

DOI: 10.19650/j.cnki.cjsi.J2413321

基于 RIME-BP 神经网络的磨齿机进给系统热误差预测*

肖捷¹, 王志永¹, 于水琴¹, 张宇¹, 薛芮²

(1. 中南林业科技大学机械与智能制造学院 长沙 410004; 2. 合肥工业大学机械工程学院 合肥 230009)

摘要:为了减少热致误差对数控机床进给系统定位精度的影响,提高被加工产品的一致性,提出一种基于霜冰算法(RIME)优化后的 BP 神经网络热误差预测模型。在不同工况下,布置温度传感器和激光干涉仪以采集温度和丝杆热误差数据。结合模糊 C 均值聚类 and 灰色关联度算法对温度样本进行特征选择,筛选出关键温度特征点。以温度和丝杆位置坐标作为输入,丝杆热误差作为输出,构建 RIME-BP 热误差预测模型。针对 H650GA 型磨齿机,利用 K 折交叉验证法对该模型预测精度进行实例验证,并与 GA-BP、BP 和 SVM 模型进行对比。结果表明,该模型的平均决定系数 R^2 高达 0.995,相对于 GA-BP、BP 和 SVM 模型,分别提高了 3.54%、9.58% 和 17.75%。所提出方法为热误差补偿提供了理论和技术指导,具有工程应用价值。

关键词: 热误差预测; 进给系统; 特征选择; 霜冰算法; 神经网络

中图分类号: TH161 文献标识码: A 国家标准学科分类代码: 460.3599

Thermal error prediction of gear grinding machine feed system based on RIME-BP neural network

Xiao Jie¹, Wang Zhiyong¹, Yu Shuiqin¹, Zhang Yu¹, Xue Rui²

(1. College of Mechanical and Intelligent Manufacturing, Central South University of Forestry and Technology, Changsha 410004, China; 2. School of Mechanical Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: To mitigate the impact of thermal errors on the positioning accuracy of the CNC machine tool feed system and improve the consistency of processed products, a thermal error prediction model based on the RIME-optimized BP neural network is introduced. Temperature sensors and a laser interferometer are deployed under various operating conditions to collect temperature and lead screw thermal error data. Fuzzy C-means clustering and grey relational analysis are applied to select features from temperature samples, identifying key temperature feature points. The RIME-BP thermal error prediction model is constructed using temperature and screw position coordinates as inputs and screw thermal error as the output. For the H650GA gear grinding machine, the K-fold cross-validation method is used to validate the model's prediction accuracy, which is compared with GA-BP, BP, and SVM models. The results show that the proposed model achieves an average coefficient of determination (R^2) of 0.995, which is 3.54%, 9.58%, and 17.75% higher than the GA-BP, BP, and SVM models, respectively. The proposed method provides theoretical and technical guidance for thermal error compensation and holds significant engineering application potential.

Keywords: thermal error prediction; feed system; feature selection; rime algorithm; neural network

0 引言

数控机床作为现代制造业的核心驱动力,是我国实现“中国制造 2025”等战略目标的关键支柱。随着先进

制造技术的不断进步,对机床精度的要求也日益提升。数控机床的精度主要受几何误差、热误差和力致误差等因素影响^[1]。由于制造业的迅速发展及加工水平的日益成熟,对于几何误差和力致误差的研究已有较好的控制和可观的成果,然而热误差仍未能得到很好的抑制。据

收稿日期: 2024-09-25 Received Date: 2024-09-25

* 基金项目: 国家自然科学基金企业创新发展联合基金项目(U22B2084)、湖南省重点研发计划项目(2023GK2053)、湖南省自然科学基金项目(2024JJ5643)资助

研究表明,热误差占总加工误差的 40%~70%^[2-4],其中越是高端精密的机床,其比例越大。因此,解决热误差问题刻不容缓,这对于推动精密加工技术的发展和提高加工精度具有全局性的意义。

目前控制热误差的方法分为两类:误差预防法和误差补偿法^[5-6]。前者是在机床设计、加工、制造阶段,提高材料的热特性。但是该方法在人力和资金上需要付出昂贵的代价,具有较大的局限性。而热误差补偿法是人为地添加一个等大、反向的新误差与原热误差相抵消。核心思想是建立热误差和关键热源映射模型,达到预测热误差的目的。相比误差预防法,热误差补偿法不仅更经济、有效,且具有重要的工业应用价值,是控制热误差的重要研究方向。该方法重点在于建立一个稳定、精确的热误差预测模型^[7-8]。

