

DOI: 10.19650/j.cnki.cjsi.J2514414

基于多源信号融合的刀具状态监测研究进展

王松^{1,2,3}, 王琛英^{1,2,3}, 张雅馨^{2,4}, 钟倩倩^{1,2,3}, 蒋庄德^{2,4}

(1. 西安交通大学仪器科学与技术学院 西安 710049; 2. 西安交通大学精密微纳制造技术全国重点实验室 西安 710049; 3. 西安交通大学微纳制造与测试技术国际合作联合实验室 西安 710049; 4. 西安交通大学机械工程学院 西安 710049)

摘要: 刀具状态监测是保障数控机床加工质量、提升生产效率及延长设备寿命的关键技术。刀具作为加工系统中的关键执行部件,其磨损、崩刃等失效形式直接影响加工精度与系统可靠性。受切削参数变化、工况波动及环境噪声等因素影响,刀具退化过程具有连续、不可逆和不确定等特征,单一传感信号在信息完整性与抗干扰能力方面存在明显不足。多源信号融合技术通过整合切削力、振动、声发射、电流、功率等多传感器信号的优势,为实现高精度、高鲁棒性的刀具在线状态监测提供了有效途径。围绕多源信号融合技术在刀具状态监测中的应用,对相关理论框架与研究进展进行了系统综述。分析了切削力、振动、声发射等常用传感器类型及其集成方式,对比了不同传感器在信号获取精度、抗干扰能力及响应特性等方面的性能差异。随后,重点探讨了数据级、特征级与决策级融合策略,涵盖滤波算法、机器学习模型及不确定性推理方法等关键技术,系统阐述了各类方法的适用场景及实现效果。结合刀具破损识别、磨损评估与剩余寿命预测等典型应用,揭示了多源信号融合在提升监测精度与可靠性方面的优势。最后,总结了当前研究挑战并提出未来发展方向,为刀具全生命周期监测提供理论依据与工程参考。

关键词: 多源信号融合; 刀具状态监测; 寿命预测; 智能制造; 深度学习

中图分类号: TH117.1 **文献标识码:** A **国家标准学科分类代码:** 460.40

Research progress on tool condition monitoring based on multi-source signal fusion

Wang Song^{1,2,3}, Wang Chenying^{1,2,3}, Zhang Yaxin^{2,4}, Zhong Qianqian^{1,2,3}, Jiang Zhuangde^{2,4}

(1. School of Instrument Science and Technology, Xi'an Jiaotong University, Xi'an 710049, China;
2. State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University, Xi'an 710049, China;
3. International Joint Laboratory for Micro/Nano Manufacturing and Measurement Technologies, Xi'an Jiaotong University, Xi'an 710049, China; 4. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Tool condition monitoring (TCM) is a key technology for ensuring machining quality, improving production efficiency, and extending the service life of computer numerical control (CNC) machine tools. As a core component of the machining system, the cutting tool is subject to failure modes such as wear and chipping, which directly affect machining accuracy and system reliability. Influenced by variations in cutting parameters, fluctuations in operating conditions, and environmental noise, the tool wear process exhibits continuous, irreversible, and uncertain characteristics, resulting in evident limitations of single-sensor signals in terms of information completeness and anti-interference capability. By integrating the complementary advantages of multi-sensor signals such as cutting force, vibration, acoustic emission, current, and power, multi-source signal fusion provides an effective approach for achieving highly accurate and robust online tool condition monitoring. Focusing on the application of multi-source signal fusion in TCM, this work presents a systematic review of relevant theoretical frameworks and research progress. Common sensor types, including cutting force, vibration, and acoustic emission sensors, as well as their integration methods, are analyzed, and the performance differences among various sensors in terms of signal acquisition accuracy, anti-interference capability, and response characteristics are compared. Subsequently, data-level, feature-level, and decision-level fusion strategies are discussed, including filtering algorithms, machine learning models, and uncertainty reasoning

methods. Typical applications such as tool breakage detection, wear monitoring, and remaining useful life prediction are reviewed to reveal the advantages of multi-source signal fusion in improving monitoring accuracy and system reliability. Finally, current challenges and future directions are summarized, providing theoretical and practical references for tool lifecycle monitoring.

Keywords: multi-source signal fusion; tool condition monitoring; remaining useful life prediction; intelligent manufacturing; deep learning

0 引言

制造业不仅是经济发展的重要支柱,更是国家综合实力与战略竞争力的集中体现。在新一轮的科技革命与产业变革中,智能制造已成为全球产业竞争的制高点。美国以“先进制造伙伴计划”和“工业互联网联盟”政策推动产业升级,德国发布“工业4.0”,日本实施“机器人新战略”,均着力应对制造业的智能化转型^[1]。我国作为全球制造业规模最大、体系最完整的国家,正处于由“制造大国”向“制造强国”转变的关键阶段。《机械工业数字化转型实施方案(2025—2030年)》明确将智能制造定位为主攻方向^[2],以装备技术与新一代信息技术深度融合为主线。这不仅驱动研发设计、生产制造、运维服务全链条的体系重构,更对生产过程中关键环节的实时感知与智能控制提出了更高要求。在众多关键环节中,加工过程执行端的关键部件直接决定了制造质量与效率,而刀具便是其中影响最为显著的因素之一。

在此背景下,刀具状态监测技术的重要性日益凸显。作为数控机床中直接参与切削的核心元件,刀具的磨损、崩刃等失效形式往往是加工精度波动、工件报废甚至机床故障的直接诱因^[3-4]。刘建春等^[5]利用机器视觉的直接检测方法,通过对刀具图像的圆周刀轮廓精确拟合,实现了检测精度达0.01 mm的磨损测量。然而,直接检测法虽直观,但需停机测量,实时性与效率较低,难以适应现代制造的高速、高精度需求。因此,发展可在线、实时诊断与预测的刀具状态监测技术,已成为保障加工质量、提高生产效率、延长设备寿命的关键途径^[6]。

与轴承、齿轮等部件相比,刀具在状态监测中具有显著的差异性。轴承、齿轮主要作为主轴或传动系统的支撑和运转零件,其典型失效形式为磨损、点蚀、疲劳或断齿等损伤与故障^[7-8],在振动等监测信号中常表现为具有明确特征频率的周期性冲击^[9-10],因此其状态识别通常可转化为基于特征频率的分类问题。相比之下,刀具是直接参与材料去除并决定工件加工质量的核心执行部件^[11],其主要失效模式为磨损。刀具磨损具有连续、不可逆和渐进退化特性,通常经历初期、稳定和严重磨损阶段^[12],且受切削参数、工况与环境等多因素耦合影响。因此,刀具状态监测不仅需要实现磨损阶段判别,更需对磨损量或剩余寿命进行预测,属于受物理约束的回归问

题。此外,刀具相关信号(如切削力、振动)是复杂的、连续的非平稳信号,难以通过简单的频域分析分离特征。同时,实际监测中多依赖间接测量^[13],易受噪声和传递路径影响,进一步增加了特征提取与状态评估的难度。

基于上述特性,仅靠单一传感信号难以全面刻画刀具状态演变规律,制约了监测精度与鲁棒性^[14]。随着机器学习、深度学习等人工智能与先进传感技术的发展,多源信号融合技术通过结合切削力、振动、声发射、电流/功率、温度、视觉等多维数据,利用不同传感器在灵敏性与信息维度上的互补性,可更准确反映刀具运行状态^[15-16],并显著提升磨损评估与寿命预测的精度与稳定性。多项研究均验证了多传感器信号融合在刀具状态监测中的优势。例如,Zhang等^[17]在刀具磨损预测中发现,单一传感器数据最大预测误差为38.9 μm ,且磨损曲线易出现跳点;而融合了多维切削力与过程信息后,误差降至9 μm ,仅为前者的约1/4。李亚等^[18]指出,主轴电流信号稳定性好、振动信号实时性高,二者结合并采用t-分布随机邻近嵌入降维与极限梯度提升算法(extreme gradient boosting, XGBoost)建模分析,可显著降低平均预测误差。Nasir等^[19]在锯切刀具温度监测中发现,声发射传感器单独表现优异,但与振动信号融合后效果更佳。Gao等^[20]通过融合切削力、振动和声发射等信号,将磨损预测误差控制在0.02 mm以内。可见,多源信号融合不仅克服了单一传感器在信息维度、稳定性或实时性上的局限,还能够在复杂加工条件下实现更高精度与鲁棒性的刀具状态评估。

随着基于多源信号融合的刀具状态监测相关研究的热度不断攀升,国内外学者也对基于传感器的智能刀具在线监测^[21]及多传感器数据融合技术在制造过程中的应用^[22]等开展了综述研究,指出监测信号在状态评估和故障诊断中的价值,并强调间接测量在稳定性与准确性上的优势,探讨了传感器技术、数据处理与人工智能在提升制造效率和质量中的作用。在此基础上,本研究从多传感器融合技术在数控机床刀具状态监测中的理论框架与应用进展出发,梳理各类传感器的性能特点,总结典型融合方法,并综述其在磨损评估、破损识别和寿命预测方面的最新成果。最后,分析该领域面临的关键挑战与未来趋势,为刀具全生命周期状态监测的理论研究与工程应用提供参考。

1 多源信号采集与融合方法

1.1 传感器选型与集成

为实现高效精准的刀具状态监测,需基于物理机制合理选用传感器并优化设计集成方案。常用的传感信号包括切削力、振动、声发射、电流/功率、温度及图像等,这些信号能从不同角度反映刀具磨损演化过程。通过融合上述类型信号可有效弥补单一信号的局限,提升系统鲁棒性与灵敏度。本节将综述各类传感器的功能特性,并讨论多传感器典型集成方式和策略。

1) 传感器类型及作用

在刀具状态监测中,多源传感器通过各自的物理响应机制提供互补信息,共同支撑刀具状态的精准识别。表1总结了常用于该领域的主要传感器类型及其性能特点。切削力是反映刀具状态变化最为敏感的物理量之一。其分量(如轴向力、径向力与扭矩)随刀具磨损程度呈现显著变化。例如,Rizal等^[23]观察到铣削过程中切削

