

机床热误差补偿建模方法研究

刘光磊, 刘康, 郭翠霞, 刘学文

(四川理工学院机械工程学院, 四川 自贡 643000)

摘要:在机床热误差补偿技术研究中,热误差鲁棒建模是机床热误差补偿的成功关键之一。对国内外几种主要的热误差建模方法进行了较为深入的分析研究,比较了不同方法各自的优缺点,并针对缺点介绍了一些改进方法。在此基础上,总结归纳了目前研究存在的问题,并对未来的发展方向进行了探讨。

关键词:机床;热误差;误差补偿;建模方法

中图分类号:TG659

文献标志码:A

随着数控机床与精密加工技术的广泛应用,机床热误差成为影响机床加工精度稳定性的主要误差源。根据有关资料统计,在具有高精度要求的机床加工过程中,热变形误差是不可忽视的重要误差,大约占到总误差的 40%~70%^[1]。因此,减小热误差对提高机床的加工精度至关重要。在机床热误差补偿技术研究中,如何建立精确性和鲁棒性较强的补偿模型是机床热误差补偿研究的关键问题之一,因此热误差补偿建模是机床热误差补偿研究的一项重要内容,对此国内外学者进行了大量的研究,提出了很多热误差补偿建模方法。

1 热误差补偿建模的常用方法

1.1 回归分析方法

所谓回归分析法,是在掌握大量观察数据的基础上,利用数理统计方法建立因变量与自变量之间的回归关系函数表达式(称回归方程式)。

多元线性回归是国内外学者研究机床热误差的经典方法,该方法的应用以自变量与因变量成线性关系的假设为基础,通过实验,得到多个测温点温度与机床单个方向上的热误差变化输出关系。多元线性回归模型关系式为:

$$Z = TC + \mu \quad (1)$$

其中:

$$Z = \begin{bmatrix} Z_1 \\ Z_2 \\ \vdots \\ Z_n \end{bmatrix}, T = \begin{bmatrix} 1 & T_{11} & \cdots & T_{m1} \\ 1 & T_{12} & \cdots & T_{m2} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & T_{1n} & \cdots & T_{mn} \end{bmatrix}$$
$$C = \begin{bmatrix} C_0 \\ C_1 \\ \vdots \\ C_m \end{bmatrix}, \mu = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_n \end{bmatrix}$$

式中: Z_i ——机床某方向第 i 次测得的热误差值

C_i ——回归系

T_{ki} ——机床上第 k 个传感器第 i 次测得的温度

μ_i ——相互独立且服从同一正态分布的随机变量

Z 与 T 为已知参数,利用最小二乘法可以求出计算参数 C 。设 c_0, c_1, \dots, c_m 分别为参数 C_0, C_1, \dots, C_m 的最小二乘估计,则回归方程为:

$$Z = c_0 + c_1 T_1 + c_2 T_2 + \cdots + c_m T_m \quad (2)$$

多元线性回归模型的建模过程不仅结构简单、而且性能可靠,对于结构、工况均比较简单的机床模型精度预测较高。但数控机床是一个很复杂的热态系统,利用线性回归很难正确反映机床温度与热误差之间的关系。

在此基础上发展了多元非线性回归,对于多元二次非线性函数,其热误差与温度自变量之间的函数关系一般为^[2]:

$$Z = C_0 + \sum_{j=1}^n C_j T_j + \sum_{j=1}^n C_{jj} T_j^2 + \sum_{j>i} C_{ji} T_j T_i \quad (i = 1, 2, \dots, n - 1) \quad (3)$$

式中各字母含义同上。文献[3]分别用多元二次非线性回归和多元三次非线性回归对机床热误差建模,结果表明多元非线性回归有更好的预测能力,但多元三次回归模型相对二次非线性模型精度提高有限,且更高次的多元非线性回归模型精度反而下降,因此可以推测机床温度和热误差之间基本符合二次函数关系^[3]。

多元线性回归模型对温度测量数据的依赖性强,并受多重共线性问题的影响,在自变量高度相关条件下,其回归系数的一般解释作用不适用。文献[4]用偏最小二乘回归方法建立了温度与热误差两者的多元线性回归模型,并对各个测温点的温度变化与主轴热误差之间的量化关系进行了定性研究。该模型具有较强的预测能力和较为理想的精度,并满足加工中心热误差实时补偿的需要。

