DOI: 10.13382/j.jemi. B2306486

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*

李 $\mu^{1,2}$ 杨赫然^{1,2} 孙兴伟^{1,2} 潘 飞^{1,2} 董祉序^{1,2} 刘 寅^{1,2}

(1. 沈阳工业大学机械工程学院 沈阳 110870;2. 辽宁省复杂曲面数控制造技术重点实验室 沈阳 110870)

摘 要:为降低数控机床热误差对数控钻攻中心的影响,提高工件的加工精度,解决不同工况下热误差预测精度不佳的问题。 在进给速度为 10 m/min、环境温度 20°的工作条件下进行数控机床进给系统热误差测量实验,采用鹈鹕优化算法对神经网络进 行优化,确定 BP 神经网络的最优权值和阈值,建立进给系统热误差的 POA-BP 预测模型,并与传统 BP 神经网络和 GA-BP 神经 网络以及 SCN 随机配置网络进行实验对比分析。结果表明,传统 BP 神经网络预测平均相对误差为 12.23%,GA-BP 神经网络 平均相对误差为 11.5%,SCN 预测模型预测平均相对误差为 12.71%,POA-BP 预测模型预测平均相对误差为 9.93%,精度有所 提升。结论:提出的鹈鹕优化算法改进的神经网络在热误差预测中具有较强的有效性和精确性,可以提高进给运动精度,为热 误差补偿的实现提供理论指导。

关键词:进给系统;热误差;鹈鹕优化算法;神经网络预测 中图分类号:TH161⁺.1;TN05 **文献标识码:**A 国家标准学科分类代码:460.4030

Prediction of thermal error of CNC drilling center feed axis based on improved neural network algorithm

Li Shuai^{1,2} Yang Heran^{1,2} Sun Xingwei^{1,2} Pan Fei^{1,2} Dong Zhixu^{1,2} Liu Yin^{1,2}

School of Mechanical Engineering, Shenyang University of Technology, Shenyang 110870, China;
 Key Laboratory of Numerical Control Manufacturing Technology for Complex Surfaces

of Liaoning Province, Shenyang 110870, China)

Abstract: To reduce the impact of thermal errors on CNC machine tools, improve the machining accuracy of workpieces, and solve the problem of poor thermal error prediction accuracy under different working conditions. The thermal error measurement experiment of the CNC machine tool feed system is conducted under working conditions of a feed speed of 10 m/min and an ambient temperature of 20°. The Pelican optimization algorithm is used to optimize the neural network, determine the optimal weight and threshold of the BP neural network, and the thermal error of the feed system prediction model of POA-BP is established. The experiment is compared and analyzed with traditional BP neural network, GA-BP neural network and the SCN random configuration network. The results show that the average relative error of traditional BP neural network prediction is 12. 23%, the average relative error of GA-BP neural network is 11. 5%, the average relative error of SCN prediction model is 12. 71%, and the average relative error of POA-BP prediction model is 9.93%, which improves the accuracy. Conclusion: The neural network improve the accuracy of feed motion and provide theoretical guidance for the realization of thermal error prediction, which can improve the accuracy of feed motion and provide theoretical guidance for the

Keywords: feed system; thermal error; pelican optimization algorithm; neural network prediction

收稿日期: 2023-04-28 Received Date: 2023-04-28

^{*}基金项目:2022年度辽宁省教育厅高等学校基本科研项目面上项目(LJKMZ20220459)、辽宁省应用基础研究计划项目(2022JH2/101300214) 资助

0 引 言

数控机床作为制造业重要的一部分,其加工精度至 关重要,而在机床的总体误差中,热误差所占比重很大, 会直接影响加工件的精度[1]。在机床的加工误差中热误 差所占的比重约40%左右,而在更加精密的机床中,热误 差占比更是达到 70% [2-3],因此可以降低热误差来提高机 床的工作精度。机床热误差的控制降低主要有热误差预 防和热误差补偿两种方法^[4],相比于热误差预防,热误差 补偿具有更有效、更简单、经济效益更好的优点[5]。而热 误差补偿关键在于热误差的预测,尤其是实现数控自动 化后,操作者不能进行人工的误差补偿,需要机床自身保 持加工精度,因此准确预测机床的热误差并合理避免其 带来的加工精度变化非常重要[6]。目前,机床热误差预 测的模型和建立涉及到许多预测算法,有 BP 神经网络 预测、支持向量机预测、径向基(radial basis function, RBF)预测等。而传统的预测算法存在许多局限性,因此 产生了许多优化算法与预测算法相结合的新型预测算 法,解决了原本预测算法的缺点。

