

文章编号 1004-924X(2015)06-1705-09

广义径向基函数神经网络在热误差建模中的应用

吕 程, 刘子云, 刘子建*, 余治民

(湖南大学 汽车车身先进设计制造国家重点实验室, 湖南 长沙 410082)

摘要:针对现有的热误差建模方法建模效率低, 模型预测精度不理想等问题, 提出了广义径向基函数神经网络(RBF)建模方法并将其应用于数控机床热误差建模中。讨论了采用广义 RBF 神经网络进行热误差建模的原理及步骤。以数控导轨磨床主轴箱系统为例, 布置了 12 个主轴热误差的关键温度测点, 测得了 2 组独立的主轴箱系统热误差数据。将测得的数据分别用于建立主轴箱系统热误差广义 RBF 神经网络预报模型和验证模型的准确性。研究结果表明, 热误差广义 RBF 神经网络模型具有预测精度高及泛化能力强的优点; 与传统的 RBF 神经网络建模方法相比, 提出的广义 RBF 神经网络建模方法建模效率更高, 模型鲁棒性及预测性能更好, 是一种可以用于数控机床热误差实时补偿的有效建模方法。

关键词:广义径向基函数; 神经网络; 热误差建模; 聚类算法; 泛化能力; 鲁棒性; 数控导轨磨床

中图分类号: TG596; TP183 **文献标识码:** A **doi:** 10.3788/OPE.20152306.1705

Application of generalized radial basis function neural network to thermal error modeling

LÜ Cheng, LIU Zi-yun, LIU Zi-jian*, YU Zhi-min

(State Key Laboratory of Advanced Design and Manufacture for Vehicle Body,
Hunan University, Changsha 410082, China)

* Corresponding author, E-mail: zijianliu@hnu.edu.cn

Abstract: In considering of the lower efficiency and worse prediction accuracy of the existing thermal error modeling methods, a generalized Radial Basis Function (RBF) neural network modeling approach was proposed to establish the thermal error model of Numerical Control (NC) machine tools. The model theory and the corresponding steps based on this method were discussed. An experiment on the spindle box of a NC guide rail grinder was performed, and two groups of independent thermal error data were obtained by setting twelve critical temperature measuring points of spindle thermal error. One group of the data was used for building the thermal error model of the spindle box system based on generalized RBF neural network method and the other was used for verifying the correction of the model. The study results show that the thermal error model based on generalized RBF neural network method has high prediction precision and good generalization ability. By comparing the generalized RBF neural network method with traditional RBF neural network modeling method, the former shows better efficiency, robustness and prediction capacity, and it is an effective modeling

收稿日期: 2014-10-15; 修订日期: 2014-12-09.

基金项目: 国家自然科学基金资助项目 (No. 51175161; No. 51475152); 国家科技重大专项资助项目 (No. 2011ZX04003-011)

method for the real-time thermal error compensation of NC machine tools.

Key words: generalized radial basis function; neural network; thermal error modeling; clustering algorithm; generalization ability; robustness; Numerical Control(NC) guide rail grinder

1 引言

当数控机床几何误差得到有效控制后,热变形引起的误差就成为影响机床精度的主要因素,其甚至可以达到机床总误差的 60%~70%^[1]。软件补偿法是目前进行数控机床热误差控制的主要方法,具有高效、经济且易于实现等优点。软件补偿法依据试验数据样本,建立反映机床温度场与热误差映射关系的热误差预报模型,然后将机床运行时实时检测的温度数据输入模型来预测机床的热误差值,最后数控软件依据这些预测值控制机床加工系统进行热误差的实时补偿。软件补偿法的关键是建立可以准确、高效、可靠反映机床热误差特性的误差预报模型。

