

# 智能制造背景下机床主轴热误差补偿策略研究

马 荣

国家能源集团宁夏煤业公司能源工程有限公司环境安全工程分公司 宁夏银川 750021

**摘要：**在智能制造与工业4.0的浪潮下，高端数控机床作为核心装备，其加工精度直接决定了产品的质量与竞争力。然而，机床在运行过程中因内部热源（如主轴、电机）和外部环境温度变化产生的热变形，是影响加工精度的主要因素之一，其中主轴热伸长尤为显著。本文旨在系统性地探讨智能制造背景下机床主轴热误差的产生机理、建模方法及补偿策略。首先，深入剖析了主轴热误差的物理本质及其影响因素；其次，对传统的经验模型、物理模型以及现代数据驱动模型（如支持向量机、神经网络、深度学习等）进行了全面综述与对比分析；进而，结合智能制造的核心特征——数据驱动、互联互通与智能决策，提出了一种融合多源信息感知、自适应建模与云端协同优化的智能热误差补偿新范式。

**关键词：**智能制造；机床主轴；热误差；误差补偿；数据驱动；深度学习

## 引言

数控机床作为智能制造的“工作母机”，其动态精度直接影响高端装备等关键领域的制造水平。然而，实际加工中，内部热源（切削、轴承摩擦等）和外部因素（环境温度波动）导致机床热变形，在精密加工中，热变形误差成为制约机床精度提升的瓶颈。主轴系统因高速旋转、高功率密度成为主要热源，其热伸长会引入加工尺寸的系统性偏差。传统被动热控制手段成本高且难以应对复杂工况，主动式热误差补偿技术应运而生，通过建立热误差与可观测变量的数学模型，实时预测并修正误差。近年来，物联网、大数据、人工智能等新兴信息技术为热误差补偿技术带来新机遇。智能制造强调全面感知、数据融合与智能应用，为构建更精准、鲁棒、自适应的热误差补偿系统提供了新框架。因此，梳理现有方法并探索下一代补偿策略，具有重要的理论价值与工程意义。

## 一、机床主轴热误差产生机理与影响因素分析

### （一）热误差的物理本质

机床主轴热误差的本质是热-力耦合效应下的结构变形。当主轴系统运行时，其内部热源（主要包括高速轴承的摩擦热、内置电机的铜损与铁损、以及切削液与刀具/工件摩擦产生的热量传导）持续产生热量。这些热量通过热传导、热对流和热辐射等方式在主轴箱体、轴承座、主轴本体等部件间传递，最终形成一个复杂

的、非稳态的三维温度场<sup>[1]</sup>。根据热胀冷缩原理，温度场的不均匀分布会导致材料产生不均匀的热膨胀，宏观上表现为机床关键部件（如主轴端面）的空间位置发生偏移，即热位移或热伸长。对于卧式加工中心，主轴热伸长主要沿Z轴方向；对于立式加工中心，则主要影响Z轴方向的定位精度。这种热位移通常是缓慢变化的，但在主轴启停、变速或负载突变时，会呈现出明显的瞬态特性。

### （二）关键影响因素

主轴热误差是高度非线性、时变的复杂行为，受多种因素耦合影响：（1）主轴转速：最直接、主要因素，转速越高，轴承摩擦和电机损耗越大，产热与热变形越显著。（2）运行时间：热变形随运行时间多呈指数增长至热平衡，不同启停模式（连续、间歇）热历史不同。（3）环境温度：其变化影响机床初始热状态与散热，是日周期性热漂移主因。（4）切削负载：主轴自身热源主导，但重载切削产生的切削热会传导至主轴前端，加剧局部温升。（5）润滑与冷却条件：润滑油流量、温度和粘度影响轴承摩擦与散热，可调控热源强度。（6）机床结构与材料：主轴箱体热对称性、材料热导率和膨胀系数等，决定热量传递与变形模式。理解这些因素及其相互作用，是构建有效热误差模型的前提。

### 二、现有热误差建模与补偿方法综述

热误差补偿的核心在于建立一个能够准确描述“输入”（温度、转速等）与“输出”（热位移）之间映射关

系的数学模型。根据建模范式的不同, 现有方法大致可分为三类: 经验模型、物理模型和数据驱动模型。

### (一) 经验模型

经验模型主要基于实验数据, 通过统计分析或简单的函数拟合来建立模型。最具代表性的是多元线性回归 (MLR) 模型:

$$\Delta L = a_0 + \sum_{i=1}^n a_i T_i$$

这是最常用的经验建模方法。假设主轴的热伸长量  $\Delta L$  (单位:  $\mu\text{m}$ ) 只和几个关键位置的温度  $T_1, T_2, \dots, T_n$  有关, 并且是线性关系。 $a_0$  是常数项 (比如初始偏移);  $a_i$  是每个测温点对热伸长的“贡献权重”; 通过实验数据拟合出这些系数, 就能用实时温度预测热误差。举个例子: 如果测得电机壳体升温  $10^\circ\text{C}$  会导致主轴伸长  $2\mu\text{m}$ , 那么对应的  $a_i$  就接近  $0.2\mu\text{m}/^\circ\text{C}$ 。

