

磁流变阻尼器非参数化模型泛化能力的提高

陈昭晖¹, 倪一清²

(1. 福州大学 土木工程学院 福州 350116; 2. 香港理工大学 土木及环境工程学系 香港)

摘要: 建立磁流变阻尼器的动态模型以描述其强非线性动力学行为是智能磁流变控制系统设计及应用的关键环节之一。泛化能力是衡量基于神经网络技术的磁流变阻尼器非参数化模型性能的重要指标,也是保证控制系统稳定性和可靠性的重要因素。基于磁流变阻尼器的动力学试验数据,提出贝叶斯推理分析框架下的非线性自回归(non-linear autoregressive with exogenous inputs, NARX)神经网络技术建立磁流变阻尼器的动态模型,通过网络结构优化和正则化学习算法的结合以有效地提高模型的预测精度和泛化能力。研究结果表明,基于贝叶斯推理的NARX网络模型能够准确地预测磁流变阻尼器在周期和随机激励下的非线性动态行为,同时验证了该模型相比于非正则化模型在泛化性能方面的优越性,因此,有利于实现磁流变控制系统的实时、鲁棒智能化控制。

关键词: 磁流变阻尼器; 非参数化模型; NARX神经网络; 贝叶斯正则化; 泛化能力

中图分类号: TU352; TB535

文献标志码: A

DOI:10.13465/j.cnki.jvs.2017.06.022

Enhanced generalization of nonparametric model for magnetorheological dampers

CHEN Zhaohui¹, NI Yiqing²

(1. College of Civil Engineering, Fuzhou University, Fuzhou 350116, China;

2. Department of Civil and Environmental Engineering, The Hong Kong Polytechnic University, Hong Kong, China)

Abstract: The dynamic modeling for magnetorheological (MR) dampers to describe their highly nonlinear dynamic characteristics is essential for the design and implementation of a smart MR control system. One critical concern in constructing a nonparametric MR damper model by employing the artificial neural network technique is its generalization capability, which is also significant to guarantee the stability and reliability of the MR control system. The paper presents the modeling of MR dampers with the employment of the NARX (nonlinear autoregressive with exogenous inputs) network technique within a Bayesian inference framework, and addresses the enhancement of model prediction accuracy and generalization capability in terms of the network architecture optimization and regularized network learning algorithm. The Bayesian regularized NARX network model for the MR damper is demonstrated to outperform the non-regularized network model with the superior prediction and generalization performance in the scenarios of harmonic and random excitations. Therefore, the proposed model with enhanced generalization is beneficial to realize the real-time and robust smart control of MR systems.

Key words: magnetorheological damper; nonparametric model; NARX network; Bayesian regularization; generalization

智能材料的发展为结构振动控制开辟了新天地,推动着结构控制往智能化方向发展。磁流变液是智能材料研究较为活跃的一个分支,它在磁场作用下可从自由或粘性流动的液体在毫秒级时间范围内转变为具有一定屈服强度的类固体^[1]。以磁流变液为工作介质制成的磁流变阻尼器属于半主动控制装置,可通过调

节阻尼器内电磁线圈中的电流强度控制磁场强度,从而改变磁流变液的工作状态,实现阻尼力的智能控制。

采用磁流变阻尼器进行结构半主动控制时,为实现高效的控制效果需要在控制系统设计中充分考虑磁流变阻尼器的动力学特性,因此,建立准确、适于实时控制的磁流变阻尼器动力学模型是关键环节之一。但是,磁流变阻尼器的动力学行为由于磁流变液的复杂流变特性而呈现强非线性,增加了阻尼器建模的困难。目前,对于此问题的研究主要采用参数化建模和非参数化建模的方法。参数化模型利用物理元件(如质量、线性/非线性弹簧、线性/非线性阻尼等)和滞回模块

基金项目: 国家自然科学基金(51608128); 福州大学科研启动基金(510110); 福建省教育厅科技项目(JA15098); 福建省自然科学基金资助项目(2016J05123)

收稿日期: 2016-01-05 修改稿收到日期: 2016-07-04

第一作者 陈昭晖 男,博士,助理研究员,1982年10月生

(Bingham、Bouc-Wen、Dahl、LuGre 等) 的串并联组合来模拟阻尼器的力学行为^[2-6]。参数化模型通常表达为强非线性方程, 虽然在一定范围内能够准确描述磁流变阻尼器的力学行为, 但其多参数的优化识别不可避免地受制于初始值、约束条件、收敛性等因素而产生难度。实际控制应用时, 对强非线性方程的数值处理可能造成控制滞后, 影响控制效果。

