

文章编号: 1001-2486 (2002) 01-0089-05

精密机床神经网络法精度建模*

王建平, 戴一帆, 洪晓丽

(国防科技大学机电工程与自动化学院, 湖南长沙 410073)

摘要: 介绍了神经网络理论在数控机床误差建模中的应用。以精密气浮花岗石铣床为研究对象, 建立了机床的精度模型, 并为此设计了一种特殊的检具, 构造了训练样本。通过神经网络精度模型对机床的定位精度进行预测。实验结果表明该方法是可行的。

关键词: 数控机床; 神经网络; 精度建模; 检具

中图分类号: TH161

文献标识码: A

Neural Network Method of Accuracy Model Building for Precision Machine Tools

WANG Jian-ping, DAI Yi-fan, HONG Xiao-li

(College of Mechatronics Engineering and Automation, National Univ. of Defense Technology, Changsha 410073, China)

Abstract: The neural network is applied for the error model building of NC machine tool. Taking a precision aerostatic granite milling machine as the research object, an accuracy model of the milling machine is established, a special gauge is designed, and a training sample is constructed as well. Positioning accuracy of the machine tool can be forecasted by the neural network accuracy model. The results show that the scheme is feasible.

Key words: NC machine tool; neural network; accuracy model building; gauge

随着我国国民经济的发展, 数控机床在机械行业中得到越来越广泛的应用, 精密、超精密技术的迅速发展, 零件加工精度的不断提高, 使得对机床的精度分析变得尤为重要。如何建立正确的机床精度模型, 对机床精度进行正确的评价, 是摆在我们面前的一个重要课题, 因为我们不仅可以依据机床本身的精度, 预测出加工零件的精度, 更重要的是我们可以通过正确的数学模型, 对机床进行误差补偿, 以提高零件加工精度。本文介绍了用神经网络法对精密三坐标机床进行精度建模的方法。

1 神经网络模型

人工神经网络是一个并行式的信息网络结构, 该网络由许多神经元组成, 每个神经元有唯一输出, 它可以连接到其他的神经元。由于神经网络在结构上模仿了人类大脑中的信息处理单元, 且具有类似人脑的记忆、学习及联想等功能, 因而在信号处理、模式识别、自动控制等领域内得到了广泛的应用。

神经网络模型有数十种, 本文采用多层感知器 (MLP) 对机床精度进行建模。其算法采用反向传播 (Back-propagation)

算法。多层感知器结构如图 1, 其中, 第一层为输入层, 第 Q 层为输出层, 中间层为隐层。设第 q 层 ($q = 1, 2, 3, \dots, Q$) 的神经元个数为 n_q , 输入到第 q 层的第 i 个神经元的连接权为 $w_{ij}^{(q)}$ ($i, j = 1, 2, 3, \dots, n_{q-1}$), 则其输入输出变换关系^[1]为:




图 1 多层感知器结构

Fig. 1 The structure of multi layer perceptron

* 收稿日期: 2001-11-02
基金项目: 国防科技重点实验室基金资助 (99JS53.6.1KG0112)
作者简介: 王建平 (1970—), 男, 硕士生。




图2 精密加工铣床
Fig.2 Precision milling machine

$$s_i^{(q)} = \sum_{j=0}^{n_q-1} W_{ij}^{(q)} x_j^{(q-1)} \quad (x_0^{(q-1)} = \theta_i^{(q)}, \quad W_{i0}^{(q)} = -1)$$

$$x_i^{(q)} = f(s_i^{(q)}) = \frac{1}{1 + e^{-ws_i^{(q)}}}$$

其中: $i = 1, 2, 3 \dots n_q, j = 1, 2, \dots n_{q-1}, q = 1, 2, 3 \dots Q, f(\cdot)$ 为 sigmoid 型非线性函数。反向传播 (Back-propagation) 算法可参阅有关神经网络的书籍。

2 机床精度模型结构

机床精度分析实质上就是建立一个数学模型,模型的输入是零件与刀具的相对位置,输出是零件与刀具相对位置的误差。对于图2所示我们自研的精密加工铣床,其精度模型与输入输出关系如图3所示。

根据 Kolmogorov^[2] 定理,我们的神经网络机床精度模型采用三层感知器结构,即一个输入层、一个隐层和一个输出层。网络的输入为刀具在零件坐标系中的坐标,我们用机床运动部件的绝对坐标表示,对精密加工铣床来说,其输入为 X 向溜板位置 x 、Y 向溜板位置 y 和 Z 向溜板位置 z 。网络的输出为刀具在零件坐标系中的定位误差 Δx 、 Δy 、 Δz 。机床精度模型神经网络的输入层和输出层神经元个数均为三个,隐层的神经元个数我们取八个。建立图4所示的 $3 \times 8 \times 3$ 的神经网络机床精度模型。

