**引文格式：**施云高，李申申，朱锟鹏.机理指导的潜力模型及其在刀具磨损状态监测中的应用[J]. 航空制造技术，2026，69(20)：26020206.

SHI Yungao, LI Shenshen, ZHU Kunpeng. Mechanism-guided latent force modeling for tool wear monitoring[J]. Aeronautical Manufacturing Technology, 2026, 69(20): 26020206.

# 机理指导的潜力模型及其在刀具磨损状态监测中的应用

施云高[1,2]，李申申[1,3]，朱锟鹏[1,2,3]

（1. 常州先进制造技术研究所，常州 213164；
2. 中国科学院合肥物质科学研究院智能机械研究所，合肥230031；
3. 武汉科技大学，武汉 430081）

[摘要] 在精密切削中，刀具磨损会改变刀具–工件接触状态，进而引起切削力波动、尺寸误差累积和表面质量退化，最终影响加工过程的一致性与可靠性。针对传统机理模型受理想化假设限制、数据驱动模型对输入噪声和工况分布变化敏感的问题，提出一种物理引导潜力模型用于刀具磨损在线监测。具体而言，采用状态空间模型显式表征加工过程中刀具状态的演化过程，将切削力视为系统的外部输入，并赋予其高斯过程先验；同时，依据切削机理设计物理信息协方差函数，以增强模型对复杂加工行为的表征能力。进一步地，构建由磨损演化机理引导的在线参数更新策略，以降低系统建模偏差并抑制多步预测误差累积。试验结果表明，所提方法在多工况下的平均绝对百分比误差和平均绝对误差分别为3.17%和1.57 μm，具有较好的预测精度和稳定性，可为航空精密铣削过程中的刀具状态监测与质量控制提供方法支撑。

**关键词：**精密铣削；刀具状态监测；状态空间模型；机理指导的潜力模型（PG–LFM）；在线更新策略

**中图分类号：**V2；TH165　　**文献标志码：**A　　**DOI:** 10.16080/j.issn1671-833x.26020206



施云高

高级工程师，研究方向为精密加工、智能制造及刀具状态监测。

航空结构件、发动机关键零部件及精密功能构件通常具有材料难加工、结构复杂、尺寸精度要求高和加工批量小等特点[1–2]。特别是在薄壁件、微小特征和复杂曲面加工过程中，刀具磨损会直接改变刀具实际切削刃几何形貌，引起切削力波动、加工热增加、尺寸误差累积和表面完整性退化，进而影响航空零件的加工一致性与服役可靠性[3–4]。因此，面向航空精密数控加工过程建立稳定的高精度刀具状态监测方法，是实现加工质量稳定控制和智能工艺调整的重要基础。

现有刀具磨损状态监测方法主要包括机理模型、数据驱动模型和机理–数据融合模型[5]。机理模型通常依据金属切削理论、磨损定律及经验或半经验公式，建立切削条件、力热载荷与刀具磨损响应之间的可解释映射关系[6]。Laakso等[7]基于磨损率演化提出了一种对数形式模型，该模型在切削条件明确的情况下具有较好地解析预测能力。为刻画磨损演

**收稿日期：**2026–05–30；**退修日期：**2026–06–19；**录用日期：**2026–07–08

**通信作者：**李申申，博士研究生，研究方向为精密加工、动力学建模、刀具状态监测。
朱锟鹏，研究员，博士生导师，研究方向为精密微铣削加工理论与智能控制技术、金属增材制造技术。

化过程的阶段性特征，Zhu等[8]采用分段建模策略，分别利用对数函数和多项式函数表征不同磨损阶段，从而扩展了模型的适用性。张子奇等[9]结合切削试验、SEM与XRD表征，剖析TiAlN涂层硬质合金刀具车削过程不同阶段的磨损机理，明确各阶段主导磨损类型，并结合磨损率模型提出对应的刀具磨损控制方法。徐锦泱等[10]应用有限元仿真方法研究了不同刀具磨损形态对钛合金切削过程的影响规律。这类模型能够较好地反映刀具磨损的物理本质，并具有较强的可解释性。然而，其模型结构通常依赖理想化假设、简化边界条件和固定材料参数，难以充分表征实际加工过程中的复杂扰动[11]。尤其在航空复杂构件加工中，薄壁结构、复杂曲面、弱刚性特征和难加工材料会导致切削力波动、热–力耦合增强、系统刚度时变以及局部振动加剧，使刀具磨损演化呈现显著的非线性和动态不确定性。因此，单一物理模型在航空构件真实加工环境中的工况适应性和预测精度仍然受到限制。

数据驱动方法主要利用机器学习和深度学习技术，从切削力、振动、声发射、温度和主轴功率等多源监测信号中学习特征表征与磨损状态之间的高维映射关系，从而实现刀具磨损预测[12]。此类方法减少了对显式机理建模的依赖，并可通过非线性特征学习提高复杂信号的表征能力[13–15]。早期研究多采用支持向量回归等方法建立人工特征与磨损量之间的回归关系[16]。随后，隐马尔可夫模型[17–18]、卷积神经网络[19]、残差网络[20]和长短期记忆网络[21]等方法被用于磨损阶段识别、时序特征建模和多步预测。此外，高斯过程模型能够提供预测均值和不确定性区间，在小样本建模中具有一定优势[22–23]。例如，刘洪成等[23]通过高斯过程对刀具磨损物理模型中的未知参数进行概率建模，避免了显式参数辨识。尽管数据驱动方法在复杂信号建模方面具有优势，但其预测性能高度依赖训练数据的覆盖范围和分布一致性。对于航空构件加工而言，典型零件通常具有小批量、多品种、高价值和工况差异大的特点，难以获取充分的全寿命标注数据。同时，数据模型的黑箱特性使其难以解释输入信号、加工机理与磨损预测结果之间的因果关系，不利于航空制造中对质量控制可靠性、过程可追溯性和决策可信性的要求。因此，纯数据驱动模型在航空复杂构件刀具状态监测中的泛化能力、稳定性和工程可信度仍存在不足。

为兼顾机理模型的可解释性与数据驱动模型的自适应能力，机理–数据融合方法逐渐成为刀具状态监测的重要发展方向[24]。现有研究主要通过物理特征输入、物理约束损失函数和决策级融合等方式引入加工机理知识，以缓解纯数据模型的“黑箱”问题，并提升机理模型对复杂工况的适应能力。物理特征输入方法通过将与刀具磨损机制相关的加工参数[25]、退化特征[26–27]或多物理场特征[28–29]等引入模型训练，来增强数据表征的物理含义。该方法无需改变模型架构，主要在特征层面提升模型的可解释性、泛化能力和小样本适应性，并可通过仿真数据或半监督学习缓解真实数据不足与分布不均问题。物理约束损失函数方法通常将刀具磨损或性能退化规律转化为正则化项嵌入模型训练过程，以抑制纯数据驱动模型产生非物理预测。Wang等[30–31]将工具磨损演变的单调性规律纳入损失函数，强制要求磨损量随加工时间增加而增大。Zhu等[32]进一步优化了该框架，通过量化磨损、切削参数与振动信号之间的物理关系，并优化损失函数中约束权重的分配，从而提升了模型在复杂切削条件下的稳定性。决策级融合方法通常以机理模型或经验模型生成可解释的初始预测结果，再利用数据驱动模型进行校正与融合。典型方式包括代理建模[33]、残差补偿[34–35]和概率融合[36–38]。代理模型用于近似复杂物理机制并降低计算成本；残差补偿通过学习基线模型与实测结果之间的偏差提升预测精度；概率融合则借助卡尔曼滤波、粒子滤波等贝叶斯方法实现状态递推、在线修正和不确定性量化。尽管上述混合模型在一定程度上缓解了数据驱动模型中先验知识嵌入不足的问题。但这类方法多侧重于模型输入、输出或训练过程的局部约束，尚未充分从模型结构层面刻画切削力与刀具磨损之间的动态耦合关系。对于航空精密铣削中常见的小样本、多工况和在线监测需求，仍需构建一种能够同时表征演化机理、实时监测和预测不确定性的混合建模方法。

基于上述分析，本研究提出一种机理指导的潜力模型，从模型结构的角度，有效解决了机理模型在实际加工中预测精度不足和数据驱动模型预测结果对输入噪声分布敏感的不足。首先，基于金属切削理论与刀具磨损机理模型构建描述切削力与刀具磨损动态耦合关系的状态空间模型；然后，基于高斯过程的线性叠加特性，将刀具磨损状态空间模型与非参数高斯过程建模的潜在力函数相结合，构建反映刀具磨损动态演化的潜在力模型；最后，为缓解小样本条件下模型训练不足的问题，将刀具磨损状态演化机理作为先验物理知识嵌入等效高斯过程回归框架中，实现刀具磨损的在线参数更新与概率预测。

## 1 机理指导的潜力模型

面对航空精密构件中微小特征、微槽结构等对刀具状态高度敏感的应用场景，刀具磨损的准确监测是保障加工精度、表面质量和过程稳定性的前提。然而，传统刀具磨损机理模型通常依赖理想化假设和固定参数，

虽具有较好可解释性，但难以充分描述精密铣削过程中由微尺度效应、材料局部非均匀性和系统振动等因素引起的非线性扰动与时变不确定性；纯数据驱动模型虽具备较强的非线性拟合能力，但对噪声、样本规模和工况分布变化敏感，在小样本、多工况条件下容易出现预测稳定性不足的问题。

针对上述问题，本研究通过将加工过程中刀具磨损的先验知识以状态空间形式嵌入高斯过程模型，构建机理指导的潜在力模型（Physics-guided latent force model，PG-LFM），实现对刀具磨损状态的精确预测。如图1所示，该框架首先基于铣削数据中包含的加工机理知识，建立刀具磨损动态演化的状态空间模型，从而利用高斯过程的线性叠加特性，构建以状态空间模型为框架高斯过程驱动的潜力模型（LFM），用于刀具磨损状态的估计。基于潜在力时空演化特性，针对性地构建包含先验知识的复合协方差函数。基于刀具磨损物理模型与当前预测的磨损状态，递推下一时刻刀具状态。同时通过引入物理模型的预测结果不断调整训练数据集，持续对模型参数进行微调，最终形成闭环优化机制，实现刀具磨损状态的精确预测。该方法在模型结构层面实现了机理与数据驱动建模的深度融合，从而提高了预测结果的物理一致性和预测精度。后续章节将对所提出的建模框架进行详细阐述。

