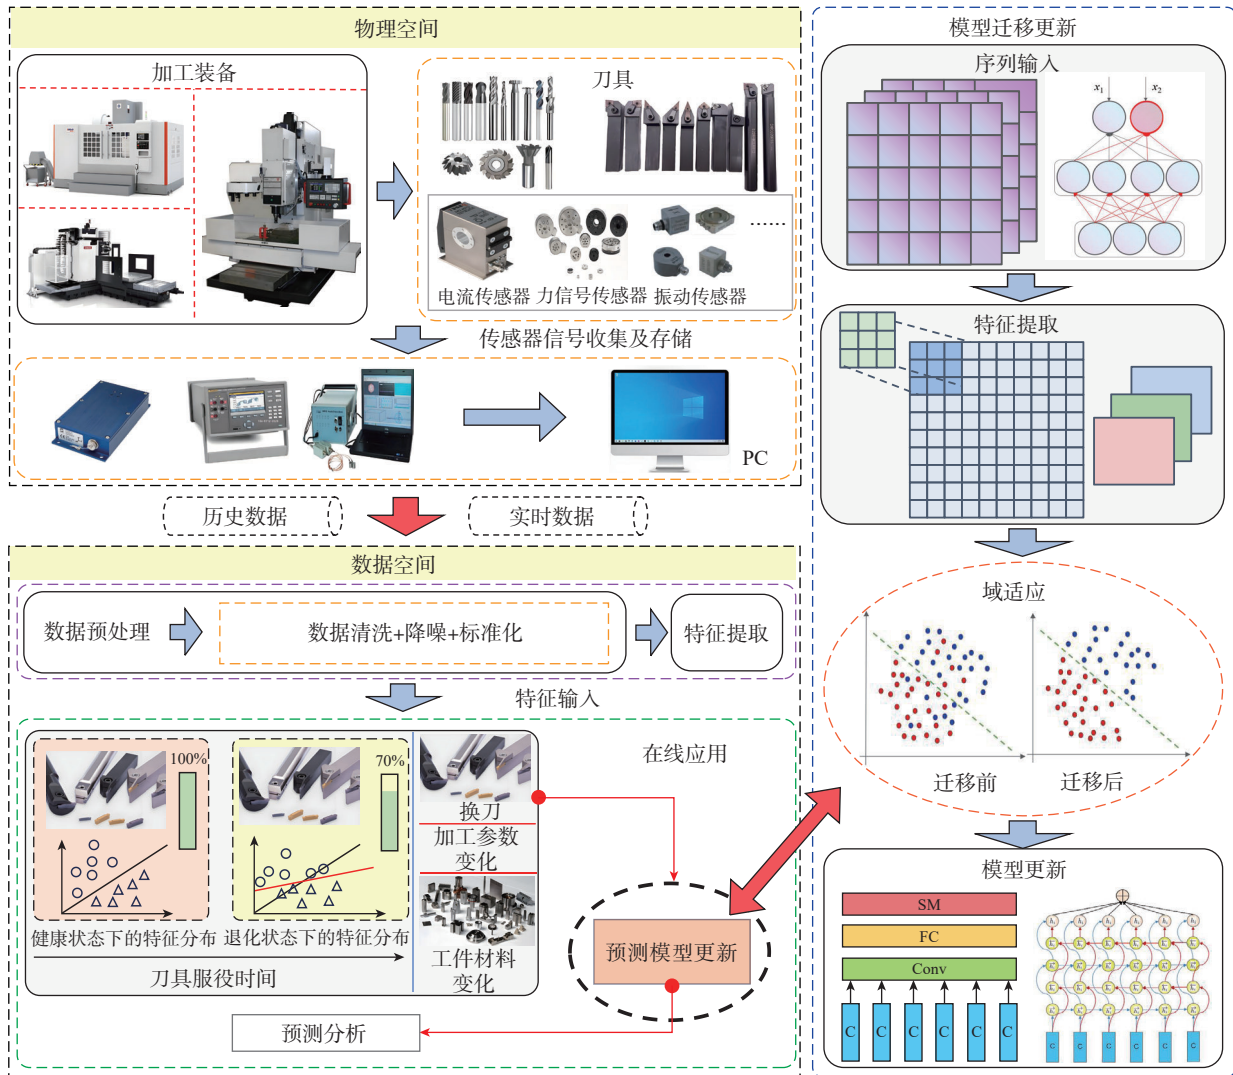


图1 变工况下刀具磨损预测模型动态更新框架

Fig.1 Dynamic update framework of tool wear predicting model under variable working conditions

法包括边缘分布自适应 (Marginal distribution adaptation, MDA)、条件分布自适应 (Conditional distribution adaptation, CDA) 及联合分布自适应 (Joint distribution adaptation, JDA)。在3种方法中, JDA综合考虑了边缘分布及条件分布的依赖关系, 能对源域和目标域数据之间的关系进行全面建模, 因此在处理复杂数据分布差异方面, 相较于MDA和CDA表现出更优的性能<sup>[26]</sup>。然而, 上述传统的迁移方法主要聚焦于缩小源域与目标域之间条件分布或边缘分布的距离, 却未能对这两种分布于不同域之间所起的作用进行定量评估, 也

未明确它们对迁移任务的具体贡献程度。在实际应用中, 这种缺失导致模型的迁移性能往往难以达到理想状态, 限制了迁移学习在对数据分布差异敏感场景下的应用效果。

DDA是在JDA的基础上对分布权重进行了改进, 其核心是对迁移学习中边缘分布和条件分布的权重进行动态、定量的自适应调整。通过这种方式, 能够有效提升模型对不同域数据差异的适应性, 从而提高模型的迁移性能和应用效果。具体原理如下:

为衡量两域间数据分布的差异, 通常采用最大均值差异MMD来计算域间的分布散度。其中, 边缘分布

距离和条件分布距离的计算分别为式(1)、(2),  $D_s$ 为源域,  $D_t$ 为目标域。

$$D_f(P_s, P_t) = \|E[f(x_s)] - E[f(x_t)]\|_H^2 \quad (1)$$

$$D_f^{(a)}(Q_s, Q_t) = \|E[f(x_s^{(a)})] - E[f(x_t^{(a)})]\|_H^2 \quad (2)$$

式中,  $D_f(P_s, P_t)$ 为边缘分布距离;  $D_f^{(a)}(Q_s, Q_t)$ 为 $a$ 类指标的条件分布距离,  $a \in \{1, \dots, A\}$ ;  $x_s \in D_s, x_t \in D_t$ 。式(3)为域间的JDA域散度计算公式。

$$\overline{D_f}(D_s, D_t) = D_f(P_s, P_t) + \sum_{a=1}^A D_f^{(a)}(Q_s, Q_t) \quad (3)$$

在式(3)中, JDA 赋予边缘分布距离和条件分布距离相同的权重。但当两域数据整体相似度较低时, 边缘分布的影响更为显著, 则  $D_f(P_s, P_t)$  在式(3)中应被赋予更大的权重; 而当两域数据整体结构相似但各类别存在差异时, 条件分布的影响更为突出, 则  $D_f^{(a)}(Q_s, Q_t)$  在式(3)中应被赋予更大的权重。

在实际加工环境中, 数控机床运行场景及工况的变化会导致特征分布差异。通过对不同工况下特征分布模式的对比分析, 可以直观评估工况变化对域间差异的影响。下面以铣削加工系统为例, 说明不同工况下数据分布的差异性。如图2所示, 基于 t-分布随机邻域嵌入(t-distributed stochastic neighbor embedding, t-SNE)算法的高维特征可视化将不同工况下源域与目标域的特征分布映射到二维空间进行呈现, 其中坐标轴为算法降维生成的抽象维度, 无具体物理单位<sup>[27]</sup>。若源域与目标域特征数据点形成明显分离的聚类簇结构, 表明两域特征分布存在显著差异。反之, 若两域重叠或混合均匀, 则说明分布相似性较高<sup>[28]</sup>。其中, 图2(a)为初始工况下源域与目标域的特征分布, 图2(b)和(c)分别为被加工材料不变(工况1)和改变时源域与目标域(工况2)的特征分布。

