

基于遗传BP神经网络的磁流变悬置模型辨识

邓召学, 郑玲, 郭敏敏, 张自伟

(重庆大学机械传动国家重点实验室 重庆 沙坪坝区 400030)

【摘要】为克服误差逆向传播算法的多层前馈型BP神经网络收敛速度慢、局部极小化问题,提出用遗传算法(GA)的全局搜索能力寻求最优的BP神经网络权值和阈值,以提高神经网络的收敛速度和克服局部最优。以磁流变液压悬置动态特性试验结果为数据样本,分别用未优化的BP神经网络和优化后的GA-BP神经网络对磁流变液压悬置正、逆模型进行辨识。结果表明,相对于BP神经网络,GA-BP神经网络具有更高的辨识精度、更快的收敛速度,在磁流变液压悬置数学模型辨识方面具备更优的性能。

关键词 BP神经网络; 遗传算法; 磁流变悬置; 模型辨识

中图分类号 U463.1

文献标志码 A

doi:10.3969/j.issn.1001-0548.2014.06.028

Model Identification of Magneto-Rheological Mount Based on Genetic Algorithms and BP Neural Network

DENG Zhao-xue, ZHENG Ling, GUO Min-min, and ZHANG Zi-wei

(State Key Laboratory of Mechanical Transmission, Chongqing University Shapingba Chongqing 400030)

Abstract Initial weights and thresholds of BP neural network are optimized by using Genetic Algorithm(GA) method to solve its slow convergence speed and local optimum. The defect of BP neural network is thus overcome by the proposed method. The direct and inverse dynamic models for a prototype of Magneto-rheological (MR) mount are identified by using traditional BP neural network and novel GA-BP neural network. The results show that the GA-BP neural network has faster convergence rate and higher precision compared with the traditional BP neural network in the identification of direct and inverse model for MR mount.

Key words BP neural network; genetic algorithm; magneto-rheological mount; model identification

磁流变悬置是以磁流变液为载体构成的发动机隔振装置,在外磁场作用下,由于磁流变液体粘度急剧变化,导致磁流变悬置阻尼力在一个较大的范围内改变^[1],磁流变悬置为实现发动机的有效宽频隔振提供了重要手段^[2]。

建立能较好体现非线性和滞回特性的磁流变液压悬置正、逆力学模型,是实现发动机磁流变悬置系统精确控制的前提条件^[3]。目前,常用模型辨识方法主要分为参数化模型和非参数化模型两大类^[4]。在参数化模型中,Bingham模型可方便地计算阻尼力与位移之间的函数关系,模型简单便于求逆,但是,低速下的阻尼力与速度的非线性辨识精度较低^[5-7]。文献[8]对非线性双粘性模型进行了改进,提出了具有4个参数的非线性滞回双粘性模型,但磁流变阻尼器低速区特性仍然难以描述。针对这一问题,文献[9]提出利用现象模型拟合磁流变阻尼器低速时的恢

复力衰减现象,但模型参数较多,数学计算较为复杂。

神经网络能够以任意精度逼近非线性连续函数,能够通过学习自动寻找输入与输出之间的‘合理规则’,具有较高的泛化和容错能力。神经网络^[10]是非参数化模型中最具发展前景的高精度辨识方法之一。文献[11]采用模糊自适应理论方法对磁流变阻尼器力学模型进行了辨识,该力学模型体现了阻尼器的滞回特性,但是由于模型参数数量较多、模型结构相对复杂导致易出现维数灾难。文献[12]提出了自适应神经-模糊推理系统(ANFIS)模型来描述MR阻尼器的力学行为。该模型包括一个神经模糊部分和一个模糊逻辑部分,其中,神经模糊部分描述速度和位移对阻尼力的影响,模糊部分描述控制电压与阻尼力的关系,该模型很好地描述磁流变阻尼器的非线性,且精度较高,但模糊逻辑部分的规则较难确定。文献[13]利用递归神经网络(RNN)对磁流变

收稿日期: 2013-06-18; 修回日期: 2014-03-16

基金项目: 中央高校基本科研业务费(CDJZR13280074)

作者简介: 邓召学(1985-),男,博士,主要从事汽车振动与控制方面的研究。

阻尼器建模，RNN网络以内部状态反馈来描述磁流变阻尼器的非线性特征，但因网络结构复杂，存在训练算法收敛速度慢的问题。文献[14]采用BP神经网络对磁流变阻尼器进行了模型辨识，神经网络阻尼力预测值的辨识精度高，由于未考虑神经网络初始权值、阈值的对BP神经网络预测精度的影响，导致预测网络出现收敛速度慢、局部极小化问题。