众多学者对热误差建模进行了研究。Zhang 等^[9]基于离散的思路提出了一种有限元分析(finite element analysis, FEA)热误差模型,通过对边界条件的研究改进模型精度。经实验验证,仿真误差小于 10%。Liang 等^[10]提出一种基于雾云架构和长短期记忆(long short-term memory, LSTM)网络相结合的热误差模型,该热误差模型自带数据预处理能力,并且有效克服了热误差补偿过程中的高延迟问题。孙兴伟等^[11]利用卷积网络(convolutional neural network, CNN)的特征提取功能和门控单元(gated recurrent unit, GRU)的时序数据处理能力,设计了一种 CNN-GRU 热误差模型。经实验验证,该模型拟合优度高达 0.995,具有优异的预测性能。李国龙等^[12]基于天鹰算法(aquila optimizer, AO)的强大寻优能力对 CNN 的超参数进行优化,设计了一种 AO-CNN 热误差模型。实验结果表明,该模型预测精度相对于传统 CNN 提升了 15%。Dai 等^[13]设计了 Elman 网络结构对热误差进行预测,并引入布谷鸟算法进行改进。预测结果显示,改进后模型预测性能提高了 53%。Cheng 等^[14]利用支持向量机(support vector machine, SVM)对热误差进行建模,引入屎壳郎算法(dung beetle optimizer, DBO)对模型参数进行优化,构建了一种 DBO-SVM 模型,为后续热误差补偿提供了理论支持。杨赫然等^[15]提出结合松鼠搜索算法和反向传播(back propagation, BP)神经网络对热变形建立映射关系,并在多工况下对模型进行实例验证。实验结果表明,预测误差由传统方法的 12.2%降低为 8.9%,体现了该方法的有效性。Wu 等^[16]建立了一种多分类的 CNN 热误差模型。该模型同时考虑图像和数据作为输入,能够更充分地捕捉热变化规律。通过切削实验验证,该模型预测精度可达 90%~93%。

由上述分析可知,热误差具有高度的非线性和时变性,但传统的热误差预测模型难以在兼顾计算效率和精度之间找到平衡。近些年来,将机器学习和智能优化算

法相结合的热误差建模方法已经成为趋势。BP 神经网络具有强大的非线性映射能力,基于此论文设计了一种 BP 网络结构来预测磨齿机进给系统热误差。然而, BP 模型初始权值和偏置是随机生成的,导致模型存在训练过程中陷入局部极值的固有风险^[17],且目前尚无较为通用的解决方案。为了解决这一问题,利用 RIME 算法的强大寻优能力,对相关参数进行全局优化,从而提升模型预测性能。此外,还采用模糊 C 均值聚类和灰色关联分析对磨齿机的温度样本进行特征选择,以提高建模效率和精度。同时以丝杆位置坐标和关键温度特征点的温升数据作为输入,丝杆热误差作为输出构建训练集数据,对 RIME-BP 模型进行训练,并采用 K 折交叉验证法在不同工况下对所提出方法的有效性进行实例验证。

1 RIME-BP 神经网络热误差建模理论

1.1 关键温度特征点选择

在热误差建模过程中,部分温度特征之间可能存在共线性等问题,过多或不合理的温度特征组合会增加模型的复杂性,导致模型预测精度下降、鲁棒性不佳等问题^[18-19]。为了避免这些问题,利用模糊 C 均值聚类和灰色关联分析对温度样本进行特征选择。

1) 模糊 C 均值聚类

设由 n 组样本构成的矩阵 $X = \{x_1, x_2, \dots, x_n\}$, 模糊 C 均值聚类的目标函数 $J_b(U, V)$ 本质上为每个样本到各聚类中心的欧几里得距离的平方和,数学表达如式(1)~(3)所示^[20]:

$$J_b(U, V) = \sum_{i=1}^c \sum_{k=1}^n (\mu_{ik})^b (d_{ik})^2 \quad (1)$$

$$\sum_{i=1}^c \mu_{ik} = 1, \mu_{ik} \in [0, 1] \quad (2)$$

$$d_{ik} = \sum_{i=1}^c \|x_k - v_i\|^2 \quad (3)$$

式中: U 为模糊隶属度矩阵; μ_{ik} 为第 k 个样本隶属于第 i 类的隶属度,并且同一个样本属于不同类别的所有隶属度之和为 1; b 表示模糊加权参数,通常取 $b = 2$; V 为聚类中心构成的矩阵; c 为聚类数; v_i 为第 i 类的聚类中心; d_{ik} 表示样本到聚类中心的欧几里得距离。

以目标函数最小化为目的,对 $J_b(U, V)$ 使用拉格朗日乘数法求解出隶属度矩阵 U 及聚类中心 V 。通过不断迭代,所得到的最终隶属度矩阵反映出最佳聚类结果。计算过程如式(4)和(5)所示。

$$\mu_{ik} = \frac{1}{\sum_{m=1}^c \left(\frac{d_{ik}}{d_{mk}} \right)^{\frac{2}{b-1}}} \quad (4)$$

$$v_i = \frac{\sum_{k=1}^n (\mu_{ik})^b x_k}{\sum_{k=1}^n (\mu_{ik})^b} \quad (5)$$

划分系数^[21] (partition coefficient, PC) 是用来衡量聚类效果的指标,取值范围在区间 $[0, 1]$ 内,其值越接近 1 则代表聚类效果越好。本文用 PC 指标确定最佳聚类数 c , 计算公式为:

$$V_{PC} = \frac{1}{n} \sum_{i=1}^c \sum_{k=1}^n \mu_{ik}^2 \quad (6)$$

式中: μ_{ik} 为第 k 个样本隶属于第 i 类的隶属度; c 为聚类数; n 表示样本数量。

2) 灰色关联分析

灰色关联分析^[22] 用于探讨每个温度特征和进给系统热误差之间的关联程度。该方法克服了传统评价方法的主观性问题,其计算结果不受样本的数量和质量所影响,适用于存在不确定性和随机性的系统分析,适应性强。灰色关联系数矩阵 P 的计算公式如下:

$$P_i(k) = \frac{\min_i \min_k |x_0(k) - x_i(k)| + \rho \cdot \max_i \max_k |x_0(k) - x_i(k)|}{|x_0(k) - x_i(k)| + \rho \cdot \max_i \max_k |x_0(k) - x_i(k)|} \quad (7)$$