### 1.1 刀具磨损演化的状态空间建模

在精密加工中，刀具磨损是一种随时间连续演化的动态现象，其状态变化共同受到切削条件、材料性能以及刀具–工件相互作用的影响。由于磨损状态难以在线直接测量，且其演化过程具有显著的时间相关性和累积效应，因此，在不完全观测条件下有效表征刀具磨损状态，是实现高精度监测与预测的关键挑战。状态空间建模通过引入潜在变量，为解决这一问题提供了一种系统的数学框架，使不可观测的磨损状态能够与可测量的切削力信号建立动态关联。本研究采用状态空间模型显式表征刀具状态演化，并将切削力作为系统外部输入引入模型。同时，设计物理信息协方差函数以表征切削力的时变特征，从而在保证物理一致性的基础上提升模型表征灵活性。

需要基于明确的物理机理描述磨损状态的时间变化，为表征加工过程中后刀面磨损的演化过程。根据Archard磨损定律，刀具体积磨损率与接触载荷和相对滑动速度密切相关。其中，进给方向切削力可用于表征后刀面接触区域的载荷水平，而刀具后刀面与已加工表面之间的相对滑动速度主要由切削运动学决定。因此，进给方向切削力和相对滑动速度可视为驱动后刀面磨损演化的主要物理因素。在此基础上，刀具磨损状态的演化过程可进一步建模为一阶连续时间动力系统，其控制微分方程可表示为

$$\omega b\frac{\mathrm{d}\omega}{\mathrm{d}t}=\frac{A}{H}F_{\mathrm{f}}V_{\mathrm{s}} \tag{1}$$

式中，$\omega$为刀具后刀面磨损宽度；$b$为切削深度；$H$为刀具材料的硬度；$V_{\mathrm{s}}$为滑动速度；$F_{\mathrm{f}}$为刀具侧面与工件之间的切削进给力；$A$为等效磨损系数，用于等效切削热引起的材料硬度下降、界面摩擦特性改变等未显式建模部分。

将刀具磨损值作为加工过程的状态变量，系统的状态空间表示如下。

$$\begin{cases}\dot{\omega}(t)=B_{\mathrm{c}}F_{\mathrm{f}}(t)/\omega(t)\\ O(t_k)=\omega^2(t_k)+v_k\end{cases} \tag{2}$$

式中，$B_{\mathrm{c}}=\dfrac{A}{Hb}V_{\mathrm{s}}$；$O(\cdot)$为观察状态；$v_k$为观测噪声；$t$为连续时间；$k$为离散采样序号；$\Delta t=k\Delta t$，$\Delta t$为时间步长。

考虑到数值实现的可行性，在零阶保持假设下，将式（2）所表示的连续时间动态模型转换为时间步长为$\Delta t$的离散时间动态模型。假设输入在每个采样间隔$\Delta t$内保持恒定，则可得

$$F_{\mathrm{f}}(t)=F_{\mathrm{f}k},\ t\in[k\Delta t,\ (k+1)\Delta t] \tag{3}$$

式中，$F_{\mathrm{f}k}$为第$k$个采样间隔保持层。将微分方程两边同时乘以$\omega$

$$\omega\dot{\omega}=\frac{\mathrm{d}}{\mathrm{d}t}\left(\frac{1}{2}\omega^2\right)=B_{\mathrm{c}}F_{\mathrm{f}k} \tag{4}$$

积分可得

$$\omega_k^2=\omega_{k-1}^2+2B_{\mathrm{c}}\Delta tF_{\mathrm{f}k-1} \tag{5}$$

因此，

$$\begin{cases}\omega_k=\sqrt{\omega_{k-1}^2+2B_{\mathrm{c}}\Delta tF_{\mathrm{f}k-1}}\\ O_k=\omega_k+v_k\end{cases} \tag{6}$$

式中，$\Delta t$表示离散时间步长，并设置为与试验采样间隔相同。对于刀具磨损演化的状态空间模型如图2所示。

### 1.2 精密加工切削力建模

在金属切削加工中，刀具磨损主

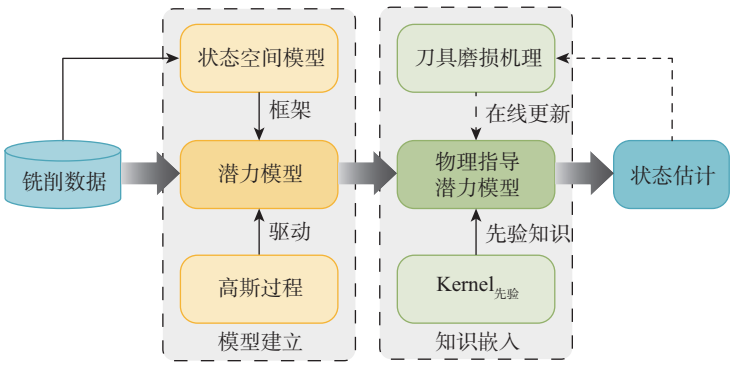



**图1 用于刀具磨损估计的机理引导潜在力模型（PG-LFM）架构**

**Fig.1 Prediction architecture of the mechanism-guided latent force model (PG-LFM) for tool wear estimation**

要由刀具与工件接触界面上的热–力耦合作用驱动。前刀面与切屑界面和后刀面与已加工表面界面上的接触压力、摩擦滑移等共同影响磨损机制的演化。切削力作为刀具与工件相互作用的宏观响应，能够间接反映界面载荷、摩擦状态和材料去除行为的变化，因此可用于表征刀具磨损的演化趋势。考虑到本文的研究重点是构建面向刀具磨损在线预测的低阶物理引导模型，而非建立完整三维切削力解析模型，因此本研究采用经典正交切削模型对三维复杂切削过程进行合理简化，以提取切削力、接触载荷、相对滑动速度与刀具磨损状态之间的主导物理关系。该模型基于以下理想化假设：(1)刀尖锋利度满足理想正交条件(刃口半径趋近于零)；(2)塑性变形严格限制在二维平面内，忽略切屑侧流效应；(3)应变梯度效应服从平面应变假定。在此基础上，切削合力$F_R$可表示为

$$F_R=\sqrt{F_x^{\,2}+F_y^{\,2}}=\frac{F_S}{\cos(\phi_c+\beta_a-\alpha_r)}=\tau_s bh\frac{1}{\sin\phi_c\cos(\phi_c+\beta_a-\alpha_r)} \tag{7}$$

式中，$F_x$和$F_y$分别为$x$和$y$方向的铣削分量；$\tau_s$，$\phi_c$，$\beta_a$，$\alpha_r$分别为剪切面上的剪切屈服应力、剪切角、刀具与切屑间的摩擦角和刀具前角；$h$和$b$分别是未切削的切屑厚度和切削宽度，切向力$F_t$和进给力$F_f$与切削合力$F_R$的关系可以表示为

$$\begin{cases}F_t=F_R\cos(\beta_a-\alpha_r)\\F_f=F_R\sin(\beta_a-\alpha_r)\end{cases} \tag{8}$$

将式(7)代入式(8)，可得到切向力$F_t$和进给力$F_f$与刀具几何参数、切削条件、加工过程及工件材料之间的关系如下。

$$\begin{cases}F_t=\tau_s bh\dfrac{\cos(\beta_a-\alpha_r)}{\sin\phi_c\cos(\phi_c+\beta_a-\alpha_r)}\\F_f=\tau_s bh\dfrac{\sin(\beta_a-\alpha_r)}{\sin\phi_c\cos(\phi_c+\beta_a-\alpha_r)}\end{cases} \tag{9}$$

### 1.3 基于高斯过程的潜在力建模

潜在力模型将机理驱动的状态空间模型与非参数高斯过程(GP)相结合，用于对复杂动力系统进行联合建模。在本研究中，潜在力模型将切削力驱动的状态空间模型与高斯过程相结合，使由切削热、振动、材料局部非均匀性等因素引起的未能显式建模扰动，能够在力信号和磨损观测数据的约束下被概率化表征。通过将传统参数化模型扩展为半参数化形式，从而克服固定参数模型在表征能力上的局限性。

针对刀具磨损演化过程，构建了式(2)所描述的混合状态空间模型。该模型由连续时间动态方程和离散时间观测方程组成，并通过引入潜在力函数项，实现物理约束与数据驱动特性的深度融合。对于刀具与工件之间的切削进给力$F_f$可表示为

$$F_f(t)\sim\mathrm{GP}(0,\boldsymbol{K}_{ff}(t,t')) \tag{10}$$

式中，$\boldsymbol{K}_{ff}(t,t')$为协方差矩阵，由Matérn核函数和周期核函数共同构成。

对于式(2)所构成的连续时间状态空间方程的解可以被表示为

$$\omega^2(t)=\omega_0{}^2+2B_c\int_0^t F_f(\tau)\mathrm{d}\tau \tag{11}$$

式中，$\omega_0$为初始状态。

因此，$\omega^2(t)$的协方差函数，可以通过式(12)计算得出。

$$K_{\omega^2\omega^2}(t,t')=E[\omega^2(t),\omega^2(t')]-E[\omega^2(t)]E[\omega^2(t')]=4B_c^2\int_0^t\int_0^{t'}\boldsymbol{K}_{\mathrm{ff}}(s,s')\,\mathrm{d}s\mathrm{d}s' \tag{12}$$

在高斯分布假设下，观测状态$\omega^2(t)$的均值和协方差函数可表示为

$$\begin{cases}\mu_\omega(t)=\omega_0^2\\K_{\omega^2\omega^2}(t,t')=4B_c^2\int_0^t\int_0^{t'}\boldsymbol{K}_{\mathrm{ff}}(s,s')\,\mathrm{d}s\mathrm{d}s'\end{cases} \tag{13}$$

综上所述，对于由式(2)和式(13)定义的铣削系统，其状态空间模型可等效表示为高斯过程回归模型，即

$$O(t_k)=\omega^2(t_k)+v_k \tag{14}$$

$$\omega^2(t)\sim\mathrm{GP}\left(\omega_0^2,4B_c^2\int_0^t\int_0^{t'}\boldsymbol{K}_{\mathrm{ff}}(s,s')\,\mathrm{d}s\mathrm{d}s'\right) \tag{15}$$

刀具磨损状态$\omega(t)$的均值($\mu_\omega(t)$)和协方差函数($K_{\omega\omega}(t,t')$)可以被表示为

$$\begin{cases}\mu_\omega(t)=\left|\sqrt{\omega^2(t)}\right|\\K_{\omega\omega}(t,t')=-\mu_\omega^2(t)+\sqrt{\mu_\omega^4(t)+K_{\omega^2\omega^2}(t,t')/2}\end{cases} \tag{16}$$

