

# 基于 SOM 神经网络和复相关系数结合的机床主轴温度测点的优化筛选

王战中, 孙少华

(石家庄铁道大学 机械工程学院, 河北 石家庄 050043)

**摘要:**提出了基于 SOM 神经网络和复相关系数相结合的温度测点的优化算法, 并应用于 SV-48 立式加工中心主轴测点优化筛选。首先, 在主轴上模拟布置温度传感器和 Z 轴位移传感器, 在有限元分析的基础上得到了一系列温度和 Z 轴热位移仿真数据; 然后, 将温度数据输入到 SOM 神经网络聚类分组; 最后利用复相关程度法将聚类的温度值与主轴 Z 轴热误差拟合, 确定出机床热敏感点。研究结果表明, 该方法简明易懂, 有效减少了测温点的数量。

**关键词:**SOM 神经网络; 复相关系数; 热敏感点; 优化算法

**中图分类号:**TG502.15 **文献标志码:**A **文章编号:**2095-0373(2017)01-0095-04

## 0 引言

高精度是制造业永久的追求目标, 被称作“工作母机”的机床承担着提高加工精度的重要使命。研究表明机床主轴的热误差是影响加工精度的关键因素之一<sup>[1]</sup>。机床热误差补偿技术能将实时采集的温度和热位移数据输入到预测模型中进而预测机床误差<sup>[2]</sup>。借助温度传感器可以采集温度和热位移数据, 温度传感器布置越多越能准确的反映出机床主轴复杂的温度场变化, 但会加大热误差测量和计算量, 同时增加了投入成本; 布置太少又难以准确反映温度场的变化情况, 影响热误差补偿模型的精度, 所以, 温度传感器的布局直接影响到机床热误差补偿效率。温度测点的优化筛选是机床热误差补偿技术研究的侧重点之一<sup>[3]</sup>。常用的方法(诸如线性回归法、模糊聚类法、神经网络求偏导数法等)选取过程耗时, 并且在处理大量样本和多指标的体系时存在一定难度, 影响了补偿模型的鲁棒性。

本文通过对 SV-48 立式加工中心主轴模型的热特性分析, 在主轴模型上模拟布置温度传感器和 Z 轴位移传感器, 提出采用 SOM 神经网络对测温点样本数据聚类分组, 再利用复决定系数判决测温点与热位移间拟合度, 从各组变量中选取典型变量作为最终的热敏感点。

## 1 测点布置

测点布置, 即温度传感器和位移传感器的布置, 需要根据实际情况综合考虑。根据文献<sup>[4]</sup>提出的测点布置策略, 结合对 SV-48 立式加工中心主轴结构分析、热特性理论分析和有限元分析结果, 在机床主轴上模拟布置 12 个温度传感器(Probe 1 ~ Probe12)和 1 个 Z 轴位移传感器(Probe 13), 布置示意图见图 1。

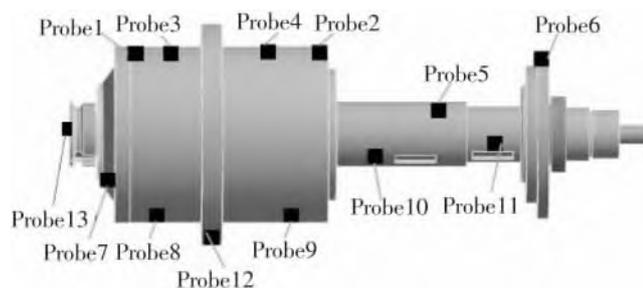


图 1 传感器布置示意图

收稿日期: 2016-01-30 责任编辑: 刘宪福 DOI: 10.13319/j.cnki.sjztdxxb.2017.01.18

作者简介: 王战中(1969-), 男, 副教授, 博士, 主要从事机器人技术与应用、数控技术及数字化制造的研究。E-mail: sjzwzz@163.com

王战中, 孙少华. 基于 SOM 神经网络和复相关系数结合的机床主轴温度测点的优化筛选[J]. 石家庄铁道大学学报: 自然科学版, 2017, 30(1): 95-98.

