

文章编号 1004-924X(2016)04-0826-09

## 五轴机床旋转轴误差的在机测量与 模糊径向基神经网络建模

叶建华<sup>1,2</sup>, 高诚辉<sup>\*1</sup>, 江吉彬<sup>2</sup>

- (1. 福州大学 机械工程及自动化学院, 福建 福州 350116;
2. 福建工程学院 机械与汽车工程学院, 福建 福州 350118)

**摘要:** 考虑五轴机床中的旋转轴误差会影响加工精度和在机测量结果, 本文研究了旋转轴误差的在机测量与建模方法。介绍了基于标准球和机床在机测量系统的旋转轴综合误差测量方法, 采用随机 Hammersely 序列分组规划旋转轴的测量角位置, 通过自由安放策略确定标准球初始安装位置。然后, 引入模糊减法聚类和模糊 C-均值聚类 (Fuzzy C-means, FCM) 建立旋转轴误差的径向基 (Radial basis function, RBF) 神经网络预测模型。最后, 进行数学透明解析, 从而为误差的精确解析建模提供新途径。利用曲面的在机测量实例验证了提出的旋转轴误差测量与建模方法。结果表明: 利用所建模型计算的预测位置与实测位置的距离偏差平均值为  $9.6 \mu\text{m}$ , 最大值不超过  $15 \mu\text{m}$ ; 利用所建模型补偿工件的在机测量结果后, 其平均值由  $32.5 \mu\text{m}$  减小到  $13.6 \mu\text{m}$ , 最大误差也由  $62.3 \mu\text{m}$  减小到  $18.6 \mu\text{m}$ 。结果显示, 提出的测量方法操作简单, 自动化程度高; 模糊 RBF 神经网络的学习速度快、适应能力强、鲁棒性好, 能满足高度非线性、强耦合的旋转轴误差建模要求。

**关键词:** 五轴机床; 旋转轴误差; 误差建模; 误差测量; 在机测量; 模糊径向基神经网络

**中图分类号:** TH161.21 **文献标识码:** A **doi:** 10.3788/OPE.20162404.0826

## On-machine measurement and fuzzy RBF neural network modeling for geometric errors of rotary axes of five-axis machine tools

YE Jian-hua<sup>1,2</sup>, GAO Cheng-hui<sup>1</sup>, JIANG Ji-bin<sup>2</sup>

- (1. School of Mechanical Engineering and Automation, Fuzhou University, Fuzhou 350116, China;
  2. School of Mechanical & Automotive Engineering, Fujian University of Technology, Fuzhou 350118, China)
- \* Corresponding author, E-mail: gch@fzu.edu.cn

**Abstract:** As geometric errors of rotary axes of a five-axis machine impact on its machining accuracy, the on-machine measurement of rotary axes and their error modeling were investigated. Firstly, the measurement method for comprehensive errors of rotary axes was presented based on a standard ball and an on-machine measurement system. The measurement angular positions of the rotation axes were planned by the random Hammersely sequence and the initial position of the standard ball was determined with a free installation strategy. Then, a Radial Basis Function (RBF) neural network model for predicting comprehensive errors of the rotary axes was built based on subtractive clustering and

**收稿日期:** 2015-12-11; **修订日期:** 2016-01-20.

**基金项目:** 国家自然科学基金资助项目 (No. 51575110); 福建省产业技术联合创新专项资助项目 (智能旋转模切机关键技术研究产业化开发); 福建省科技区域发展项目资助项目 (No. 2016H4006); 福建省自然科学基金资助项目 (No. 2015J01628, 2016J01202)

Fuzzy C-means(FCM) cluster. Finally, mathematical analysis was carried out to provide a new way to model accurately for geometric errors of rotary axes. A cambered measuring example was used to verify the proposed on-machine measurement method and modeling method. The experimental results indicate that the average deviation between the predicted points from the mathematics model and measured points is  $9.6 \mu\text{m}$  and the maximum deviation is not more than  $15 \mu\text{m}$ . After the measuring results are corrected by the mathematic model with a 3D coordinate measuring machine established by this paper, the average value is reduced to  $13.6 \mu\text{m}$  from  $33.5 \mu\text{m}$  and the maximum value is reduced to  $18.6 \mu\text{m}$  from  $62.3 \mu\text{m}$ . It concludes that the measurement method is simple to operate and has high automation. The neural network's training is not only fast speed, adaptable and good robust, but also can meet highly linear and strongly coupling of modeling of the geometric errors of rotary axes.