由图2(a)可知, 初始工况下源域与目标域提取的特征在空间分布

上重叠程度较高, 整体分布较为接近, 表明两域间特征差异较小。这说明初始工艺条件下, 数据特征的边缘分布和条件分布相对稳定, 模型能够较好地适配源域与目标域数据。由图2(b)可知, 当工况变化但被加工材料保持不变时, 源域与目标域的特征分布差异依然较小, 特征样本在空间分布上部分重叠, 表明工况小幅变化时, 数据特征演变较为平缓, 模型具备较强的适应能力。然而, 由图2(c)可知, 当工况变化涉及被加工材料改变时, 源域与目标域的特征分布差异显著增大, 特征样本在空间分布上呈现明显分离趋势。说明工件材料的变化对数据特征的边缘分布和条件分布影响较大, 导致特征分布发生显著偏移, 因此需为两类分布赋予差异化权重。

为体现边缘分布与条件分布在域散度中的贡献程度, 提出了一种基于动态分布自适应的迁移学习方法, 通过引入自适应因子  $\omega$  来动态地调整两种分布的权重。动态分布的域散度  $\bar{D}_f$  定义为

$$\bar{D}_f(D_s, D_t) = (1-\omega)D_f(P_s, P_t) + \omega \sum_{a=1}^A D_f^{(a)}(Q_s, Q_t) \quad (4)$$

式中,  $\omega \in [0, 1]$  为自适应因子。当  $\omega \rightarrow 0$  时, 表示源域与目标域之间存在较大差异性, 此时边缘分布更为重要; 当  $\omega=0.5$  时, 表示两种分布具有

同等的重要性; 当  $\omega \rightarrow 1$  时, 表示源域与目标域之间有较高相似性, 此时条件分布更为重要。

自适应因子  $\omega$  的取值通常与源域和目标域间的数据分布差异及分类器的判别性能密切相关。传统联合分布自适应算法通常假设条件分布与边缘分布对领域差异的贡献度相同, 但这一假设在实际应用中往往难以成立。平衡分布自适应(Balance distribution adaptation, BDA)虽尝试对边缘分布和条件分布进行定量估计, 但仍未解决自适应因子  $\omega$  的精确计算问题<sup>[29]</sup>。针对该问题, DDA 方法通过引入 A-distance 度量准则, 实现了  $\omega$  值的精确量化。A-distance 是衡量源域与目标域分布差异的有效方法, 其核心思想是通过训练线性分类器  $h$  对源域和目标域样本进行分类判别, 从而评估两域间的分布差异程度<sup>[30]</sup>。A-distance 的定义为式(5)。

$$d(D_s, D_t) = 2(1 - 2\varepsilon(h)) \quad (5)$$

式中,  $\varepsilon(h)$  为分类器的判别损失, 即分类器在区分源域和目标域样本时的错误率。

利用式(5)可以直接计算边缘分布的 A-distance, 用  $d_M$  来表示。A-distance 值越大, 表明源域和目标域间的分布差异越大。对于类别的条件分布的 A-distance, 可由式(6)计算得出。

$$d_a = d(Q_s^{(a)}, Q_t^{(a)}) \quad (6)$$




图2 工况变化前后源域与目标域的特征分布

Fig.2 Distribution of features in the source and target domains before and after working condition changes

式中,  $\Omega_s^{(a)}$  和  $\Omega_t^{(a)}$  分别为来自源域和目标域的第  $a$  类指标的样本。

域散度是由边缘分布和条件分布共同决定的, 用  $d_M + \sum_{a=1}^A d_a$  表示, 其中  $\sum_{a=1}^A d_a$  为所有类的条件分布距离。则  $\omega$  可以由式(7)估计获得。

$$\omega = 1 - \frac{d_M}{d_M + \sum_{a=1}^A d_a} \quad (7)$$

通过这种方式, DDA 方法能够动态地调整  $\omega$  的值, 实现自适应因子  $\omega$  的精确量化, 从而更精准地反映边缘分布和条件分布在领域差异中的权重分配。

## 2.2 基于 SE-CNN-BiLSTM 的特征提取

传统的 CNN-BiLSTM 模型虽结合了卷积神经网络(CNN)的空间特征提取能力与双向长短期记忆网络(BiLSTM)的时序依赖建模能力, 但未充分挖掘特征通道间的关联信息, 导致对多通道传感信号中关键特征的捕捉能力有限。为解决这一问题, 本文引入 SE(Squeeze-and-excitation

block) 注意力机制<sup>[31]</sup>, 通过自适应校准通道特征响应、强化关键特征表达, 与 CNN-BiLSTM 形成协同互补, 构建出兼具通道自适应、局部特征提取与时序规律建模能力的混合特征提取器, 精准适配刀具磨损预测中多维度时序传感数据的处理需求。

### 2.2.1 SE 注意力机制

SE 注意力机制的核心是通过“挤压-激励”过程, 量化各特征通道对刀具磨损预测任务的重要性, 动态分配通道权重, 从而增强有用特征、抑制冗余干扰。其本质是建立通道间的非线性依赖关系, 让模型聚焦与刀具磨损强相关的传感信号特征。SE 模块的结构如图 3 所示。

(1) 挤压。对每个通道的所有特征值取均值, 将每个通道的  $H \times W$  个数据浓缩为 1 个全局统计量  $s_c$ , 相当于提炼每个通道的核心信息。

$$s_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_c(i, j) \quad (8)$$

式中,  $X_c(i, j)$  为第  $c$  个通道在位置  $(i, j)$  处的特征值;  $H$ 、 $W$  分别为特征

图的高度和宽度。

(2) 激励。通过两层简易神经网络, 根据全局信息为每个通道分配 0~1 之间的权重  $a_c$ , 权重越大表示该通道对磨损预测的重要性越高。

$$a_c = \sigma_2(W_2 \cdot \sigma_1(W_1 \cdot s + b_1) + b_2) \quad (9)$$

式中,  $\sigma_1$  为 ReLU 激活函数;  $\sigma_2$  为 Sigmoid 激活函数(将权重限制在 0~1 之间);  $W_1$ 、 $W_2$  为网络权重;  $s$  为经 SE 注意力机制挤压操作后得到的全局统计量;  $b_1$ 、 $b_2$  为偏置参数。

(3) 加权。将学到的权重  $a_c$  与原通道特征相乘, 强化有用特征、抑制无用特征:

$$Y_c = a_c \cdot X_c \quad (10)$$

式中,  $Y_c$  为校准后第  $c$  个通道的特征图。

### 2.2.2 SE-CNN-BiLSTM 混合模型

本文将 SE 模块嵌入 CNN-BiLSTM 网络, 构建新型 SE-CNN-BiLSTM 特征提取器。该提取器可动态学习各特征通道的重要性, 并为不同通道分配对应权重, 从而根据任务需求自适应增强或抑制特定通道的特征表达。不仅能提取更具判别性的特征, 还可显著提升模型在复杂工况下的稳定性与泛化能力。SE-CNN-BiLSTM 网络的具体结构如图 4 所示, 计算过程如下。

(1) CNN 局部特征提取。设输入为多通道时序传感数据  $U \in \mathbb{R}^{N \times L \times C}$  ( $N$  为样本数;  $L$  为时序长度;  $C$  为通道数), 经 CNN 卷积与池化操作后,