力幅值随磨损加剧而明显升高;Kang等^[24]发现切削力系数理论上可作为监测刀具刃口状态的有效指标,随着切削刃因磨损逐渐变钝,切削力系数值呈上升趋势。振动信号在明显刀具磨损时表现出显著的时域与频域特征,但对早期微小磨损变化的识别能力有限,且易受加工噪声影响^[25]。声发射传感器通过捕捉切削过程产生的高频弹性波来反映加工过程刀具的微小裂纹产生及扩展^[26]。声发射信号常与振动联合使用以提升识别准确性^[19],但需辅以有效的噪声抑制策略。主轴电流与功率提供切削载荷的宏观趋势信息。虽然其灵敏度和实时性通常低于振动类信号^[18],但对异常加工状态(如崩刃、严重磨损)具有相对稳定的指示作用。温度传感器则主要揭示切削区热状态与冷却效果,其测量精度易受切屑、冷却液与振动等环境干扰^[19]。视觉/图像方法可直接获得刀具几何与磨损形貌,适用于定量评估,但多限于离线、需停机且易受遮挡与照明影响^[15]。综上,合理融合上述传感器输出能够在保留各自优势的同时补偿单一通道的缺陷,从而提升刀具状态监测的整体性能。

表1 不同传感器类型的特点对比

Table 1 Comparison of the characteristics for different sensor types

| 传感器类型 | 反映信息 | 测量信息 | 优点 | 局限性 | 应用方式 |
|----------|---------------------------|-----------------------|------------------------|-----------------------------|--------|
| 切削力传感器 | 切削过程中的力学作用 | 三轴切削力、扭矩 | 对磨损变化最敏感,直接反映切削状态 | 需要高精度安装与标定,可能改变系统动力学 | 在线 |
| 振动传感器 | 机械/结构振动状态 | 三轴加速度(振动) | 对异常状态敏感,安装简便 | 对早期磨损敏感度一般,易受外界干扰 | 在线 |
| 声发射传感器 | 高频应力波、微破裂/摩擦等事件 | 高频信号幅值、能量等 | 响应快,对崩刃/突变很敏感,与振动互补效果好 | 对耦合与环境噪声敏感;需高带宽采样/前置放大 | 在线 |
| 电流/功率传感器 | 用主轴电流/功率变化间接反映切削力与负载变化 | 主轴电流、功率等 | 安装非侵入,系统级容易获取 | 对小磨损/轻载分辨率低,实时性有限 | 在线 |
| 温度传感器 | 刀具或切削区域温度、温度变化反映切削性能与冷却效果 | 接触温度(热电偶)、温度分布(红外传感器) | 直观反映热负荷与冷却效果 | 受切屑、冷却液等影响大,接触式影响工况 | 在线/半在线 |
| 视觉/图像传感器 | 刀具几何与磨损形貌 | 磨损带宽度/面积、崩刃与缺口等 | 直观、可定量;可识别形貌异常 | 多用于离线/需停机;易受切屑、光照、液体干扰;成本较高 | 离线为主 |

2) 多传感器的集成方式

多传感器融合系统的集成方式直接关系到刀具状态监测的信号获取效率与系统稳定性,主要可分为外部安装与智能刀柄集成两类。

外部安装方式将各类传感器固定于主轴箱体、工件、工作台等位置,通过前端放大、数据采集模块(如测力计配套系统、数据采集与转换设备或定制采集板)获取信号,并利用数控代码触发或统一时钟对通道进行时间对

齐,以减少因加工参数变化导致的时序错位与数据融合干扰^[11]。例如,Gomes等^[27]将加速度传感器与麦克风分别固定于工件与机床工作台附近,并连接至信号转换设备及采集系统以获取多模态数据,所构建的融合系统在刀具磨损分类中达到97.54%的准确率。Wei等^[28]在三坐标数控铣床上分别布设力、振动及声发射传感器,同时使用工业相机采集刀具磨损图像,如图1所示。以后刀面磨损宽度(flank wear width, VB)为标签,结合3类

传感器数据特征,构建了去噪与在线监测模型,预测准确率达 95.51%。然而,外部安装方式存在安装复杂、侵入性强等问题,如测力计在更换工件时需重复调整;加速度计因离切削区较远,信号易衰减并受噪声干扰,影响感知精度。此外,不同零件加工还需频繁更换安装位置,通用性和灵活性较差。因此,研究者逐渐关注将多传感器集成于刀柄/刀具本体的智能刀柄方案^[29]。




图 1 基于外部安装的多传感器刀具磨损测量系统^[28]

Fig. 1 Externally mounted multi-sensor tool wear monitoring system

智能刀柄将切削力、扭矩与振动等传感器集成到刀具系统内部,实现靠近切削区的多源信号同步感知。此类系统通常配备内置电源(如锂电池),并通过无线或有线(如导电滑环)方式连续传输信号。靠近加工界面带来的高信噪比与快速响应使其易于迁移至不同机床并减少对加工过程的干扰。Xie 等^[14]开发的无线多传感器智能刀柄(图 2)即可非侵入性地同时测量多维切削力、扭矩与振动,有效克服了传统外部方案中系统复杂、信号不同步及对加工过程干扰等问题,刀具状态识别平均准确率可达 95%。除力与振动传感器外,Zhang 等^[30]还将温度传感器集成至智能刀柄中。与现有测力计相比,该方案在加工数据采集方面具有更高精度,相对偏差 $<1.5\%$,并在铣削温度与振动信号采集中表现出良好的重复性。




图 2 多传感器集成智能刀柄^[14]

Fig. 2 Multi-sensor integrated smart toolholder

不过智能刀柄也存在挑战,例如空载或低载工况下噪声较大、振动信号易受刀体自身模态和安装松动影响等,这些因素会制约其实用性。

1.2 多源信号融合技术

在复杂加工环境中,刀具失效机理多样且刀具状态随工况不断演化,导致监测信号普遍表现出非线性、时变性与高度不确定性。多源信号融合技术通过整合来自多种传感器的异构信息,并辅以智能算法进行协同分析,能够显著提高监测系统的鲁棒性与诊断精度。按信息处理层次划分,多源信号融合通常分为数据级融合、特征级融合和决策级融合,这 3 类方法共同构成了实现高可靠性刀具状态监测的系统化技术框架,如图 3 所示^[31-32]。表 2 总结对比了 3 类信号融合方法的特点。

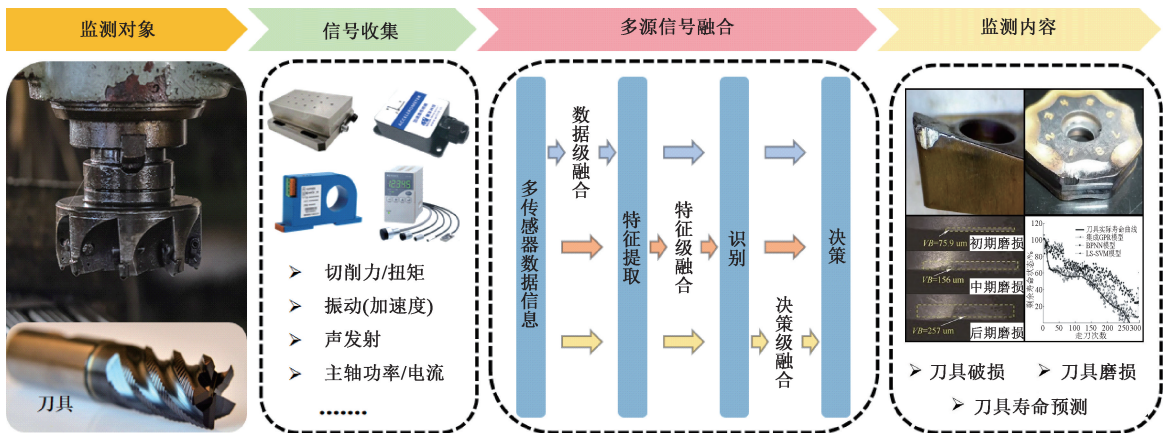


图 3 多源信号融合架构^[31-32]

Fig. 3 Multi-source signal fusion architecture

表 2 不同多源信号融合技术对比

Table 2 Comparison of different multi-source signal fusion techniques

| 融合类型 | 核心思路 | 优点 | 不足 | 适用场景 |
|-------|------------|-------------------|--------------------|--------------|
| 数据级融合 | 原始信号直接融合 | 信息最完整;实时性与状态估计精度高 | 易受噪声干扰;同步要求高;计算量大 | 多通道信号实时监测 |
| 特征级融合 | 提取特征后再融合 | 应用最广;互补性强;精度与鲁棒性高 | 传统方法依赖人工经验;特征构造有限 | 复杂工况下状态识别与预测 |
| 决策级融合 | 多分类器结果联合判定 | 处理不确定性好;冲突信息可协调 | 性能依赖局部决策质量;冲突大时受影响 | 多状态、异构决策整合 |

1) 数据级融合

数据级融合是指在特征提取或决策之前,直接对来自多种传感器的原始或经最小预处理的信号进行处理与融合,确保不同来源信号的在时间上和空间上的一致性,从而得到统一的多通道数据供后续分析或端到端模型使用。

数据级融合最常见的实现方式是直接通道拼接,即将多个传感器的时序样本沿通道维度堆叠,形成多通道输入窗,便于直接送入端到端网络进行处理。例如, Dong 等^[33]针对每次切削事件从多个传感器截取原始时序点,并在通道维直接堆叠形成多通道样本矩阵,用于数据级融合输出。Kou 等^[34]利用格拉姆角场方法,将振动和电流信号转换为二维图像,实现不同模态信号的联合表示。类似地,Zangane 等^[35]将多通道声发射信号按时间顺序分段堆叠成二维图像,随后送入卷积网络进行状态分类。

为实现对原始多源信号的递推加工状态估计,并有效抑制噪声与不确定性,数据级融合中通常会采用各种滤波算法,典型算法包括卡尔曼滤波、粒子滤波和贝叶斯滤波等。卡尔曼滤波通过状态空间模型和卡尔曼增益递推更新来减小测量误差和过程噪声,从而提升状态估计的精度与可靠性,尤其适合融合高采样率与低采样率信号。Shi 等^[36]利用卡尔曼滤波融合多个加速度传感器的原始振动信号,实现统一的振动状态估计;Mosallaei 等^[37]则基于状态向量融合的分散式扩展卡尔曼滤波器,在同步与异步多传感器动态系统中实时解决数据融合问题,从而优化状态估计效果。相比之下,粒子滤波基于蒙特卡洛方法,用随机粒子群对后验概率进行近似,更适用于非线性、非高斯及多模态场景,能够在突发或复杂工况下更准确地跟踪工具状态。例如,Orton 等^[38]利用粒子滤波直接融合异步的原始振动与声发射信号,有效应对通信延迟下的数据级融合问题。此外,贝叶斯滤波也是数据级融合中的常见算法,核心思想是通过贝叶斯定理将先验信息与观测数据结合,递推更新状态的后验概率分布。在基于时序信号的数据级融合中,贝叶斯滤波能