1.2 灰色系统模型

灰色系统理论由我国学者邓聚龙教授于 1982 年最先提出,它是一种研究少数据、贫信息不确定性问题的新方法。该系统可依据其自身数据建立动态微分方程进而预测自身的发展。对灰色变量的处理通常是将获得的原始数据作累加或累减,以减弱甚至消除原序列中的随机性信息,生成具有较强规律性的数据序列。

设 $Z^{(0)} = \{Z^{(0)}(1), Z^{(0)}(2), \dots, Z^{(0)}(n)\}$ 为原始数据序列, $Z^{(1)}(t)$ 为累加生成序列,即

$$Z^{(1)}(t) = \sum_{m=1}^t Z^{(0)}(m) \quad t = 1, 2, \dots, n$$

则灰色系统 GM(1,1)模型相应的微分方程为

$$\frac{dZ^{(1)}}{dt} + aZ^{(1)} = u$$

式中: a 为发展灰数; u 为内生控制灰数。

解微分方程得到灰色模型

$$Z^{(1)}(t + 1) = (Z^{(0)}(1) - \frac{u}{a})e^{-at} + \frac{u}{a} \quad (4)$$

做一次累减运算,可得还原模型

$$Z^{(0)}(t + 1) = Z^{(1)}(t + 1) - Z^{(1)}(t) \quad t = (1, 2, \dots, n) \quad (5)$$

灰色系统 GM(1,1)模型包括了一般线形回归和幂函数的内容,对于机床热误差建模有很好的拟合和预测效果,具有较强的趋势性。而且建模和计算速度快,对

原始数据要求不高,不需要大量的数据信息作为建模基础,是一种比较简便而对采集数据信息要求较宽的模型。

但从式(5)可知,灰色系统是根据自身原始数据来预测自身的发展的模型。在实际建模中,原始数据序列的数据不一定全部用来建模,在原始数据序列中取不同的数据,建立的模型就不一样。为了提高模型的精确性和鲁棒性,文献[5]提出了新信息 GM(1,1)模型和新陈代谢 GM(1,1)模型,其中新陈代谢 GM(1,1)模型预测精度最好,分别比新信息 GM(1,1)模型和全数据 GM(1,1)模型预测误差减小了 19.06% 和 55.62%。

灰色系统另一主要问题是其仅通过机床某一热误差元素(如机床 x 向热误差)自身时序数据建立模型,忽略了相关热源温度变化对其造成的影响。文献[6]针对这一问题提出了 GM(1,4)及 GM(0,4)模型,从理论上讲能够更为深入的揭示了热误差同其成因即机床各热源间的联系,获得更高的预测精度。

1.3 神经网络建模

神经网络是一种模仿生物神经网络的结构和功能的数学模型。由大量的神经元相互连接构成。每个神经元代表一种特定的输出函数,称为激励函数(activation function)。每两个神经元间的连接都代表一个对于通过该连接信号的加权值,称之为权重(weight),这相当于人工神经网络的记忆。网络的输出则依网络的连接方式,权重值和激励函数的不同而不同。神经元的结构如图 1 所示。

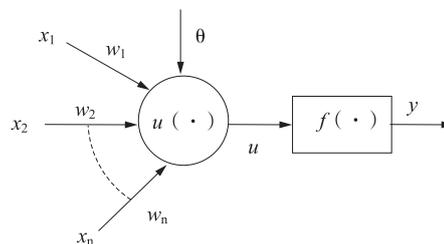


图 1 神经元结构图

神经网络模型结构由输入层、隐含层和输出层组成。对于热误差网络结构,输入层是测温点数据,输出层为热误差值,输入层与输出层之间为隐含层,目前在热误差建模中一般采用三层网络结构,即包含一个隐含层,其结构如图 2 所示。

利用神经网络建模的中间过程基本上可看作一个“黑匣子”,一般在 MATLAB 上建模,利用 MATLAB 自带的神经网络工具箱,可直接调用相关函数,避免复杂的编程过程,利用神经网络建立机床热误差的步骤为^[7]:

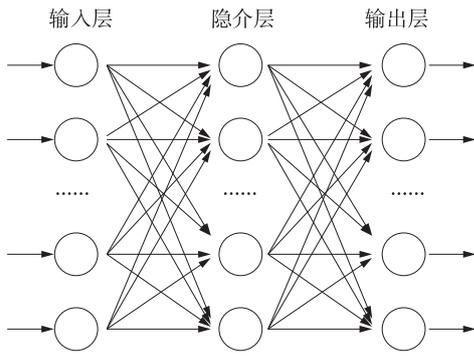


图 2 热误差神经网络结构

(1) 将实验采集的温度和热误差数据分成训练样本和验证样本;

