**引文格式：**陈志祥，张金，陶桂宝，等．物理引导深度学习的刀具磨损监测：方法、挑战与展望[J]．航空制造技术，2026，69(20)：26010008.

CHEN Zhixiang, ZHANG Jin, TAO Guibao, et al. Tool Wear Monitoring Based on Physics-Guided Deep Learning: Methods, Challenges, and Prospects[J]. Aeronautical Manufacturing Technology, 2026, 69(20): 26010008.

# 物理引导深度学习的刀具磨损监测：方法、挑战与展望

陈志祥[1,2]，张　金[1,2]，陶桂宝[1,2]，秦逢泽[1,2]，曹华军[1,2]

（1. 重庆大学机械与运载工程学院，重庆 401331；
2. 重庆大学高端装备机械传动全国重点实验室，重庆 401331）

[摘要]　刀具被誉为“机床牙齿”，其磨损状态直接影响机床加工效率和工件成型质量。基于物理模型的刀具磨损监测（Tool wear monitoring，TWM）方法受限于建模过程的理想假设，难以适应实际加工场景；基于数据模型的深度学习网络虽能学习刀具磨损过程的非线性变化，但监测精度对训练样本数量和质量高度依赖，同时受其“黑箱”特性缺乏物理透明性，使之监测结果可信度有限。因此，融合物理信息和深度学习的混合驱动方法为此提供了新的解决思路，本文从刀具退化模式和常用传感器类型出发，对刀具磨损物理建模及传感信息获取与预处理技术进行了梳理；随后，对当前基于物理引导深度学习（Physics-guided deep learning，PGDL）方法中的物理信息融合策略进行了归纳；最后，面向工程应用，对现有方法存在的挑战进行了阐明，并对未来发展方向进行了展望。

**关键词：**刀具磨损；物理引导深度学习；寿命预测；状态识别；可信加工

**中图分类号：**V2；TG71；TP183　　**文献标志码：**A　　**DOI：**10.16080/j.issn1671-833x.26010008



陈志祥

博士研究生，研究方向为切削过程智能监测与运维。

航空航天、医疗等领域的高端制造对加工精度和质量要求极高，而加工对象多为难加工材料，切削负载与热效应更强，刀具磨损更易加剧且具有不确定性。为避免因刀具过度磨损导致工件质量不佳、加工效率低等问题，对刀具磨损状态进行实时监测是至关重要的[1]。现有的刀具磨损监测（Tool wear monitoring，TWM）方法主要可分为直接监测法和间接监测法两类[2]，如图1所示。直接监测法利用光学成像、激光扫描、超声波测量等手段，通过直接量化刀具表面几何形貌变化来判断刀具磨损状态，具有精度高、直观性强等显著优势。为了满足在机无人监测需求，图像处理等技术被广泛应用在该监测方式中。例如，张松等[3]基于改进U-Net的视觉方法实现了铣刀磨损区域的像素级分割与量化。然而，这些方法在实际应用中存在各自的局限性，具体来说，基于光学视觉的方法易受切屑和切削液干扰，且通常难以满足在机实时监测需求；激光测量方法则面临设备昂贵及扫描效率低等缺陷；而超声波监测方法不仅对温度较为

**收稿日期：**2026-01-07；**退修日期：**2026-01-29；**录用日期：**2026-02-24

**基金项目：**国家重点研发计划（2022YFB3206703）；国家自然科学基金（52505542）；中国博士后科学基金面上项目（2025M781351）

**通信作者：**曹华军，教授，博士，研究方向为绿色制造战略及基础理论、数控机床绿色化及智能化、产品及制造系统碳排放核算与精益管控、智能基础零部件。

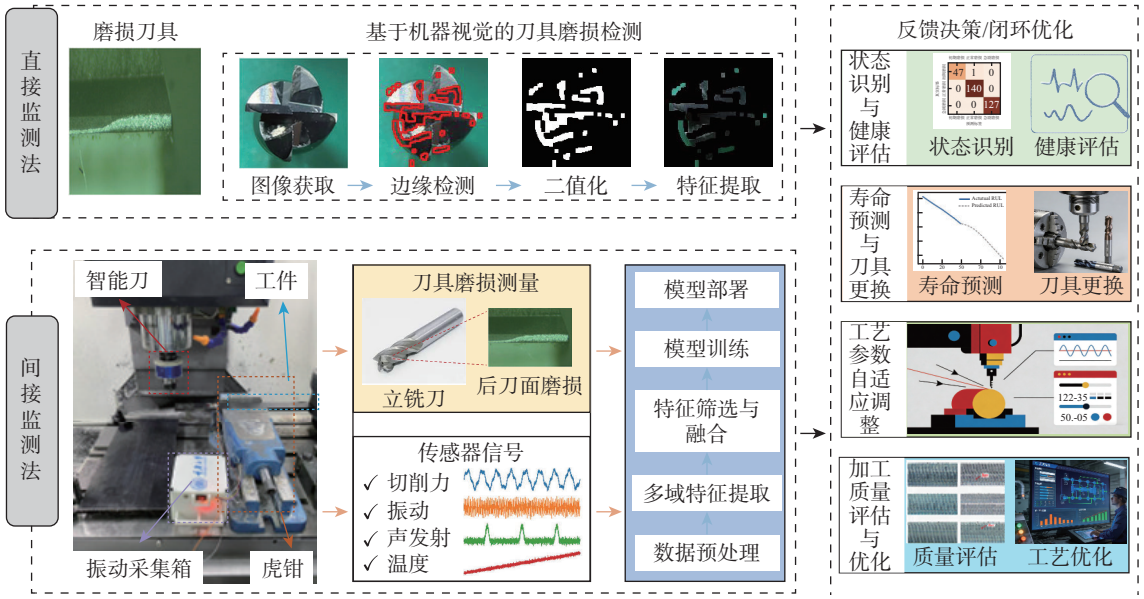



**图1 TWM框架**

**Fig.1 Framework of TWM**

敏感，且对声束耦合状态及探头安装定位精度具有极高的要求。

相比之下，间接监测法则是利用传感器采集切削加工过程中的物理信号，结合信号处理技术与模式识别算法来推断刀具磨损状态，具有易集成、实时性强等优势[4]。常用的传感器包括力、振动、声发射、温度传感器等。在早期阶段，间接检测法多聚焦于信号降噪、时域频域等数据预处理和特征提取技术，并采用支持向量机（Support vector machine, SVM）、随机森林（Random forest, RF）等传统机器学习算法建立传感信息与刀具磨损值之间的映射关系[5]。得益于计算机硬件不断的提升和人工智能算法的快速发展，基于间接监测法的TWM步入了新的发展阶段。在此期间，通过构建深层网络架构以应对复杂非线性映射成为主流，如利用卷积神经网络（Convolutional neural network, CNN）挖掘传感器信号中的局部空间关联特征及多模态信息[6–7]，及基于长短期记忆网络（Long short–term memory, LSTM）、门控循环单元（Gated recurrent unit, GRU）等时序框架捕获刀具性能退化的长期依赖关系[8–9]。与此同时，为满足硬件端部署和实时推理等需求，一些研究聚焦于结合注意力机制的轻量化网络架构[10–12]。此外，诸如Transformer[13]及新兴的Kolmogorov-Arnold网络（Kolmogorov-Arnold network, KAN）[14]等前沿模型也被引入该领域。然而，基于数据驱动的深度学习框架在模型训练阶段通常需要大量高质量的标注样本。同时，此类方法属于“黑箱”模型，监测过程缺乏物理可解释性，且难以量化决策置信度[15]，限制了其在可信加工中的进一步应用。

基于物理引导深度学习（Physics-guided deep learning, PGDL）为解决基于数据驱动的TWM方法的瓶颈提供了一种新思路，该方法通过将刀具磨损物理信息融合到神经网络架构中，使得模型在保证TWM准确性的同时符合刀具退化物理规律[16]。此外，这种数据模型和物理信息深度耦合的方法不仅降低了神经网络对训练样本量的依赖，而且赋予“黑箱”模型明确的物理一致性，从而提高了监测结果的可解释性，为可信加工提供了有力支持。

本文首先从刀具磨损基础出发，对刀具退化过程、刀具磨损物理模型、传感信号获取、预处理和特征提取技术进行简要介绍，为后续不同TWM方法分析提供基础；然后从磨损演化机理与多源感知信息出发，系统梳理现有研究中物理知识与数据驱动建模在TWM中的融合方式，重点归纳输入端、训练端与结构端的PGDL策略及其适用条件；随后对当前基于PGDL的TWM方法存在的局限性进行分析，并围绕物理先验可迁移性、跨工况泛化、可信评估与工程部署等角度对未来TWM研究进行展望；最后进行总结，给出PGDL在TWM场景下实现“精度、鲁棒性与物理一致性”协同提升的关键思路，以期为不同加工场景下的监测方案选择提供清晰的框架设计与参考依据。

## 1 刀具磨损监测基础

### 1.1 刀具退化过程

在切削过程中，受刀尖与工件间的持续相互作用，刀具逐渐产生磨损。依据磨损程度通常可分为两类，即渐进式磨损与突发性断裂。高速

切削条件下，切削刃、前刀面及侧刃往往首先发生磨损，进而形成局部缺口；随着切削继续进行，磨损程度不断加剧，最终可能导致刀具崩损或完全失效。尽管刀具磨损有多种形式，但后刀面磨损是最常见的形式，也是TWM中用于衡量刀具磨损程度的常用标准。如图2所示，根据切削刀具整个生命周期的磨损规律，典型的刀具磨损可分为3个阶段：初期磨损、正常磨损和急剧磨损。

（1）初期磨损。

由于新刀具刃口表面存在微观粗糙度，且与工件表面接触面积非常小，使得切削刃与工件表面的接触应力高度集中。因此，在初期磨损阶段，刀具表面的微观凸峰在强烈的机械摩擦作用下迅速被磨平或断裂，导致磨损量在短时间内急剧增加。以GH4169等难加工材料为例，此阶段主要以高强度的磨粒磨损和粘结磨损为主[17]。

（2）正常磨损。

经初期磨损阶段的剧烈磨合后，刀具进入相对平稳的正常磨损阶段。此时，刀具与工件之间的接触几何关系及热力学状态趋于稳定，磨损速率较低且相对恒定，磨损曲线呈现显著的近似线性增长。此外，该阶段也是刀具工作的主要阶段，为延缓磨损进程、提升刀具使用寿命，可采用强化冷却润滑与工艺辅助等策略。例如，在碳纤维增强塑料（Carbon fiber reinforced polymer, CFRP）与钛合金叠层制孔过程中，相较于液氮冷却与微量润滑，水基冷却液更好地平衡了冷却与润滑效果，进而延长刀具使用寿命[18]。此外，预应力切削可通过调控切削区应力状态抑制微观裂纹扩展，进而延缓陶瓷刀具磨损[19]。而超声辅助加工能够在钛合金铣削中降低切削力并减缓刀具磨损，配合Zr系PVD涂层协同提升加工过程中的耐磨性能[20]。图3[21]展示了该阶段刀具后刀面的典型微观形貌特征，沿切削速度方向分布的沟槽与划痕较为明显，并伴随局部凹坑，表明该阶段以磨粒磨损为主，同时存在黏着与颗粒剥落等复合磨损特征。

（3）急剧磨损。

随着切削继续进行，切削热在刀具内部不断积聚，当切削区域温度升至刀具材料发生相变或急剧软化的临界值后，与扩散、氧化、化学反应相关的磨损会显著增强。此外，随着正常磨损阶段的结束，涂层刀具表面的耐磨涂层因磨耗殆尽或剥落而失效，致使刀具基体直接暴露在高温高压的切削环境中，从而失去保护屏障，导致刀具磨损速率呈指数级急剧上升。

## 1.2 经典刀具磨损物理模型

为精确量化切削条件与磨损程度之间的关系，研究者们通过分析磨损机理或汇总试验经验，构建了一系列刀具磨损物理模型。

（1）泰勒刀具寿命方程。

泰勒刀具寿命方程是最具代表性的磨损经验模型之一，主要用于描述切削参数对刀具服役期限的影响。其标准的数学表达式为

$$v \cdot T^n = C \tag{1}$$

式中，$v$为切削速度；$T$为刀具的有效使用寿命；$n$与$C$为通过试验标定得到的经验系数，主要由刀具与工件材料及其匹配关系所决定。基于该关系式可对刀具寿命进行定量评估，因而在工艺参数选取与寿命估算中具有一定工程实用性。然而，该模型本