机床热误差是机床不同部位热变形综合作用的结果,其受机床温度场、结构、几何精度等的影响而变化,具有非线性、耦合性、时滞性等特点^[2-3]。基于经验公式、数值计算的传统热误差建模方法存在实时性差、外插值性差、精度低等缺陷^[4-5],实用意义不大;而神经网络具有较强的数据并行处理能力和数据存储、容错能力,以及非线性映射的特点,故以神经网络为代表的智能补偿技术已广泛应用于热误差建模中^[6-7]。现有的神经网络建模方法一般采用全局逼近网络,即对于每个输入—输出数据对,网络的每一个连接权均需要进行调整,从而导致网络学习速度慢,且容易陷入局部极点,严重影响了建模的效率和精度。近年来发展起来的径向基函数(Radial Basis Function, RBF)神经网络采用局部逼近法,该方法对于每个输入—输出数据对仅需要少量的连接权进行相对全局逼近网络,使学习速度有了大幅提升^[8]。但由于基函数与 RBF 网络的训练样本一一对应。当样本数很大时,网络的计算量将大得惊人,求解过程中易产生病态解,会导致网络学习速度变慢、陷入局部极点^[9-12]。

为解决 RBF 网络的上述问题,Moody 和

Darken 提出了一种由两个阶段组成的混合学习型 RBF 神经网络(广义 RBF 神经网络)^[13],其具有网络计算量少、模型精度高、可避免训练过程中陷入局部极点、收敛速度快及鲁棒性强等优点^[14-15]。

本文以某大型数控龙门导轨磨床主轴箱系统为研究对象,研究运用广义 RBF 神经网络构建主轴热误差预报模型的方法,并详细分析了该方法的建模效率、鲁棒性及模型的预测精度。

2 热误差广义 RBF 神经网络建模方法

本文建立的热误差广义 RBF 神经网络结构如图 1 所示。




图 1 广义 RBF 神经网络结构

Fig. 1 Structure of generalized RBF neural network

网络有 n 个输入节点, m 个隐节点, r 个输出节点。图中 $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$ 为温度输入矢量 (n 为温度测点数量); $\mathbf{W}_k = (\omega_{1,k}, \omega_{2,k}, \dots, \omega_{m,k})^T$ ($k=1, 2, \dots, r$) 为第 k 个输出节点的权值矩阵, 其中 $\omega_{j,k}$ 为隐层第 j 个节点与输出层第 k 个节点间的突触权值; $\mathbf{Y} = [y_1, y_2, \dots, y_r]^T$ 为网络的输出矢量 (r 为输出矢量个数), 即模型预测的热误差矢量; φ_j ($j=1, 2, \dots, m$) 为第 j 个隐节点的径向基函数, 简称基函数。本文选取格林函数作为网络隐节点的基函数, 定义为:

$$\varphi_j(\| \mathbf{X} - \mathbf{C}_j \|) = \exp\left\{-\frac{\| \mathbf{X} - \mathbf{C}_j \|^2}{2\sigma_j^2}\right\}$$

$$(j=1,2,\dots,m), \quad (1)$$

式中: \mathbf{X} 为输入温度矢量; \mathbf{C}_j 为数据中心; σ_j 为扩展常数。由式(1)可知,每个基函数对应一个数据中心和扩展常数,基函数以输入温度矢量与数据中心的欧式距离作为函数的自变量。

热误差广义 RBF 神经网络建模需解决如下问题:如何确定网络隐节点数,如何确定各径向基函数的数据中心及扩展常数,以及如何修正输出权值等。其建模和验证流程如图 2 所示,方法的具体步骤如下。




图 2 广义 RBF 热误差建模与验证流程

Fig. 2 Modeling and validation process of generalized RBF thermal error

(1) 试验数据采集与分组。对所研究机床进行热误差试验,利用温度传感器和位移传感器分别采集机床的温度和热误差数据。将获得的试验数据分成两组,每组均包含 P 个样本,一组作为建模的训练样本,一组用来验证模型的预测性能。

(2) 根据实验结果估计隐节点数 m (要求 $m < P$),从而确定数据中心的个数。

(3) 采用 K-means 聚类算法确定基函数的数据中心和扩展常数。因为由第(2)步确定的网络隐节点数为 m ,每个隐节点包含一个基函数,故与基函数对应的数据中心的数量也为 m 。广义 RBF 神经网络的数据中心并不是样本数据本身,而是通过聚类算法,不断迭代求得的。设 $\mathbf{C}_1(k), \mathbf{C}_2(k), \dots, \mathbf{C}_m(k)$ 分别为第 k 次迭代时的聚类中心。聚类算法确定数据中心和扩展常数的过程