式中，$t$与$t'$分别为两个时间输入。

在贝叶斯优化框架下，可通过最大化对数边际似然来选择超参数。具体而言，将超参数视为具有先验分布的随机变量。随后，通过对模型参数进行积分消去，计算训练数据的对数边际似然。最后，通过最大化该对数边际似然获得最优超参数。

### 1.4 物理引导的在线参数更新策略

在加工过程中，由于人为因素和环境变化，训练好的模型与实际运行

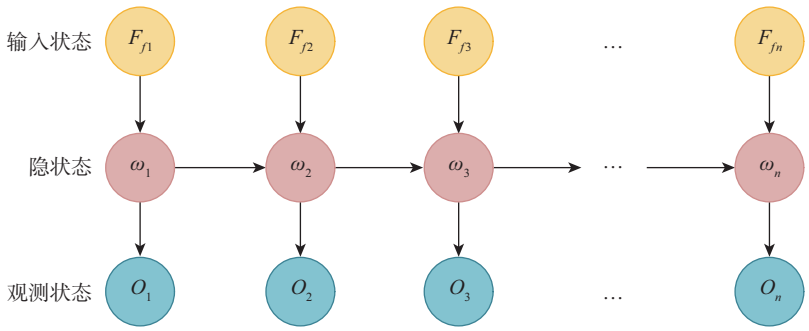



图2 刀具磨损演化状态空间模型

Fig.2 State-space model of tool wear evolution

条件之间可能存在偏差，且在线阶段无法获取真实磨损标签。递归参数更新为在不增加训练数据集规模的情况下提高预测精度提供了一种有效途径。为应对此类时变不确定性，本文提出了一种在线参数更新策略，通过刀具磨损状态之间的演化关系递推生成带物理约束的磨损估计值（伪标签），构建了潜在力模型的在线参数更新策略，增强航空精密加工小样本条件下磨损预测的可靠性和置信度。其相应伪代码如表1所示。该策略首先根据当前时刻的磨损预测结果，利用相邻磨损状态之间的演化关系估计下一时刻的刀具磨损状态；随后，将由物理模型估计得到的磨损状态与新采集的监测数据共同引入模型参数的递归更新过程，并保持训练样本数量 $N$ 不变。通过这种方式，模型能够适应连续变化的加工条件。对于相邻刀具磨损状态之间的关系，Zhu等[8]提出的可调系数模型可表示为

$$\omega_{n+1}=G(\omega_n)=\omega_n+h(1/6K_1+2/6K_2+2/6K_3+1/6K_4) \tag{17}$$

$$K_1=F(t_n,\omega_n) \tag{18}$$

$$K_2=F(t_n+1/2\,h,\omega_n+1/2\,hK_1) \tag{19}$$

$$K_3=F(t_n+1/2\,h,\omega_n+1/2\,hK_2) \tag{20}$$

$$K_4=F(t_n+h,\omega_n+hK_3) \tag{21}$$

$$F=\left[AB/(Bt+1)+CDt^{D-1}\right]/\left(A\ln(Bt+1)+Ct^D\right)\omega \tag{22}$$

式中，$\omega_{n+1}$ 和 $\omega_n$ 为相邻刀具磨损状态；$h$ 为刀具磨损固定采样时间间隔；$n$ 为时间步序号；$K_1$、$K_2$、$K_3$、$K_4$ 为四阶 Runge-Kutta 法的四个阶段斜率；$F(t,\omega)$ 为磨损演化速率函数；$A$、$B$、$C$、$D$ 为经验模型拟合参数。

基于前述理论推导与分析，本文提出的混合潜在力建模方法将式（2）中定义的潜在未知输入建模问题，重新表述为式（15）所给出的高斯过程回归模型。如图3所示，刀具磨损状态演化状态空间模型中的未知输入项采用非参数高斯过程进行表征，从而实现机理知识与数据驱动信息的深度融合。通过克服传统纯数据驱动方法的局限性，所提出的方法主要具有以下两方面优势。

（1）通过先验分析未知输入的时空演化特性，可针对性地构建复合协方差结构，从而将工艺机理知识显式编码至核函数超参数中，有效缓解了纯黑箱模型的过拟合风险。

（2）将高斯过程回归的协方差核函数嵌入到状态空间模型的驱动信号内，构建出兼具物理约束与数据驱动特性的潜在力模型。该模型有效弥补了纯数据驱动模型在外推能力方面的局限性，为刀具磨损动态演化过程提供了一种概率化的建模方法。

## 2 模型验证与分析

### 2.1 试验设置

为验证所提出方法的有效性，在五轴高速铣削加工中心（HSM600U）上开展高速精密加工试验，如图4所示。该平台具有较高的主轴转速、运动精度和动态稳定性，能够满足微细刀具加工中高转速、小切深和微小进给的控制要求，可用于表征航空精密构件中小尺寸特征、微槽结构及局部精密加工场景。试验采用双刃硬质合金微细立铣刀，刀具直径为0.5 mm，切削刃长度为1.5 mm，表面为UT涂层，螺旋角为30°，其几何尺寸和加工尺度具有典型微铣削特征。工件材料为40CrNi2Mo钢，硬度为30HRC~40HRC，试样尺寸为30 mm×60 mm。

考虑到航空精密构件加工中常存在小批量、多工况、弱刚性特征明显及切削参数组合差异较大等特点，为提高试验数据的代表性，并分析不同切削参数对微细刀具磨损演化的影响，采用田口试验方法进行工况设计。试验选取主轴转速、轴向切削深度和每齿进给量作为主要影响因素，每个因素设置3个水平，共构建9种加工工况。所有试验均采用槽铣方式，以保证刀具–工件接触状态和材料去除形式的一致性。各工况下的铣削参数设置如表2所示。

表1 机理模型潜力模型参数在线更新伪代码

Table 1 Pseudocode for online parameter updating of mechanism-guided latent force model

| 步骤 | 内容 |
|---|---|
| 输入 | 带标签的铣削数据[$X$,$\omega$],不带标签的铣削数据[$X^*$] |
| 输出 | 刀具磨损预测值[$\omega^*$] |
| 初始化模型权重 $\theta_0$ | $\log P(\omega\mid X,\theta_0)=-\frac{1}{2}\omega^{\mathrm{T}}\left[K_{\omega,\omega}+\sigma_n^2 I\right]^{-1}\omega-\frac{1}{2}\log\left\lvert K_{\omega,\omega}+\sigma_n^2 I\right\rvert-\frac{N}{2}\log 2\pi$ |
| 循环以下操作 | （1）根据初始化模型权重 $\theta_0$，进行第 $i$ 个铣削数据 $x_i^*\in X^*$ 的预测，得到模型预测值 $\omega_i^*=\mathrm{GP}(x_i^*\mid\theta_i)$<br>（2）根据刀具磨损机理模型，预测相邻刀具磨损状态：$\omega'_{i+1}=G(\omega_i^*)$<br>（3）更新数据集：加入新样本点 $\omega'_{i+1}$，并删除旧的样本点 $\omega'_{i+1-N}$<br>（4）更新模型参数：<br>$\log P(\omega_{i+1}^*\mid x_{i+1}^*,\theta_i)=-\frac{1}{2}\omega^{\mathrm{T}}\left[K_{\omega,\omega}+\sigma_n^2 I\right]^{-1}\omega-\frac{1}{2}\log\left\lvert K_{\omega,\omega}+\sigma_n^2 I\right\rvert-\frac{N}{2}\log 2\pi$<br>（5）根据新模型参数，预测下一时刻刀具磨损状态：$\omega_{i+1}^*=\mathrm{GP}(x_{i+1}^*\mid\theta_i)$<br>（6）计算误差：$\mathrm{error}_{i+1}=\omega_{i+1}^*-\hat{\omega}_{i+1}$<br>直到切削完毕<br>返回：$\{\omega^*\}$ |

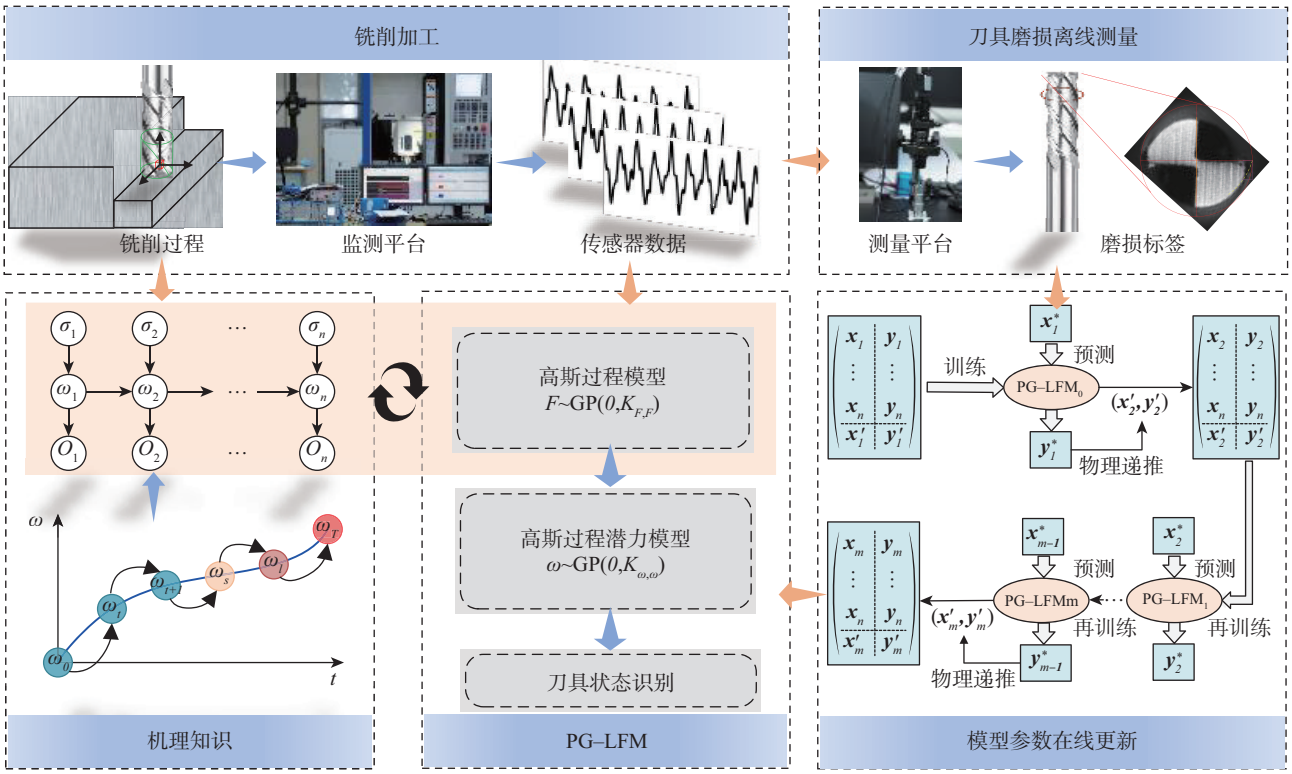
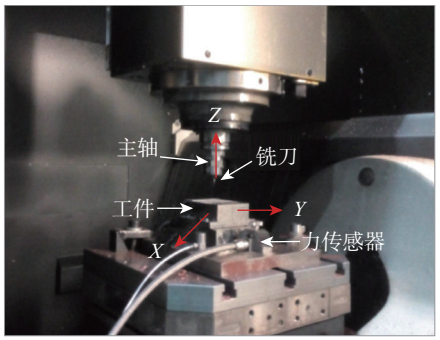
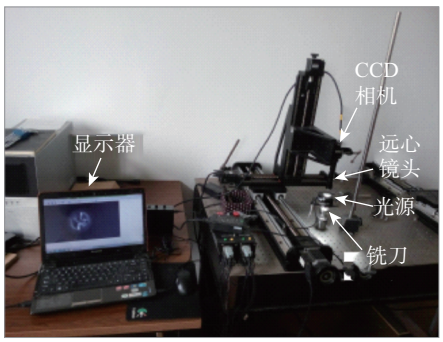



