

doi:10.6041/j.issn.1000-1298.2020.08.047

基于并联深度信念网络的数控机床热误差预测方法

杜柳青 余永维

(重庆理工大学机械工程学院, 重庆 400054)

摘要: 针对基于传统浅层网络理论的热误差数学模型存在适应性、鲁棒性差的问题,提出一种基于并联深度信念网络的数控机床热误差预测与补偿方法。建立一种基于3个子深度信念网络并联的深度学习预测模型,各子深度信念网络具有相同的网络结构、不同的权值参数,并共享输入层的限制玻尔兹曼机;构建基于预测误差的并联深度网络结构,确定每个RBM隐含层的神经元数量;提出初始权值共享的并联深度网络训练方法,采用对数散度无监督学习方法预训练模型中的1个深度信念网络,其他深度信念网络共享该初始权值,并用反向传播算法分别微调生成各子深度信念网络的最优权值。实验结果表明,预测的主轴热误差均方根误差为2.2 μm,在提高预测准确性的同时,显著提高了热误差补偿的适应性和鲁棒性。

关键词: 数控机床; 热误差; 预测模型; 并联深度信念网络; 深度学习

中图分类号: TG659; TH115 文献标识码: A 文章编号: 1000-1298(2020)08-0414-06 OSID: 

Thermal Error Prediction Method of CNC Machine Tools
Based on Parallel Depth Belief Network

DU Liuqing YU Yongwei

(College of Mechanical Engineering, Chongqing University of Technology, Chongqing 400054, China)

Abstract: It is difficult to establish the accurate mapping relationship between thermal error and temperature of machine tools. Aimed at the problems of adaptability and robustness of the thermal error model based on the traditional shallow network, a method of thermal error prediction and compensation based on parallel deep learning network was proposed. A deep learning prediction model based on three sub depth belief networks in parallel was established. Each sub depth belief network had the same network structure and different weight parameters. And the restricted Boltzmann machine of the input layer was shared to each sub depth belief network. A construction method of the parallel depth network structure based on prediction error was designed to determine the number of neurons in each RBM hidden layer. A parallel depth network training method based on initial weight sharing was proposed. One of the depth belief networks of the model was pre-trained based on the unsupervised learning method with logarithmic divergence. Other depth belief networks shared the initial weight. And the back-propagation algorithm was used to further adjust the optimal weights of each sub depth belief network. The experimental results showed that the root mean square error of thermal error model based on parallel deep learning network was 2.2 μm. This method improved the adaptability and robustness of thermal error compensation greatly while improving the accuracy of prediction.

Key words: numerical control machine; thermal error; prediction model; parallel depth belief network; deep learning

0 引言

热误差引起的数控机床加工误差占比达40% ~

70%^[1]。热误差具有准静态时变、非线性、衰减延迟及耦合等特征,建立机床热误差和温度之间的准确映射关系是热误差控制的难点^[2-5]。反向传

收稿日期: 2019-11-19 修回日期: 2019-12-26
基金项目: 国家自然科学基金面上项目(51775074)、重庆市重点产业共性关键技术创新重点研发项目(cstc2017zdcy-zdyfX0066、cstc2017zdcy-zdyfX0073)、重庆市技术创新与应用示范重点项目(cstc2018jszx-cydzX0144)和重庆市基础研究与前沿探索项目(cstc2018jcyyAX0352)
作者简介: 杜柳青(1975—),女,教授,博士,主要从事机床精度设计和智能制造研究,E-mail: lqdu@cqut.edu.cn

播 (Back propagation, BP) 网络^[6-7]、径向基函数 (Radial basis function, RBF) 网络^[8]、灰色系统理论^[9]等浅层网络理论建立的传统热误差模型存在以下不足:浅层模型采用人工特征,其适应性和鲁棒性不强^[10-12];浅层模型难以表征大数据下监测信号与热误差之间的映射关系,模型精度尚待提高。

