doi:10.6041/j.issn.1000-1298.2019.10.046

基于深度自编码器的大型龙门加工中心热误差建模方法

杜柳青　王承辉　余永维　徐　李
(重庆理工大学机械工程学院, 重庆 400054)

摘要: 为提高热误差模型的预测能力,提出一种基于深度学习方法的数控机床热误差建模方法。利用模糊聚类法和灰色关联度分析法选取温度变量的热敏感点,采用深度自编码器(Stacked automatic encoder, SAE)网络从选出的输入样本中提取特征,构建特征集,然后使用遗传优化算法(Genetic optimization algorithm, GA)对 BP 神经网络参数进行寻优,从而提出一种基于 SAE - GA - BP 的数控机床热误差建模方法。以某大型龙门五面加工中心为实验对象,研究并选择了加工中心加工过程中的主要误差源——主轴热误差进行补偿,对主轴热误差深度学习模型和多元回归模型进行了分析对比。结果表明,在预测精度方面所提出的建模方法优于传统多元回归模型,从而验证了该建模方法的可行性和有效性。

关键词: 大型龙门五面加工中心; 热误差建模; 特征提取; 深度学习
中图分类号: TH115　　**文献标识码**: A　　**文章编号**: 1000-1298(2019)10-0395-06

Thermal Error Modeling Method Based on Stacked Auto-encoder for Large Gantry Five-sided Machining Center

DU Liuqing　WANG Chenghui　YU Yongwei　XU Li
(*College of Mechanical Engineering*, *Chongqing University of Technology*, *Chongqing* 400054, *China*)

Abstract: A thermal error modeling method of NC machine tools based on deep learning method was proposed in order to improve the prediction ability of thermal error model. Fuzzy clustering method and grey relationship analysis method were used to select the sensitive points of temperature variables and the stacked automatic encoder (SAE) network was used to extract the features of the temperature variables from the selected input samples to construct the feature sets. Then, genetic optimization algorithm (GA) was used to optimize BP neural network parameters so as to propose a thermal error modeling method based on SAE - GA - BP neural network for NC machine tools. Taking a large gantry five-sided machining center as the experimental object, the spindle thermal error of the large gantry five-sided machining center was studied and selected as the main error source to achieve compensation in the machining process. The deep learning model of main shaft thermal error was compared with the multiple regression model. The experimental results showed that the proposed modeling method was better than the traditional multiple regression model in prediction accuracy of the thermal error of NC machine tools, which verified the feasibility and effectiveness of the proposed thermal error modeling method.

Key words: large gantry five-sided machining center; thermal error modeling; feature extraction; deep learning

0　引言

热误差及几何误差是机床各种误差源中最主要的误差,高端数控机床 40% ~70% 的误差由热变形引起[1]。热误差已经成为影响零件加工精度的主要误差来源。建立可以准确描述机床热变形状态的模型是进行热误差补偿的基础和决定性因素。已有研究通常采用多元线性回归模型、有限元模型、最小

收稿日期: 2019-03-03　修回日期: 2019-04-24
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)和重庆市基础研究与前沿探索项目(cstc2018jcyjAX0352)
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

二乘支持向量机、支持向量机[2-3]、灰色理论[4]和神经网络模型[5]等建模方法。王秀山等[6]建立的多元线性回归模型可补偿 40% 左右的热误差;李永祥[7]利用灰色系统理论提出一种热关键点优化选择的方法,并研究了热误差的智能预测模型。该模型建模过程简单、计算量小,适用于贫乏信息、小批量、任意分布的样本数据的热误差建模。余文利等[8]采用偏最小二乘法(Partial least squares, PLS)构建输入样本的特征集,并用改进的粒子群优化算法(Improved particle swam optimization, IPSO)对核心向量回归机(Core vector regression, CVR)进行模型参数的寻优,从而提出一种基于 PLS - IPSO - CVR 的数控机床热误差建模方法,该方法在预测精度和速度方面优于传统的 SVR 模型和 BP 神经网络模型。余永维等[9]提出一种基于时序深度学习网络的数控机床运动精度建模方法,通过自动提取时空特征,挖掘时间序列前后关联信息,以实现对机床误差的预测,其最大相对误差不大于 7.96%,优于 ARMA 时序方法和 BP 网络预测方法。