式中: x_0 和 x_i 分别表示热误差数和温度样本序列; k 为温度样本的维度; ρ 为分辨系数。

1.2 基于 RIME-BP 的热误差模型

1) 霜冰优化算法

霜冰优化算法 (rime optimization algorithm, RIME), 由 Su 等^[23] 提出,其灵感来源于自然界中霜冰的形成和生长规律,是一种新兴的智能优化算法。该算法核心是软霜搜索和硬霜穿刺机制,通过模拟霜冰粒子的运动,在搜索空间中实现阶梯式探索,具有强大的全局寻优和局部调整能力。具体步骤如下:

(1) 初始化霜冰种群的空间位置矩阵 R 。每个霜冰晶体 S_i 代表一组待优化参数的候选解,如式(8)所示。

$$R = \begin{bmatrix} S_1 \\ S_2 \\ \vdots \\ S_i \end{bmatrix}; S_i = [x_{i1}, x_{i2}, \dots, x_{ij}] \quad (8)$$

式中: i 表示霜冰晶体的个数; j 表示霜冰颗粒的个数; x_{ij} 表示第 i 个霜体中的第 j 个霜粒,即某个候选解中的一个优化参数。

(2) 利用软霜搜索策略实现全局寻优。在低风速下,自由状态的霜粒在搜索空间中根据一定的规律缓慢运动,移动到软霜附近时会与内部颗粒凝结。通过考虑随机性和环境因素,以确保在早期阶段能够快速覆盖整

个解空间。霜体位置更新公式如式(9)所示。

$$\begin{cases} R_{ij}^{\text{new}} = R_{\text{best},j} + r_1 \cdot \cos\theta \cdot \beta \cdot (h \cdot (Ub_{ij} - Lb_{ij}) + Lb_{ij}), & r_2 < E \\ E = \sqrt{(t/T)} \\ \theta = \pi \cdot \frac{t}{10 \cdot T} \\ \beta = 1 - \left[\frac{w \cdot t}{T} \right] / w \end{cases} \quad (9)$$

式中: $R_{\text{best},j}$ 是最优候选解的第 j 个霜粒的位置; r_1 为随机系数,取值范围为 $[-1, 1]$,与 $\cos\theta$ 一起控制霜粒的移动方向; t 和 T 分别表示迭代次数和最大迭代限制; β 表示环境因子,其表达式为一个阶跃函数,随着迭代次数 t 的变化而调整,确保算法的可收敛性; w 取默认值 5,控制 β 的步进幅度; Ub_{ij} 表示解空间的上界; Lb_{ij} 表示解空间的下界; E 为凝结系数,影响霜粒位置更新的概率; r_2 为随机系数,取值范围为 $[0, 1]$,与 E 共同作为候选解更新的限制条件。

(3) 利用硬霜穿刺机制进行局部开发。在强风速下,软霜会沿着同一方向聚集形成硬霜,不同霜体的颗粒之间频繁交互。通过硬霜穿刺机制使不同霜体信息进行交叉和互换,有利于跳出局部最优,进一步提高算法收敛性。该机制数学表达式如下:

$$R_{ij}^{\text{new}} = R_{\text{best},j}, r_3 < F^{\text{norm}}(S_i) \quad (10)$$

式中: R_{ij}^{new} 表示更新后的霜体种群; r_3 为随机系数,取值范围 $[-1, 1]$; $F^{\text{norm}}(S_i)$ 为经过标准化之后的霜体适应度值,即第 i 个霜体被选择的概率。

2) BP 神经网络

BP 神经网络是应用最为广泛的神经网络类型之一^[24],结构上包括输入层、隐含层、输出层,每一层又包含数个神经元。其数学模型如式(11)所示。

$$O_i = f_m \left(\sum_{j=1}^n w_j \cdot I_j - \theta_i \right) \quad (11)$$

式中: I_j 为来自前一层第 j 个神经元的输入值; O_i 为第 i 个神经元被激活后的输出值; w_j 表示神经元与前一层第 j 个神经元之间的连接权值; θ_i 表示神经元的偏置项; f_m 为激活函数。

输入信号通过连接权值、偏置和激活函数正向传递得到输出值。随后误差反向传播,利用梯度下降法不断迭代更新权值和偏置,如式(12)所示。

$$\begin{cases} L = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \\ w_j^{(t+1)} = w_j^{(t)} - \eta \cdot \frac{\partial L}{\partial w_j} \\ \theta^{(t+1)} = \theta^{(t)} - \eta \cdot \frac{\partial L}{\partial \theta} \end{cases} \quad (12)$$

式中: $\hat{y}_i$ 为实际输出; y_i 为期望输出; L 为损失函数,其量

化了所有样本的预测值和实际测量值之间的总体差异; t 表示迭代次数; η 表示学习率; n 表示样本数量。

当损失函数值满足约束条件或者达到最大迭代次数时,模型训练结束。本文所设计 BP 神经网络结构如图 1 所示。




图 1 BP 神经网络结构

Fig. 1 Structure of the BP neural network

3) RIME-BP 热误差建模流程

BP 神经网络的初始权值和偏置是随机产生的,具有不确定性。为了避免初始参数的随机性对模型性能的影响,使用霜冰算法对其进行全局优化,其具体步骤如下:

(1) 确定 BP 神经网络的损失函数以及超参数,包括各层神经元个数、迭代次数、学习率、激活函数和训练目标等;

(2) 将 BP 神经网络的损失函数设置为 RIME 算法的适应度函数。生成一定数量的霜冰晶体种群,并且每个霜体维度与待优化参数数量一致。每个霜体对应一组 BPNN 的权重和偏置,即目标函数的解向量;

(3) 使用初始霜冰晶体种群训练 BP 模型,通过训练结果计算适应度函数值。评估每个霜体的适应度,将搜索空间中适应度最高的霜体作为最优解;

(4) 根据式(9)和(10)更新霜体的位置向量。这一步模拟了软霜和硬霜的形成过程,表示向最优解收敛的过程;

(5) 重复(3)和(4),当适应度值满足停止条件或达到最大迭代次数时,优化过程停止,得到最优的 BP 神经网络初始权值和偏置;

(6) 利用 RIME 算法优化后所得到的最优权值和偏置对 BP 神经网络进行初始化。输入样本数据,通过反复迭代训练,最终建立 RIME-BP 热误差预测模型。

2 热误差实验

2.1 实验设备布置

实验以型号为 H650GA 的螺旋锥齿轮磨齿机为研究对象。温度采集设备选用 11 个 Pt100 磁吸式铂电阻温

度传感器,测量范围为 $-50^{\circ}\text{C} \sim 350^{\circ}\text{C}$,精度为 $\pm 0.1^{\circ}\text{C}$,分辨力为 0.01°C 。通过 16 路温度采集模块和 RS232 通讯协议实时记录关键零部件的温升值,主要包括丝杆螺母、驱动电机、丝杆轴承、环境温度等。Pt100 温度传感器的检测位置和安装分别如表 1 和图 2 所示。

表 1 Pt100 温度传感器安装位置

Table 1 Installation locations of Pt100 temperature sensors

温度传感器编号	温度测点位置
T1, T6	前轴承底座外壳
T2, T4	后轴承底座外壳
T3	Z 轴丝杆驱动电机
T5	滑块
T7	丝杆螺母端面
T8	床身
T9	导轨
T10	立柱
T11	环境温度




图 2 Pt100 温度传感器安装

Fig. 2 Installation diagram of Pt100 temperature sensor

热误差测量设备选用雷尼绍 XL-80 激光干涉仪,线性测量精度为 $\pm 0.5 \mu\text{m}/\text{m}$,分辨力为 $0.001 \mu\text{m}$ 。该设备主要由激光头、分光镜和反光镜组成,利用光路变化完成定位误差的测量。机床运动之前,定位误差即丝杆的几何误差,主要由机床本身设计和装配精度决定,属于静态误差。而机床运动后会产生大量热量,此时定位误差主要由热误差和几何误差叠加而成。因此,通过计算不同时刻的定位误差相对于初始状态下的差值,即可获得丝杆热误差。磨齿机进给系统热误差检测现场如图 3 所示。

2.2 实验方案及流程

实验环境温度为 $20^{\circ}\text{C} \pm 1^{\circ}\text{C}$,每组实验持续约 360 min。为了确保实验数据不受上次实验的影响,每两次实验之间至少保持 12 h 的冷却时间。为了研究丝杆




图 3 热误差实验现场

Fig. 3 Thermal error experiment setup

不同位置热误差之间的差异,使 H650GA 磨齿机 Z 轴在绝对坐标 $-500 \sim -900$ mm 的行程内往复运动,总行程为 400 mm。每隔 100 mm 取 1 个测点,则共有 5 个测点,分别记录为 P1~P5,如图 4 所示。




图 4 磨齿机丝杆热误差测点

Fig. 4 Diagram of thermal error measurement points on the lead screw of the gear grinding machine

在进给速度 2 500 和 5 000 mm/min 的不同工况下进行实验。实验流程如下:

1) 在机床运行之前,确保所有温度传感器和激光干涉仪正确布置,等待模拟量信号稳定。测量初始状态下丝杆各测点的定位误差并记录保存;

2) 机床开机运动,Z 轴以一定的进给速度往复运行,每 12 min 记录一次关键部位的温升值和丝杆定位误差。为了保证数据的稳定性,在各个测点停留 4 s。并且设置进给越程 8 mm,避免反向间隙对实验结果的影响;

3) 将不同时刻的定位误差减去初始状态下的测量值,获得热误差数据。将热误差和温度数据保存汇总。

2.3 实验结果分析

1) 温度数据分析

根据上述实验方案,使磨齿机进给系统连续运行,由 Pt100 温度传感器记录 T1~T11 各温度测点的温升变化情况,绘制 2 500 和 5 000 mm/min 不同进给速度下的温升曲线,如图 5 和 6 所示。