有学者针对进给系统的热误差采用智能算法进行了 预测分析,也有学者对机床的主轴进行了预测探讨。王 新孟等^[7]提出最小二乘支持向量机(least squares support vector machine,LSSVM)预测方法来降低热误差对机床定 位精度的影响。朱星星等^[8]提出了一种基于协同训练支 持向量机回归算法(COSVR)的方法来进行热误差建模。 靳增锋等^[9]根据改进的 BP 算法(LMBP)建立了热误差 模型。魏新园等^[10]提出了基于偏最小二乘法的热误差 稳健建模算法。问梦飞等^[11]采用鲸鱼优化算法(whale optimization algorithm, WOA)和支持向量回归(support vector regression,SVR)相结合的方法,建立电主轴的热误 差预测模型。Liu 等^[12]提出了一种结合温度场检测、自 适应 FCM (fuzzy c-means) 聚类算法和径向基函数网络 (radial basis function network, RBF)神经网络模型的方 法。Fu 等^[13]和李国龙等^[14]提出了基于在机测量 CES-UKF 和 AO-CNN 的数控机床主轴热误差模型。魏弦^[15] 基于 KPCA 自变量优化方法结合进给系统误差建模理论 建立了热误差模型。黄智等[16]提出了一种采用鲨鱼嗅 觉优化(SSO)算法和神经网络的复合建模方式。Li 等^[17]建立了 AO(aquila optimizer) 优化的 LSSVM 预测模 型。谭峰等^[18]提出一种基于长短期记忆(long short-term memory,LSTM)循环神经网络的数控机床热误差预测方 法。孙昂等^[19]采用蝙蝠算法(bat algorithm, BA)优化小 波神经网络对主轴轴向热误差进行预测研究。Cheng 等^[20]将 LSTM 和卷积神经网络 (convolutional neural networks, CNN)结合建立了热误差模型。Ye 等^[21]提出

了一种基于自适应最小绝对收缩选择算子(least absolute shrinkage and selection operator, LASSO)和极端梯度提升 (XGBoost)算法改进的热误差稳健预测方法。郑金勇 等^[22]对机床主轴建立了遗传算法(genetic algorithm, GA) 优化的灰色神经网络热误差预测模型。

由前人的研究成果可以发现,虽然上述文献建立的 热误差模型都具有较高的预测精度,但应用机床各异,模 型泛化能力有限,预测算法特点各异,针对不同工况下进 给系统热误差预测问题,依然需要建立更加精准的预测 模型进行针对性的深入研究。

1 基于改进 BP 神经网络的热误差预测模型

BP 神经网络具有结构简单、较强的适应性和自学习 性等优点^[23-24],因此广泛用于数据的预测。但其预测精 度受初始权值、阈值的影响较大,因此有必要对神经网络 进行相应优化,从而达到提高训练速度、不易陷入局部极 值的目的。

本文采用鹈鹕优化算法(pelican optimization algorithm,POA)对BP神经网络进行初始权值、阈值的优 化,通过进给系统热误差测量实验,得到不同温升时丝杠 各位置处的热误差,将得到的实验数据作为训练样本输 入至预测模型中进行训练,从而建立热误差补偿模型 POA优化BP流程如图1所示。采用POA算法优化BP 神经网络实现的前提是有实验数据的支持,因此需要进 行热误差实验来进行相关数据的采集,将采集的相关数 据进行分类整理,整理成能输入到神经网络中进行预测 的数据集,因输入输出各项数据的类型不同因此需要将 数据进行归一化处理,再将归一化后的数据输入到改进 后的神经网络进行训练和预测。

鹈鹕优化算法改进神经网络算法的主要步骤流 程为:

1)种群初始化。设定种群规模、迭代次数。

种群初始化公式如下:

 $X_{i,j} = l_j + rand \cdot (u_j - l_j)$ (1) 式中: $X_{i,j}$ 为第 *i* 个鹈鹕在第 *j* 维的位置, *rand* 是[0,1]之 间的随机数, u_j 和 l_j 分别是求解问题的上下边界, 也就是 文中权值阈值的上下边界。其中 *i*=1,2,3,…,*N*,*j*=1,2, 3,…,*M*,*N* 为鹈鹕种群数量, *M* 为求解问题维度。

鹈鹕种群位置表示为如下矩阵:

	$\begin{bmatrix} X_1 \end{bmatrix}$			$ X_{1,1} $	•••	$X_{1,j}$	•••	$X_{1,M}$	
	:			:				:	
<i>X</i> =	X_i		=	$X_{i,1}$		$X_{i,j}$		$X_{i,M}$	
	:			:	•••	•••		:	
	X_N	N×M		$X_{N,1}$		$X_{N,j}$		$X_{N,M} \rfloor_{N \times M}$	
								(2)



图 1 POA-BP 算法流程 Fig. 1 Flow chart of the POA-BP algorithm

其中,X代表鹈鹕种群矩阵,X_i为第 i 个鹈鹕。

2) 对数据集归一化处理并划分训练集与测试集。

3) 初始化 BP 神经网络模型参数,包括输入层、隐含 层、输出层神经元个数、神经网络层数以及隐含层和输出 层激活函数等等。

4)使用 POA 对 BP 神经网络优化,将网络预测值与 实测值之间的误差作为模型适应度函数并计算目标函 数值。

鹈鹕种群的目标函数可以表示为:

$$\boldsymbol{F} = \begin{bmatrix} \boldsymbol{F}_{1} \\ \vdots \\ \boldsymbol{F}_{i} \\ \vdots \\ \boldsymbol{F}_{N} \end{bmatrix}_{N \times 1} = \begin{bmatrix} \boldsymbol{F}(\boldsymbol{X}_{1}) \\ \vdots \\ \boldsymbol{F}(\boldsymbol{X}_{i}) \\ \vdots \\ \boldsymbol{F}(\boldsymbol{X}_{N}) \end{bmatrix}_{N \times 1}$$
(3)

根据鹈鹕觅食的第1阶段、第2阶段的位置更新公 式更新种群位置直至达到迭代次数结束。

5) 第1阶段位置更新公式如下:

$$X_{i,j}^{P_1} = \begin{cases} X_{i,j} + rand \cdot (P_j - I \cdot X_{i,j}), F_p < F_i \\ X_{i,j} + rand \cdot (X_{i,j} - P_j), \notin \mathbb{td} \end{cases}$$
(4)

式中: $X_{i,j}^{p_1}$ 为基于第1阶段更新后第i个鹈鹕的第j维的 位置;rand 是[0,1]范围内的随机数;I为1或2的随机 整数; P_j 为猎物的第j维的位置; F_p 为猎物的目标函 数值。

在 POA 算法中,如果目标函数值在该位置得到改

善,则接受鹈鹕的新位置。在这种类型的更新中,也被称 为有效更新,该算法不能移动到非最优区域。这个过程 可以如式(5)所示。

$$X_{i} = \begin{cases} X_{i}^{p_{1}}, F_{i}^{p_{1}} < F_{i} \\ X_{i}, \ddagger \& \end{cases}$$
(5)

式中: X_i^{P1} 为第 i 个鹈鹕的新位置; F_i^{P1} 为基于第 1 阶段更新后的第 i 个鹈鹕的新位置的 X_i^{P1} 目标函数值。

第2阶段位置更新公式为:

$$X_{i,j}^{P2} = X_{i,j} + R \cdot (1 - \frac{t}{T}) \cdot (2 \cdot rand - 1) \cdot X_{i,j}$$
(6)

式中: *X^{p2}_{i,j}* 为基于第 2 阶段更新后第 *i* 个鹈鹕的第 *j* 维的 位置; *rand* 是[0,1]范围内的随机数; *R* 为 0 或 2 的随机 整数; *t* 为当前迭代次数; *T* 为最大迭代次数。

6)根据最优种群即最优权值和阈值参数构建 POA-BP 模型。

2 进给系统热误差实验

2.1 热误差测量实验布置及结果

为获得足够的训练样本来建立热误差模型以及验证 预测模型预测情况的准确性,在 i5M1.4 智能立式加工中 心建立 Y 轴进给系统的热误差测量实验。如图 2 所示, 工作台通过导轨在鞍座上进行横向移动的方向即为 X 轴,鞍座通过导轨滑块在床身上纵向运动,即 Y 轴。



图 2 i5M1.4 数控钻攻加工中心 Fig. 2 i5M1.4 CNC drilling and tapping machining center

热误差实验在进给速度为10 m/min、环境温度20 ℃ 的工作条件下进行,主要需要用到温度传感器、温度数显 仪表、激光干涉仪、接触式测温仪、计算机等主要实验设备,具体实验设备测量布置情况如图3 所示,因其实际行程 380 mm 将丝杠分为 P1~P8 等 8 个测量点位。