够直接联合多源原始信号,同时量化不确定性,并可结合自适应误差机制提升估计精度。

2) 特征级融合

特征级融合是刀具状态监测领域应用最为广泛的多源信号融合策略。其基本思想是从多个传感器获取的异构或同构信号中提取特征,并在特征层面进行整合与处理,以构建更具代表性和判别力的特征向量供后续模型使用。该方法的核心在于挖掘多源信号间的互补性与协同性,从而显著提升监测模型的精度与鲁棒性。

传统特征融合方法主要依赖人工特征提取与特征工程。这类方法首先从多源信号中提取如均值、均方根、标准差、偏度、峭度、峰值、波形因子、脉冲因子等时域特征,功率谱均值、频率重心、均方频率等频域特征,以及小波包能量等时频域特征。在此基础上,通过相关性分析、互主成分分析等方法对特征进行筛选与降维,以剔除冗余或低敏感性特征,从而简化模型结构并提高效率。随后,将筛选后的特征向量直接拼接输入预测模型。例如,曾浩等^[39]在铣削刀具磨损预测中,从振动和切削力信号中提取绝对均值、峰值等 11 个时域特征,重心频率、均方频率等 4 个频域特征,以及 3 层小波分解后得到的能量特征,每组信号共计 144 个特征。这些特征经过斯皮尔曼和最大互信息相关系数分析筛选后,直接拼接成一个特征向量实现特征级数据融合,从而显著提升了刀具磨损预测模型的精度。张曦等^[40]在刀具破损监测中融合主轴电流信号的时域(如平均值、峰峰值、方差等 9 个特征)、频域(如重心频率、均方频率等 5 个特征)和时频域特征,利用改进的麻雀搜索算法优化反向传播(back propagation, BP)神经网络,有效增强了模型的分类能力。此外,李雪冰^[41]提出基于雷达图的特征融合方式,将多个敏感特征映射为多边形的面积与周长,以二维指标表征磨损演化趋势。这种方法在降低特征维度的同时保留了重要的特征信息,为复杂多源特征的直观表示提供了新的思路。可以看出,传统特征融合方法具有实现简便、可解释性强的优势,但其性能往往受限于人工特征提取的经验依赖与特征构造的有限性。

与此相比,基于深度学习的特征融合方法能够从原始信号中自动提取高层次抽象特征,有效减少信息丢失并避免对人工经验的依赖^[42],尤其适用于大规模、多维度、复杂工况下的监测任务。其中,卷积神经网络(convolutional neural network, CNN)能够捕捉多源信号的空间特征,特别适用于处理图像输入信号,如曹大理等^[43]将振动、力、声发射等原始数字信号视为一维图像输入进行自适应特征提取,有效实现了刀具磨损的预测和状态识别。循环神经网络(recurrent neural network, RNN)及其变体在建模时间序列和捕捉长期依赖关系方面具有优势,能够融合不同传感器在时间维度上的动态关联。为兼顾空间与时间特性,学者们常将CNN与RNN相结合,构建混合模型以实现更全面的特征提取与融合。例如,Lei等^[6]通过CNN提取空间特征,再结合双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)捕捉时间依赖性,并利用全连接层实现深度集成,从而显著提高了预测准确性和鲁棒性。近年来,注意力机制也逐渐被引入特征级融合研究中。该机制通过对不同通道与时间点特征赋予差异化权重,将计算资源集中于更关键的信息,能够有效筛选磨损敏感特征并抑制冗余信息。Wei等^[44]提出并行CNN结构,并在特征提取过程中引入通道-空间注意力机制,不仅增强了模型对磨损敏感特征的辨识能力,还缓解了过渡阶段状态特征模糊的问题,提高了训练稳定性与识别精度。

3) 决策级融合

决策级融合是指在各传感器生成局部决策后,对这些结果进行联合处理以获得最终判定。决策级融合核心是如何在存在不确定性与冲突的情况下,形成全局最优的加工状态判别。根据对不确定性的建模方式,决策级融合方法可大致分为基于概率和非概率不确定性的融合方法两类。

典型的概率融合算法包括贝叶斯网络(Bayesian network, BN)及其扩展的动态贝叶斯网络,它们通过构建条件概率模型描述传感器特征与加工状态之间的依赖关系,并利用后验概率更新实现多源局部判决的统一融合。He等^[45]利用动态BN概率推理框架,在决策级实现了多传感器信息的深度融合。这为高效计算跨时间步的多传感器状态联合概率提供了基础,并支撑了全局最优决策。同样,Dong等^[46]将多传感器提取的健康特征作为观测输入,通过状态转移与条件概率建模加工状态的动态演化,在决策级融合中将各传感器局部证据统一推理,从而生成刀具健康状态的全局判定。此外,其他概率类方法还包括隐马尔可夫模型(hidden Markov model, HMM)、朴素贝叶斯和条件随机场等。

基于非概率不确定性的融合方法将传感器对目标状态的不确定性度量(如隶属度、可能性或基本概率分配)

转化为可组合的数学表达,并通过特定的组合规则将多源局部证据整合为全局决策。典型代表是证据理论框架,核心机制是将每个传感器输出映射为基本概率分配(basic probability assignment, BPA)。BPA允许对单个状态或状态集合赋予支持度,从而在统一数学框架下同时表达部分支持、信息不完整性及证据冲突。Hui等^[47]利用Dempster-Shafer(D-S)证据理论将多源冲突决策映射为BPA并进行融合,有效解决局部判决间的矛盾与不确定性,从而显著提升多状态监测的决策准确性与可靠性。类似地,Koksalimis等^[48]提出了基于D-S理论的大规模群体决策方法,结合传感器的主客观权重,实现了多源信息的有效整合。

模糊理论是另一类常见的非概率融合框架,它通过隶属度刻画传感器输出的连续模糊性,并利用模糊规则或积分方法聚合多源信息以实现全局决策。与证据理论相比,模糊方法在处理连续变量和表达渐进不确定性方面更直观且计算简便。Majumder等^[49]提出基于模糊理论的决策级融合方法,利用高斯隶属度函数量化各传感器输入与目标类别的匹配程度,并通过加权平均融合生成最终决策。最近,Akhoundi等^[50]采用模糊规则将传感器实时差异及信号变化率的模糊语义转化为动态权重分配和漂移补偿,实现了基于专家经验的非线性推理,有效缓解传感器特性冲突问题。

2 多源信号融合在刀具状态监测中的应用

2.1 刀具破损

在长期加工过程中,刀具易因疲劳、磨损及切削力波动等因素发生突发性破损或崩刃。此类失效具有显著随机性,极易导致工件报废、设备损伤甚至安全事故。通过传感器实时监测加工信号并实现刀具破损或崩刃的智能预警,可显著提升刀具加工的安全性和经济性。

刀具破损作为瞬间发生的动态过程,对监测系统的响应时间提出了严格要求。切削力、声发射与主轴/驱动电流是破损监测中常用的3类信号。切削力信号的峰值与波动特征对破损识别高度敏感,信噪比高,但对传感器的安装位置和刚性要求较高;声发射信号能捕捉材料断裂时产生的瞬态弹性波,响应最快,但信号复杂,关键在于从强噪声背景中准确提取破损特征;电流信号随切削力的突变而快速波动,传感器易于安装且成本低,不干扰加工过程,是工业现场常用的破损监测测量之一。上述不同类型信号虽对破损状态足够敏感,但面对工况波动状况均存在一定的不足^[40,51-52],利用不同物理量数据特征交叉验证实现多源信号监测,可以显著提升监测的精度和鲁棒性^[53-54]。鉴于破损信号特征相对明显,阈值法仍是当前主流的监测方法,通

常利用时域统计特征(如均方根、峰值周期)或频域特征(如幅值、能量)来设定阈值,从而识别破损瞬态信号。例如,Zhang等^[55]提出七通道比切削力系数,通过解耦铣削力、主轴箱振动及驱动电流等多参数实现信息互补,定义频域幅值比作为破损特征参数,实现刀具破损状态的准确判别(图4)。Kang等^[56]提出基于主

轴振动峰值周期的崩刃检测方法,融合切削力、振动和主轴电流,并采用抗混叠滤波与自回归滤波,在不同切削速度及崩刃、沟槽磨损形态下验证了方法的普适性。然而,阈值法在应用中容易受到材料不均匀性、机床状态波动以及刀片质量差异等因素的影响,导致破损检测中存在误报和漏报,从而限制了其预测能力^[57-59]。

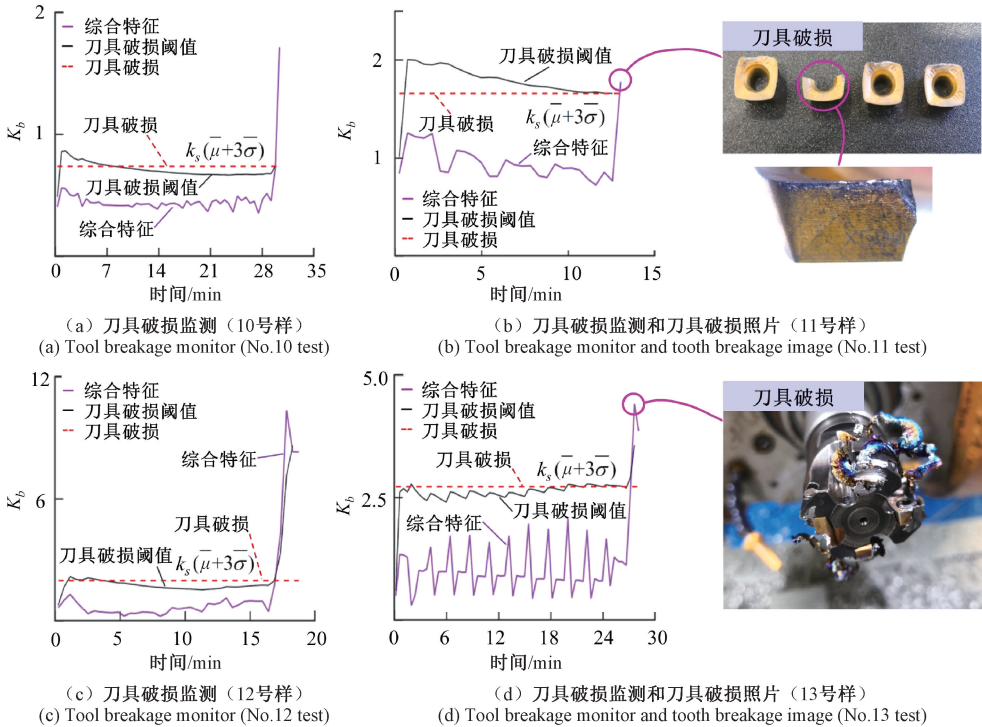


图4 信号融合在刀具破损监测的应用^[55]