热误差具有时变、非线性和耦合的特点,不同的工况会导致机床不同的温度分布模式和不同的热误差。传统方法如核主成分分析、多尺度变换法等只适合服从高斯分布和服从线性分布的特定数据集,且在提取特征时需依靠现场经验和专业知识,限制了特征集的表达;为提高模型的精确度,常在机床关键位置布置大量温度传感器,导致相邻测点的输出信号具有较大的多重相关性[3]。因此,热误差预测是一个高维、大样本问题。高维数据会产生维数灾难,会造成建模的拟合效果良好、而预测效果差的现象;同时传统方法建立的模型会因环境和季节的变化而表现出很强的阶段性效应,尤其是在样本量较少的情况下,难以满足热误差模型的鲁棒性要求,在一定程度上制约了热误差补偿技术的实施。

深度学习由于深度特征的挖掘能力而受到广泛关注。为解决模型的非线性、小样本和维数灾难等问题,本文将深度学习引入机床热误差建模,通过采集足够数量的样本,利用数据重构进行温度特征的提取。

1 热误差建模原理

热误差模型的原理如图 1 所示,首先将温度数值进行归一化处理,通过温度测点优化筛选出与主轴 3 个方向热误差相关性较大的测点。然后将关键温度测点的数值作为自变量输入到堆叠自编码器神经网络中,提取出温度的相应特征。最后将该温度特征作为自变量,相应的热误差作为因变量输入 GA - BP 神经网络训练并进行热误差预测。

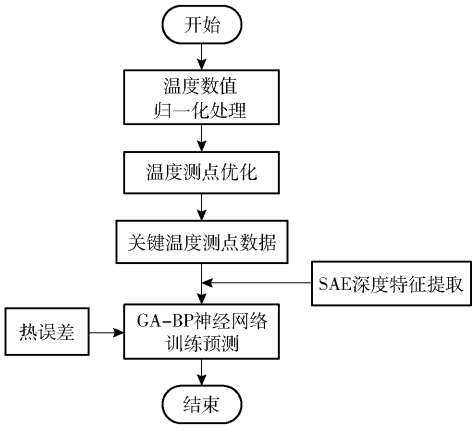

图 1 热误差模型原理图

Fig. 1 Schematic of thermal error model

2 基于 SAE 的温度数据特征挖掘

2.1 自动编码器网络特征提取原理

自动编码器(Auto-encoder, AE)[10]是一种尽可能重构输入信号的 3 层无监督学习神经网络,利用贪婪逐层训练算法初始化网络权重,并使用 BP 反向传播算法微调网络参数,优化整体性能,其结构如图 2 所示。

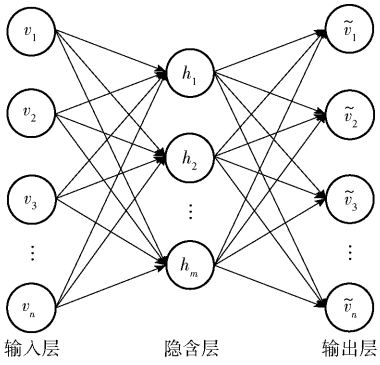

图 2 自动编码器结构图

Fig. 2 Structure chart of auto-encoder

自动编码器的输入数据和输出目标相同,包含编码器和解码器两部分,有 1 个输入层、1 个隐含层和 1 个输出层。由于输出层可对输入数据进行重构,因此编码矢量称为输入数据的一种特征表示[11]。

假设输入样本集 $\boldsymbol{v}=(v_1,v_2,\cdots,v_n)$,编码器定义的编码函数为 f_θ,解码器定义的重构函数为 $g_{\theta'}$。先使用编码函数 f_θ 将每个训练样本 v_i 转换为隐含层矢量,即

$$\boldsymbol{h}=f_\theta(\boldsymbol{v})=s(\boldsymbol{W}\boldsymbol{v}+\boldsymbol{b}) \tag{1}$$