非参数化模型主要采用人工神经网络、模糊逻辑、神经模糊推理等技术基于足够丰富的试验数据建立磁流变阻尼器输入、输出的非线性映射关系以表征其动力学行为^[7-10]。其中, 神经网络具有很强的自学习能力能够获得精确的预测模型。实际应用中, 神经网络模型的泛化能力, 即网络识别训练数据以外样本的能力, 被认为是衡量神经网络性能的重要指标。但以往的研究却很少对磁流变阻尼器的神经网络模型进行泛化能力方面的深入探讨。用于神经网络训练的试验数据不可避免地包含噪声, 如果网络结构冗余, 这些噪声会影响到整个网络训练后期的收敛, 导致训练偏离全局最优点, 并造成网络过拟合(overfitting)而记忆了噪声细节, 降低泛化能力。过拟合的神经网络模型将无法保障磁流变阻尼器控制系统的稳定性和可靠性。

本文基于磁流变阻尼器的动态性能试验数据, 从网络结构和学习算法相结合的角度来研究磁流变阻尼器神经网络模型泛化能力的提高。提出采用 NARX 模型与神经网络技术相结合的 NARX 网络建模方法表征磁流变阻尼器的非线性动力学行为, 并利用基于贝叶斯推理的学习算法来有效地提高磁流变阻尼器模型在不同输入激励条件下的泛化能力。

1 磁流变阻尼器的动力学试验

以美国 LORD 公司的 RD-8040 磁流变阻尼器为试验对象, 采用 MTS 材料试验机进行磁流变阻尼器的动态力学性能测试。试验时, 控制 MTS 作动器输出不同频率和幅值的谐波位移激励信号施加于磁流变阻尼器, 同时对阻尼器输入不同的直流电流。图 1 显示了其中在幅值为 5 mm、频率为 2.5 Hz 的正弦激励以及不同直流输入下的实测位移-阻尼力和速度-阻尼力滞回曲线。由图可见, 在无输入电流(0 A)的情况下, 磁流变阻尼器的出力由磁流变液的黏性行为及活塞与密封圈间的摩擦主导。随着电流的增大, 磁流变阻尼力及耗能能力增大, 其增幅随着磁流变液趋于磁饱和状态而减小。当活塞速度较小时, 阻尼器呈现出滞回现象, 阻尼力随着速度的增加而增大, 当速度增大到一定幅值后, 阻尼力的增加减缓, 阻尼器表现出屈服现象。因此, 磁流变阻尼器具有很强的非线性动力特性。

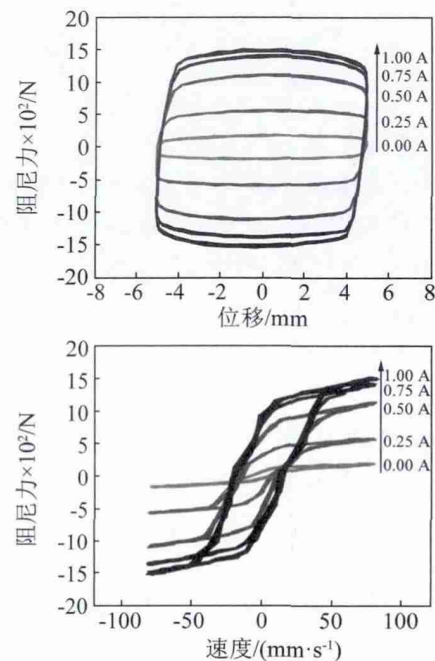


图 1 不同电流下的滞回特性曲线(5 mm, 2.5 Hz)
Fig. 1 Measured hysteresis loops under different current levels (5 mm, 2.5 Hz)

2 NARX 网络建模方法

2.1 NARX 网络

NARX 模型具有很好的表征非线性动态行为的能力, 理论上可以描述任意有限自由度的非线性动态系统^[11]。NARX 模型用离散时间的输入-输出方程表达为

$$\hat{y}(t) = f(y(t-1); \dots; y(t-n_y), u(t); \mu(t-1); \dots; \mu(t-n_u); \theta) + e(t) \quad (1)$$

式中: $u(t)$ 和 $y(t)$ 分别为 t 时刻的系统输入和输出; $\hat{y}(t)$ 为 $y(t)$ 的预测值; n_u 和 n_y 分别为系统输入和输出的时延阶数; $e(t)$ 为模型误差; $f(\cdot; \theta)$ 为描述输入和输出关系的非线性函数; θ 为待辨识的模型参数向量。为保证模型式(1)能够准确描述真实系统特性, $f(\cdot; \theta)$ 必须具有全局逼近能力。

多层感知器(multilayer perceptron, MLP)是一种前馈神经网络模型, 能够反映输入与输出之间的映射关系。它包含多层神经元, 各层神经元之间通过连接权以前馈方式传递信息。含有单隐层的 MLP 已经理论上被证明具有全局逼近能力, 即只要其隐层神经元数目足够, 通过优化其连接权就能以任意精度逼近非线性连续函数^[12]。因此, 可以采用 MLP 网络辨识式(1)的 NARX 模型 $f(\cdot; \theta)$, 其参数向量 θ 则由神经网络参数(连接权和阈值)组成, 由此构成的方法为 NARX 网络, 它具有强大的表征复杂非线性行为(如迟滞、饱和、混沌等)的能力^[13]。