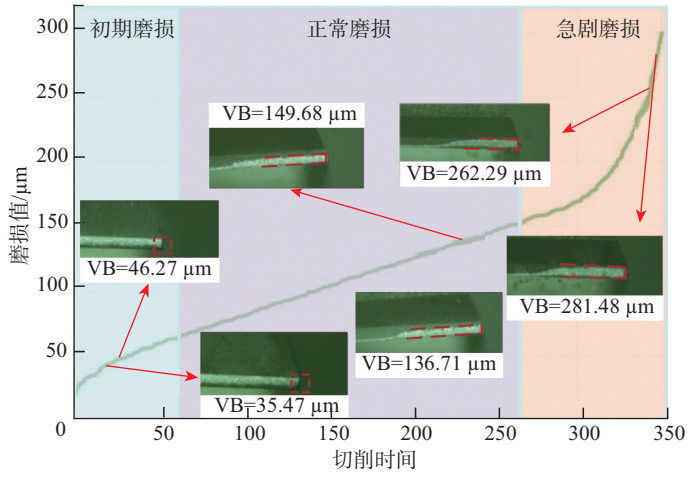



图2 刀具磨损阶段划分及磨损曲线趋势

Fig.2 Classification of tool wear stages and wear curve trends

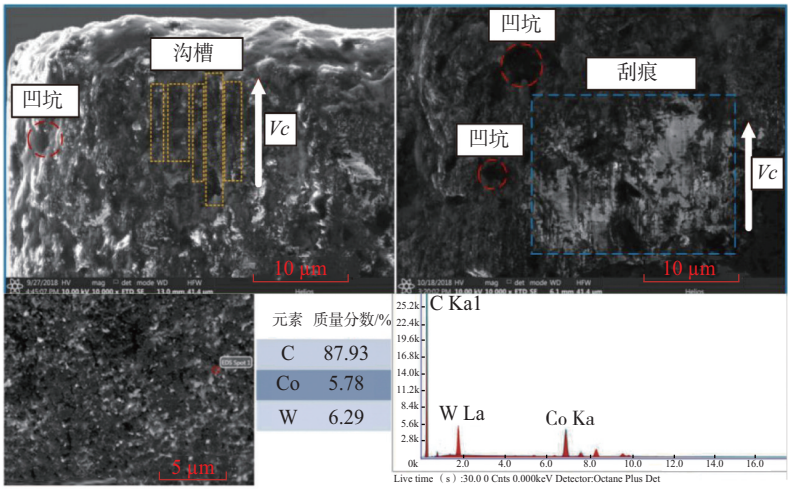



图3 刀具磨损形貌及EDS分析[21]

Fig.3 Tool wear morphology and EDS analysis[21]

质上属于离线的静态预测，难以表征刀具在实际切削过程中的实时磨损状态及其随加工条件波动而产生的动态演化特征。

(2)扩展泰勒刀具磨损模型。

为了建立刀具寿命与切削参数及时间之间的关系，设计出一些基于泰勒方程的改进的经验模型，其中最具典型的是扩展泰勒方程。

$$W=a_1\cdot v^{b_1}\cdot f^{c_1}\cdot t^{d_1} \tag{2}$$

式中，$W$为刀具平均磨损量；$f$和$t$分别为进给率和切削时间；$a_1$为与刀具类型和工件材料相关的系数；$b_1$、$c_1$、$d_1$为通过试验数据拟合确定的经验系数。

(3)非线性磨损演化模型。

然而，上述扩展模型难以精确表征刀具全寿命磨损趋势，尤其是其非线性演化特征。为了解决这一问题，通过引入对数与多项式函数拟合刀具各磨损阶段的历史数据，从而构建出能够表征刀具全寿命周期的经验模型[22]，其数学表达式为

$$W=a_2\cdot\ln(b_2\cdot t+1)+c_2\cdot t^3 \tag{3}$$

式中，$W$为刀具磨损量；$t$为切削时间；$a_2$、$b_2$和$c_2$为通过试验数据拟合确定的经验系数。该模型利用对数项描述初期磨损阶段磨损率随时间递减的趋势，并利用三次项表述急剧磨损阶段磨损率随时间加速增长的规律，从而实现了对刀具从磨合到失效完整退化过程的高精度拟合。

(4)指数型经验磨损模型。

考虑到刀具磨损过程通常可以分为3个阶段，即初期磨损、正常磨损和急剧磨损，Sipos等[23]提出了一种基于指数函数的刀具磨损经验物理模型。其中，变量$a$、$b$和$c$可以通过拟合历史数据获取。

$$W=t\cdot\exp(a_2+b_2\cdot t_2+c_2\cdot t^2) \tag{4}$$

此外，Fang等[24]采用隐式建模方式构建了刀具磨损的非线性演化模型；Yue等[25]则基于分段建模策略，以刀具磨损演化曲线为依据建立了显式函数表达式。

### 1.3 监测信号获取

不同的TWM方法所依赖的监测信号存在显著差异性。其中，直接监测法通常以图像信号为主，即通过光学设备获取刀具磨损区域图像，并利用图像处理技术识别刀具磨损状态。而间接监测法则通常借助传感器获取切削加工中的多源信号，经分析处理后间接推断出刀具磨损程度。表1展示了当前TWM任务中典型监测信号、获取方式及其对应优势与局限性。

#### 1.3.1 图像信号

图像信号因其能够直观显示磨损区域的几何形貌变化，成为TWM中最直观且精度较高的一种监测手段。然而，高质量图像往往需要停机测量。为满足实时、无人监测需求，图像信号通常需结合机器视觉技术和高速光学设备来监测刀具磨损情况。在基于图像信号的TWM系统开发方面，彭锐涛等[26]采用边缘特征提取与最小外接矩形实现侧面磨损的定量表征，用于机上检测；林苑等[27]构建了集成化在线监测系统，以支撑刀具全寿命周期管理。在算法层面，任慧等[28]利用Fisher准则实现复杂背景下磨损区域的有效分割；Makhesana等[29]对比了多种侧磨损测量方法的精度与稳定性，指出霍夫变换与像素扫描在其试验设置下表现更优；Pan等[30]则针对传统生产线设备难以改造的痛点，提出了基于自蒸馏机制的轻量化卷积神经网络，成功实现了移动检测机器人对刀具磨损状态的高效识别。然而，高速光学设备成本较高，且极易受切削液飞溅、切屑遮挡及光照条件变化等环境因素干扰，导致图像信号在复杂车间环境中的应用仍存在明显限制[31]。

#### 1.3.2 切削力信号

切削力信号能够直接反映刀具与工件在切削区域的接触载荷和能量消耗，是TWM中物理意义最直接的过程信号之一。因此，切削力信号常被广泛应用于TWM领域。在特征提取方面，Song等[32]从切削力信

**表1 TWM任务中常用传感器类型及优缺点**

**Table1 Common sensor types and their advantages and disadvantages in TWM tasks**

| 监测信号类型 | 信号采集装置 | 优势 | 局限性 |
|---|---|---|---|
| 图像信号 | 光学设备(工业高速相机、刀具磨损测量仪等) | 可直观观察磨损区域；可量化磨损几何参数 | 光学设备成本高，且在线监测易受切削液、切屑遮挡及光照影响 |
| 切削力信号 | 测力装置(测力台、测力刀柄、力传感器等) | 能够直接反映载荷变化；对几何退化高度敏感；在线测量精度高 | 装置成本高；安装受限；易受振动/噪声干扰 |
| 振动信号 | 振动传感器 | 布置灵活、成本低；对刚度退化及颤振敏感 | 信号成分复杂，易受机床背景噪声干扰，特征提取难度大 |
| 温度信号 | 薄膜热电偶、光纤辐射测温等温度传感器 | 直观反映热磨损机理(扩散/氧化)；非接触式测量对加工干扰极小 | 易受切削液和切屑影响；接触式传感器安装困难且响应延迟；难以精确获取刀尖温度 |
| 声发射信号 | 声发射传感器 | 对微裂纹、界面摩擦等微损伤更敏感 | 对高频采样/降噪要求较高；信号特性受切削路径影响较大 |

号中提取时域、频域和时频域特征并进行特征融合用于多核高斯过程回归（Gaussian process regression, GPR）训练和测试。Pan等[33]采用切削力模型从测得的切削力信号中反演切削力系数，并通过这些系数消除切削参数变化的影响，从而适用于可变参数的磨损监测。Cheng等[34]从切削力中提取多尺度归一化特征，并通过注意力机制赋予不同尺度特征权重以突出对磨损最敏感的信息。Ma等[35]强调切削力信号变化趋势与磨损演化的一致性，并将其作为深度学习网络的主要输入，以构建TWM模型。此外，为挖掘深层信息，Li [36]和Zhou [37] 等分别利用小波变换和编码技术，将周期性变化的切削力信号转变为时频图像和序列图像，以适用于计算机视觉与图像处理技术。尽管当前基于力信号的TWM已形成较为成熟的技术体系，但高精度测力设备价格昂贵，且其接触式或嵌入式的安装方式可能会降低工艺系统的刚性或限制加工空间。此外，切削力信号对于切削参数的变化极度敏感，若缺乏有效的解耦机制，极易将切削工况的改变误判为刀具磨损，因此通常需要与其他传感器信号融合使用以降低误监测率。

1.3.3 振动信号

得益于振动传感器布局灵活、成本低廉以及对工艺系统刚度退化具有高度敏感性，振动信号在TWM中得到了广泛的应用。例如，Twardowski等[38]开发了一种使用振动加速度进行铸铁铣削的机器学习模型。Bouchama等[39]利用从振动信号中提取的功率谱密度（Power spectral density, PSD）和均方根值以定量表征表面粗糙度和刀具磨损。Rmili等[40]建立了一种基于振动信号的在线辨识的自动化系统。Rahman等[41]分析了马氏体不锈钢铣削振动信号中特征频率与磨损之间的相关关系。Yang等[42]从切削振动的阻尼行为中推导出了磨损敏感指标。为了解决复杂的可变工况，Lan等[43]提出了一种基于振动主轴谱的深度迁移学习框架。此外，Wang等[44]利用振动信号结合CNN与双向LSTM（Bidirectional LSTM, BiLSTM）注意力网络实现了刀具磨损程度识别。汪进超等[45]则基于多点振动采集设计了一套适用于航空涡轮盘切割的刀具健康监测系统。尽管如此，仍需注意的是振动传感器对环境噪声较为敏感，通常需要其他传感信号融合以确保监测结果的鲁棒性。

1.3.4 温度信号

温度信号能够直接表征切削过程中的热力学状态，是当前TWM的重要信号之一。在TWM应用中，He等[46]将薄膜热电偶集成到PCBN刀尖，利用全生命周期数据和堆叠式稀疏自动编码器（Stacked sparse autoencoder, SSAE）实现变切削工况下的高鲁棒性磨损预测。同样，Li等[47]在硬车削中采用了嵌入式热电偶来量化最高温度和磨损阶段之间的相关性，并基于机器学习构建温度与磨损之间的映射关系。此外，Yin等[48]在刀具后刀面上集成了一个热电偶阵列，通过机器学习建立了多点温度场和磨损程度之间的映射。Han等[49]利用光纤多光谱辐射测温技术来捕获车削过程中的温度信号，并通过SSAE和聚类算法成功识别出刀具磨损状态。然而，由于温度传感器易受切削液和高温切屑干扰，且接触式传感器安装工艺较为复杂，因此温度信号通常作为补充信息源被用于TWM中。

1.3.5 声发射信号

声发射（Acoustic emission, AE）信号是材料局部快速变形、微裂纹萌生扩展等过程中瞬态释放能量所产生的高频弹性波信号，对于刀具刃口附近的微观损伤更为敏感，因此常被视为刀具早期磨损感知的重要信息源。鉴于实际应用中在工件上布置AE传感器可行性低的问题，Wan等[50]在主轴处安装AE传感器，并将AE传感器信号变换到频域，结果显示主轴AE的高相关特征集中在150 kHz以上。进一步地，Huang等[51]考虑到工业微铣削路径通常不是直线，路径几何变换会导致接触体积与方向变化，从而使得监测系统难以部署的问题，设计了包含直线、方形和圆形的微铣削试验，并分析对应AE能量分布，结果表明约170 kHz附近的频率特征所有路径均更具备可迁移性。Zhang等[52]在复合切削中，结合傅里叶变换（Fourier transform, FT）和小波包分析将AE能量分解为磨损等级特征以用于刀具磨损状态识别。针对刀具从正常磨损进入急剧磨损拐点难判定的问题，Maia等[53]通过构造滤波器分离来自刀具的AE成分后，采用短时傅里叶变换（Short–time Fourier transform, STFT）在时频域上分离磨损相关信号，用于识别与磨损机制相关的关键频率区间。然而，AE信号对工艺参数、切削路径、工件材料等较为敏感，导致模型在实际应用中泛化性不足。

### 1.4 数据预处理与特征提取技术

值得注意的是，尽管传感器信号变化能够反映刀具运行状态，但受传感器布置位置、信号获取环境及机床振动等因素的影响，导致获取的原始传感器信号通常包含较大干扰。针对信号采集过程中的噪声干扰问题，数据预处理技术提供了有效方案。例如，曾浩等[54]采用Hampel滤波对振动信号和力信号进行降噪处理。郭润兰等[55]采用变分模态分解（Variational mode decomposition, VMD）分解原始信号并选择最优分量信号用于刀具磨损监测。此外，常见的降噪技术还包括，Kalman滤波、小波变换、带通滤波等[56]。

需要注意的是，采集的实时传感器信号单样本包含的采样点数往往高达数万乃至数百万，直接利用

这些高维原始信号构建模型不仅会引入大量冗余信息，同时对计算机硬件算力也具有极高的要求。为构建轻量化可部署模型，特征提取技术提供了解决方案，通过对采集信号进行降维映射能够有效压缩数据长度，从而降低用于模型训练和测试的特征维度与计算负载。图4所示为刀具磨损监测框架下的典型特征提取流程，具体来说，将包含非平稳冲击的切入和切出信号截断并剔除后，进行窗口划分，计算每个窗口的时域特征（如均值、均方根值、峭度）、频域特征（如谱偏差、重心频率等）、时频域特征（如小波能量等）构成原始多域特征矩阵[57]。值得注意的是，由于传感器信号量纲和特征类型不同，提取的特征在数值量级上会存在明显差异。为避免模型更关注数值大的特征，而不是学习与刀具磨损相关信息，通常需要对提取的特征进行归一化处理，例如采用最大最小归一化、Z-Score归一化等。