如下:

1) 确定数据中心。在训练样本的温度输入矢量 $\mathbf{X}_p(p=1,2,\dots,P)$ 中随机选取 m 组作为初始聚类中心 $\mathbf{C}_1(0), \mathbf{C}_2(0), \dots, \mathbf{C}_m(0)$ 。计算训练样本的温度输入矢量与各聚类中心的欧式距离:

$$D_{p,j} = \| \mathbf{X}_p - \mathbf{C}_j(k) \| (p=1,2,\dots,P; j=1,2,\dots,m).$$

设 j^* 为第 j 个聚类中心 $\mathbf{C}_j(k)$ 对应的类($j=1,2,\dots,m$)。对每一个温度输入矢量 \mathbf{X}_p ,根据其与各聚类中心的最小欧式距离确定其归类 j^* ,即当 $\min_i D_{p,i} = D_{p,j^*}$ ($i=1,2,\dots,m$) 时,将 \mathbf{X}_p 归为 j^* 类,从而将全部温度输入矢量样本划分为 m 个子集: $U_1(k), U_2(k), \dots, U_m(k)$,每个子集构成一个以聚类中心为典型代表的聚类域。

对各聚类域中的样本取均值。令 $U_j(k)$ 表示第 j ($j=1,2,\dots,m$) 个聚类域, N_j 表示第 j 个聚类域中的样本数,则有:

$$\mathbf{C}_j(k+1) = \frac{1}{N_j} \sum_{\mathbf{X} \in U_j(k)} \mathbf{X} (j=1,2,\dots,m).$$

预先设置模型精度目标 C_{\min} ,当第 K 次迭代后聚类中心与迭代前聚类中心的欧式距离之和 $\sum_{j=1}^m \| \mathbf{C}_j(K+1) - \mathbf{C}_j(K) \| < C_{\min}$ 时,结束迭代,此时的聚类中心 $\mathbf{C}_1(K+1), \mathbf{C}_2(K+1), \dots, \mathbf{C}_m(K+1)$ 即为网络的数据中心。

2) 确定扩展常数。在确定了数据中心后,根据各中心之间的欧式距离确定对应径向基函数的扩展常数。令第 j 个数据中心 $\mathbf{C}_j(K+1)$ 的最小欧式距离 $d_j = \min_i \| \mathbf{C}_j - \mathbf{C}_i \|$ ($i=1,2,\dots,m; i \neq j$),则第 j 个基函数的扩展常数为:

$$\sigma_j = \lambda \times d_j,$$

式中: λ 为重叠系数,本文取 $\lambda=0.2$ 。

(4) 采用伪逆法计算输出层的权值。由基于径向基函数技术的插值函数的定义可知,网络各输出节点的输出为基函数的线性组合:

$$y_k = \sum_{j=1}^m \tau_{j,k} \varphi_j(\| \mathbf{X} - \mathbf{C}_j \|) (k=1,2,\dots,r). \quad (2)$$

由式(2)可知,各输出节点的权值矩阵只对本节点的输出产生影响。当用训练样本求解权值时,权值矩阵 \mathbf{W}_k 只与输入温度矢量 \mathbf{X}_p 及对应输出节点的输出 $y_{p,k}$ 有关($p=1,2,\dots,P; k=1,2,\dots,r$)。

将训练样本 $(\mathbf{X}_p, y_{p,k}) (p=1, 2, \dots, P)$ 代入式(2)中, 得到 P 个关于未知权值 $\omega_{j,k} (j=1, 2, \dots, m)$ 的线性方程组:

$$\begin{cases} \sum_{j=1}^m \omega_{j,k} \varphi_j(\|\mathbf{X}_1 - \mathbf{C}_j\|) = y_{1,k} \\ \sum_{j=1}^m \omega_{j,k} \varphi_j(\|\mathbf{X}_2 - \mathbf{C}_j\|) = y_{2,k} \\ \vdots \\ \sum_{j=1}^m \omega_{j,k} \varphi_j(\|\mathbf{X}_p - \mathbf{C}_j\|) = y_{p,k} \end{cases}, \quad (3)$$