式中 s——sigmoid 激活函数

$\boldsymbol{W}$——输入层到隐含层的权值矩阵

$\boldsymbol{b}$——偏置系数

然后再通过解码网络将隐藏层矢量用解码函数进行重构，得到 $\tilde{\boldsymbol{v}}$ 为

$$\tilde{\boldsymbol{v}} = g_{\theta'}(\boldsymbol{h}) = s(\boldsymbol{W}'h + \boldsymbol{b}') \tag{2}$$

式中　$\boldsymbol{W}'$——隐含层到输出层的权值矩阵

$\boldsymbol{b}'$——偏置系数

AE 算法通过网络训练寻找最优的参数矩阵，最小化输出数据与输入数据的误差。因此，需要构建误差损失函数用于网络训练，误差损失函数为

$$L = \sum_{i=1}^{m} \| \boldsymbol{v} - \tilde{\boldsymbol{v}} \|^2 \tag{3}$$

式中　i——样本序号

m——样本总数量

AE 利用梯度下降算法调整网络权值，经过多次迭代使得重构误差 L 在训练样本集的过程中尽可能降到最小，最终实现输出向量 $\tilde{\boldsymbol{v}}$ 约等于输入向量 $\boldsymbol{v}$。

2.2　深度自编码器的网络构建及特征挖掘

深度自编码器是由多个浅层自编码器堆叠形成的深度神经网络，可以逐层地学习数据特征[12]。其网络层数越多，提取的特征也就越抽象[13]。在构建该网络模型中，SAE 结构的隐含层数和节点数是自动编码器模型的重要参数。模型的输入层节点个数为 4，对应的期望输出节点个数为 4。分别设置不同过程的神经元隐含层节点个数和隐含层层数，比较重构误差，确定其网络结构。由表 1 可知，当 SAE 深度隐含层数增加到一定限度时，重构误差不再减小，反而增加。由表1 可知，当选择节点为4－3－2－3－4 的结构时，即将自编码器堆叠形成堆叠自编码器，此时数据的重构误差最小，表示输入数据已被很好地编码。

表 1　不同网络结构的重构误差比较

Tab. 1　Comparison of reconfiguration errors for different network structures

网络结构	重构误差		
	X 方向	*Y* 方向	*Z* 方向
4－3－2－4	0.008 4	0.008 1	0.008 4
4－3－2－3－4	0.008 8	0.002 4	0.008 0
4－2－4－2－4	0.013 2	0.011 7	0.012 0
4－5－6－5－4	0.018 0	0.032 5	0.015 8
4－6－10－6－4	0.048 1	0.093 3	0.069 0
4－10－20－10－4	0.025 1	0.046 6	0.021 3

2.3　深度自编码器网络训练及参数优化

深度学习一般包括逐层预训练和微调两个阶段。根据表 1 的结构，先选择所采集的数据进行预训练。在预训练阶段，每层作为一个自编码器进行训练，其目标是最小化重构误差。在每一层进行特征提取，提取的隐含层作为下一个隐含层的输入。当所有的层预训练完成时，神经网络进入微调阶段。在该阶段，对整个神经网络进行反向传播使得预测误差最小化，图 3 为具有 4 个隐含层的堆叠自编码器的结构图。其中，神经网络的学习参数设置如表 2 所示。堆叠自编码器的训练过程如图 4 所示。

