

基于改进型 RBF 神经网络的磁流变阻尼器 动力学建模及仿真

周 勇¹, 冯志敏¹, 刘小锋¹, 周 航², 胡 敏¹

(1. 宁波大学 海运学院, 浙江宁波 315211; 2. 中国科学技术大学 网络空间安全学院, 合肥 230001)

摘 要: 为提高磁流变阻尼器 (MRD) 动力学精度, 提出一种网络连接权值自适应调整的改进型 RBF 神经网络模型。利用与任一测试样本相邻的两个训练样本对应的实际连接权值, 对测试样本连接权值进行线性插值, 提出连接权值的自适应算法; 搭建 MRD 动力试验平台, 进行多频率、多振幅的动力性能试验, 利用大量实测力学特性数据, 建立 RBF 神经网络模型以及连接权值自适应调整的改进型 RBF 神经网络模型, 分析比较 RBF 神经网络模型在改进前后的平均累计相对误差变化规律, 并进行数值仿真计算和试验测试分析。研究表明, 在正弦激励频率 0.25 Hz ~ 1.0 Hz、振幅 5 mm ~ 15 mm、电流 0 ~ 1.25 A 工况下, 相比于传统 RBF 神经网络模型 5% 的最大误差均值, 改进型 RBF 神经网络模型使建模误差均值多控制在 0.45% ~ 0.85% 之间, 有效改善 MRD 的动力学特性, 建模精度较好满足工程实际需要。

关键词: RBF 神经网络; 磁流变阻尼器; 动力学模型; 线性插值; 连接权值

中图分类号: TH703.62 **文献标志码:** A **【DOI】** 10.13788/j.cnki.cbge.2019.04.16

Dynamic Modeling and Simulation of Magneto-rheological Damper Based on Improved RBF Neural Network

ZHOU Yong¹, FENG Zhimin¹, LIU Xiaofeng¹, ZHOU Hang², HU Min¹

(1. Faculty of Maritime and Transportation, Ningbo University, Zhejiang Ningbo 315211, China; 2. School of Cyberspace Security, University of Science and Technology of China, Hefei 230001, China)

Abstract: In order to improve the dynamic accuracy of magneto-rheological fluid shock absorber (MRD), an improved RBF neural network model with adaptive weights adjustment is proposed. Linear interpolation of test sample connection weights is performed by using the actual connection weights corresponding to two training samples adjacent to a test sample, the adaptive algorithm for the linear interpolation of the test samples is put forward, the dynamic test platform of MRD is built, the dynamic performance test of multi frequency and multi amplitude is carried out, and a large number of measured mechanical properties data are used to establish the RBF neural network model. The modified RBF neural network model with adaptive adjustment of connection weights is used to analyze and compare the average cumulative relative error changes of the RBF neural network model before and after the improvement, and carry out numerical simulation calculation and test analysis. The study shows that, under the condition of sinusoidal excitation frequency 0.25 Hz~1.0 Hz, amplitude 5 mm~15 mm and current 0~1.25 A, compared to the maximum error mean of the traditional RBF neural network model 5%, the improved RBF neural network model makes the mean of modeling error control between 0.45%~0.85%, effectively improving the dynamic mechanical properties of MRD, and the precision of modeling satisfies the project better.

收稿日期: 2018-09-12; 修回日期: 2018-12-09

基金项目: 国家自然科学基金资助项目 (51675286)

作者简介: 周 勇 (1992—), 男, 硕士研究生, 研究方向: 机械工程结构动力学与振动分析。

通信作者: 冯志敏 (1960—), 男, 教授、博士生导师。E-mail: fengzhimin@nbu.edu.cn

Keywords: *RBF neural network; magneto-rheological damper (MRD); dynamic model; linear interpolation; connection weight*