由温升曲线可知,在不同工况下,各关键部位整体温




图 5 2 500 mm/min 进给速度下的温升曲线

Fig. 5 Temperature rise curve at 2 500 mm/min




图 6 5 000 mm/min 进给速度下的温升曲线

Fig. 6 Temperature rise curve at 5 000 mm/min

升趋势一致,呈现出先迅速上升后趋于稳定。这是由于在前 100 min 内,进给系统的运行产生大量热量,导致了不均匀的温度场,温度变化幅度十分明显。大约连续运行 120 min 后,磨齿机达到热平衡状态,各关键部位温度波动较小。并且在 5 000 mm/min 进给速度下,各测点整体最大温升普遍比在 2 500 mm/min 时更高,这是由于更快的进给速度导致产生了更多的热量。其中电机处 T3 的温升最明显,在 2 500 和 5 000 mm/min 进给速度下,最高温升分别约为 7.5°C 和 10.6°C。其次是后轴承底座 T2,最高温升分别约为 5.1°C 和 8.6°C,前轴承底座处 T1 最高温升分别约为 3.0°C 和 4.5°C。后轴承比前轴承温升更明显,这是由于后轴承位于电机附近,电机的热辐射使后轴承的温度更高。丝杆螺母端面 T7 的温升也较为显著,这是由于丝杆的回转运动不断产生摩擦热量。在不同工况下,其最大温升分别约为 2.1°C 和 3.0°C。导轨是由日本 THK 公司生产的滚柱直线导轨,通过采用滚柱保持器,能获得低摩擦的平滑运动,热特性较好,因此温度变化不明显。并且由于机床内的通风散热和空气自然

对流,导致 T9 处的温度呈现出些许下降。

2) 热误差数据分析

根据实验方案,2 500 和 5 000 mm/min 进给速度下的热误差变化曲线分别如图 7 和 8 所示。




图 7 2 500 mm/min 进给速度下的热误差曲线
Fig. 7 Thermal error curve at 2 500 mm/min

由热误差变化曲线可知,丝杆上各测点的热误差均随时间逐步增大后趋于稳定。并且进给速度越快,所产生的热误差值越大,这与温度变化趋势一致。在开机后的前 20 min 内,热误差变化不明显,说明热误差相对于温度变化具有一定的滞后性。在 20~200 min 之间,各测点热误差迅速增大,连续运行 200 min 后,热误差基本趋于稳定,达到热平衡状态。其中在热误差迅速增长阶段,越靠近-900 mm 位置处热误差越大,这是由于-900 mm 测点一端更靠近电机,热量积累更快。达到热平衡状态

$$\mu = \begin{bmatrix} 0.014\ 5 & 0.984\ 2 & 0.917\ 7 & 0.730\ 2 & 0.000\ 5 & 0.000\ 2 & 0.022\ 2 & 0.002\ 6 & 0.002\ 4 & 0.000\ 2 & 0.001\ 2 \\ 0.015\ 6 & 0.003\ 7 & 0.023\ 8 & 0.047\ 9 & 0.996\ 5 & 0.000\ 3 & 0.098\ 2 & 0.981\ 3 & 0.985\ 8 & 0.998\ 4 & 0.993\ 0 \\ 0.970\ 0 & 0.012\ 1 & 0.058\ 5 & 0.222\ 0 & 0.003\ 0 & 0.999\ 6 & 0.879\ 6 & 0.016\ 1 & 0.011\ 8 & 0.001\ 4 & 0.005\ 9 \end{bmatrix} \quad (13)$$




图 9 最佳聚类数 c 计算结果

Fig. 9 Calculation results for the optimal number of clusters
在最终所得隶属度矩阵中,每一行代表一个簇类,共有 3 行,分别代表了 3 个簇类。每一列分别对应 T1 至 T11 温度测点。在每一列中,最大的值所对应的行号代表该温度测点所隶属的簇类。依据隶属度矩阵计算结果,可以确定 T1~T11 的聚类结果如表 2 所示。




图 8 5 000 mm/min 进给速度下的热误差曲线
Fig. 8 Thermal error curve at 5 000 mm/min

之后,各位置测点的热误差之间呈明显的线性关系,越接近-500 mm 位置处热误差越大,这是由于丝杆一端浮动一端固定的安装方式所导致。在 2 500 和 5 000 mm/min 进给速度下的最大热误差值分别约为 3.65 和 6.10 μm 。

3 热误差建模

3.1 最佳温度特征点筛选结果

以热误差实验中 2 500 和 5 000 mm/min 进给速度下获得的实验数据作为训练样本,根据式(6),通过 PC 指标确定最佳聚类数 c 为 3,其计算结果如图 9 所示。并且根据式(1)、(4)和(5)计算得到模糊隶属度矩阵,如式(13)所示。

表 2 温度传感器聚类结果	
Table 2 Clustering results of temperature sensors	
类别	温度测点
1	T2,T3,T4
2	T5,T8,T9,T10,T11
3	T1,T6,T7

由表 2 可知,11 个温度测点按照相似程度被分为 3 类,再利用灰色关联度算法计算出每个温度测点与丝杆热误差之间的关联程度。根据式(7),得到灰色关联度计算结果如表 3 所示。
根据表 3 的计算结果,将 11 个温度测点和丝杆热误差之间的关联度进行排序:T7>T1>T6>T3>T4>T2>T9>T5>T8>T11>T10。再结合表 2 和 3,将每个类别中与热

误差关联度最高的温度测点作为关键温度特征点,用于最终的热误差建模。具体来说,类别 1 中选取 T3,类别 2 中选取 T9,类别 3 中选取 T7。因此,最终确定 T3、T7 和 T9 为关键温度特征点。