前馈型BP神经网络可以实现对复杂非线性的映射功能，具有自学习能力，通过误差反向传播来不断调整网络的权值和阈值，提高网络的预测精度；基于以上优点，本文提出用遗传算法(GA)的全局搜索能力寻求最优的BP神经网络权值和阈值，以提高神经网络的收敛速度和克服局部最优，以磁流变液压悬置动态特性试验结果为数据样本对磁流变液压悬置力学模型进行辨识。

1 GA-BP神经网络模型

1.1 BP神经网络算法

BP神经网络的拓扑结构如图1所示，包括输入层、隐含层、输出层。 X_1, X_2, \dots, X_n 是BP神经网络的输入，输入个数为 n ； Y_1, Y_2, \dots, Y_m 是BP神经网络的输出，输出个数为 m ； b_k, a_j 分别为神经网络输出层、隐含层阈值； ω_{ij} 为输入层与隐含层间连接权值； ω_{jk} 为隐含层与输出层间连接权值。神经网络具有高度的非线性映射能力可看成一个非线性连续函数^[15]。BP神经网络算法的具体过程包含以下内容：




图1 BP神经网络拓扑结构图

1) 隐含层表达式

根据输入向量 \mathbf{X} ，连接权值 ω_{ij} 和阈值 a_j ，计算隐含层输出为：

$$H_j = f\left(\sum_{i=1}^n \omega_{ij}x_i - a_j\right) \quad j=1,2,\dots,l \quad (1)$$

式中， l 为隐含层节点数； f 为隐含层激励函数，该函数为：

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

2) 输出层表达式

根据隐含层输出 H_j 、连接权值 ω_{jk} 和阈值 b_k ，可以得到网络预测输出为：

$$O_k = \sum_{j=1}^l H_j \omega_{jk} - a_k f \quad k=1,2,\dots,m \quad (3)$$

3) 误差计算

根据网络预测输出 O_k 和期望输出 Y_k ，计算网络预测误差为：

$$e_k = Y_k - O_k \quad (4)$$

4) 权值、阈值更新

根据网络预测误差 e_k 更新网络预测权值 ω_{ij} 、 ω_{jk} 和网络节点阈值 a_j, b_k ，有：

$$\omega_{ij} = \omega_{ij} + \eta H_j (1 - H_j) x(i) \sum_{k=1}^m \omega_{jk} e_k \quad (5)$$

$$\omega_{jk} = \omega_{jk} + \eta H_j e_k \quad (6)$$

$$a_j = a_j + \eta H_j (1 - H_j) x(i) \sum_{k=1}^m \omega_{jk} e_k \quad (7)$$

$$b_k = b_k + e_k \quad (8)$$

式中， η 为学习速率。

1.2 GA-BP神经网络模型

遗传算法是模拟生物遗传和进化过程而建立起来的一种全局寻优算法，具有较强的鲁棒性和全局搜索能力^[16]。本文利用遗传算法优化BP神经网络的初始连接权值和阈值，来改善神经网络的性能。

图2所示为GA-BP神经网络的算法流程，包括遗传算法极值寻优和BP神经网络预测两部分。遗传算法极值寻优主要是对神经网络初始权值和阈值进行编码，以BP神经网络辨识误差为适应度值进行寻优；BP神经网络预测部分首先包含神经网络的拓扑结构，以遗传算法得出的初始权值和阈值进行神经网络预测，通过权值更新和迭代最终得到预测结果。

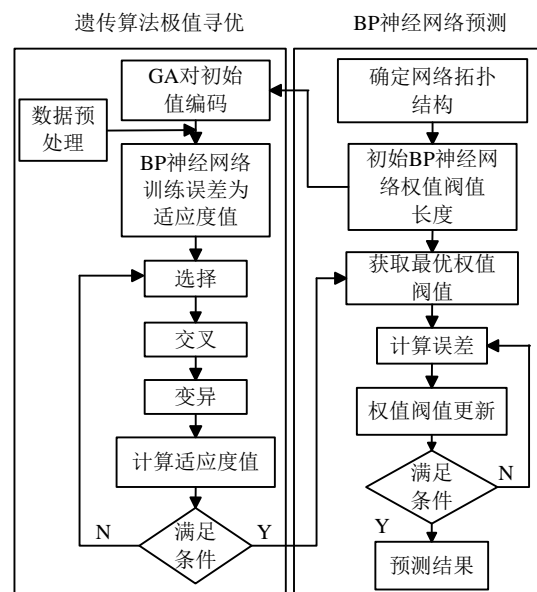


图2 算法流程

2 磁流变悬置GA-BP网络模型辨识

采用重庆中意减振器厂的CRIMS电液伺服试验台对流动模式的磁流变液压悬置进行动态特性试验, 激振峰峰值为1 mm, 激振频率为1~50 Hz, 间隔为1 Hz, 激励电流为0~1 A, 间隔为0.25 A, 试验现场如图3所示。