由于刀具型号、工件材料、加工环境等因素的影响，原始多域特征集中往往存在冗余或无关信息，并非所有特征均能有效表征刀具磨损状态。为了避免低相关特征对模型训练的影响并降低计算量，特征筛选与特征融合技术提供了关键解决思路。具体来说，特征筛选通过量化特征与刀具磨损的相关性来筛选相关程度更高的特征。通常采用的相关性分析指标包括皮尔森相关系数、斯皮尔曼相关系数和互信息等，其数学表达式分别为

$$\mathrm{PCC}_s^i=\sum_{j=1}^{n}(\tilde{f}_s^{i,j}-\overline{\tilde{f}_s^{i}})(y^j-\bar{y})\Big/\left(\sqrt{\sum_{j=1}^{n}(\tilde{f}_s^{i,j}-\overline{\tilde{f}_s^{i}})^2}\cdot\sqrt{\sum_{j=1}^{N}(y^j-\bar{y})^2}\right) \tag{5}$$

$$\mathrm{SCC}_s^i=1-6\sum_{j=1}^{n}(R(\tilde{f}_s^{i,j})-R(y^j))^2\Big/n(n^2-1) \tag{6}$$

$$\mathrm{MI}_s^i=\sum_{f\in\tilde{f}_s^i}\sum_{w\in y}p(f,w)\log\left(\frac{p(f,w)}{p(f)p(w)}\right) \tag{7}$$

式中，$\mathrm{PCC}_s^i$、$\mathrm{SCC}_s^i$和$\mathrm{MI}_s^i$分别为第$s$个传感器提取的第$i$个特征值计算得到的皮尔森相关系数、斯皮尔曼相关系数和互信息；$\tilde{f}_s^{i,j}$和$\overline{\tilde{f}_s^{i}}$分别为该特征的第$j$个特征点及特征均值；$y^j$和$\bar{y}$分别为第$j$个特征点对应磨损值及磨损均值；$R(\cdot)$为秩；$p(f,w)$为联合概率；$p(f)$和$p(w)$为边缘概率。这3个绝对值越大，表示对应特征与刀具磨损相关性越强。基于相关性排序，可以筛选出与磨损更相关的特征，如图5所示。

除了基于相关性分析的特征筛选外，另一类常用的数据降维与增强策略是特征融合。常用的特征融合方法如主成分分析（Principal component analysis, PCA）、核主成分分析（Kernel principal component

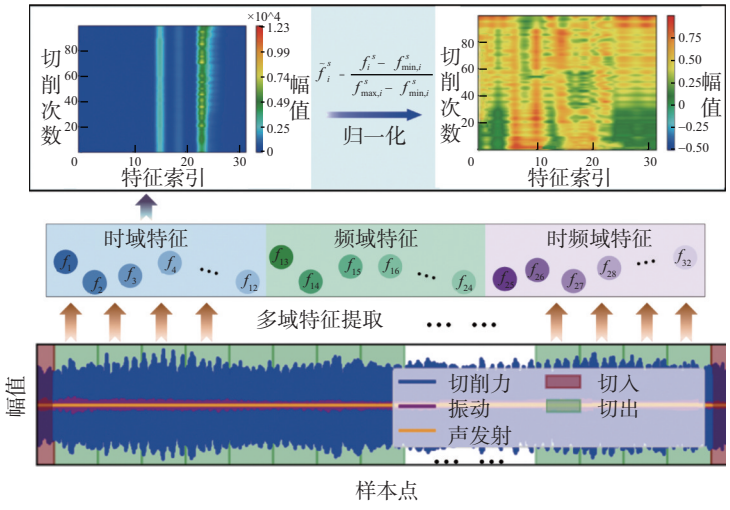



图4　典型切削信号特征提取流程

Fig.4　Typical cutting signal feature extraction process

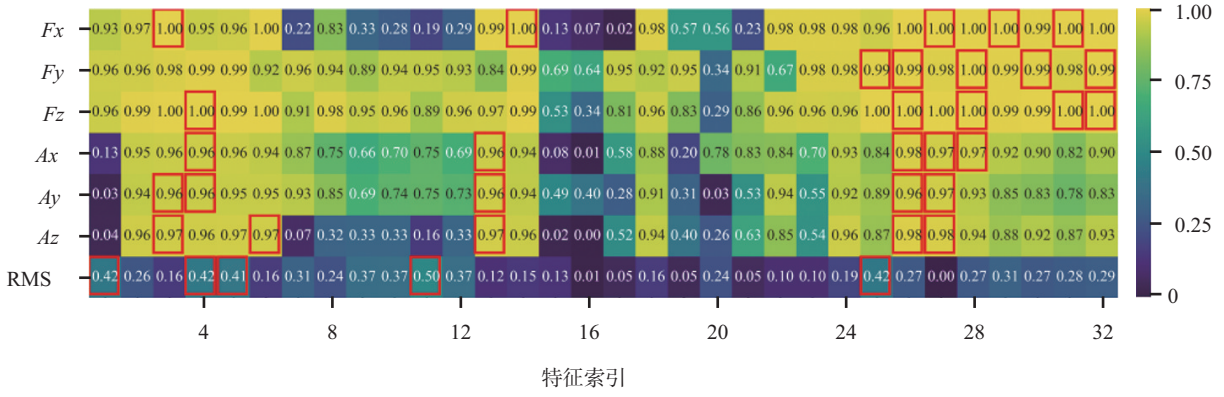



图5　多域特征相关性分析

Fig.5　Multi-domain feature correlation analysis

analysis, KPCA）、线性判别算法（Linear discriminant analysis, LDA）等，通过这些特征融合算法处理原始特征矩阵，不仅可以有效降低特征维度，同时也能够有效抑制噪声干扰。此外，基于相关性分析进行自适应权重分配的融合策略也备受关注。例如，Wang等[58]计算提取特征与刀具磨损值之间的相关系数构建相关矩阵，并基于设计的权重分配公式进行自适应特征融合，其融合原理如图6所示。

## 2 基于PGDL的刀具磨损监测方法

在完成信号获取、预处理与特征提取后，TWM的核心任务是构建模型学习与刀具磨损相关信息，并构建输入数据与磨损值之间的高精度映射关系。与纯数据驱动方法性能严重依赖复杂网络结构与大量高质量标注数据不同的是，PGDL通过将领域先验知识融入模型构建中，使模型在数据受限或数据分布存在偏移的场景下仍具备优异的性能表现。此外，物理先验知识作为一种正则化项，能够有效抑制小样本训练任务下的过拟合问题。更重要的是，PGDL通过显式或隐式引入物理约束与机理信息，为模型输出提供可追溯的物理依据，显著提升了监测结果的工程可解释性与可信度。图7给出了基于PGDL的TWM总体框架。为系统梳理PGDL在TWM中的实现路径，现有研究通常可按嵌入位置归纳为3类：输入端嵌入、训练端嵌入与结构端嵌入。

### 2.1 物理信息指导的数据增强

在输入端层面，基于PGDL的TWM方法利用磨损物理模型、数值仿真分析或关键物理量参数对训练样本数据进行增强，从而在输入层面实现物理信息与深度学习模型融合。图8所示为基于物理信息增强数据的TWM框架。

在样本与标签扩充方面，Pashmforoush等[59–60]分别在车削与铣削中构建了包含后刀面磨损的热–机械切削力模型，利用少量实测切削力和后刀面磨损数据标定模型参数，进而在广义工况空间内生成“工况–切削力–磨损”仿真样本，用于训练由切削力反推磨损的机器学习模型，实现了典型的物理驱动数据增广。Li等[22]提出的物理信息深度学习方法在基于三维铣削力模型和通用磨损模型的基础上生成大规模仿真力–磨损序列，对DL模型进行预训练，再用实测数据微调，提高了对

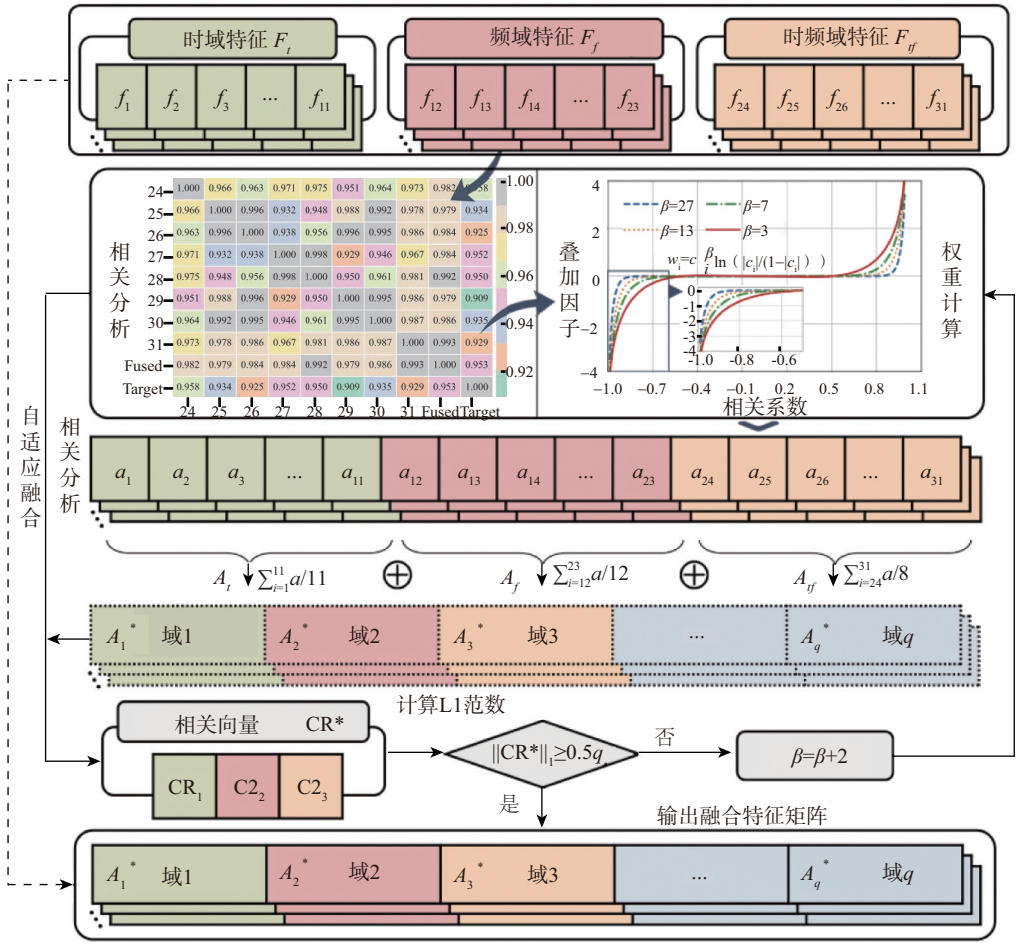



图6 自适应特征融合方法[58]

Fig.6 Adaptive feature fusion method[58]

真实工况的适应能力。Yuan等[61]将通用磨损经验模型与在线学习结合，设计了一种物理辅助在线学习框架，实现了在小样本、变工况条件下的高精度刀具磨损预测。Li等[62]利用磨损经验模型对有限VB测量数据进行插值外推，得到细颗粒度的磨损标签和初期、正常和急剧磨损阶段划分，再结合深度神经网络与隐马尔可夫模型进行了时序建模和状态识别。面向多刀具小样本且随机性强的场景，Liu等[63]利用非线性磨损经验模型构建目标域磨损先验，在此约束下设计了物理知情数据生成与领域对抗结构，合成具有合理磨损分布的目标域伪样本，并结合迁移学习实现了跨域监测。

然而，上述用于增强数据的物理方法多基于静态或稳态假设，难以精准表征实际加工过程中复杂切削轨迹下的瞬态几何时变特征。随着数字孪生技术的发展，利用数控加工几何仿真实时获取切削过程中的关键物理或几何信息已成为一种获取高保真物理先验的新策略。例如，张雷等[64]提出一种“机理–数据–知识”混合驱动架构，明确了通过几何仿真解析切削过程瞬态行为的必要性。Zhang等[65]提出一种基于局部布尔运算与2D图像映射的快速特征提取方法，通过仅更新刀具局部拓扑结构，显著降低了多轴加工过程中刀具–工件啮合与瞬态切削厚度信息