令 $\varphi_{p,j} = \varphi_j(\|\mathbf{X}_p - \mathbf{C}_j\|) (p=1, 2, \dots, P; j=1, 2, \dots, m)$, $\mathbf{Y}_k = [y_{1,k}, y_{2,k}, \dots, y_{p,k}]^T$, $\mathbf{W}_k = (\omega_{1,k}, \omega_{2,k}, \dots, \omega_{m,k})^T$

$$\hat{\Phi} = \begin{bmatrix} \varphi_{1,1} & \varphi_{1,2} & \dots & \varphi_{1,m} \\ \varphi_{2,1} & \varphi_{2,2} & \dots & \varphi_{2,m} \\ \vdots & \vdots & \vdots & \vdots \\ \varphi_{P,1} & \varphi_{P,2} & \dots & \varphi_{P,m} \end{bmatrix},$$

则式(3)可改写为:

$$\hat{\Phi} \mathbf{W}_k = \mathbf{Y}_k,$$

则第 k 个输出层的权值矩阵为:

$$\mathbf{W}_k = \hat{\Phi}^+ \mathbf{Y}_k,$$

式中: $\hat{\Phi}^+ = (\hat{\Phi}^T \hat{\Phi})^{-1} \hat{\Phi}^T$, $\hat{\Phi}^+$ 称为 $\hat{\Phi}^T$ 的伪逆矩阵。

利用聚类算法确定的数据中心和扩展常数以及由伪逆法计算求得的输出层权值, 构建热误差广义 RBF 神经网络模型, 实现对机床热误差系统的仿真。

(5)将步骤(1)中的另一组试验数据代入模型中, 以检验模型的预测性能。

3 龙门磨床主轴热误差建模实例

下面以某大型精密数控龙门导轨磨床主轴箱系统热误差建模为例, 按照第 1 节的建模步骤, 建立基于广义 RBF 神经网络的主轴系统热误差模型, 验证其预报能力, 并与 RBF 神经网络建模方法进行对比分析。

3.1 试验数据采集

实验采用的温度测量装置为非接触式红外温度检测仪, 如图 3 所示。因设备数量有限, 本试验共使用 3 个温度检测仪, 实验时由 3 个人手持进行温度测量。如图 4~6 所示, 电机与主轴箱固定


在安装座上, 电机通过皮带轮带动主轴旋转。通过分析主轴箱系统的工况、结构及热源, 在系统上布置 12 个主轴热误差的关键温度测点。具体布置为: 皮带轮上 2 个(1~2), 主轴箱体上 4 个(3~6), 主轴上 3 个(7~9), 电机上 1 个(10), 安装座上 2 个(11~12)。



图 3 非接触式红外温度检测仪

Fig. 3 Non-contact infrared temperature detector

具体试验过程为: 以加工速度空载运行 205 min, 每间隔 5 min 同时对 12 个测点的温度进行测量(因温升较慢, 且温度测量操作简单快捷, 因此, 每次测量时不同测点间的时差可忽略, 即可认为 12 个温度测点为同一时刻的温度值), 并用千分表测量主轴在 X、Y、Z 3 个方向上的热变形误差。经过 42 次测量, 得到第一组主轴热误差数据, 并用该组数据进行建模。机床停车冷却后, 再次在相同条件下采用相同的方式进行 42 次测量, 采集到第二组主轴热误差数据, 该组数据用于模型精度验证。由于磨床在恒温车间工作, 在此不考虑环境温度变化。



A-皮带轮 B-主轴箱 C-主轴 D-安装座 E-电机

图 4 龙门导轨磨床主轴箱系统

Fig. 4 Spindle box system of gantry rail grinder




图 5 主轴箱系统实体

Fig. 5 Prototype of spindle box system




图 6 主轴热误差测量

Fig. 6 Measurement of spindle thermal error

3.2 主轴箱系统热误差建模与分析

图 7、8 分别为第一组数据中的 12 个温度测点的温升与主轴 X、Y、Z 方向上的热误差。通过灰关联度^[16]分析得知,编号为 1、3、4、6、11、12 的 6 个测点的温升与热误差的关联度较大,用以上 6 个温度测点的数据作为建模的输入参数,即可以保证模型的精度又能提高建模的效率^[17]。