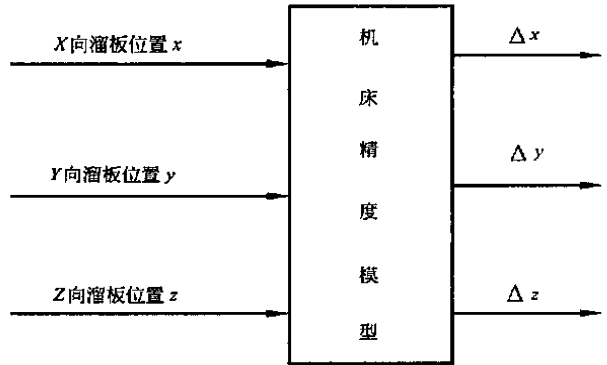


图3 精密加工铣床精度模型及输入输出关系
Fig.3 The accuracy model of the precision milling machine and the relation between input and output

3 输入输出样本的建立

3.1 检具结构

我们在神经网络机床精度模型确定后,需要用输入输出样本来训练该神经网络。且样本必须有一定的代表性,因为它决定了模型的精度与可靠性。样本是通过特殊检具进行测量得到的。因而检具的设计是整个精度建模的关键。对于检具,我们提出了以下几点基本要求:

- (1) 检具上的测量点布局要合理,能够反映设备的运动空间特征;
- (2) 检具结构简单,而且容易加工;
- (3) 检具使用方便,对操作者技能要求较低;




图4 精密加工铣床神经网络精度模型

Fig. 4 The NNT accuracy model of the precision milling machine

(4) 检具重复精度高, 稳定性好。

当然, 在上述要求中测量点布局合理是一个定性概念, 不能一味增加测量点, 因为过多的测量点会增加测量的工作量, 这与神经网络精度建模的初衷是相悖的。另外, 要求测量点在整个加工空间中均匀分布, 如果仅仅从增加检具尺寸方面考虑, 可能会与其它要求发生矛盾, 结果得不偿失。因而, 在检具设计时要充分兼顾上述要求。

根据被测机床的工作空间 ($200\text{mm} \times 200\text{mm} \times 100\text{mm}$)^[4], 我们设计了相应的检具^[3]如图5。检具包括 (a) 和 (b) 两件, (a) 由尺寸呈等差分布的 20 个台阶组成, x 轴方向台阶高为 10mm , y 轴方向台阶高为 10mm , z 轴方向台阶高为 5mm ; 检具 (b) 同样由 20 个台阶组成, y 方向台阶间隔为 10mm , x 、 z 方向上台阶高度不变, z 方向最大高度为 100mm 。检具 (a) 尺寸基本占据 $1/4$ 个机床的加工空间, 检测过程基本保证三轴作全程定位运动。由于是相对测量, 检具不需要很高的尺寸精度。

3.2 误差测量原理

我们用三个互相垂直的电感微位移传感器组成定位装置装在检具 (a) 上, 用二个互相垂直的电感微位移传感器组成定位装置装在检具 (b) 上, 传感器的分辨率为 $0.01\mu\text{m}$ 。定位装置通过测杆与精密加工铣床主轴上的刀具保持相联, 它的绝对坐标可以用机床上的刀具设定及测量装置确定。测量时首先需选择一个基准, 我们选择图 5 右边第十个台阶作为基准 (该台阶尺寸为 $100\text{mm} \times 10\text{mm} \times 100\text{mm}$), 此时检具 (a) z 方向高度为 100mm 。基准确定后, 装上检具 (a) 并调整使其 x 轴、 y 轴、