0 引言

船舶在行驶或作业中,往往因风浪波动而产生强烈振动,不仅会损害驾驶员身体健康,而且还将缩短船舶机械设备使用寿命。磁流变液阻尼器(Magneto-rheological Damper, MRD)能够快速、有效地制振,在船舶降噪、海洋平台减振及桥梁拉索的振动控制中具有广泛的应用^[1-4]。MRD由磁流变液、永磁铁、励磁线圈、活塞、密封体等组装而成,其动力性能因磁场作用而连续变化。为精确而合理地输出阻尼力,使MRD在工程应用中取得良好振动控制效果,需要寻求一种MRD动力学精确建模方法。目前,Bouc-Wen、Sigmoid、多项式、神经网络等MRD动力学建模^[5-7]方法,均不同程度地提高了MRD减振控制效果。其中,神经网络^[8]是一种可快速、精准建立输入-输出间非线性关系的网络结构,适用于复杂物理模型的构建,逐渐受到学者们关注。王楠等^[9]利用粒子群算法优化隐含层节点数,采用遗传算法优化权值和阈值,使模型具有较小训练误差和较强泛化能力;AYALA等^[10]对目标函数进行改进,融合遗传算法与差分进化算法并实现神经网络预测精度的提高。然而,RBF神经网络学习完成后,连接权恒定不变,对每一输入数据难以实现理想精度的预测。为此,魏娟等^[11]采用递推最小二乘法、李仁军等^[12]和石为人等^[13]采用Lyapunov理论法,分别在网络结构确定及设计自适应控制率特定环境下,对网络连接权值进行自动调整,大幅度提升特定网络的精度。因此,对适应特定环境条件下的连接权值自适应算法需做进一步探究。

本文采用线性插值的方式,实现连接权重自适应调整,并提出RBF神经网络改进算法。利用与任一测试样本相邻的两个训练样本对应的实际连接权值,插值求取测试样本的连接权值,实现网络连接权值随测试样本输入的自适应调整。搭建了MRD试验平台,在3个频率、3个振幅、6个电流工况条件下,对MRD进行动力性能试验,由此构建了基于改进型RBF神经网络的MRD动力学模型,对其进行1 000次以上的循环测试和仿真计算,精度误差均值多控制在0.45%~0.85%之间,网络稳定可靠,有效满足实际工程应用要求。

1 MRD 动力性能试验

1.1 试验平台

试验对象是宁波杉工智能安全科技股份有限公司研制的MRD60型磁流变阻尼器^[14],主要参数见表1。

试验平台主要由动静试验机、计算机、控制器、电流源、液压机构等设备组成,见图1。试验所用的

力学性能试验机是由长春机械科学研究院研制的SDS-100型电液伺服动静试验机,主要由主机、控制系统模块、液压机构、传感器模块等组成,控制系统采用德国DOLI公司研制的EDC580型全数字控制器。试验机主要参数见表2。

表1 MRD 主要参数

参数	数值	参数	数值
最大阻尼力/kN	5	外径/mm	70
行程/mm	±40	重量/kg	10
频率范围/Hz	<10	输入电流/ADC	0~2
伸后最大全长/mm	540	输入阻抗/Ω	<1.0
		温度范围/℃	-40~60




图1 试验平台示意图

表2 SDS-100 试验机主要参数

参数	数值
最大静负荷/kN	±100
最大动负荷/kN	±100
静态负荷精度	示值的±1%
最大可加载位移/mm	±50
位移测量精度	±1% F.S
函数发生器频率/Hz	0.01~50
试验频率/Hz	0.01~50
可输出波形	正弦波、三角波、方波等

MRD 需要通入电流,采用 Tektronic 公司生产的PWS2326 直流电流源,技术参数表见表3。

表3 电流源主要参数

参数	数值	参数	数值
可输出电流/A	0~6	基本电流精度	0.20%
可输出电压/V	0~32	基本电压精度	0.05%
编程分辨率	10 mA、10 mV		

1.2 试验方法

1) 将 MRD 活塞杆向下夹紧到试验机的上下钳口。钳位稳定后, 将励磁线圈的导线连接到电流源。

2) 从计算机集成的软件中, 输入试验所设定的工况参数, 计算机通过调配控制器实现对动静试验机液压系统的动态控制。液压系统控制动静试验机的下夹头为 MRD 施加预定的振动激励, 同时, 试验机上夹头处内置有位移、加速度等传感器, 可实时输出所得的阻尼力值, 并按预定时间间隔将其记录下来。

3) 以专用软件处理测得数据, 绘制相应的力学性能曲线。

1.3 工况设定

由于桥梁拉索振动频率主要在 0.25 Hz~2.0 Hz 之间, 以此作为 MRD 动力性能试验频段。陈昭晖等^[8]通过神经网络建立工作频带范围的 MRD 动力学模型, 模型预测值与试验值吻合较好, 证明工作频带上

的频率点均能保证良好的性能, 因此选用一定间隔的频带点作为 MRD 激励频率; 幅值由 MRD 安装位置与外界激励决定^[15]; MRD 输入电流量程不超过 2 A, 故选取表 4 所示的试验工况。