**图3　基于机理指导高斯过程潜力模型的刀具磨损预测框架**

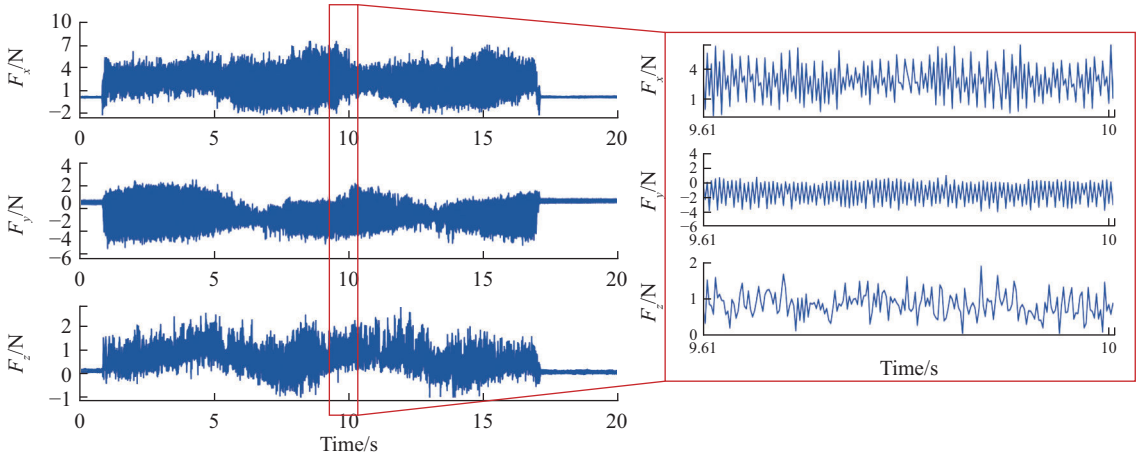
**Fig.3　Tool wear prediction framework based on mechanism-guided latent force models**




（a）铣削加工平台




（b）刀具磨损观测与测量平台




（c）实测三向切削力时域波形

**图4　高速铣削试验装置**

**Fig.4　Experimental setup of high speed milling**

在试验中，通过型号为Kistler 9119A的三方向力传感器获取铣刀在加工过程中的3个方向切削力信号（$F_x$, $F_y$, $F_z$），传感器采样频率为24 kHz。典型工况下的实测三向切削力时域波形如图4（c）所示，信号呈现刀齿与工件啮合的周期性波动趋势。加工过程中，每次切削一个长度为30 mm的槽。在走刀结束后，通过电子显微镜对刀刃后刀面的磨损值进行离线测量，该实测值仅用于模型离线训练与事后性能评价，不参与在线参数更新。表2中，“检测次数”指的是在同一刀具的寿命周期内对刀具的后刀面磨损进行检测的次数，鉴于不同工况会对磨损速率产生影响，相同型号的刀具在不同工况下的使用寿命存在差异。故而，从新刀状态加工至试验设定的刀具使用终止条件，不同工况下离线检测次数亦有所不同。

## 2.2 潜在力协方差函数的设计和选择

为准确表征刀具磨损状态空间模型中的潜在力，需要将加工机理知识与试验数据特征相结合，并系统分析潜在力的统计行为。这一分析可为协方差函数的合理选择提供理论依据。作为驱动刀具磨损状态演化的关键隐变量，潜在力的统计建模能力直接影响状态估计精度和模型泛化性能。

在铣削过程中，监测信号通常同时表现出两类典型结构特征。首先，由于刀齿与工件之间存在周期性啮合，信号中通常包含显著的周期成分，在频域中表现为齿通过频率及其谐波处的明显谱峰。这种周期结构反映了刀齿激励对系统响应的主导作用，是铣削过程固有的动态特征。其次，随着刀具磨损逐渐累积以及加工条件缓慢漂移，监测信号中还会叠加缓慢演化的趋势成分。该趋势通常表现为信号包络或统计特性的渐变，反映了由磨损机理驱动的长期演化行为，并具有较强的时间相关性和累积效应。

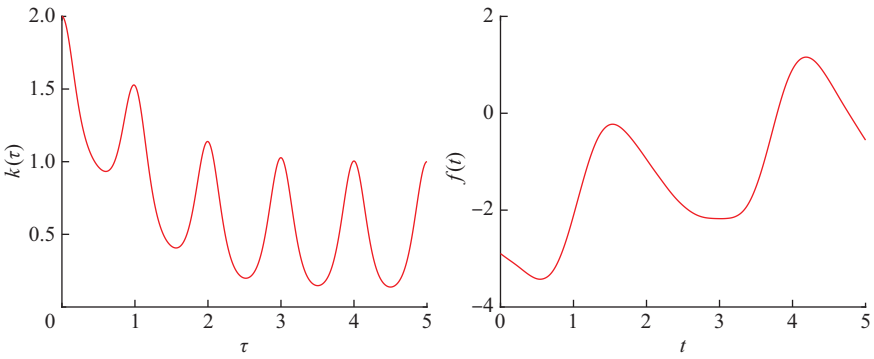
基于上述信号特征，Periodic核函数是一类专门用于表征时序信号周期性重复规律的协方差函数，其通过调控周期长度与局部平滑度参数，精准拟合具有固定重复模式的波动特性，对平稳周期性信号具有极强的表征能力。对于铣削加工过程，刀齿与工件的周期性啮合会使切削力信号呈现以齿通过频率为基频的规则波动，这一动态特性与周期核的建模特性高度匹配，因此引入周期核可精准捕捉切削力信号中的周期激励成分，有效提升模型对铣削动态特征的拟合与预测效果。然而，仅依赖周期核函数不足以描述由磨损演化引起的长期相关性和缓慢变化。相比之下，Matérn核函数由于具有可调的平滑度参数，能够在不同平滑性假设下灵活表征时间序列中的长程依赖，因此特别适合描述由刀具磨损机理驱动的缓慢演化行为。值得注意的是，在特定平滑度参数设置下，指数核函数和平方指数核函数均可视为Matérn核族的特殊情形。因此，Matérn核族为此类监测信号提供了更具一般性和统一性的建模基础。

因此，本文采用Matérn核与Periodic核线性组合的复合核函数对潜在力进行建模，Periodic核用于表征刀齿周期啮合引起的短周期波动，Matérn核用于描述磨损演化引起的长期相关性和缓慢变化。从而在统一框架下同时表征短周期波动结构和长期演化趋势。图5展示了该复合核函数的协方差函数曲线及其对应的先验采样结果。该选择在模型表征能力与推理复杂度之间取得了较好的平衡。协

表2 铣削试验参数设置

Table 2 Machining parameters of milling setting

| 工况 | 主轴转速$n$/(r/min) | 轴向切深$a_p$/μm | 每齿进给$f_t$/(μm/tooth) | 检测次数 |
|---|---|---|---|---|
| T1 | 18000 | 60 | 2 | 10 |
| T2 | 18000 | 80 | 4 | 10 |
| T3 | 18000 | 100 | 6 | 16 |
| T4 | 24000 | 80 | 6 | 16 |
| T5 | 30000 | 60 | 6 | 15 |
| T6 | 24000 | 60 | 4 | 9 |
| T7 | 24000 | 100 | 2 | 14 |
| T8 | 30000 | 80 | 2 | 10 |
| T9 | 30000 | 100 | 4 | 11 |




（a）协方差函数曲线　　（b）先验采样函数轨迹

图5 Matérn+Periodic核函数特性

Fig.5 Kernel function characteristics of Matérn+Periodic

方差函数的具体形式如下。

$$K_{\mathrm{Mat+per}}(x_p,x_q)=C_1\cdot K_{\mathrm{Mat}}(x_p,x_q)+C_2\cdot K_{\mathrm{per}}(x_p,x_q) \tag{23}$$

$$K_{Mat}\left(x_p,x_q\right)=\sigma^2\frac{2^{1-v}}{\Gamma(v)}\left(\frac{\sqrt{2v}\left|x_p-x_q\right|}{l}\right)^v K_v\left(\frac{\sqrt{2v}\left|x_p-x_q\right|}{l}\right) \tag{24}$$

$$K_{\mathrm{per}}\left(x_p,x_q\right)=\sigma^2\exp\left(-\frac{2\sin^2\left(\pi\left|x_p-x_q\right|/p\right)}{l^2}\right) \tag{25}$$

式中，$K_{\mathrm{Mat+per}}$为复合核函数；$K_{\mathrm{Mat}}$为Matérn核；$K_{\mathrm{per}}$为周期核；$x_p$、$x_q$为第$p$、$q$个采样时刻输入样本；$C_1$、$C_2$为两核权重；$\sigma^2$为信号方差；$v$为平滑度参数；$\Gamma$为伽马函数；$K_v$为$v$阶第二类修正贝塞尔函数，$l$为长度尺度。