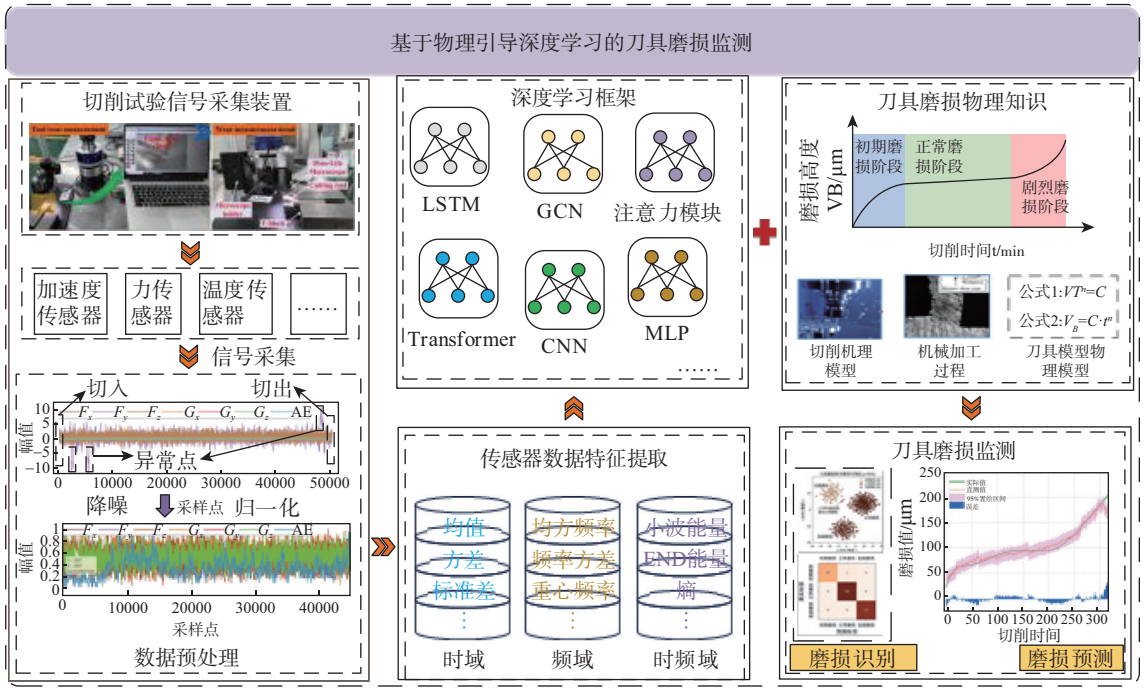



图7　基于物理引导神经网络的刀具磨损监测框架

Fig.7　Framework of TWM based on PGDL

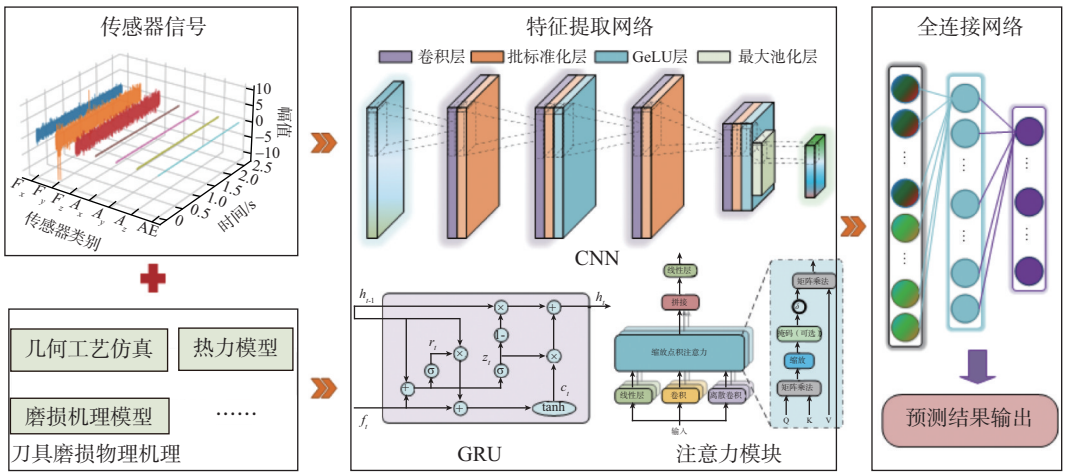



图8　基于物理信息指导进行增强数据的TWM框架

Fig.8　TWM framework for enhancing data based on physical information guided

提取复杂度。Qiu 等[66]则通过引入前瞻机制与动态体素结构，利用时序相关性分析降低冗余计算从而显著提高几何仿真响应速度，进一步验证了基于数字孪生信息提取和数控加工几何仿真在数据增强方面的优势。

与单纯利用物理模型扩充样本规模不同，将加工过程的关键物理量转化为适配模型输入格式的可学习特征也被验证为一种有效的基于物理知识增强方法。该策略使模型能够直接从关键物理量中捕获跨工况的演变规律，从而有效实现变工况下的 TWM。例如，Kang 等[67]用功率信号反推切削力系数，并与振动信号特征融合后作为模型输入，实现了具有物理可解释性的磨损预测。针对多源传感器因采样频率、量纲等差异导致融合困难的问题，Zhou 等[68]建立了统一的多域特征体系，以实现每个传感器信号均能映射为同构特征向量，随后采用 Transformer 的自注意力学习跨传感器、跨域特征相关性，从而实现刀具磨损预测。为满足在线监测需求，Qiu 等[69]通过几何访真计算刀具与工具啮合（Cutter workpiece engagement）与瞬时材料去除体积作为传感数据的物理语义通道，以赋予传感器信息明确的物理意义。

总体而言，基于物理信息增强输入数据的策略对于扩充训练数据并提升输入样本的物理一致性具有重要应用意义。然而，现有物理建模方法通常在理想化条件下进行，当该物理模型或经验知识与实际加工存在较大差异时，引入的偏差反而可能误导模型训练，降低监测精度。

### 2.2 物理信息指导的损失函数设计

从训练端层面看，TWM 模型训练过程中最常用的优化策略通过最小化损失函数来更新网络参数，从而建立输入样本与刀具磨损值之间的非线性映射关系。因此，在目标函数构建阶段，将物理模型或经验先验以正则化损失项的形式引入到模型训练过程中是现有 PGDL 中较为成熟且被广泛研究的方式之一，其基本流程如图 9 所示。

TWM 本质上属于一种典型的回归预测任务。在模型训练阶段，其核心目标是通过最小化磨损监测值与真实值之间的差异，从而构建输入特征与磨损状态之间的精确映射关系。通常采用均方误差（Mean squared error, MSE）作为指导模型可训练参数更新的策略，MSE 的数学表达式（$\mathrm{Loss}_d$）可以表示为

$$\mathrm{Loss}_d=\frac{1}{N}\sum_{i=1}^{N}(y_i-\tilde{y}_i)^2 \tag{8}$$

式中，$N$ 为样本个数；$y_i$ 和 $\tilde{y}_i$ 分别为实际测量的刀具磨损值和模型给出的估计值。然而，对于噪声较大的输入样本，仅考虑数据拟合精度通常会导致预测结果并不完全符合物理规律。具体来说，刀具磨损本质是一个随时间渐进递增的过程，这意味着模型估计的刀具磨损值不应该出现剧烈的波动，应符合渐进单增的趋势。基于此，将这一物理先验知识构建成损失函数并引入到模型训练过程中已成为物理约束损失函数驱动的 TWM 方法中的典型策略之一，该物理先验知识构建的损失函数可以表述为

$$\mathrm{Loss}_k=\sum_{i=1}^{N-1}\max(0,\tilde{y}_i-\tilde{y}_{i+1}) \tag{9}$$

通过引入该损失函数，给予训练过程中出现的前一个磨损估计值大于后一个更大的惩罚，使得模型训练能够尽可能地满足磨损值渐进单增。例如 Wang 等[70]将渐进单增作为正则项引入到设计的自监督网络中，有效抑制了小样本训练过程中的过拟合问题。

需要进一步说明的是，正常的刀具磨损不仅是一个渐进单增，具体来说，刀具正常使用的阶段主要为正常磨损阶段，而该阶段磨损率变化应满足渐进平稳特性。这意味着磨损率变化不应出现剧烈的波动，因为剧烈波动的磨损率变化意味着前后两个时间点的刀具磨损值存在较大偏差，这通常发生在刀具崩刃过程中。基于这一特性，Chen 等[71]在磨损渐进单增这一物理先验知识的基础上引入了磨损率一致性约束，该约束可以表示为

$$\mathrm{Loss}_r=\frac{1}{N}\sum_{i=1}^{N}(\partial\tilde{y}_i/\partial t_i-\partial p_i/\partial t_i)^2 \tag{10}$$

式中，$\partial\tilde{y}_i/\partial t_i$ 和 $\partial p_i/\partial t_i$ 分别为第 $i$ 个样本处模型给出的磨损估计值磨损率与经验物理模型磨损率，经验物理模型 $p$ 通过拟合实际磨损值构建。

除了基于磨损变化渐进单增和磨损率渐进平稳变化构建的物理先

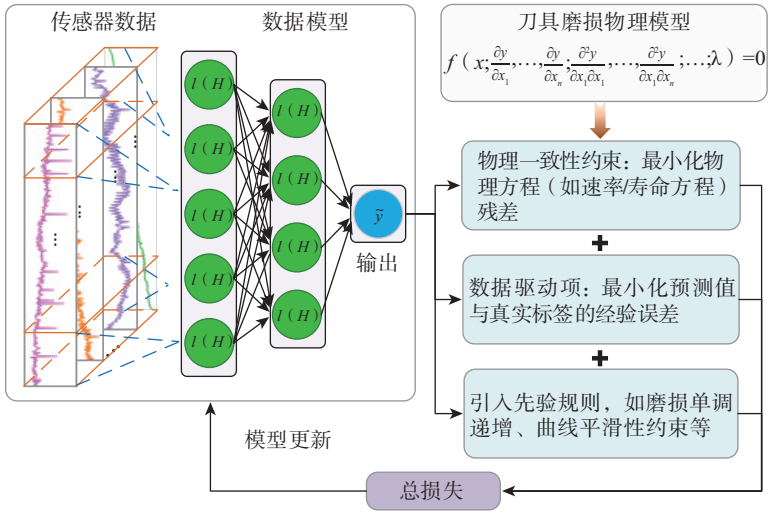



图 9 基于物理信息设计损失函数的 TWM 框架

Fig.9 TWM framework for designing loss function based on physical information

验损失外，将物理模型直接引入损失函数中，并基于物理模型和数据驱动模型刀具磨损估计值之间的误差构建物理一致性损失函数，是当前基于PGDL训练范式中的常见策略，该物理一致性损失可以表示为

$$\mathrm{Loss}_p=\frac{1}{N}\sum_{i=1}^{N}(\tilde{y}_i-\tilde{p}_i)^2 \qquad (11)$$

式中，$\tilde{p}_i$为物理模型给出的刀具磨损估计值，该物理模型通常包括通用型的刀具磨损经验物理模型或者基于特定加工条件下构建的物理模型。例如，Li等[72]以非线性磨损演化模型和数值分析为基础，构建出当前刀具磨损状态与前一刻状态之间的关系方程，并以该方程估计值与数据驱动模型输出值的误差构建物理一致性损失函数，从而提高预测结果的物理可解释性和可信性。Peng等[73]以指数型刀具磨损经验物理模型为基础，通过其与数据驱动模型估计值之间的误差构建了物理一致性约束，同时结合自适应特征融合机制，提出了一种轻量化PINN用于刀具磨损监测。

需要指出的是，上述以物理模型与数据驱动模型对刀具磨损估计值误差构建的损失函数，本质上需要依赖于经验物理模型的合理性。具体而言，当训练集和测试集刀具磨损实际趋势差异较大情况下，该物理模型对于测试集是不适用的。针对这一问题，Fang等[24]通过对数据驱动模型输出求偏导，构建了一种隐式物理一致性损失函数，并联合刀具磨损渐进单增和数据拟合精度约束模型训练过程，使得模型在考虑磨损预测精度的同时保证结果符合刀具磨损物理规律。

尽管通过将切削物理机理或者先验知识等设计为损失函数嵌入到模型训练过程中能够迫使模型训练过程中兼顾预测精度和物理规律，但多个损失项的幅值通常是不一致的，由此会导致某些损失项在模型训练过程中占据主导地位。具体来说，当模型损失项幅值远大于其它损失项后，整个训练过程中可能会以该损失为主，甚至是仅该损失有效。针对这一问题，权重分配过程提供一种有效解决思路，该过程可以表述为：

$$\mathrm{Loss}=\lambda_1\cdot\mathrm{Loss}_d+\lambda_2\cdot\mathrm{Loss}_p+\lambda_3\cdot\mathrm{Loss}_k+\ldots \qquad (12)$$

式中，$\lambda$为对应损失项的权重，通常可以基于预训练确定，或者采用权重自适应分配策略来生成。例如，Xu等[74]通过线性层和激活函数来拟合模型预测输出、实际磨损标签及物理信息损失项的输出结果，从而自适应分配3个损失项的权重。Hua等[75]通过量化每个批次训练过程的预测方差来进行权重自适应分配，从而在物理模型不准确或数据噪声较强时自适应抑制高不确定性来源，实现精度与误差稳定性的同步提升。针对无标签变切削加工场景需求，Kim等[76]以逆格拉姆子空间匹配（Inverse Gram subspace matching, IGSM）实现源目标分布对齐并保持尺度一致，同时引入伪标签成对正则排序损失仅约束伪标签的相对序性以维持磨损演化合理趋势；进一步采用动态加权平均分配各损失权重，平衡拟合与对齐正则，减少人工调参并提升跨工况稳定性。