Fig. 4 Application of signal fusion for tool breakage monitoring

面对变工况带来的监测挑战,机器学习和深度学习技术在破损监测中展现出强大潜力,为实现预测性维护提供了有效手段^[60-62]。例如,温坤等^[63]通过经典信号分析与小波包分解提取多源信号特征,结合相对向量机与概率神经网络算法,实现了高达97.46%的破损识别率。此外,基于深度学习的特征提取技术可直接从原始信号中挖掘刀具状态信息,如李雪冰^[41]采用梯度惩罚辅助分类生成对抗网络,从时域波形、统计特征和可视化特征多角度评估数据质量,达到97.8%的破损识别精度和5ms的实时响应。Cheng等^[64]以主轴伺服信号和切削扭矩为关键变量,通过长短期记忆神经网络(long short-term memory, LSTM)实时预测切削扭矩,结合一维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)进行破损判定,该方法在提升检测频率和减少训练数据的条件下,仍展现出优异的鲁棒性。然而,如何在样本稀缺条件下,基于深度学习技术开展高效、高精度的实时刀具破损监测研究,仍是未来面临的关键挑战。

2.2 刀具磨损

刀具磨损是数控加工中引起精度下降、零件质量恶化与效率降低的关键因素。为实现磨损监测与早期预警,研究人员通过采集加工过程中的多源信号并建立其与磨损之间的映射关系,开展磨损状态识别与量化预测。从任务形式来看,刀具磨损监测通常分为两类:一类是分类任务,用于识别当前的磨损状态或阶段^[23,65-66];另一类是回归任务,用于预测具体的磨损量(如VB)或其他连续指标^[67-69]。由于刀具磨损过程具有高度非线性、时变性与复杂耦合特征,且多数现场信号难以用物理模型精确描述,单纯依赖传统建模在精度与泛化能力上存在局限,因此人工智能技术成为解决该问题的重要途径^[70]。表3总结了近年来基于多源信号融合实现刀具磨损监测的关键技术及特点。

基于特征工程的传统机器学习方法是刀具磨损预测的主要技术路线。如图5所示^[23],不同的刀具磨损状态下,切削力、扭矩、振动、温度等信号呈现出明显的差异性。

表3 基于多源信号融合的刀具磨损识别关键技术及特点

Table 3 Key technologies and characteristics of tool wear recognition based on multi-source signal fusion

| 文献 | 多源信号类型 | 信号处理关键技术 | 信号融合模型 | 实现的功能 | 主要性能指标 |
|------|------------------|--|--|-----------|--|
| [27] | 振动、声音 | 特征提取;归一化处理;特征筛选 | 支持向量机 | 磨损状态分类 | 分类精度 97.54% |
| [14] | 三轴切削力、扭矩和切削振动 | 信号采集转换、特征提取、信号同步 | 隐马尔可夫模型 | 磨损状态分类 | 平均准确率 95% |
| [71] | 切削力、振动和切削声音 | 时域、频域和时频域特征提取;基于信息测度的特征选择方法进行特征降维 | 多分类支持向量机 | 磨损状态分类 | 整体分类精度 96.7% |
| [65] | 三轴切削力、扭矩和三轴振动 | 不同尺度卷积核自动提取特征并融合 | 多尺度宽一维卷积残差网络 | 磨损状态分类 | 识别精度 97.5% |
| [44] | 三轴切削力与振动信息 | 连续小波变换获得时频图像;CNN 并行结构提取并融合特征 | 多维注意力机制的卷积神经网络模型 | 磨损状态分类 | 综合识别精度 98.2% |
| [72] | 声发射、振动、功率 | 时域、频域和时频域特征提取;皮尔逊相关系数特征筛选;主成分分析特征降维 | BP 神经网络和 D-S 证据理论相结合的 BP 神经网络-D/S 模型 | 磨损状态分类 | 识别准确率 100% |
| [15] | 三轴振动、功率、数控系统参数 | 同步信号采集;归一化融合;信号切割;皮尔逊相关系数特征筛选降维 | 1D-CNN | 磨损状态分类 | 平均识别精度 99.81% |
| [73] | 图像、切削力和振动 | 图像数据提取刀具最大 VB 值作为磨损值标签;传感器数据提取时域、频域和时频域特征,最大信息系数方法降维 | 多核加权高斯过程回归模型 | 磨损状态分类与预测 | MAE :0.005 3 mm $RMSE$:0.008 1 mm R^2 :0.986 1 |
| [24] | 功率、振动 | 功率信号中获取切削力系数作为可解释的核心特征;从主轴振动信号中提取时域、频域和时频域特征 | 注意力机制增强门控循环单元(gated recurrent unit, GRU)网络 | 磨损预测 | $RMSE$:12.02 μm MAE :6.74 μm R^2 :0.969 |
| [20] | 三轴切削力、三轴振动和声发射 | 时域、频域特征提取,小波包分解提取频带能量值;归一化处理 | 门控循环单元 | 磨损预测 | MAE :4.632 $\times 10^{-3}$ mm $RMSE$:9.654 $\times 10^{-3}$ mm |
| [74] | 切削力、振动 | 信号截断、去噪;归一化;并行 CNN 层自动提取与组合特征 | 注意力机制卷积神经网络 | 磨损预测 | MAE :9.86 μm $RMSE$:14.11 μm R^2 :0.98 |
| [6] | 三轴切削力、三轴振动、声发射 | 去噪、降采样、标准化;模型自动提取特征 | 深度卷积神经网络-多通道双向长短期记忆网络模型 | 磨损预测 | $MAPE$ 最低为 3.04% |
| [67] | 三轴振动、电流和声音信号 | 时域、频域特征提取;皮尔逊相关系数筛选特征 | 基于时间-空间注意力机制的 CNN-LSTM 模型 | 磨损预测 | 相关因子:0.972 |
| [75] | 切削力、三轴振动与声发射信号 | 时域、频域和时频域特征提取;相关性分析特征降维 | GSA 优化的 BP 神经网络模型 | 磨损预测 | 平均预测误差为 2.73% |
| [76] | 三轴振动、切削力和声音信号 | 小波阈值降噪、降采样、Z-score 标准化处理;自动提取空间与时序特征 | 改进 CNN-BiLSTM 模型 | 磨损预测 | 3 个刀具测试集的 $RMSE$ 值分别为 0.012 0 mm、0.008 6 mm、0.009 2 mm |
| [3] | 三轴切削力、三轴振动和声发射信号 | 统计特征提取;特征列平滑处理 | 堆叠集成机制,融合了 ANN、随机森林和 XGBoost | 磨损预测 | R^2 :0.955 $RMSE$:58.237 μm |

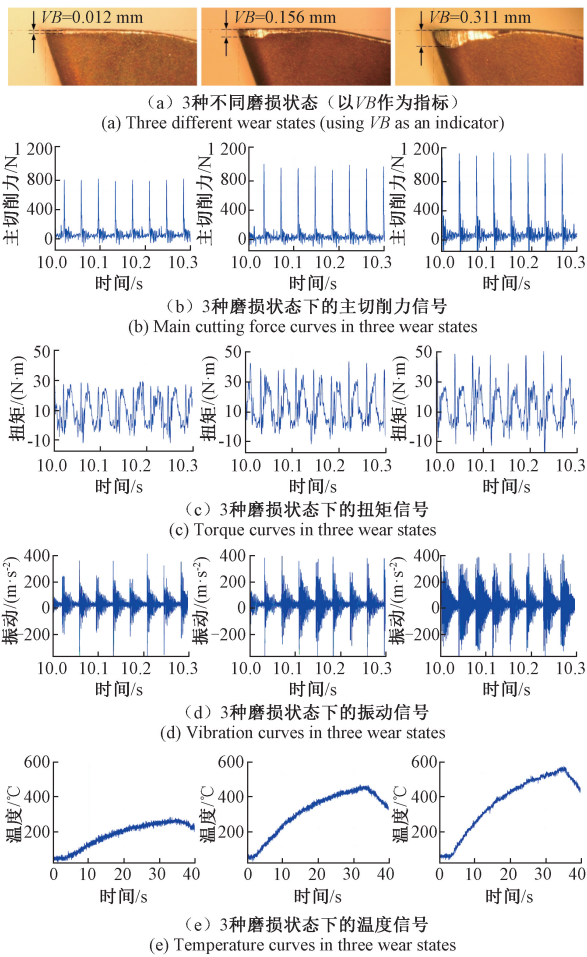



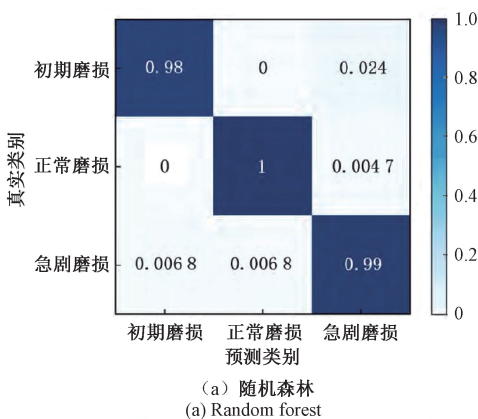
图 5 铣削过程中刀具的不同磨损状态及对应的信号变化^[23]

Fig. 5 Different wear states of tools during milling and corresponding signal curves

采用传统特征融合方法,从多源信号中提取代表性特征,并输入到分类或回归模型中,就能够在不同程度上实现磨损识别与预测。典型模型包括支持向量机 (support vector machine, SVM)^[68,71]、人工神经网络 (artificial neural network, ANN)^[77]、高斯过程回归 (gaussian process regression, GPR)^[78] 和 HMM^[14]。这些模型结构明确、计