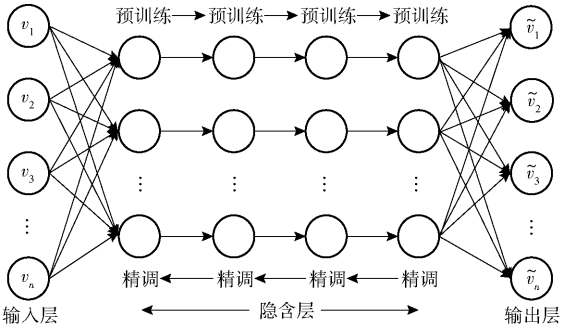

图 3　具有 4 个隐含层的堆叠自编码器结构图

Fig. 3　Structure chart of stacked auto-encoders with four hidden layers

表 2　网络学习参数设置

Tab. 2　Network learning parameters settings

参数	批量大小	学习速率	迭代次数	稀疏标准	动量值
数值	50	2	900	0.05	0.5

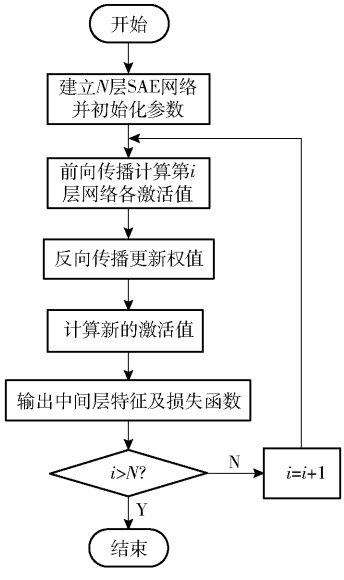

图 4　堆叠自编码器网络的训练过程

Fig. 4　Training process of stacked auto-encoder network

3　基于 GA 的 BP 网络优化及热误差预测

BP 网络是基于梯度的算法[14]，存在收敛速度慢、容易陷入局部极值点和网络结构不易确定等缺点[15]，而 GA 具有全局寻优、能自动获取搜索空间等优点[16－18]，可利用 GA 的优点对 BP 网络的拓扑结构、权值、阈值和初始值进行优化，以加快 BP 网络的收敛速度并提高预测精度。建模步骤如下：

(1)确定网络的输入与输出。将归一化处理后的关键点温度与主轴热误差分别作为网络的输入和输出。网络输入节点和输出节点分别设置为 4 和 1。

(2)应用 GA 优化 BP 网络。优化 BP 网络的结构,确定采用 3 层 BP 神经网络作为预测模型。然后对种群的进化次数、规模、交叉概率、变异概率等进行初始化,对种群进行实数编码,并将预测输出与期望输出之间误差平方的倒数作为适应度函数;在进化搜索时,遗传算法将适应度函数作为依据,通过执行选择、交叉和变异操作计算搜索个体适应度,然后找出当前最优适应度的个体,反复迭代直至满足条件。

(3)GA-BP 网络预测。当 GA 确定了 BP 网络的拓扑结构、初始值、阈值、权值后,利用样本数据对 BP 网络进行训练,得到最优预测模型,预测主轴热误差。通过分析结果的均方根误差和平均绝对百分比误差评价模型性能。

4 实验分析与建模

4.1 实验

主轴空运转下的热学特性(温升、热态几何精度等)是衡量机床质量的标准[19],同时为便于采集实验数据,在实验中机床处于空运转状态。实验时,机床从冷态开始运行。热机 30 min 后进行数据采集,并作为数据记录的时间零点,每隔 5 min 采集一次数据,中午暂停 1 h,下午继续采集数据。实验共得到 360 组数据。

如图 5 所示,温度和主轴热误差的采集平台为某国产龙门五面加工中心。采集所需硬件包括温度传感器、温度变送器、数据采集卡、便携式计算机和位移传感器等。其中,PT100 型温度传感器具有精度高的优点,用于测量加工中心关键点的温度变化。温度通过温度传感器再经过温度变送器和数据采集卡输送到计算机中;位移传感器用于测量加工中心主轴各方向的热误差。



图 5 大型龙门五面加工中心

Fig. 5 Large gantry five-sided machining center

通过分析加工中心的热源,温度传感器布置如表 3 所示。

表 3 加工中心温度传感器布置

Tab. 3 Temperature sensor arrangement of machining center

温度传感器布置部位	温度传感器序号
立柱部位	电机 T1;轴承座 T2、T3;导轨 T4、T5;螺母座 T6
横梁部位	电机 T7;轴承座 T8、T9;导轨 T10、T11;丝杠螺母 T12
滑枕部位	电机 T13;电机轴承座 T14;导轨 T15
主轴箱部位	电机 T16;主动箱上下轴承座 T17、T18
主轴法兰	T19
环境温度	T20