图 7 温度测点温升

Fig. 7 Temperature rise in temperature measuring points




图 8 主轴 3 个方向的热误差

Fig. 8 Thermal errors of spindle in three directions

以上述 6 个温度测点的温度为输入参数,主轴 3 个自由度方向的热误差为输出,按照第 1 节的建模步骤,采用 MATLAB 软件编写主轴箱系统热误差的广义 RBF 神经网络建模程序。将第 2 组数据中 6 个温度测点的数据代入模型,算出对应的热误差模型预测值。将热误差模型的预测值与试验测量值进行对比,验证模型的预测精度。

建立主轴在 X、Y、Z 方向上的热误差广义 RBF 神经网络模型。其输出节点数为 3,设置隐性节点数为 12,训练结束后的网络权值矩阵为 $W = [W_1 \ W_2 \ W_3]$ ($W_k = (\omega_{1,k}, \omega_{2,k}, \dots, \omega_{12,k})^T$, $k=(1,2,3)$),具体如下:

$$W = \begin{bmatrix} 0.1619 & 0.2742 & 0.8811 \\ -1.6467 & 2.5909 & 3.9903 \\ 0.1955 & 1.6651 & 1.8510 \\ -0.3632 & -1.4275 & 1.1058 \\ -0.4671 & -0.8594 & -1.3973 \\ -0.1836 & 1.5608 & 1.6903 \\ 0.1677 & -2.0277 & -0.6766 \\ -0.0310 & -1.2871 & 1.6262 \\ -5.0927 & 3.5332 & -1.3740 \\ -2.0499 & -0.3826 & -1.5878 \\ -1.6400 & 0.1165 & -1.7698 \\ -3.0466 & 0.7425 & 2.3804 \end{bmatrix}$$

主轴在 X、Y、Z 方向上的热误差广义 RBF 神经网络模型预测值与实测值的对比如图 9~11 所示。预测值与实测值间的差值为残余误差,残余误差的大小反映了模型的补偿效果。广义 RBF 神经网络模型的性能指标如表 1 所示。由表 1 可

知,经过广义 RBF 神经网络模型补偿后,主轴在 X、Y、Z 方向上残余误差的最大绝对对偏差、偏差带宽、均方差均较补偿前大幅度下降。这说明采用广义 RBF 神经网络建模对热误差进行补偿效果显著。

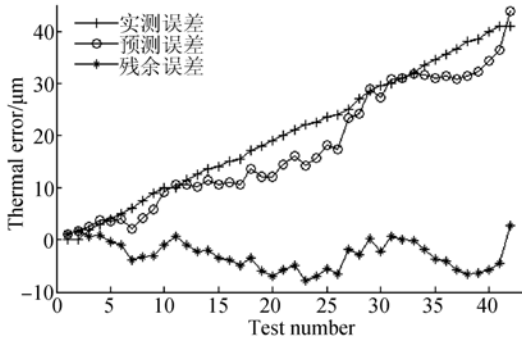


图 9 主轴 X 方向热误差预测值与实测值对比

Fig. 9 Comparison of predicted and measured values of spindle thermal error in X direction

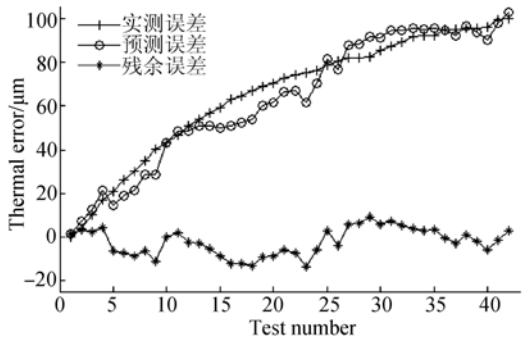


图 10 主轴 Y 方向热误差预测值与实测值对比

Fig. 10 Comparison of predicted and measured values of spindle thermal error in Y direction