图 3 SE 注意力机制结构图

Fig.3 Structure of squeeze-and-excitation block

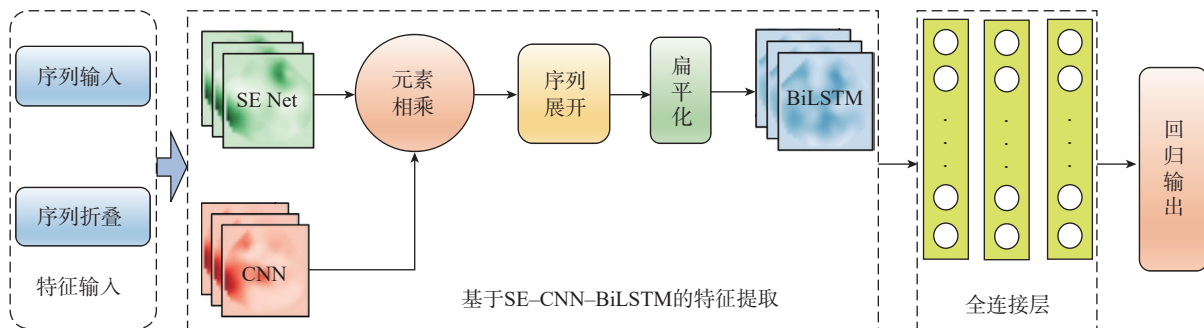


图 4 SE-CNN-BiLSTM 模型结构图

Fig.4 Structure of the SE-CNN-BiLSTM model

输出局部特征图( $C_{out}$ 为卷积输出通道数),即

$$\mathbf{F} = \text{Pool}(\sigma_{\text{ReLU}}(\mathbf{U} * \mathbf{K} + \mathbf{b}_{\text{conv}})) \quad (11)$$

式中,“\*”为卷积操作; $\mathbf{K}$ 为卷积核权重; $\mathbf{b}_{\text{conv}}$ 为卷积偏置; $\text{Pool}(\cdot)$ 为最大池化操作; $\sigma_{\text{ReLU}}$ 为SE注意力机制激励环节的复合映射操作,实现通道权重的计算生成。

(2)SE通道权重校准。将CNN输出的局部特征图 $\mathbf{F}$ 输入SE模块,按式(8)~(10)完成通道权重学习与特征校准,得到校准后特征 $\mathbf{F}_{\text{SE}} \in \mathbb{R}^{N \times H \times W \times C_{\text{out}}}$ ,即

$$\mathbf{F}_{\text{SE}}(n, :, :, c) = a_c(n) \cdot \mathbf{F}(n, :, :, c) \quad (12)$$

式中, $n \in [1, N]$ 为样本索引; $a_c(n)$ 为第 $n$ 个样本第 $c$ 个通道的自适应权重,由SE模块动态学习得到。

(3)BiLSTM时序建模。将校准后的特征 $\mathbf{F}_{\text{SE}}$ 展平为时序特征序列 $\mathbf{F}_{\text{seq}} \in \mathbb{R}^{N \times L' \times C_{\text{out}}}$ ( $L' = H \times W$ 为时序长度),输入BiLSTM学习时序依赖关系,输出全局特征 $\mathbf{H} \in \mathbb{R}^{N \times 2H_{\text{hid}}}$ ( $H_{\text{hid}}$ 为LSTM隐藏层维度),即

$$\mathbf{H}(n) = \text{BiLSTM}(\mathbf{F}_{\text{seq}}(n, :, :)) \quad (13)$$

该全局特征既保留了CNN提取的局部判别性特征,又通过SE模块强化了关键通道信息,同时融入了BiLSTM捕捉的时序演化规律,为后续刀具磨损预测提供高质量特征支撑。

### 2.3 SCBDA-Net

针对离线训练的源域模型与在线应用的目标域数据因工况变化产生分布差异的问题,本文提出SCBDA-Net自适应框架,核心是融合SE-CNN-BiLSTM的特征提取能力与DDA的动态域适应机制,实现模型跨域迁移与在线更新。网络结构如图5所示。该网络的设计思路为:(1)在传统神经网络基础上,通过融合SENet注意力机制强化通道间特征依赖关系,有助于提高DDA中数据分布对齐的有效性;(2)通过提取数据深度特征,动态域适应模块实时计算边缘分布与条件分布的贡献率差异,以最小化源域与目标域之间的最大均值差异,提高模型对于不同数据分布的适应性。

网络由特征提取模块和动态域适应模块组成。其中,特征提取模块

基于SE-CNN-BiLSTM实现,负责从源域和目标域数据中提取兼具通道特异性与时序关联性的深层特征,为后续分布对齐提供高质量输入。动态域适应模块包含全局域分类器和局部子域分类器。全局域分类器用于对齐源域与目标域的边缘分布,实现全局分布自适应;局部子域分类器用于识别各类别细粒度信息,对齐条件分布,实现局部分布自适应。

学习过程分为两个阶段:首先,将源域数据和目标域数据并行输入SE-CNN-BiLSTM,分别提取两者的深层特征;随后,结合源模型 $M_0$ 和其对应工况 $G_0$ 的特征数据 $D_0$ ,通过动态域适应模块计算两类分布的A-distance,动态调整权重系数,迭代优化MMD损失函数,完成跨域特征对齐与模型在线更新。

## 3 基于SCBDA-Net的刀具磨损预测模型

### 3.1 基于动态域适应方法的模型迁移流程

基于t-SNE高维特征可视化结果,工况的显著改变(如工件材料变




图5 深度动态域自适应方法

Fig.5 Deep dynamic-domain adaptation method

化、刀具更换)会导致源域与目标域间的特征分布差异显著增大,模型 $M_0$ 在新工况 $G_n$ 下的适用性大幅降低,严重影响预测模型的泛化性能。动态分布自适应算法通过最大均值差异量化并最小化跨域特征分布差异,其核心是采用深度迁移学习驱动的目标域自适应方法,解决变工况下的数据分布偏移问题。模型的迁移流程如图6所示,主要包含以下3个阶段。

(1) 离线训练阶段。基于传感器历史数据构建源域数据集,经最大最小归一化预处理后,按预设比例划分为训练集与测试集,通过学习训练得到初始源域模型 $M_0$ 。该阶段确保模型具备基础工况 $G_0$ 下的预测能力。

(2) 在线应用与预测阶段。在数控机床运行过程中,实时采集传感器数据并输入 $M_0$ 模型进行状态预测。同步采集新工况 $G_n$ 下的加工数据,经标准化与特征提取生成目标域特征数据集 $D_n$ 。模型更新触发机

制基于以下两种情况:①根据工况变化的周期性规律,在设定好的时间间隔内定期对模型进行评估与更新,以确保模型在长期运行中保持良好的适应性和预测精度;②实时监测加工参数或工艺条件变化,当偏移超过阈值时立即触发更新,确保模型快速适应刀具磨损、热误差等动态衰退因素。

(3) 模型自适应更新阶段。首先针对系统的变化通过短期仿真快速生成少量样本,再通过DDA模块动态调节边缘分布与条件分布的权重系数 $\omega$ ,迭代优化MMD损失函数以实现跨域特征对齐;当迁移损失收敛至最优值时,输出更新后模型 $M_n$ 。若评估指标未达预期,则继续优化网络参数直至满足精度要求,形成“预测-更新-验证”的闭环反馈机制。

### 3.2 评估指标

为全面评估模型性能,本文采用均方根误差RMSE、决定系数 $R^2$ 作为

评价指标。式(14)和(15)中RMSE值越小,表示模型的预测精度越高; $R^2$ 值越接近1,表示模型对数据的解释能力越强,预测结果越准确。

$$RMSE = \sqrt{\frac{1}{n_1} \sum_{i=1}^{n_1} (y_i - \hat{y}_i)^2} \quad (14)$$

$$R^2 = 1 - \frac{\sum_{i=1}^{n_1} (y_i - \hat{y}_i)^2}{\sum_{i=1}^{n_1} (y_i - \bar{y})^2} \quad (15)$$

式中, $y_i$ 为实际值; $\hat{y}_i$ 为预测值; $\bar{y}$ 为实际值的平均值; $n_1$ 为数据点的数量。

## 4 案例和讨论

为验证所提动态域适应方法的有效性,本文以铣削加工刀具磨损监测为典型场景构建验证体系。数据来源于NASA铣削数据集,该数据集因包含切削参数与工件材料的系统性变化,为检验动态域适应方法处理复杂分布偏移的能力提供了理想的测试平台。试验采用Matsuura加

