

神经网络在非线性减振器建模中的应用

Application of the Neural Network in Modeling of Nonlinear Shock Absorber

谈际清 杨平

(桂林电子工业学院机电与交通工程系 桂林541004)

Abstract In general the theory of modeling has its deficiency. In this paper, on the base of the data from the Experiment, Recursive Least Squares Algorithm(RLSA) of Radial Basis Function Network is applied to Model Identification. By this, a more closer mathematical model could be founded. At last, simulation is made to the mathematical model.

Keywords Neural network, Nonlinear, Model identification, Simulation

0 引言

理论建模是把具体的机械结构作出必要的简化与假设,根据力学原理建立数学模型。然而,在建模中采用的假设与简化和建模人员的经验水平密切相关,和对所研究的结构认识深度有关。实践里的数学模型与实际结构有一定的差异,一些理论的未知因素和建模时未考虑的因素甚至可能造成局部建模的错误^[1]。

一般而言,试验建模弥补了理论建模的不足,试验建模所得到的数学模型比理论建模获得的数学模型能更好地代表实际系统,所得的结果更加可靠准确。试验建模包括系统的参数识别技术,系统的描述方法不同识别的内容也不同。然而,物理参数识别技术尽管已经提出了各种各样的方法,但仍不太成熟,无法应用于实际工程中解决复杂结构问题。

神经网络从诞生之日起,由于其在解决非线性、不确定问题上独特的优越性,使其自发展之初就受到广泛的关注。BP算法虽然是目前应用最为广泛的一种模型,但其有自身的缺陷。本文应用一种改进的BP算法—径向基函数网络递推最小二乘学习算法,来说明神经网络在非线性减振器建模中的具体实现过程及其效果^[2]。

1 径向基函数网络递推最小二乘学习算法

径向基函数网络结构(RBFN)如图1所示,网络中的输入节点、隐层节点和输出节点数分别为N, L, M。其中隐层单元的作用相当于对输入模式进行一次变换,将低维的模式输入数据变换到高维空间内,以利于输出层进行分类识别。隐单元的变换作用实际上也可以看作是对输入数据进行特征提取。

首先定义至第k个迭代时刻的加权误差目标函数:




图1 径向基函数网络结构示意图

式中: λ —加权遗忘因子; t —输入模式矢量的次数标记; $d_j(t)$ —输出层第j个节点在第t个模式输入时对应的期望输出; $y_j(t)$ —输出层第j个节点在第t个模式输入时对应的实际输出。

λ 的作用是将过去样本对当前样本对当前估值的影响逐渐遗忘,使所估计的参数尽量反映当前时刻样本的特征。通常 λ 的取值范围为 $0 < \lambda < 1$, λ 取值越大,反映对过去的样本影响权重越大。

这里,假设径向基函数网络隐单元的变换函数为常用的高斯核,则其第i个单元对应的输出为:

$$z_i = \exp \left[-\frac{\sum_{j=1}^N (x_j(t) - s_{ij})^2}{2\sigma_i^2} \right] \quad 1 \leq i \leq L \quad (2)$$

式中: z_i —第i个隐单元的输出(即径向基函数); s_{ij} —隐层中第i个单元的变换中心矢量; σ_i —对应第i个中心矢量的控制参数(即形状参数)。

RBFN的输出层节点为线性处理单元,其第j个单元对应的输出为:

$$y_j(t) = \sum_{i=1}^L w_{ji}(k) z_i(t) + \theta_j(t) = \sum_{i=0}^L w_{ji}(k) z_i(t) = z^T(t) w_j(k) \quad 1 \leq j \leq M \quad (3)$$

式中 $w_{j0}(k) = \theta_j(k)$; $z_0(t) = 1$;

$$w_j(k) = [w_{j0}(k), w_{j1}(k), \dots, w_{jM}(k)]^T; z(T) =$$

$[x_0(t), x_1(t), \dots, x_M(t)]^T$ 。

将 $J(k)$ 对 $w_i(k)$ 微分, 令 $w_i(K) = \hat{w}_i(k)$, 由 $\frac{\partial J(k)}{\partial w_i(k)}$
 $= 0$ 可得

$$\sum_{i=1}^N \lambda^{k-i} z(t) z^T(t) \hat{w}_i(k) = \sum_{i=1}^N \lambda^{k-i} z(t) d_i(t) \quad (4)$$