算复杂度较低,在小样本条件下仍能保持较好拟合性,因此在早期研究中广泛应用。为提升模型的预测能力,一些研究进一步引入了优化算法以增强参数学习过程的有效性。例如, Meng 等^[75] 利用引力搜索算法 (gravitational search algorithm, GSA) 优化反向传播神经网络的权重与阈值, Huang 等^[79] 采用粒子群优化对支持向量回归模型进行参数调优,均在一定程度上提高了模型性能。此外,遗传算法被用于 GPR 模型的超参数选择,有效解决 GPR 在传统共轭梯度算法训练上易受初始值影响并陷入局部最优的问题^[73]。部分研究还探索了马哈拉诺比斯-田口系统^[23] 等方法以实现磨损状态的分类与检测。Gomes 等^[27] 融合振动与声信号,采用递归特征消除筛选最相关特征组合作为 SVM 输入,并通过网格搜索优化超参数与核函数,实现了高精度的磨损状态分类。

凭借对大规模、复杂多源信号的建模能力以及端到端的自动特征提取优势,深度学习已在刀具磨损监测研究中得到广泛应用。例如,尹晨等^[15] 基于 1D-CNN 建立诊断模型,在刀具磨损识别中实现了 99.81% 的准确率,计算时间仅为 22.98 ms,显著优于随机森林、SVM 与 BP 神经网络等传统机器学习模型 (图 6)。Zhou 等^[80] 则采用 BiLSTM 模型,捕捉序列信息中的前向与后向依赖关系,从而建立了深度融合特征与刀具磨损渐进过程之间的关联,实现了高精度预测。在多模型融合方面,刘会永等^[76] 提出的 CNN-BiLSTM 混合架构结合了局部表示与双向时间信息,有效提升了磨损识别能力并简化了监测流程,而 Xu 等^[81] 进一步引入图卷积网络 (graph convolutional network, GCN), 构建 CNN-BiLSTM-GCN 模型以建模传感器信号间层级关系,从而增强了多源信息的联合表示。进一步的研究还尝试将自注意力机制与卷积特征及全局优化 (如 Transformer-CNN 与灰狼优化结合) 整合,提升复杂工况下的适应性^[82]。除此之外,集成学习思路也被应用,例如王润琼等^[69] 将 AdaBoost 与 GRU 组合,构建多模型框架提升了整体鲁棒性与预测精度。



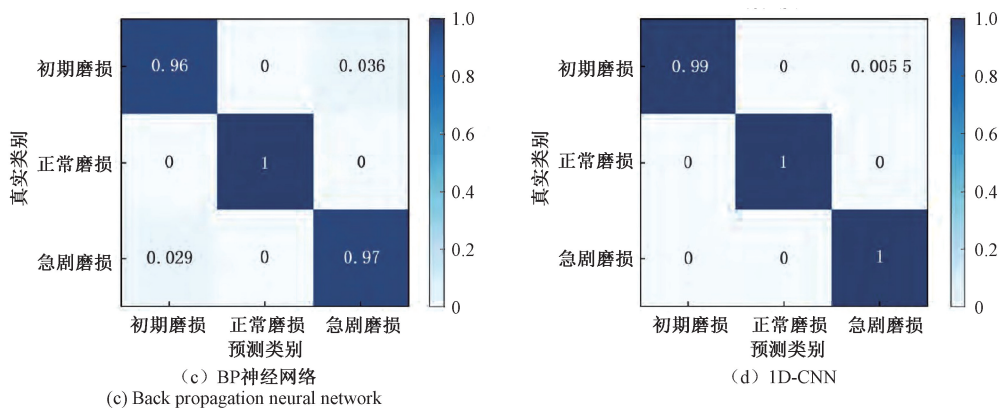
图 6 不同模型刀具磨损分类的混淆矩阵^[15]

Fig. 6 Confusion matrix for classification of tool wear for different models

深度学习虽在刀具磨损预测中取得显著效果,但其“黑箱”特性限制了工程部署的信任度,因此模型可解释性正逐渐受到重视。注意力机制是提升可解释性的有效手段。Xu 等^[83]通过为不同特征图赋权,突出对预测有用的信号并抑制无关信息,从而在提高预测精度的同时揭示了模型关注的关键特征。Wang 等^[84]在解码器中引入注意力,自适应放大与磨损相关的表示并抑制干扰,既增强了编码器的有用表征能力,也提供了直观的解释线索。此外,通过将切削力模型、电流-功率传递关系或振动响应规律等物理先验嵌入深度学习模型,不仅提升了预测精度,还增强了结果的物理一致性与工程适用性。例如,Kang 等^[24]将由功率信号导出的切削力系数与多维统计特征共同作为模型输入,实现了符合物理规律的状态识别并提高了对异常的敏感性。

2.3 寿命预测

为保障加工质量与系统可靠性,准确预测刀具剩余使用寿命(remaining useful life, RUL)是实现临界失效前精准更换的关键。不同于刀具磨损监测,RUL 预测主要目标是通过整合多源信号数据,量化预测刀具从当前状态到其失效点(寿命终点)的剩余可用寿命,从而能最大限度减少停机时间并显著降低生产成本。传统 RUL 预测方法通常基于物理模型来描述刀具退化过程,例如 Taylor 刀具寿命方程、Paris 裂纹扩展模型、Forman 扩展模型等^[85-87]。这些模型往往难以完全理解复杂机械系统失效过程,因此在工业应用中受限。同时,大多数物理模型中的系数难以实时更新,降低了其在实际 RUL 预测任务中的灵活性。概率模型方法在 RUL 预测中同样应用广泛。Han 等^[88]提出了一种基于分层狄利克雷过程-隐马尔可夫模型的刀具磨损估计和寿命预测方法,模型预测准确率可达到 80% 以上。Sun 等^[89]提出了一种用于 RUL 预测的新型指数模型。它结合了贝叶斯更新和期望最大化算法进行参数估计,并使用粒子滤波进行状态估

计。研究表明该方法特别适用于系统退化信号呈现指数趋势的 RUL 预测场景。概率模型在刀具寿命预测中较物理模型具有可量化不确定性、依赖领域知识少、参数可自适应、无需大量校准等优势,适用于机理不明或难建模的复杂系统。但概率模型依赖特定退化假设,且对复杂非线性过程适应性不足。

然而,无论是物理模型还是概率模型,在实际工业数据分析中仍面临多重挑战。具体而言,切削过程中的快速载荷波动与强烈的机械冲击使振动与声发射信号呈现高度非平稳特性,叠加环境噪声与工艺扰动,信噪比大幅下降,显著提高了特征提取与稳健建模的难度。在数据获取层面,刀具全生命周期试验成本高昂,失效阶段数据极度稀缺,导致样本类别严重不平衡。Zhang 等^[90]在多指标生成对抗网络(multi-index generative adversarial network, MI-GAN)框架中指出,失效样本不足是工业刀具监测的主要瓶颈之一。在跨工况适应性方面,不同刀具几何、工件材料以及加工参数导致显著分布偏移,使单一工况训练的模型难以泛化,且在跨刀具、跨材料场景中易发生严重性能坍塌。Cai 等^[91]以及 Wang 等^[92]分别证实,即便微小的切削条件变化也会导致统计特征发生系统性漂移,使传统模型无法直接迁移至新工况。尽管迁移学习和域自适应方法已经用于缓解分布差异,但在跨设备、跨材料及强随机性条件下,其有效性仍受显著限制。

近年来,基于深度学习的 RUL 预测方法正逐步受到关注。例如,Huang 等^[93]融合力、震动、声发射传感器信号输入实时卷积网络(刀具预测重构时间序列卷积神经网络(reshaped time series convolutional neural network, RTSCNN)结构如图 7(a)所示),在铣削实验中较传统方法误差降低 50% 以上。An 等^[87]设计 CNN 与堆叠双向单向长短期记忆神经网络(stacked bi-directional and unidirectional LSTM, SBULSTM)混合模型处理 18 通道信

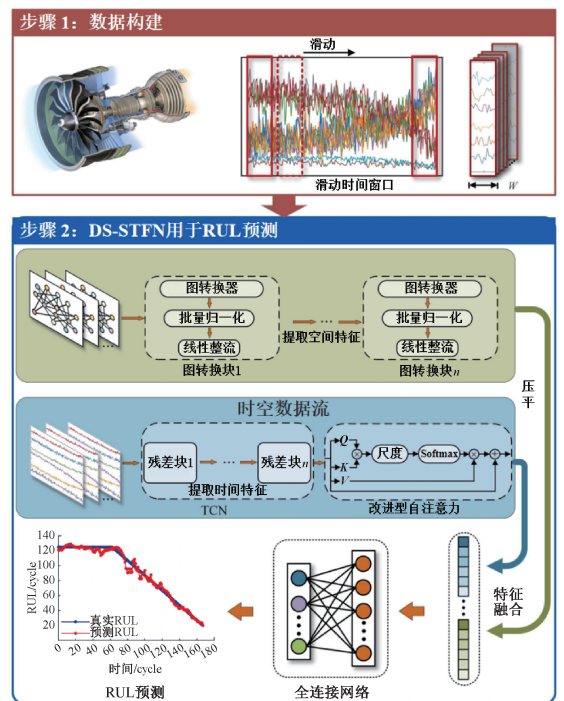
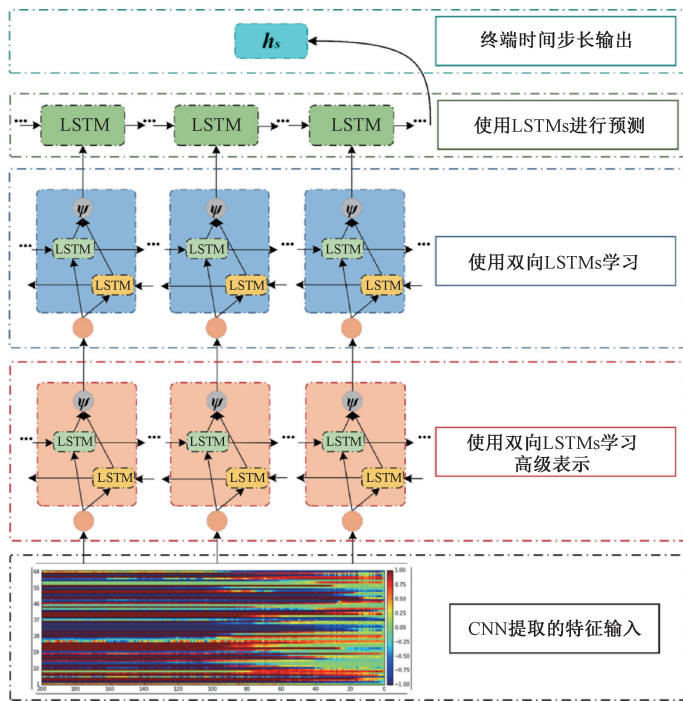
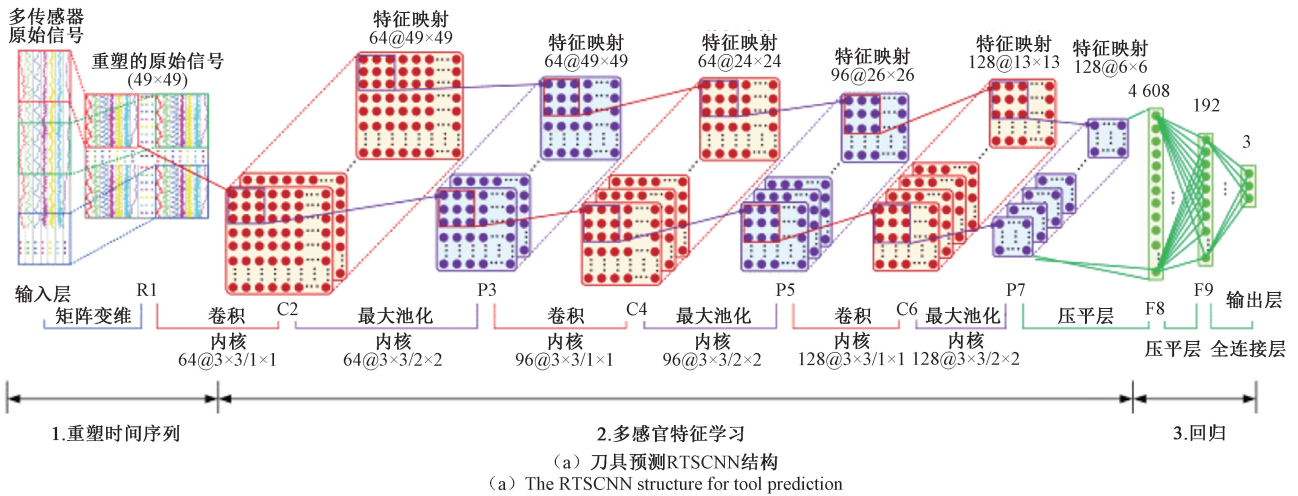