## 3 结果与讨论

### 3.1 PG–LFM对刀具磨损状态的预测效果

基于表2所列的9组不同工况下的铣削加工试验，系统评估了所提出模型在刀具磨损状态预测中的性能。模型性能采用4项指标进行量化：平均绝对百分比误差（Mean absolute percentage error, MAPE）、平均绝对误差（Mean absolute error, MAE）、预测区间覆盖概率（Prediction interval coverage probability, PICP）和预测区间宽度（Prediction interval width, PIW）。其中，MAPE和MAE用于评价预测精度；PICP和PIW用于评价不确定性量化的可靠性和稳定性。

为充分考察模型在未知工况下的泛化能力，本文采用留一交叉验证策略。模型在MATLAB平台上实现，试验计算机配置为Windows11操作系统、AMDR5–3600 CPU和16GB内存。单次预测的平均推理时间为39 ms。考虑到现代工业控制计算机软件的数据传输频率约为4 Hz（如SIMATIC WinCC7.5的最快采集周期为250 ms），本模型的推理速度完全处于刀具磨损估计与自适应决策可接受的延迟范围之内。模型预测结果如表3和图6所示。可以看出，相较于传统物理模型及纯数据驱动模型，机理指导的潜力模型在复杂未知工况下展现出显著优势，在9种工况下混合模型预测结果的平均MAPE和MAE分别为3.17%和1.57 μm。其预测误差（MAE）相较于物理预测模型和数据驱动预测模型分别平均降低了35.12%和31.14%。

以工况T1为例，不同模型的预测结果如图7所示。物理模型的预测轨迹较为平滑（图7(a)），这是因为此模型严格遵循磨损演化方程。然而，此类物理模型通常基于既定机理、经验假设和固定参数离线构建，并采用开环方式预测刀具磨损演化，难以及时融合加工过程中的实时状态信息。当材料不均匀性、热变形、装夹误差或局部振动等未建模扰动出现时，模型预测轨迹仍主要遵循预设的磨损演化规律，因而容易产生系统偏差并随预测过程逐步累积。相比之下，本文提出的PG–LFM将在线采集的铣削力信号作为状态演化的动态输入，使加工状态变化能够反馈

表3 误差分析对照表

Table 3 Comparative of error analysis

| 工况 | MAPE/% | | | MAE/μm | | |
|---|---|---|---|---|---|---|
| | 机理模型 | 数据模型 | 混合模型 | 机理模型 | 数据模型 | 混合模型 |
| T1 | 6.50 | 7.54 | 3.23 | 3.25 | 2.30 | 1.69 |
| T2 | 4.40 | 3.70 | 2.96 | 2.05 | 2.02 | 1.39 |
| T3 | 5.55 | 8.09 | 3.72 | 2.59 | 2.98 | 1.77 |
| T4 | 3.77 | 5.93 | 3.00 | 1.73 | 1.78 | 1.46 |
| T5 | 4.81 | 6.47 | 3.41 | 2.64 | 2.43 | 1.76 |
| T6 | 5.99 | 7.99 | 2.89 | 2.53 | 2.86 | 1.71 |
| T7 | 4.68 | 5.11 | 3.37 | 2.27 | 1.92 | 1.54 |
| T8 | 7.29 | 7.23 | 3.43 | 2.47 | 2.05 | 1.54 |
| T9 | 4.41 | 7.20 | 2.53 | 2.28 | 2.19 | 1.30 |
| 平均值 | 5.27 | 6.58 | 3.17 | 2.42 | 2.28 | 1.57 |

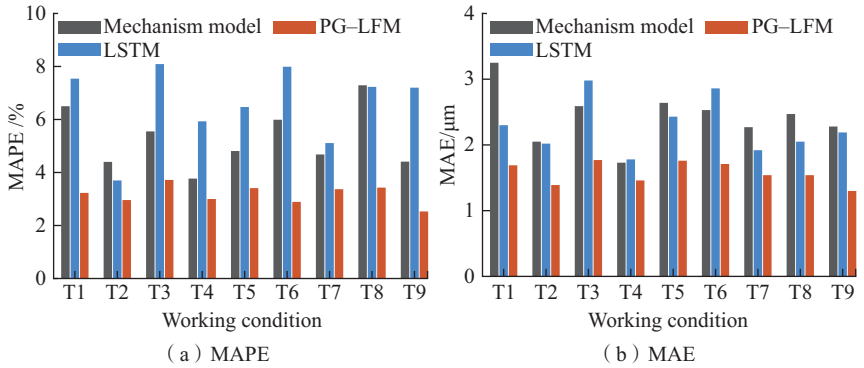



图6 不同工况下物理模型、LSTM和PG-LFM预测误差对比

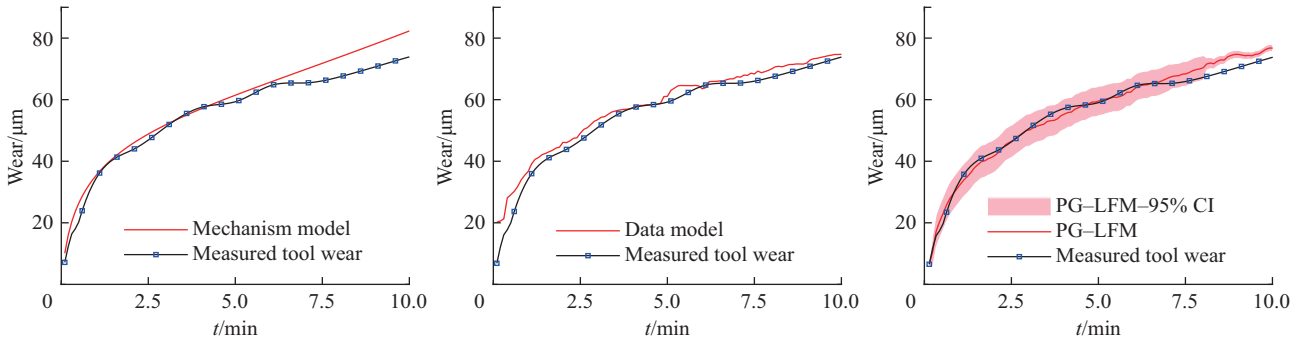
Fig.6 Comparison of prediction errors of the mechanism model, LSTM and PG-LFM under different working conditions

至磨损估计与模型参数更新过程，从而提高模型对未建模扰动的感知和自适应修正能力。此外，多数物理模型基于完整刀具寿命周期建立，而工业现场通常会在严重磨损阶段前更换刀具，这种不匹配容易导致磨损后期的系统性高估。

相比之下，纯数据驱动模型通过学习实时监测信号与磨损值之间的非线性映射关系，实现了预测轨迹的动态自修正（图7(b)）。借助在线数据反馈，其预测结果在一定程度上能够接近真实磨损演化过程。然而，此类方法对数据分布高度敏感，在小样本和工况变化条件下，纯数据驱动模型对训练数据分布及信号扰动较为敏感，预测结果可能出现局部波动。因此，为验证所提PG–LFM模型对监测信号噪声的鲁棒性，选取T1工况为例，保持训练/测试划分不变，在数据集上分别叠加SNR为20 dB、10 dB的零均值高斯白噪声开展对比测试，预测轨迹与精度指标分别如图8和表4所示。随着噪声强度升高，纯数据驱动LSTM模型的预测轨迹波动明显加剧，误差持续增大；而PG–LFM在不同工况和噪声水平下保持了相对较低的预测误差和较稳定的预测结果。其原因在于，PG–LFM并非完全依赖监测数据建立输入与磨损状态之间的统计映射，而是通过磨损演化机理和物理信息协方差函数约束模型函数空间，并利用在线参数更新修正信号扰动引起的状态偏差。

上述结果表明，物理模型和数据驱动模型在复杂加工环境中均存在性能边界。本文提出的PG–LFM通过融合显式物理建模与隐式数据驱动表征，实现了机理约束与数据建模的深度结合。一方面，物理信息被嵌入协方差结构中，用于约束模型函数空间，从而降低过拟合和欠拟合风险；另一方面，通过物理模型递推获得的实时物理量用于高斯过程超参数的在线校准，使模型能够在时变工况下保持预测稳定性和物理一致性。此外，从航空精密加工应用角度看，PG–LFM不仅能够输出刀具磨损预测值，还能够给出预测不确定性，为刀具更换、刀具补偿和加工参数调整提供置信依据。与纯数据驱动模型相比，该方法对训练样本数量的依赖较低，更适用于航空零件小批量、多品种和工况变化频繁的加工场景。

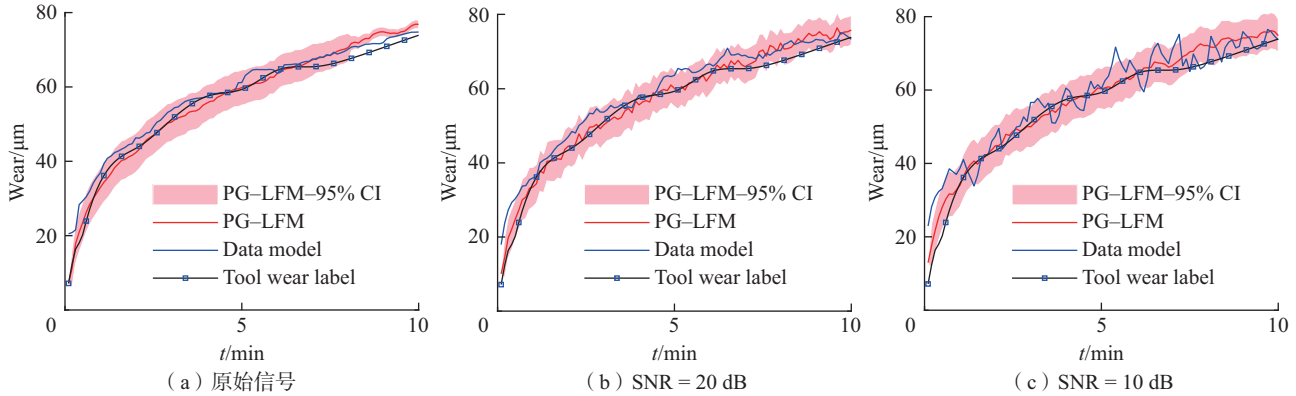
需要指出的是，本文所提方法面向刀具正常渐进磨损过程建立，当刀具发生崩刃等突发性失效时，原有切削机理与磨损演化模型不再适用。然而，崩刃属于突发性刀具失效，会引发监测信号的显著突变，可通过简单的阈值判别或奇异性分析实现准