(2) 用训练样本对神经网络进行训练,直至满足精度要求为止;

(3) 用验证样本对训练好的网络进行验证,若满足精度要求,则认为此时的网络参数合理;若不满足要求,则返回第二步对神经网络重新训练,直到训练误差与验证误差均满足精度要求为止。

神经网络可以充分逼近任意复杂的非线性关系,可学习和自适应不确定的系统,所有定量或定性的信息都等势分布贮存于网络内的各神经元,故有很强的鲁棒性和容错性。早在 1993 年国外就有人利用神经网络运用到机床热误差建模中^[8-9],提高了热误差数学模型的精度。在机床热误差的补偿建模中大部分均采用 BP (Back Propagation) 和 RBF (Radial Basis Function) 神经网络模型,并与最小二乘的多元线性回归模型进行比较,实验表明,神经网络模型能更好的模拟热误差的实际情况,具有更高的预测精度,其中 BP 网络精度最高。但 BP 算法收敛速度慢,容易陷入局部最小,初始值很难确定。RBF 网络的精度虽然略差于 BP 网络,但因为大部参数可以根据实际问题在初始化时给出较好的初始值,从而网络结构设计简便,训练速度也较快。

神经网络隐含层设计中,对于神经元数目的确定,理论上还并没有一个很好的解析式。在以往的热误差建模中,隐含层的数目一般是根据前人经验和自己进行试验来确定,但这样不仅花时间而且不一定准确。目前在利用神经网络建立热误差模型时一般先通过一些智能算法,如粒子群优化算法、蚁群算法、遗传算法等优化隐含层数目及初始值,以提高模型的收敛速度和预测精度^[10-12]。

1.4 支持向量机模型

支持向量机是近年来发展起来的一种专门针对小

样本情况进行研究的机器学习规律理论,被认为是针对小样本统计和预测学习的最佳理论^[13]。

对于给定的训练数据集:

$$(x_i, y_i), x_i, y_i \in R, i = 1, 2, \dots, n$$

支持向量机的基本思想就是把输入向量 x 通过一个非线性变换 $\Psi(x)$ 映射到一个高维空间 Z ,并在 Z 中求最优回归函数。这样在低维空间的非线性回归就对应高维空间中的一个线性回归,即:

$$\begin{cases} f(x) = w \cdot \Psi(x) + b \\ \Psi: R^n \rightarrow Z, w \in Z \end{cases}$$

式中 w 为权向量,对于热误差建模 $x = [T_1, T_2, \dots, T_n]$ 是由 n 个温测点测得的温度值, b 为阈值, $f(x)$ 即为对应的热误差值。引入不敏感函数 ξ , 则用于函数回归的支持向量机可以表示为:

$$\begin{cases} \min \Phi(w) = \frac{1}{2}(w \cdot w) + C \sum_{i=1}^n (\xi_i + \xi_i^*) \\ \text{s. t: } y_i - (w \cdot \Psi(x_i)) - b \leq \varepsilon + \xi_i \\ (w \cdot \Psi(x_i)) + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0, (i = 1, 2, \dots, n) \end{cases}$$

引入拉格朗日函数将其转换为对偶问题:

$$\begin{cases} \max W(\alpha, \alpha^*) = \sum_{i=1}^n y_i (\alpha_i^* - \alpha_i) - \sum_{i=1}^n \varepsilon (\alpha_i^* + \alpha_i) \\ - \frac{1}{2} \sum_{i,j=1}^n (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) (\Psi(x_i) \cdot \Psi(x_j)) \\ \text{s. t: } \sum_{i=1}^n (\alpha_i^* - \alpha_i) = 0, i = 1, 2, \dots, n \\ 0 \leq \alpha_i^* \leq C, 0 \leq \alpha_i \leq C \end{cases}$$

通过约束优化问题的对偶凸二次规划问题解得拉格朗日系数:

$$\bar{\alpha}^* = (\bar{\alpha}_1, \bar{\alpha}_1^*, \dots, \bar{\alpha}_n, \bar{\alpha}_n^*)^T$$

$$\bar{b} = y_i - \sum_{i=1}^n (\alpha_i^* - \alpha_i) (\Psi(x_i) \cdot \Psi(x_j)) - \varepsilon$$

得到对未来样本 x 的预测函数为:

$$f(x) = \sum_{i=1}^n (\bar{\alpha}_i^* - \bar{\alpha}_i) K(x_i, x) + \bar{b} \quad (6)$$