## 2 测温点优化筛选

借助 ANSYS Workbench 有限元分析软件,基于示意图 1 测点的布置,模拟主轴在转速 8 000 下工作 7 200 s。每隔 300 s 提取一次数据,整理各测温点和 Z 轴热位移的仿真结果分别如图 2、图 3 所示。

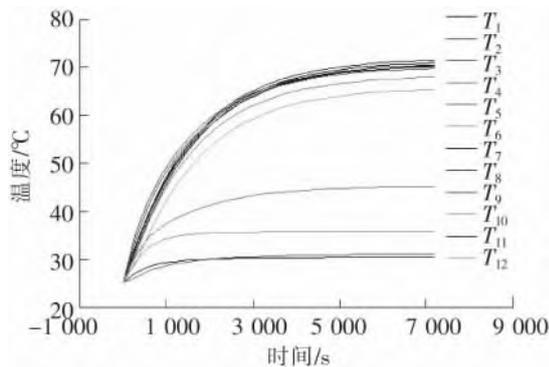


图 2 各测温点温度值仿真结果

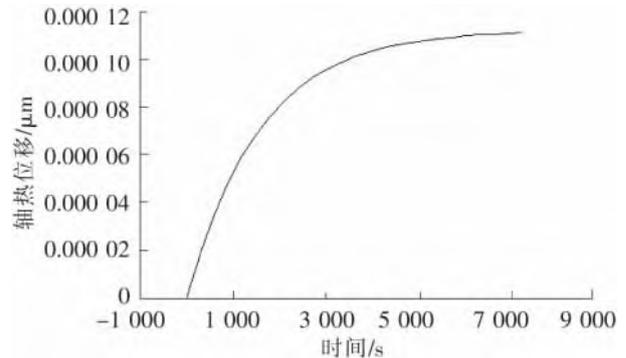


图 3 Z 轴热位移仿真结果

### 2.1 基于 SOM 神经网络的测温点的聚类分析

聚类<sup>[5]</sup>分析是直接比较各事物之间的性质,将性质相近的归为一类,将性质差别较大的归入不同的类。SOM 神经网络采用的算法属于无导师的聚类法,能将任意维数的输入模式在竞争层映射成一维或二维离散图,同时保持拓扑结构不变。其具体学习过程如下:

(1)初始化。对输出层各权向量赋小随机数并做归一化处理,得到权值  $W_j, j=1, 2, \dots, m$ ; 建立初始优胜领域  $N_{j^*}(0)$ ; 学习率  $\eta$  赋初始值。

(2)接受输入。归一化处理的对象为输入模型,该模型是从训练集中随机选取的,结果为  $X^p$ , 其中  $p \in \{1, 2, \dots, p\}$ 。

(3)寻求获胜节点计算  $X^p \cdot W_j$ , 从中选出点积最大的获胜节点。

(4)定义优胜领域  $N_{j^*}(t)$ 。以  $j^*$  为中心,确定  $t$  时刻的权值调整域,  $N_{j^*}(t)$  在训练过程中会随训练时间逐渐收缩。

(5)调整权值。对优胜邻域  $N_{j^*}(t)$  内的所有节点调整权值为公式  $w_{ij}(t+1) = w_{ij}(t) + \eta(t, N)[x_i^p - w_{ij}(t)]$ , 其中  $i=1, 2, \dots, n, j \in N_{j^*}(t)$

(6)结束检查。检查学习率是否衰减到零或某个预定的正小数。

本节聚类分析的目的就是将图 2 中  $T_1 \sim T_{12}$  的共 12 组数据分类。使用 newsom 函数创建 SOM 神经网络,其格式为 `net=newsom(PR, [D1,D2,...], TFCN, DFCN, OLR, OSTEPS, TLR, TND)`。本节中使用的 TFCN、DFCN、OLR、OSTEPS、TLR、TND 均采用缺省值。初始化 init 设置的初始化权值是自动完成的,用随机数设置输入层和竞争层之间权值的初始值。设置训练 train 次数分别为 50、100、1 000、2 000 次,便于对运算结果进行比较。

将  $T_1 \sim T_{12}$  组测温点数据从 ANSYS Workbench 中以 xls 格式导出,文件命名为 'shuju', 作为训练样本数据,输入到 SOM 神经网络中,在默认初始化权值下,对训练样本进行多次训练。测温点数据再次输入到训练好的模型中,在 sim 函数下,得到的聚类结果如表 1 所示,数值相同的为一类。