表 3 灰色关联分析结果

Table 3 Results of grey relational analysis

温度测点	关联度	温度测点	关联度
T1	0.931 2	T7	0.941 9
T2	0.916 2	T8	0.748 3
T3	0.927 4	T9	0.913 8
T4	0.920 2	T10	0.660 3
T5	0.850 1	T11	0.694 1
T6	0.931 0		

利用模糊 C 均值聚类算法和灰色关联分析对温度变量进行优化,温度变量由 10 个减少到 3 个,不仅提高了建模效率且避免了部分温度测点之间的共线性问题,有利于提升热误差模型预测精度。

3.2 RIME-BP 热误差建模

根据关键温度特征点的筛选结果,以 T3、T7 和 T9 的温度数据和丝杆位置坐标作为模型的输入,丝杆热误差作为输出,构建 RIME-BP 热误差模型。基本步骤如下:

初始化 BP 神经网络参数:BP 神经网络的输入层、隐含层、输出层的神经元节点个数分别为 4、10 和 1,即待优化的连接权值和神经元偏置一共有 $61(4\times10+10\times1+10+1)$ 个;隐含层和输出层的激活函数分别选用 tansig 和 purelin 函数;学习速率设为 0.01;目标误差设为 0.000 1;BP 神经网络训练最大迭代次数为 100。在霜冰优化算法中,设置霜体种群数量为 20;最大迭代次数为 100;将 BP 神经网络的损失函数作为霜冰算法的适应度函数,使用霜冰优化算法确定 BP 神经网络的初始连接权值和偏置。

热误差实验中,在两种工况下一共采集到 300 组样本,采用 K 折交叉验证法将样本数据划分为 5 组测试集和训练集。具体来说,从第 1 个样本开始每 5 个样本取 1 个组成测试集,其余样本组成训练集。再从第 2 个样本开始每 5 个样本取 1 个构建测试集,依此类推,一共构建了 5 组 K 折交叉验证子集。这样能保证每个样本数据都能被作为测试集来评估模型,使评估结果更为可靠。并且每个子集都包含了不同工况下的样本数据,有利于模型学习到更全面的数据信息,提高模型的泛化性和预测精度。

为了消除量级差异对后续建模的影响,采用最大最

小法对所有样本进行归一化处理,具体方法如式(14)所示。

$$x_k = \frac{[\max(y) - \min(y)] [x - \min(x)]}{\max(x) - \min(x)} + \min(y)$$

(14)

式中: x 为原样本数据; x_k 为归一化处理后的样本数据; $\max(y)$ 取值为 1, $\min(y)$ 取值为 0,表示将原数据取值范围映射到区间 $[0,1]$ 之间。

利用归一化处理后的训练集样本对 RIME-BP 热误差模型进行训练。以子集 1 的训练样本为例,RIME 算法在优化 BP 神经网络过程中,适应度函数变化情况如图 10 所示。




图 10 适应度变化曲线
Fig. 10 Fitness variation curve

4 热误差模型性能验证和对比分析


为了更直观地体现所提出方法的优越性和有效性,采用基于遗传算法 (genetic algorithm, GA) 优化的 GA-BP、传统 BP 以及 SVM 模型进行对比。利用相同的训练集对不同模型进行训练,相同的测试集对各模型进行评估。各模型分别在 2 500 和 5 000 mm/min 的不同工况下进行热误差预测,本文选用决定系数 R^2 作为模型的预测性能评估指标,量化不同模型的预测精度和鲁棒性,如式(15)所示。

$$R^2 = \frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2}$$


(15)

式中: $\hat{y}_i$ 表示实际输出; y_i 表示期望输出; $\bar{y}$ 为期望值平均值; R^2 的取值范围为 $[0,1]$,其计算结果越接近 1,则表示模型预测精度越高。

利用 K 折交叉验证的 5 组子集分别对模型进行训练和验证。以子集 1 样本为例,所有模型在两种不同工况下预测结果如图 11 和 12 所示。为了方便对比,根据预测结果对每个子集计算 R^2 后,取平均值作为模型性能评估指标值,计算结果如表 4 所示。




(a) 热误差预测结果
(a) Thermal error prediction results




(b) 残差图
(b) Residual plot

图 11 2 500 mm/min 工况的热误差预测结果
Fig. 11 Thermal error prediction results at 2 500 mm/min



(a) 热误差预测结果
(a) Thermal error prediction results



(b) 残差图
(b) Residual plot

图 12 5 000 mm/min 工况的热误差预测结果
Fig. 12 Thermal error prediction results at 5 000 mm/min

表 4 不同模型的 R^2 计算结果

Table 4 Calculation results of R^2 for different models

模型	R^2 (子集 1)	R^2 (子集 2)	R^2 (子集 3)	R^2 (子集 4)	R^2 (子集 5)	平均 R^2	平均 R^2 相对变化量/%
RIME-BP	0.996	0.997	0.994	0.991	0.996	0.995	0
GA-BP	0.936	0.969	0.954	0.980	0.964	0.961	3.54
BP	0.868	0.907	0.873	0.926	0.965	0.908	9.58
SVM	0.759	0.858	0.911	0.803	0.894	0.845	17.75