图 11 主轴 Z 方向热误差预测值与实测值对比

Fig. 11 Comparison of predicted and measured values of spindle thermal error in Z direction

表 1 广义 RBF 神经网络模型性能指标

Tab. 1 Performance indicators of generalized RBF neural network model

方向	类型	偏差带宽	最大绝对偏差	均方差
X 向	实测误差/ μm	41	41	12.41
	残余误差/ μm	10.65	7.81	2.84
	下降比例/(%)	74.0	81.0	77.1
Y 向	实测误差/ μm	101	101	28.43
	残余误差/ μm	22.70	13.41	6.27
	下降比例/(%)	77.5	86.7	77.9
Z 向	实测误差/ μm	81	81	24.70
	残余误差/ μm	23.08	14.94	5.67
	下降比例/(%)	71.5	81.6	77.0

注:下降比例 = (实测误差 - 残余误差) / 实测误差 $\times 100\%$ 。

3.3 建模方法比较验证

为了验证广义 RBF 神经网络建模方法的综合性能,本文进一步构建了主轴箱系统的 RBF 神经网络热误差模型,并编制了相应的计算程序,采用相同的试验数据,分别从建模效率、建模鲁棒性及模型的预测精度三方面进行对比分析。

3.3.1 模型补偿效果对比

由两种方法建立的模型,经补偿后在 X、Y、Z 方向上残余误差的比较如图 12~14 所示,两种模型性能指标的对比数据如表 2 所示。




图 12 两种模型 X 方向残余误差对比

Fig. 12 Comparison of residual errors for two models in X direction

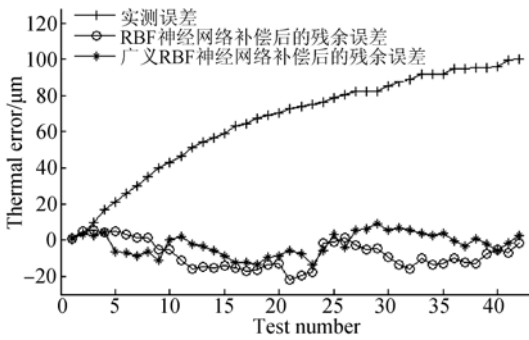


图 13 两种模型 Y 方向残余误差对比

Fig. 13 Comparison of residual errors for two models in Y direction




图 14 两种模型 Z 方向残余误差对比

Fig. 14 Comparison of residual errors for two models in Z direction

表 2 两种模型预测性能指标对比

Tab. 2 Comparison of prediction performance indicators for two models

方向	类型	偏差带宽	最大绝对偏差	均方差
X 向	残余误差 (RBF)/ μm	14.91	13.27	3.35
	残余误差 (广义 RBF)/ μm	10.65	7.81	2.84
	下降比例/(%)	28.6	41.1	15.2
Y 向	残余误差 (RBF)/ μm	27.51	21.85	7.75
	残余误差 (广义 RBF)/ μm	22.70	13.41	6.27
	下降比例/(%)	17.5	38.6	19.1
Z 向	残余误差 (RBF)/ μm	28.29	16.20	6.85
	残余误差 (广义 RBF)/ μm	23.08	14.94	5.67
	下降比例/(%)	18.4	7.8	17.2

注:下降比例=(残余误差(RBF)-残余误差(广义 RBF))/残余误差(RBF) $\times 100\%$ 。

由表 2 可知,广义 RBF 神经网络模型的补偿效果全面优于传统 RBF 神经网络模型。

3.3.2 建模效率对比

RBF 神经网络方法的关键是隐层节点基函数中心的选取,若中心选取不当可能会使学习过程不收敛^[18-19],而利用同一组数据的建模过程中,每次运算所建立的模型均存在差异,需经过多次尝试才能得到较理想的模型。这说明 RBF 神经网络建模的稳定性差、效率较低。而广义 RBF 神经网络方法通过一次运算就收敛于理想稳定的模型,较 RBF 神经网络方法的建模效率大幅提高。