**Key words:** five-axis machine tool; geometric error of rotary axis; error modeling; error detection; on-machine measurement; fuzzy radial basis function

## 1 引言

五轴机床通过旋转轴提升了机床的柔性,利用在机测量系统实现了测量过程与加工过程的有机融合,是复杂曲面类零件的理想加工设备。旋转轴既存在组成构件的制造、装配误差,又存在磨损、变形等,使得旋转轴误差往往比直线轴的大很多<sup>[1]</sup>,直接影响复杂曲面的加工精度和在机测量结果,为了保证产品质量,需要对旋转轴误差进行测量与补偿。

旋转轴误差不容易直接精确测量,目前,主要通过球杆仪<sup>[2]</sup>、R-test<sup>[3]</sup>、3D测头-球座一体仪<sup>[4]</sup>、4D测头<sup>[5]</sup>、电容测头<sup>[6]</sup>等设备对综合误差进行测量。而随着高精度接触式在机测量技术的成熟,测量系统与数控机床无缝集成,使得接触式在机测量系统成为误差自动测量与补偿的理想工具,受到学界和产业界的重视。ISO 230-10<sup>[7]</sup>给出了接触式测头的测量规范标准。IBAEAKI S.等人<sup>[8]</sup>基于3个标准方块利用接触式在机测量系统进行五轴机床旋转轴误差的综合测量,利用小角度误差理论和其次坐标变换原理进行各轴位置误差和运动误差的分步辨识。BI Q Z等人<sup>[9]</sup>基于单个标准方块利用触发式在机测量系统进行五轴机床旋转轴误差的测量,并基于刚体运行学的误差建模理论进行误差的分轴辨识。上述方法中,方块作为测量标定器,容易自遮挡影响测点的布局,且对不同旋转轴的耦合误差难以精确分解。Erkan T等人<sup>[10]</sup>基于多个标准球利用触发式在机测量系统进行五轴机床误差失真程度的分析,

测量点只布置在旋转轴的等角度间隔位置上,且未给出误差的建模与辨识方法。

旋转轴误差的成因复杂,误差项多。每根旋转轴包含4项定位误差和6项运动误差<sup>[11]</sup>,不同轴间的误差存在耦合,呈高度非线性关系,使得精确建模与辨识困难。人工神经网络,模拟人脑神经元结构,通过学习形成推理、辨别的能力,在数控机床热误差建模中得到广泛应用,取得了较好的成果<sup>[12,13]</sup>。神经网络模型的知识往往通过节点权值与阈值表达,是初级的知识表达,通常难以理解。模糊逻辑则模拟人的思维过程,能满足高级知识的表达,但提取模糊规则和生成模糊变量隶属度困难<sup>[14]</sup>。将RBF神经网络与模糊技术相结合,可增强神经网络模型的知识表达能力和模糊知识的学习能力,在多参量、强耦合、非线性的旋转轴误差建模中具有优势,同时借助径向基神经网络的强解析性能,能将“黑箱”知识“透明化”,为旋转轴误差的精确解析建模提供新途径。

本文基于标准球和在机测量系统提出一种简单的旋转轴综合误差测量方法;引入模糊减法聚类和模糊C均值聚类方法建立旋转轴综合误差的RBF神经网络模型;同时对RBF神经网络进行解析,获得误差模型的解析表达式。

## 2 旋转轴综合误差的在机测量

### 2.1 旋转轴综合误差测量方法

五轴机床有双转台、双摆头、转台加摆头等多种形式,以转台加摆头结构形式的五轴数控机床为例,进行旋转轴综合误差测量方法的阐述。相

同的原理可以移植到其它结构形式的五轴机床上。转台加摆头的五轴数控机床中,旋转轴的布置及误差测量方案如图 1 所示。

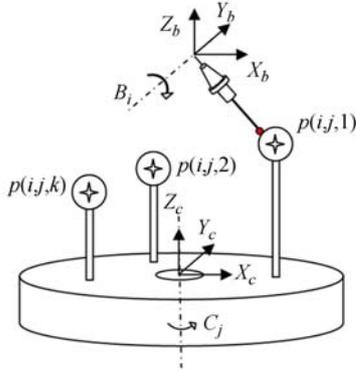


图 1 转台加摆头机床结构与测量方案简图

Fig. 1 Simplified structure diagram of five-axis machine tool with table-head structure and the schematic of measurement method

在旋转工作台上安装位置不同、高度不一的  $N_s$  个标准球。旋转轴 B、C 刚开始处于零位,  $b_1 = 0, c_1 = 0$ , 利用直线轴的插补运动驱动触发式测头测得标准球的初始球心坐标  $p(1, 1, k)$  ( $k = 1 \cdots N_s$ )。然后, 旋转 B、C 轴到  $b_i, c_j$  ( $i = 1 \cdots N_b, j = 1 \cdots N_c$ ) 处, 运动后球心点的名义坐标值为  $p'(i, j, k)$ , 测量值为  $p(i, j, k)$ 。  $p(i, j, k)$  与  $p'(i, j, k)$  的偏差即为该位姿下旋转轴的综合误差  $p_{e(i, j, k)}$ 。  $p_{e(i, j, k)}$  与标准球的初始安装位置及轴的旋转位置直接相关, 可描述为:

$$\begin{bmatrix} p_{e(i, j, k)} \\ 1 \end{bmatrix} = \begin{bmatrix} p(i, j, k) \\ 1 \end{bmatrix} - \begin{bmatrix} p'(i, j, k) \\ 1 \end{bmatrix} = f(T, p(1, 1, k)), \quad (1)$$

其中:  $T = [\theta, r, h, b, c]$ ,  $\theta$  为标准球相对于工作台的安装初始角度,  $r$  为安装半径,  $h$  为安装高度。