注:平均 R^2 相对变化量=(RIME-BP 的平均决定系数-模型平均决定系数)/该模型的平均决定系数

由图 11 和 12 的预测结果可知,在不同工况下 RIME-BP 模型的残差曲线整体更为平缓,在 0 轴附近波动,说明预测值更接近测量值,预测偏差小。从表 4 中可知,在交叉验证中的每个子集下,RIME-BP 模型的 R^2 均超过 0.990,决定系数的计算结果波动较小,且在每个数据集上均高于其他模型,这说明 RIME-BP 模型在不同数据集上的预测性能十分稳定,对于未知数据的适应能力和泛化能力较强,体现出该模型良好的泛化性和稳定性。此外,RIME-BP 模型的平均决定系数高达 0.995,相比于 GA-BP、BP 和 SVM 模型分别提高了 3.54%、9.58% 和 17.75%,表现出更好的预测精度和鲁棒性。并且该模型相对于传统的 BP 模型,热误差预测表现显著提升,验

证了所提出方法的有效性。RIME-BP 热误差模型通过霜冰算法强大的全局寻优能力以及神经网络隐含层的非线性映射,能够更好地捕捉复杂的非线性热误差关系,从而在预测精度方面表现更佳。

5 结 论

为了有效抑制数控磨齿机进给系统热误差,提高被加工产品一致性,本文提出了一种基于霜冰算法优化 BP 神经网络的热误差预测模型。总结如下:

1) 本文提出使用霜冰优化算法对 BP 神经网络的初始连接权重和偏置进行优化,减少了初始参数的随机性

对模型性能的影响,避免模型训练过程出现局部极值和过拟合问题;

2) 利用模糊 C 均值聚类算法对温度测点进行聚类,并采用 PC 指标确定最优聚类数。通过灰色关联度算法筛选每一类中与热误差相关度最高的关键温度特征,提高建模效率并减少输入特征之间的共线性问题;

3) 在 H650GA 型磨齿机上进行实例预测验证,利用 K 折交叉验证法以确保模型性能评估的稳定性和可靠性。实验结果表明:相比于 GA-BP、BP 和 SVM 模型, RIME-BP 模型的 R^2 分别提高了 3.54%、9.58% 和 17.75%,表现出更好的预测性能和鲁棒性。所提出方法为热误差补偿提供了系统的理论和技术支撑,具有较好的工程应用价值。

参考文献

- [1] ZHANG Y, LIU ZH G, LIU Q Y, et al. A comprehensive prediction and compensation method of spindle thermal error for a CNC grinding machine[J]. Digital Engineering, 2024, 2: 100012.
- [2] LI Y, ZHAO W H, LAN SH H, et al. A review on spindle thermal error compensation in machine tools[J]. International Journal of Machine Tools and Manufacture, 2015, 95: 20-38.
- [3] MA CH, ZHAO L, MEI X S, et al. Thermal error compensation of high-speed spindle system based on a modified BP neural network[J]. The International Journal of Advanced Manufacturing Technology, 2017, 89(9): 3071-3085.
- [4] 岳玉霞,王秀山,李利军. 五轴数控机床的误差实时补偿控制器[J]. 电子测量技术, 2021, 44(13): 145-149.
YUE Y X, WANG X SH, LI L J. Real time error compensation controller for five axis CNC machine tools[J]. Electronic Measurement Technology, 2021, 44(13): 145-149.
- [5] WEI X Y, FENG X G, MIAO E M, et al. Sub-regional thermal error compensation modeling for CNC machine tool worktables[J]. Precision Engineering, 2022, 73: 313-325.
- [6] GUI H Q, LIU J L, MA CH, et al. New machine learning application platform for spatial-temporal thermal error prediction and control with STFGCN for ball screw system[J]. Mechanical Systems and Signal Processing, 2023, 192: 110240.
- [7] 李彬,张云,王立平,等. 基于遗传算法优化小波神经网络数控机床热误差建模[J]. 机械工程学报, 2019, 55(21): 215-220.
LI B, ZHANG Y, WANG L P, et al. Modeling for CNC

machine tool thermal error based on genetic algorithm optimization wavelet neural networks[J]. Journal of Mechanical Engineering, 2019, 55(21): 215-220.

- [8] WEI X Y, YE H H, WANG G, et al. Adaptive thermal error prediction for CNC machine tool spindle using online measurement and an improved recursive least square algorithm[J]. Case Studies in Thermal Engineering, 2024, 56: 104239.
- [9] ZHANG J F, FENG P F, CHEN CH, et al. A method for thermal performance modeling and simulation of machine tools[J]. The International Journal of Advanced Manufacturing Technology, 2013, 68(5): 1517-1527.
- [10] LIANG Y CH, LI W D, LOU P, et al. Thermal error prediction for heavy-duty CNC machines enabled by long short-term memory networks and fog-cloud architecture[J]. Journal of Manufacturing Systems, 2022, 62: 950-963.
- [11] 孙兴伟,杨铜铜,杨赫然,等. 基于 CNN-GRU 组合神经网络的数控机床进给系统热误差研究[J]. 仪器仪表学报, 2023, 44(10): 219-226.
SUN X W, YANG T T, YANG H R, et al. Thermal error prediction of CNC machine tool feed system based on CNN-GRU combined neural network[J]. Chinese Journal of Scientific Instrument, 2023, 44(10): 219-226.
- [12] 李国龙,陈孝勇,李喆裕,等. 采用天鹰优化卷积神经网络的精密数控机床主轴热误差建模[J]. 西安交通大学学报, 2022, 56(8): 51-61.
LI G L, CHEN X Y, LI ZH Y, et al. Thermal error modeling of spindle for precision CNC machine tool based on AO-CNN[J]. Journal of Xi'an Jiaotong University, 2022, 56(8): 51-61.
- [13] DAI Y, WANG X, LI ZH L, et al. Thermal error modeling of electric spindles based on cuckoo algorithm optimized Elman network[J]. The International Journal of Advanced Manufacturing Technology, 2024, 132(3): 1365-1375.
- [14] CHENG Y N, QIAO K ZH, JIN SH H, et al. Research on electric spindle thermal error prediction model based on DBO-SVM[J]. The International Journal of Advanced Manufacturing Technology, 2024, 132(7): 3333-3347.
- [15] 杨赫然,李帅,孙兴伟,等. 基于改进松鼠搜索算法优化神经网络的数控机床进给系统热误差预测[J]. 仪器仪表学报, 2024, 45(1): 60-69.
YANG H R, LI SH, SUN X W, et al. Thermal error prediction of CNC machine tool feed system based on neural network optimized by improved squirrel search algorithm[J]. Chinese Journal of Scientific Instrument,