图3 磁流变悬置动态特性测试试验台

2.1 GA-BP神经网络正模型

图4所示为磁流变悬置GA-BP神经网络正模型辨识框图, 正模型的辨识神经网络输入变量分别为前一时刻的位移 s_{k-1} 和当前时刻的位移 s_k , 前一时刻的电流 I_{k-1} 和当前时刻的电流 I_k , 前一时刻的激振频率 f_{k-1} 和当前时刻的激振频率 f_k , 前一时刻的阻尼力 F_{k-1} ; 正模型神经网络输出变量为当前时刻的阻尼力 F_k 。




图4 磁流变悬置GA-BP神经网络正模型辨识框图




图5 GA适应度值进化曲线

神经网络结构为7-5-1, 共有40个权值、6个阈值。取初始化参数为: 种群规模30、最大迭代次数30、交叉概率0.7、变异概率0.01。图5所示为GA适应度

值进化曲线, 其最小适应度为10.75。图6所示为GA-BP神经网络预测结果。表1和表2所示分别为GA-BP神经网络正模型结构阈值和权值的优化结果。




图6 GA-BP神经网络预测输出阻尼力

表1 最优权值

输入输出节点编号	隐含层节点				
	1	2	3	4	5
Input_1	1.77	-0.04	-0.87	1.65	-1.58
Input_2	2.07	1.89	2.08	-0.78	-0.70
Input_3	2.17	-0.22	0.42	1.17	2.77
Input_4	0.28	0.82	0.43	2.56	2.18
Input_5	-1.98	-1.93	-1.54	0.59	-1.81
Input_6	-2.19	2.19	-1.89	0.93	-1.53
Input_7	-0.94	0.02	-2.65	-2.43	2.05
Output_1	0.74	-2.84	-1.09	0.19	-1.04

表2 最优阈值

	1	2	3	4	5
隐含层节点	0.29	-2.01	-0.04	0.21	-1.80
输出层节点	0.64				




图7 BP神经网络正模型预测误差




图8 GA-BP神经网络正模型预测误差

利用遗传算法优化BP神经网络后，结合磁流变悬置性能试验数据，对GA-BP神经网络正模型进行训练。其中随机选取3 600组数据作为训练样本，选取3 600组数据作为辨识精度测试样本，仿真得到BP神经网络与GA-BP神经网络正模型的预测输出力误差，分别如图7、图8所示。

从图7、图8中看出，相对于BP神经网络，GA-BP神经网络具有更高的预测精度。为了更好地体现预测能力的差别，比较两者在不同电流时预测误差的均方根值，如表3所示。

表3 神经网络不同电流时的预测结果

电流 /A	BP神经网络平均相对误差/(%)	BP神经网络误差标准差	GA-BP神经网络平均相对误差/(%)	GA-BP神经网络误差标准差
0	2.13	5.731 4	0.67	1.299 3
0.25	1.88	7.970 5	0.47	2.021 6
0.50	1.45	7.482 8	0.44	2.393 3
0.75	1.42	7.033 9	0.48	2.454 7
1.00	1.20	6.853 2	0.48	2.661 5

由表3可知，GA-BP神经网络平均相对误差最大为0.67%，预测误差的标准差最大为2.661 5；BP神经网络的平均相对误差最大为2.13%，预测误差的标准差最大为7.970 5。对比可知，相对于BP神经网络，GA-BP神经网络具有更小的辨识误差准。




图9 BP神经网络正模型训练均方误差收敛曲线




图10 GA-BP神经网络正模型训练均方误差收敛曲线

如图9所示，BP神经网络正模型当训练次数达到20左右时，网络训练均方误差为0.008，不再随训

练次数的增加而变化，并未达到训练目标值0.001，显然BP神经网络正模型已陷入局部最优。由图10可知，GA-BP神经网络训练次数为10时就已达到训练目标值0.001。通过对比可知GA-BP神经网络不仅有效地避免了BP神经网络的局部最优，而且训练速度也有提高。