针对现有技术的不足,利用深度学习强大的特征自学习和大数据建模能力^[13-19],本文提出一种基于并联深度信念网络的数控机床热误差预测与补偿方法,以自动提取数控机床温度数据深层特征,准确表征大数据下监测温度信号与热误差之间复杂的映射关系,提高热误差预测与补偿精度、实时性和鲁棒性。

1 主轴热误差预测原理

与传统方法相比,深度学习方法依靠数据驱动,能自动地从数据中提取特征(知识),对于分析非结构化、模式不明多变、热误差等大数据具有显著优势^[20-25]。

本文提出的基于并联深度信念网络的数控机床热误差预测与补偿原理如下:首先采集样本数据,在数控机床上选取热源测量点,检测热源测量点的温度 and 对应时间点的主轴热误差;建立基于并联深度信念网络的深度学习热误差预测模型;然后,实时检测数控机床热源测量点的温度,并输入到训练后的深度学习热误差预测模型,实时预测热误差;最后,将预测的热误差作为数控机床坐标系原点的补偿平移量,通过坐标系原点偏移实现热误差实时补偿(图 1)。该方法能够准确

表征大数据情况下监测温度信号与热误差之间复杂的映射关系。




图 1 数控机床热误差预测与补偿原理图

Fig. 1 Thermal error prediction and compensation principle of CNC machine tools

2 热误差预测模型

2.1 深度学习热误差预测模型

数控机床深度学习热误差预测模型由 3 个深度信念网络 (Depth belief network, DBN) DBN1、DBN2、DBN3 并联而成。3 个深度信念网络有相同的网络结构和不同的权值,并共享 1 个限制玻尔兹曼机 (Restricted Boltzmann machine, RBM),即 RBM1 层。DBN1、DBN2、DBN3 分别预测主轴在径向方向 (2 个)和轴向方向 (1 个)的热误差。建立数控机床深度学习热误差预测模型,如图 2 所示。

2.2 并联深度信念网络结构构建

每个深度信念网络均包含 1 个可视输入层、3 个限制玻尔兹曼机 RBM 隐含层 (即 RBM1、RBM2、RBM3)和 1 个输出层。

可视输入层神经元数量与设置的关键热源点数量相同;输出层神经元数量为 1,其输出为主轴在某个方向上的热误差预测值。

输出层神经元数量为 1 个,其输出分别为主轴




图 2 数控机床深度学习热误差预测模型

Fig. 2 Thermal error prediction model for deep learning of CNC machine tools

在 X 轴方向、 Y 轴方向或 Z 轴方向上的热误差。

每个 RBM 隐含层的神经元数量与热源关键点数 r 、样本数据量 N 有关。每个 RBM 隐含层的神经元初始数量 p_0 均设定为 $p_0 = r/2$, 然后以步长为 S 逐步增加, 以模型预测均方根误差最小为判断指标最终确定每个 RBM 隐含层的神经元数量, 各 DBN 隐含层神经元数量确定方法如图 3 所示。




图 3 并联深度网络隐含层神经元构建流程图
Fig. 3 Construction process of hidden layer neurons based on parallel depth network

2.3 并联深度网络训练方法

提出一种初始权值共享的并联深度网络训练方法, 首先采用对数散度无监督学习方法, 预训练模型中的其中一个深度信念网络 DBN1, 获得其网络初始权值, 深度信念网络 DBN2、DBN3 共享该初始权值。深度信念网络对数散度无监督学习方法如图 4 所示。




图 4 并联深度信念网络训练流程图
Fig. 4 Training process of parallel depth belief network

- (1) 将 DBN 的每一层神经元随机初始化为 0 或 1, 不同层之间的神经元连接权值 $w_{ij} (i = 1, 2, \dots; j = 1, 2, \dots)$ 置为 (0, 1) 范围的任意值。首先预训练 RBM1。
- (2) 利用温度样本数据由可视层神经元 v_i 算出隐含层神经元 h_j , 则连接权值 w_{ij} 的正向梯度为 $H_{ij} =$