表 4 力学性能试验工况

参数	输入值
激励频率/Hz	0.25、0.50、0.75
激励幅值/mm	5、10、15
输入电流/A	0、0.25、0.50、0.75、1.00、1.25

1.3 试验结果与分析

图2和图3为不同振动幅值、振动频率状态下的正弦激励和0~1.25 A等距输入电流下的实测阻尼力-位移、阻尼力-速度的动力学规律, 其幅值、频率分别为 10 mm、0.25 Hz, 5 mm、0.25 Hz, 10 mm、0.5 Hz, 15 mm、0.5 Hz和15 mm、0.75 Hz 5种工况。




图 2 5 种工况条件下不同电流的阻尼力-位移曲线




图 3 5 种工况条件下不同电流的阻尼力-速度曲线 (I)




图3 5种工况条件下不同电流的阻尼力-速度曲线(II)

从图2和图3可知,在无输入电流时,MRD的输出由未磁化的低黏度磁流变液提供。随着电流增加,流体的剪切屈服强度随着磁化程度而增加,并且阻尼值增加。当活塞杆速度较小时,MRD呈现滞回现象;当活塞杆速度较大时,阻尼力缓慢增加,表现出剪切变薄现象。因此,MRD具有很强的非线性动力特性。

2 RBF 神经网络改进算法

2.1 RBF 神经网络结构

RBF神经网络是具有单隐含层的三层前向网络,取隐含层节点函数为高斯函数,则RBF神经网络隐含层节点的输出和网络的输出分别为

$$h_j = \exp\left(-\frac{\|x - c_j\|^2}{2\sigma_j^2}\right), j = 1, 2, \dots \quad (1)$$

$$o_l = \sum h_j w_{jl}, l = 1, 2, \dots \quad (2)$$

式中: x 为输入向量; C_j 、 σ_j 为网络的第 j 个隐含层节点中心向量和宽度向量; h_j 为神经网络第 j 个隐含层节点的输出; w_{jl} 为第 j 个隐含层到第一个输出节点的连接权值。

采用MRD动力性能试验数据,建立关于MRD的RBF神经网络模型,见图4。该模型的表达式为

$$F_t = f(A, f, s, v, i) \quad (3)$$

式中: F_t 代表 t 时刻MRD的阻尼力值; A 、 f 、 s 、 v 、 i 代表 t 时刻MRD的振幅、频率、位移、速度及电流值。




图4 MRD-RBF 神经网络模型

2.2 改进算法

首先,运用一定的分类方法将MRD动力性能试验数据划分为训练样本集与测试样本集,对训练集的五个输入量进行归一化处理,并利用处理后的训练集构建RBF神经网络模型,隐含层节点数、节点中心、连接权值等得到确定;其次,由式(2)可知,网络的输出与隐含层节点的输出呈线性关系,因此对系数矩阵 W 进行插值处理,从而获得测试样本的连接权值;然后,随着测试样本的改变,自适应地调整RBF神经网络连接权重;最后,利用式(2)得到测试样本对应的理想网络输出,计算与实际输出值的误差以验证算法的精度。

连接权值自适应算法具体过程如下:

1) 结合数据特点,运用一定分类规则将数据集划分为训练样本集 $\{x_\varepsilon, \varepsilon=1, 2, \dots, n\}$ 与测试样本集 $\{x'_\tau, \tau=1, 2, \dots, z\}$ 。其中, n 为训练样本数; z 为测试样本数。

2) 使用数值仿真软件 Matlab 快速构建RBF神经网络模型,其中,模型的隐层节点数、节点中心以及高斯基函数宽度同时得到确定。

3) 向RBF神经网络输入一测试样本 x'_τ , 计算其与训练集各样本间欧氏距离

$$D_\varepsilon = \|x'_\tau - x_\varepsilon\|, \varepsilon = 1, 2, \dots, n \quad (4)$$

4) 找出 $\{D_\varepsilon, \varepsilon=1, 2, \dots, n\}$ 中最小两值分别对应的训练样本 $x_{\varepsilon-1}$ 、 $x_{\varepsilon-2}$ 。