多输入单输出的 NARX 网络可表达为

$$\hat{y}(t) = g_2 \left(\sum_{j=1}^{n_h} w_j^o g_1 \left(\sum_{i=1}^{n_i} w_{ji}^h z_i(t) + b_j^h \right) + b^o \right) \quad (2)$$

式中:

$$z(t) = [y(t-1); \dots; y(t-n_y); \mu(t); \mu(t-1); \dots; \mu(t-n_\mu)]$$

和 $\hat{y}(t)$ 分别为模型输入和输出; $n_i (=n_y + n_\mu + 1)$ 和 n_h 分别为输入层和隐层的神经元数目; w_{ji}^h 为第 i 个输入神经元与第 j 个隐层神经元间的连接权; w_j^o 为输出神经元与第 j 个隐层神经元的连接权; b_j^h 和 b^o 分别为第 j 个隐层神经元和输出神经元的阈值; $g_1(\cdot)$ 和 $g_2(\cdot)$ 分别为隐层和输出层的激励函数。利用数据样本对 NARX 网络进行训练, 所得到的网络参数, 即权值 $w (= \{w_{ji}^h, w_j^o\}^T)$ 和阈值 $b (= \{b_j^h, b^o\}^T)$ 将构成模型参数向量 θ 。

2.2 贝叶斯学习算法

MLP 网络模型的学习训练通常采用最大似然法 (如反向传播算法) 进行模型参数估计。基于 N_D 个训练数据样本 D , 通过最小化模型预测值与真实值间的误差平方和指标式 (3) 确定网络参数

$$E_D = \sum_{t=1}^{N_D} (\hat{y}(t) - y(t))^2 \quad (3)$$

然而, 采用最大似然法训练的 MLP 网络结构容易过于冗余, 导致对训练样本的过拟合现象, 即网络模型仅记忆样本数据, 而没有学习到数据间的真实映射关系, 从而导致网络泛化能力降低, 无法对未经训练的输入给出正确的输出预测。

正则化方法是改善网络泛化能力的有效方法之一, 其将反应网络结构复杂性的正则惩罚项引入式 (3) 中改进误差函数形式为

$$S(\theta) = \beta E_D + \alpha E_\theta \quad (4)$$

式中附加的惩罚项 $E_\theta = \sum_{i=1}^{n_\theta} \theta_i^2$ 为网络参数的平方和, N_θ 为参数数量。通过此惩罚项约束网络参数的增加, 达到控制网络结构冗余度的目的。 α 与 β 为正则化参数, 控制着惩罚项在目标函数中的参与程度。若 $\alpha \ll \beta$, 训练过程以增加网络结构复杂性为代价来减小模型误差, 结果可能造成模型过拟合现象; 若 $\alpha \gg \beta$, 则以牺牲模型预测精度为代价来获得结构精简的网络, 由此得到的模型的泛化能力有望提高。因此, 正则化方法的关键问题在于如何确定最优的正则化参数来权衡网络模型的预测准确度和结构复杂性。为此, MACKAY^[14] 利用贝叶斯推理的方法训练网络进行参数寻优的同时自适应地调节正则化参数, 并使其达到最优。

2.2.1 网络训练的贝叶斯推理

贝叶斯方法着眼于网络参数在整个权空间中的概率分布, 将网络参数视为随机变量。在网络结构确定的情况下, 没有样本数据时网络参数的先验分布为

$P(\theta|\alpha)$ 。有了样本数据 D 后, 根据贝叶斯理论, 可得网络参数的后验条件概率为

$$P(\theta|D, \alpha, \beta) = \frac{P(D|\theta, \beta) P(\theta|\alpha)}{P(D|\alpha, \beta)} \quad (5)$$

式中 $P(D|\theta, \beta)$ 为似然函数, $P(D|\alpha, \beta)$ 为归一化因子。

假设训练数据 D 含有零均值高斯噪声, 且网络参数 θ 服从高斯先验分布, 则有

$$P(D|\theta, \beta) = \exp(-\beta E_D) / Z_D(\beta) \quad (6)$$

$$P(\theta|\alpha) = \exp(-\alpha E_\theta) / Z_\theta(\alpha) \quad (7)$$

式中: $Z_D(\beta) = (\pi/\beta)^{N_D/2}$, $Z_\theta(\alpha) = (\pi/\alpha)^{N_\theta/2}$ 。把式 (6) 和式 (7) 代入式 (5) 可得参数的后验概率分布为

$$P(\theta|D, \alpha, \beta) = \exp(-S(\theta)) / Z_S(\alpha, \beta) \quad (8)$$

式中: $S(\theta)$ 由式 (4) 给出, $Z_S(\alpha, \beta) = \int \exp(-S(\theta)) d\theta$ 。

