

文章编号 1004-924X(2009)07-1766-08

基于最小二乘支持向量回归机的 无线传感器网络目标定位法

刘桂雄, 张晓平, 周松斌

(华南理工大学机械与汽车工程学院, 广东 广州 510640)

摘要:针对 RSSI 测距误差直接影响无线传感器网络(WSN)目标定位准确度的问题,从目标位置与目标到传感器节点测距矢量的双射关系入手,建立最小二乘支持向量回归机(LSSVR)目标定位的数学模型,提出了一种基于 LSSVR 的 WSN 目标定位方法 TL-LSSVR。根据虚拟目标坐标和虚拟目标到传感器节点距离矢量构造出训练样本,通过确定学习区域及网格化采样获得训练样本集,采用 LSSVR 训练得到定位模型,将测量得到的距离矢量输入定位模型实现目标定位。对不同传感器节点数量以及不同节点分布情况下的 WSN 目标进行了定位实验。结果显示,对于节点随机分布的情况,TL-LSSVR 方法的定位误差比最小二乘法减小 21.0%~43.1%;对于节点均匀分布的情况,TL-LSSVR 方法的定位误差则减小 26.5%~48.7%,表明 TL-LSSVR 方法能有效减小测距误差对定位结果的影响,提高目标定位准确度。

关键词:无线传感器网络(WSN);目标定位;最小二乘支持向量回归机(LSSVR);回归建模

中图分类号:TP301 **文献标识码:**A

Target localization in wireless sensor networks based on LSSVR

LIU Gui-xiong, ZHANG Xiao-ping, ZHOU Song-bin

(School of Mechanical and Automotive Engineering,
South China University of Technology, Guangzhou 510640, China)

Abstract: In consideration of the effect of ranging errors of the RSSI method on the target localization accuracy in a Wireless Sensor Networks (WSN), a mathematical model of target localization based on Least Square Support Vector Regression (LSSVR) is established according to the double mapping between the target's coordinate and the distance vector measured from the target to sensor nodes. Furthermore, the target localization method based on LSSVR in the WSN, TL-LSSVR, is proposed. According to TL-LSSVR, the training samples are formed in accordance with the virtual target coordinate and the distance vector between the virtual target and the sensor nodes, and then the training sample sets are obtained by selecting learning areas and grid sampling. Moreover, the localization model can be trained using LSSVR and the target can be located by inputting the distance vector between the target and the sensor nodes into a localization model. The experiments of target localization in the WSN under different numbers and distributions of sensor nodes are performed. Experimental

收稿日期:2008-09-02; **修订日期:**2008-10-10.

基金项目: 粤港关键领域重点突破项目(No. 2007A30310004); 广东省科技攻关计划项目(No. 2007B010400046, No. 2006B12407003); 教育部新世纪优秀人才支持计划项目(No. NCET-08-0211)

results show that when sensor node distributes randomly, the target localization errors using the TL-LSSVR are reduced by 21.0%-43.1% compared with that of a least square estimation, and when sensor node distributes uniformly, the target localization errors are reduced by 26.5%-48.7%, which indicates that the target localization errors are reduced evidently, and the accuracy of target localization is improved.

Key words: wireless sensor network(WSN); target localization; least square support vector regression (LSSVR); regression modeling

1 引言

基于无线传感器网络(WSN)^[1]的目标定位是指部署在监测区域内的大量传感器节点通过信息感知、协作信号与信息处理的方式实现对目标位置的估计,它是解决特定环境中物理实体移动问题(如环境监测、入侵跟踪)的关键技术,也是近年来国内外研究的热点问题^[2-3]。目标定位有非测距定位和测距定位两种方法,非测距的定位方法^[4]利用节点间的连通关系实现定位,但定位准确度通常较低;基于测距的定位方法在测量得到3个以上不在同一直线的节点到目标的距离(或信号到达方向)后,通过最小二乘法可以估计目标位置。估计方法主要有到达方向法(AOA)、到达时间差法(TDOA)和接收信号强度指示法(RSSI)^[5]。其中,AOA法需要引入额外的硬件设备,增加成本和能耗;TDOA法用于宽带信号,通常需加装声波或超声波测量装置,且对传感器节点的放置有一定要求;目前主流方法是RSSI法,该方法根据接收信号强度测量节点到目标距离,相对其它方法更容易实现,因而实际中得到广泛应用^[6];但由于模型误差、多径效应、加性噪声等因素影响,RSSI法通常有较大距离测量误差,经最小二乘估计得到的目标定位误差也较大,从而导致目标定位准确度不足^[7]。综上所述,探索运用机器学习方法挖掘网络中潜在的有用信息实现目标定位,以减小测距误差对定位准确度的影响,将是一件有意义的工作。