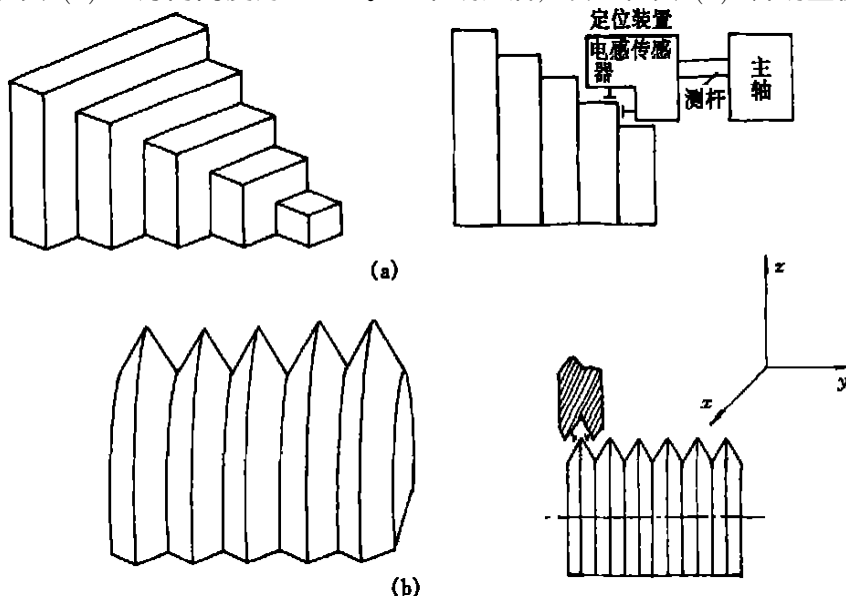


图5 检具结构与误差测量装置

Fig. 5 The gauge structure and error measuring device

z 轴分别与机床的 X 向、 Y 向和 Z 向平行, 记下定位装置定位于基准处的机床读数, 用点动进给方式分别将定位装置定位在其它各台阶边缘角处, 记下机床读数, 计算它们相对基准的相对坐标; 更换检具 (a) 和定位装置, 装上检具 (b) 并调整使其轴线与机床 Y 向平行, 安装定位装置时应保持基准的绝对坐标不变, 记下定位装置定位于基准处的机床读数, 用点动进给的方式分别将定位装置定位在其它各台阶边缘角处, 记下机床读数, 并计算它们相对基准的坐标。

通过上述测量我们得到了 (a) 图和 (b) 图中各台阶边缘角相对测量基准的坐标值。各台阶边缘角相对基准的实际尺寸可事先标定或在高一精度等级的设备上用上述方法测量, 将上述测得的数据与实际值相减就得到定位误差。

3.3 输入输出样本的构造

通过测量得到了机床在 39 个位置上的定位误差, 但如果仅仅用这些点作为样本训练神经网络, 样本数目显然不够, 其结果是神经网络的输出在这些位置上可能与样本比较接近, 而在其它位置上很可能发生畸变。其根本原因是仅仅依靠这些点不能唯一确定误差空间。因而必须利用其它条件, 构造训练样本。为了构造更多的训练样本, 先要分析各轴运动误差的影响情况:

机床 X 向是独立的, 其位置误差只和其本身有关而不受其它单元位置影响, 同时 X 向的位置也不影响 Y 向和 Z 向的位置误差。这可从该机床的龙门型对称布局中明显看出。另外假设 Y 向刚度足够高, 在全行程范围内其变形在误差允许范围内。

无论 X 向和 Z 向溜板处于什么位置上, 即对于不同的 x 和 z 值, 检具相对基准的定位误差都不会改变。

根据上述分析和合理假设, 我们可以利用 39 个测量点构造出 $20 \times 20 \times 20$ 个输入输出样本。构造方法如下:

空间一点在某固定轴轴向的定位误差, 是由该轴本身的定位误差和其它轴的耦合误差共同决定的。设某次测量时检具 (a) 边缘角 T_i 的坐标为 (x_i, y_i, z_i) , $i = 1, 2, \dots, 20$, 其定位误差分别为 Δx_{T_i} 、 Δy_{T_i} 和 Δz_{T_i} ; 检具 (b) 边缘角的坐标为 (x_{10}, y_j, z_{10}) , $j = 1, 2, \dots, 20$, 由于 x 轴向的位置误差只和其本身位置有关而与其它单元位置无关, 故 x 向的定位误差主要由机床坐标轴的垂直度偏差引起, 而 z 向定位误差则主要受到不同 y 值的影响。故对应的定位误差分别为 Δx_{g_j} 、 Δy_{c_j} 和 Δz_{g_j} 。这样, 我们可以根据所测得的定位误差计算出测量空间中点 $m(x_u, y_v, z_w)$ ($u, v, w = 1, 2, \dots, 20$) 的定位误差: 对于点 $m(x_u, y_v, z_w)$ 其 x 向的定位误差 Δx_m 为 $\Delta x_m = \Delta x_{aw} + (\Delta x_{Tu} - \Delta x_{aw})$, 其中 Δx_{aw} 是由机床坐标轴的垂直度偏差引起的误差, $\Delta x_{Tu} - \Delta x_{aw}$ 是不同的 x 值所产生的定位误差, y 向定位误差 Δy_m 为 $\Delta y_m = \Delta y_{av} + (\Delta y_{Tv} - \Delta y_{av})$, 其中 Δy_{av} 是 z 值不变时 y 向定位误差, $\Delta y_{Tv} - \Delta y_{av}$ 是 z 值改变而产生的 y 向定位误差。同理, 对于 Δz_m 有 $\Delta z_m = \Delta z_{aw} + (\Delta z_{Tw} - \Delta z_{aw})$ 。于是我们可以用下式计算测量空间中点 $m(x_u, y_v, z_w)$ ($u, v, w = 1, 2, \dots, 20$) 的定位误差:

$$\Delta x_m = \Delta x_{aw} + (\Delta x_{Tu} - \Delta x_{aw})$$

$$\Delta y_m = \Delta y_{av} + (\Delta y_{Tv} - \Delta y_{av})$$

$$\Delta z_m = \Delta z_{aw} + (\Delta z_{Tw} - \Delta z_{aw})$$

其中 $u, v, w = 1, 2, \dots, 20$

由此可以构造出整个机床加工空间中 $20 \times 20 \times 20$ 个定位误差点, 将这些点作为训练样本可以较全面地表示机床全工作空间的运动定位误差情况。

4 结论

我们用上述方法得到了 39 个测量数据, 并利用这些数据构造出 $20 \times 20 \times 20$ 个训练样本, 将它们输入到 MATLAB 软件的神经网络工具箱, 训练前面确定的三层感知器, 当网络输出误差平方和小于 0.001 时结束训练。最后得到该网络的权值和阈值分别为:

$$w^1 = \begin{bmatrix} 0.1628 & 17.7552 & -3.2154 \\ -12.8721 & 1.2856 & 2.2174 \\ 0.8695 & 2.2214 & -0.2772 \\ -0.6994 & -1.2278 & 2.3365 \\ 0.5748 & -2.2014 & -1.4408 \\ -8.2568 & 4.2637 & 2.9552 \\ 3.2778 & -6.4257 & -0.7713 \\ -0.4236 & 0.2268 & 1.3674 \end{bmatrix} \quad w^2 = \begin{bmatrix} 1.4386 & 4.2337 & -2.3342 \\ 5.2431 & -1.6635 & 0.8637 \\ -0.6542 & 2.4763 & 5.6336 \\ 2.3314 & 0.0861 & 10.1996 \\ -0.2306 & 1.2886 & -0.4662 \\ 4.5936 & -5.2784 & 1.2331 \\ 6.2993 & 2.1178 & -1.2692 \\ -0.1169 & -2.6692 & 4.2328 \end{bmatrix}^T$$

$$\theta_1 = (-4.2236 \quad -0.4432 \quad -2.9607 \quad 3.2548 \quad -2.6988 \quad 4.3265 \quad -2.1145 \quad -1.5484)^T,$$

$$\theta_2 = (-4.8776 \quad -0.3287 \quad -1.1278)^T$$

将测量空间中点的坐标 x 、 y 、 z 代入神经网络, 就能用神经网络预测出该点的定位误差 Δx 、 Δy 、 Δz 。

评价神经网络机床精度模型置信度的定量指标可由以下两个量的比值来衡量。

$$\text{RMSAL} = \frac{\left[\sum_{i=1}^n (\Delta x(i)^2 + \Delta y(i)^2 + \Delta z(i)^2) \right]^{1/2}}{n}$$

$$\text{RMSDL} = \frac{\left[\sum_{i=1}^n \left((\Delta x_m(i) - \Delta x(i))^2 + (\Delta y_{nn}(i) - \Delta y(i))^2 + (\Delta z_m(i) - \Delta z(i))^2 \right) \right]^{1/2}}{n}$$

RMSAL 为检验样本实际定位误差均方根 (root mean square); RMSDL 为神经网络预测值与真实值距离的均方根。它们的比值 RMSDL / RMSAL 越小表示神经网络的输出越接近实际值, 即模型置信度越高。我们假设由变分法模型得到的定位误差为真实值, 并在测量空间中均匀抽取 $80 \times 65 \times 50$ 个点作为检验样本, 得到:

$$\frac{\text{RMSDL}}{\text{RMSAL}} = 0.0396 < 1$$

说明神经网络精度模型在测量空间范围具有较高的置信度。所以我们得出这样的结论: 神经网络精度模型在整个测量空间中有较高的精度。

参考文献:

- [1] 孙增圻, 张再兴, 邓志东. 智能控制理论与技术[M]. 北京: 清华大学出版社, 1997.
- [2] 朱建忠. 精密、超精密机床精度分析、建模与精度控制技术研究[D]. 国防科技大学, 1997.
- [3] 李书和, 杨世民, 张奕群, 张国雄. 机床误差的快速检具[J]. 组合机床与自动化技术, 1997 (12).
- [4] 彭小强. 微小零件加工机床设计研究[D]. 国防科技大学, 2001.