图 7 刀具状态预测框架^[87,93,95]

Fig. 7 Tool condition prediction framework

号(图 7(b)),端到端预测钛合金铣刀剩余寿命,误差较随机森林降低 77%;邱俊杰等^[94]提出多尺度注意力 BiLSTM,通过自训练权重过滤噪声,在发动机传感器数据上实现 94.47%寿命预测准确率,框架可直接迁移至刀具场景。Zhang 等^[95]提出双流时空融合网络(dual-stream spatio-temporal fusion network, DS-STFN),结合图变换器与改进自注意力机制,通过多传感器信号融合实现刀具剩余寿命预测,在 CMAPSS 和 PHM2010 数据集上性能超越现有方法,图 7(c)是 DS-STFN 的 RUL 预测框架。

3 结 论

系统梳理了基于多源信号融合的刀具状态监测研究进展,围绕刀具破损检测、磨损识别与剩余寿命预测这 3 项核心任务,归纳了从原始信号采集、特征提取到决策模型构建的研究脉络与主要技术挑战。研究表明,不同物理量(如切削力、振动、声发射与主轴电流等)具有明显互补性,合理融合可显著提高状态识别的准确性与抗干扰能力。此外,在算法层面,研究重心正由传统方法向

端到端深度学习转移,深度学习模型在复杂工况下展现出更强的特征学习与判别能力,但同时也对样本规模、可解释性、实时部署能力及跨机床/刀具的泛化能力提出了更高要求。在硬件层面,靠近切削区的智能传感装备(如智能刀柄)为现场可靠部署提供了技术保障,但要实现工业化推广仍需传感可靠性、同步采集与系统集成等方面开展工程验证与协同攻关。为推动上述问题的解决,需针对以下3个方面展开深入研究:

1) 微型智能传感单元开发:在刀柄或近切削区嵌入微型传感器,实现振动、温度、应变等多参数的原位同步测量,从源头提升信号的完整性与可靠性。与此同时,应注重传感器小型化、低功耗与自供能设计,保证其在高速、高温及强扰动环境下的长期稳定运行;并结合多传感器协同布设与高效信号预处理,有效抑制混叠与环境噪声干扰,从而为复杂工况下的实时监测和工业化应用奠定硬件基础。

2) 智能算法优化:开发多尺度、多模态的融合方法,以增强对噪声、干扰和异步采样的适应能力。在保证精度的同时,应关注模型的实时性与计算开销,使监测与预警满足工业应用要求。此外,应探索构建基于物理机理的信号-状态映射模型,将切削力等基本规律融入特征提取和判别过程,从而增强特征选择与物理解释的一致性,避免完全依赖“黑箱”式模型。同时,结合迁移学习和联邦学习算法开展动态优化,从而实现跨刀具、跨机床的自适应调整,提升模型的泛化性能。

3) 系统集成与产业化验证:依托边缘计算与云端协同,可以实现信号的实时处理与长期数据分析,进而形成刀具全生命周期的健康评价体系,为预测性维护提供支持。与此同时,应用数字孪生技术有望结合物理仿真与实时数据,实现切削参数的动态优化和失效过程的模拟,为工艺改进提供闭环支撑。进一步,将监测系统融入工业物联网,有助于实现设备状态的互联与资源的合理调度,推动感知、决策与控制的协同运行,加快技术在智能制造中的实际应用。

参考文献

- [1] 金培健. 面向铣削加工过程的多传感智能刀柄系统设计与性能评价[D]. 济南:山东大学, 2024.
JIN P J. Design and performance evaluation of multi-sensors smart toolholder system for milling process[D]. Jinan: Shandong University, 2024.
- [2] 工业和信息化部装备工业一司. 工业和信息化部等八部门关于印发《机械工业数字化转型实施方案》的通知[EB/OL]. (2025-08-01)[2025-08-20].
Equipment Industry Department of the Ministry of Industry and Information Technology. Notice of the Ministry of Industry and Information Technology and other

eight departments on issuing the "implementation plan for digital transformation of the machinery industry"[EB/OL]. (2025-08-01)[2025-08-20].

- [3] JONES T, CAO Y. Tool wear prediction based on multisensor data fusion and machine learning[J]. The International Journal of Advanced Manufacturing Technology, 2025, 137(9/10): 5213-5225.
- [4] WU J, SU Y H, CHENG Y W, et al. Multi-sensor information fusion for remaining useful life prediction of machining tools by adaptive network based fuzzy inference system[J]. Applied Soft Computing, 2018, 68: 13-23.
- [5] 刘建春, 江俊杰, 邹朝圣. 基于机器视觉的立铣刀磨损检测方法研究[J]. 制造技术与机床, 2020(1): 136-140.
LIU J CH, JIANG J J, ZHOU CH SH. Research on wear detection method of endmill based on machine vision[J]. Manufacturing Technology & Machine Tool, 2020(1): 136-140.
- [6] LEI H Y, LI B, LIU H CH, et al. Optimizing tool wear prediction in intelligent manufacturing: A multi-sensor approach enhanced by RealNVP[J]. Measurement Science and Technology, 2024, 35(12): 1-16.
- [7] 李学军, 刘治新, 杨同光, 等. 一种可解释性空时模型的风力发电机轴承智能诊断新框架[J]. 仪器仪表学报, 2025, 46(2): 51-69.
LI X J, LIU ZH X, YANG T G, et al. A new intelligent diagnosis framework for wind power insulated bearings based on spatio-temporal models of interpretable lightweight[J]. Chinese Journal of Scientific Instrument, 2025, 46(2): 51-69.
- [8] 栾孝驰, 白天, 赵俊豪, 等. 多通道振动信号与滑油屑末信息融合的滚动轴承状态监控方法[J]. 仪器仪表学报, 2025, 46(1): 298-310.
LUAN X CH, BAI T, ZHAO J H, et al. Multi-channel vibration signal and debris particle information fusion for rolling bearing condition monitoring method [J]. Chinese Journal of Scientific Instrument, 2025, 46(1): 298-310.
- [9] 丁伊博. 基于时频分析的机床主轴状态判别与误差测量技术研究[D]. 哈尔滨: 哈尔滨工业大学, 2024.
DING Y B. Research on machine tool spindle state discrimination and error measurement technology based on time-frequency analysis[D]. Harbin: Harbin Institute of Technology, 2024.
- [10] 罗茂林, 杨松, 苏祖强, 等. 圆柱滚子轴承内外圈缺陷耦合机理建模研究[J]. 仪器仪表学报, 2024, 45(10): 26-37.
LUO M L, YANG S, SU Z Q, et al. Research on