近年来,在非线形回归估计问题中表现出优良性能的支持向量回归机(SVR)^[8-10]成为国内外的研究热点,它建立在统计学习理论上,在小样本情况下具有良好的泛化能力^[11]。文献[12]利用SVR对移动电话基站信号接收强度和移动

电话位置的关系进行建模,实现移动电话用户的目标定位,但该方法需预先实地测量若干组基站信号,若地域发生变化则需重新测量。本文在前期工作中,开展了利用最小二乘支持向量回归机(LSSVR)进行WSN传感器节点自定位研究^[13],取得了比已有方法更高的定位准确度,突破了文献[12]要求实地测量物理信号的局限性。文中探索利用LSSVR对未知节点坐标和它到已知节点距离矢量之间的非线性关系进行回归建模;将未知节点到锚节点的跳段距离之和输入到LSSVR节点自定位模型,实现了节点坐标估算;此外,还研究了增加LSSVR自定位模型中较小测距误差特征量权重的方法,进一步提高了定位准确度。基于LSSVR的目标定位与基于LSSVR的节点定位相比,不同之处在于它只需对局部网络区域进行学习及回归建模,学习区域(位置和大小)具有不确定性,不同定位时刻感知目标的传感器节点数量和分布又具有随机性。

本文拟解决以下几方面问题:(1)确定学习区域范围并建立LSSVR定位模型,利用该模型减小RSSI高斯分布测距误差对定位结果的影响;(2)证明目标位置与目标到传感器节点距离矢量之间存在双射关系;(3)分析学习区域、传感器节点数量和分布对定位结果的影响,优化LSSVR目标定位方法。

2 LSSVR回归定位建模

2.1 LSSVR目标定位的数学原理

图1为LSSVR目标定位示意图, $T(x_T, y_T)$ 为活动目标,感知距离为 R ; $S_i(x_i, y_i)$ ($i=1, 2, \dots, N$)为感知目标信息的传感器节点, $S_1(x_1, y_1)$ 为簇头节点CH。WSN目标定位就是根据 $S_i(x_i, y_i)$ 的坐标与 $S_i(x_i, y_i)$ 到目标 $T(x_T, y_T)$ 的

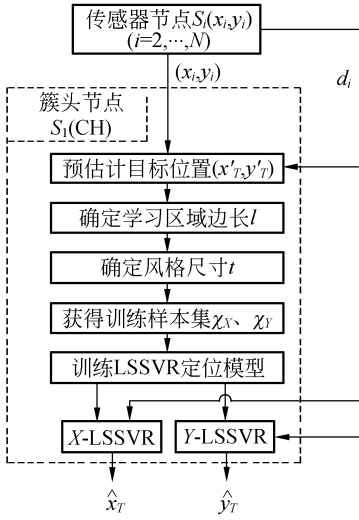


图 2 LSSVR 回归建模与定位

Fig. 2 Regression modeling and localization based on LSSVR

的最小二乘估计 (x_T', y_T') , 以 (x_T', y_T') 为几何中心确定学习区域 $Q = [x_{min}, x_{min} + l] \times [y_{min}, y_{min} + l]$;