3.3.3 建模鲁棒性对比

建模鲁棒性反映了热误差模型的建模精度对输入参数变动的敏感程度。在试验中,温度传感器存在的测试误差,甚至会发生传感器失效等,这都会直接影响热误差模型的预测精度。现假设前述的 6 个温度测点中,出现某一传感器失效导致该测点的温度数据丢失的情况。这时可依据其它 5 个测点的温度数据用两种方法分别建立模型,图 15 为两种模型补偿后 X 方向的残余误差。




图 15 两种模型 X 方向残余误差比较

Fig. 15 Comparison of residual errors for two models in X direction

与采用 6 个测点温度数据建模时模型补偿后的残余误差相比,RBF 神经网络模型补偿后残余误差的偏差带宽、最大绝对偏差、均方差分别上升了 35.3%,8.5%和 20.9%;而广义 RBF 神经网络模型补偿后残余误差的偏差带宽、最大绝对偏差、均方差仅上升了 16.7%,5.8%和 7.0%,变动量小于 RBF 神经网络模型,说明广义 RBF 神经网络建模方法的鲁棒性全面优于 RBF 神经网络

建模方法。

4 结 论

本文提出了热误差广义 RBF 神经网络建模方法,并将其用于实时预测机床主轴箱系统的热误差。利用一组热误差试验数据,按照本文提出的建模步骤建立了主轴箱系统热误差广义 RBF 神经网络预报模型,并通过另一组独立的试验数

据进行验证,结果显示,所建模型具有较高的预测精度和较好的泛化能力。通过将广义 RBF 神经网络建模方法与 RBF 神经网络建模方法进行对比分析,进一步验证了本文所提方法在模型补偿效果、建模效率、建模鲁棒性上全面优于 RBF 神经网络建模方法,是一种相对准确、高效、可靠的热误差建模方法。本文的研究为利用数控软件系统实现机床的热误差实时补偿提供了理论借鉴和可行参考。

参考文献:

- [1] RAMESH R, MANNAN M A, POO A N. Error compensation in machine tools-a review: Part II: thermal errors [J]. *International Journal of Machine Tools and Manufacture*, 2000, 40 (9): 1257-1284.
- [2] 阳红, 方辉, 刘立新, 等. 基于热误差神经网络预测模型的机床重点热刚度辨识方法研究[J]. *机械工程学报*, 2011, 47(11): 117-124.
- YANG H, FANG H, LIU L X, *et al.*. Method of key thermal stiffness identification on a machine tool based on the thermal errors neural network prediction model [J]. *Journal of Mechanical Engineering*, 2011, 47(11): 117-124. (in Chinese)
- [3] 田良巨. 数控加工中心电主轴热误差研究[D]. 天津: 天津大学, 2011.
- TIAN L J. *Motorized spindle thermal error research of CNC machining center* [D]. Tianjin: Tianjin University, 2011. (in Chinese)
- [4] TAN K K, HUANG S N, SEET H L. Geometrical error compensation of precision motion systems using radial basis function [J]. *IEEE Transactions on Instrumentation and Measurement*, 2000, 49 (5): 984-991.
- [5] YANG S, YUAN J, NI J. The improvement of thermal error modeling and compensation on machine tools by CMAC neural network [J]. *International Journal of Machine Tools and Manufacture*, 1996, 36(4): 527-537.
- [6] 满忠伟, 汪世益. 基于神经网络的机床——工件系统热误差补偿技术研究[J]. *制造技术与机床*, 2011(7): 99-102.
- MAN ZH W, WANG SH Y. Study of thermal error compensation on the system of machine tool and work-piece based on neural network [J]. *Manufacturing Technology & Machine Tools*, 2011(7): 99-102. (in Chinese)
- [7] 张毅. 数控机床误差测量、建模及网络群控实时补偿系统研究[D]. 上海: 上海交通大学, 2013.
- ZHANG Y. *Error measuring, modeling and network group control real-time compensation system research of NC machine tool* [D]. Shanghai: Shanghai Jiaotong University, 2013. (in Chinese)
- [8] ILIYAS S A, ELSHAFEI M, HABIB M A, *et al.*. RBF neural network inferential sensor for process emission monitoring [J]. *Control Engineering Practice*, 2013, 21(7): 962-970.
- [9] YANG H, NI J. Dynamic neural network modeling for nonlinear, nonstationary machine tool thermally induced error [J]. *International Journal of Machine Tools & Manufacture*, 2005, 45 (4-5): 455-465.
- [10] ER M J, WU S Q, LU J, *et al.*. Face recognition with radial basis function (RBF) neural networks [J]. *IEEE Transactions on Neural Networks*, 2002, 13(3): 697-710.
- [11] 兰天鸽, 方勇华, 熊伟, 等. 自构造 RBF 神经网络及其参数优化[J]. *计算机工程*, 2008, 33(9): 200-202.
- LAN T E, FANG Y H, XIONG W, *et al.*. Self-growing RBF neural networks and parameters optimization [J]. *Computer Engineering*, 2008, 33 (9): 200-202. (in Chinese)
- [12] BAEK J Y, PARK B J, OH S K. The design of polynomial RBF neural network by means of fuzzy inference system and its optimization [J]. *Transactions of the Korean Institute of Electrical Engineers*, 2009, 58(2): 399-406.
- [13] MOODY J, DARKEN C J. Fast learning in networks of locally-tuned processing units [J]. *Neural Computation*, 1989, 1(2): 281-294.