5) 设 $x_{\varepsilon-1}$ 、 $x_{\varepsilon-2}$ 、 x'_τ 在第 j 隐节点的输出值分别为 $h_{\varepsilon-1}^j$ 、 $h_{\varepsilon-2}^j$ 、 h_τ^j , 已知理想输出向量分别为 $o_{\varepsilon-1}^k$ 、 $o_{\varepsilon-2}^k$ 、 $h_{\varepsilon-1}^j$ 、 $h_{\varepsilon-2}^j$ 、 h_τ^j 、 $o_{\varepsilon-1}^k$ 、 $o_{\varepsilon-2}^k$, 则可算得 $x_{\varepsilon-1}$ 、 $x_{\varepsilon-2}$ 在隐含层第 j 节点和输出层第 k 节点间的实际连接权重为

$$w_{jk}^1 = \frac{o_{\varepsilon-1}^k}{r \cdot h_{\varepsilon-1}^j}, j = 1, 2, \dots, r, k = 1, 2, \dots, m \quad (5)$$

$$w_{jk}^2 = \frac{o_{\varepsilon-2}^k}{r \cdot h_{\varepsilon-2}^j}, j = 1, 2, \dots, r, k = 1, 2, \dots, m \quad (6)$$

6) 设 w_{jk}^τ 为 x'_τ 在隐层第 j 节点与输出层第 k 节点间的连接权重。因 $h_{\varepsilon-1}^j$ 、 $h_{\varepsilon-2}^j$ 、 h_τ^j 、 w_{jk}^1 、 w_{jk}^2 已知, w_{jk}^τ

可利用线性插值法计算获得。

$$\frac{h_{e-2}^j - h_{e-1}^j}{w_{jk}^2 - w_{jk}^1} = \frac{h_{\tau}^j - h_{e-1}^j}{w_{jk}^{\tau} - w_{jk}^1} \quad (7)$$

$$w_{jk}^{\tau} = \frac{w_{jk}^1 (h_{e-2}^j - h_{\tau}^j) + w_{jk}^2 (h_{\tau}^j - h_{e-1}^j)}{h_{e-2}^j - h_{e-1}^j} \quad (8)$$

$$j=1, 2, \dots, r \quad k=1, 2, \dots, m$$

7) 计算 x_{τ}^k 输出层第 k 节点的输出值为

$$y_{te}^k = \sum_{j=1}^r w_{jk}^{\tau} h_{\tau}^j \quad (9)$$

算法流程见图5。




图5 连接权值自适应算法流程图

3 仿真测试结果与比较分析

表5比较了在正弦激励条件下,改进型RBF神经网络模型测量值的预测误差。由表5可知,预测误差

多控制在1%以内,最低可至0.201%。可见,对随机选取的测试样本,所提出的模型可较精准地预测样本阻尼力。

表5 改进型RBF神经网络测试结果

测试样本	仿真值/kN	试验值/kN	误差/%
1	-2.691 6	-2.6862	0.201
2	-3.696 4	-3.685 8	0.288
3	-4.053 8	-4.041 6	0.302
4	0.970 6	0.972 9	0.236
5	-0.870 7	-0.864 0	0.775
6	-0.359 7	-0.361 5	0.498
7	-4.245 3	-4.237 5	1.841

为充分证明改进型RBF神经网络具备良好的泛化性,随机选取1000组测试样本并进行仿真测试,对阻尼力的预测值和试验值进行比较分析。与图2相对应的振动幅值和频率5种工况条件下(10 mm、0.25 Hz, 5 mm、0.25 Hz, 10 mm、0.5 Hz, 15 mm、0.5 Hz和15 mm、0.75 Hz)的动力学仿真与试验比较结果见图6和图7。

从图6和图7可见,在平滑曲线上,预测值与测试值近乎完全吻合;在部分波动曲线上,预测值与测试值有微小偏离。比较不同工况下的预测值的离散程度,可知预测值的精度不受活塞杆速度、位移及输入电流的影响。对任意选取的MRD动力性能测试样本,改进型RBF神经网络预测值均能与试验值吻合很好。




图6 5种工况条件下改进型RBF仿真与试验值的阻尼力-位移曲线




图 7 5 种工况条件下改进型 RBF 仿真与试验值的阻尼力-速度曲线

图8比较了正弦激励下改进型RBF和原RBF神经网络模型对测试样本的仿真误差。由图8可知,对于原RBF神经网络,在平滑曲线上,少量预测值与试验值有较大偏移,多数预测值在试验值附近上下波动;在波动曲线上,大量预测值与试验值有较大偏移。采用改进型RBF神经网络对测试样本进行仿真,多数预测值与测试值吻合很好,少量预测值与试验值有微小偏移。由图8中曲线对比可知,改进型RBF神经网络较改进前RBF神经网络有更高的预测精度。

对 400 组随机选取的测试样本进行 1 000 次循环测试,参考文献[7]计算每次循环测试的平均累计相对误差,结果见图 9 所示。由图 9a)可知,改进型 RBF 神经网络的阻尼力预测误差均值小于 1.1%,主要误差均值控制在 0.45%~0.85%之间。图 9b)为 RBF 神经网络