由于 $Z_S(\alpha, \beta)$ 与 θ 无关, 由式 (8) 可知, 通过贝叶斯推理的网络训练以最小化 $S(\theta)$ 可以求得参数后验概率的最大值, 此时对应的网络参数 θ^{MP} 即为最优参数值。

2.2.2 正则化参数的贝叶斯优化

贝叶斯推理学习算法的另一个优势是网络训练过程中可以同步优化正则化参数 α 和 β 。根据贝叶斯理论, 给定训练数据 D 后, 正则化参数的后验概率为

$$\frac{P(\alpha, \beta|D)}{P(D)} = \frac{P(D|\alpha, \beta) P(\alpha, \beta)}{P(D)} \quad (9)$$

假设先验分布 $P(\alpha, \beta)$ 满足一种很宽的分布函数, 即对 α 和 β 不敏感, 且归一化因子 $P(D)$ 与 α, β 无关, 因此, 求取正则化参数的最大后验概率分布的问题转化为求解最大似然函数 $P(D|\alpha, \beta)$ 。由式 (5) ~ (8) 可得,

$$P(D|\alpha, \beta) = \frac{P(D|\theta, \beta) P(\theta|\alpha)}{P(\theta|D, \alpha, \beta)} = \frac{Z_S(\alpha, \beta)}{Z_D(\beta) Z_\theta(\alpha)} \quad (10)$$

当样本数据量较多时, 网络参数的后验分布趋于高斯分布, 通过简化可求出 $Z_S(\alpha, \beta)$, 再将其代入式 (10) 并取对数后分别对 α 和 β 求偏导, 可得到

$$\alpha^{MP} = \frac{\gamma_{\text{eff}}}{2E_\theta^{MP}} \quad (11a)$$

$$\beta^{MP} = \frac{N_D - \gamma_{\text{eff}}}{2E_D^{MP}} \quad (11b)$$

式中: $\gamma_{\text{eff}} = N_\theta - 2\alpha^{MP} \text{trace}((\nabla \nabla S(\theta^{MP}))^{-1})$ 表示实际参与正则化学习的网络参数的数量。由于 γ_{eff} 与 α 有关, α 和 β 值在网络训练过程中由式 (11) 进行循环估计。

NARX 网络的训练采用具有快速和稳定收敛优势的 Levenberg-Marquardt (LM) 算法^[15] 优化网络参数 θ^{MP} 以最小化目标函数 (4)。在进行正则化参数优化过程中, 需要计算 $S(\theta)$ 在其最小点 θ^{MP} 处的 Hessian 阵 $\nabla \nabla S(\theta^{MP})$, 为减小计算量、提高计算速度, 可以利用 LM 算法对其做近似计算, 即

$$\nabla \nabla S(\theta)^{MP} \approx 2\beta^{MP} J^T J + 2\alpha^{MP} I \quad (12)$$

式中: J 为误差函数 E_D^{MP} 的 Jacobian 矩阵 I 为 $N_\theta \times N_\theta$ 维的单位阵。

采用贝叶斯学习算法进行网络训练时 输入和输出数据都归一化为 $[-1, 1]$ 之间。为避免网络陷入局部最优解 对网络参数随机初始化进行重复训练后取最优。

3 磁流变阻尼器的模型辨识

根据式 (1) 磁流变阻尼器的动力学模型可表示为

$$\hat{F}(t) = N_{fwd}(x(t), \dots, x(t-n_x), \dot{x}(t), \dots, \dot{x}(t)(t-n_x), I(t), \dots, I(t-n_I), F(t-1), \dots, F(t-n_F)) \quad (13)$$

式中: x, \dot{x}, I 和 F 分别为阻尼器活塞杆的位移、速度、输入电流和阻尼力; $n_x, n_{\dot{x}}, n_I$ 和 n_F 分别为位移、速度、电流和阻尼力的时延阶数; $N_{fwd}(\cdot)$ 为反映输入输出映射关系的单隐层 NARX 网络 其隐层和输出层激励函数分别选为双曲正切 S 函数和线性函数 即

$$g_1(a) = \tanh(a) = \frac{1 - \exp(-2a)}{1 + \exp(-2a)} \quad (14a)$$

$$g_2(a) = a \quad (14b)$$

式中: 隐层激励函数 $g_1(\cdot)$ 赋予 NARX 网络表征非线性行为的运算能力 这样的网络形式已被证明具有全局逼近能力。式(13)包含了磁流变阻尼器输入输出的多阶时延信息 因此可以反映其动态行为。