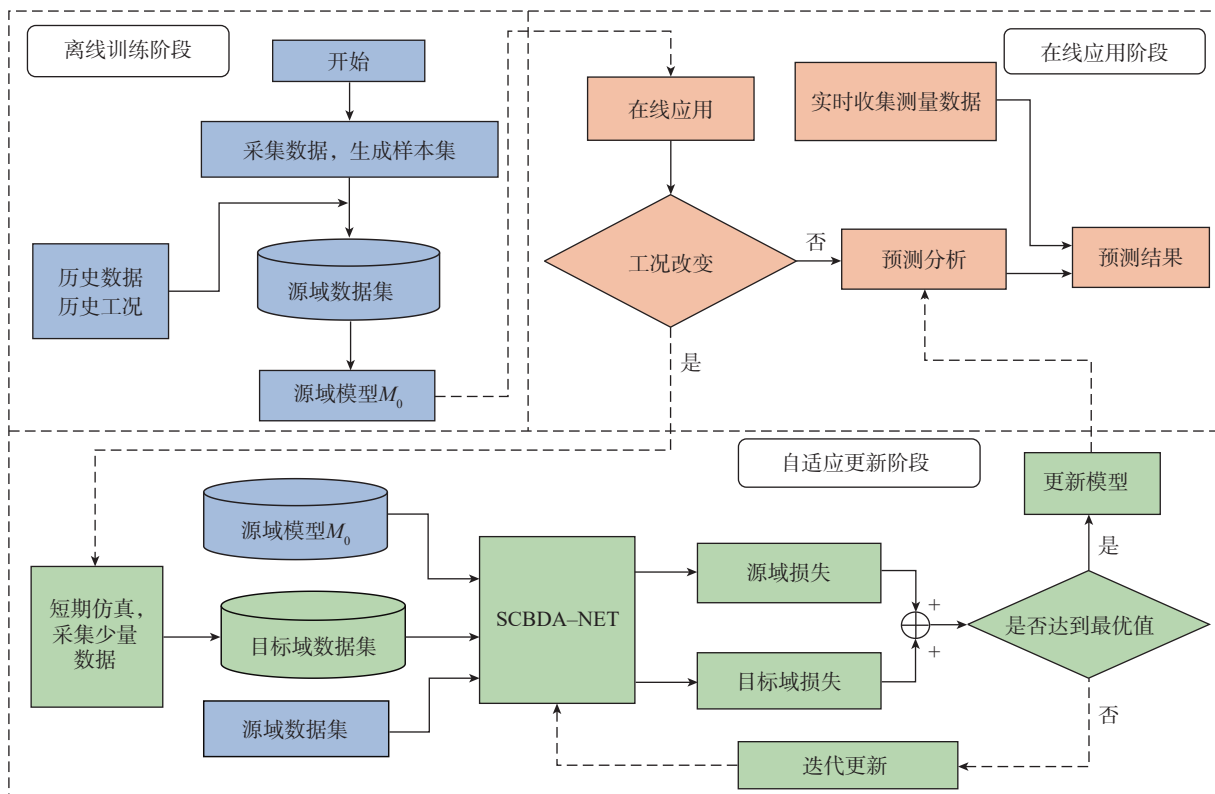


图6 变工况下预测模型更新流程图

Fig.6 Flowchart for updating the prediction model under variable working conditions

工中心(MC-510V),在不同切削参数下进行干铣粗加工,所用刀具为直径70 mm的六刃面铣刀,表面涂覆碳化钛、碳氮化钛与氮化钛3层涂层,加工零件尺寸为483 mm×178 mm×51 mm。该数据集采集了多种切削过程监测信号,主要包括主轴电机交流信号(smcAC)与直流信号(smcDC)、工作台振动信号(vib\_table)与主轴振动信号(vib\_spindle),以及工作台声发射信号(AE\_table)与主轴声发射信号(AE\_spindle)<sup>[32]</sup>。传感器安装位置及刀具磨损监控过程如图7所示。

#### 4.1 样本生成

数据预处理阶段,首先对采集的信号进行均方根(RMS)处理,并将采样频率统一为250 Hz。每个切削循环中,6种监测信号的采样点数均为9000个。根据切削深度、进给速度及加工材料的差异,共设计8种工况,每种工况开展2组独立试验,总计完成16组试验。每组试验包含多次切削运行(run),运行次数以切削循环(cycle)数量表示,且每次运行的加工时间不固定。每次运行结束后均测量刀具后刀面磨损VB值,部分运行因故障未完成测量。最终形成的试验数据集包含16个实例、167个样本,各实例的工况参数详见表1。

通过分析电机直流信号发现,监测数据中同时包含进刀和退刀过程。如图8所示,当进给速度为0.25 mm/r时,实例15第7次进刀信号仅包含进刀阶段;而进给速度提升至0.5 mm/r时,信号中同时包含进刀与退刀过程。为确保数据一致性与稳定性,选取信号的第2000~6999个采样点作为有效监测数据(共5000个采样点),舍弃进刀和退刀阶段的数据。

数据质量控制过程中,发现部分样本存在异常需剔除:Case6仅包含1次运行;实例3、实例5、实例10的第1次运行切削时间为0;实例1第17次运行后的磨损值异常,甚至小

于第15次运行的测量值。经数据清洗后,最终保留15个有效实例,其中含磨损标签的样本共140个。鉴于磨损样本数量有限且缺损较多,研究采用数据增强技术扩充样本规模<sup>[33]</sup>:将原始样本中5000个采样点的有效监测数据,以1000个采样点为间隔

划分为5个新样本,新样本共享同一磨损值标签。经过处理,样本数量扩充至原规模的5倍,每个新样本维度为(1,1000,6)。

#### 4.2 试验设计

试验设定初始工艺条件为切削深度1.5 mm、进给量0.5 mm/r、加工

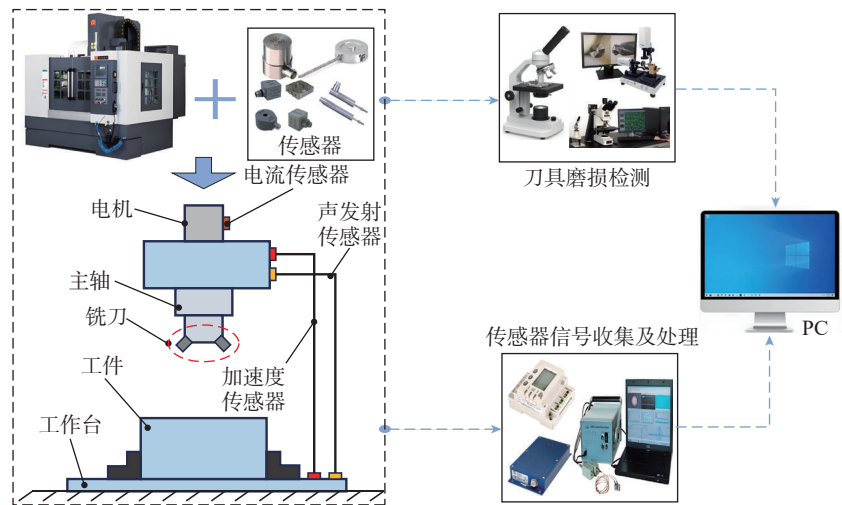


图7 铣削磨损试验平台示意图

Fig.7 Schematic diagram of the milling wear experiment platform

表1 16个实例的工况参数

Table 1 Working conditions parameters of 16 examples

实例	切削速度 / ( $m \cdot \min^{-1}$ )	切削深度 / mm	进给量 / ( $mm \cdot r^{-1}$ )	加工材料
实例1	200	1.5	0.5	铸铁
实例2	200	0.75	0.5	铸铁
实例3	200	0.75	0.25	铸铁
实例4	200	1.5	0.25	铸铁
实例5	200	1.5	0.5	钢
实例6	200	1.5	0.25	钢
实例7	200	0.75	0.25	钢
实例8	200	0.75	0.5	钢
实例9	200	1.5	0.5	铸铁
实例10	200	1.5	0.25	铸铁
实例11	200	0.75	0.25	铸铁
实例12	200	0.75	0.5	铸铁
实例13	200	0.75	0.25	钢
实例14	200	0.75	0.5	钢
实例15	200	1.5	0.25	钢
实例16	200	1.5	0.5	钢