- $v_i h_j$ 。
- (3) 由隐含层神经元 h_j 反向计算得到的可视层神经元为 v'_i , 则连接权值的反向梯度为 $H'_{ij} = v'_i h_j$ 。
- (4) 更新连接权值: $w_{ij} = w_{ij} + \varepsilon (H_{ij} - H'_{ij})$, 其中 ε 为学习速率, 一般设定为 0 ~ 1。
- (5) 利用采集的温度样本数据循环训练 RBM1 网络, 不停迭代, 直到收敛, 即 $L_{ij} - L'_{ij} \leq \delta$, L_{ij} 、 L'_{ij} 为似然函数值, δ 为一极小收敛阈值, 一般设定为小于 0.01。

- (6) 同样方法, 依次预训练 RBM2 和 RBM3 的连接权值。
- (7) 将训练完成的 DBN1 参数对应赋值给 DBN2、DBN3, 实现初始权值共享。
- 然后, 采用 BP 算法分别微调生成 3 个深度信念网络的最优权值。利用标签数据反向修正预训练获得的初始权值; 然后, 正向测试新得到的各层权值参数; 如此反复, 直到模型预测的均方根误差 E 收敛为止。

均方根误差 E 收敛判别式为

$$\frac{E(t-1) - E(t)}{E(t-1)} \leq \lambda$$

(1)

式中 t ——训练次数
 λ ——极小阈值, 一般设定为小于 0.01

3 实验与结果分析

3.1 数据采集

实验以 XHA6120 型动梁式大型龙门五面加工中心为研究对象。根据该龙门加工中心的结构、工况及热源分布, 将热源关键点设置在机床发热较集中部位或其附近, 采用 18 个温度传感器检测温度, 温度关键点编号为 $T_1 \sim T_{18}$ 。

测量龙门加工中心主轴在径向方向和轴向方向的 3 个热误差: e_x 、 e_y 、 e_z 。测量方法如图 5 所示。采用德国米依公司 ES-U1 型电涡流传感器, 其量程为 1 mm, 分辨率为 0.02 μm , 线性度为 $\pm 1\%$, 能够满足本实验的精度要求。




图 5 龙门加工中心主轴热误差测量方式
Fig. 5 Measurement method of thermal error

模拟龙门加工中心连续循环加工状态、主轴旋转、进给轴移动、冷却液循环, 每隔 5 min 记录一次各温度传感器的数值和主轴位移传感器的数值, 共采集 150 组温度及热误差作为样本数据。将 150 组

样本数据归一化,用于深度学习预测模型的训练和验证,计算式为

$$a'_i = \frac{a_i - a_{\min}}{a_{\max} - a_{\min}} \tag{2}$$

式中 a'_i ——各样本数据归一化后的值
 a_i ——各样本数据原始值
 $a_{\max}$ ——各类型样本数据的最大值
 $a_{\min}$ ——各类型样本数据的最小值

3.2 模型结构确定及训练

可视输入层神经元数量与设置的关键热源点数量相同,均为 18 个。DBN1 的输出为主轴在 X 轴方向上的热误差;DBN2 的输出为主轴在 Y 轴方向上的热误差;DBN3 的输出为主轴在 Z 轴方向上的热误差。

每个 RBM 隐含层的神经元数量对模型的预测精度和泛化能力影响较大。神经元数量过少会造成温度特征信息的丢失,导致特征提取不完整,预测精度低。增加神经元数量,预测精度会提高,但神经元数量过多会造成模型的泛化能力差。RBM 隐含层的神经元数量确定步骤为:

(1)根据热源关键点数 $r=18$ 和采集的样本数据量 $L=150$,先设定每个 RBM 隐含层的神经元初始数量均为 $p_0=\lfloor r/2 \rfloor$,该式含义为取 $r/2$ 的整数部分。 p_0 为初始值 9 时,计算得到的均方根误差为 0.102。

