

DOI: 10.3969/j.issn.1001-3881.2012.23.002

基于最小二乘支持向量机的超磁致伸缩执行器磁滞非线性模型

李跃松¹, 朱玉川^{1,2}, 吴洪涛¹, 牛世勇³, 田一松³

(1. 南京航空航天大学机电学院, 江苏南京 210016; 2. 浙江大学流体动力与机电系统国家重点实验室, 浙江杭州 310027; 3. 西安飞行自动控制研究所, 陕西西安 710065)

摘要: 为准确模拟超磁致伸缩执行器的磁滞非线性特性, 基于最小二乘支持向量机与实验数据建立了超磁致伸缩执行器的模型, 结果显示所建模型都能够充分逼近非线性实验数据点。为提高模型的求解速度, 仅选用一半的实验数据建立了小样本模型, 并与神经网络所建小样本模型对比, 结果表明: 基于最小二乘支持向量机所建模型的位移预测误差小于 1.2 μm , 而基于神经网络所建模型的位移预测误差大于 1.5 μm 。

关键词: 超磁致伸缩; 磁滞非线性; 最小二乘支持向量机; 神经网络

中图分类号: TH113.1 **文献标识码:** A **文章编号:** 1001-3881 (2012) 23-004-3

Hysteresis Nonlinearity Model of Giant Magnetostrictive Actuator Based on Least Squares Support Vector Machine

LI Yuesong¹, ZHU Yuchuan^{1,2}, WU Hongtao¹, NIU Shiyong³, TIAN Yisong³

(1. College of Mechanical and Electrical Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing Jiangsu 210016, China; 2. The State Key Lab of Fluid Power Transmission and Control, Zhejiang University, Hangzhou Zhejiang 310027, China; 3. Flight Automatic Control Research Institute, Xi'an Shaanxi 710065, China)

Abstract: The model of giant magnetostrictive actuator based on least squares support vector machine and the experimental data was developed to describe the hysteresis nonlinearity of giant magnetostrictive actuator. The results show that least squares support vector machine can fit experimental data accurately. In order to solve the model quickly, only a half of experimental data were used for modeling, and the model based neural network was also built to make comparison with the model based on least squares support vector machine. The results show that the displacement error of model based on least squares support vector machine is less than 1.2 μm , the displacement error of model based on neural network is more than 1.5 μm .

Keywords: Giant magnetostrictive; Hysteresis nonlinearity; Least squares support vector machine; Neural network

稀土超磁致伸缩执行器 (Giant Magnetostrictive Actuator, GMA) 具有响应快、精度高、承载能力强等优点, 在精密加工、水声换能、主动减震等需要快速反应或精确定位的控制系统中, 有着广泛的应用前景^[1]。但因磁滞的影响, GMA 的输出呈现严重的非线性, 为提高 GMA 的定位精度和线性度, 需要建立 GMA 的模型对其非线性进行补偿。

最小二乘支持向量机 (Least Squares Support Vector Machine, LS-SVM) 能够逼近任意复杂的非线性系统, 与神经网络相比, 无“过学习”、“欠学习”现象, 且模型泛化性好、求解速度快、所需实验样本

少^[2], 因此基于 LS-SVM 能够建立精度与模型求解速度综合最优的 GMA 磁滞非线性模型。

1 LS-SVM 建模原理

对于给定的建模样本集

$$S = \{ s_i | s_i = (x_i, y_i) \quad x_i \in \mathbf{R}^n \quad y_i \in \mathbf{R} \quad i = 1, 2, \dots, l \} \quad (1)$$

通过 $x \rightarrow \phi(x)$ 的非线性映射后, 可利用 $\phi(x)$ 的线性函数

$$y(x) = w\phi(x) + b \quad (2)$$

对建模样本集拟合。

收稿日期: 2011-10-19

基金项目: 国家自然科学基金资助项目 (51175243, 50805080); 航空科学基金资助项目 (20110752006); 流体动力与机电系统国家重点实验室 2011 年度开放基金资助项目 (GZKF-201116); 江苏省普通高校研究生科研创新计划资助项目 (CXZZ11_0196)

作者简介: 李跃松 (1985—), 男, 博士研究生, 研究方向为机电控制及自动化。E-mail: liyaosong707@163.com。通信作者: 朱玉川, E-mail: meeyczhu@nuaa.edu.cn。

式中: x_i 为输入数据, y_i 为输出数据, $\phi(x)$ 是 x 的非线性特征映射, w 和 b 是待求的回归参数。

根据结构风险最小化原则, 式 (2) 的回归问题可转化为如下的约束优化问题

$$\begin{cases} \min J(w, \varepsilon) = \frac{1}{2} w \cdot w^T + \gamma \sum_{i=1}^l \varepsilon_i^2 \\ \text{s. t. } y_i = w\phi(x_i) + b + \varepsilon_i \quad i=1, 2, \dots, l \end{cases} \quad (3)$$