4.2 温度敏感点的选择

机床热误差由许多温度变量相互作用产生,合理地优化温度传感器测点是热误差建模中的一个重要问题,直接影响模型精度和鲁棒性。合理地选择温度测点,以最少的温度测点代替众多温度测点的同时又能较为准确地进行热误差建模是关键。通过对大型龙门五面加工中心的分析,采用模糊聚类分析[20]与灰色关联度[21]相结合的方法来选择温度关键测点,即先将各测点之间的温度数据通过聚类分析进行聚类,最后在各类测点中选取具有代表性的测点作为热误差建模所用变量。经计算,与主轴 X 方向具有较强相关度的温度传感器为 T2、T11、T14 和 T18;与主轴 Y 方向具有较强相关度的温度传感器为 T4、T5、T8 和 T15;与主轴 Z 方向具有较强相关度的温度传感器为 T5、T6、T7 和 T12。

4.3 热误差建模

为便于建模,设计了热误差建模系统,并将本文提出的深度学习建模方法与传统的多元回归模型进行比较。模型预测结果界面如图 6 所示。

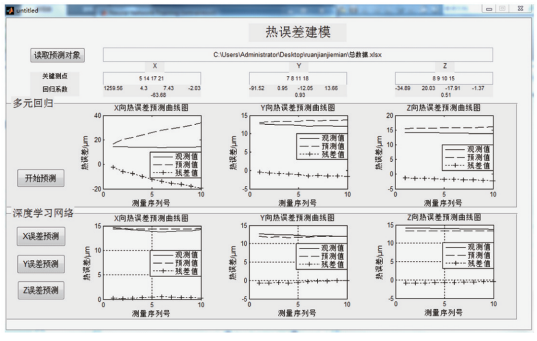

图 6 热误差建模与预测界面

Fig. 6 Interface of thermal error modeling and prediction

首先读取预测文件,数据文件的前 3 列分别为 X、Y、Z 方向的热误差数据,从第 4 列起为所测得的温度,然后根据之前筛选得到的关键测点进行热误

差预测。

4.4　模型精度分析

图 7、8 为两种模型分别在 X、Y、Z 3 个方向上的预测曲线。实验结果表明，所提出的建模方法有较高的预测精度，优于传统多元回归模型等方法。实验时，多元回归模型的最大误差可达 20 μm，深度学习模型的预测误差范围在 1 μm 以内。采用均方根误差（Root mean square error，RMSE）和平均绝对百分比误差（Mean absolute percentage error，MAPE）对模型的预测准确度进行评价，评价结果如表 4 所示。