改进前后阻尼力预测误差对比图,改进前的 RBF 神经网络模型误差均值最大达 5%,误差幅值急剧波动,而改进型 RBF 神经网络模型误差均值曲线位于原模型最小误差以下,幅值较低且平稳状态。结果表明,改进型 RBF 神经网络可以构建精确的 MRD 模型来描述非线性动力学特性,实现阻尼器精准的出力控制。

4 结论

在 MRD 动力性能试验基础上,建立改进型 RBF 神经网络动力学模型,利用测试样本集对模型进行仿真分析与测试对比,得到如下结论:

1) 提出了一种将线性插值法融入 RBF 神经网络的建模算法,使网络参数随样本输入的变化而具有自适应调整功能。测试表明,预测误差多控制在 1%以




图 8 RBF 改进前后仿真曲线图




图9 1000次循环测试图

内,最低可至 0.201%。连接权值自适应的 RBF 神经网络改进算法明显提高了建模精度。

2) 将改进型 RBF 神经网络算法应用于 MRD 的 RBF 神经网络动力学建模,阻尼力预测最大误差均值从 5%降低到 1.1%以下,主要误差均值控制在 0.45%~0.85%之间,表明改进型 RBF 神经网络建模方法可精确描述 MRD 复杂非线性动力学特性,为船舶、斜拉索减振的 MRD 提供较为准确的阻尼力预估,该方法也可应用于船舶主机温度预测、船舶姿态预报等领域。

参考文献:

- [1] DENG Z H, ZHANG D G, YAO X L. Experimental Study on Ship Equipments Vibration Reduction Based on Magnetorheological Damper [C]// Proceedings of the International Offshore and Polar Engineering Conference. 2008.
- [2] ANKITA S, DIPTESH D. Seismic Vibration Control of Offshore Jacket Platforms Using Decentralized Sliding Mode Algorithm [J]. Ocean Engineering, 2018, 152(1): 337-390.
- [3] SHI D Y, SHI X J, REN L L. Experiment Research on Low-frequency Vibration of Ship Isolator [J]. Journal of Vibration, Measurement and Diagnosis, 2012, 32(6): 961-965.
- [4] 万乐坤, 嵇春艳, 尹群. 海洋平台磁流变模糊半主动振动控制研究[J]. 船舶工程, 2007, 29(4):28-31.
- [5] DYKE S J. Acceleration Feedback Control Strategies for Active and Semi-active Control systems: Modeling, Algorithm Development, and Experimental Verification [D]. Indiana : University of Notre Dame, 1996.
- [6] HU G L, LIU Q J, LI G, et al. Simulation and Analysis of Adjustable Sigmoid Model for a Typical Magnetorheological Damper [J]. Machine Tool & Hydraulics, 2016, 44(24): 9-15.
- [7] 董致臻, 冯志敏, 伍广彬, 等. 基于粒子群优化算法的磁流变阻尼器多项式动力学建模方法[J]. 中国机械工程, 2018, 29(12): 1421-1427.
- [8] 陈昭晖, 倪一清. 磁流变阻尼器非参数化模型泛化能力的提高[J]. 振动与冲击, 2017, 36(6):146-151.
- [9] 王楠, 潘忠文, 王旭, 等. 整星隔振用磁流变阻尼器神经网络模型[J]. 力学与实践, 2017, 39(6): 579-584.
- [10] AYALA H V H, COELHO L D S. Cascaded Evolutionary Algorithm for Nonlinear System Identification Based on Correlation Functions and Radial Basis Functions Neural Networks [J]. Mechanical Systems and Signal Processing, 2016, 69(68): 378-393.
- [11] 魏娟, 杨恢先, 谢海霞. 基于免疫 RBF 神经网络的逆运动学求解[J]. 计算机工程, 2010, 36(22): 192-194.
- [12] 李仁军, 刘宏昭, 原大宁. 基于 RBF 神经网络的混合输入机构自适应控制[J]. 农业机械学报, 2010, 41(4): 204-208.
- [13] 石为人, 陶芬, 张元涛. 基于 RBF 神经网络的减摇鳍自适应滑模控制[J]. 控制工程, 2012, 19(6): 978-981.
- [14] 冷志鹏, 徐慧, 李宏伟. 一种新型磁流变阻尼器: 中国, CN 102425636 A[P]. 2012-04-25
- [15] 冯志敏, 张兴军, 张刚, 等. 斜拉索-阻尼器系统建模与减振控制研究[J]. 农业机械学报, 2013, 44(S1): 282-287.