### (二) 物理模型

物理模型试图从热力学和传热学的基本原理出发, 通过建立机床的热-结构耦合有限元 (FEA) 模型来仿真预测热变形。

$$\rho c_p \frac{\partial T}{\partial t} - \nabla \cdot (k \nabla T) = Q$$

$$[K]\{u\} = [K_T]\{\Delta T\}$$

方程1: 这个方程描述了机床部件内部温度是如何随着时间变化的。其中:  $T$  是某一点的温度 (单位:  $^\circ\text{C}$ );  $t$  是时间 (单位: 秒);  $\rho$  是材料密度 (单位:  $\text{kg}/\text{m}^3$ );  $c_p$  是材料的比热容 (单位:  $\text{J}/(\text{kg} \cdot ^\circ\text{C})$ ), 表示材料“储存热量的能力”;  $k$  是导热系数 (单位:  $\text{W}/(\text{m} \cdot ^\circ\text{C})$ ), 反映材料“传导热量的快慢”;  $Q$  是单位体积内产生的热量 (比如电机发热、摩擦生热等, 单位:  $\text{W}/\text{m}^3$ );  $\nabla \cdot (k \nabla T)$  表示热量在空间中的扩散 (即从高温区流向低温区)。简单说: 左边第一项 ( $\rho c_p \frac{\partial T}{\partial t}$ ) 代表材料“温度升高的速度”, 第二项代表“热量流走的速度”; 右边  $Q$  是“内部热源”。整个方程说明: 温度变化 = 内部发热 - 热量散失。

方程2: 这个方程用于计算由于温度变化引起的机床结构变形 (如主轴伸长或弯曲)。其中:  $\{u\}$  是结构的位移向量 (即我们关心的“热误差”, 单位:  $\text{mm}$ );  $[K]$  是结构的刚度矩阵, 反映机床抵抗变形的能力;  $\{\Delta T\}$  是各处相对于初始状态的温度变化 (单位:  $^\circ\text{C}$ );  $[K_T]$  是“热载荷矩阵”, 它把温度变化转换成等效的机械力 (称为“热应力”)。简单说: 温度升高会让材料膨胀, 但机

床结构会约束这种膨胀, 从而产生内应力, 最终导致微小变形。这个公式就是用来把温度变化“翻译”成实际的位移 (热误差)。

### (三) 数据驱动模型

随着机器学习技术的发展, 数据驱动模型因其强大的非线性拟合能力和对复杂系统内在规律的挖掘潜力, 成为当前热误差建模的主流方向。(1) 支持向量机 (SVM): 通过核函数将低维非线性问题映射到高维空间进行线性回归, 能有效处理小样本问题, 在早期研究中表现出色。(2) 人工神经网络 (ANN): 特别是多层前馈神经网络 (MLP), 凭借其万能逼近定理, 能够以任意精度逼近复杂的非线性函数。通过引入循环神经网络 (RNN) 或长短期记忆网络 (LSTM), 还能有效捕捉热误差的时间序列特性。(3) 深度学习模型: 近年来, 更复杂的深度学习架构被引入<sup>[2]</sup>。例如, 卷积神经网络 (CNN) 可用于处理分布式温度传感器阵列形成的“温度图像”; 图神经网络 (GNN) 则能更好地刻画机床各部件间的物理连接与热传导关系。优点是对系统内部机理依赖小, 仅需输入输出数据即可训练, 能自动学习复杂的非线性及时滞关系, 预测精度高。缺点是通常被视为“黑箱”模型, 可解释性差; 对训练数据的质量和数量要求较高; 模型一旦训练完成, 在面对未见过的新工况时, 可能存在过拟合或泛化不足的问题。

## 三、面向智能制造的主轴热误差智能补偿新策略

智能制造的核心在于构建一个“感知-分析-决策-执行”的闭环智能系统。基于此理念, 本文提出一种“多源感知-自适应建模-云端协同”的智能热误差补偿新策略。

### (一) 多源异构信息感知层

本策略首先在感知层进行革命性重构, 构建一个多源、异构、高维的信息融合体系。具体而言, 在温度感知方面, 摒弃以往仅关注少数“热关键点”的做法, 转而部署由低成本、微型化无线传感器构成的高密度传感网络。该网络不仅覆盖轴承座、电机外壳等传统热点区域, 还延伸至主轴箱体外表面、内部空腔结构乃至冷却润滑油回路, 从而能够捕捉到更为精细和完整的时空温度场演化过程。与此同时, 充分利用现代数控系统 (CNC) 日益开放的数据接口 (如 OPC UA), 实时获取包括主轴转速、负载电流、进给速度、累计运行时间等在内的全维度运行状态参数, 这些参数直接反映了机床的动态工作负荷与能量消耗, 是驱动热源变化的内在动