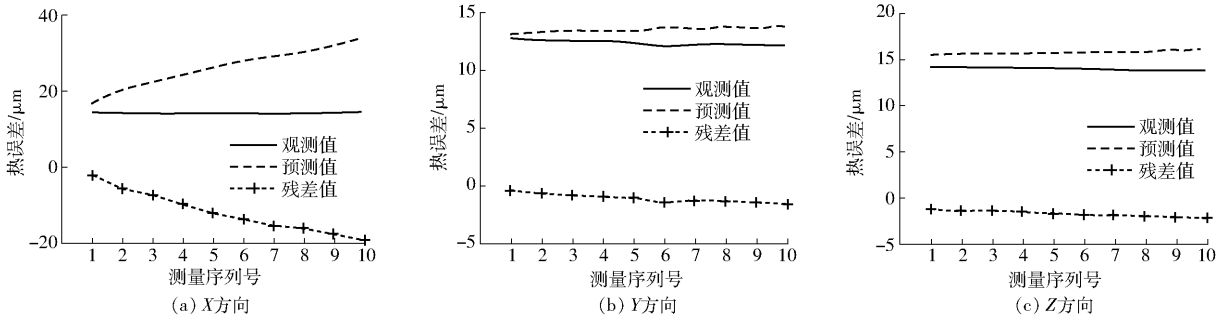

图 7　多元回归模型的热误差预测曲线

Fig. 7　Thermal error prediction curves of multivariate regression model

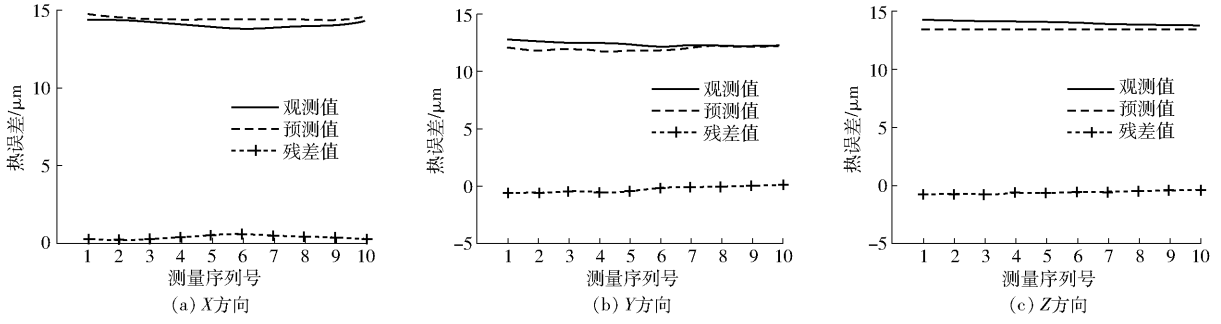

图 8　深度学习模型的热误差预测曲线

Fig. 8　Thermal error prediction curves of deep learning model

表 4　预测结果评价

Tab. 4　Evaluation of prediction results

模型	参数	X 方向	Y 方向	Z 方向
多元回归	RMSE/μm	13.19	1.21	1.80
	MAPE/%	86.25	9.40	12.70
深度学习	RMSE/μm	0.36	0.48	0.69
	MAPE/%	2.29	3.42	5.07

多元回归方法虽然计算量小，便于实现，但不能反映热误差的非线性特征，预测精度低。从图 7、8 及表 4 可看出，基于 SAE－GA－BP 的热误差模型与实际测得的热误差吻合情况较好，由此可见，该方法预测精度高，能够有效估计机床的热误差变化趋势。

综上所述，基于 SAE－GA－BP 的热误差模型的整体预测精度比传统的多元回归模型具有明显的优势，能有效弥补现有模型的局限性。

5　结论

（1）基于 SAE－GA－BP 的热误差建模方法可以应用于数控机床热误差建模和预测。

（2）通过对输入变量的特征提取和 GA－BP 神经网络算法选择最优参数后建立的模型对加工中心主轴热误差的预测值与实际值吻合程度较高，该方法预测精度高，与多元回归模型相比，更适合用于数控机床热误差建模。

参　考　文　献

[1] BRYAN J. International status of thermal error research[J]. Annals of the CIRP,1990,9(2):645－656.

[2] RAMESH R,MANNAN M A,POO A N. Support vector machines model for classification of thermal error in machine tools[J]. International Journal of Advanced Manufacturing Technology,2002,20(2):114－120.

[3] RAMESH R,MANNAN M A,POO A N, et al. Thermal error measurement and modeling in machine tools. part II. hybrid Bayesian network-support vector machine model[J]. International Journal of Machine Tools & Manufacture,2003,43(4):405－419.

[4] WANG K C. The grey-based artificial intelligence modeling of thermal error for machine tools[J]. Journal of Grey System,2010,22(4):353－366.

[5] 傅建中，陈子辰. 精密机械热动态误差模糊神经网络建模研究[J]. 浙江大学学报（工学版），2004，38(6)：742－746.

FU Jianzhong, CHEN Zichen. Research on modeling thermal dynamic errors of precision machine based on fuzzy logic and artifical neural network[J]. Journal of Zhejiang University(Engineering Edition), 2004, 38(6): 742 - 746. (in Chinese)

[6] 王秀山,杨建国,余永昌,等. 双转台五轴数控机床热误差建模、检测及补偿实验研究[J]. 中国机械工程,2009,20(4): 405 - 408.
WANG Xiushan, YANG Jianguo, YU Yongchang, et al. Research on thermal error modeling, measurement and compensation for the two turntable 5-axis NC machine tools[J]. China Mechanical Engineering, 2009, 20(4): 405 - 408. (in Chinese)