基于磁流变阻尼器的性能试验数据 建立其 NARX 网络模型分为两阶段: ①利用训练样本进行网络的贝叶斯学习训练 同时利用验证样本进行网络结构设计; ②利用未经训练的测试样本检验优化训练后的网络模型的泛化性能。获取训练、验证和测试数据的实验工况如表 1 所示 输入激励为各种频率和幅值的谐波位移信号以及不同水平的直流电流。磁流变阻尼器活塞的速度采用有限差分法对位移求导得到。模型的预测性能采用实测阻尼力和模型预测输出之间的均方根 (RMS) 误差进行评价 即

$$\delta_{rms} = \sqrt{\frac{1}{N_D} \sum_{t=1}^{N_D} [\hat{F}(t) - F(t)]^2} \quad (15)$$

为简化模型结构以适用于实时控制应用及提高其泛化能力 需要对输入变量及其时延阶数和隐层神经元数目进行优化选择。图 2 显示了不同输入变量组合下模型的训练和验证误差的统计情况。由图可见 没有考虑阻尼器速度 \dot{x} 和阻尼力 F 的情况下 即输入变量组合为 (x, I, F) 和 (x, \dot{x}, I) 时 模型的预测结果并不理想。由于磁流变阻尼器出力大小受输入电流的影响 根据网络模型输入为 (x, \dot{x}, F) 和 (x, \dot{x}, I, F) 时的结果比较 有必要将电流纳入为模型输入变量以减小预测误差。当模型输入为 (\dot{x}, I, F) 和 (x, \dot{x}, I, F) 时 由两者误差比较可见 阻尼器位移的参与对提升模型预

测性能的贡献很小。综上所述 NARX 网络模型的输入变量取为磁流变阻尼器速度 \dot{x} 、电流 I 和过去时刻的阻尼力 F 。

表 1 NARX 网络训练、验证及测试的实测数据样本

Tab.1 Measurement data sets for NARX network training, validation and testing

| 数据 | 类型 | 位移激励 | | 电流 / A | 阻尼力 / N (RMS 值) | |
|----|-----|---------|---------|------------|-----------------|----------------|
| | | 幅值 / mm | 频率 / Hz | | | |
| 训练 | 正弦波 | 1.0 | 1.0 | 0:0.25:1.0 | 106.5 ~ 825.0 | |
| | | 5.0 | 5.0 | 0:0.25:1.0 | 161.5 ~ 1484.4 | |
| | | 1.0 | 5.0 | 0:0.5:1.0 | 129.0 ~ 40.1 | |
| | | 5.0 | 1.0 | 0:0.5:1.0 | 149.7 ~ 1211.2 | |
| | | 1.0 | 1.0 | 0.5 | 592.9 | |
| 验证 | 正弦波 | 5.0 | 5.0 | 0.5 | 1016.6 | |
| | | 1.0 | 5.0 | 0.25, 0.75 | 303.1, 855.9 | |
| | | 5.0 | 1.0 | 0.25, 0.75 | 446.0, 1139.8 | |
| | | 1 正弦波 | 2.5 | 2.5 | 0:0.25:1.0 | 151.3 ~ 1291.5 |
| | | 2 正弦波 | 5.0 | 2.5 | 0:0.25:1.0 | 117.0 ~ 918.1 |
| 测试 | 三角波 | 5.0 | 2.5 | 0:0.5:1.0 | 93.6 ~ 1281.6 | |

图 3 进一步比较了输入变量时延阶数 ($n_x = n_I = n_F = L = 1, 2, 3$) 和隐层神经元数目 ($n_h = 5, 10, 15, 20$) 分别取不同值时 NARX 网络模型的训练和验证误差结果。随着时延阶数 L 的增大 模型输入的动态信息量增加 同时隐层神经元数目的增加也提高了模型的学习能力 因此可降低模型的预测误差。当时延阶数由 $L = 2$ 增大为 $L = 3$ 时 模型的性能提高有限。为权衡 NARX 网络模型的结构复杂度和预测精度 取 $L = 2$ 。




图 2 不同输入变量组合下的模型误差分析

Fig.2 RMSE analysis for different input combinations ($n_x = n_{\dot{x}} = n_I = 0, n_F = 1, n_h = 15$)




图 3 不同输入变量时延阶数下的模型误差分析

Fig.3 RMSE analysis for different numbers of input lags

模型输入层结构确定之后,需要进行隐层神经元数目 n_h 的优化选择。图 4 显示了单隐层 NARX 网络模型分别设计有 5 ~ 25 个隐层神经元时的训练和验证统计误差。随着 n_h 值的增大,网络参数数量也随之增加,因此,网络具有更强的学习能力,减小了训练误差。但是,过于冗余的网络模型将可能导致过拟合现象。通过贝叶斯正则化对于模型参数大小和数量增长的控制,则可有效地降低验证误差的过度增长。通过权衡图 4 中训练和验证误差结果,隐层神经元个数选为 18。