旋转位置  $[b, c]$  的测量位置规划可归为二维空间的采样规划范畴。利用随机 Hammersely 序列法<sup>[15]</sup>对 B、C 轴的测量角位移进行分组规划, 以通过有限测点尽可能地全局反映旋转轴角位移对误差的影响关系, 并兼顾后续自由确定标准球安装位置的便捷性。设 B 轴、C 轴的旋转范围分别为  $[b_l, b_u]$  和  $[c_l, c_u]$ , 分成  $N_m$  组, 每组采样  $N_h$  个点, 则第  $k$  ( $k = 1 \cdots N_m$ ) 组的测点角位移为:

$$b_{ki} = \left( \frac{N_m i + k}{N_h \times N_m} + b_{\text{rand}} \right) \bmod_1 \times (b_u - b_l) - b_l$$

$$c_{kj} = \left( \sum_{j=0}^{\lceil \log_2(N_h \times N_m) \rceil - 1} \left( \left\lfloor \frac{N_m i + k}{2^j} \right\rfloor \bmod_2 \right) 2^{-j-1} + c_{\text{rand}} \right) \bmod_1 \times (c_u - c_l) - c_l, \quad (2)$$

其中:  $i = 0 \cdots N_h, \lceil \log_2 N_h \times N_m \rceil$  为向上最小整数,  $\lfloor \frac{N_m i + k}{2^j} \rfloor$  为向下取最大整数,  $b_{\text{rand}}, c_{\text{rand}}$  为  $0 \sim 1$  的随机数。

同时, 为了避免超行程和增加采样的多样性, 在角位移分组规划的基础上结合测量仿真自由确定标准球的安装位置。基本过程为: 在工作台自由确定标准球初始安装位置,  $b_1 = 0, c_1 = 0$  状态下测得初始球心坐标; 根据初始球心坐标, 对第  $k$  组角位移规划位置进行测量仿真, 剔除超行程的规划点; 对未超行程的规格点位, 通过编程实现自动化测量采样; 调整标准球的安装位置和高度, 重复上述过程直至这一组规划的角位置都测量完成。

## 2.2 旋转轴综合误差的测量实验

在转台加摆头结构形式的德国 DMG DMU60 五轴加工中心上进行旋转轴综合误差的测量。图 2 所示为机床结构简图, 图 3 所示为现场测量图。机床的回转工作台直径为  $\Phi 600$  mm, 转角为  $0 \sim 360^\circ$ , 摆头 B 轴转角为  $-120 \sim 30^\circ$ , X/Y/Z 向行程为 630/560/560 mm。采用 Heidenhain TS740 接触式测头, 各向探测精度特性相同, 测量头精度为  $1 \mu\text{m}$ , 重复精度小于  $0.25 \mu\text{m}$ 。标准球的标定半径为  $20.0021$  mm。测量前机床充分预热, 测量环境温度  $22^\circ\text{C}$ , 忽略热变形误差的影响。

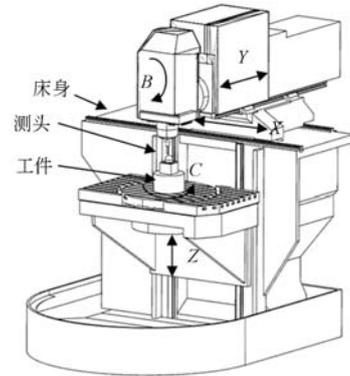


图 2 DMG DMU60 五轴机床简图

Fig. 2 Simplified structure diagram of DMG DMU60

利用式(2), 并分 3 组, 每组 40 个测量位置进行  $[b, c]$  测量角位移的规划, 结果如图 4 所示。可见不管是分组还是整体的规划点都能均匀充满整



图 3 现场测量图

Fig. 3 Measurement of rotary axes errors on site

个角度空间。每组至少在工作台上安放 3 个位置进行测量。标准球安放位置无需精确确定,但应尽量使标准球球心的测量位置均匀覆盖工作台面和高度行程所形成的空间。

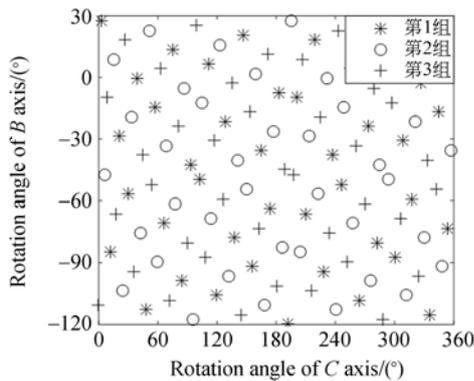


图 4 旋转轴旋转位置规划图

Fig. 4 Planning for rotation position of two rotary axes

在实验测量时,球心坐标通过测量球面 5 点坐标值拟合而成,其中 1 点处在测量头球心与标准球球心的连线上,其余 4 点均匀分布在与该连线相垂直的最大切球上。每个球心位置点,通过球面五点的 4 次测量获得。第一次为粗测量,以理论点为测量目标点。利用第一次测量拟合的球心坐标作为后续 3 次的测量目标点,取后续 3 次测量的均值作为测量结果。

通过上述方法,总共获得球心坐标的总采样个数为 396 个。预测值与测量值相比,平均偏离距离为 28.7  $\mu\text{m}$ ,最大偏离距离为 56.6  $\mu\text{m}$ 。虽然物理空间中相近的点,由于 B、C 轴所处的角位移不一样,距离偏差值会明显不同。