表 1 温度值聚类结果

训练次数	Probe 1	Probe 2	Probe 3	Probe 4	Probe 5	Probe 6	Probe 7	Probe 8	Probe 9	Probe 10	Probe 11	Probe 12
50	1	1	1	2	5	5	1	1	1	6	5	3
100	1	1	1	2	5	6	1	1	1	6	5	2
1 000	1	1	1	2	5	6	1	1	1	4	5	2
2 000	1	1	1	2	5	6	1	1	1	4	5	2

结果表明,当运算次数为 50、1 000、2 000 次时,聚类为 5 类;当运算次数为 100 次时,聚类为 4 类。综合实际情况,最终将温度值聚类为 5 类: $T^1=[T_1, T_2, T_3, T_7, T_8, T_9]$ ;  $T^2=[T_4, T_{12}]$ ;  $T^3=[T_5, T_{11}]$ ;  $T^4=[T_6]$ ;  $T^5=[T_{10}]$ 。

### 2.2 基于复决定系数的最优测温点的选取

聚类是将具有相似属性的测温点归为一类,而拟合则是提取具有代表性的测温点作为典型的温度变量。数据拟合度可以用复相关系数  $R$  衡量。复相关系数  $R$  反映出几个要素(自变量)与某一要素(因变量)的复相关程度。当有  $k$  个自变量时,可用式  $R_{y_1,2,\dots,k} = \sqrt{1 - (1 - r_{y_1}^2)(1 - r_{y_2,1}^2) \cdots (1 - r_{y_k,1,2,\dots,(k-1)}^2)}$  表示,其中,  $0 \leq R_{y_1,2,\dots,k} \leq 1$ 。通常在拟合分析时使用修正后的复决定系数  $R^2$  代替复相关系数  $R$ ,  $R^2$  越大,表明要素(变量)的相关程度越密切。

利用 SPSS 软件中的复相关程度法将聚类的温度值与主轴 Z 轴热误差拟合,根据拟合程度对温度值进行取舍。本节将 2.1 中的聚类结果以 EXCEL 格式保存。对  $T^1$ 、 $T^2$ 、 $T^3$  数据分别进行拟合分析,将 3 类样本得到的拟合结果与  $T^4$ 、 $T^5$  组合作为新一类样本  $T^0$  与主轴 Z 轴热误差拟合,最终得到最优测温点。SPSS 分析流程如图 4 所示。

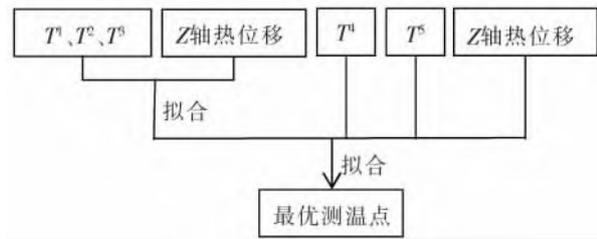


图 4 最优测温点分析流程图

以  $T^1$  类数据为例,SPSS 拟合分析过程如下所示:

使用 SPSS19.0,选择“分析”中的“回归”进行线性拟合。因变量设置为主轴 Z 轴热误差,自变量为  $T^1=[T_1, T_2, T_3, T_7, T_8, T_9]$  中的 6 组数据。线性回归方法设置为逐步回归,即每次只纳入或者移除一个变量进入模型,其他按默认设置。结果预测变量为  $T_7$ ,此时负相关系数  $R$  为 1,标准估计的误差为  $6.498\ 423\ 8 \times 10^{-8}$ 。已排除的变量如表 2 所示。

表 2 已排除的变量

模型	Beta In	t	Sig.	偏相关	共线性统计量容差
$T_1$	-1.825 <sup>a</sup>	-5.639	0.000	-0.769	$7.347 \times 10^{-7}$
$T_2$	0.002 <sup>a</sup>	0.262	0.796	0.056	0.004
$T_3$	-0.002 <sup>a</sup>	-0.082	0.935	-0.018	0.000
$T_8$	-0.760 <sup>a</sup>	-5.685	0.000	-0.771	$4.270 \times 10^{-6}$
$T_9$	0.006 <sup>a</sup>	0.573	0.572	0.121	0.002