(2)保持 RBM2 和 RBM3 隐含层的神经元数量固定不变,以步长 $S=2$ 逐渐增加 RBM1 隐含层的神经元数量 p_1 。当 $p_1=21$ 时,模型预测的均方根误差达到最小值 0.025,将 $p_1=21$ 确定为 RBM1 隐含层的神经元数量。




图 6 热误差预测及补偿
Fig.6 Prediction and compensation of thermal error

该龙门加工中心主轴在 X 、 Y 、 Z 3 个方向上的热误差分别为 e_x 、 e_y 、 e_z ,将此作为机床坐标系原点的补偿平移量,机床坐标系原点在 X 、 Y 、 Z 轴 3 个方向上分别平移 $-e_x$ 、 $-e_y$ 、 $-e_z$,补偿后的 X 、 Y 、 Z 方向的最大残差分别为 2.5、3.0、2.5 μm ,表明本文方法能够实现机床热误差的高精度补偿。

利用该龙门数控机床数据样本构建传统支持向量机 (Support vector machine, SVM) 预测模型和 BP

(3)同理,在确定 RBM2 的时候,RBM1 的神经元数量固定在 21,RBM3 的神经元数量固定在 9,最终确定 RBM2 的神经元数量为 21。在确定 RBM3 的时候,RBM1 的神经元数量固定在 21,RBM2 的神经元数量固定在 21,最终确定 RBM3 的神经元数量为 19。

采用对数散度无监督学习方法,首先预训练 RBM1,学习速率 ε 设定为 0.1,迭代收敛阈值设定为 0.005,经 990 次迭代后完成预训练。同理,分别经 860 次和 1 100 次迭代后完成对 RBM2 和 RBM3 的预训练。将训练完成的 DBN1 参数对应赋值给 DBN2、DBN3,实现初始权值共享。

用标签样本数据、采用 BP 算法分别微调生成 3 个深度信念网络的最优权值。均方根误差 E 的收敛阈值 λ 设为 0.005,微调学习速率设为 0.1。3 个深度信念网络分别经 35、46、39 次迭代后完成权值微调,此时 3 个并联的深度信念网络的预测均方根误差分别为 0.01、0.015、0.012。

经过上述预训练和调优后,预测模型构建完成,各模型参数成功获得。然后将实时检测的一系列温度输入预测模型,用来预测对应的主轴热误差值。

3.3 实验结果分析

实时测量 28 组该龙门加工中心关键热源点温度,输入该深度学习预测网络预测主轴热误差,获得了高精度的热误差预测结果,如图 6 所示。模型预测的热误差均方根误差为 2.2 μm ,平均绝对百分比误差为 7.8%,实时数据预测与训练样本数据预测的性能指标基本一致,说明深度学习热误差预测模型具有非常好的泛化能力。

神经网络预测模型。对比实验中,SVM 预测模型和 BP 神经网络预测模型的 X 、 Y 、 Z 方向热误差预测效果如图 7 所示,二者的均方根误差分别为 4.9、5.3 μm ,平均绝对百分比误差分别为 22%、33%,二者的预测准确性均远低于本文方法,本文提出的深度层次结构能够比浅层网络更准确提取出蕴含在温度数据中的本质特征信息,所以本文方法的预测精度比传统方法更高,鲁棒性更好。




图7 SVM模型和BP模型的主轴热误差预测结果

Fig. 7 Thermal error prediction based on SVM model and BP model

4 结论

(1)提出一种基于3个子深度信念网络并联的深度预测模型,设计的各子深度信念网络采取共享网络结构与初始权值的策略,大大提高了模型训练的效率。

(2)基于并联深度信念网络的主轴热误差预测与补偿方法能够自动提取数控机床温度数据深层特

征,准确建立热误差与数控机床温度测点的非线性映射关系,实现了热误差状态的智能预测与补偿。

(3)并联深度信念网络预测模型解决了传统浅层网络方法预测精度不高、鲁棒性差等问题,实验获得主轴热误差预测值的均方根误差为 $2.2\ \mu\text{m}$,优于传统的SVM和BP预测方法。本文方法在提高预测准确性的同时,显著提高了热误差补偿的适应性和鲁棒性。