综上,通过对模型结构和预测精度的比较和权衡,优化后的磁流变阻尼器 NARX 网络模型具有 8 个输入神经元、18 个隐层神经元和 1 个输出神经元的结构。




图 4 不同隐层神经元数目下的模型误差分析 ($L=2$)

Fig. 4 RMSE analysis for different numbers of hidden neurons

4 模型验证

4.1 周期激励下的泛化能力

采用表 1 的 3 组周期激励下的测试数据对优化设计的贝叶斯正则化 NARX 网络模型进行泛化性能检验。表 2 给出了该模型在测试数据下的预测结果,同时与采用非正则化的普通 LM 算法得到的 NARX 网络模型误差进行比较。模型预测误差由式 (15) 计算得到。由表 2 可见,贝叶斯 NARX 网络模型的均方根误差值基本上低于相应的实测阻尼力均方根值(表 1)的 5%;同时,相比 LM 算法,采用贝叶斯学习算法可提高模型的预测精度至 30% ~ 75%,验证了贝叶斯正则化的 NARX 网络模型具有很好的泛化能力。由图 5 可知,贝叶斯 NARX 网络模型预测的位移-阻尼力和速度-阻尼力滞回曲线与实测结果吻合很好,表明了 NARX 网络模型对非训练样本的准确预测能力。

4.2 随机激励下的泛化能力

为保证磁流变阻尼器模型在控制应用中的准确预测能力,需获得覆盖磁流变阻尼器工作范围的丰富动态响应信息进行建模。为此,将磁流变阻尼器安装到置于振动台上的钢框架结构上,由振动台产生有限带

表 2 周期激励下 NARX 网络模型泛化能力

Tab. 2 Generalization performance of NARX network models in harmonic excitation scenarios

| 测试样本 | 预测误差 | 电流/A | | | | |
|------|-------------------|-------|-------|-------|-------|-------|
| | | 0 | 0.25 | 0.5 | 0.75 | 1.0 |
| 1 | δ_{rms1}/N | 3.69 | 7.94 | 11.46 | 16.29 | 16.11 |
| | δ_{rms2}/N | 3.94 | 11.77 | 17.06 | 23.32 | 28.97 |
| | $\Delta_{rms}/\%$ | 6.35 | 32.54 | 32.83 | 30.15 | 44.39 |
| 2 | δ_{rms1}/N | 26.91 | 12.35 | 17.80 | 24.29 | 31.32 |
| | δ_{rms2}/N | 29.64 | 43.10 | 70.83 | 85.05 | 92.47 |
| | $\Delta_{rms}/\%$ | 9.21 | 71.35 | 74.87 | 71.44 | 66.13 |
| 3 | δ_{rms1}/N | 13.34 | - | 20.55 | - | 31.96 |
| | δ_{rms2}/N | 22.64 | - | 45.59 | - | 69.37 |
| | $\Delta_{rms}/\%$ | 41.08 | - | 54.92 | - | 53.93 |

注: δ_{rms1} 和 δ_{rms2} 分别为贝叶斯正则化模型和非正则化模型的均方根预测误差; $\delta_{rms} = (\delta_{rms2} - \delta_{rms1}) / \delta_{rms2} \times 100\%$

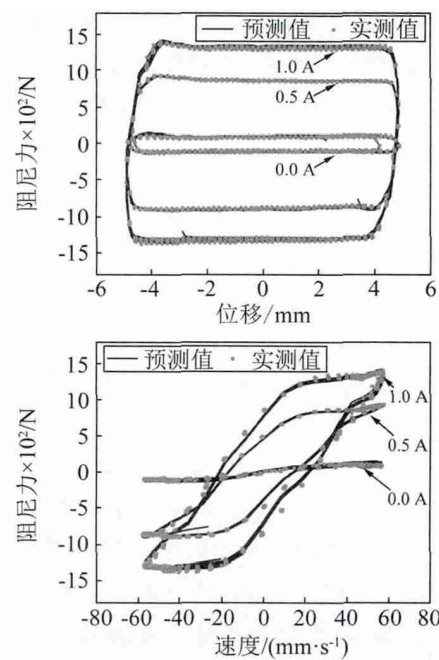


图 5 周期测试样本 3 下预测和实测滞回特性曲线的比较

Fig. 5 Comparison between predicted and measured hysteresis loops for harmonic testing data set 3

宽的白噪声基础振动加速度信号,使磁流变阻尼器在随机振动状态下工作,同时对其施加带限白噪声的随机电流,以获取其动态响应。图 6 显示了在幅值为 0.2 g、频率范围为 0.8 ~ 10 Hz 的基础加速度激励以及输入电流幅值为 0 ~ 2 A、频率范围为 0 ~ 10 Hz 的情况下,磁流变阻尼器的活塞位移、速度、电流和阻尼力历程。利用该组数据分别对上述贝叶斯正则化模型和非正则化模型进行重新学习训练,并采用表 3 的 3 组不同输入工况下的测试数据进行泛化性能比较和检验。