- [14] 吴月明,王益群,李莉. BP神经网络与广义RBF神经网络在产品寿命分布模型识别中的应用研究[J]. 中国机械工程, 2006, 20(17): 1012-1019.
WU Y M, WANG Y Q, LI L. Application study on BP network and generalized RBF network in estimating distribution model of mechanical products [J]. *China Mechanical Engineering*, 2006, 20(17): 1012-1019. (in Chinese)
- [15] 党开放,杨利彪,林廷圻. 一种新型的广义RBF神经网络及其训练方法[J]. 计算技术与自动化, 2007, 26(1): 9-13.
DANG K F, YANG L B, LIN T Q. A new type of general RBF neural network and its training method [J]. *Computing Technology and Automation*, 2007, 26(1): 9-13. (in Chinese)
- [16] ÇAYDAŞ U, HASÇALIK A. Use of the grey relational analysis to determine optimum laser cutting parameters with multi-performance characteristics [J]. *Optics and Laser Technology*, 2008, 40(7): 987-994.
- [17] 余治民,刘子建,艾彦迪,等. 基于神经模糊控制理论的数控机床热误差建模[J]. 中国机械工程, 2014, 25(16): 2225-2231.
YU ZH M, LIU Z J, AI Y D, *et al.*. Thermal error modeling of NC machine tool using neural fuzzy control theory [J]. *China Mechanical Engineering*, 2014, 25(16): 2225-2231. (in Chinese)
- [18] 杜正春,杨建国,窦小龙,等. 基于RBF神经网络的数控车床热误差建模[J]. 上海交通大学学报, 2003, 37(1): 26-29.
DU ZH CH, YANG J G, DOU X L, *et al.*. Thermal error modeling of CNC turning center using radial basis function neural network [J]. *Journal of Shanghai Jiaotong University*, 2003, 37(1): 26-29. (in Chinese)
- [19] MAILLARD E P, GUEROT D. RBF neural network, basis functions and genetic algorithm [C]. *IEEE International Conference on Neural Networks*, 1997, 4: 2187-2192.

作者简介:



吕程(1988—),女,辽宁抚顺人,博士研究生,2010年于湖南大学获得学士学位,主要从事复杂装备精度链理论研究。E-mail:lvcheng0424@126.com

作者简介:



刘子建(1953—),男,湖南常德人,教授,博士生导师,1975年、1983年、2002年于湖南大学分别获得学士、硕士、博士学位,主要从事复杂装备精度链理论研究、产品信息一致性理论研究、汽车车身的刚度理论研究。E-mail:zijianliu@hnu.edu.cn

(版权所有 未经许可 不得转载)