综上所述，将物理模型或经验知识构建为损失函数用于约束模型训练在TWM任务中已被验证为是一种有效且易于实现的方式。然而，多个损失项对刀具各阶段磨损的作用机理和贡献尚不明确。此外，现有多目标梯度竞争和权重自适应分配尚未形成可靠的技术方案。

### 2.3 融合物理信息的网络框架设计

从结构端层面看，将物理信息以可集成的模块嵌入到网络架构中是实现PGDL的有效方式之一。如图10所示，具有代表性的融合方式包括：其一，机理模型与数据驱动模

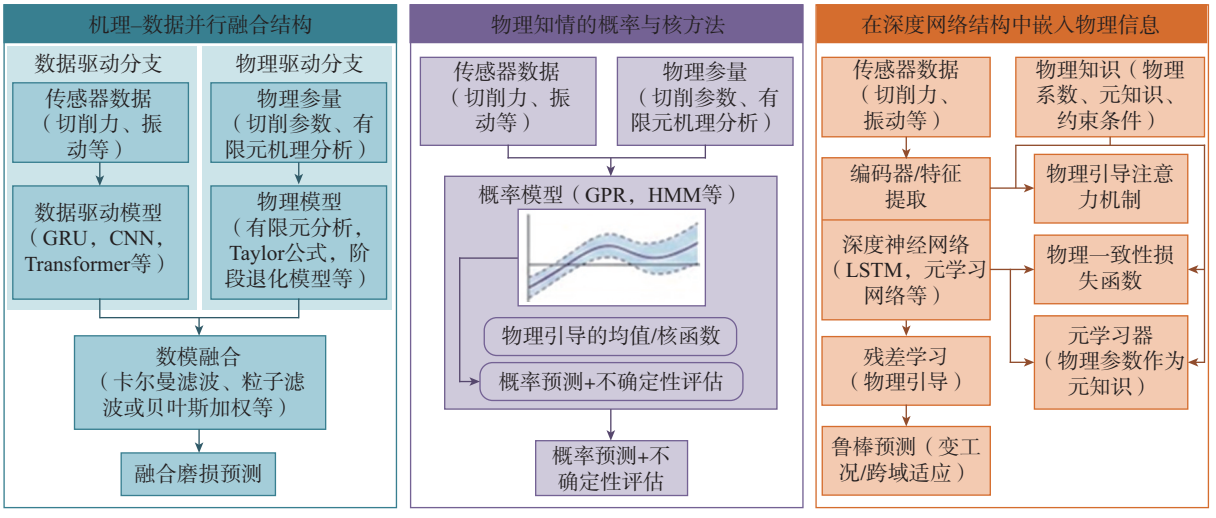



图10 物理信息模块化嵌入的TWM方法

Fig.10 TWM method for modular embedding of physical information

型的并行学习和融合架构；其二，基于物理启发构建的概率或代理模型；其三，在网络内部嵌入物理知识以重构网络结构。

第一类方法通过在并行分支中分别刻画机理退化先验与数据驱动观测，并在状态空间或贝叶斯推断等框架下进行融合更新，以实现对退化轨迹的在线一致性校正。陈安航等[77]以机理仿真结果作为状态先验，采用强跟踪卡尔曼滤波（Strong tracking Kalman filter, STKF）将多尺度卷积 Transformer 网络（Multi – scale convolutional – transformer, MSCTNN）的预测输出作为量测更新，从而实现了磨损状态在线闭环校正。Gao等[78]构建贝叶斯融合机制，将物理信息建模为先验分布、将数据模型输出视为观测似然，通过后验概率推断有效提升了预测结果的鲁棒性。朱昀等[79]提出将基于铣削力与功率的机理磨损估计与多源特征进行联合建模的策略，并引入物理一致性约束以抑制非物理波动。Fang等[80]进一步融合 Transformer–GRU 与粒子滤波算法（Transformer–GRU and particle filter, TG–PF），通过滤波算法的迭代更新特性实现对模型累积误差的动态修正。Li等[81]则在贝叶斯推断框架下引入支持向量回归（Support vector regression, SVR）估计刀具磨损及其阶段信息，并结合滑动窗口粒子滤波（Particle filter, PF）实时迭代更新物理模型参数，从而显著降低了刀具剩余使用寿命（Remaining useful life, RUL）预测的不确定性。

第二类方法通过将磨损机理转化为统计建模中的结构化先验，并与概率推断或核方法相结合，从而提升模型在工况变化与噪声干扰条件下的适应性，使监测结果在动态扰动下仍能保持趋势合理性。例如，Zhu等[82]将铣削机理与先验知识引入隐马尔可夫模型（Hidden Markov model, HMM），以概率形式描述刀具磨损的阶段演化过程；Li等[83]利用磨损机理与 GPR 的相关性约束来增强磨损估计的稳定性。此外，Wang等[84]提出的 PIGPR 在 GPR 的均值函数中引入退化物理模型作为物理信息项，从而提升外推能力，并能够同时刻画外推过程中的不确定性。Qiang等[85]进一步提出物理引导递归 GPR（Physics – guided recursive Gaussian process regression, PRGPR），以物理均值函数表征累积磨损效应对材料去除率演变的影响，并结合实例迁移学习实现了跨工况的刀具磨损预测。

第三类方法则从网络结构层面直接嵌入物理信息。此类方法通常将切削参数与物理估计量作为显式条件先验，通过编码器或注意力模块实现物理信息在网络中嵌入与特征重校准，以显著提升模型的跨工况表征与泛化能力。Zhu等[86]基于自适应双尺度分层长短时记忆网络（Adaptive dual–hierarchical LSTM, ADHL）构建物理信息深度学习框架，将切削参数与物理模型估计量通过注意力机制注入网络多层，并结合周期结构设计与多任务损失等策略提升了变工况下的鲁棒性。Li等[87]提出了一种物理信息元学习方法，将经验公式参数视作元知识并与网络权重协同更新，以缓解由磨损率变化带来的适应性问题。此外，Gao等[88]提出模型和知识引导多专家加权对抗性深度迁移学习（Model and knowledge – guided multi – expert weighted adversarial deep transfer learning, MKWADTL）框架，在对抗对齐过程中引入知识校准辅助网络及物理引导损失，从而在跨域特征对齐时保持物理一致性并提升泛化性能。

总体而言，从网络结构设计层面引入物理信息能够使得模型训练过程中不仅学习数据驱动的观测映射，同时在物理先验约束下维持退化轨迹的合理性。然而，并行融合框架对先验模型精度、观测噪声分布及相关假设较为敏感；基于物理启发的概率估计和代理模型构建往往对领域专家知识有较高要求；而将物理知识模块化内嵌至模型结构中，则对物理–数据耦合接口的设计提出了极高要求。

## 3 关键挑战与未来展望

尽管现有基于 PGDL 的刀具磨损状态监测已形成了系统性的技术路线，但与实际加工应用中的轻量化部署、实时推理、跨域泛化等需求仍存在较大的差距，具体如下。

### 3.1 物理建模与多目标优化

当前大多数物理磨损模型是通过简化加工过程来构建的，例如近似稳定切削，以及将材料特性与刀具几何进行等效处理等。这类假设在真实加工中易受载荷突变、热力耦合、刀具刃口形貌变化与材料各向异性等因素影响，从而削弱模型对非均匀磨损与动态扰动情况下刀具磨损的表示能力，并在刀具全寿命演化的监测过程中形成误差累积[89–90]。因此，未来研究应推动物理模型由静态经验拟合向动态可更新先验转变，通过开发参数可学习与状态可校正的轻量化代理模型，实现机理约束随工况与磨损阶段的自适应调整，从根本上降低模型失配风险[91–92]。同时，应将不确定性纳入统一建模框架，通过概率化表征与不确定性传播形成可信度量，使预测结果具备可解释的置信依据，并为磨损预测、RUL 评估与工艺决策提供风险参考[89,93]。

此外，在模型训练层面，不同磨损阶段的损失主导项往往存在显著差异，损失尺度不一致与梯度竞争会导致训练收敛不稳定，进而影响模型性能。尽管一些研究中采用经验或自适应算法分配不同损失项权重避免了单一项的主导效应，但各项损失在不同磨损阶段的作用机制与贡献尚不清晰。因此，构建可迁移的动态权重分配与分阶段训练策略，在物理一致性、收敛稳定性与预测精度之间

形成具备可解释且可分析评估的平衡机制，是基于PGDL的TWM方法重要研究方向之一。

### 3.2 变工况泛化、可解释性与可信评估

在实际切削加工中，切削参数的动态调整容易引发监测信号出现显著的分布偏移与尺度漂移，进而导致基于固定工况假设训练的模型在新工况下鲁棒性不足[94]。针对这一问题，单纯依赖统计特征对齐的数据驱动迁移方法难以捕获切削过程中的物理规律。因此，未来研究应从“特征统计对齐”策略向“切削机理引导泛化”递进。一方面，开发具有切削机理引导的领域泛化网络，将物理机制与尺度信息引入特征空间来增强模型鲁棒性，并结合对比学习等方法，解决弱标签或无标签条件下的在线工况适配问题[16,95-96]；另一方面，利用刀具动态演变物理机理构建具有“物理不变量”的泛化框架，并结合元学习策略实现快速跨域适配，从而使得模型能够具有变工况泛化性[97]。

其次，针对深度学习“黑箱”特性导致其在高端制造领域受限的问题，尽管现有研究尝试通过特征可视化等方式来提高过程透明性，然而这种局限于对模型关注区域的训练过程展示，未能从模型决策背后的物理因果逻辑出发。尽管部分研究通过在模型训练阶段引入物理信息来提高模型的可解释性，但本质上仍是侧重于物理先验的外部嵌入或对监测结果的约束，未能改变神经网络特征提取过程依赖于数据统计相关特性这一事实。因此，未来研究可考虑构建基于工艺语义和物理机理的特征解耦及因果推理架构，通过建立神经网络与切削力、温度、应力分布等切削机理量之间的显式映射关系，使得模型学习刀具动态演化过程中的物理因果关系，从根本上提高模型的可解释性。

此外，针对现有模型过度追求监测精度而忽略了结果可信性的问题，未来研究需要构建物理感知的不确定性量化与可信评估体系，通过建立基于物理一致性的风险边界判定，明确模型的适用范围，从而实现模型由“监测精度优先”到“结果风险可控”转变。总体而言，如图11所示，未来基于PGDL的TWM方法可从3个研究方向进行增强：以机理与尺度信息引导跨域适配以提升变工况泛化能力；以物理因果映射与工艺语义解释提升可追溯性与可解释性；并在此基础上引入物理感知的不确定性量化与风险边界判定以确保结果可信与风险可控。

### 3.3 刀具差异性、环境异质性与方法适配性

尽管基于PGDL的方法在提升监测精度和可解释性方面已表现出巨大潜力，但现有研究多集中于标准铣削与车削过程，对攻丝、钻削、拉削等复杂工艺研究较少。然而，在航空航天与汽车制造等实际工业场景中，切削加工过程通常涉及多种类型刀具的协同作业。如表2所示，不同类型的刀具在切削运动学、受力状态与失效机理上有着本质区别，因此构建基于PGDL的TWM方法也有所不同。

首先，受刀具类型差异性影响，不同刀具切削机理差异性较大，导致难以构建具有统一表征能力的物理先验知识。具体来说，车削过程通常表现为连续切削过程，其力热耦合相对稳定。相比之下，铣削过程则具有显著的断续切削特征，多齿交替切入切出引发的强迫振动与热冲击，导致切削过程呈现高频周期性波动。对于丝锥等半封闭加工刀具，受排屑与散热条件限制，其失效模式多表现为瞬时折断而非渐进式磨损。其次，不同类型的刀具切削过程中信号特征与可监测性也存在一定差异性。例如，在铣削和车削过程中，力、振动和声发射信号能够很好地表征刀具动态演化。然而，深孔钻或攻丝等半封闭加工，则受限于信号传输路径复杂及受切削液与切屑干扰，导致传感器信号表示能力不足。

此外，即便针对同一类型的刀具，微观结构参数与切削环境的异质性同样会给模型的泛化能力带来严峻挑战。一方面，由于生产厂家工艺不同，同规格刀具在刃线、容屑槽、螺旋槽、前后刀面及涂层等结构参数存在微观偏差；另一方面，即便采用相同的切削参数，因机床差异、工件差异导致对应的切削信号也会呈现显著的异质性。