注:预测变量为  $T_7$ ,因变量为  $Y$ 。

最终计算结果显示  $T^1$  类样本最优测温点为  $T_7$ 。对  $T^2=[T_4, T_{12}]$ 、 $T^3=[T_5, T_{11}]$  按照同样的方法计算,分别得到最优测温点  $T_4$ 、 $T_{12}$ 、 $T_{11}$ 。重新组合各类样本最优测温点,即  $T^0=[T_7, T_4, T_{12}, T_{11}, T_6, T_{10}]$ 。对  $T^0$  类数据拟合分析,得到最终优化测温点为  $T_4, T_7, T_{10}$ 。

### 3 结束语

本文依托有限元瞬态热-结构耦合分析,在主轴上模拟布置 12 个温度传感器和 1 个位移传感器,每隔 300 s 收集一次温度和位移数据,将最终得到的 12 组温度数据和 1 组 Z 轴位移数据作为样本。详细阐述了使用 SOM 神经网络聚类和复相关系数优化相结合的方法优化筛选温度测点的过程,最终将温度测点数量降到 3 组。结果表明该方法简明易懂,有效减少了测温点的数量。

### 参 考 文 献

[1] 窦小龙, 杨建国. 温度测量点优化在机床主轴热误差建模中的应用[J]. 航空精密制造技术, 2003, 39(4): 33-36.  
 [2] 张成新, 高峰, 李艳. 基于实时反馈的机床热误差在线补偿模型[J]. 中国机械工程, 2015(3): 361-364.

- [3]陈瑜婷. 数控机床热误差补偿中测温点优化研究[D]. 武汉:武汉理工大学, 2014.
- [4]黎新齐. 铣削加工中心主轴组件热特性的研究[D]. 兰州:兰州理工大学, 2008.
- [5]张建萍, 刘希玉. 基于聚类分析的 K-means 算法研究及应用[J]. 计算机应用研究, 2007, 24(5):166-168.

## Optimal Selection of Temperature Measuring Points for Spindle of Machine Tool Based on Method of Combining SOM Neural Network and Multiple Correlation Coefficient

Wang Zhanzhong, Sun Shaohua

(School of Mechanical Engineering, Shijiazhuang Tiedao University, Shijiazhuang 050043, China)

**Abstract:** A novel optimization algorithm based on method of combining the SOM neural network and multiple correlation coefficient for identifying temperature measuring points is presented, which is applied to the main spindle of SV-48 vertical machining center. Firstly, a series of temperature sensors and Z-direction displacement sensors are placed on the spindle in simulation state and a series of temperature simulation data and Z-direction thermal displacement simulation data are obtained; A series of temperature simulation data are then clustered by SOM neural network. Finally, the temperature value after clustering and the spindle Z-direction thermal error are fitted by using complex correlation method, then, the thermal sensitive points of the machine tool are determined. The result shows that the method is clear and easy to understand, and effectively reduces the number of temperature measurement points.

**Key words:** SOM neural network; multiple correlation coefficient; the thermal sensitive points; optimization algorithm

(上接第 85 页)

- [11] 侯丽娴, 杨绍普, 刘永强, 等. 基于共振解调的铁路货车轴承故障诊断[J]. 石家庄铁道大学学报:自然科学版, 2013, 26(4):47-51.
- [12] 樊永生. 机械设备诊断的现代信号处理方法[M]. 北京:国防工业出版社, 2009.

## Bearing Fault Diagnosis Based on Gabor Transform and EMD

An Xiaohong, Niu Jiangchuan, Ren Bin, Shen Yongjun, Yang Shaopu

(School of Mechanical Engineering, Shijiazhuang Tiedao University, Shijiazhuang 050043, China)

**Abstract:** Bearing fault diagnosis method based on vibration signal processing is widely used. Because in the actual acquisition of vibration signal is often mixed with other interference signals, a method of bearing fault diagnosis is proposed, which combines the blind source separation method based on Gabor transform and Hilbert envelope spectrum analysis method after empirical mode decomposition (EMD). The blind source separation method based on Gabor transform is used to separate the vibration signal. Then the intrinsic mode functions(IMF) are obtained by EMD method. And the characteristics of the bearing fault are determined by the zoom in the local Hilbert envelope spectrum analysis. The analysis results show that the fault characteristics of the signal can be more obvious, and the accuracy of fault diagnosis can be improved by blind source separation and EMD to the bearing's vibration signal.

**Key words:** fault diagnosis; blind source separation; empirical mode decomposition