根据进给系统热源分布情况及传感器布置原则选择 2 端轴承座表面及螺母表面进行温度传感器布置得到测 点温度 T1、T3、T2。为了能更全面的了解进给系统的温



Fig. 3 Schematic diagram of thermal error measurement

度分布情况,采用接触式测温仪对丝杠中点以及靠近浮动端轴承(后轴承)丝杠处进行测量得到丝杠上温度 T4、 T5。温度传感器的实际布置情况如图 4~6 所示。取机 床内和机床外平均温度 T6 的平均温度作为环境温度参 考标准。



图 4 前轴承表面温度测点 T1 示意图 Fig. 4 Schematic diagram of front bearing surface temperature measuring point T1



图 5 螺母座表面温度测点 T2 示意图 Fig. 5 Schematic diagram of front bearing surface temperature measuring point T2

激光干涉仪作为热误差的重要测量仪器,其对光与 镜组的布置是实验进行的前提,测量时需要保证激光头 射出的光线经过分光镜、固定反射镜组成的干涉镜反射 回的光线与角锥放射镜反射回的光线汇聚成一条光线射 到回光孔,且随着角锥反射镜的移动回光孔的光斑不动, 实验激光测量回路如图7所示。

因此镜组布置有如下几点:1)将固定反射镜与分光



图 6 后轴承表面温度测点 T3 示意图

Fig. 6 Schematic diagram of front bearing surface temperature measuring point T3 temperature measuring points



Fig. 7 Experimental laser measurement loop

镜组成的干涉镜固定在机床外壳。2)将移动锥角反射镜 固定在机床工作台上。3)调整激光头、干涉镜以及反射 镜保证三者在一条直线上。激光干涉仪及其镜组布置如 图 8 所示。



图 8 激光干涉仪及镜组布置示意图 Fig. 8 Schematic diagram of laser interferometer and mirror group

各个测点的温度随时间变化趋势如图 9 所示,内外 环境温度稳定在 20 ℃左右,Y 轴进给系统的整体温度呈 先快后慢再稳定的趋势,前 50 min 温度上升较快,随后 缓慢上升,最后在 60 min 左右达到热平衡。前轴承座的 温度 T1 最高,稳态时达到 27 ℃左右,其次是螺母座的温 度,稳态时达到 23 ℃左右,后轴承的温度最低,稳态时达 到 21 ℃左右。滚珠丝杠中点的温度很大来源于螺母副 产生的热量,较来自轴承尾座的的热量传递更多,因此丝 杠中点的温度 T4 要大于靠近轴承尾座的温度 T5。T6 作 为环境温度,因实验季节为夏季,实验时间较长,从中午 到晚上温度会有所下降,其温度变化的较为缓慢且变化 范围不超过0.3℃。



图 9 不同位置处温度随时间的变化曲线



图 10 为各测点温升随时间变化的趋势,达到热平衡时前轴承温升 ΔT1 在 8 ℃左右,螺母处温升 ΔT2 在 4 ℃ 左右,后轴承温升丝杠中点温升 ΔT4 在 6 ℃左右,其中 ΔT1 温升最大,ΔT3 温升最小。







2.2 热误差数据分析

热误差采用激光干涉仪进行测量,激光干涉仪只能 测量出定位误差,将定位误差减去初始测量的定位误差 即为各时间段各测点的热误差,发热引起的偏移以远离 电机端(前轴承)的方向为正,图11为丝杠不同位置处定 位误差随时间变化的趋势曲线,其中0min时为初始定位 误差,图12为热误差随时间变化曲线,从图中可以看出 离电机端越远的丝杠测点热误差越大,初始定位误差为 负,逐渐向正方向偏移,这是由于一端固定一端浮动的安 装方式造成的,在50min前热偏移量较大,随后缓慢增 加直至基本稳定。其中 P1处即后轴承处的热误差最大, 最大达到53.65 μm。





3 数控机床进给系统热误差预测模型及 验证

3.1 POA-BP 热误差预测模型的建立

根据热误差实验测量结果,确定 BP 神经网络的结构。选择温度测点 T1、T2、T3 的温升数据和丝杠各点位置作为 BP 神经网络的输入,输入层节点 m=4,预测输出为热误差,故输出节点 n=1 个,根据隐含层节点计算公式^[25] $k = \sqrt{m \times n} + 1$ 得 k = 3,隐含层层数越深,理论上拟合函数的能力增强,效果理应更好,但是实际上更深的层数可能会带来过拟合的问题,同时也会增加训练难度,使模型难以收敛。因此对一般简单的数据集 1 层或 2 层的隐含层已经足够。