（a）机理模型　（b）数据驱动模型　（c）所提出模型

图7　工况T1下所提出模型、机理模型和数据驱动模型的结果对比

**Fig.7　Comparison of results obtained by the proposed model, the mechanism model, and the data-driven model under operating condition T1**



（a）原始信号　（b）SNR = 20 dB　（c）SNR = 10 dB

图8　不同噪声强度下刀具磨损预测结果对比

**Fig.8　Comparison of tool wear prediction results under different noise intensities**

表4　同噪声条件下模型预测精度对比

Table 4　Comparison of model prediction accuracy under different noise conditions

| 噪声条件 | 评价指标 | 数据驱动模型(LSTM) | PG–LFM |
|---|---|---|---|
| 原始信号 | MAE/μm | 2.30 | 1.69 |
| | MAPE/% | 7.54 | 3.23 |
| SNR=20 dB | MAE/μm | 3.19 | 1.84 |
| | MAPE/% | 9.28 | 4.12 |
| SNR=10 dB | MAE/μm | 3.80 | 2.09 |
| | MAPE/% | 11.84 | 5.48 |

确识别与单独处理。此外,由于物理模型与实际加工过程之间的系统偏差不可避免,所提出的方法在磨损后期仍会对真实磨损状态产生轻微高估。这一现象反映了物理先验在概率建模中的双重作用。未来工作可通过引入分阶段磨损建模策略、面向工况自适应的物理参数更新方法,或基于多源传感信息的物理约束动态修正机制,进一步提升模型在磨损后期及极端工况下的预测精度和鲁棒性。

### 3.2　基准模型对比分析

为系统评估所提出模型的预测性能与方法优势,本文选取了若干具有代表性的先进数据驱动模型和混合建模方法进行对比分析,包括多层感知机(Multilayer perceptron,MLP)、残差网络(Residual network,ResNet)、长短期记忆网络(Long short-term memory network,LSTM)、高斯过程回归(Gaussian process regression,GPR)、基于决策级融合的混合模型(Hybrid1)[37],及基于物理损失约束的混合模型(Hybrid2)[30]。其中,MLP、ResNet和LSTM分别代表典型前馈网络、深层特征提取网络和时序建模网络;GPR代表具有不确定性量化能力的非参数贝叶斯回归方法;Hybrid1和Hybrid2则代表两类典型物理–数据融合策略,分别通过决策级融合和物理损失约束将机理先验引入数据驱动建模过程。

所有基准模型均在相同计算环境下实现,包括NVIDIA RTX 1650s、AMD R5–3600、Python 3.8和TensorFlow 2.1,并采用留一交叉验证策略进行训练与评估,为保证对比试验的公平性,对基准对比模型关键参数进行调优设置,从而发挥出基准模型的最大性能,各模型的主要结构与关键参数如表5所示。

以工况T2为例,不同模型对刀具磨损状态的预测结果如图9所示。可以看出,基于MLP和ResNet的模型预测性能相对较差。这主要是因为此类模型在建模过程中仅依赖试验数据建立输入与输出之间的映射关系,而忽略了监测信号固有的时间序列特性。在实际加工过程中,当前刀具磨损状态不仅受当前时刻传感器信号的影响,还与历史监测信息密切相关;然而,MLP和ResNet难以有效捕捉这种时间依赖关系。相比之下,LSTM通过门控机制选择性地保留和更新序列信息,能够更有效地提取信号中的时序特征。如图9(c)所示,LSTM的预测精度明显高于MLP和ResNet。然而,在训练样本数量有限的情况下,其性能仍受到一定限制。

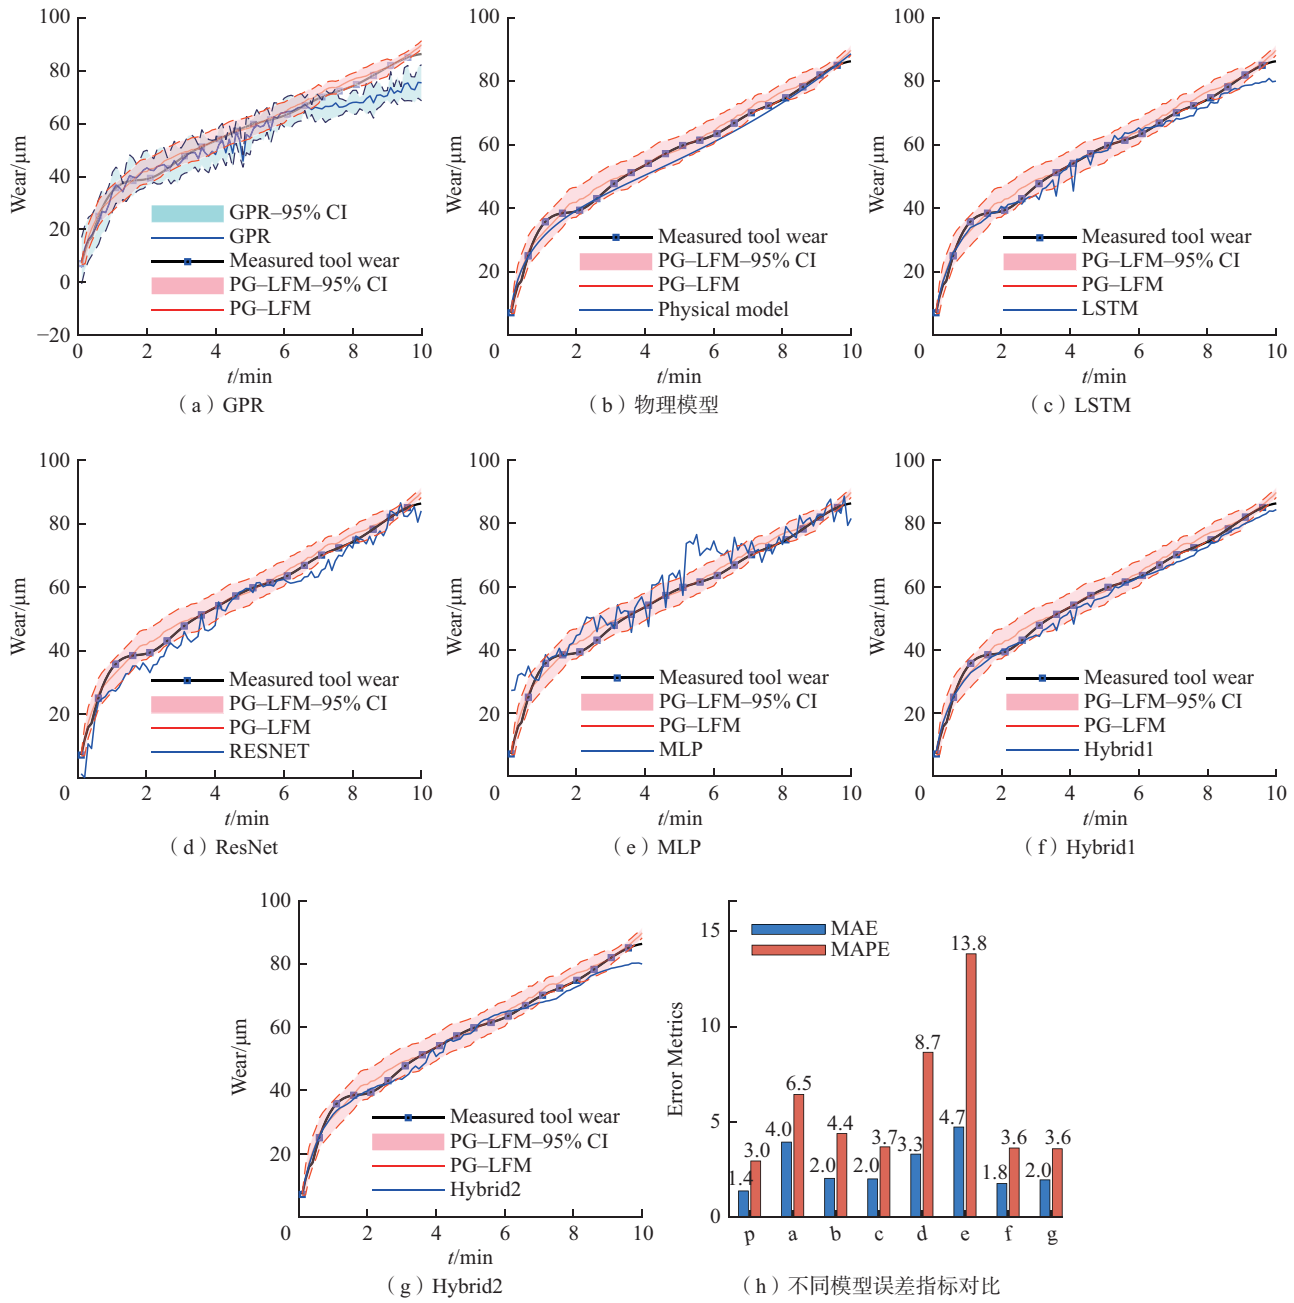
高斯过程回归是在贝叶斯框架下构建的非参数模型,在小样本建模场景中具有固有优势。通过合理设计协方差函数,GPR能够构建灵活的函数空间,并在预测过程中同时给出磨损状态估计值及其对应的不确定性区间。然而,当预测点远离训练样本时,协方差函数对样本相关性的约束会逐渐减弱,导致未观测区域的不确定性增大,进而产生较大的预测方差。

所提出方法与经典物理引导深度学习方法的预测性能对比如图9(f)~(g)所示,其中本文方法表现出明显优势。对于混合模型Hybrid1[37],物理模型与数据驱动模型通过粒子滤波进行融合。在该框架中,数据驱动模型的预测结果被视为观测值,而物理模型用于计算

表5　基准模型的主要结构与关键参数

Table 5　Main structure and key parameters of benchmark models

| 模型 | 模型结构 | 关键参数设置 |
|---|---|---|
| MLP | 3层全连接层 | FC(32)–FC(64)–FC(64);ReLU激活;MSE损失;迭代500次;学习率0.01 |
| ResNet | ResNet18残差网络 | 卷积核尺寸为240×1和10×1;通道数为128和256;MSE损失;迭代500次;学习率0.01 |
| LSTM | 两层LSTM与两层全连接层 | FC(32)–LSTM(64)–LSTM(64)–FC(32);ReLU激活;MSE损失;迭代500次;学习率0.01 |
| GPR | 高斯过程回归模型 | 零均值函数;SE协方差函数;协方差函数超参数初始值设为0.1 |
| Hybrid1 | LSTM与物理模型的决策级融合 | 采用含高斯过程噪声的粒子滤波器进行状态估计;粒子数设为100 |
| Hybrid2 | 基于物理损失约束的LSTM模型 | 物理损失项由相邻时刻磨损差值经ReLU函数构造,即:Relu($Wear_t$–$Wear_{t-1}$) |