2.2 GA-BP神经网络逆模型

图 11 所示为磁流变悬置 GA-BP 网络逆模型辨识框图，辨识神经网络输入变量分别为前一时刻的位移 s_{k-1} 和当前时刻的位移 s_k ，前一时刻的激振频率 f_{k-1} 和当前时刻的激振频率 f_k ，前一时刻的阻力力 F_{k-1} 和当前时刻的阻力力 F_k ，前一时刻的电流 I_{k-1} ；逆模型神经网络输出变量为当前时刻的阻力力 I_k 。




图11 磁流变悬置GA-BP神经网络逆模型辨识框图

图12所示为GA适应度值进化曲线，收敛时对应的最小适应度为 2.723×10^{-3} 。图13所示为GA-BP神经网络预测结果。表4和表5所示分别为GA-BP神经网络逆模型阈值和权值的优化结果。




图12 GA适应度值进化曲线




图13 GA-BP神经网络预测输出电流

表4 最优权值

输入输出 节点编号	隐含层节点				
	1	2	3	4	5
Input_1	-2.46	2.46	-2.13	1.05	-1.72
Input_2	-1.05	0.03	-2.98	-2.73	2.29
Input_3	-2.58	0.57	-0.96	2.49	0.98
Input_4	-1.35	-0.62	-2.06	1.49	-2.78
Input_5	2.87	0.03	0.99	0.24	-0.37
Input_6	-0.60	-1.64	-1.05	0.86	1.35
Input_7	-1.98	-1.98	-1.54	0.59	-1.80
Output_1	0.73	-2.84	-1.09	0.19	-1.04

表5 最优阈值

	1	2	3	4	5
隐含层节点	-0.36	-1.71	-0.84	1.12	1.63
输出层节点	-1.14				

利用遗传算法优化BP神经网络后, 结合磁流变悬置性能试验数据对GA-BP神经网络逆模型进行训练。BP神经网络与GA-BP神经网络逆模型的预测电流误差如图14、图15所示。




图14 BP网络逆模型预测误差




图15 GA-BP网络逆模型预测误差

从图中看出, 相对于BP神经网络, GA-BP神经网络逆模型具有更高的预测精度。

为了评价GA-BP神经网络逆模型的逼近精度, 建立如下的指标^[17]:

$$E_i = 1 - \frac{\sum_{q=1}^n |I - \hat{I}|}{n \max(|\hat{I}|)} \quad (9)$$

式中, E_i 为神经网络的辨识精度; I 为试验电流; \hat{I} 为逆模型辨识输出电流; n 为试验数据样本容量。

根据式(9)可以得到不同电流下的相对逼近精度。表6所示为不同电流下的相对逼近精度。可以看出, 相对于BP神经网络逆模型, GA-BP神经网络逆模型的逼近精度更高。

表6 神经网络逆模型逼近精度

网络模型	I/A			
	0.25	0.50	0.75	1.00
EI(BP)/(%)	98.8	97.9	96.3	98.5
EI(GA-BP)/(%)	99.8	99.5	99.7	99.8

由图16可知, 磁流变悬置BP神经网络逆模型当训练次数达到50左右时, 网络训练均方误差值为 9.6×10^{-5} , 基本达到训练目标值 1×10^{-4} , BP神经网络逆模型未陷入局部最优, 这也说明神经网络辨识精度与网络初始连接权值与阈值有较大的关系。由图17可知, GA-BP神经网络训练次数为14时就已达到训练目标值 1×10^{-4} 。通过对比可知, GA-BP神经网络在训练速度明显快于BP神经网络。




图16 BP网络逆模型训练均方误差收敛曲线




图17 GA-BP网络逆模型训练均方误差收敛曲线

3 总结

本文将遗传算法与BP神经网络相融合, 对磁流变悬置正、逆模型进行辨识。针对BP网络初始连接权值与阈值的随机选取造成的网络易陷入局部收敛、误差较大、训练速度慢等缺陷, 利用遗传算法

的全局搜索能力寻求最优的BP神经网络权值和阈值,以磁流变悬置动态性能试验结果为神经网络的训练数据,分别采用BP神经网络、GA-BP神经网络对磁流变液压悬置进行模型辨识,研究结果表明:

1) BP神经网络正模型陷入局部最优而BP神经网络逆模型未陷入局部最优,表明并非所有的BP神经网络都会出现局部最优的问题,这与网络的初始连接权值与阈值选取有直接关系;

2) GA-BP神经网络正(逆)模型相对于BP神经网络正(逆)模型,均未出现局部最优问题,表明GA算法通过优化网络连接初始权值和阈值可以有效地避免网络陷入局部最优;优化前后正(逆)模型辨识误差对比表明,GA算法可以有效地提高BP神经网络的辨识精度;