### 3 RBF 神经网络建模

RBF 神经网络具有拓扑结构紧凑,学习收敛速度快,鲁棒性强,可映射任意复杂的非线性关系,拥有唯一最佳逼近的特性,理论证明在前向网络中 RBF 网络是完成映射功能的最优网络<sup>[14]</sup>,同时具有良好的解析性能,能将“黑箱”神经网络透明化,可满足五轴机床旋转轴误差的建模与固化预测要求。

#### 3.1 RBF 神经网络

RBF 神经网络是一种前馈神经网络,其结构如图 5 所示,由输入层、隐含层和输出层组成。

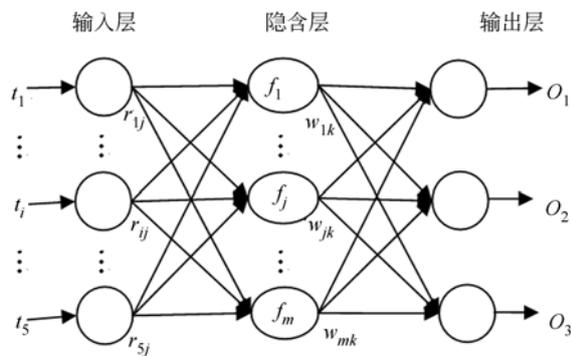


图 5 RBF 神经网络结构

Fig. 5 Structure of RBF neural network

输入层传递输入信息到隐含层,  $T = [t_1, \dots, t_i, \dots, t_5]^T$  为测量点位置值  $[0r, h, b, c]^T$ , 节点数与输入向量维数相同为 5 个。隐含层只有一个,由一组径向基向量构成高维的隐空间。输出层对输入提供响应,  $O = [o_1, o_2, o_3]^T$  为输入点位对应的综合误差  $p_e$  在 3 个线性坐标轴向的分量,节点数为 3。其模型函数表达式为:

$$f_j = \exp \left[ -\frac{\|T - \varphi_j\|^2}{2\sigma_j^2} \right], j = 1, 2, \dots, m, \quad (3)$$

$$o_k = \sum_{j=1}^m \omega_{jk} f_j, k = 1, 2, 3, \quad (4)$$

其中:  $\varphi_j$  是基函数的中心向量  $\varphi_j = [\phi_{1j}, \phi_{2j}, \dots, \phi_{ij}, \dots, \phi_{sj}]^T$ ,  $\sigma_j$  是隐含层第  $j$  个神经元高斯基函数的宽度;  $\|\cdot\|$  为欧几里德范数。 $\omega_{jk}$  为隐含层第  $j$  个神经元与输出层第  $k$  个神经元的连接权值。

#### 3.2 基于模糊聚类的 RBF 神经网络学习方法

在 RBF 神经网络中,隐含层节点个数  $m$ 、聚

类中心  $\phi$  需通过无师学习是神经网络建构的关键。选择不当会直接影响模型学习的有效性,传统的试凑法和与训练样本数相等的方法难以兼顾学习效率与精度,引入模糊减法聚类确定聚类中心个数  $m$  以解决这一问题。并进一步采用模糊 C-均值聚类方法代替传统的 C-均值聚类方法,以增强聚类的模糊鲁棒推理能力。

### 3.2.1 模糊减法聚类计算中心个数

模糊减法聚类是一种与样本维度无关,通过样本周围点密度指标快速推定样本数据聚类个数和聚类中心的方法。首先,将  $n$  个 5 维的输入样本数据  $T=[t_{ij}]_{i=1,2,\dots,n,j=1,2,\dots,5}$  都作为候选的聚类中心,并计算各个样本点  $t_i$  周围的密度指标为:

$$\rho_i = \sum_{j=1}^n \exp\left[-\frac{\|t_i - t_j\|^2}{(r_a/2)^2}\right], \quad (5)$$

其中:  $r_a$  为该点的领域半径。接着,找出密度指标最高的点作为第一个聚类中心  $t_{m1}$ ,对  $t_i$  的密度指标进行修正:

$$\rho_i = \rho_i - \rho_{a1} \exp\left[-\frac{\|t_i - t_{m1}\|^2}{(r_b/2)^2}\right], \quad (6)$$

其中:  $r_b$  为聚类中心  $t_{m1}$  的影响领域半径,以避免在邻近的  $r_b$  半径范围内出现另一聚类中心。然后,在修正后的密度指标中找出最大者作为下一聚类中心。不断重复上述过程直到剩余样本作为聚类中心的可能性低于设定的指标,从而找到个聚类中心,即可确定隐含层节点个数和初始的聚类中心。

### 3.2.2 模糊 C-均值聚类算法确定聚类中心

模糊 C-均值聚类方法是在 C-均值聚类方法的基础上,引入模糊理论,通过不断的迭代修改聚类中心矩阵和隶属度矩阵以搜索目标函数的最小点,进而实现将无明显边界的数据点按相似程度进行分类。