因此，未来研究应突破“一刀一法”的局限，研究具有适应不同类型

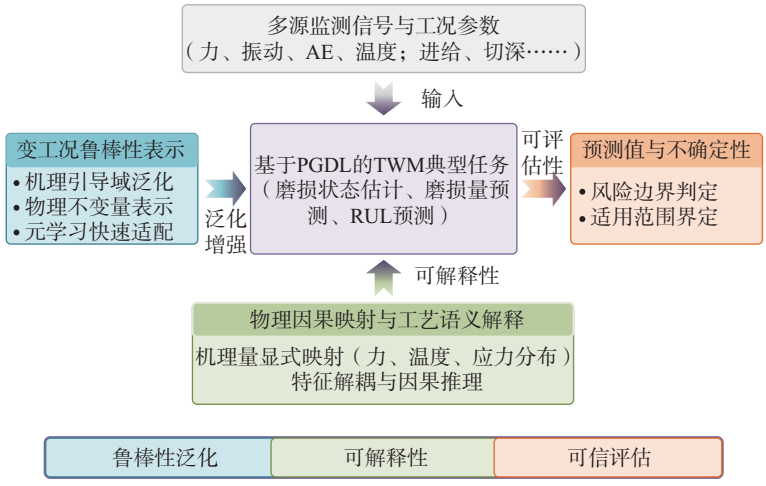



**图11 面向TWM的变工况泛化、可解释性与可信评估示意图**

**Fig.11 Flowchart of condition generalization, interpretability, and trustworthiness for TWM**

表2　不同刀具类型的TWM信号选择与监测策略构建思路

Table2　Signal selection and monitoring strategy design guidelines for different tool types in TWM

| 刀具类型 | 切削特点 | 刀具失效主导机理 | 可选择监测信号类型 | 监测难点 | 监测模型构建思路 |
|---|---|---|---|---|---|
| 铣刀 | 多齿断续切削，周期性明显 | 渐进磨损、周期性冲击诱导崩刃、振动、颤振等耦合导致的不规则退化 | 振动、切削力、AE、温度、主轴电流和功率 | 多齿磨损趋势不一致、信号非平稳性强；周期调制明显 | 基于齿通频率与主轴转速的周期性特性构建物理约束，同时引入每齿一致性与周期调制约束以抑制非物理波动 |
| 车刀 | 连续切削、接触区域相对稳定、热力耦合较平稳 | 渐进磨损为主，高负载时可能出现崩刃 | 振动、切削力、AE、温度、主轴电流和功率 | 信号漂移问题受工况差异影响大 | 构建能量与温升先验的物理代理模型，并结合工况漂移校准以增强跨工况鲁棒性 |
| 丝锥 | 半封闭加工、切屑阻塞风险高、扭矩波动明显 | 磨损与粘结并存；易发生瞬时折断和崩刃 | 振动、AE、温度、扭矩和电流 | 失效多为突发事件，前兆弱；切屑堵塞和润滑变化易导致强噪声和误报 | 基于扭矩与电流的瞬态特征及能量突变开展事件检测，并按加工阶段设置分段物理约束与风险判据 |
| 钻头 | 半封闭/封闭切削、排屑与散热受限 | 渐进磨损、粘结和积屑导致的磨粒磨损和黏着磨损 | 推力、扭矩、振动、AE | 信号传输路径长、衰减问题严重；冷却液和切屑干扰强；孔深差异引起的分布漂移 | 将孔深、进给与冷却状态作为条件变量，构建阶段可变的磨损映射以缓解分布漂移 |

刀具切削环境的PGDL框架。具体来说，可考虑通过构建具有“物理不变性”的特征表达，以缓解车、铣、钻等不同加工机理间的表征差异；另一方面，可开发集成机理感知策略的模型，并引入领域自适应技术，将与刀具结构差异性和环境异质性导致的具有明显分布差异性监测信号映射到统一物理特征空间，从而使得模型学习刀具动态演化共性知识，从而实现从特定刀具、特定机床向跨厂家、跨设备场景的低成本快速迁移。

### 3.4　孪生仿真实时性与虚实一致性

近年来，数字孪生和数控加工几何仿真技术的发展，为TWM提供了切削轨迹、接触区域、瞬时切削体积等关键信息，为构建基于PGDL的TWM提供了关键先验信息。如图12所示，面向TWM的数字孪生系统可抽象为五维模型，即由物理实体、虚拟实体、孪生数据、加工服务以及连接与更新迭代构成，其中“连接”用于实现物理实体与虚拟实体间的信息传输，“更新迭代”实现在线校准与状态演化[98–99]。然而，这种持续更新通常面临着两个问题，即“实时性”和“虚实一致性”，可以具体描述为以下内容。

首先，精细化几何仿真与在线监测的时效性需求间存在显著矛盾。传统的全局仿真策略计算复杂度通常随仿真规模呈指数级增长，难以满足实际加工过程中的毫秒级实时响应需求。尽管现有研究中通过局部更新策略在一定程度上缓解了计算压力，但在面临航空叶轮等高精尖复杂曲面或微铣削中微米级特征提取时，如何在有限算力情况下保持几何特征解析精度，仍是亟须突破的瓶颈[100]。因此，未来研究可以考虑基于GPU并行加速、神经渲染及自适应多分辨率体素等新型算法，以实现复杂加工场景下的高精实时映射。

其次，现有数字孪生与几何仿真通常忽略了实际加工过程中普遍存在的刀具–工件弹性变形、切削颤振及刀具磨损等复杂动态耦合特性，使得基于该策略生成的切削轨迹、接触区域、瞬时切削体积等信息与实际加工过程存在明显的“虚实失配”。因此，未来的数字孪生和几何仿真系统应具备主动进化机制，通过融合加工过程中工艺参数和实时传感信息，在

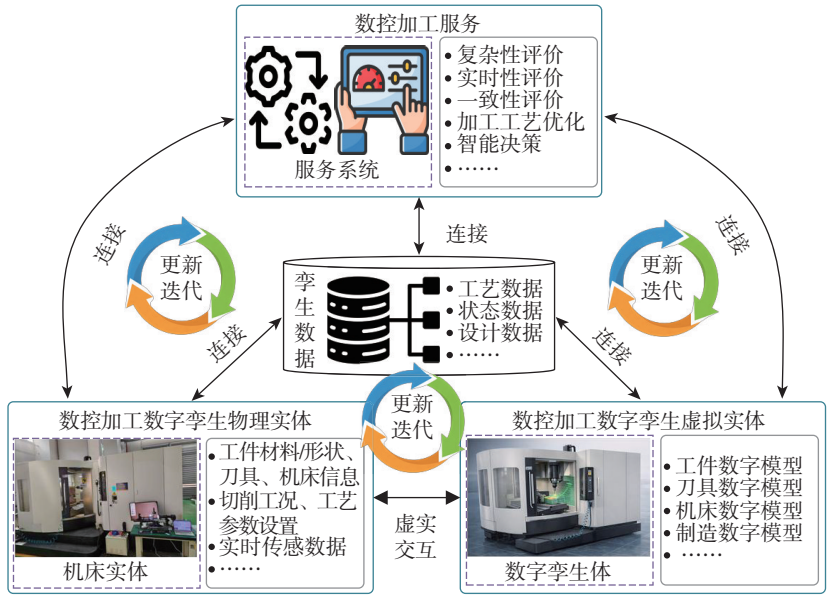



图12　面向TWM的数字孪生驱动五维模型

Fig.12　Digital twin-driven five-dimensional model for TWM

线更新虚拟世界几何边界和状态参数，确保数字孪生体在全寿命加工周期内保持与真实世界的动态一致性。

### 3.5 工程部署、系统集成与规范标准

相比于模型的快速迭代，工程化部署与系统集成仍是PGDL方法在工程应用中的关键瓶颈。首先，在边缘硬件或工业PC资源受限的条件下，需要在保证监测精度的同时兼顾模型轻量化、可部署性与可维护性。其次，实时在机监测对时效性要求严格，从传感数据采集到预处理、特征构建再到模型推理的全链路时延必须控制在可接受范围内，否则难以支撑在线报警、换刀决策与工艺调整等任务。此外，就系统集成而言，当前模型部署在输入输出定义、数据接口与标签口径等方面仍缺乏统一规范，模型版本管理、运行监测与更新机制也不够完善，导致跨设备、跨材料与跨工况迁移成本较高且难以长期稳定运行。

因此，面向TWM工程化需求，未来研究可通过构建如图13所示“云–边–端”协同部署架构[101]。端侧物理机床加工平台利用现场可编程门阵列（Field – programmable gate array, FPGA）等高性能硬件系统[101]，实时高保真获取切削加工过程中的多源传感信息、机床信息等，形成规范化数据流，确保推理部分数据真实可用性。数据通信层通过TCP/IP与OPC UA等工业通信机制实现数据流高质量传输。边缘侧数字孪生智能加工平台通过模型对刀具磨损状态实时评估结果，基于阈值或风险判据为换刀、工艺调整等提供建议，并触发更新机制促进数字孪生体参数与加工状态在线调整，进而提高虚实一致性与决策可解释性[102]。云端数据库存储主轴信息、切削参数、传感数据与异常记录，为跨设备与跨工况监测提供指导。

更为重要的是，为推动PGDL从“模型可用”走向“系统实用与工程可信”，未来研究中还需考虑进一步促进开放数据资源共享，形成统一评估方法，并建立兼顾准确性、物理一致性与部署成本的工程化指标体系。

## 4 结论

TWM是保障数控切削加工效率和工件质量的关键支撑技术之一。传统物理模型虽具有较强可解释性，但受建模理想假设与参数固定等限制，难以适应真实加工中的动态扰动与工况变化；而纯数据驱动的深度学习虽能有效表征刀具磨损过程的非线性演化，但其监测精度对样本数量与质量高度依赖，且“黑箱”特性导致物理透明性不足、结果可信度有限。围绕上述矛盾，融合物理信息与深度学习的PGDL为实现高精度、可解释与可信的TWM提供了新的选择。本文从刀具退化模式与常用传感器类型出发，系统性梳理了刀具磨损演化的典型规律与影响因素，并归纳了力、振动、声发射、温度与图像等信号的获取方式、预处理与特征构建流程，明确不同信号在表征刀具磨损演化与工况扰动等方面的优势与局限，为形成可用且可解释的数据表征奠定基础。在此基础上，面向基于PGDL的TWM方法体系，按物理信息引入方式将现有研究归纳为输入端、训练端与结构端3种引入策略，并总结了物理先验在数据增强、损失约束与模型结构融合中的主要实现机制与适用边界。进一步地，结合工程应用需求，围绕物理先验可迁移性、变工况泛化、可信评估、孪生仿真实时性与

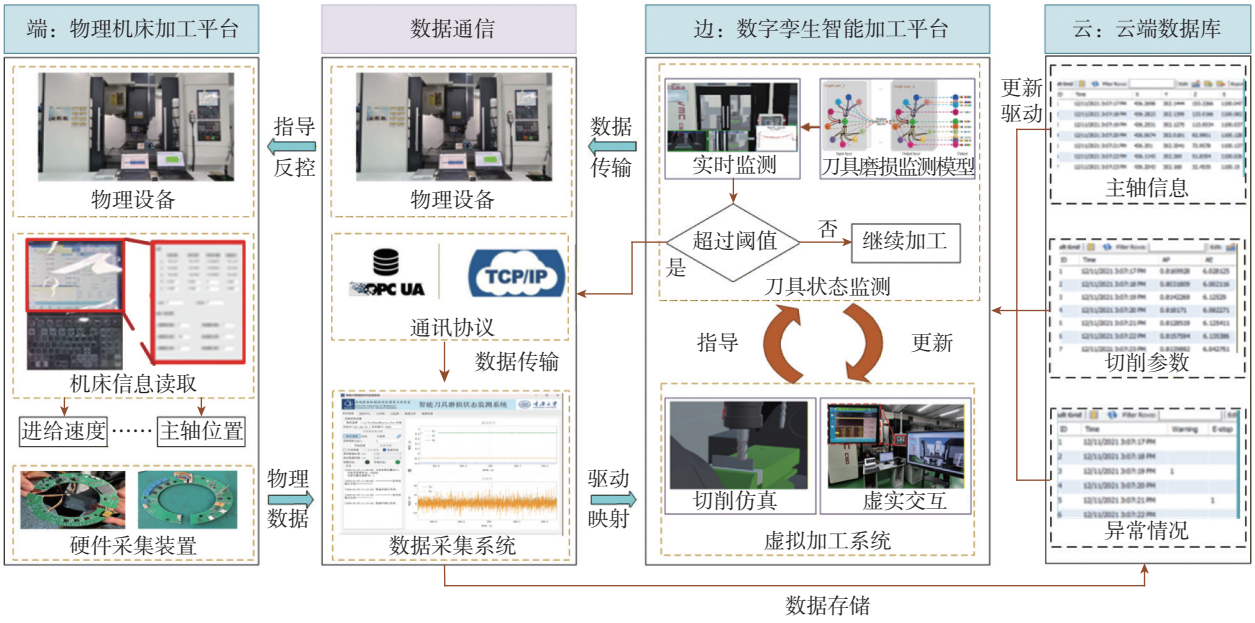



图13 面向TWM的端–边–云协同部署与系统集成架构示意

Fig.13 Architecture of end–edge–cloud collaborative deployment and system integration for TWM

虚实一致性、以及工程部署与规范标准等方面，系统总结了当前基于PGDL的TWM方法存在的关键挑战并进行了未来展望，为在TWM场景下实现精度、鲁棒性与物理一致性的协同提升提供了清晰的思路。

## 参 考 文 献


[1] Khadka S, Rahman Rashid 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): 3037–3076.

[2] 王海泉, 郭修远, 李辉, 等. 刀具磨损检测技术综述[J]. 自动化技术与应用, 2024, 43(7): 1–6.

Wang Haiquan, Guo Xiuyuan, Li Hui, et al. Overview of tool wear detection technology[J]. Techniques of Automation and Applications, 2024, 43(7): 1–6.

[3] 张松, 张超勇, 朱传军, 等. 基于空间注意力机制U-Net的铣刀磨损在位监测方法[J]. 中国机械工程, 2025, 36(11): 2720–2727.