式(6)中 $\bar{\alpha}_i^*, \bar{\alpha}_i$ 为拉格朗日系数, x_i 为支持向量, $K(x_i, x) = \Psi(x_i) \cdot \Psi(x)$ 为核函数, n 为支持向量机个数, \bar{b} 为阈值。核函数主要包括线性函数、多项式函数、B 样条、高斯径向基函数 (RBF) 和多层感知器函数 (MLP) 等。热误差建模中核函数一般选择高斯径向基核函数:

$$K(x_i, x) = \exp(-\|x_i - x\|^2 / \sigma^2)$$

式中 σ 为函数的宽度参数。

支持向量回归机 (Support Vector Regrs - sion, SVR) 建立在 VC 维理论上,采用结构风险最小化原则,它

不仅结构简单,且可以有效解决模型选择与欠学习、过学习、小样本、非线性、局部最优和维数灾难等问题,泛化能力大大提高^[14]。国内外学者对于将支持向量机用于热误差分析进行了很多研究,新加坡国立大学的 Ramesh R 等人^[15]曾利用支持向量机进行热误差建模,并取得了一定成果。浙江大学江亮,刘健等人^[16]利用支持向量机对加工误差进行预测,并与其他常用的建模方法进行了比较,结果表明该方法的预测精度最高。文献^[17]对机床在不同环境温度或环境温度变化较大的条件下热误差模型本身的稳健性进行探讨,验证了支持向量回归机模型用于热误差建模的稳健性。

利用支持向量机进行热误差建模的最大问题是参数的优化选择,目前还没有很好的办法,比较流行的是网格法和交叉验证法,但并不是很理想。利用智能算法进行参数优化是一个可行而且理想的途径,但目前还很少看到相关文献,需要进一步研究。支持向量机另一个问题是求解过程需要很大的计算资源,而且速度较慢。有很多学者在这方面对支持向量机进行了改进,其中一个重要的变种是 J. A. K. Suykens 提出的最小二乘支持向量机(LS-SVM),它在保持 SVM 优点的基础上,通过适当的变换,简化了运算算法,显著降级了计算成本。浙江大学傅建中,许亚洲,林伟青等人^[18-19]利用该方法对机床热误差进行建模,取得了很好的效果,但在参数的优化选择方面和 SVM 存在同样的问题。

2 其他建模方法

除了上述主要的建模方法外,研究人员还尝试了许多新的建模方法:清华大学赵大泉等^[20]提出了主轴热误差自组织补偿法,只需根据对主轴热误差定性测量结果即可进行误差补偿,无需精确知道热误差具体数值,对传感器精度要求不高;华中科技大学雷琪等人^[21]基于贝叶斯理论,提出针对机床加工过程中热误差动态建模方法,对机床热误差实时补偿的控制需求,提出了解决方案;Ramesh R 等^[22]利用有限元技术确定了机床温度分布和热变形,并对发热部件及包含热源的支撑部件进行了优化;刘又午等^[23]基于多体系统理论建立了数控加工中心热误差模型,以实时补偿方式分别沿三个方向进行了加工验证。

3 热误差建模方法总结与展望

所有这些热误差模型都有一定的补偿效果,对热误差补偿研究起到了巨大的推动作用,但这些模型都存在自身的某些方面的不足,很难满足生产过程的实际需

要。主要存在两方面的原因:

(1) 上述建模方法大部分为离线建模,一般情况下,离线建模所用的样本数据库中的数据是机床加工过程中某段时间内的数据,不能反映机床在整个加工过程中的具体情况,利用该样本数据库建立起来的热误差模型不能很好的预测机床在整个加工过程中的误差值,当加工条件变化时,预测的误差值与真实值之间就有可能发生较大的偏差,所以该方法鲁棒性较差。

(2) 由于热误差的产生机理及变化规律错综复杂,其中存在着时变性、非线性、不确定性的作用关系,单一的预测模型很难将所有的关系表达出来,不可避免的存在着较大的误差,精确性不好。

针对上面两个问题,研究人员提出了组合模型和在线建模方法。组合模型能将每一种预测方法在处理数据发挥的独特功能,根据不同的角度进行推理和阐释,获得更有价值的预测结果。在线建模能够在机床加工的过程中不断的采集新的数据来更新样本数据库,实时的改变热误差模型,提高模型的鲁棒性,通用性更好。目前在这两方面已有学者在研究,如文献^[6]、^[21],但方法还需进一步完善。将一些建模方法的优点集中起来,取长补短,并建立在线建模方法将是未来发展方向之一。相信这些新方法的提出将会不断地对热误差模型的建立予以完善,使热误差建模方法将更加实用化,达到商业化应用。