- coupling mechanism modelling of composite inner and outer raceway defects of the cylindrical roller bearing[J]. Chinese Journal of Scientific Instrument, 2024, 45(10): 26-37.
- [11] 周文军. 基于深度学习的刀具磨损状态监测研究[D]. 绵阳: 西南科技大学, 2024.
ZHOU W J. Research on tool wear condition monitoring based on deep learning [D]. Mianyang: Southwest University of Science and Technology, 2024.
- [12] 杨程越. 基于机器学习的CFRP/TC4叠层材料钻削刀具磨损监测技术研究[D]. 沈阳: 沈阳航空航天大学, 2024.
YANG CH Y. Research on CFRP/TC4 laminated material drilling tool wear monitoring technology based on machine learning [D]. Shenyang: Shenyang Aerospace University, 2024.
- [13] 向福星, 孟博洋, 李众杰, 等. 刀具磨损状态监测综述[J/OL]. 制造技术与机床, 1-14[2025-08-20].
XIANG F X, MENG B Y, LI ZH J, et al. Overview of tool wear condition monitoring [J/OL]. Manufacturing Technology & Machine Tool, 1-14[2025-08-20].
- [14] XIE ZH Y, LU Y, CHEN X L. A multi-sensor integrated smart tool holder for cutting process monitoring[J]. The International Journal of Advanced Manufacturing Technology, 2020, 110(3/4): 853-864.
- [15] 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.
- [16] 汪鑫, 廖小平, 刘树胜, 等. 多传感器融合下多工况刀具磨损状态预测的深度森林方法研究[J]. 仪器仪表学报, 2023, 44(9): 265-274.
WANG X, LIAO X P, LIU SH SH, et al. Research on the deep forest method for tool wear state prediction under multiple working conditions with multi-sensor fusion[J]. Chinese Journal of Scientific Instrument, 2023, 44(9): 265-274.
- [17] 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.
- [18] 李亚, 黄亦翔, 赵路杰, 等. 基于t分布邻域嵌入与XGBoost的刀具多工况磨损评估[J]. 机械工程学报, 2020, 56(1): 132-140.
LI Y, HUANG Y X, ZHAO L J, et al. Multi-condition wear evaluation of tool based on t-SNE and XGBoost[J]. Journal of Mechanical Engineering, 2020, 56(1): 132-140.
- [19] NASIR V, KOOSHBAGHI M, COOL J, et al. Cutting tool temperature monitoring in circular sawing: Measurement and multi-sensor feature fusion-based prediction [J]. The International Journal of Advanced Manufacturing Technology, 2021, 112(9/10): 2413-2424.
- [20] GAO K P, XU X X, JIAO SH 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.
- [21] HUANG J SH, CHEN G J, WEI H, et al. Sensor-based intelligent tool online monitoring technology: Applications and progress [J]. Measurement Science and Technology, 2024, 35(11): 1-23.
- [22] KONG L B, PENG X, CHEN Y, et al. Multi-sensor measurement and data fusion technology for manufacturing process monitoring: A literature review [J]. International Journal of Extreme Manufacturing, 2020, 2(2): 022001.
- [23] RIZAL M, GHANI J A, NUAWI M Z, et al. Cutting tool wear classification and detection using multi-sensor signals and Mahalanobis-Taguchi system [J]. Wear, 2017, 376: 1759-1765.
- [24] KANG N SH, MA H W, FENG F, et al. A multi-sensor tool wear monitoring method based on mechanism-data fusion for industrial scenario [J]. Mechanical Systems and Signal Processing, 2025, 234: 112834.
- [25] HERRERA-GRANADOS G, MISAKA T, HERWAN J, et al. An experimental study of multi-sensor tool wear monitoring and its application to predictive maintenance [J]. The International Journal of Advanced Manufacturing Technology, 2024, 133(7/8): 3415-3433.
- [26] BHUIYAN M S H, CHOUDHURY I A, DAHARI M, et al. Application of acoustic emission sensor to investigate the frequency of tool wear and plastic deformation in tool condition monitoring [J]. Measurement, 2016, 92: 208-217.
- [27] GOMES M C, BRITO L C, DA SILVA M B, et al. Tool wear monitoring in micromilling using support vector machine with vibration and sound sensors [J]. Precision Engineering, 2021, 67: 137-151.
- [28] WEI X D, LIU X L, YUE C X, et al. A multi-sensor signals denoising framework for tool state monitoring based on UKF-CycleGAN [J]. Mechanical Systems and

- Signal Processing, 2023, 200: 110420.
- [29] AN Q L, YANG J, LI J L, et al. A state-of-the-art review on the intelligent tool holders in machining[J]. Intelligent and Sustainable Manufacturing, 2024, 1(1): 10002.
- [30] ZHANG J, KANG X ZH, YE ZH M, et al. Development and testing of a wireless smart toolholder with multi-sensor fusion[J]. Frontiers of Mechanical Engineering, 2023, 18(4): 55.
- [31] 陈小康, 涂焯, 许维东, 等. 基于 Bagging 集成高斯过程回归模型的刀具寿命预测[J]. 制造技术与机床, 2020, 12(1): 110-115, 121.
CHEN X K, TU X, XU W D, et al. Tool life prediction based on Bagging integrated Gaussian process regression model[J]. Manufacturing Technology & Machine Tools, 2020, 12(1): 110-115, 121.
- [32] 朱响, 李方春, 李俊龙, 等. 基于机理-数据融合的刀具磨损预测方法[J/OL]. 机械工程学报, 1-16[2025-08-20].
ZHU Y, LI F CH, LI J L, et al. Tool wear prediction method based on mechanism-data fusion[J/OL]. Journal of Mechanical Engineering, 1-16[2025-08-20].
- [33] DONG L, WANG CH SH, YANG G, et al. An improved ResNet-1d with channel attention for tool wear monitor in smart manufacturing[J]. Sensors, 2023, 23(3): 1240.
- [34] KOU R, LIAN SH W, XIE N, et al. Image-based tool condition monitoring based on convolution neural network in turning process [J]. The International Journal of Advanced Manufacturing Technology, 2022, 119(5/6): 3279-3291.
- [35] ZANGANE M, SHAHBAZI M, NIKNAM S A. Using deep convolutional networks combined with signal processing techniques for accurate prediction of surface quality[J]. Scientific Reports, 2025, 15(1): 7134.
- [36] SHI ZH L, DUAN J J, LI F Q. Machine tool operating vibration prediction based on multi-sensor fusion and LSTM neural network [J]. Electronics Letters, 2024, 60(22): 70100.
- [37] MOSALLAEI M, SALAHSHOOR K, BAYAT M R. Process fault detection and diagnosis by synchronous and asynchronous decentralized Kalman filtering using state-vector fusion technique[C]. 2007 International Conference on Intelligent Sensors, Sensor Networks and Information, 2007: 209-214.
- [38] ORTON M, MARRS A. Particle filters for tracking with out-of-sequence measurements[J]. IEEE Transactions on Aerospace and Electronic Systems, 2005, 41(2): 693-702.
- [39] 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.
- [40] 张曦, 肖雄, 郑文姝, 等. 基于 SSA-BP 算法的刀具破损状态在机识别技术[J]. 计量与测试技术, 2023, 50(3): 57-61, 64.
ZHANG X, XIAO X, ZHENG W N, et al. On machine recognition of tool breakage based on SSA-BP algorithm[J]. Metrology & Measurement Technique, 2023, 50(3): 57-61, 64.
- [41] 李雪冰. 铣削加工过程刀具磨损及破损状态智能监测技术研究[D]. 哈尔滨: 哈尔滨理工大学, 2023.
LI X B. Research on intelligent monitoring technology for tool wear and breakage conditions during milling process[D]. Harbin: Harbin University of Science and Technology, 2023.
- [42] 何彦, 凌俊杰, 王禹林, 等. 基于长短时记忆卷积神经网络的刀具磨损在线监测模型[J]. 中国机械工程, 2020, 31(16): 1959-1967.
HE Y, LING J J, WANG Y L, et al. In-process tool wear monitoring model based on LSTM-CNN[J]. China Mechanical Engineering, 2020, 31(16): 1959-1967.
- [43] 曹大理, 孙惠斌, 张纪锋, 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 Systems, 2020, 26(1): 74-80.
- [44] WEI P N, LI R Y, LIU X L, et al. Research on tool wear state identification method driven by multi-source information fusion and multi-dimension attention mechanism[J]. Robotics and Computer Integrated Manufacturing, 2024, 88: 102741.
- [45] HE K, ZHAO ZH ZH, JIA M P, et al. Dynamic Bayesian network-based approach by integrating sensor deployment for machining process monitoring[J]. IEEE Access, 2018, 6: 33362-33375.
- [46] DONG M, YANG ZH B. Dynamic Bayesian network based prognosis in machining processes [J]. Journal of Shanghai Jiaotong University (Science), 2008, 13(3): 318-322.
- [47] HUI K H, LIM M H, LEONG M S, et al. Dempster-Shafer evidence theory for multi-bearing faults diagnosis[J]. Engineering Applications of Artificial Inte-

- lligence, 2017, 57: 160-170.
- [48] KOKSALMIS E, KABAK Ö. Sensor fusion based on Dempster-Shafer theory of evidence using a large scale group decision making approach [J]. *International Journal of Intelligent Systems*, 2020, 35 (7): 1126-1162.
- [49] MAJUMDER S, PRATHAR D K. Multi-sensors data fusion through fuzzy clustering and predictive tools[J]. *Expert Systems with Applications*, 2018, 107: 165-172.
- [50] AKHOUNDI M A A, VALAVI E. Multi-sensor fuzzy data fusion using sensors with different characteristics [J]. *The CSI Journal on Computer Science and Engineering*, 2019, 16(2): 44-53.
- [51] XIAO ZH X, MA H F, LU Y ZH, et al. Real-time milling tool breakage monitoring based on multiscale standard deviation diversity entropy [J]. *International Journal of Mechanical Sciences*, 2023, 240: 107929.
- [52] SEVILLA-CAMACHO P Y, ROBLES-OCAMPO J B, MUÑIZ-SORIA J, et al. Tool failure detection method for high-speed milling using vibration signal and reconfigurable bandpass digital filtering[J]. *The International Journal of Advanced Manufacturing Technology*, 2015, 81(5): 1187-1194.
- [53] 陈群涛, 石新华, 邵华. 基于多传感器信息融合方法的刀具破损识别[J]. *组合机床与自动化加工技术*, 2013(10): 61-65.
CHEN Q T, SHI X H, SHAO H. Tool breakage monitoring based on information coordination from multi-sensors[J]. *Modular Machine Tool & Automatic Manufacturing Technique*, 2013(10): 61-65.
- [54] BALSAMO V, CAGGIANO A, JEMIELNIAK K, et al. Multi sensor signal processing for catastrophic tool failure detection in turning [J]. *48th CIRP International Conference on Manufacturing Systems*, 2016, 41: 939-944.
- [55] ZHANG X, GAO Y, GUO ZH CH, et al. Physical model-based tool wear and breakage monitoring in milling process[J]. *Mechanical Systems and Signal Processing*, 2023, 184: 109641.
- [56] KANG G S, KIM S G, YANG G D, et al. Tool chipping detection using peak period of spindle vibration during end-milling of inconel 718[J]. *International Journal of Precision Engineering and Manufacturing*, 2019, 20(11): 1851-1859.
- [57] PAN T H, ZHANG J, YANG L, et al. Tool breakage monitoring based on the feature fusion of spindle acceleration signal [J]. *The International Journal of Advanced Manufacturing Technology*, 2021, 117(9/10): 2973-2986.
- [58] HEINEMANN R, HINDUJA S. A new strategy for tool condition monitoring of small diameter twist drills in deep-hole drilling[J]. *International Journal of Machine Tools and Manufacture*, 2012, 52(1): 69-76.
- [59] BOURNE K A, KAPOOR S G. Process monitoring during micro-drilling via acoustic emission, ultrasonic sound, and spindle load sensors [C]. *ASME International Manufacturing Science and Engineering Conference*, 2012, 54990: 781-790.
- [60] 王向阳, 何岭松, 王平江, 等. 基于 VMD 的铣刀破损检测[J]. *振动与冲击*, 2020, 39(16): 135-140,162.
WANG X Y, HE L S, WANG P J, et al. Milling cutter breakage detection based on VMD[J]. *Journal of Vibration and Shock*, 2020, 39(16): 135-140,162.
- [61] SUN SH X, HU X F, ZHANG W J. Detection of tool breakage during milling process through acoustic emission[J]. *The International Journal of Advanced Manufacturing Technology*, 2020, 109(5/6): 1409-1418.
- [62] XIAO ZH X, MA H F, SONG Q H, et al. A novel cross-domain tool breakage monitoring method based on locality preserving joint transfer with intra-class compactness[J]. *Journal of Manufacturing Processes*, 2024, 116: 149-164.
- [63] 温坤, 张汉林, 魏东, 等. 不同信号融合的立铣刀刀具磨损状态监测方法研究[J]. *机械研究与应用*, 2017, 30(5): 127-132.
WEN K, ZHANG H L, WEI D, et al. Research on CNC milling cutter wear and breakage monitoring technology[J]. *Mechanical Research & Application*, 2017, 30(5): 127-132.
- [64] CHENG Y H, LI Y G, LI G X, et al. Tool breakage monitoring driven by the real-time predicted spindle cutting torque using spindle servo signals[J]. *Robotics and Computer-Integrated Manufacturing*, 2025, 92: 102888.
- [65] ZHANG P F, GAO D, LU Y, et al. Cutting tool wear monitoring based on a smart toolholder with embedded force and vibration sensors and an improved residual network[J]. *Measurement*, 2022, 199: 111520.
- [66] 聂鹏, 杨程越, 彭新月, 等. 采用空间和通道激励注意力机制优化 ResNet-50 的 CFRP/TC4 叠层材料钻削刀具磨损状态监测 [J]. *中国机械工程*, 2024, 35(10): 1793-1801.
NIE P, YANG CH Y, PENG X Y, et al. Tool wear condition monitoring for drilling CFRP/TC4 laminated materials using scSE optimised ResNet-50 [J]. *China Mechanical Engineering*, 2024, 35(10): 1793-1801.