(2) 虚拟目标位置采样: 用 $t \times t$ 的网格对 Q 进行网格化(如图 1 所示), 所有 M 个网格中心布置虚拟目标 $T_j'(x_j', y_j')$ ($j = 1, 2, \dots, M$), $T_j'(x_j', y_j')$ 到 $S_i(x_i, y_i)$ 的距离为 d_{ij}' , $T_j'(x_j', y_j')$ 对应的距离矢量 $\mathbf{V}_j' = [d_{1j}', d_{2j}', \dots, d_{Nj}']$;

(3) 获取训练样本集: 将 M 个虚拟目标 $T_j'(x_j', y_j')$ 对应的距离矢量 \mathbf{V}_j' 与 $T_j'(x_j', y_j')$ 的坐标构成训练样本集 $\chi_x = \{(\mathbf{V}_j', x_j') | j = 1, 2, \dots, M\}$, $\chi_y = \{(\mathbf{V}_j', y_j') | j = 1, 2, \dots, M\}$;

(4) 建立 LSSVR 定位模型: 根据 χ_x, χ_y 分别进行 LSSVR 回归建模, 对于训练样本集 χ_x 求解如下最优化问题^[14]:

$$\min_{\omega, \xi, b} J(\omega, \xi) = \frac{1}{2} \omega^T \omega + \gamma \frac{1}{2} \sum_{j=1}^M \xi_j^2, \quad (6)$$

s. t. $x_j' = \omega^T \cdot \phi(\mathbf{V}_j') + b + \xi_j, j = 1, 2, \dots, M$, 其中, $\phi(\cdot)$ 表示非线性映射函数, b 为偏差, ω 为权重向量, $\gamma > 0$ 为规则化参数, $\xi_j (j = 1, 2, \dots, M)$ 表示随机误差。

定义核函数 $K(\mathbf{V}_i', \mathbf{V}_j') = \phi(\mathbf{V}_i')^T \cdot \phi(\mathbf{V}_j')$ ($i, j = 1, 2, \dots, M$), $K(\mathbf{V}_i', \mathbf{V}_j')$ 满足 Mercer 条件, 以上问题转化为求解下式的未知数 α 和 b :

$$\begin{bmatrix} 0 & \bar{\mathbf{1}}^T \\ \bar{\mathbf{1}} & \Omega + \gamma^{-1} I \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{x}' \end{bmatrix}, \quad (7)$$

其中, $\mathbf{x}' = [x_1', x_2', \dots, x_M']$, $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_M]^T$, $\bar{\mathbf{1}} = [1_1, 1_2, \dots, 1_M]^T$, $\Omega_{i,j} = \varphi(\mathbf{V}_i', \mathbf{V}_j')$ 。可以得到:

$$\hat{x}_T = f(\mathbf{V}) = \sum_j^M \alpha_j K(\mathbf{V}, \mathbf{V}_j') + b. \quad (8)$$

这就是定位模型 X-LSSVR。同理, 由训练样本集 χ_y 可得到定位模型 Y-LSSVR;

(5) 目标定位: 将传感器节点 $S_i(x_i, y_i)$ 测量得到的距离矢量 $\mathbf{V} = [d_1, d_2, \dots, d_N]$ 输入 X-LSSVR 和 Y-LSSVR 分别得到输出值 \hat{x}_T, \hat{y}_T , 将 (\hat{x}_T, \hat{y}_T) 作为 $T(x_T, y_T)$ 的位置估计。

3 基于 LSSVR 的 WSN 目标定位方法

3.1 基于 LSSVR 的 WSN 目标定位方法

下面重点分析基于 LSSVR 的 WSN 目标定位方法(TL-LSSVR)。该方法信息交换的过程包括目标信息感知、数据汇聚、建立定位模型和定位实施 4 个阶段。

(1) 目标信息感知阶段: 由传感器节点 $S_i(x_i, y_i) (i = 1, 2, \dots, N)$ 感知目标信息, 得到目标距离 d_i ;

(2) 数据汇聚阶段: 传感器节点 $S_i(x_i, y_i)$ 将自身坐标以及 $S_i(x_i, y_i)$ 到目标测量距离的信息传送到簇头节点 CH;