材料为铸铁。基于初始工况,首先离线训练构建源域模型,利用 SE-CNN-BiLSTM 特征提取器对初始工况下的 6 种加工信号进行初级特征提取,再采用提取的特征训练算法模型,并通过测试集验证模型性能,图 9 展示了部分试验的预测结果。尽管刀具磨损量存在显著随机波动,但所构建的初始工况预测模型仍能较好地跟踪实际磨损趋势,且预测误差被控制在较小区间内,说明该模型在初始工况下具备优异的拟合稳定性。

实际生产中,不同工况下采集的传感器信号既存在相关性也存在差异性。本文考虑的工况变化包括切削参数调整与被加工工件材料的改变。为验证铣削变工况刀具磨损预测模型在不同工况下的准确性与适应性,基于源域数据建立的预测模型,对不同工况下的模型迁移可行性开展验证,设计了 6 个迁移任务,初始工况为  $D_S$ 。其中,迁移任务  $D_S \rightarrow D_{T1}$ 、 $D_S \rightarrow D_{T2}$ 、 $D_S \rightarrow D_{T3}$  和  $D_S \rightarrow D_{T4}$  涉及被加工材料改变与切削参数调整,  $D_S \rightarrow D_{T5}$ 、 $D_S \rightarrow D_{T6}$  仅涉及切削参数调整,迁移任务的详细设置如表 2 所示。

### 4.3 结果分析

#### 4.3.1 SCBDA 在不同目标域下的性能测试

对新工况下的刀具磨损状态进行预测,针对从源域到目标域的 6 个迁移任务,得到的预测结果如图 10 所示。其中 3 条曲线分别表示刀具磨损的真实变化趋势(蓝色)、迁移前模型的预测结果(紫色)、迁移后模型的预测结果(红色)。

由图 10 可知,未迁移模型的输出结果与试验结果存在显著偏差,表明未经迁移调整的模型难以准确捕捉工况显著变化时的刀具磨损状态。而采用 DDA 领域自适应方法后,模型可有效对齐源域与目标域的特征分布,预测性能显著提升。迁移前模型的误差范围(紫色区域)完全覆盖

迁移后模型的误差范围(红色区域),且迁移后误差幅值明显收敛、波动显著减小。试验结果显示,迁移学习

优化后的模型输出结果与试验结果吻合度较高,DDA 方法在处理高差异工况时可有效降低模型预测误差。

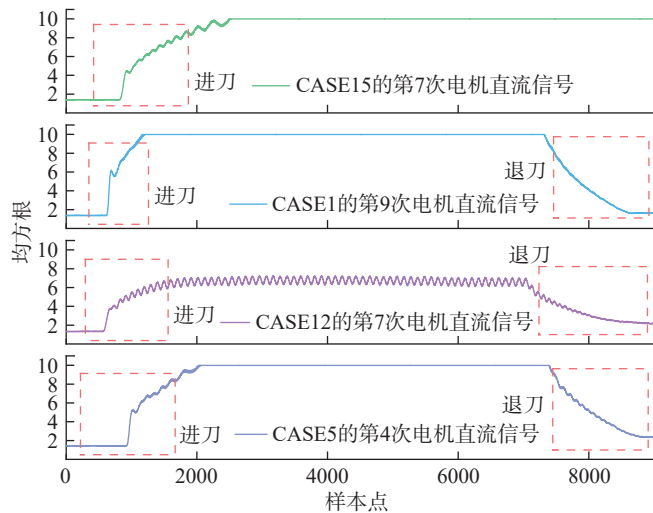


图 8 电机直流信号  
Fig.8 DC signal of motor




图 9 SE-CNN-BiLSTM 模型的预测结果  
Fig.9 Prediction results of the SE-CNN-BiLSTM model

表 2 迁移任务设置  
Table 2 Transfer task settings

工况类型	迁移任务	数据域	切削速度 / (m/min)	切削深度 / mm	进给量 / (mm/r)	加工材料
源域工况	—	$D_S$	200	1.5	0.5	铸铁
目标域工况	$D_S \rightarrow D_{T1}$	$D_{T1}$	200	1.5	0.5	钢
	$D_S \rightarrow D_{T2}$	$D_{T2}$	200	0.75	0.25	钢
	$D_S \rightarrow D_{T3}$	$D_{T3}$	200	0.75	0.5	钢
	$D_S \rightarrow D_{T4}$	$D_{T4}$	200	1.5	0.25	钢
	$D_S \rightarrow D_{T5}$	$D_{T5}$	200	0.75	0.5	铸铁
	$D_S \rightarrow D_{T6}$	$D_{T6}$	200	0.75	0.25	铸铁