（a）GPR　（b）物理模型　（c）LSTM

（d）ResNet　（e）MLP　（f）Hybrid1

（g）Hybrid2　（h）不同模型误差指标对比

**图9　工况T2下PG–LFM与基准模型的预测对比及误差评价**

**Fig.9　Prediction comparison and error evaluation between PG–LFM and baseline models under operating condition T2**

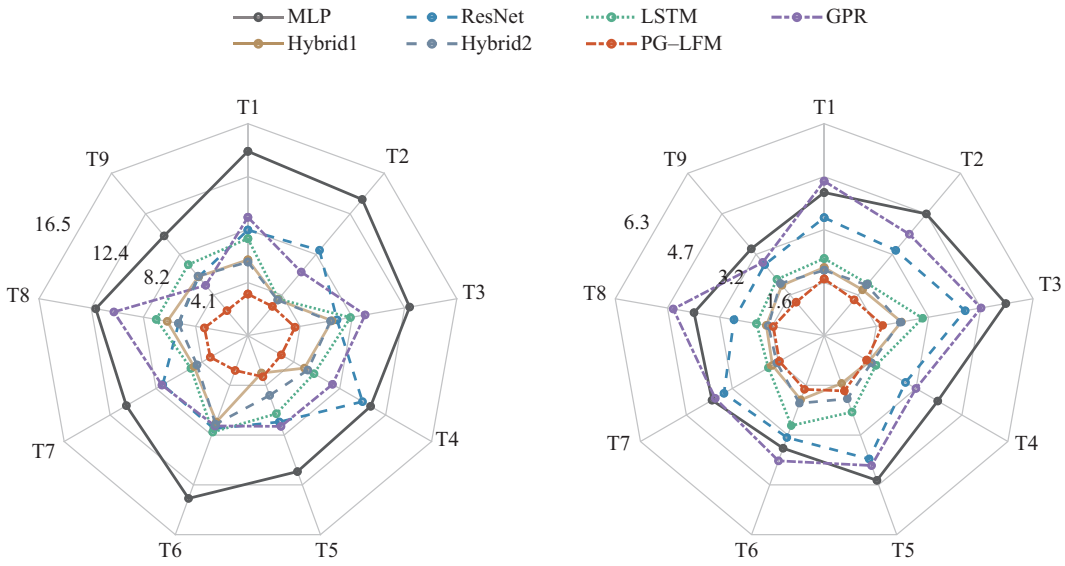
相邻磨损状态之间的状态转移。然而，由于纯数据驱动模型在小样本条件下预测精度有限，同时物理模型中采用的一阶Taylor近似会导致误差累积，因此粒子滤波带来的性能提升较为有限。对于混合模型Hybrid2，Wang等[30]通过引入物理信息损失函数，将刀具磨损的不可逆性纳入模型训练过程，以约束当前磨损状态与历史磨损值之间的关系。尽管该约束在一定程度上增强了数据驱动模型的物理一致性，但其预测性能对物理损失项权重和训练数据规模较为敏感，因此可能导致次优结果出现。

其他工况下各模型的预测性能可由图10和表6中的评价指标间接反映。可以看出，在不同工况下，所提出方法在预测精度方面均优于各对比模型。

### 3.3　消融试验研究

为进一步评估PG–LFM框架中关键组成部分的贡献，本文通过系统移除或修改特定模块开展消融试验，包括潜在力建模机制和物理引导的在线参数更新策略。每个消融变体均以渐进方式引入额外组成部分，从而能够独立评估各模块对模型整体性能的影响。

图11给出了各消融变体的可视




（a）平均绝对百分比误差（MAPE/%）　　（b）平均绝对误差（MAE/μm）

**图10　9种工况下基准模型与所提出方法的预测误差对比**

**Fig.10　Comparison of prediction errors between the benchmark model and the proposed method under nine different working conditions**

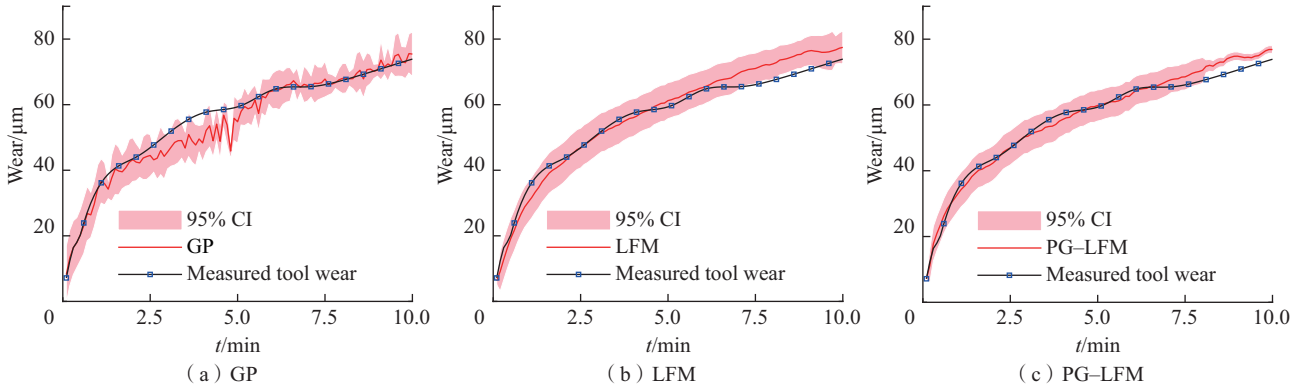
化对比结果，用于定量评估模型性能。可以发现，在去除潜在力建模机制或物理引导在线参数更新模块后，预测的刀具磨损轨迹与实测结果之间出现明显偏差，同时预测置信区间显著增大。产生这一现象的主要原因在于，小样本条件下有限的训练数据难以充分表征加工过程数据的分布特征，因而不可避免地导致系统性偏差。表7汇总了工况T1~T9的平均评价指标，从不确定性指标来看，物理引导的在线更新使模型后验分布更贴合实时工况波动，预测区间宽度（PIW）显著收窄，不确定性量化的紧致性与工程参考价值提升；受物理机理模型固有微小系统偏差影响，预测区间覆盖概率（PICP）略有下降，但仍维持在93%以上的较高可靠水平，整体在预测精度与区间可靠性之间取得了更优平衡。

相比之下，借助物理引导在线参数更新机制，模型能够在预测过程中基于新获取的样本进行自适应修正，从而显著降低由训练数据集与输入数据分布不匹配所引起的预测误差。图11（b）和（c）中的预测结果进一步

**表6　与基准模型的误差分析及对比**

**Table 6　Error analysis and comparison with baseline models**

| 参数 | | T1 | T2 | T3 | T4 | T5 | T6 | T7 | T8 | T9 | 平均值 |
|---|---|---|---|---|---|---|---|---|---|---|---|
| MAPE/% | MLP | 14.33 | 13.82 | 12.76 | 11.01 | 11.26 | 13.48 | 10.90 | 12.00 | 10.12 | 12.19 |
| | ResNet | 8.21 | 8.66 | 7.03 | 10.28 | 7.15 | 7.71 | 7.64 | 5.46 | 5.96 | 7.57 |
| | LSTM | 7.54 | 3.70 | 8.09 | 5.93 | 6.47 | 7.99 | 5.11 | 7.23 | 7.20 | 6.58 |
| | GPR | 9.20 | 6.45 | 9.25 | 7.59 | 7.52 | 7.48 | 7.71 | 10.57 | 5.10 | 7.87 |
| | Hybrid1 | 5.89 | 3.64 | 6.63 | 5.07 | 3.10 | 7.15 | 4.83 | 6.36 | 5.98 | 5.41 |
| | Hybrid2 | 5.72 | 3.60 | 6.52 | 5.37 | 4.95 | 7.34 | 4.56 | 5.48 | 6.03 | 5.51 |
| | Proposed | 3.23 | 2.96 | 3.72 | 3.00 | 3.41 | 2.89 | 3.37 | 3.43 | 2.53 | 3.17 |
| MAE/μm | MLP | 4.27 | 4.74 | 5.50 | 3.91 | 4.60 | 3.58 | 3.86 | 3.94 | 3.38 | 4.20 |
| | ResNet | 3.52 | 3.32 | 4.27 | 2.80 | 3.92 | 3.24 | 3.45 | 2.73 | 2.76 | 3.33 |
| | LSTM | 2.30 | 2.02 | 2.98 | 1.78 | 2.43 | 2.86 | 1.92 | 2.05 | 2.19 | 2.28 |
| | GPR | 4.61 | 3.95 | 4.75 | 3.16 | 4.13 | 3.98 | 3.75 | 4.57 | 2.85 | 3.97 |
| | Hybrid1 | 2.03 | 1.78 | 2.34 | 1.54 | 1.52 | 2.04 | 1.78 | 1.75 | 1.96 | 1.86 |
| | Hybrid2 | 1.95 | 1.97 | 2.30 | 1.63 | 2.01 | 2.15 | 1.63 | 1.69 | 2.03 | 1.93 |
| | Proposed | 1.69 | 1.39 | 1.77 | 1.46 | 1.76 | 1.71 | 1.54 | 1.54 | 1.30 | 1.57 |
| PICP/% | GPR | 58.00 | 68.00 | 79.00 | 87.00 | 83.00 | 91.00 | 96.00 | 65.00 | 98.00 | 81.00 |
| | Proposed | 80.00 | 95.00 | 98.00 | 90.00 | 95.00 | 91.00 | 100.00 | 94.00 | 98.00 | 93.44 |
| PIW/μm | GPR | 9.20 | 10.92 | 19.87 | 16.92 | 27.97 | 13.07 | 29.57 | 13.79 | 16.28 | 17.51 |
| | Proposed | 8.18 | 7.48 | 8.78 | 11.01 | 11.07 | 10.51 | 8.62 | 9.09 | 9.10 | 9.32 |




（a）GP　（b）LFM　（c）PG–LFM

图11　工况 T1 下不同消融变体的预测结果对比

Fig.11　Comparison of prediction results of different ablation variants under operating condition T1