参考文献

- [1] PEKLENNIK J, JERELE A. Some basic relationships for identification of the machining process[J]. CIRP Annals, 1992, 41(1): 155 - 159.
- [2] YANG Zhiyong, SUN Minglu, LIANG Wenyong, et al. Modified Elman network for thermal deformation compensation modeling in machine tools[J]. International Journal of Advanced Manufacturing Technology, 2011, 54(5 - 8): 669 - 676.
- [3] GUO Qianjian, YANG Jianguo. Application of projection pursuit regression to thermal error modeling of a CNC machine tool[J]. International Journal of Advanced Manufacturing Technology, 2011, 55(5 - 8): 623 - 629.
- [4] 杜柳青, 王承辉, 余永维, 等. 基于深度自编码器的大型龙门加工中心热误差建模方法[J/OL]. 农业机械学报, 2019, 50(4): 395 - 400.
DU Liuqing, WANG Chenghui, YU Yongwei, et al. Thermal error modeling method based on stacked auto-encoder for large gantry five-sided machining center[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(4): 395 - 400. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20191046&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2019.10.046. (in Chinese)
- [5] 褚宁, 张为民. 基于张量理论的数控机床误差补偿模型[J/OL]. 农业机械学报, 2017, 48(10): 408 - 416.
CHU Ning, ZHANG Weimin. Error compensation model of CNC machine-tool based on tensor theory[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(10): 408 - 416. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20171052&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2017.10.052. (in Chinese)
- [6] LU Yuxia, ISLAM M N. A new approach to thermally induced volumetric error compensation[J]. International Journal of Advanced Manufacturing Technology, 2012, 62(9 - 12): 1071 - 1085.
- [7] YANG J, SHI H, FENG B, et al. Applying neural network based on fuzzy cluster pre-processing to thermal error modeling for coordinate boring machine[J]. Procedia CIRP, 2014, 17(1): 698 - 703.
- [8] MIZE C D, ZIEGERT J C. Neural network thermal error compensation of a machining center[J]. Precision Engineering, 2000, 24(4): 338 - 346.
- [9] 张毅, 杨建国. 基于灰色理论预处理的神经网络机床热误差建模[J]. 机械工程学报, 2011, 47(7): 134 - 139.
ZHANG Yi, YANG Jianguo. Modeling for machine tool thermal error based on grey model preprocessing neural network[J]. Journal of Mechanical Engineering, 2011, 47(7): 134 - 139. (in Chinese)
- [10] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion[J]. Journal of Machine Learning Research, 2010, 11(12): 3371 - 3408.
- [11] BENGIO Y. Learning deep architectures for AI[J]. Foundations and Trends in Machine Learning, 2009, 2(1): 1 - 127.
- [12] 江雪梅, 陶媛媛, 姜平, 等. 数控机床热误差预测模型的评估方法[J]. 计算机集成制造系统, 2019, 25(1): 81 - 89.
JIANG Xuemei, TAO Yuanyuan, LOU Ping, et al. Evaluation method for thermal error prediction models of computer numerical control machine tools[J]. Computer Integrated Manufacturing Systems, 2019, 25(1): 81 - 89. (in Chinese)
- [13] 余永维, 殷国富, 殷鹰, 等. 基于深度学习网络的射线图像缺陷识别方法[J]. 仪器仪表学报, 2014, 35(9): 2012 - 2019.
YU Yongwei, YIN Guofu, YIN Ying, et al. Defect recognition for radio graphic image based on deep learning network[J].