(3) 建立定位模型阶段: CH 根据接收到的信息, 利用最小二乘法预估计目标位置 (x_T', y_T') , 以 (x_T', y_T') 为几何中心确定学习区域 Q , 根据 2.3 节所述方法建立 X-LSSVR 和 Y-LSSVR 定位模型;

(4) 定位阶段: CH 将距离矢量 $\mathbf{V} = [d_1, d_2, \dots, d_N]$ 分别输入定位模型 X-LSSVR 和 Y-LSSVR, 将输出 (\hat{x}_T, \hat{y}_T) 作为目标坐标的估计值。

3.2 WSN 目标定位能耗分析

WSN 目标定位的能耗主要包括通信能耗和计算能耗, 通信能耗是 WSN 节点能耗的主要方面^[15]。目标定位时, 感知目标信息的传感器节点发送信息到 CH 进行融合, 主要包括传感器节点自身坐标与节点到目标的测量距离, 这些均是 TL-LSSVR 方法、最小二乘估计定位方法的基础。故两种方法在通信量和通信能耗方面基本相同。但 TL-LSSVR 方法的计算量方面较大, 当感知目标的传感器节点数量 N 一定时, 计算时间与

训练样本数量 M 的二次方成正比。随着微电子技术的发展,节点运算能力会不断增强,相同算法在 WSN 节点的计算时间不断减少,计算能耗会逐渐降低。


4 实验

在 MATLAB 平台上对 TL-LSSVR 目标定位方法的性能进行验证。设目标 $T(50 \text{ m}, 50 \text{ m})$ 的感知距离 $R=50 \text{ m}$, 传感器节点 $S_i(x_i, y_i)$ 到目标测距噪声 $\epsilon_i \sim N(0, \sigma_i^2)$ ($\sigma_i = 0.2 \sqrt{(50-x_i)^2 + (50-y_i)^2}$) (m), 目标定位误差 E_i 定义为目标估计位置和真实位置的欧氏距离与目标感知距离 R 的比值。选用 RBF 核函数 $K(\mathbf{V}_i', \mathbf{V}_j') = e^{-\|\mathbf{V}_i' - \mathbf{V}_j'\|^2 / \delta^2}$, 其中 $\delta^2 = 8$, 规则化参数 $\gamma = 100$, 学习区域 Q 边长为 l , 网格宽度为 t 。在传感器节点 $S_i(x_i, y_i)$ 一定情况下, 下面分别进行 100 次蒙特卡洛计算, 分析传感器节点数量 $N=16$ 、节点分布(随机分布和均匀分布)、区域边长 l 对 TL-LSSVR 方法和最小二乘法(LSE)目标定位误差的影响。

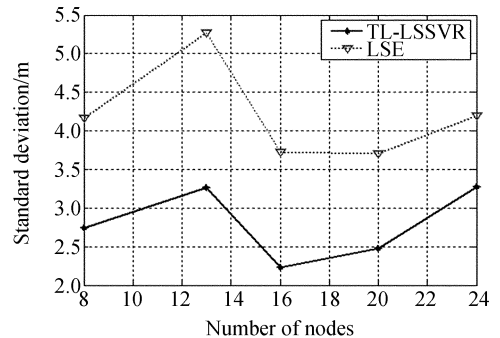
图 3 为传感器节点 $N=16$ 的随机分布, $l=30 \text{ m}$, $t=10 \text{ m}$, 100 次蒙特卡洛计算所得到的 WSN 目标定位误差分布曲线。可以看出, TL-LSSVR 方法、LSE 方法的目标定位误差均为一定变化范围的随机量, 并且 TL-LSSVR 方法中有 93 个定位误差值小于 LSE 方法, TL-LSSVR 方法误差值的标准差 2.24 m 小于 LSE 方法的 3.74 m , 这一定程度上说明 TL-LSSVR 方法比 LSE 方法在目标定位误差方面具有更高的稳定

性及和可靠性。

图 4(a)、(b) 为不同数量传感器节点随机分布时目标定位误差的均值和标准差曲线。结果表明, TL-LSSVR 方法定位误差均值相比 LSE 方法减小 $21.0\% \sim 43.1\%$, 误差值标准差减小 $21.9\% \sim 40.1\%$ 。