式中: ε_i 为误差, γ 为惩罚因子。

用拉格朗日法求解式 (3) 的优化问题, 建立拉格朗日函数

$$L(w, b, \varepsilon, \alpha) = \frac{1}{2} w \cdot w^T + \gamma \sum_{i=1}^l \varepsilon_i^2 - \sum_{i=1}^l \alpha_i (w\phi(x_i) + b + \varepsilon_i - y_i) \quad (4)$$

由优化条件:

$$\begin{cases} \frac{\partial L}{\partial w} = w - \sum_{i=1}^l \alpha_i \phi(x_i) = 0 \\ \frac{\partial L}{\partial b} = - \sum_{i=1}^l \alpha_i = 0 \\ \frac{\partial L}{\partial \varepsilon_i} = 2\gamma \varepsilon_i - \alpha_i = 0 \\ \frac{\partial L}{\partial \alpha_i} = w\phi(x_i) + b + \varepsilon_i - y_i = 0 \end{cases} \quad (5)$$

化简, 消除 w, ε_i , 可得,

$$\phi(x_i) \sum_{i=1}^l \alpha_i \phi(x_i) + b + \frac{\alpha_i}{2\gamma} = y_i \quad (6)$$

根据 Mercer 条件, 存在映射函数 $\phi(\cdot)$ 使得核

表 1 GMA 输入输出实验样本数据及其归一化

电流/A	电流归一化	升程位移/ μm	升程位移归一化	回程位移/ μm	回程位移归一化
0	0	0	0	1.5	0.034 1
0.2	0.090 9	1.5	0.034 1	4.5	0.102 3
0.4	0.181 8	4	0.090 9	7.5	0.170 5
0.6	0.272 7	7	0.159 1	12	0.272 7
0.8	0.363 6	10	0.227 3	16.5	0.375 0
1.0	0.454 5	14	0.318 2	21	0.477 3
1.2	0.545 5	18	0.409 1	26	0.590 9
1.4	0.636 4	22	0.500 0	30	0.681 8
1.6	0.727 3	25	0.568 2	35	0.795 5
1.8	0.818 2	31.5	0.715 9	39	0.886 4
2.0	0.909 1	38	0.863 6	42.5	0.965 9
2.2	1.000 0	44	1.000 0	44	1.000 0

2.2 基于 LS-SVM 的 GMA 磁滞非线性模型

由式 (8) 建立的 GMA 磁滞非线性模型, 需求取决定适应误差最小化和平滑程度的惩罚因子及决定模型精度和泛化能力的核函数。为了提高模型精度与泛化性能, 核函数选取处理非线性样本较优的径向基函数^[3]

函数 $K(x_i, x_j) = \phi(x_i) \phi(x_j)$, 则式 (6) 可表示如下

$$A \cdot K = y \quad (7)$$

式中: $A = [b \ \alpha_1 \ \alpha_2 \ \dots \ \alpha_l], y = [0 \ y_1 \ y_2 \ \dots \ y_l]$,

$$K = \begin{bmatrix} 0 & 1 & \dots & 1 \\ 1 & K(x_1, x_1) + \frac{1}{\gamma} & \dots & K(x_1, x_l) \\ \vdots & \vdots & \dots & \vdots \\ 1 & K(x_l, x_1) & \dots & K(x_l, x_l) + \frac{1}{\gamma} \end{bmatrix}。$$

用最小二乘法求解式 (7) 中的回归系数 α_i 和偏差 b , 得非线性预测模型

$$y(x) = \sum_{i=1}^l \alpha_i K(x, x_i) + b \quad (8)$$

2 GMA 磁滞非线性模型

2.1 实验数据及其处理

实验所用超磁致伸缩棒长度 80 mm, 线圈匝数 1 400 匝, 在预压力为 488 N 情况下, 从 0 间隔 0.2 A 增大线圈电流到 2.2 A, 然后间隔 0.2 A 减小线圈中输入电流到 0, 实测 GMA 输出位移如表 1, 在建立 LS-SVM 磁滞模型之前, 需分别对电流、位移进行归一化处理, 归一化转换采用线性公式