因<sup>[3]</sup>。更进一步，通过与上层制造执行系统（MES）或工艺数据库的集成，系统还能自动获取当前加工任务的上下文信息，例如工件材料属性、刀具几何参数、预设切削用量等工艺知识。这种将物理状态（温度）、设备行为（运行参数）与制造语义（工艺信息）三者深度融合的感知模式，为后续构建一个能够深刻理解“工况-热源-变形”因果链条的智能模型提供了前所未有的、坚实而全面的数据基础。

## （二）自适应智能建模与推理层

面对由上述多源感知层提供的海量、高维数据，本策略在建模与推理层引入了核心的自适应机制，以解决传统数据驱动模型泛化能力弱、鲁棒性差的根本缺陷。首先，模型被赋予在线学习与增量更新的能力。通过采用在线梯度下降、递归最小二乘法等算法，或设计专门的增量式神经网络架构，模型能够在机床正常运行过程中，持续吸收新产生的数据流，并动态微调其内部参数。这种能力使得补偿系统能够有效跟踪并适应诸如机床长期使用导致的性能老化、季节更替引发的环境温湿度漂移等缓慢时变因素，确保模型在整个生命周期内始终保持高精度。其次，针对新机床部署或工况剧变导致的数据匮乏问题，策略引入了迁移学习技术。对于同一系列或结构相似的机床，可以将在一台数据丰富的“源域”机床上训练成熟的高性能模型作为先验知识，仅需利用少量“目标域”机床的实测数据进行快速微调，即可实现模型的高效迁移，极大地缩短了新设备的建模周期与调试成本。最后，为了提升整个补偿系统的可靠性与安全性，本策略强调不确定性量化的重要性。通过采用贝叶斯神经网络（BNN）或蒙特卡洛 Dropout 等先进技术，模型不仅能输出热误差的点估计值，还能同步提供一个反映预测置信度的概率分布或置信区间。当系统检测到预测不确定性异常升高时——这可能预示着传感器故障、未知极端工况或模型失效——系统可自动触发预警机制，或切换至更为保守的补偿策略（如暂停补偿或采用安全阈值），从而避免因错误的补偿指令而导致灾难性的加工事故，显著增强了系统的工程实用性。

## （三）云端协同优化与知识沉淀层

为充分发挥计算资源的效能，本策略构建了一个边缘计算与云计算深度融合的分层协同架构。在靠近机床的边缘端，部署经过高度优化的轻量化推理模型（如通过知识蒸馏得到的紧凑型网络），其核心任务是在毫秒

级的时间尺度内完成热误差的实时预测，并生成相应的补偿指令发送给数控系统，确保控制回路的低延迟与高响应性。而在功能强大的云端，则扮演着“智慧大脑”与“知识仓库”的双重角色。云端平台持续汇集来自工厂内所有同类机床的历史运行数据、补偿效果反馈以及维护日志等海量信息。基于这些全局数据，云端能够执行更为复杂的智能任务：其一，进行全局模型优化，定期训练出精度更高、泛化能力更强的“黄金”基准模型，并将优化后的模型或其轻量化版本安全、高效地下发至各边缘节点，实现模型资产的持续迭代与升级；其二，致力于知识的结构化沉淀，将不同工况、不同设备积累的热行为规律抽象为实体与关系，构建机床热误差领域的专用知识图谱，从而实现领域知识的有效共享、复用与传承；其三，依托数字孪生技术，在云端为每台物理机床构建一个高保真的虚拟映射体<sup>[4]</sup>。这个数字孪生体不仅是离线仿真、预测性维护的强大工具，更能作为一个安全、高效的强化学习训练环境，用于探索和验证最优的主动热管理策略，例如，自动生成个性化的最佳预热程序，以最小能耗实现最快的热稳定状态。

## 结语

本文聚焦智能制造背景下机床主轴热误差补偿问题，深入剖析热误差物理机理及其特性，梳理现有建模方法及局限。在此基础上，创新提出融合多源感知、自适应建模与云端协同的智能补偿新范式，构建动态补偿生态系统。展望未来，热误差补偿技术发展空间大：探索多物理场协同误差预测补偿；研究无监督或弱监督学习减少传感器依赖；利用联邦学习协同训练大模型；长远将智能补偿与主动热控集成，推动热管理新模式。

## 参考文献

- [1] 李楠, 王阳阳. 基于多元线性回归的数控机床主轴热误差分析[J]. 精密制造与自动化, 2025, (02): 31-33.
- [2] 周梦洁, 尹玲, 张丽娟, 等. 基于优化的BP神经网络的机床主轴热误差建模方法研究[J]. 机床与液压, 2024, 52(23): 136-142.
- [3] 毛杰. 基于能耗大数据的机床主轴热误差补偿建模技术研究[D]. 湖北文理学院, 2024.
- [4] 张雄. 数控机床主轴热误差自动化测量与补偿应用技术研究[D]. 华中科技大学, 2024.