表 4 比较了随机激励下贝叶斯正则化模型和非正则化模型对测试数据的预测误差。可见,贝叶斯正则化模型对各组测试数据的阻尼力的均方根预测误差均小于相应的实测阻尼力均方根值(表 3)的 5%。图 7

显示了贝叶斯正则化 NARX 网络模型对测试样本 3 的磁流变阻尼力的预测结果及误差时程,图 8 比较了相应的预测和实测位移-阻尼力、速度-阻尼力滞回特性曲线,可见模型预测值与测量值吻合很好。此外,与非正则化模型相比,贝叶斯正则化模型的预测误差减小了 60% 以上,大大提高了磁流变阻尼器模型的泛化能力。




图 6 磁流变阻尼器在随机激励下的动态响应
Fig. 6 Random responses of MR damper

表 3 NARX 网络模型测试的随机数据样本

Tab. 3 Random testing data sets for NARX network model

| 序号 | 输入激励 | | 类型 | 输入电流 | | 阻尼力 RMS/N |
|----|------|--------|-------|------|-------|-----------|
| | 幅值/g | 频率/Hz | | 幅值/A | 频率/Hz | |
| 1 | 0.20 | 0.5-10 | 直流 | 1.25 | - | 939.4 |
| 2 | 0.12 | 0.5-10 | Chirp | 0-2 | 0.1-5 | 671.0 |
| 3 | 0.15 | 0.5-10 | 随机 | 0-2 | 0-10 | 741.3 |

表 4 随机激励下 NARX 网络模型泛化能力

Tab. 4 Generalization performance of NARX network models in random excitation scenarios

| 测试样本 | δ_{rms1} /N | δ_{rms2} /N | δ_{rms} /% |
|------|--------------------|--------------------|-------------------|
| 1 | 24.96 | 64.37 | 61.23 |
| 2 | 27.99 | 77.59 | 63.93 |
| 3 | 21.31 | 57.62 | 63.02 |

注: δ_{rms1} 和 δ_{rms2} 分别为贝叶斯正则化模型和非正则化模型的均方根预测误差; $\delta_{rms} = (\delta_{rms2} \times \delta_{rms1}) / \delta_{rms2} \times 100\%$




图 7 随机测试样本 3 下磁流变阻尼力预测和实测时程的比较

Fig. 7 Comparison between predicted and measured damper forces for random testing data set 3

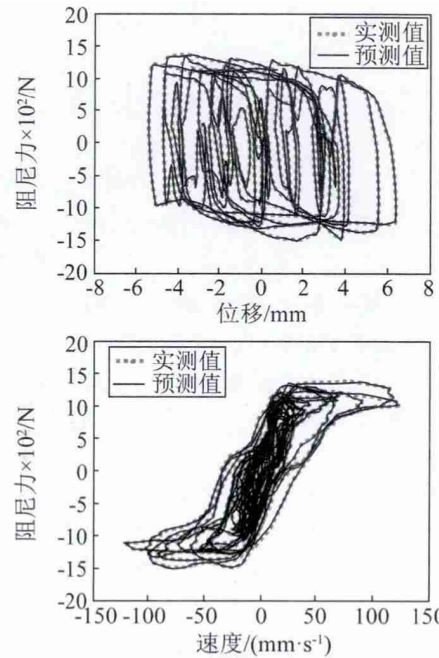


图 8 随机测试样本 3 下预测和实测滞回特性曲线的比较

Fig. 8 Comparison between predicted and measured hysteresis loops for random testing data set 3

5 结论

本文利用磁流变阻尼器的动态测试数据,建立基于贝叶斯推理的 NARX 网络技术的磁流变阻尼器非参数化模型。为保证磁流变阻尼器模型在控制应用中的有效性和可靠性,从网络结构优化和学习算法相结合的角度来提高 NARX 网络的泛化性能。研究结果表明:

- (1) NARX 网络结构的合理设计及选取有利于获得结构简单、泛化性能高、计算速度快的动态模型;
- (2) 基于贝叶斯推理的 NARX 网络模型能够准确描述磁流变阻尼器在周期激励下的非线性动力学行为,以及准确预测其在随机激励下的阻尼力输出;
- (3) 由于贝叶斯正则化能有效控制网络的复杂度、减少过拟合,由此得到的 NARX 网络模型相比非正则化模型具有很好的泛化能力,有利于保持和改善智能磁流变控制系统的有效性、稳定性和鲁棒性。

参考文献

[1] CATERINO N, SPIZZUOCO M, OCCHIUZZI A. Promptness and dissipative capacity of MR dampers: experimental investigations [J]. Structural Control and Health Monitoring, 2013, 20(12): 1424-1440.

[2] SPENCER B F, DYKE S J, SAIN M K, et al. Phenomenological model for magnetorheological dampers [J]. Journal of Engineering Mechanics, 1997, 123(3): 230-238.