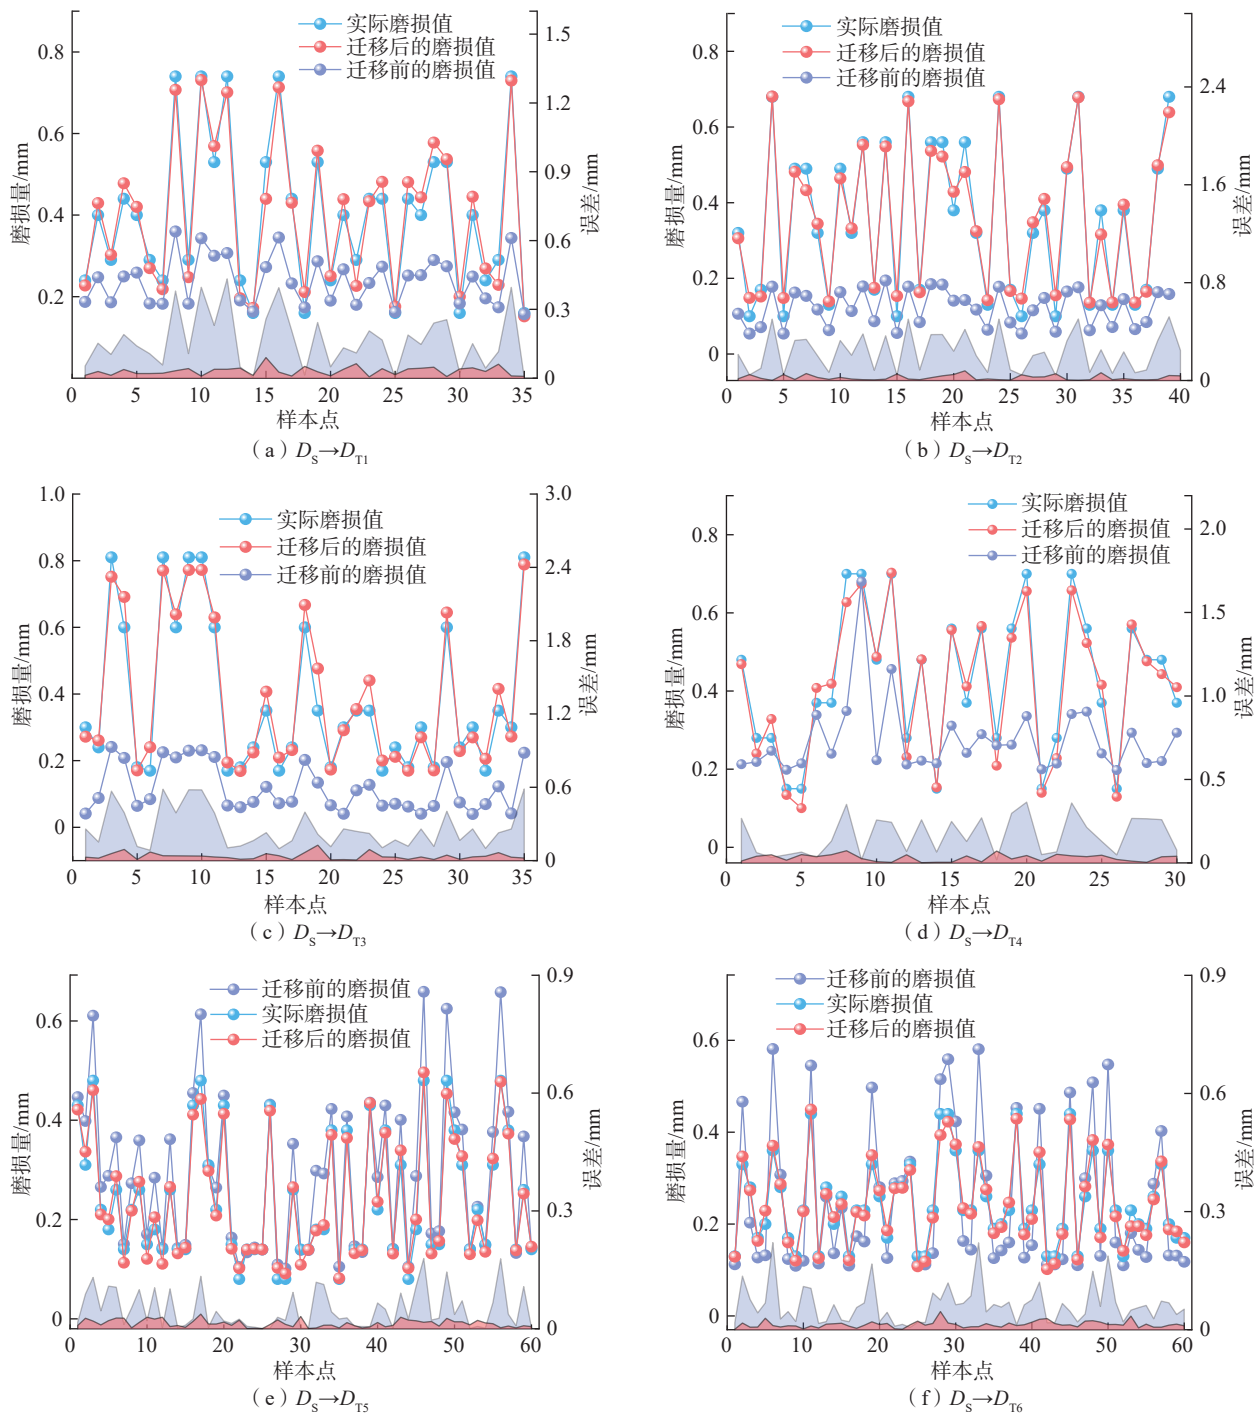


图 10 工况变化下的预测结果

Fig.10 Prediction results under changing working conditions

优化后的模型不仅能准确预测该材料多切削参数下的磨损值,还表现出良好的泛化性能。

由表 3 可知,与未迁移模型相比,迁移后模型的各项性能指标均显著提升, RMSE 值大幅降低,  $R^2$  值明显升高,尤其在低差异工况下性能提

升更为突出。这表明深度迁移学习策略可有效缩小源域与目标域的分布差异,使模型学习到两域数据的共性特征,从而提高模型在目标域的计算精度。

为直观展示模型迁移更新的优势,选取工况  $D_{T_2}$  的目标域数据作为

测试集,分别输入迁移前、迁移后模型进行测试,结果如图 11 所示。迁移前模型的预测误差较大,表明未经迁移调整的模型适配新工况的能力不足;而迁移后模型的预测误差显著降低,验证了迁移学习在提升模型适应性与准确性方面的显著效果。

此外,折线图进一步表明,迁移后的误差在各工况下均显著低于迁移前的误差。

### 4.3.2 t-SNE 可视化试验结果及分析

为更清晰地体现所提方法的优越性,采用 t-SNE 可视化工具对 6 种工况变化下的源域与目标域特征分布进行可视化,其中红色点代表源域特征,蓝色点代表目标域特征。由图 12 可知,模型更新前,源域与目标域的特征分布距离较远,尤其在材料突变工况下,特征分布呈现明显分离状态,差异显著,表明原始模型对两域特征的区分度较高,无法很好适配目标域数据特性。而通过迁移学习后,源域与目标域的特征分布距离显著拉近,特征重叠程度提升,表明所提方法可有效对齐不同工况下的特征分布,增强模型的跨工况适应能力。

通过对 6 个迁移任务的试验结果分析可知,本文提出的迁移方法在刀具磨损预测中具有有效性。DDA 领域自适应方法可有效对齐特征分布,提升模型泛化能力,迁移后的模型能更好地捕捉新工况下的特征变化,从而显著提高预测精度。

### 4.3.3 DDA 的迁移性能对比

为验证 DDA 的迁移性能,选取基于分布对齐的 BDA、边缘分布自适应(MDA)、条件分布自适应(CDA)方法,对源域模型 SE-CNN-BiLSTM 开展迁移对比试验,评估 DDA 在跨域任务中的表现。对比试验结果如图 13 所示,其中每个顶点代表一个目标域的  $R^2$  值,覆盖面积越大表示预测性能越优。

由图 13 可知,DDA 在刀具磨损预测方面的性能优于其他迁移学习方法,且在各目标域均具备较高的预测准确率。BDA 虽同时考虑了条件分布与边缘分布的影响,但其固定的权重分配机制无法动态适配不同工况下的分布特征变化;MDA 和 CDA 因仅关注单一分布对齐,在工况变化

表 3 工况改变后模型的 RMSE,  $R^2$  计算结果

Table 3 RMSE and  $R^2$  calculation results of the model after changing the working conditions

工况类型	迁移任务	RMSE		$R^2$	
		迁移前	迁移后	迁移前	迁移后
目标域工况	$D_s \rightarrow D_{T1}$	0.205	0.036	-0.280	0.960
	$D_s \rightarrow D_{T2}$	0.280	0.031	-0.969	0.976
	$D_s \rightarrow D_{T3}$	0.307	0.050	-0.918	0.948
	$D_s \rightarrow D_{T4}$	0.201	0.041	-0.234	0.949
	$D_s \rightarrow D_{T5}$	0.069	0.016	0.695	0.982
	$D_s \rightarrow D_{T6}$	0.080	0.015	0.214	0.970




图 11 新工况下不同模型预测误差

Fig.11 Prediction errors of different models under new working conditions

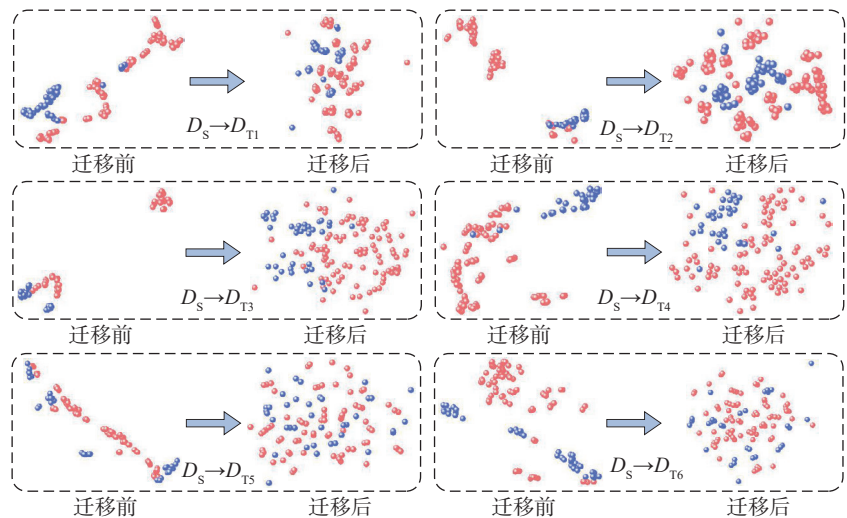


图 12 模型更新前后的特征分布

Fig.12 Feature distribution before and after model update

时表现出明显的适应性不足,说明仅对齐条件分布或边缘分布的方法难以达到预期效果。相比之下,DDA 通过 A-distance 计算并动态调整边缘分布与条件分布的权重,具备更优的自适应性与迁移性能。