将(4)式记成

$$\hat{R}(k) \hat{w}_i(k) = \hat{D}_i(k) \quad (5)$$

其中 $\hat{R}(k) = \sum_{i=1}^N \lambda^{k-i} z(t) z^T(t) = \lambda \hat{R}(k-1) + z(k) z^T(k)$

$$\hat{D}_i(k) = \sum_{i=1}^N \lambda^{k-i} z(t) d_i(t) = \lambda \hat{D}_i(k-1) + z(k) d_i(k) \quad (7)$$

记 $P(k) = \hat{R}^{-1}(k)$, 称为逆相关矩阵, 利用矩阵求逆引理可得连接权矢量的递推最小二乘关系式如下

$$g(k) = \frac{p(k-1)x(k)}{\lambda + x^T(k)p(k-1)x(k)} \quad (8)$$

$$p(k) = \frac{1}{\lambda} [p(k-1) - g(k)x^T(k)p(k-1)] \quad (9)$$

$$\hat{w}_i(k) = \hat{w}_i(k-1) + g(k)[d_i(k) - x^T(k)p(k-1)] \quad (10)$$

$$J(k) = \lambda J(k-1) + \frac{1}{2} \sum_{i=1}^N [d_i(k) - x^T(k)\hat{w}_i(k-1)]^2 \quad (11)$$

式中 $g(k)$ 称为 k 时刻的卡尔曼增益(KG)。(8)~(11)式即为径向基函数网络对应的递推最小二乘反向传播学习算法。

对于式(2)中的 α_i , 一般取经验公式:

$$\alpha_i = \frac{\beta^2}{N} (2M_i)^{-\beta/N} \quad (12)$$

式中, N —模式样本矢量的维数; β —确信系数 ($0 < \beta < 0.5$); M_i —第 i 个模式对应的训练样本。

通过上面的分析, 我们可得基于 RBFN 建模步骤如下:

(1) 给定初始权值矢量 $\hat{w}_i(0)$ ($1 \leq i \leq M$), 逆相关矩阵初始值 $p(0)$, 高斯形式参数 α_i , 差能量迭代终止值 ϵ 。

(2) 随机选取径向基函数中心矢量 S_i ($1 \leq i \leq NM$, NM 为训练样本的总数)。

(3) 按(2)式计算径向基函数 z_i ($1 \leq i \leq L$)。

(4) 迭代开始, $k=1$ 。

(5) 按(8)、(9)式分别计算卡尔曼增益矢量 $g(k)$ 与训练样本逆相关矩阵 $P(k)$ 的值。

(6) 计算输出端每个节点对应的误差信号:

$$e_i(k) = d_i(k) - x^T(k)\hat{w}_i(k-1), 1 \leq i \leq M \quad (13)$$

(7) 按(10)式计算更新得到的连接权值 $\hat{w}_i(k)$ ($1 \leq i \leq M$) 的值。

(8) 按(11)式计算累积误差能量 $J(k)$ 的值, 若 $J(k) \geq \epsilon$, 则 $k=k+1$, 转(3); 否则转(9)。

(9) 训练结束。

2 对非线性减振器建模

对于减振系统而言, 减振器性能的好坏, 直接影响减振系统的减振效果。而减振器本身结构复杂, 影响因素多, 且存在非线性, 基于常规方法难以建立较精确的数学模型。而采用神经网络方法, 由于其具有良好的非线性拟合特性, 为非线性减振器的建模提供了有效的依据。在实际建模时, 输入是某一组激励的频率, 输出是由传感器测得的加速度传递率。神经网络结构为 $24 \times 72 \times 1$, $\alpha_i = 50$, $\epsilon = 0.001$, 通过 Matlab 软件仿真, 可以得到某一减振器的试验模型和通过神经网络建立模型的误差曲线图(图2)。




图2 某一减振器的试验模型和神经网络建立模型的误差

以上曲线存在较大的误差, 是由多方面的因素引起的, 主要受试验条件的限制。

结束语 由减振器数学模型的建立, 可知神经网络在非线性模型的建立方面有其优势。由于本文中, 是在确定性输入激励下进行模式识别的, 但工程中输入的往往是随机激励, 有待进一步研究。

参考文献

- 付兰芳. 非线性振冲隔离器油阻阻尼特性研究及参数识别. [桂林电子工业学院硕士论文]
- 黄德双著. 神经网络模式识别系统理论. 北京: 电子工业出版社, 1996
- 郑思让, 等. 基于神经网络的纸张洗涤过程建模. 控制过程, 2000, 27(4)
- 段玉波, 等. 基于神经网络的加热器建模方法. 大庆石油学院学报, 2001, 25(3)