3) 均方误差收敛曲线表明,GA-BP神经网络正(逆)模型较之BP神经网络正(逆)模型具有更快的训练速度。

磁流变液压悬置GA-BP神经网络正、逆模型具有更高的辨识精度和更快的收敛速度,为磁流变悬置应用于系统的振动控制奠定了基础。

参 考 文 献

- [1] KOO J H, GONCALVES F D, AHMADIAN M. A comprehensive analysis of the response time of MR dampers[J]. *Smart Materials and Structures*, 2006, 15(2): 351-358.
- [2] NGUYEN C C. The performance of an adaptive magnetorheological fluid mount[C]//*Proceedings of the ASME International Mechanical Engineering Congress and Exposition*. Seattle, USA: ASME, 2008: 261-268.
- [3] SAVARESI S M. Identification of semi-physical and black-box non-linear models: The case of MR-dampers for vehicles control[J]. *Automatica*, 2005, 41(1): 113-127.
- [4] BOADA M J L, CALVO J A. Modeling of a magnetorheological damper by recursive lazy learning[J]. *International Journal of Non-Linear Mechanics*, 2011(46): 479-485.
- [5] HMADKHANDLOU F, MAHBOOB M. An improved model for magnetorheological fluid-based actuators and sensors[J]. *Journal of Intelligent Material Systems and Structures*, 2010, 21(1): 3-18.
- [6] HONG S R, WERELEY N M, CHOI Y T, et al. Analytical and experimental validation of a nondimensional Bingham model for mixed-mode magnetorheological dampers[J]. *Journal of Sound and Vibration*, 2008, 312(3): 399-417.
- [7] 周强, 瞿伟廉. 磁流变阻尼器的两种力学模型和试验验证[J]. *地震工程与工程振动*, 2002, 22(4): 144-150.
ZHOU Qiang, QU Wei-lian. Two mechanic models for magnetorheological damper and corresponding test verification[J]. *Earthquake Engineering and Engineering Vibration*, 2002, 22(4): 144-150.
- [8] WERELEY N, PANG L. Nondimensional analysis of semi-active electrorheological and magnetorheological dampers using approximate parallel plate models[J]. *Smart Materials and Structures*, 1998(7): 732-743.
- [9] WANG Xiao-jie, GORDANINEJAD F. A new magnetorheological fluid-elastomer mount: Phenomenological modeling and experimental study[J]. *Smart Materials and Structures*, 2009, 18(9): 130-138.
- [10] DU H, LAM J, ZHANG N. Modelling of a magnetorheological damper by evolving radial basis function networks[J]. *Engineering Applications of Artificial Intelligence*, 2006, 19(8): 869-881.
- [11] SCHURTER K, ROSCHKE P N. Fuzzy modeling of a magnetorheological damper using anfis[C]//*The Ninth IEEE International Conference Fuzzy Systems*. San Antonio, USA: IEEE, 2000.
- [12] AHN K K, TROUNG D Q, ISLAM M A. Modeling of a magnetorheological (MR) fluid damper using a self tuning fuzzy mechanism[J]. *Journal of Mechanical Science and Technology*, 2009(23): 1485-1499.
- [13] WANG D H, LIAO W H. Neural network modeling and controllers for magnetorheological fluid dampers[C]//*The 10th IEEE International Conference on Fuzzy Systems*. Melbourne, Australia: IEEE, 2001.
- [14] 王修勇, 宋璨. 磁流变阻尼器的性能试验与神经网络建模[J]. *振动与冲击*, 2009, 28(4): 42-46.
WANG Xiu-yong, SONG Can. Test of a MR damper and its modeling using neural network[J]. *Journal of Vibration and Shock*, 2009, 28(4): 42-46.
- [15] 孙志强, 葛哲学. 神经网络理论与MATLAB7实现[M]. 北京: 科学出版社, 2005.
SUN Zhi-qiang, GE Zhe-xue. *Neural network theory and realization of MATLAB7*[M]. Beijing: Science Press, 2005.
- [16] 陈国良, 王煦法. 遗传算法及其应用[M]. 北京: 人民邮电出版社, 2001.
CHEN Guo-liang, WANG Xu-fa. *Genetic algorithm and its application*[M]. Beijing: Posts and Telecom Press, 2001.
- [17] 王昊, 胡海岩. 磁流变阻尼器的模糊逼近[J]. *振动工程学报*, 2006, 19(1): 31-36.
WANG Hao, HU Hai-yan. The fuzzy approximation of MR damper[J]. *Journal of Vibration Engineering*, 2006, 19(1): 31-36.

编辑 黄 莘