### 4.3.4 不同特征提取器的迁移性能对比

为验证所提 CNN-BiLSTM-SE 特征提取器的有效性,在相同 DDA 迁移学习框架下,分别采用支持向量机(SVM)、随机森林(RF)、XGBoost、

ResNet、CNN-BiLSTM 及 SE-CNN-BiLSTM 作为特征提取器,在 6 个不同工况目标域( $D_{T1} \sim D_{T6}$ )上进行对比试验,评估不同特征提取器对迁移性能的影响。各模型在 DDA 迁移后的预测性能如表 4 所示, $R^2$  值越接近 1、RMSE 值越接近 0 表示预测精度越高。

表 4 结果表明,在统一 DDA 迁移框架下,特征提取器的结构设计对模型在材料变化工况( $D_{T1} \sim D_{T4}$ )中的预测性能存在显著影响;而在工

况稳定性更强的  $D_{T5} \sim D_{T6}$  中,各模型的性能差距相对缩小。具体分析如下:传统机器学习方法(SVM、RF、XGBoost)受限于人工特征依赖与浅层特征表征能力,难以从多源时序传感信号中提取深层关联特征,迁移预测精度较低,平均  $R^2$  仅为 0.66~0.70;ResNet 凭借深层卷积网络的层级特征提取能力,将平均  $R^2$  提升至 0.75,体现出深度学习在特征表征方面的优势;CNN-BiLSTM 融合卷积神经网络的局部空间特征提取优势与双

向长短期记忆网络的时序依赖建模能力,有效实现多源时序信号的特征提取,平均  $R^2$  提升至 0.93,预测精度显著提高;所提 SE-CNN-BiLSTM 在上述结构基础上引入 SE 注意力机制,通过对通道维度特征自适应加权,增强与刀具磨损状态强相关的关键传感特征响应,同时抑制冗余噪声干扰,最终以 0.964 的平均  $R^2$  与最低平均 RMSE,取得全工况最优迁移预测性能。尤其在材料变化显著的  $D_{T1} \sim D_{T4}$  工况中,其  $R^2$  较 CNN-BiLSTM 提升 3.9%~6.9%,充分验证了该特征提取器在工况动态变化场景下的良好适应性。

## 5 结论

针对刀具磨损预测模型在动态工况下面临的性能衰退与预测失准问题,本文提出一种基于深度迁移学习的刀具磨损预测模型自适应更新方法,通过理论分析与试验验证得出以下结论。

(1) 预测模型的自适应重构能力。所提动态权重分配机制可依据工况变化自适应调整边缘分布与条件分布的权重比例,实现迁移特征差异的精准优化。在域适应阶段,该策略既能自适应对齐特征分布,又能动态调节两类分布的重要性权重,最小化源域与目标域的特征差异,实现预测模型的有效更新,为解决工况变化导致的模型预测失准问题提供了可




图 13 DDA 对比试验结果

Fig.13 Results of DDA comparative experiment

表 4 不同特征提取器在 DDA 迁移下的性能对比

Table 4 Performance comparison of different feature extractors under DDA transfer

模型	$D_S \rightarrow D_{T1}$		$D_S \rightarrow D_{T2}$		$D_S \rightarrow D_{T3}$		$D_S \rightarrow D_{T4}$		$D_S \rightarrow D_{T5}$		$D_S \rightarrow D_{T6}$	
	$R^2$	RMSE	$R^2$	RMSE	$R^2$	RMSE	$R^2$	RMSE	$R^2$	RMSE	$R^2$	RMSE
RF	0.635	0.191	0.612	0.197	0.598	0.205	0.626	0.193	0.825	0.102	0.795	0.108
XGBoost	0.658	0.185	0.628	0.193	0.615	0.198	0.642	0.189	0.838	0.095	0.808	0.098
SVM	0.608	0.198	0.592	0.202	0.574	0.215	0.601	0.199	0.818	0.112	0.782	0.112
ResNet	0.752	0.136	0.702	0.146	0.661	0.152	0.728	0.141	0.847	0.080	0.812	0.091
CNN-BiLSTM	0.924	0.052	0.915	0.063	0.908	0.077	0.917	0.056	0.965	0.019	0.948	0.023
SE-CNN-BiLSTM	0.960	0.036	0.976	0.031	0.948	0.050	0.949	0.041	0.982	0.016	0.970	0.015

行方案。

(2) 迁移策略的稳定性。构建的 SCBDA 迁移学习框架, 形成了覆盖特征提取、分布对齐与模型校准的全流程更新策略。基于 NASA 铣削数据集的多工况测试表明, 模型对切削参数突变、刀具磨损演化等动态场景的适应性显著提升, 验证了该方法在变工况加工环境中的工程适用性与稳定性。

尽管本文所提框架在模型迁移性能与跨工况适应性方面取得了进展, 但要实现在复杂工业场景中的可靠落地, 仍需开展更深入的研究。未来的工作将重点围绕以下方向展开: (1) 探索多源、多变条件下刀具磨损的精确物理演进规律, 并建立数据驱动预测模型与刀具实际物理状态之间的动态同步机制, 以提升预测结果的可信度与工程实用性; (2) 推动机械、材料与信息学科的深度交叉融合, 通过集成系统动力学、材料行为分析与自适应智能算法, 解决预测技术在工业现场长期运行中的适应性与稳定性问题。

### 参考文献

[1] 罗欢, 张定华, 罗明. 航空难加工材料切削刀具磨损与剩余寿命预测研究进展[J]. 中国机械工程, 2021, 32(22): 2647–2666.

LUO Huan, ZHANG Dinghua, LUO Ming. Tool wear and remaining useful life estimation of difficult-to-machine aerospace alloys: A review[J]. China Mechanical Engineering, 2021, 32(22): 2647–2666.

[2] 刘献礼, 李雪冰, 丁明娜, 等. 面向智能制造的刀具全生命周期智能管控技术[J]. 机械工程学报, 2021, 57(10): 196–219.

LIU Xianli, LI Xuebing, DING Mingna, et al. Intelligent management and control technology of cutting tool life-cycle for intelligent manufacturing[J]. Journal of Mechanical Engineering, 2021, 57(10): 196–219.

[3] SUN J C, LIU Z Y, WANG D, et al. A parallel network model: Intelligent monitoring of tool wear under variable working conditions[J]. Robotics and Computer-Integrated

Manufacturing, 2025, 96: 103065.

[4] LI N P, LEI Y G, GEBRAEEL N, et al. Multi-sensor data-driven remaining useful life prediction of semi-observable systems[J]. IEEE Transactions on Industrial Electronics, 2021, 68(11): 11482–11491.

[5] 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]. 机械工程学报, 2025, 61(19): 299–326.

WANG Min, CHE Changjia, GAO Xiangsheng, et al. Tool wear condition monitoring and remaining life prediction under complex working conditions: A review[J]. Journal of Mechanical Engineering, 2025, 61(19): 299–326.

[6] LI N, WANG X, WANG W Z, et al. A multi-feature dataset of coated end milling cutter tool wear whole life cycle[J]. Scientific Data, 2025, 12: 16.

[7] MOHANRAJ T, SHANKAR S, RAJASEKAR R, et al. Tool condition monitoring techniques in milling process—A review[J]. Journal of Materials Research and Technology, 2020, 9(1): 1032–1042.

[8] SAYYAD S, KUMAR S, BONGALE A, et al. Data-driven remaining useful life estimation for milling process: Sensors, algorithms, datasets, and future directions[J]. IEEE Access, 2021, 9: 110255–110286.