最终根据输入层、隐含层、输出层的节点个数建立如图 13 所示的 3 层 BP 神经网络结构:





图 13 BP 神经网络结构 Fig. 13 The BP neural network structure

图 13 中, ΔT1、ΔT2、ΔT3 为滚珠丝杠进给系统 3 个 关键点的温升, P 为丝杠上位移测点位置, ΔT1、ΔT2、 ΔT3、P 皆为 BP 神经网络的节点输入值, E 为热误差预测 值, 为节点输出值。W_{ij}、W_{jk} 为 BP 神经网络的权值和 阈值。

网络中输入层到隐藏层之间设置 tansig 为激活函数, 隐藏层到输出层设置线性 purelin 函数为激活函数; 然后利用鹈鹕算法优化 BP 神经网络的初始权值、阈值。

本文采用 Y 轴进给系统的前轴承、螺母、后轴承 3 个 温度测点的温升以及丝杠测点位置作为输入,热误差作 为输出,实现热误差预测模型的建立,实验数据一共 240 组,实验数据如表 1 所示。

表 1 热误差实验数据 Table 1 Experimental data for thermal error

	不同	不同位置温升/℃			————————————————————————————————————								
编号 Δ	A T 1	A T 2	A T2	P1	P2	P3	P4	Р5	P6	P7	P8		
	$\Delta I 1$	$\Delta I 1 \Delta I 2$	$\Delta T3$	(0,0)	(55,0)	(110,0)	(165,0)	(220,0)	(275,0)	(330,0)	(385,0)		
1	0.5	0.4	0.1	17.30	15.95	15.40	13.90	12.90	11.75	11.30	10.50		
2	1.3	1.0	0.2	26.50	24.80	23.50	21.85	20.05	18.60	17.60	16.20		
3	2.1	1.3	0.5	33.00	30.85	29.10	27.35	24.85	23.00	21.35	20.75		
4	3.4	1.8	0.7	36.90	34.80	32.75	31.00	27.75	26.15	24.30	23.35		
5	3.9	1.9	0.8	38.75	37.10	35.05	32.85	30. 20	28.10	26.30	25.25		
6	4.5	2.2	0.8	41.90	39.75	37.45	35.20	32.30	29.95	27.90	26.85		
7	4.7	2.4	0.8	44.05	41.80	39.50	37.25	34.35	31.85	29.40	28.35		
8	5.3	2.5	0.8	46.60	43.85	41.60	39.00	36.10	33.15	31.55	29.25		
9	5.6	2.4	0.8	48.40	45.95	43.50	41.30	38.10	35.05	33.40	30.65		
10	6.1	2.6	1.1	50.80	48.15	45.40	43.10	39.80	36.90	34.95	32.85		
11	6.2	2.7	1.1	51.75	49.45	46.45	43.80	40.80	37.55	35.35	33.35		
12	6.0	2.5	1.0	50.40	48.00	45.05	42.60	39.55	36.45	34.00	32.15		
13	6.0	2.4	1.0	50.25	47.95	44.35	42.10	38.75	35.85	33.10	31.55		
14	6.1	2.7	1.1	50.45	48.05	45.05	42.10	39.20	36.05	33.90	31.15		
15	6.9	3.1	1.3	51.80	49.33	46.15	43.55	40.15	37.15	35.15	33.10		
16	7.0	3.2	1.2	52.15	50.05	46.6	43.95	40.80	37.75	35.65	33.60		
17	7.1	3.2	1.3	52.2	49.80	46.35	43.85	40.45	37.50	34.70	32.90		
18	6.8	3.1	1.3	51.15	49.10	45.8	42.95	39.9	36.95	34.45	32.55		
19	6.9	3.1	1.4	51.35	49.35	46.05	43.35	40.00	37.05	34.45	31.80		
20	7.2	3.3	1.5	51.80	49.60	46.15	43.45	39.95	37.10	34.65	32.70		
21	7.6	3.7	1.7	53.00	49.20	46.00	43.40	40.00	37.10	34.50	32.55		
22	7.2	3.4	1.6	51.95	49.50	46.20	43.45	40.10	36.75	34.30	32.10		
23	7.5	3.6	1.7	52.60	50.15	47.12	44.10	40.75	37.75	35.05	32.85		
24	7.3	3.5	1.6	52.46	50.30	46.80	43.85	40.40	37.55	34.75	32.35		
25	8.0	4.0	1.8	54.00	51.95	48.20	45.45	42.00	39.1	36.10	33.75		
26	7.9	4.0	1.8	53.65	51.30	48.05	45.95	42.35	39.2	36.65	35.20		
27	7.9	3.9	1.7	53.45	51.15	48.00	45.05	41.50	38.7	35.75	33.80		
28	7.7	3.8	1.7	53.10	50.95	47.50	44.65	41.50	38.5	35.60	33.75		
29	7.8	3.8	1.8	53.30	51.20	47.80	45.30	41.50	38.5	35.75	33.75		
30	7.4	3.6	1.6	52.40	50.45	47.30	44. 25	41.10	37.95	35.55	33.15		