(a)



(b)

图 4 不同传感器节点数量下定位误差及标准差(随机分布)

Fig. 4 Average localization errors and standard deviations when sensors distribute randomly ($l=30 \text{ m}$, $t=10 \text{ m}$)

图 5(a)、(b) 为不同数量传感器节点均匀分布时目标定位误差的均值和标准差曲线。其中, TL-LSSVR 方法定位误差均值相比最小二乘法减小 $26.5\% \sim 48.7\%$, 误差值标准差减小 $31.4\% \sim 46.7\%$ 。

由图 4、图 5 可以发现, 在感知目标信息的传感器节点数量和分布不同情况下, TL-LSSVR 方法的定位准确度和定位结果的稳定性相比于 LSE 方法具有明显提高。

图 6(a)、(b) 为 $t=10 \text{ m}$ 、不同学习区域边长为 l 时, TL-LSSVR 方法的定位误差均值和标准差曲线。




图 3 定位误差分布曲线

Fig. 3 Distribution curves of localization errors

($l=30 \text{ m}$, $t=10 \text{ m}$, $N=16$)

由图 6 可见,增加边长 l , TL-LSSVR 方法定位误差逐渐减小;当 $l > 30$ m 时, TL-LSSVR 方法定位误差均值和标准差逐渐趋于稳定。考虑到


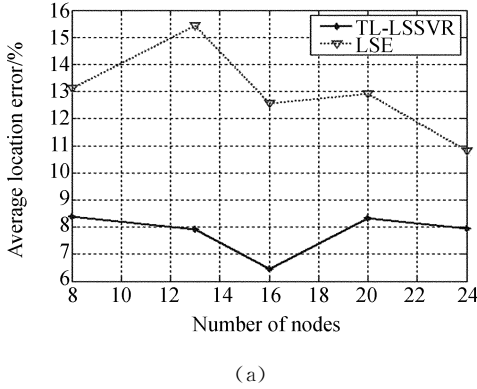


图 5 不同传感器节点数量下定位误差及其标准差 (均匀分布)
Fig. 5 Average localization errors and standard deviations when sensors distribute uniformly ($l = 30$ m, $t = 10$ m)


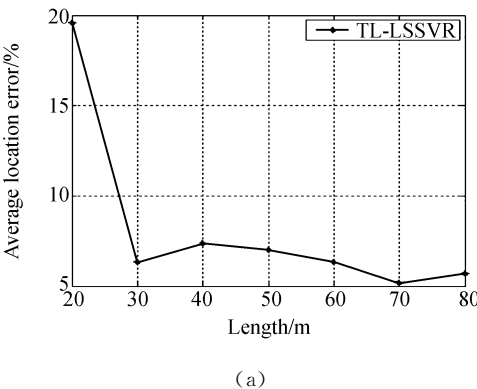


图 6 不同学习区域边长下目标定位误差均值及标准差
Fig. 6 Average localization errors and standard deviations in different side lengths of learning area ($t = 10$ m, $N = 16$)

t 一定的情况下,增加边长 l 会增大训练样本数量,从而导致计算量增加,取 $l = 30$ m 较合理。

5 结 论

(1) 本文提出了活动目标到各传感器节点距离向量与目标坐标之间的非线性关系,通过 LSSVR 拟合出相应的映射(即满足应用 SVR 进行回归目标位置估计建模的基本条件),从而能充分利用 SVR 良好的噪声容忍能力和泛化能力,大大减少测距误差对位置估计结果的影响;

(2) TL-LSSVR 方法根据虚拟目标坐标、虚拟目标到传感器节点距离矢量构造出训练样本,通过确定学习区域及网格化采样获得训练样本集,采用 LSSVR 训练得到定位模型,将测量得到的距离矢量输入定位模型实现目标定位;

(3) 对不同传感器节点数量以及不同节点分布情况下的 WSN 目标进行定位实验。结果表明,对于节点随机分布的情况,TL-LSSVR 方法的定位误差相比最小二乘法减小 21.0%~43.1%;对于节点均匀分布的情况,TL-LSSVR 方法的定位误差则减小 26.5%~48.7%。TL-LSSVR 方法能有效减小测距误差对定位结果的影响,提高目标定位准确度。

参考文献:

[1] 马奎, 黄河清, 沈杰, 等. 基于混合汇聚节点的无

线传感器网络数据收集方法[J]. 光学精密工程, 2008,16(9):1752-1758.