[3] DOMÍNGUEZ-GONZÁLEZ A, STIHARU I, SEDAGHATI R. Practical hysteresis model for magnetorheological dampers [J]. Journal of Intelligent Material Systems and Structure, 2014, 25(8): 967-979.

(下转第 167 页)

理工大学 2002: 2-6.

[4] NECHITAILO N V ,BATRA R C. Penetration/perforation of aluminum , steel and tungsten plates by ceramic rods [J]. Computers & Structures ,1998 ,66 (5) : 571 - 583.

[5] NECHITAILO N V. Advanced high-speed ceramic projectiles against hard targets [J]. IEEE Trans Magnet , 2009 ,45(1) : 614 - 619.

[6] 付建平 杨金龙 印立魁 ,等. 氧化锆陶瓷子弹的高速冲击动态性能[J]. 硅酸盐学报 2016 44(2) : 346 - 352. FU Jianping , YANG Jinlong , YIN Likui , et al. Dynamic properties of Zirconia ceramic bullets under high-speed impact [J]. Journal of the Chinese Ceramic Society , 2016 , 44

(2) : 346 - 352.

[7] 荣吉利 , 诸葛迅 李健 ,等. 不同弹头形式的易碎弹冲击航空有机玻璃的数值分析[J]. 振动与冲击 2015 34(1) : 203 - 205. RONG Jili , ZHU Gexun , LI Jian , et al. Numerical analysis on fragile projectile with different warheads impacting against aviation organic glass [J]. Journal of Vibration and Shock , 2015 ,34(1) : 203 - 205.

[8] 白旭. 基于风险的球柱组合壳结构性能分析[D]. 哈尔滨: 哈尔滨工程大学 2013: 15 - 24.

[9] 刘鸿文 林建兴 ,曹曼玲. 板壳理论[M]. 杭州: 浙江大学出版社 ,1987: 373 - 407.

(上接第 151 页)

[4] AGUIRRE N , IKHOUANE F , RODELLAR J , et al. Parametric identification of the Dahl model for large scale MR dampers [J]. Structural Control and Health Monitoring , 2011 ,19(3) : 332 - 347.

[5] YANG F , SEDAGHATI R , ESMAILZADEH E. Development of LuGre friction model for large-scale magneto-rheological fluid damper [J]. Journal of Intelligent Material Systems and Structures ,2009 ,20(8) : 923 - 937.

[6] WANG D H , LIAO W H. Magnetorheological fluid dampers: a review of parametric modelling [J]. Smart Materials and Structures ,2011 ,20(2) : 023001.

[7] 王修勇 , 宋璨 , 陈政清 , 等. 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 Xiuyong , SONG Can , Chen Zhengqing , et al. Test of a MR damper and its modeling using neural network [J]. Journal of Vibration and Shock , 2009 , 28(4) : 42 - 46.

[8] 王戡 , 郑玲 , 刘非. 基于广义回归神经网络的磁流变减振器模型辨识 [J]. 汽车工程 , 2013 , 35(7) : 619 - 623. WANG Kan , ZHENG Ling , LIU Fei. Model identification of MR damper based on generalized regression neural network [J]. Automotive Engineering , 2013 , 35(7) : 619 - 623.

[9] ASKARI M , LI J , SAMALI B , et al. Experimental forward and inverse modelling of magnetorheological dampers using an

optimal Takagi-Sugeno-Kang fuzzy scheme [J]. Journal of Intelligent Material Systems and Structures , 2016 , 27(7) : 904 - 914.

[10] 潘公宇 , 杨海 , 徐腾跃 , 等. 磁流变阻尼器试验与建模研究 [J]. 振动与冲击 , 2015 , 34(6) : 36 - 40. PAN Gongyu , YANG Hai , XU Tengyue , et al. Tests and modeling for magneto-rheological (MR) dampers [J]. Journal of Vibration and Shock , 2015 , 34(6) : 36 - 40.

[11] CHEN S , BILLINGS S A , GRANT P M. Non-linear system identification using neural networks [J]. International Journal of Control , 1990 , 51(6) : 1191 - 1214.

[12] HORNIK K. Approximation capabilities of multilayer feedforward networks [J]. Neural Networks , 1991 , 4(2) : 251 - 257.

[13] SUYKENS J A K , VANDEWALLE J P L , DE MOOR B L R. Artificial neural networks for modeling and control of non-linear systems [M]. Boston: Kluwer Academic , 1996.

[14] MACKAY D J C. A practical Bayesian framework for backprop networks [J]. Neural Computation , 1992 , 4(3) : 448 - 472.

[15] HAGAN M T , MENHAJ M B. Training feedforward networks with the Marquardt algorithm [J]. IEEE Transactions on Neural Networks , 1994 , 6(5) : 989 - 993.