- 2024, 45(1): 60-69.
- [16] WU CH Y, XIANG S T, XIANG W SH. Spindle thermal error prediction approach based on thermal infrared images: A deep learning method [J]. Journal of Manufacturing Systems, 2021, 59: 67-80.
- [17] 李帅, 杨赫然, 孙兴伟, 等. 基于改进神经网络算法的数控钻攻中心进给轴热误差预测[J]. 电子测量与仪器学报, 2023, 37(9): 234-242.
- LI SH, YANG H R, SUN X W, et al. Prediction of thermal error of CNC drilling center feed axis based on improved neural network algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(9): 234-242.
- [18] 郭世杰, 张学炜, 张楠, 等. 机床主轴热关键点选择与典型转速热误差预测[J]. 吉林大学学报(工学版), 2023, 53(1): 72-81.
- GUO SH J, ZHANG X W, ZHANG N, et al. Thermal key point select and error prediction under typical speed of machine tool spindle[J]. Journal of Jilin University (Engineering and Technology Edition), 2023, 53(1): 72-81.
- [19] LI G Q, TANG X D, LI ZH Y, et al. The temperature-sensitive point screening for spindle thermal error modeling based on IBGOA-feature selection[J]. Precision Engineering, 2022, 73: 140-152.
- [20] 陈庚, 郭世杰, 丁强强, 等. 数控车床主轴热误差 SHO-LSTM 预测建模[J]. 工程科学与技术, 2024, 56(2): 277-288.
- CHEN G, GUO SH J, DING Q Q, et al. SHO-LSTM prediction model for CNC lathe spindle thermal errors[J]. Advanced Engineering Sciences, 2024, 56(2): 277-288.
- [21] REZAEE B. A cluster validity index for fuzzy clustering[J]. Fuzzy Sets and Systems, 2010, 161(23): 3014-3025.
- [22] 张伟, 叶文华. 基于灰色关联和模糊聚类的机床温度测点优化[J]. 中国机械工程, 2014, 25(4): 456-460.
- ZHANG W, YE W H. Optimization of temperature measuring points for machine tools based on grey correlation and fuzzy clustering analysis[J]. China Mechanical Engineering, 2014, 25(4): 456-460.
- [23] SU H, ZHAO D, HEIDARI A A, et al. RIME: A physics-based optimization[J]. Neurocomputing, 2023, 532: 183-214.

- [24] BAO L, XU Y L, ZHOU Q, et al. Thermal error modeling of numerical control machine based on beetle antennae search back-propagation neural networks [J]. International Journal of Computational Intelligence Systems, 2023, 1:1-2.

作者简介



肖捷, 2022 年于中南林业科技大学获得学士学位, 现为中南林业科技大学硕士研究生, 主要研究方向为螺旋锥齿轮磨齿机热误差建模与补偿技术。

E-mail: 1079013524@qq.com


Xiao Jie received his B.Sc. degree from Central South University of Forestry and Technology in 2022. He is currently a master student at Central South University of Forestry and Technology. His main research interests include thermal error modeling and compensation technology for spiral bevel gear grinding machines.



王志永 (通信作者), 1996 年于沈阳工业大学获得学士学位, 1999 年于东北大学获得硕士学位, 2006 年于中南大学获得博士学位, 现为中南林业科技大学副教授, 主要研究方向为复杂齿轮切齿加工理论及其数字化制造技术。

E-mail: wangzy@csuft.edu.cn

Wang Zhiyong (Corresponding author) received his B.Sc. degree from Shenyang Institute of Technology in 1996, received his M.Sc. degree from Northeast University in 1999, and received his Ph.D. degree from Central South University in 2006. He is currently an associate professor at Central South University of Forestry and Technology. His main research interests include the machining theory and digital manufacturing technology of complex gears.



薛芮, 2016 年于安徽工程大学获得学士学位, 2021 年于中国矿业大学获得硕士学位, 现为合肥工业大学博士研究生, 主要研究方向为数控加工技术、运动控制。

E-mail: xuerrui315@163.com

Xue Rui received his B.Sc. degree from Anhui Polytechnic University in 2016, received his M.Sc. degree from China University of Mining and Technology in 2021. He is currently a Ph.D. candidate at Hefei University of Technology. His main research interests include CNC machining technology and motion control.