对  $T=[t_{ij}]_{i=1,2,\dots,n,j=1,2,\dots,5}$  进行  $M$  类划分的模糊聚类目标函数为:

$$J(U, V) = \sum_{i=1}^m \sum_{j=1}^n u_{ij}^c \|v_i - t_j\|^2, \quad (7)$$

其中:  $c$  为模糊指数,  $c \in [1, \infty]$ ;  $U$  为隶属度矩阵,  $U = \{u_{ij}\}_{i=1,2,\dots,m,j=1,2,\dots,n}$ ;  $u_{ij}$  表示样本集合中第  $j$  个元素隶属于第  $i$  个聚类中心的程度;  $V = \{v_i\}_{i=1,2,\dots,m}$ , 为聚类中心。同时,  $u_{ij}$  还需要满足以下条件:

$$\begin{cases} 0 \leq u_{ij} \leq 1 & i = 1, 2, \dots, m; j = 1, 2, \dots, n \\ \sum_{i=1}^m u_{ij} = 1 & j = 1, 2, \dots, n \\ 0 < \sum_{j=1}^n u_{ij} < n & i = 1, 2, \dots, n \end{cases}, \quad (8)$$

样本的最佳模糊 C-均值聚类是目标函数(7)的最小方差稳定解。通过求解可得:

$$u_{ij} = \left[ \sum_{k=1}^m \left( \frac{\|v_i - t_j\|^{2/(c-1)}}{\|v_k - t_j\|^{2/(c-1)}} \right) \right]^{-1}, \quad (9)$$

$$v_i = \frac{\sum_{j=1}^n u_{ij}^c x_j}{\sum_{j=1}^n u_{ij}^c} \quad i = 1, 2, \dots, m, \quad (10)$$

由于式(9)、(10)无解析解,将模糊减法聚类所确定的中心个数和聚类中心作为初始设定值,通过  $s$  次迭代计算,当  $\|U^s - U^{s+1}\| \leq \epsilon$  时,为给定的停止条件,得到目标函数的最优解。所求的最优解即为聚类中心  $\varphi$ 。

### 3.3 模糊 RBF 神经网络建模与仿真

将实验获得的 396 组数据样本用于 RBF 神经网络的误差建模。将输入样本根据机床的行程归一化到 0~1 内。模糊减法聚类的初始参数,  $r_a = 0.5$ ,  $r_b = 1.25 r_a$ , 计算出的聚类中心个数为 16, 确定网络模型结构为  $5 \times 16 \times 3$ 。利用模糊减法聚类获得的聚类中心作为初始值,采用模糊 C-均值聚类方法计算聚类中心。运用梯度下降法求解基宽参数和隐含层到输出层的连接权值。图 6 为旋转轴综合误差 X 方向分量的部分训练结果图。从图中可知训练后的网络能较好的逼近样本数据,达到建模的目的。

对同组样本数据,采用 K-均值聚类方法、模糊 C-均值聚类算法与本文模糊减法聚类结合模糊 C-均值聚类的方法进行比较。研究发现采用 K-均值聚类方法、模糊 C-均值聚类算法对聚类个数敏感,不合适的聚类个数对网络的有效性影响明显,而模糊减法聚类能较合适的确定聚类中心个数。设置的聚类个数相等的情况下,将模糊减法聚类获得的聚类中心作为模糊 C-均值聚类中心的初值所需的迭代次数和目标函数均值在大多数情况都小于其它两种。可知,通过模糊减法聚类和模糊 C-均值聚类相结合,使得网络的自适应

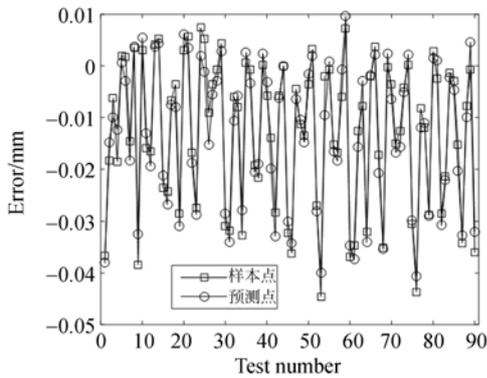


图 6 X 方向 RBF 神经网络训练结果图

Fig. 6 Training results of RBF neural network in X direction

能力增强,迭代计算减少,学习速度加快,精度提高。

另外,利用同样的方法随机测量不同点位的旋转轴综合误差,运用采集的数据样本对建立的网络模型进行仿真验证。从仿真验证结果可知,预测坐标点与实测坐标点的距离偏差平均值为

9.6  $\mu\text{m}$ ,最大值不超过 15  $\mu\text{m}$ ,图 7 为部分预测坐标点与实测坐标点相对于理论点的距离偏差图。通过仿真结果,说明了该模型的泛化能力好,能基本满足机床误差的预测要求。表 1 为所建模型的结构参数。

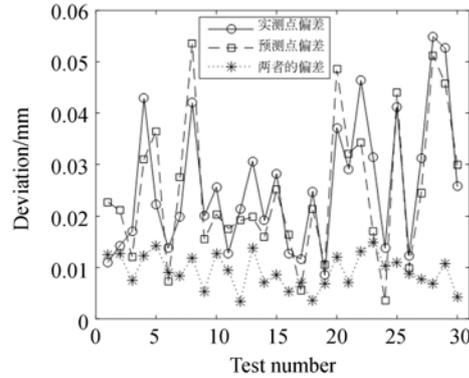


图 7 预测偏差与实测数据偏差对比图

Fig. 7 Contrast of deviations of predicted and measured results

表 1 RBF 神经网络结构参数

Tab. 1 Structure parameter of RBF neural network (注:保留四位小数)