参考文献:

- [1] Bryan J. International Status of Thermal Error Research [J]. CIRP Annals-Manufacturing Technology, 1990, 39 (2):645-656.
- [2] 张金标,王泾文.热挤压工艺多元非线性回归与多目标优化技术研究[J].中国机械工程,2010,21(11):1338-1341.
- [3] 叶三排.数控机床的热误差补偿技术研究[D].大连:大连理工大学,2012.
- [4] 薛冰云.主轴热误差的数值建模分析[J].机械,2009 (1):31-33.
- [5] 闫嘉钰,杨建国.灰色 GM(X,N)模型在数控机床热误差建模中的应用[J].中国机械工程,2009,20(11):1297-1300.
- [6] 李永祥.数控机床热误差建模新方法及其应用研究[D].上海:上海交通大学,2007.
- [7] 章婷,刘世豪.数控机床热误差补偿建模综述[J].机

- 床与液压,2011,39(1):122-127.
- [8] Veldhuis S C, Elbestawi M A. A strategy for compensation of errors in Five-Axis Machining[J]. Annals of CIRP, 1995, 44(1): 373-377.
- [9] Lee J, Kramer B M. Analysis of machine degradation using a Neural Network based Pattern Discrimination Model[J]. Journal of Manufacturing Systems, 1993, 38(2): 379-387.
- [10] 郭前建, 杨建国. 基于蚁群算法的机床热误差建模技术[J]. 上海交通大学学报, 2009(5): 803-806.
- [11] 陈晨, 马术文, 丁国富. 基于GA-BP网络的多轴机床热误差建模[J]. 机械科学与技术, 2013(4): 616-619, 624.
- [12] 任兵, 任小洪, 李国志. 基于PSO算法优化BP神经网络的数控机床热补偿[J]. 机床与液压, 2013(3): 59-61, 25.
- [13] Vapnik V N. Statistical learning theory[M]. New York: J. Wiley, 1998.
- [14] 邓乃扬, 田英杰. 支持向量机—理论、算法与拓展[M]. 北京: 科学出版社, 2009.
- [15] Ramesh R, Mannan M A. Thermal error measurement and modeling in machine tools (Part II): thermal errors [J]. International Journal of Machine tools & Manufacture 2000, 40: 1257-1284.
- [16] 江亮, 刘健, 潘双夏. 基于支持向量机的加工误差预测建模方法研究[J]. 组合机床与自动化加工技术, 2005(8): 13-15.
- [17] 苗恩铭, 龚亚运, 成天驹, 等. 支持向量回归机在数控加工中心热误差建模中的应用[J]. 光学精密工程, 2013, 21(4): 980-986.
- [18] 许亚洲. 基于最小二乘支持向量机的数控机床热误差建模的研究[D]. 杭州: 浙江大学, 2006.
- [19] 林伟青, 傅建中, 许亚洲, 等. 基于最小二乘支持向量机的数控机床热误差预测[J]. 浙江大学学报: 工学版, 2008, 42(6): 905-908.
- [20] 赵大泉, 张伯鹏. 主轴热误差的自组织补偿原理及其仿真[J]. 清华大学学报: 自然科学版, 2004, 44(2): 209-211.
- [21] 雷琪. 贝叶斯网络在机床热误差动态补偿建模中的应用[D]. 武汉: 华中科技大学, 2012.
- [22] Ramesh R, Manan M A, Poo A N. Error compensation in machine tool—a review (Part I): geometric, cutting-force induced and fixture dependent errors[J]. International Journal of Machine Tools & Manufacture, 2000, 40: 1235-1256.
- [23] 刘又午, 章青, 赵小松, 等. 基于多体理论模型的加工中心热误差补偿技术[J]. 机械工程学报, 2002, 38(1): 127-130.

Research about Thermal Error Compensation Modeling Method for Machine Tools

LIU Guang-lei, LIU Kang, GUO Cui-xia, LIU Xue-wen

(School of Mechanical Engineering, Sichuan University of Science & Engineering, Zigong 643000, China)

Abstract: In the research of thermal error compensation technology, robust modeling for thermal error is the key to the success of machine tool thermal error compensation. In the paper, several main thermal error modeling methods commonly used in home and abroad are analyzed and researched in depth, and their respective advantages and disadvantages are discussed. Then, some improved methods targeting at their shortcomings are introduced. Finally, the problems currently existing in the research work are pointed out and the future developments are also discussed.

Key words: machine tools; thermal error; error compensation; modeling methods