$$Y_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (9)$$

式中: $X_i, Y_i, X_{\min}, X_{\max}$ 分别为电流 (或位移)、归一化结果、电流 (或位移) 的最小值与最大值。

$$K(x_i, x_j) = e^{(-|x_i - x_j|^2 / 2\sigma^2)} \quad (10)$$

式中: σ 为核宽度, γ 和 σ^2 可采用 MATLAB 中 LS-SVM 工具箱中的留一交叉验证法确定^[4]。

由表 1 知, 模型为单输入双输出, 为了提高模型精度, 分别建立升程段电流与位移的关系模型、回程段电流到与位移的关系模型。在保证建模样本的拟合

相对误差小于 1% 时, 按上述方法求解升程段与回程段式 (8)、(10) 中的参数如表 2 所示^[4], 所拟合建模样本如图 1 所示。

表 2 LS-SVM 非线性模型的参数取值

参数	升程	回程
γ	4 405. 1	445. 246 3
σ^2	1. 410 2	3. 333 4
α_1	6. 387 1	-4. 330 9
α_2	-17. 974 5	7. 089 9
α_3	-7. 757 7	-9. 089 9
α_4	58. 041 1	2. 614 1
α_5	-44. 829 0	3. 857 3
α_6	-21. 274 8	-0. 484 3
α_7	-3. 327 9	7. 907 0
α_8	129. 351 0	-14. 141 1
α_9	-183. 871 4	0. 796 0
α_{10}	107. 014 8	-0. 201 7
α_{11}	-23. 590 2	9. 934 5
α_{12}	1. 831 5	-3. 950 9
b	0. 169 6	-0. 107 8

由图 1 可以看出: 基于 LS-SVM 理论所建的模型可高精度地逼近 GMA 实验的非线性样本数据点。

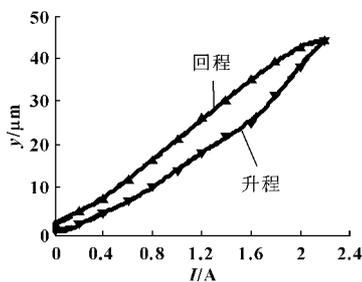


图 1 LS-SVM 对建模样本点的拟合曲线

小样本建模可以大幅度提高模型的求解速度, 因此, 在保证所需模型精度的前提下, 应采用小样本建模。为对 LS-SVM 小样本建模进行评估, 仅选取线圈电流为 0、0.4、0.8、1.2、1.6、2.0 A 时的实验数据作为建模样本, 剩余的实验数据作为模型检验样本, 在建模样本拟合的相对误差均小于 1% 时, 得检验样本的预测误差如表 3 所示。

表 3 LS-SVM 小样本模型对检验样本的预测误差

电流/A	升程位移误差/ μm	回程位移误差/ μm
0.2	0.350 6	-0.194 0
0.6	-0.276 0	-0.095 4
1.0	-0.675 5	0.119 2
1.4	-0.351 9	0.614 8
1.8	0.182 8	-0.002 4
2.2	-0.591 7	1.149 2

2.3 基于神经网络的 GMA 磁滞非线性模型

径向基函数神经网络 (RBF 网络) 是具有单隐层的三层前馈网络, 所需的训练时间比 BP 网络要少, 且 RBF 网络也能够以任意精度逼近任意连续函数^[5], 因此选取 RBF 网络建立的小样本 GMA 模型与基于 LS-SVM 建立的小样本 GMA 模型对比, 在建模样本拟合相对误差均小于 1% 时, 得检验样本的预测误差如表 4 所示。

表 4 RBF 网络小样本模型对检验样本的预测误差

电流/A	升程位移误差/ μm	回程位移误差/ μm
0.2	-1.500 0	-3.050 3
0.6	-3.135 5	-4.751 5
1.0	-4.336 7	-5.057 5
1.4	-4.607 7	-4.878 8
1.8	-7.343 8	-5.180 6
2.2	-7.285 3	-2.936 3

对比表 3 与表 4 可看出, LS-SVM 小样本模型的泛化能力强于 RBF 网络小样本模型。

3 结论

基于 LS-SVM 建模理论分别建立了 GMA 的全样本模型和小样本模型, 并与基于 RBF 神经网络所建的小样本模型对比, 得出: 基于 LS-SVM 建模理论可以任意精度地拟合 GMA 的实验样本点, 且所建立的小样本模型对 GMA 实验数据点的预测能力强于基于 RBF 神经网络所建的小样本模型。

参考文献:

- [1] 王传礼, 丁凡, 许贤良. GMA 喷嘴挡板阀参数设计及特性研究 [J]. 机床与液压 2006 (8): 69 - 103.
- [2] IPLIKCI Serdar. A Support Vector Machine Based Control Application to the Experimental Three-Tank System [J]. ISA Transaction 2010 49(3): 376 - 386.
- [3] ONG C J, SUI D, GILBERT E G. Enlarging the Terminal Region of Nonlinear Model Predictive Control Using the Support Vector Machine Method [J]. Automatica 2006 42 (6): 1011 - 1016.
- [4] DE BRABANTER K, KARSMARKERS P, OJEDA F, et al. LS-SVMlab Toolbox User's Guide: Version 1.7 [M]. Belgium: Katholieke Universiteit Leuven 2010: 23 - 38.
- [5] KUCUK I. Prediction of Hysteresis Loop in Magnetic Cores Using Neural Network and Genetic Algorithm [J]. Journal of Magnetism and Magnetic Materials, 2006, 305 (2): 423 - 427.