RBF 聚类中心 $\varphi$				RBF 宽度 $\sigma$			连接权值 W	
0.253 9	0.320 0	0.386 2	0.679 2	0.779 4	0.290 2	0.030 6	-0.004 9	0.002 0
0.435 2	0.319 8	0.382 2	0.532 5	0.246 2	0.270 8	0.035 7	-0.019 9	0.013 5
0.743 2	0.431 3	0.497 8	0.355 6	0.668 8	0.299 1	-0.009 5	-0.012 7	-0.031 1
0.343 8	0.180 7	0.304 0	0.397 4	0.762 8	0.303 0	-0.013 1	-0.017 8	0.009 2
0.196 5	0.587 2	0.358 2	0.131 4	0.844 3	0.301 8	-0.008 6	0.003 4	-0.004 1
0.526 5	0.700 9	0.556 0	0.529 0	0.499 8	0.328 5	-0.034 9	-0.105 4	-0.023 0
0.128 3	0.573 4	0.369 5	0.148 3	0.506 5	0.290 7	0.027 4	0.017 0	0.009 0
0.425 4	0.429 9	0.494 9	0.390 4	0.233 8	0.320 4	-0.035 6	-0.016 6	-0.022 1
0.065 2	0.830 9	0.471 2	0.667 2	0.135 0	0.300 4	0.000 1	-0.017 0	0.004 1
0.624 5	0.427 2	0.499 8	0.273 6	0.490 6	0.313 0	-0.006 3	0.039 6	0.032 1
0.887 6	0.585 8	0.232 4	0.829 1	0.504 0	0.322 1	-0.010 7	0.017 4	0.002 1
0.675 2	0.705 2	0.540 3	0.668 2	0.279 2	0.272 7	0.040 7	0.040 8	0.000 0
0.485 9	0.821 3	0.488 2	0.660 8	0.824 0	0.285 5	0.016 5	-0.024 4	-0.012 2
0.928 9	0.081 9	0.351 1	0.850 0	0.290 9	0.301 8	0.001 5	0.007 4	0.001 1
0.565 4	0.754 6	0.546 3	0.698 9	0.616 3	0.290 5	0.017 0	0.059 7	0.031 2
0.678 5	0.604 3	0.352 9	0.147 3	0.190 8	0.302 1	-0.005 8	0.011 3	-0.006 2

进一步地,根据 RBF 神经网络的模型结构参数,可以解析 RBF 神经网络的传递方式与规律,

建立旋转轴综合误差的精确解析模型。根据表 1 参数可得网络模型隐含层节点的传递函数为:

$$\begin{aligned}
 f_1 &= \exp \left[ -\frac{\sqrt{(t_{i1}-0.2539)^2+(t_{i2}-0.32)^2+(t_{i3}-0.3862)^2+(t_{i4}-0.6792)^2+(t_{i5}-0.7794)^2}}{2 \times 0.2902^2} \right] \\
 f_2 &= \exp \left[ -\frac{\sqrt{(t_{i1}-0.4352)^2+(t_{i2}-0.3198)^2+(t_{i3}-0.3822)^2+(t_{i4}-0.5325)^2+(t_{i5}-0.2462)^2}}{2 \times 0.2708^2} \right], \\
 &\vdots \\
 f_{16} &= \exp \left[ -\frac{\sqrt{(t_{i1}-0.6795)^2+(t_{i2}-0.6043)^2+(t_{i3}-0.3529)^2+(t_{i4}-0.1473)^2+(t_{i5}-0.1908)^2}}{2 \times 0.3021^2} \right]
 \end{aligned} \quad (11)$$

根据网络的映射关系,即可建立输入与输出的映射关系表达式为:

$$\begin{aligned}
 \Delta_x = o_1 &= 0.0306f_1 + 0.0357f_2 + (-0.0095)f_3 \cdots + (-0.0058)f_{16} \\
 \Delta_y = o_2 &= -0.0049f_1 + (-0.0199)f_2 + (-0.0127)f_3 \cdots + 0.0113f_{16}, \\
 \Delta_z = o_3 &= 0.002f_1 + 0.0135f_2 + (-0.0311)f_3 \cdots + (-0.0062)f_{16}
 \end{aligned} \quad (12)$$

通过式(12)即可将神经网络的“黑箱”模型透明化,再结合归一化函数即可建立起旋转轴误差的解析表达模型,因此混合模糊聚类方法能将高度非线性误差模型的建立融合到聚类过程中,为误差的解析建模提供另外一个途径。

#### 4 工件的在机测量实验

工件的在机测量结果中包含旋转轴的误差,利用解析出的旋转轴误差模型对一曲面零件的在机测量结果进行补偿,并将补偿结果与三坐标测量机的检测结果进行比较,以验证误差测量与建模方法的有效性。