Zhang Song, Zhang Chaoyong, Zhu Chuanjun, et al. In-situ monitoring method of milling cutter wear based on spatial attention mechanism U-net[J]. China Mechanical Engineering, 2025, 36(11): 2720–2727.

[4] 向福星, 孟博洋, 李众杰, 等. 刀具磨损状态监测综述[J]. 制造技术与机床, 2026(1): 46–59.

Xiang Fuxing, Meng Boyang, Li Zhongjie, et al. Overview of tool wear condition monitoring[J]. Manufacturing Technology & Machine Tool, 2026(1): 46–59.

[5] 黄贤振, 孙良仕, 高娓, 等. 基于SFS-SVR的高速铣削刀具剩余使用寿命预测[J]. 东北大学学报(自然科学版), 2023, 44(6): 824–831.

Huang Xianzhen, Sun Liangshi, Gao Wei, et al. Remaining useful life prediction of cutting tools based on SFS-SVR in high speed milling operations[J]. Journal of Northeastern University (Natural Science), 2023, 44(6): 824–831.

[6] Hou W, Wang J C, Wang L L, et al. Novel tool wear prediction method based on multimodal information fusion and deep subdomain adaptation[J]. Mechanical Systems and Signal Processing, 2025, 224: 112128.

[7] Nie P, Guo Y X, Lou B X, et al. Tool wear monitoring based on scSE-ResNet-50-TSCNN model integrating machine vision and force signals[J]. Measurement Science and Technology, 2024, 35(8): 086117.

[8] Xu Z C, Zhang B L, Luo Fan 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.

[9] 胡德凤, 张晨曦, 汪世涛, 等. 基于深度信号处理和堆叠残差GRU的刀具磨损智能预测模型[J]. 计算机科学, 2021, 48(6): 175–183.

Hu Defeng, Zhang Chenxi, Wang Shitao, et al. Intelligent prediction model of tool wear based on deep signal processing and stacked-ResGRU[J]. Computer Science, 2021, 48(6): 175–183.

[10] Xue Z L, Yang J, Chen J L, et al. Dual-band interactive convolution and frequency-prior adaptive channel attention network for tool wear prediction[J]. Advanced Engineering Informatics, 2026, 69: 104007.

[11] Hou K L, Li R Y, Liu X L, et al. Swin-fusion: An adaptive multi-source information fusion framework for enhanced tool wear monitoring[J]. Journal of Manufacturing Systems, 2025, 79: 435–454.

[12] Zhao P Y, Li Z T, You Z C, et al. SE-U-lite: Milling tool wear segmentation based on lightweight U-Net model with squeeze-and-excitation module[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 5018408.

[13] 李悦, 谢恒, 周公博, 等. 基于半监督贝叶斯Transformer的刀具磨损软测量及不确定性分析方法[J]. 中国机械工程, 2024, 35(11): 2015–2025.

Li Yue, Xie Heng, Zhou Gongbo, et al. Soft sensor modeling and uncertainty analysis approach of tool wear based on semi-supervised Bayesian transformer[J]. China Mechanical Engineering, 2024, 35(11): 2015–2025.

[14] Wan M, Cao M W, Wang S, et al. Recognition of tool wear in milling using Kolmogorov-Arnold networks and multi-sensor feature fusion[J]. Chinese Journal of Mechanical Engineering, 2026, 39: 100146.

[15] Truong T T, Airao J, Hojati F, et al. Data-driven prediction of tool wear using Bayesian regularized artificial neural networks[J]. Measurement, 2024, 238: 115303.

[16] Zheng Q, Chen Y, Zhang K, et al. CMSE – DGNet: A cutting mechanism-guided spatial-scale enhanced domain generalization network-based method for tool wear monitoring[J]. Mechanical Systems and Signal Processing, 2025, 239: 113304.

[17] 张子奇, 刘战强, 吕文军. 直角车削GH4169刀具全阶段磨损机理及磨损控制[J]. 航空制造技术, 2025, 68(9): 78–91.

Zhang Ziqi, Liu Zhanqiang, Lü Wenjun. Wear mechanism and control for full-stage wear of tool during orthogonal turning of GH4169[J]. Aeronautical Manufacturing Technology, 2025, 68(9): 78–91.

[18] 孟祥军, 郭南, 陈燕, 等. 冷却润滑方式对CFRP/钛合金叠层制孔刀具磨损的影响[J]. 航空制造技术, 2023, 66(13): 87–93.

Meng Xiangjun, Guo Nan, Chen Yan, et al. Effect of cooling strategies on tool wear of drilling CFRP/TC4 stacks[J]. Aeronautical Manufacturing Technology, 2023, 66(13): 87–93.

[19] Xiao X W, Geng M Z, Peng R T, et al. Mitigating ceramic tool wear in GH4169 machining through pre-stressed cutting: Insights from DEM – FEM coupling[J]. Engineering Failure Analysis, 2025, 182: 110166.

[20] 鲁艳军, 叶永辉, 关伟锋, 等. 基于PVD涂层刀具的钛合金超声辅助铣削工艺优化及磨损机理研究[J]. 机械工程学报, 2025, 61(23): 344–360.

Lu Yanjun, Ye Yonghui, Guan Weifeng, et al. Process optimization and wear mechanism of ultrasonic-assisted milling of titanium alloy based on PVD-coated tools[J]. Journal of Mechanical Engineering, 2025, 61(23): 344–360.

[21] Deng B, Peng F Y, Zhou L, et al. A comprehensive study on flank wear progression of polycrystalline diamond micro-tool during micro end-milling of SiCp/Al composites[J]. Wear, 2020, 456–457: 203291.

[22] Li S S, Lin X, Shi H, et al. Physics-guided deep learning method for tool condition monitoring in smart machining system[J]. IEEE/ASME Transactions on Mechatronics, 2024, 29

(3): 2327–2337.

[23] Sipos Z. Investigation of cutting performance of coated HSS tools made in Hungary[R]. Budapest: Budapest Tech, 2006.

[24] Fang X H, Song Q H, Wang X J, et al. An intelligent tool wear monitoring model based on knowledge-data-driven physical-informed neural network for digital twin milling[J]. Mechanical Systems and Signal Processing, 2025, 232: 112736.

[25] Yue C X, Qin Y Y, Liu X L, et al. Data-physics collaborativige fusion prediction method for tool remaining useful life based on Mamba state space and physical description [J]. Journal of Manufacturing Systems, 2025, 81: 1–15.

[26] 彭锐涛, 丁珑, 赵林峰, 等. 基于机器视觉的铣刀磨损在机检测方法[J]. 航空制造技术, 2023, 66(14): 143–152.

Peng Ruitao, Ding Long, Zhao Linfeng, et al. Milling cutter wear detection method based on machine vision[J]. Aeronautical Manufacturing Technology, 2023, 66(14): 143–152.

[27] 林苑, 徐俊. 智能切削刀具磨损视觉在线监测系统探析[J]. 模具制造, 2025, 25 (3): 186–188.

Lin Yuan, Xu Jun. Analysis of intelligent cutting tool wear visual online monitoring system[J]. Die & Mould Manufacture, 2025, 25 (3): 186–188.

[28] 任慧, 马金萍. Fisher准则函数在机械刀具切削磨损检测中的应用[J]. 机械设计与制造, 2025(1): 154–159, 165.

Ren Hui, Ma Jinping. Application of fisher criterion function in mechanical tool cutting wear detection[J]. Machinery Design & Manufacture, 2025(1): 154–159, 165.

[29] Makhesana M A, Bagga P J, Patel K M, et al. Comparative analysis of different machine vision algorithms for tool wear measurement during machining[J]. Journal of Intelligent Manufacturing, 2025, 36(7): 4567–4591.

[30] Pan Y, Hao L, He J L, et al. Deep convolutional neural network based on self-distillation for tool wear recognition[J]. Engineering Applications of Artificial Intelligence, 2024, 132: 107851.

[31] 杨超, 李宏坤, 彭德锋, 等. 基于DCVAE–ELM的立铣刀磨损状态识别方法[J]. 振动、测试与诊断, 2025, 45(4): 831–837.

Yang Chao, Li Hongkun, Peng Defeng, et al. Recognition method of end-milling tool wear state based on DCVAE–ELM[J]. Journal of Vibration, Measurement & Diagnosis, 2025, 45(4): 831–837.

[32] Song G H, Zhang J H, Zhu K Y, et al. Tool wear monitoring based on multi-kernel Gaussian process regression and Stacked Multilayer Denoising AutoEncoders[J]. Mechanical Systems and Signal Processing, 2023, 186: 109851.

[33] Pan T H, Zhang J, Zhang X, et al. Milling force coefficients-based tool wear monitoring for variable parameter milling[J]. The International Journal of Advanced Manufacturing Technology, 2022, 120(7): 4565–4580.

[34] Cheng M H, Jiao L, Yan P, et al. Intelligent tool wear monitoring and multi-step prediction based on deep learning model[J]. Journal of Manufacturing Systems, 2022, 62: 286–300.

[35] Ma J Y, Luo D C, Liao X P, et al. Tool wear mechanism and prediction in milling TC18 titanium alloy using deep learning[J]. Measurement, 2021, 173: 108554.

[36] Li R Y, Wei P N, Liu X L, et al. Cutting tool wear state recognition based on a channel-space attention mechanism[J]. Journal of Manufacturing Systems, 2023, 69: 135–149.

[37] Zhou X Y, Yu T Y, Wang G Z, et al. Tool wear classification based on convolutional neural network and time series images during high precision turning of copper[J]. Wear, 2023, 522: 204692.

[38] Twardowski P, Czyżycki J, Felusiak-Czyryca A, et al. Monitoring and forecasting of tool wear based on measurements of vibration accelerations during cast iron milling[J]. Journal of Manufacturing Processes, 2023, 95: 342–350.

[39] Bouchama R, Bouhalais M L, Cherfia A. Surface roughness and tool wear monitoring in turning processes through vibration analysis using PSD and GRMS[J]. The International Journal of Advanced Manufacturing Technology, 2024, 130 (7): 3537–3552.

[40] Rmili W, Ouahabi A, Serra R, et al. An automatic system based on vibratory analysis for cutting tool wear monitoring[J]. Measurement, 2016, 77: 117–123.

[41] Rahman A Z, Jauhari K, Al Huda M, et al. Correlation analysis of vibration signal frequency with tool wear during the milling process on martensitic stainless steel material[J]. Arabian Journal for Science and Engineering, 2024, 49(8): 10573–10586.

[42] Yang B, Wang M, Liu Z H, et al. Tool wear process monitoring by damping behavior of cutting vibration for milling process[J]. Journal of Manufacturing Processes, 2023, 102: 1069–1084.

[43] Lan Q X, Chen B Q, Yao B, et al. Tool wear state recognition with deep transfer learning based on spindle vibration for milling process[J]. Computer Modeling in Engineering & Sciences, 2024, 138(3): 2825–2844.

[44] Wang Y N, Zhao S Y, Zhang P, et al. The pin tool wear identification with vibration signal of friction stir lap welding based on a new pin tool wear division model[J]. Measurement, 2025, 242: 116131.

[45] 汪进超, 林毅, 宋平, 等. 航空涡轮盘拉削刀具健康监测系统设计[J]. 工业控制计算机, 2024, 37(1): 66–68.

Wang Jinchao, Lin Yi, Song Ping, et al. Design of health monitoring system of broach tools in aviation turbine disc[J]. Industrial Control Computer, 2024, 37(1): 66–68.

[46] He Z P, Shi T L, Xuan J P, et al. Research on tool wear prediction based on temperature signals and deep learning[J]. Wear, 2021, 478: 203902.

[47] Li T X, Shi T L, Tang Z R, et al. Real-time tool wear monitoring using thin-film thermocouple[J]. Journal of Materials Processing Technology, 2021, 288: 116901.

[48] Yin J W, Li Y A, Deng S, et al. Monitoring temperature signals from thin-film thermocouple array to construct the relationship between temperature and tool wear in milling processes[J]. Measurement, 2026, 260: 119880.

[49] Han J H, Liu Z Y, Cao K W, et al. Cutting temperature measurement in turning using fiber-optic multi-spectral radiation thermometry and its application in tool wear status recognition[J]. Measurement, 2022, 198: 111413.

[50] Wan B S, Lu M C, Chiou S J. Analysis of spindle AE signals and development of AE–based tool wear monitoring system in micro-milling[J]. Journal of Manufacturing and

Materials Processing, 2022, 6(2): 42.

[51] Huang C R, Lu M C. Investigation of cutting path effect on spindle vibration and AE signal features for tool wear monitoring in micro milling[J]. Applied Sciences, 2023, 13 (2): 1107.

[52] Zhang C J, Wang J H, Cao Y J, et al. Tool wear status monitoring under laser – ultrasonic compound cutting based on acoustic emission and deep learning[J]. Journal of Mechanical Science and Technology, 2024, 38 (5): 2411–2421.

[53] Maia L H A, Abrão A M, Vasconcelos W L, et al. Enhancing machining efficiency: Real–time monitoring of tool wear with acoustic emission and STFT techniques[J]. Lubricants, 2024, 12(11): 380.

[54] 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 Hao, Cao Huajun, Dong Jianxiong. Tool wear prediction method based on ISABO – IBiLSTM model[J]. China Mechanical Engineering, 2024, 35(11): 1995–2006.