- Chinese Journal of Scientific Instrument, 2014, 35(9): 2012 – 2019. (in Chinese)
- [14] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504 – 507.
- [15] 余永维, 杜柳青. 基于深度学习特征匹配的铸件微小缺陷自动定位方法[J]. 仪器仪表学报, 2016, 37(6): 1364 – 1370. YU Yongwei, DU Liuqing. Automatic location of casting small defect based on deep learning feature[J]. Chinese Journal of Scientific Instrument, 2016, 37(6): 1364 – 1370. (in Chinese)
- [16] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735 – 1780.
- [17] GERS F A, SCHMIDHUBER J. Learning to forget: continual prediction with LSTM[J]. Neural Computation, 2000, 12(10): 2451 – 2471.
- [18] 冯海林, 胡明越, 杨垠晖, 等. 基于树木整体图像和集成迁移学习的树种识别[J/OL]. 农业机械学报, 2019, 50(8): 235 – 242, 279. FENG Hailin, HU Mingyue, YANG Yinhui, et al. Tree species recognition based on overall tree image and ensemble of transfer learning[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(8): 235 – 242, 279. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20190825&journal_id=jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2019. 08. 025. (in Chinese)
- [19] 余永维, 杜柳青. 深度学习框架下数控机床运动误差溯源方法[J]. 仪器仪表学报, 2019, 40(1): 28 – 34. YU Yongwei, DU Liuqing. Motion error tracing of NC machine tools based on deep learning framework[J]. Chinese Journal of Scientific Instrument, 2019, 40(1): 28 – 34. (in Chinese)
- [20] 高云, 郭继亮, 黎煊, 等. 基于深度学习的群猪图像实例分割方法[J/OL]. 农业机械学报, 2019, 50(4): 179 – 187. GAO Yun, GUO Jiliang, LI Xuan, et al. Instance-level segmentation method for group pig images based on deep learning[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(4): 179 – 187. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20190420&journal_id=jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2019. 04. 020. (in Chinese)
- [21] 熊俊涛, 戴森鑫, 区炯洪, 等. 基于深度学习的大豆生长期叶片缺素症状检测方法[J/OL]. 农业机械学报, 2020, 51(1): 195 – 202. XIONG Juntao, DAI Senxin, OU Jionghong, et al. Leaf deficiency symptoms detection method of soybean based on deep learning[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(1): 195 – 202. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20200121&flag=1. DOI: 10. 6041/j. issn. 1000-1298. 2020. 01. 021. (in Chinese)
- [22] 李庆旭, 王巧华, 顾伟, 等. 基于深度学习的种鸭蛋孵化早期受精信息无损检测[J/OL]. 农业机械学报, 2020, 51(1): 189 – 194. LI Qingxu, WANG Qiaohua, GU Wei, et al. Non-destructive testing of early fertilization information in duck egg laying based on deep learning[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(1): 189 – 194. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20200120&flag=1. DOI: 10. 6041/j. issn. 1000-1298. 2020. 01. 020. (in Chinese)
- [23] 祝诗平, 卓佳鑫, 黄华, 等. 基于 CNN 的小麦籽粒完整性图像检测系统[J/OL]. 农业机械学报, 2020, 51(5): 36 – 42. ZHU Shiping, ZHUO Jiaxin, HUANG Hua, et al. Wheat grain integrity image detection system based on CNN[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(5): 36 – 42. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20200504&flag=1. DOI: 10. 6041/j. issn. 1000-1298. 2020. 05. 004. (in Chinese)
- [24] VINYALS O, TOSHEV A, BENGIO S, et al. Show and tell: lessons learned from the 2015 MSCOCO image captioning challenge[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2016, 39(4): 652 – 663.
- [25] XIANG Y, MOTTAGHI R, SAVARESE S. Beyond PASCAL: a benchmark for 3D object detection in the wild[C]// IEEE Winter Conference on Applications of Computer Vision (WACV). IEEE Computer Society, 2014: 75 – 82.