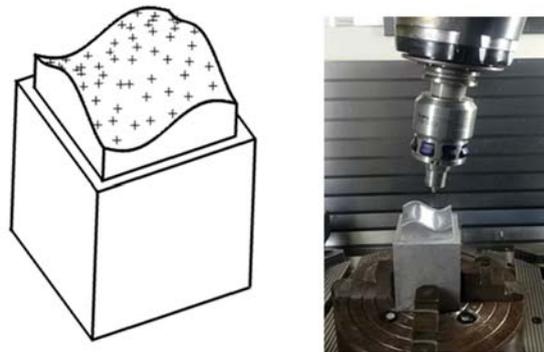
工件的曲面方程为:

$$S(x, y, z) = \begin{cases} x=75u \\ y=75v \\ z=-8(\sin(2\pi u) + \cos(2\pi v)) \end{cases}, \quad (13)$$

$$u \in [0, 1], v \in [0, 1].$$

在测量实例零件的边缘与下侧加工出高精度的大平面,作为测量与匹配对齐的参考基准,采用 Hammersely 序列采样法对曲面的测量点进行规划,规划点为 60 个。工件模型与测点分布如图 8(a)所示。零件加工后,在机床上静置 2 h,进行零件的在机测量。在机测量时,通过 B、C 轴的旋转,使测头沿着法向接近测量点。测量设备、环境与旋转轴误差测量实验相同,利用 PowerINSPECT 软件生成自动测量程序,图 8(b)所示为未拆卸零件的在机测量现场图。然后,同样利用 PowerINSPECT 软件生成 LK G90 三坐标测量

机的自动测量程序,对相同规划点进行测量,图 8(c)所示为在三坐标测量机上的测量现场图。



(a) 工件模型与测点图

(b) 在机测量

(a) Part model and sampling points

(b) On-machine measurement



(c) CMM 离线测量

(c) On CMM measurement

图 8 工件测量的验证实例

Fig. 8 A illustration of verification for the workpiece measurement

将三坐标测量机的测量结果作为参照,对旋转轴误差补偿的有效性进行分析。表2列举了部分在机测量原始数据、补偿旋转轴误差后的数据和对应的CMM测量数据。补偿后数据与CMM测量数据的差值体现这两组数据的接近程度。通过对

比分析得知,在机测量值与三坐标测量机的测量值间,最大偏差为 $62.3\ \mu\text{m}$ ,平均偏差为 $32.5\ \mu\text{m}$ ,标准方差为 $9.4\ \mu\text{m}$ ;经在机测量误差补偿后与三坐标测量机的测量值间的最大偏差为 $18.6\ \mu\text{m}$ ,平均值为 $13.6\ \mu\text{m}$ ,标准方差为 $5.2\ \mu\text{m}$ 。

表2 曲面零件部分点补偿前后的在机测量与CMM离线测量精度对比表

Tab.2 Comparison of workpiece' precision of on-machine measurement results without and with error compensation and on CMM measurement results (mm)

序号	在机测量的部分数据						对应的CMM测量数据			补偿后与CMM测量数据的距离偏差
	补偿前			补偿后			x	y	z	
	x	y	z	x	y	z				
1	3.597 2	14.046 4	24.527 9	3.609 2	14.035 1	24.533 8	3.604 3	14.028 1	24.538 2	0.009 6
2	14.881 4	35.109 3	30.278 5	14.868 7	35.120 8	30.266 5	14.854 3	35.121 9	30.264 1	0.014 6
3	28.641 7	28.105 3	30.199 8	28.608 3	28.097 3	30.215 9	28.604 3	28.090 6	30.215 3	0.007 8
4	44.845 4	32.798 3	42.024 1	44.849 6	32.788 6	41.996 1	44.854 3	32.778 1	42.005 1	0.014 6
5	57.323 4	58.563 2	36.434 7	57.352	58.564 2	36.421 5	57.354 3	58.559 4	36.427 7	0.008 1
6	27.378 5	65.612 3	18.341 2	27.358 6	65.604 3	18.343 9	27.354 3	65.590 6	18.349 4	0.015 4
7	67.354 3	56.215 6	34.809 7	67.340 2	56.193 7	34.824 7	67.332 1	56.185 6	34.821 6	0.011 9
8	22.354 3	49.184 4	26.825 6	22.341 2	49.201 4	26.814 6	22.346 3	49.196 8	26.816 5	0.007 1
9	31.104 3	9.340 6	20.242 1	31.126 4	9.345 5	20.230 7	31.125 4	9.342 7	20.243 2	0.012 9
10	71.104 3	74.965 6	24.564 7	71.091 6	74.939 8	24.554 7	71.086 9	74.942 6	24.548 7	0.008 1

## 5 结 论

本文提出了一种旋转轴综合误差的快速测量与鲁棒建模方法,有效破解五轴机床旋转轴误差的测量与建模难题。基于高精度标准球和机床的在机测量系统,设计了旋转轴综合误差的便捷测量方法,大幅度降低了测量操作难度。针对旋转轴误差的高度非线性,提出了基于RBF神经网络的误差建模方法,在无师学习阶段引入模糊减法聚类和模糊C-均值聚类算法,克服了聚类方法对