[55] 郭润兰, 尉卫卫, 王广书, 等. 基于深度SSDAE网络的刀具磨损状态识别[J]. 振动 测试与诊断, 2024, 44(2): 305–312, 410–411.

Guo Runlan, Yu Weiwei, Wang Guangshu, et al. Tool wear state recognition based on deep stacking sparse denoising auto-encoder network[J]. Journal of Vibration, Measurement & Diagnosis, 2024, 44(2): 305–312, 410–411.

[56] 刘海波, 邓平, 迟庆宇, 等. 智能加工中数据使能技术与应用[J]. 机械工程学报, 2026, 62(2): 407–444.

Liu Haibo, Deng Ping, Chi Qingyu, et al. Technologies and applications of data enablement in intelligent machining[J]. Journal of Mechanical Engineering, 2026, 62(2): 407–444.

[57] 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 Runqiong, Song Qinghua, Peng Yezhen, 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.

[58] Wang R Q, Song Q H, Peng Y Z, et al. Self-adaptive fusion of local-temporal features for tool condition monitoring: A human experience free model[J]. Mechanical Systems and Signal Processing, 2023, 195: 110310.

[59] Pashmforoush F, Ebrahimi Araghizad A, Budak E. Physics-informed tool wear prediction in turning process: A thermo-mechanical wear-included force model integrated with machine learning[J]. Journal of Manufacturing Systems, 2024, 77: 266–283.

[60] Pashmforoush F, Ebrahimi Araghizad A, Budak E. Tool wear prediction in milling process using physics-informed machine learning and thermo-mechanical force model with monitoring applications[J]. Journal of Manufacturing Systems, 2025, 82: 1192–1212.

[61] Yuan D Z, Luo T, Zhang D, et al. A physics-assisted online learning method for tool wear prediction[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 3515611.

[62] Li G C, Shang X H, Yang L, et al. Milling tool wear condition monitoring based on physics-informed autoregression transformation of audio signals[J]. IEEE Sensors Journal, 2025, 25(23): 42540–42549.

[63] Liu D L, Liu Z Q, Wang B, et al. Challenges of randomness in tool wear with small samples: A physics-informed cross-domain monitoring method[J]. Journal of Manufacturing Systems, 2025, 80: 694–722.

[64] 张雷, 刘检华, 庄存波, 等. 数字孪生机床的内涵、体系架构及关键技术[J]. 计算机集成制造系统, 2023, 29(6): 1983–1995.

Zhang Lei, Liu Jianhua, Zhuang Cunbo, et al. Connotation, architecture and key technologies of digital twin machine tools[J]. Computer Integrated Manufacturing Systems, 2023, 29(6): 1983–1995.

[65] Zhang X, Wang X Q, Zhang P F, et al. Fast extraction of cutter-workpiece engagement for milling force prediction in multi-axis machining[J]. Measurement, 2024, 231: 114490.

[66] Qiu T Z, Dai B F, Xiao W L, et al. An efficient online geometric simulation algorithm for real-time CNC machining process based on look-ahead method[J]. Journal of Manufacturing Systems, 2025, 80: 108–125.

[67] Kang N S, 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.

[68] Zhou J, Liu X Y, Liao Q H, et al. Multi-sensor heterogeneous signal fusion transformer for tool wear prediction[J]. Sensors, 2025, 25(15): 4847.

[69] Qiu T Z, Liu Y, Xiao W L, et al. STEP-compliant CNC system featuring real–time material removal simulation for online tool wear monitoring[J]. Journal of Manufacturing Systems, 2025, 83: 904–922.

[70] Wang Z C, Lu Y, Deng K N, et al. Physics-informed self-supervised learning for tool wear monitoring leveraging signal and degradation features under limited labels[J]. Advanced Engineering Informatics, 2025, 67: 103503.

[71] Chen Z X, Zhang J, Qin F Z, et al. PIDGGCN: A novel physics-informed deep learning framework for tool wear monitoring[J]. Advanced Engineering Informatics, 2025, 68: 103790.

[72] Li S S, Li J, Zhu K P. Application of physics-guided deep learning model in tool wear monitoring of high-speed milling[J]. Mechanical Systems and Signal Processing, 2025, 224: 111949.

[73] Peng Y Z, Kang W M, Yu F W, et al. Edge device deployment for intelligent machine tools: A lightweight and interpretable tool wear monitoring method considering wear behavior[J]. Robotics and Computer-Integrated Manufacturing, 2025, 95: 103033.

[74] Xu H T, Wang W, Sun J, et al. Physics-informed graph convolutional neural networks with weighted adaptive loss for tool wear prediction under variable working conditions[J]. Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture, 2026, 240(10): 1937–1950.

[75] Hua J Q, Li Y G, Liu C Q, et al. Physics-informed neural networks with weighted losses by uncertainty evaluation for accurate and stable prediction of manufacturing systems[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(8): 11064–11076.

[76] Kim G, Yang S M, Jeon S, et al. Robust tool wear prediction under novel operating conditions via physics-guided unsupervised domain adaptation[J]. Advanced Engineering Informatics, 2026, 69: 103883.

[77] 陈安航, 张海霞, 袁东风, 等. 数据机理双模型融合的刀具磨损监测方法[J]. 机械工程学报, 2026, 62(4): 37–51.

Chen Anhang, Zhang Haixia, Yuan Dongfeng, et al. Data-mechanism dual-model fusion method for tool wear monitoring[J]. Journal of Mechanical Engineering, 2026, 62 (4): 37–51.

[78] Gao T H, Zhu H P, Wu J, et al. Hybrid physics data-driven model-based fusion framework for machining tool wear prediction[J]. The International Journal of Advanced Manufacturing Technology, 2024, 132(3): 1481–1496.

[79] 朱昀, 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]. 机械工程学报, 2026, 62(9): 238–253.

Zhu Yun, Li Fangchun, Li Junlong, et al. Tool wear prediction method based on mechanism-data fusion[J]. Journal of Mechanical Engineering, 2026, 62(9): 238–253.

[80] Fang X H, Song Q H, Li X X, et al. A cutting tool wear data-physics fusion-driven monitoring method[J]. International Journal of Mechanical Sciences, 2025, 301: 110526.

[81] Li Y F, Xiang Y Y, Pan B S, et al. A hybrid remaining useful life prediction method for cutting tool considering the wear state[J]. The International Journal of Advanced Manufacturing Technology, 2022, 121(5): 3583–3596.

[82] Zhu K P, Li X, Li S S, et al. Physics-informed hidden Markov model for tool wear monitoring[J]. Journal of Manufacturing Systems, 2024, 72: 308–322.

[83] Li D H, Li Y G, Liu C Q. Gaussian process regression model incorporated with tool wear mechanism[J]. Chinese Journal of Aeronautics, 2022, 35(10): 393–400.

[84] Wang Z H, Zhou G H, Zhang C, et al. Physics-informed Gaussian process regression for tool wear monitoring with uncertainty quantification[J]. Reliability Engineering & System Safety, 2026, 268: 111984.

[85] Qiang B Y, Shi K N, Liu N, et al. Integrating physics-informed recurrent Gaussian process regression into instance transfer for predicting tool wear in milling process[J]. Journal of Manufacturing Systems, 2023, 68: 42–55.

[86] Zhu K P, Guo H, Li S, et al. Physics-informed deep learning for tool wear monitoring[J]. IEEE Transactions on Industrial Informatics, 2024, 20(1): 524–533.

[87] Li Y L, Wang J J, Huang Z G, et al. Physics-informed meta learning for machining tool wear prediction[J]. Journal of Manufacturing Systems, 2022, 62: 17–27.

[88] Gao Z L, Chen N, Li L. A novel algorithm for tool wear monitoring utilizing model and knowledge-guided multi-expert weighted adversarial deep transfer learning[J]. Mechanical Systems and Signal Processing, 2025, 228: 112456.

[89] Li G C, Xu S X, Jiang R, et al. Physics-informed inhomogeneous wear identification of end mills by online monitoring data[J]. Journal of Manufacturing Processes, 2024, 132: 759–771.

[90] Mao Z, Luo M, Zhang D H. Tool wear prediction through a physics-assisted method using few-sensor monitoring data[J]. The International Journal of Advanced Manufacturing Technology, 2025, 139(3): 1645–1660.

[91] Huang W J, Zhang X Y, Wu C Q, et al. Tool wear prediction in ultrasonic vibration-assisted drilling of CFRP: A hybrid data-driven physics model-based framework[J]. Tribology International, 2022, 174: 107755.

[92] Zhang Y, Zhu K P. Tool wear estimation with a data-driven physics coupling approach[J]. Manufacturing Letters, 2022, 34: 38–42.

[93] Sun M J, Wang X D, Guo K, et al. Tool wear monitoring based on physics-informed Gaussian process regression[J]. Journal of Manufacturing Systems, 2024, 77: 40–61.

[94] 王一帆, 孙江, 杨恒, 等. 基于深度迁移学习的跨工况在线刀具磨损预测[J]. 组合机床与自动化加工技术, 2025(1): 160–164.

Wang Yifan, Sun Jiang, Yang Heng, et al. A method for predicting tool wear in different working conditions online based on deep transfer learning[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2025(1): 160–164.

[95] Cheng M H, Yan P, Liang G X, et al. A novel inherent information constrained unsupervised domain adaptation with feature conversion for tool wear monitoring under variable cutting conditions[J]. Measurement, 2025, 256: 118323.

[96] 赖旭伟, 丁昆, 张楷, 等. 基于可解释物理引导空间注意力改进的跨工艺参数立铣刀磨损辨识[J]. 机械工程学报, 2024, 60 (12): 147–157.

Lai Xuwei, Ding Kun, Zhang Kai, et al. Improved interpretable-based physically guided spatial attention for cross-process parameters end milling cutter wear identification[J]. Journal of Mechanical Engineering, 2024, 60(12): 147–157.

[97] 卢志强, 朱海平, 吴军. 基于元学习与多头注意力的刀具磨损值预测[J]. 计算机集成制造系统, 2024, 30(10): 3588–3599.

Lu Zhiqiang, Zhu Haiping, Wu Jun. Prediction of tool wear value based on meta-learning and multi-head attention[J]. Computer Integrated Manufacturing Systems, 2024, 30 (10): 3588–3599.

[98] 耿博文. 基于数字孪生技术的框梁类薄壁件加工变形监控研究[D]. 哈尔滨: 哈尔滨理工大学, 2024.

Geng Bowen. Research on machining deformation monitoring of frame beam thin-walled parts based on digital twin technology [D]. Harbin: Harbin University of Science and Technology, 2024.

[99] 戚浩, 李晓月, 陶强, 等. 数字孪生驱动的机械工艺系统研究进展[J]. 航空学报, 2024, 45(21): 628970.

Qi Hao, Li Xiaoyue, Tao Qiang, et al. Research progress of mechanical process system driven by digital twin[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45 (21): 628970.

[100] Wang Z H, Zhou G H, Zhang C, et al. A tool wear prediction model integrating mechanism-data fusion with transfer learning for machine tool digital twins[J]. Robotics and Computer-Integrated Manufacturing, 2026, 100: 103235.

[101] 朱博彦, 朱建阳, 张兵. 基于FPGA的机床刀具磨损监测系统研究与设计[J]. 中国仪器仪表, 2024(11): 27–33.

Zhu Boyan, Zhu Jianyang, Zhang Bing. Research on tool wear monitoring system of machine tool based on FPGA[J]. China Instrumentation, 2024(11): 27–33.

[102] 周紫璇, 朱传军, 付强, 等. 基于数字孪生的刀具磨损检测方法[J]. 机床与液压, 2025, 53(18): 117–123.

Zhou Zixuan, Zhu Chuanjun, Fu Qiang, et al. Tool wear detection method based on digital twin[J]. Machine Tool & Hydraulics, 2025, 53 (18): 117–123.

# Tool Wear Monitoring Based on Physics-Guided Deep Learning: Methods, Challenges, and Prospects

CHEN Zhixiang[1,2], ZHANG Jin[1,2], TAO Guibao[1,2], QIN Fengze[1,2], CAO Huajun[1,2]

(1. College of Mechanical and Vehicle Engineering, Chongqing University, Chongqing 401331, China;
2. State Key Laboratory of Mechanical Transmissions for Advanced Equipment,
Chongqing University, Chongqing 401331, China)

**[ABSTRACT]** Cutting tools are known as the "teeth of machine tools", and their wear state directly affects machining efficiency and workpiece quality. Physical model–based tool wear monitoring (TWM) methods are limited by the ideal assumptions made during the modeling process and are difficult to adapt to actual machining scenarios. Although deep learning networks based on data models can learn the nonlinear changes in the tool wear process, their monitoring accuracy is highly dependent on the quantity and quality of training samples. Furthermore, their "black box" nature lacks physical transparency, limiting the credibility of the monitoring results. A hybrid driven method that integrates physical information and deep learning offers a new solution. This paper reviews tool degradation modes and common sensor types, and summarizes physical modeling of tool wear and sensing information acquisition and preprocessing techniques. Subsequently, it summarizes the physical information fusion strategies in current physics–guided deep learning (PGDL) methods. Finally, it clarifies the challenges of existing methods for engineering applications and provides insights into future development directions.

**Keywords:** Tool wear; Physics-guided deep learning; Remaining useful life prediction; State recognition; Trustworthy machining

（责编　晓月）