3.2 模型对比

为验证文中采用 POA 优化 BP 神经网络的有效性, 将 POA-BP 与原始传统 BP、GA-BP 预测模型以及 SCN 随机网络进行对比。其中,4 种初始数据与取样比例,为 了更好的训练模型,对数据进行泛化采样,每隔 6 组数据 取一个作为模型测试样本,其余为训练样本。设定种群 规模为 30,迭代次数为 100。通过 POA 优化后的 BP 神 经网络计算可以得到热误差预测模型,其中适应度曲线 如图 14 所示。



从图 14 可以看出,适应度曲线下降的很快,在较少的迭代次数下就可以达到有效的优化,优化前后的 4 种模型预测对比如图 15 所示,表 2 为 4 种预测模型预测精度的参数对比结果。



从图 10 和 12 中可以看出低温时温度上升较快,真 实的热误差值也随之迅速增大,同一时间段前后差异较 大,预测模型在进行预测时预测值与真实值也会有所差 异。而温度高时其上升较缓慢,真实的误差值同一时间 段前后差异较小,其预测值与真实值的差异较低温时更小,因此在低温时其预测精度与高温时相比会有所降低。

表 2 预测精度评价参数对比结果

 Table 2
 Comparison results of parameters for prediction accuracy

	-	-		
预测模型	MSE	MAPE	RMSE	
POA-BP	8.04	9.93%	2.84	
GA-BP	10.15	11.50%	3.17	
BP	10.77	12.23%	3.28	
SCN	11.39	12.71%	3.38	

预测结果表明, POA-BP 模型计算的结果均方根误差(RMSE)为2.84,较GA-BP 神经网络的均方根误差3.17和BP 神经网络的均方根误差3.28以及SCN随机配置网络的均方根误差3.38 有明显的降低,具有更高的预测精度,且经POA 优化后的POA-BP 神经网络预测结果的平均相对误差从12.23%降低到9.93%,与GA-BP的平均相对误差11.50%和SCN的平均相对误差12.71%相比有较大的提升。由此可以得出经过POA 优化的BP 神经网络具有更高的预测精度。

4 结 论

本文为实现数控机床进给系统热误差的有效预测, 以高速智能钻攻中心 i5M1.4 作为研究对象建立了热误 差模型,结论如下:

1)本文以 i5M1.4 数控钻攻中心搭建了实验平台进 行了热误差实验,得到了神经网络模型计算所需的输入 及输出数据集,为热误差模型的建立和优化奠定了基础。

2)根据实验所得数据建立了经优化后的 POA-BP 神 经网络模型,为了凸显本文预测模型的准确性,依据所得 实验数据另建立了 GA-BP 神经网络模型和 SCN 随机配 置网络模型并加以对比,预测结果得出采用 BP 神经网 络的平均相对误差为 12.23%;GA-BP 神经网络的平均 相对误差为 11.50%;SCN 的平均相对误差为 12.71%; POA-BP 预测的平均相对误差为 9.93%,可以看出经优 化后的 POA-BP 热误差预测模型具有更高的预测精度。

3)采用 POA 鹈鹕优化算法对 BP 神经网络的初始权 值和阈值进行优化可以有效的提高 BP 神经网络的预测 精度,从而应用于热误差补偿之中。

参考文献

 [1] 王维,杨建国,姚晓栋,等.数控机床几何误差与热误 差综合建模及其实时补偿[J].机械工程学报,2012, 48(7):165-170,179.

WANG W, YANG J G, YAO X D, et al. Synthesis modeling and real-time compensation of geometric error and thermal error for CNC machine tools [J]. Journal of Mechanical Engineering, 2012, 48(7): 165-170,179.

[2] 李逢春,王海同,李铁民.重型数控机床热误差建模及 预测方法的研究[J].机械工程学报,2016,52(11): 154-160.