- [67] FENG T T, GUO L, GAO H L, et al. A new time-space attention mechanism driven multi-feature fusion method for tool wear monitoring[J]. *The International Journal of Advanced Manufacturing Technology*, 2022, 120(7/8): 5633-5648.
- [68] MULPUR S B, THELLA B R. Multi-sensor heterogeneous data-based online tool health monitoring in milling of In718 superalloy using OGM (1, N) model and SVM [J]. *SSRN Electronic Journal*, 2022, 199: 111501.
- [69] 王润琼, 宋清华, 彭业振, 等. 基于特征自适应融合和集成学习的高性能铣削刀具状态监测[J]. *机械工程学报*, 2024, 60(1): 149-158.
WANG R Q, SONG Q H, PENG Y ZH, et al. Tool condition monitoring for high performance milling based on feature adaptive fusion and ensemble learning [J]. *Journal of Mechanical Engineering*, 2024, 60(1): 149-158.
- [70] CHENG Y N, GAI X Y, GUAN R, et al. Tool wear intelligent monitoring techniques in cutting: A review[J]. *Journal of Mechanical Science and Technology*, 2023, 37(1): 289-303.
- [71] NIU B Y, SUN J, YANG B. Multisensory based tool wear monitoring for practical applications in milling of titanium alloy[J]. *Materials Today: Proceedings*, 2020, 22: 1209-1217.
- [72] ZHUO R J, DENG ZH H, TENG H ZH, et al. The grinding wheel wear condition monitoring method based on multi-sensor information hierarchical fusion for high-speed cylindrical grinding [J]. *Advanced Engineering Informatics*, 2025, 67: 103541.
- [73] PENG R T, XIAO Z L, PENG Y H, et al. Research on multi-source information fusion tool wear monitoring based on MKW-GPR model [J]. *Measurement*, 2025, 242: 116055.
- [74] KUMAR A, VASU V. Tool wear prediction using multi-sensor data fusion and attention-based deep learning[J]. *Production Engineering*, 2025, 19: 455-471.
- [75] MENG X F, ZHANG J J, XIAO G CH, et al. Tool wear prediction in milling based on a GSA-BP model with a multisensor fusion method[J]. *The International Journal of Advanced Manufacturing Technology*, 2021, 114(11/12): 3793-3802.
- [76] 刘会永, 张松, 李剑峰, 等. 采用改进 CNN-BiLSTM 模型的刀具磨损状态监测[J]. *中国机械工程*, 2022, 33(16): 1940-1947, 1956.
LIU H Y, ZHANG S, LI J F, et al. Tool wear detection based on improved CNN-BiLSTM model [J]. *China Mechanical Engineering*, 2022, 33(16): 1940-1947, 1956.
- [77] BAGGA P J, CHAVDA B, MODI V, et al. Indirect tool wear measurement and prediction using multi-sensor data fusion and neural network during machining[J]. *Materials Today: Proceedings*, 2022, 56: 51-55.
- [78] HUANG ZH W, SHAO J J, GUO W CH, et al. Tool wear prediction based on multi-information fusion and genetic algorithm-optimized Gaussian process regression in milling[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 2516716.
- [79] HUANG ZH W, SHAO J J, GUO W CH, et al. Hybrid machine learning-enabled multi-information fusion for indirect measurement of tool flank wear in milling [J]. *Measurement*, 2023, 206: 112255.
- [80] ZHOU CH AN, ZHANG K X, XU J W, et al. Tool wear monitoring for robotic milling based on multi-dimensional stacked sparse autoencoders and bidirectional LSTM networks with singularity features [J]. *The International Journal of Advanced Manufacturing Technology*, 2025, 136(7/8): 3543-3557.
- [81] XU ZH CH, ZHANG B L, FAN L L, et al. Deep-learning-driven intelligent tool wear identification of high-precision machining with multi-scale CNN-BiLSTM-GCN[J]. *Advanced Engineering Informatics*, 2025, 65: 103234.
- [82] 赛希亚拉图, 成佳闻, 张超勇. 基于 Transformer-CNN-GWO 的多信息融合刀具磨损预测[J]. *华中科技大学学报(自然科学版)*, 2025, 53(6): 7-14.
SAIXIYALATU, CHENG J W, ZHANG CH Y. Transformer-CNN-GWO based multi-information fusion tool wear prediction [J]. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 2025, 53(6): 7-14.
- [83] XU X W, WANG J W, ZHONG B F, et al. Deep learning-based tool wear prediction and its application for machining process using multi-scale feature fusion and channel attention mechanism [J]. *Measurement*, 2021, 177: 109254.
- [84] WANG G, ZHANG F. A sequence-to-sequence model with attention and monotonicity loss for tool wear monitoring and prediction [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 3525611.
- [85] KHADKA S, RAHMAN R R A, STEPHENS G, et al. Predicting cutting tool life: Models, modelling, and monitoring [J]. *The International Journal of Advanced Manufacturing Technology*, 2025, 136(7/8): 3037-3076.

- [86] 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.
- [87] AN Q L, TAO ZH 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.
- [88] HAN D Y, YU J S, TANG D Y. An HDP-HMM based approach for tool wear estimation and tool life prediction [J]. *Quality Engineering*, 2020, 33(2): 208-220.
- [89] SUN M J, GUO K, ZHANG D SH, et al. A novel exponential model for tool remaining useful life prediction [J]. *Journal of Manufacturing Systems*, 2024, 73: 223-240.
- [90] ZHANG G K, XIAO H P, JIANG J W, et al. A multi-index generative adversarial network for tool wear detection with imbalanced data [J]. *Complexity*, 2020, 2020(1): 5831632.
- [91] CAI ZH G, LI W Y, SONG J X, et al. Tool wear state identification method with variable cutting parameters based on multi-source unsupervised domain adaptation [J]. *Sensors*, 2025, 25(6): 1742.
- [92] WANG P E, RUSSELL M. Domain adversarial transfer learning for generalized tool wear prediction [C]. *Annual Conference of the PHM Society*, 2020, 12(1): 8.
- [93] HUANG ZH W, ZHU J M, LEI J T, et al. Tool wear predicting based on multisensory raw signals fusion by reshaped time series convolutional neural network in manufacturing [J]. *IEEE Access*, 2019, 7: 178640-178651.
- [94] 邱俊杰, 郑红, 程云辉. 基于多尺度 LSTM 预测模型研究 [J]. *系统仿真学报*, 2022, 34(7): 1593-1604.
- QIU J J, ZHENG H, CHENG Y H. Research on prediction of model based on multi-scale LSTM [J].

Journal of System Simulation, 2022, 34(7): 1593-1604.

- [95] ZHANG Q, YANG P X, LIU Q. A dual-stream spatio-temporal fusion network with multi-sensor signals for remaining useful life prediction [J]. *Journal of Manufacturing Systems*, 2024, 76: 43-58.

作者简介



王松, 2025 年于西安交通大学获得博士学位, 现为西安交通大学助理教授, 主要研究方向为智能传感器技术与微纳制造。

E-mail: wangsong@xjtu.edu.cn

Wang Song received his Ph. D. degree from Xi'an Jiaotong University in 2025. He is currently an assistant professor at Xi'an Jiaotong University. His main research interests include intelligent sensor technology and micro-nano manufacturing.



王琛英 (通信作者), 2014 年于西安交通大学获得博士学位, 现为西安交通大学教授, 主要研究方向为微纳制造、计量与传感技术。

E-mail: wangchenying@xjtu.edu.cn

Wang Chenying (Corresponding author) received her Ph. D. degree from Xi'an Jiaotong University in 2014. She is currently a professor at Xi'an Jiaotong University. Her main research interests include micro-nano manufacturing, metrology, and sensing technology.



张雅馨, 2019 年于西安交通大学获得学士学位, 现为西安交通大学博士研究生, 主要研究方向为微纳制造技术。

E-mail: zhangyaxin@stu.xjtu.edu.cn

Zhang Yaxin received her B.Sc. degree from Xi'an Jiaotong University in 2019. She is currently a Ph. D. candidate at Xi'an Jiaotong University. Her main research interests include micro-nano manufacturing technology.