[7] 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.
LI Yongxiang. New methods of thermal error modeling for NC machine tools and their researchment and application[D]. Shanghai: Shanghai Jiaotong University, 2007. (in Chinese)

[8] 余文利,姚鑫骅,孙磊,等. 基于 PLS 和改进 CVR 的数控机床热误差建模[J/OL]. 农业机械学报,2015,46(2): 357 - 364.
YU Wenli, YAO Xinhua, SUN Lei, et al. Thermal error modeling of CNC machine tool based on partial least squares and improved core vector regression[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(2): 357 - 364. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? file_no = 20150253&flag = 1. DOI: 10.6041/j.issn.1000-1298.2015.02.053. (in Chinese)

[9] 余永维,杜柳青,易小波,等. 基于时序深度学习的数控机床运动精度预测方法[J/OL]. 农业机械学报,2019,50(1): 421 - 426.
YU Yongwei, DU Liuqing, YI Xiaobo, et al. Prediction method of NC machine tools' motion precision based on sequential deep learning[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(1): 421 - 426. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? file_no = 20190149&flag = 1. DOI: 10.6041/j.issn.1000-1298.2019.01.049. (in Chinese)

[10] HINTON G E, ZEMEL R S. Autoencoders, minimum description length, and Helmholtz free energy[M]. COWAN J, TESAURO G, ALSPECTOR J. Advances in neural information processing systems. 6th edition. San Mateo: Morgan Kaufman Publishers, 1994: 3 - 10.

[11] 时培明,梁凯,赵娜,等. 基于深度学习特征提取和粒子群支持向量机状态识别的齿轮智能故障诊断[J]. 中国机械工程,2017,28(9): 1056 - 1061,1068.
SHI Peiming, LIANG Kai, ZHAO Na, et al. Intelligent fault diagnosis for gears based on deep learning feature extraction and particle swarm optimization SVM state indentification[J]. China Mechanical Engineering, 2017, 28(9): 1056 - 1061, 1068. (in Chinese)

[12] 邓烜堃,万良,黄娜娜. 基于 DAE - BP 神经网络的股票预测研究[J]. 计算机工程与应用,2019,55(3): 126 - 132.
DENG Xuankun, WAN Liang, HUANG Nana. Stock prediction research based on DAE - BP neural network [J]. Computer Engineering and Applications, 2019, 55(3): 126 - 132. (in Chinese)

[13] WANG Y, CAI W D, WEI P C. A deep learning approach for detecting malicious JavaScript code [J]. Security & Communication Networks, 2016, 9(11): 1520 - 1534.

[14] JIN W, LI Z J, LI Z, WEI L S, et al. The improvements of BP neural network learning algorithm[C]// Proceedings of the 5th International Conference on Signal Processing. Washington, D.C., USA, IEEE, 2000: 1647 - 1649.

[15] SADEGHI B H M. A BP-neural network predictor model for plastic injection molding process[J]. Journal of Materials Processing Technology, 2000, 103(3): 411 - 416.

[16] GEN M, CHENG R. Genetic algorithms and engineering optimization[M]. New York: Wiley-Interscience, 1999.

[17] SCHAFFER J D. Multiple objective optimization with vector evaluated genetic algorithms[C]// Proceedings of an International Conference on Genetic Algorithms, Pittsburgh, PA., 1995.

[18] FONSECA C M, FLEMING P J. Genetic algorithms for multi-objective optimization: formulation, discussion and generalization [C]// Proceedings of the 5th International Conference Genetic Algorithm, San Mateo, USA, 1993: 416 - 423.

[19] RAMESH R, MANNAN M A, POO A N. Error compensation in machine tools-a review. part Ⅱ. thermal errors[J]. International Journal of Machine Tools and Manufacture, 2000, 40(9): 1257 - 1284.

[20] 王桂祥. 模糊数理论及应用[M]. 北京:国防工业出版社,2011.

[21] 刘思峰,杨英杰,吴利丰,等. 灰色系统理论及其应用[M]. 7 版. 北京:科学出版社,2017.