> LI F CH, WANG H T, LI T M. Research on thermal error modeling and prediction of heavy CNC machine tools [J]. Journal of Mechanical Engineering, 2016, 52(11): 154-160.

- [3] BRYAN J B. International status of thermal error research [J]. CIRP Annals Manufacturing Technology, 1990, 39(2): 645-656.
- [4] 刘阔,韩伟,王永青,等.数控机床进给轴热误差补偿 技术研究综述[J].机械工程学报,2021,57(3): 156-173.

LIU K, HAN W, WANG Y Q, et al. Review on thermal error compensation for feed axes of CNC machine tools[J]. Journal of Mechanical Engineering, 2021, 57 (3): 156-173.

[5] 曹利,彭骥,殷鸣,等.基于 MEA-BP 算法的卧式加工 中心主轴热误差建模[J].组合机床与自动化加工技 术,2022,581(7):30-33,37.

> CAO L, PENG J, YIN M, et al. Thermal error modeling of horizontal machining center spindle based on MEA-BP algorithm [J]. Modular Machine Tool & Automatic, 2022, 581 (7): 30-33,37.

- [6] 王海同,李铁民,王立平,等. 机床热误差建模研究综述[J]. 机械工程学报,2015,51(9):119-128.
 WANG H T, LI T M, WANG L P, et al. Review on thermal error modeling of machine tools[J]. Journal of Mechanical Engineering, 2015, 51(9): 119-128.
- [7] 王新孟,杨军,梅雪松,等.精密坐标镗床进给系统热 误差分析与预测[J].西安交通大学学报,2015, 49(10):22-28.

WANG X M, YANG J, MEI X S, et al. Analysis and prediction for thermal error of precision coordinate boring machine[J]. Journal of Xi'an Jiaotong University, 2015, 49(10): 22-28.

[8] 朱星星,赵亮,雷默涵,等.精密进给系统热误差的协同训练支持向量机回归建模与补偿方法[J].西安交通大学学报,2019,53(10):40-47.

ZHU X X, ZHAO L, LEI M H, et al. Co-training support vector machine regression modeling and compensation for thermal error of precision feed system[J]. Journal of Xi'an Jiaotong University, 2019, 53(10): 40-47.

[9] 靳增锋, 王品. 基于神经网络系统的滚珠丝杠热误差 建模[J]. 组合机床与自动化加工技术, 2012, 455(1): 1-4, 7.

JIN Z F, WANG P. Neural network-based thermal error modelling in ball screw [J]. Modular Machine Tool &

Automatic Manufacturing Technique, 2012, 455(1): 1-4,7.

 [10] 魏新园,钱牧云,冯旭刚,等.基于偏最小二乘的数控 机床热误差稳健建模算法[J].仪器仪表学报,2021, 42(5):34-41.

WEI X Y, QIAN M Y, FENG X G, et al. Robust modeling method for thermal error of CNC machine tools based on partial least squares algorithm [J]. Chinese Journal of Scientific Instrument, 2021, 42(5): 34-41.

- [11] 问梦飞,钟建琳,彭宝营,等.基于 WOA-SVR 的电主轴 热误差优化建模[J]. 机床与液压,2022,50(22): 38-42.
 WEN M F, ZHONG J L, PENG B Y, et al. Thermal error optimization modeling of motorized spindles based on WOA-SVR[J]. Machine Tool & Hydraulics, 2022, 50 (22): 38-42.
- [12] LIU J Y, CAI Y H, ZHANG Q J, et al. Thermal error analysis of tauren EDM machine tool based on FCM fuzzy clustering and RBF neural network [J]. Journal of Intelligent & Fuzzy Systems, 2021, 41(6): 6003-6014.
- [13] FU G Q, ZHENG Y, ZHOU L F, et al. Look-ahead prediction of spindle thermal errors with on-machine measurement and the cubic exponential smoothingunscented Kalman filtering-based temperature prediction model of the machine tools [J]. Measurement, 2023, 210: 112536.
- [14] 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.
 LIGL, CHENXY, LIZHY, 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.
 [15] 魏弦.基于核主成分分析的热误差模型自变量优化[J].
 - 15] 魏弦.基于核主成分分析的热误差模型自变量优化[J]. 电子测量与仪器学报,2017,31(12):2017-2022.
 WEI X. Independence variable optimization of thermal error model based on KPCA [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31 (12): 2017-2022.
- [16] 黄智,刘永超,廖荣杰,等. 基于 SSO 算法优化神经网络的数控机床热误差建模[J].东北大学学报(自然科学版),2021,42(11):1569-1578.
 HUANG ZH, LIU Y CH, LIAO R J, et al. Thermal error modeling of numerical control machine tools based on neural network neural network by optimized SSO algorithm [J]. Journal of Northeastern University (Natural Science), 2021, 42 (11): 1569-1578.
- [17] LI Z L, WANG Q H, ZHU B, et al. Thermal error modeling

of high-speed electric spindle based on aquila optimizer optimized least squares support vector machine [J]. Case Studies in Thermal Engineering, 2022, 39: 102432.