[9] ZHANG H, YANG W K, XU W Y, et al. Tool wear prediction with few samples based on stacked BiLSTM and parallel residuals with multi-head self-attention[J]. Measurement, 2026, 258: 119078.

[10] LIU X L, LIU S Y, LI X B, et al. Intelligent tool wear monitoring based on parallel residual and stacked bidirectional long short-term memory network[J]. Journal of Manufacturing Systems, 2021, 60: 608–619.

[11] 包振科, 曹华军, 秦逢泽, 等. 基于 IWOA-IECA-BiLSTM 模型的刀具磨损监测[J]. 中国机械工程, 2025, 36(12): 2936–2943.

BAO Zhenke, CAO Huajun, QIN Fengze, et al. Tool wear monitoring based on IWOA-IECA-BiLSTM model[J]. China Mechanical Engineering, 2025, 36(12): 2936–2943.

[12] 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 Peng, MA Yao, GUO Yongyi, 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.

[13] XIE Y, ZHANG C Y, LIU Q. Tool wear status recognition and prediction model of milling cutter based on deep learning[J]. IEEE Access, 2021, 9: 1616–1625.

[14] CHE Z Y, PENG C, LIAO T W, et al. Improving milling tool wear prediction through a hybrid NCA-SMA-GRU deep learning model[J]. Expert Systems with Applications, 2024, 255: 124556.

[15] ZHANG P F, GAO D, HONG D B, et al. Intelligent tool wear monitoring based on multi-channel hybrid information and deep transfer learning[J]. Journal of Manufacturing Systems, 2023, 69: 31–47.

[16] WANG Y F, GAO J, WANG W, et al. A novel method based on deep transfer learning for tool wear state prediction under cross-dataset[J]. The International Journal of Advanced Manufacturing Technology, 2024, 131(1): 171–182.

[17] 孙安东, 莫轩东, 胡小锋. 变工况背景下基于域泛化和元学习的小样本刀具磨损预测方法[J]. 计算机集成制造系统, 2025, 31(9): 3197–3208.

SUN Andong, MO Xuandong, HU Xiaofeng. Small data tool wear prediction based on domain generalization and meta-learning under varying cutting condition[J]. Computer Integrated Manufacturing Systems, 2025, 31(9): 3197–3208.

[18] 强碧瑶, 史恺宁, 任军学, 等. 基于实例迁移学习的跨工况刀具剩余寿命预测[J]. 航空学报, 2024, 45(13): 197–209.

QIANG Biyao, SHI Kaining, REN Junxue, et al. Instance transfer for tool remaining useful life prediction cross working conditions[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(13): 197–209.

[19] WANG R Q, SONG Q H, PENG Y Z, et al. Toward digital twins for high-performance manufacturing: Tool wear monitoring in high-speed milling of thin-walled parts using domain knowledge[J]. Robotics and Computer-Integrated Manufacturing, 2024, 88: 102723.

[20] MAREI M, LI W D. Cutting tool prognostics enabled by hybrid CNN-LSTM with transfer learning[J]. The International Journal of Advanced Manufacturing Technology, 2022, 118(3): 817–836.

[21] LI J B, LU J, CHEN C Y, et al. Tool

wear state prediction based on feature-based transfer learning[J]. *The International Journal of Advanced Manufacturing Technology*, 2021, 113(11): 3283–3301.

[22] 张春霖, 周婷婷, 胡天亮, 等. 刀具切削变工况数字孪生模型构建方法[J]. *计算机集成制造系统*, 2023, 29(6): 1852–1866.

ZHANG Chunlin, ZHOU Tingting, HU Tianliang, et al. Construction method of digital twin model for cutting tools under variable working conditions[J]. *Computer Integrated Manufacturing Systems*, 2023, 29(6): 1852–1866.

[23] GAO Z L, CHEN N, YANG Y F, et al. An innovative multisource multibranch metric ensemble deep transfer learning algorithm for tool wear monitoring[J]. *Advanced Engineering Informatics*, 2024, 62: 102659.

[24] LI K, LI Z L, JIA X S, et al. A domain adversarial graph convolutional network for intelligent monitoring of tool wear in machine tools[J]. *Computers & Industrial Engineering*, 2024, 187: 109795.

[25] WANG J D, CHEN Y Q, FENG W J, et al. Transfer learning with dynamic distribution adaptation[J]. *ACM Transactions on Intelligent Systems and Technology*, 2020, 11(1): 1–25.

[26] WANG J Z, ZHU Y Q, GAO Y P, et al. Detecting energy theft in different regions based on convolutional and joint distribution adaptation[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 2520109.

[27] CAI T T, MA R. Theoretical foundations of t-SNE for visualizing high-dimensional clustered data[EB/OL]. [2105–10–23]. <https://arxiv.org/abs/2105.07536>.

[28] ALLAOUI M, HEDJAM R, BOUANANE K, et al. Exploring non-negativity for improved manifold embedding: Application to t-SNE[J]. *Knowledge-Based Systems*, 2025, 330: 114547.

[29] WANG L L, LI Y Q, ZHANG C Y, et al. Research on bearing fault feature transfer diagnosis based on balanced distribution adaptation under feature fusion[J]. *Advances*

in *Mechanical Engineering*, 2025, 17(6): 16878132251348366.

[30] XU H Y, WANG J L, LIU J, et al. A novel joint distinct subspace learning and dynamic distribution adaptation method for fault transfer diagnosis[J]. *Measurement*, 2022, 203: 111986.

[31] ZHU H J, GU W, WANG L M, et al. Android malware detection based on multi-head squeeze-and-excitation residual network[J]. *Expert Systems with Applications*, 2023, 212: 118705.

[32] MO X D, HU X F, SUN A D, et al. A meta-learning method for smart manufacturing: Tool wear prediction using hybrid information under various operating conditions[J]. *Robotics and Computer-Integrated Manufacturing*, 2025, 91: 102846.

[33] ZHANG P F, GAO D, HONG D B, et al. Intelligent tool wear monitoring based on multi-channel hybrid information and deep transfer learning[J]. *Journal of Manufacturing Systems*, 2023, 69: 31–47.

## Online Updating Method for Tool Wear Predicting Model Based on Dynamic Domain Adaptation Network

XIN Junbo, HUANG Hua, REN Yapeng, WANG Keren, LIAN Guodang

(School of Mechanical and Electrical Engineering, Lanzhou University of Technology, Lanzhou 730000, China)

**[ABSTRACT]** Traditional tool wear predicting methods are predominantly based on empirical models or static optimization strategies, which exhibit poor adaptability in complex machining environments characterized by multi-variable coupling and dynamically evolving working conditions. Such inadequacy is prone to inducing distribution shifts in monitoring data, thereby leading to inaccurate model predictions and diminished generalization capability. To address this issue, an online update method for tool wear prediction models based on dynamic domain adaptation networks was proposed in this paper. By introducing a dynamic distribution adaptation mechanism, the contribution ratios of marginal distributions and conditional distributions to domain shifts were quantified in real time, and the feature alignment weights were dynamically adjusted to achieve continuous and accurate calibration of the model. Taking milling tool wear monitoring as the application scenario, the cross-working-condition adaptability of the model was enhanced from two aspects: feature selection and distribution adaptation. Firstly, a feature extractor based on SE–CNN–BiLSTM was constructed to strengthen the screening capability of multi-channel key working condition features; secondly, the dynamic distribution adaptation algorithm was integrated, and the SCBDA–Net (SE–CNN–BiLSTM Dynamic Domain Adaptation Network) adaptive framework was proposed to accomplish cross-domain transfer and update of the model under varying working conditions. Experimental results demonstrate that the proposed method can significantly improve the cross-working-condition generalization performance and prediction accuracy of the model.

**Keywords:** Tool wear; Transfer learning; Dynamic domain adaptation; Varying working conditions; Attention mechanism

(责编 晓月)