表7　PG–LFM 模型消融研究

Table 7　Ablation study of PG–LFM model

| GP | LFM | PG–LFM | MAPE/% | MAE/μm | PICP/% | PIW/μm |
|---|---|---|---|---|---|---|
| √ | | | 7.87 | 3.97 | 81.00 | 17.51 |
| √ | √ | | 4.83 | 2.39 | 95.32 | 12.69 |
| √ | √ | √ | 3.17 | 1.57 | 93.44 | 9.32 |

表明，所提出方法能够有效降低模型对标记数据的依赖。

## 4　结论

针对航空精密铣削过程中刀具磨损状态难以准确在线预测的问题，提出了一种机理引导潜在力模型，实现了加工过程中刀具磨损状态的高效、精确预测，得出以下主要结论。

（1）本研究基于金属切削理论与刀具磨损机理构建了刀具磨损状态演化的状态空间模型，为数据驱动模型提供了物理约束框架，使预测结果具备可解释的物理基础。

（2）提出的机理指导潜力模型通过将高斯过程回归的协方差核函数嵌入状态空间模型驱动信号，构建了兼具物理一致性与数据适应性的混合建模框架。该框架有效解决了机理模型外推能力不足的问题，实现了刀具磨损状态的概率化预测。

（3）针对小工况下模型跨工况预测不适应问题，本研究提出了一种机理指导的高斯过程模型参数在线更新方法。该方法通过引入物理约束作为先验信息，有效抑制了多步预测的误差累积现象，试验结果表明所提方法在九种工况下的平均 MAPE 和 MAE 分别为 3.17% 和 1.57μm。

需要指出的是，本文所提出的 PG–LFM 是一种具有可扩展性的机理–数据融合建模框架，但这种扩展并非直接套用，而需要根据具体加工方式重新定义状态变量、外部输入、磨损演化方程、切削力分量及协方差函数结构。因此所提出方法仍依赖于所采用物理先验的有效性。当物理模型与实际加工过程之间存在系统性偏差时，物理先验可能会在概率推断中引入偏置，并进一步降低预测性能。未来工作可进一步验证模型在车削、钻削、磨削等跨工况条件下的模型有效性。

## 参 考 文 献

[1]　赵明伟, 岳彩旭, 陈志涛, 等. 航空结构件铣削变形及其控制研究进展[J]. 航空制造技术, 2022, 65(3): 108–117.

Zhao Mingwei, Yue Caixu, Chen Zhitao, et al. Research progress on milling deformation and control of aviation structural parts[J]. Aeronautical Manufacturing Technology, 2022, 65(3): 108–117.

[2]　Li Z Q, Zeng Z P, Yang Y, et al. Research progress in machining technology of aerospace thin-walled components[J]. Journal of Manufacturing Processes, 2024, 119: 463–482.

[3]　王民, 车昌家, 高相胜, 等. 复杂工况条件下刀具磨损状态监测与剩余寿命预测研究进展[J]. 机械工程学报, 2025, 61(19): 299–326.

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

[4]　王建肖, 陈光军, 赵理想, 等. 切削加工刀具磨损及其预测建模技术研究进展[J]. 航空制造技术, 2023, 66(18): 98–109.

Wang Jianxiao, Chen Guangjun, Zhao Lixiang, et al. Research progress of tool wear and its prediction modeling technology in cutting process[J]. Aeronautical Manufacturing Technology, 2023, 66(18): 98–109.

[5]　Zhang H Y, Jiang S L, Gao D F, et al. A review of physics-based, data-driven, and hybrid models for tool wear monitoring[J]. Machines, 2024, 12(12): 833.

[6]　Zhang X, Gao Y, Guo Z C, et al. Physical model-based tool wear and breakage monitoring in milling process[J]. Mechanical Systems and Signal Processing, 2023, 184: 109641.

[7]　Laakso S V A, Johansson D. There is logic in logit-including wear rate in Colding's tool wear model[J]. Procedia Manufacturing, 2019, 38: 1066–1073.

[8] Zhu K P, Zhang Y. A generic tool wear model and its application to force modeling and wear monitoring in high speed milling[J]. Mechanical Systems and Signal Processing, 2019, 115: 147–161.

[9] 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.

[10] 徐锦泱, 黄祥辉, 陈明, 等. 刀具磨损形态对Ti6Al4V切削过程影响的有限元仿真研究[J]. 航空制造技术, 2020, 63(3): 14–21.

Xu Jinyang, Huang Xianghui, Chen Ming, et al. Finite element study on effects of tool wear patterns on the machining process of Ti6Al4V[J]. Aeronautical Manufacturing Technology, 2020, 63 (3): 14–21.

[11] 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.

[12] 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.

[13] Jin S H, Cheng Y N, Zhai W J, et al. Research on transfer monitoring model of tool wear driven by adaptive signal processing and multimodal feature fusion[J]. Measurement, 2026, 278: 121688.

[14] Liu Q, Liu J Q, Liu X L, et al. Based on domain adversarial neural network with multiple loss collaborative optimization for milling tool wear state monitoring under different machining conditions[J]. Precision Engineering, 2024, 91: 692–706.

[15] Cheng Y N, Guan R, Jin Y B, et al. Research on intelligent tool condition monitoring based on data-driven: A review[J]. Journal of Mechanical Science and Technology, 2023, 37(7): 3721–3738.

[16] Li Y F, Wang X Q, He Y, et al. Deep spatial-temporal feature extraction and lightweight feature fusion for tool condition monitoring[J]. IEEE Transactions on Industrial Electronics, 2022, 69(7): 7349–7359.

[17] Li W J, Liu T S. Time varying and condition adaptive hidden Markov model for tool wear state estimation and remaining useful life prediction in micro-milling[J]. Mechanical Systems and Signal Processing, 2019, 131: 689–702.

[18] Li K, Qiu C C, Zhou X Z, et al. Modeling and tagging of time sequence signals in the milling process based on an improved hidden semi−Markov model[J]. Expert Systems with Applications, 2022, 205: 117758.

[19] Ge J M, Cao D H, Liu W, et al. An online monitoring approach of grinding wheel wear condition for robotic weld grinding based on enhanced CNN−GRU model[J]. Mechanical Systems and Signal Processing, 2025, 241: 113483.

[20] 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.

[21] Manwar A, Varghese A, Bagri S, et al. Online tool condition monitoring in micromilling using LSTM[J]. Journal of Intelligent Manufacturing, 2025, 36(2): 935–955.

[22] Cheng F, Zhai S C, Dong J Y. Investigation of Gaussian mixture clustering model for online diagnosis of tip-wear in nanomachining[J]. Journal of Manufacturing Processes, 2022, 77: 114–124.

[23] 刘洪成, 袁德志, 朱锟鹏. 基于高斯过程潜力模型的刀具磨损预测[J]. 机械工程学报, 2023, 59(17): 310–324.

Liu Hongcheng, Yuan Dezhi, Zhu Kunpeng. Tool wear prediction based on Gaussian process latent force model[J]. Journal of Mechanical Engineering, 2023, 59(17): 310–324.

[24] Wang J J, Li Y L, Gao R X, et al. Hybrid physics-based and data-driven models for smart manufacturing: Modelling, simulation, and explainability[J]. Journal of Manufacturing Systems, 2022, 63: 381–391.

[25] 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.

[26] Wang J J, Yan J X, Li C, et al. Deep heterogeneous GRU model for predictive analytics in smart manufacturing: Application to tool wear prediction[J]. Computers in Industry, 2019, 111: 1–14.

[27] 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.

[28] 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.

[29] 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.

[30] Wang J J, Li Y L, Zhao R, et al. Physics guided neural network for machining tool wear prediction[J]. Journal of Manufacturing Systems, 2020, 57: 298–310.

[31] 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.

[32] 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.

[33] Awasthi U, Bollas G M. Symbolic regression-based method for developing a physics-informed surrogate model for a manufacturing process[M]//33rd European Symposium on Computer Aided Process Engineering. Amsterdam: Elsevier, 2023: 1559–1564.

[34] Yang Q, Pattipati K R, Awasthi U, et al. Hybrid data-driven and model-informed online tool wear detection in milling machines[J]. Journal of Manufacturing Systems, 2022, 63: 329–343.

[35] Zhou Y J, Xia T B, Li R R, et al. Physics-informed orthogonal network with hierarchical time-frequency feature refining strategy for tool wear recognition[J]. Journal of Manufacturing Systems, 2025, 82: 60–82.

[36] Wang S, Li S S, Lin X, et al. Mechanism-driven data model for tool condition

monitoring[J]. Mechanical Systems and Signal Processing, 2025, 237: 113042.

[37] Fang X H, Song Q H, Li Z Y, et al. Intelligent monitoring system for production lines in smart factories: A hybrid method integrating Transformer and Kalman filter[J]. Journal of Manufacturing Systems, 2025, 79: 27–47.

[38] 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.

# Mechanism-Guided Latent Force Modeling for Tool Wear Monitoring

SHI Yungao[1,2], LI Shenshen[1,3], ZHU Kunpeng[1,2,3]

（1. Changzhou Institute of Advanced Manufacturing Technology, Changzhou 213164, China;
2. Institute of Intelligent Machines, Hefei Institutes of Physical Science,
Chinese Academy of Sciences, Hefei 230031, China;
3. Wuhan University of Science and Technology, Wuhan 430081, China）

**[ABSTRACT]** In precision machining, tool wear changes the tool-workpiece contact state, thereby inducing cutting force fluctuations, dimensional error accumulation, and surface quality degradation. These effects ultimately compromise the consistency and reliability of the machining process. To address the limitations of conventional mechanistic models caused by idealized assumptions, as well as the sensitivity of data-driven models to input noise and variations in operating-condition distributions, a mechanism-guided latent force model is proposed for online tool wear monitoring. Specifically, a state-space model is employed to explicitly characterize the evolution of tool states during machining. The cutting force is regarded as an external input to the system and is assigned a Gaussian process prior. Meanwhile, a physics-informed covariance function is designed according to cutting mechanisms to enhance the model's capability to represent complex machining behaviors. Furthermore, an online parameter updating strategy guided by the wear evolution mechanism is developed to reduce systematic modeling bias and suppress error accumulation in multi-step prediction. Experimental results show that the proposed method achieves an average mean absolute percentage error and mean absolute error of 3.17% and 1.57 μm, respectively, under multiple operating conditions. These results demonstrate its favorable prediction accuracy and stability, providing methodological support for tool condition monitoring and quality control in aerospace precision milling.

**Keywords:** Precision milling; Tool condition monitoring; State-space model; Mechanism-guided latent force model（PG–LFM）; Online updating strategy

（责编　晓月）