[18] 谭峰,李成南,萧红,等. 基于 LSTM 循环神经网络的数 控机床热误差预测方法[J]. 仪器仪表学报,2020,41(9):79-87.

TAN F, LI CH N, XIAO H, et al. A thermal error prediction method for CNC machine tool based on LSTM recurrent neural network [J]. Chinese Journal of Scientific Instrument, 2020, 41(9): 79-87.

[19] 孙昂,刘茂龙,谢新连,等.基于蝙蝠算法优化的小波 神经网络车床主轴热误差建模[J].机床与液压, 2021,49(6):118-123.

SUN ANG, LIU M L, XIE X L, et al. Thermal error modeling of lathe spindle based on wavelet neural network optimized by bat algorithm [J]. Machine Tool & Hydraulics, 2021, 49(6): 118-123.

- [20] CHENG Y N, ZHANG X P, ZHANG G X, et al. Thermal error analysis and modeling for high-speed motorized spindles based on LSTM-CNN [J]. The International Journal of Advanced Manufacturing Technology, 2022, 121(5-6): 3243-3257.
- [21] YE H H, WEI X Y, ZHUANG X D, et al. An improved robust thermal error prediction approach for CNC machine tools[J]. Machines, 2022, 10(8): 624-624.
- [22] 郑金勇,刘保国,冯伟. 基于遗传算法优化灰色神经网络的机床主轴热误差建模研究[J]. 机电工程,2019, 36(6):602-607.

ZHENG J Y, LIU B G, FENG W. Machine tool spindle thermal error modeling based on genetic algorithm optimization grey neural network [J]. Journal of Mechanical & Electrical Engineering, 2019, 36(6): 602-607.

 [23] 仇海涛,徐梦桐,刘伟,等. 基于 ACO-BP 神经网络的 光纤陀螺温度补偿方法研究[J]. 电光与控制,2023, 30(7):78-81,118.

QIU H T, XU M T, LIU W, et al. Research on temperature compensation method of fiber optic gyroscope based on ACO-BP neural network [J]. Electronics Optics & Control, 2023, 30(7):78-81, 118.

[24] 江兵,杨春,杨雨亭,等. 基于 ACO 优化 BP 神经网络 的变压器热点温度预测[J]. 电子测量与仪器学报, 2022,36(10):235-242.

> JIANG B, YANG CH, YANG Y T, et al. Temperature prediction of transformer hot spot based on BP neural network optimized by ACO [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36 (10): 235-242.

[25] 董浩生,杨赫然,孙兴伟,等.基于砂带表面磨粒分布 的螺杆曲面重复磨削区域表面粗糙度预测.电子测量 与仪器学报,2022,36(3):87-95.

DONG H SH, YANG H R, SUN X Y, et al. Prediction of surface roughness in repeated grinding area of screw surface based on abrasive particle distribution on abrasive belt surface[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(3): 87-95.

作者简介



李帅,2018年于辽宁科技大学获学士 学位,现为沈阳工业大学机械工程学院硕士 研究生,主要研究方向为复杂曲面数字化制 造技术与装备。

E-mail: ls15566281270@163.com

Li Shuai graduated from Liaoning

University of Science and Technology in 2018 with a bachelor's degree. He is currently a master's student at the School of Mechanical Engineering, Shenyang University of Technology. His main research direction is digital manufacturing technology and equipment for complex surfaces.



杨赫然(通信作者),分别于 2006 年、 2008 年和 2012 年在吉林大学获得学士、硕 士和博士学位,现为沈阳工业大学机械工程 学院副教授,主要研究方向为复杂曲面数字 化制造技术与装备。

E-mail: yangheran@ sut. edu. cn

Yang Heran (Corresponding author) received his B. Sc. degree, M. Sc. degree and Ph. D. degree all from Jilin University in 2006, 2008 and 2012, respectively. He is now an associate professor at Shenyang University of Technology. His main research interests include digital manufacturing technology and equipment of complex surface.