中心个数敏感的难题,提升了网络的学习速度快,所建模型精度高,自适应能力强。同时对RBF神经网络模型进行解析,建立旋转轴误差模型的解析表达式,为旋转轴误差的精确解析建模提供新途径。利用曲面的在机测量实例进行旋转轴误差测量与建模方法的有效性验证,试验结果表明,通过本文预测误差进行在机测量误差补偿后,平均值由补偿前的 $32.5\ \mu\text{m}$ 减小到 $13.6\ \mu\text{m}$ ,最大误差也由 $62.3\ \mu\text{m}$ 减小到 $18.6\ \mu\text{m}$ ,证明了本文方法的有效性。

## 参考文献:

- [1] HONG C F, IBAEAKI S, MATSUBARA A, Influence of position-dependent geometric errors of rotary axes on a machining test of cone frustum by five-axis machine tools [J]. *Precision Engineering*, 2011, 35(1): 1-11.
- [2] XIANG S, YANG J. Using a double ball bar to measure 10 position-dependent geometric errors for rotary axes on five-axis machine tools[J]. *The International Journal of Advanced Manufacturing Technology*, 2014, 75(1-4): 559-572.
- [3] IBAEAKI S, NAGAI Y, OTSUBO H, et al.. R-Test analysis software for error calibration of five-axis machine tools - application to a five-axis machine tool with two rotary axes on the tool side[J]. *International Journal of Automation Technology*, 2015, 9(4): 387-395.
- [4] LEI W T, HSU Y Y. Accuracy enhancement of five-axis CNC machines through real-time error compensation [J]. *International Journal of Ma-*

- chine Tools and Manufacture, 2003, 43(9): 871-877.
- [5] WEIKERT S, KNAPP W. R-test, a new device for accuracy measurements on five axis machine tools [J]. *CIRP Annals-Manufacturing Technology*, 2004, 53(1): 429-432.
- [6] ZARGARBASHI S H H, MAYER J R R. Single setup estimation of a five-axis machine tool eight link errors by programmed end point constraint and on the fly measurement with Capball sensor [J]. *International Journal of Machine Tools and Manufacture*, 2009, 49(10): 759-766.
- [7] ISO 230-10:2011, Test Code for Machine Tools-Part 10: Determination of measuring performance of probing systems of numerically controlled machine tools[S]. 2010.
- [8] IBAEAKI S, OTA Y. Error calibration for five-axis machine tools by on-the-machine measurement using a touch-trigger probe [J]. *International Journal of Machine Tools & Manufacture*, 2014, 8: 20-27.
- [9] BI Q Z, HUANG N D, SUN C, *et al.*. Identification and compensation of geometric errors of rotary axes on five-axis machine by on-machine measurement[J]. *International Journal of Machine Tools & Manufacture*, 2015, 89: 182-191.
- [10] ERKAN T, MAYER J R R, DUPONT Y. Volumetric distortion assessment of a five-axis machine by probing a 3D reconfigurable uncalibrated master ball artefact [J]. *Precision Engineering*, 2011, 35(1): 116-125.
- [11] ISO 230-7: 2015, Test code for machine tools - Part7: Geometric accuracy of axes of rotation[S]. 2015.
- [12] 谢春, 张为民. 车铣复合加工中心综合误差检测及补偿策略[J]. *光学 精密工程*, 2014, 22(4): 1004-1011.
- XIE CH, AHANG W M. Comprehensive measurement errors of 5-axis turning-milling centers and their compensation strategies[J]. *Opt. Precision Eng.*, 2014, 22(4): 1004-1011. (in Chinese)
- [13] 吕程, 刘子云, 刘子建, 等. 广义径向基函数神经网络在热误差建模中的应用[J]. *光学 精密工程*, 2015, 23(6): 1705-1713.
- LU CH, LIU Z Y, LIU Z J, *et al.*. Application of generalized radial basis function neural network to thermal error modeling [J]. *Opt. Precision Eng.*, 2015, 23(6): 1705-1713. (in Chinese)
- [14] 张永志, 董俊慧. 基于模糊 C 均值聚类的模糊 RBF 神经网络预测焊接接头力学性能建模[J]. *机械工程学报*, 2014, 50(12): 58-64.
- ZHANG Y ZH, DONG J H. Modeling fuzzy RBF neural network to predict of mechanical properties of welding joints based on fuzzy C-means cluster [J]. *Journal of Mechanical Engineering*, 2014, 50(12): 58-64. (in Chinese)
- [15] 温秀兰, 王东霞, 朱晓春, 等. 基于坐标测量机的自由曲面检测采样策略[J]. *光学 精密工程*, 2014, 22(10): 2725-2732.
- WEN X L, WANG D X, ZHU X CH, *et al.*. Sampling strategy for free-form surface inspection by using coordinate measuring machines [J]. *Opt. Precision Eng.*, 2014, 22(10): 2725-2732. (in Chinese)

#### 作者简介:



叶建华(1980—),男,福建宁德人,博士研究生,讲师,2003年、2006年于华侨大学分别获得学士、硕士学位,主要从事制造过程自动化及信息化的研究。E-mail: yeuser@fjut.edu.cn

#### 导师简介:



高诚辉(1953—),男,福建福清人,教授,博士生导师,1982年、1985年于福州大学分别获得学士、硕士学位,1990年于机械部机械科学研究院获得博士学位,主要从事数字化设计、摩擦学和表面工程的研究。E-mail: gch@fzu.edu.cn.