MA K, HUANG H Q, SHEN J, et al.. A data

- collection method with hybrid sinks in wireless sensor networks[J]. *Opt. Precision Eng.*, 2008, 16(9):1752-1758. (in Chinese)
- [2] LIU X Q, ZHAO G, MA X L. Target localization and tracking in noisy binary sensor networks with known spatial topology[C]. *Proc. of IEEE International Conference on Acoustics, Speech and Signal Processing, Honolulu, HI*, 2007, 2: 1029-1032.
- [3] LEE J, CHO K, LEE S, *et al.*. Distributed and energy-efficient target localization and tracking in wireless sensor networks[J]. *Computer Communications*, 2006, 29(13-14):2494-2505.
- [4] HE T, HUANG C D, BLUM B M, *et al.*. Range-free localization and its impact on large scale sensor networks [J]. *ACM Transactions on Embedded Computing System (TECS)*, 2005, 4(4):877-906.
- [5] HARA S, ANZAI D. Experimental performance comparison of RSSI and TDOA-based location estimation methods[C]. *Proc. of IEEE 2008 Vehicular Technology Conference, Singapore*, 2008: 2651-2655.
- [6] NIU R, VARSHNEY P K. Target location estimation in sensor networks with quantized data[J]. *IEEE Transactions on Signal Processing*, 2006, 54(12):4519-4528.
- [7] HARA S, ANZAI D. Comparison of three estimation methods for RSSI-based localization with multiple transmit antennas[C]. *Proc. of Mobile Adhoc and Sensor Systems 2007 IEEE International Conference, Pisa*, 2007:1-3.
- [8] 赵吉文,刘永斌,苏亚辉,等. 新型直线电机支持向量机非线性建模研究[J]. *光学 精密工程*, 2006, 14(3):450-455.
ZHAO J W, LIU Y B, SU Y H, *et al.*. Research on SVM model of a novel cylinder linear motor[J]. *Opt. Precision Eng.*, 2006, 14(3):450-455. (in Chinese)
- [9] 赵吉文,刘永斌,孔凡让,等. 基于 SVM 和遗传算法的新型直线电机结构参数优化[J]. *光学 精密工程*, 2006, 14(5):870-875.
ZHAO J W, LIU Y B, KONG F R, *et al.*. Parameter optimization of novel cylinder type linear motor based on SVM and genetic algorithm[J]. *Opt. Precision Eng.*, 2006, 14(5):870-875. (in Chinese)
- [10] 林伟青,傅建中,许亚洲,等. 基于 LS-SVM 与遗传算法的数控机床热误差辨识温度传感器优化策略[J]. *光学 精密工程*, 2008, 16(9):1682-1687.
LIN W Q, FU J ZH, XU Y ZH, *et al.*. Optimal sensor placement for thermal error identification of NC machine tool based on LS-SVM and genetic algorithm[J]. *Opt. Precision Eng.*, 2008, 16(9):1682-1687. (in Chinese)
- [11] IPLIKCI S. Support vector machines-based generalized predictive control [J]. *Journal of Robust and Nonlinear Control*, 2006, 16(17):843-862.
- [12] WU H L, NG J K, KARL R, *et al.*. Location estimation via support vector regression [J]. *Mobile Computing*, 2007, 6(3):311-321.
- [13] 周松斌. 基于 SVR 回归建模的无线传感器网络定位理论和算法[D]. 广州:华南理工大学, 2008.
ZHOU S B. *WSN localization theory and method based on SVR regression modeling* [D]. Guangzhou: South China Univ. of Technology, 2008.
- [14] ZHANG M G, LI Z M, LI W H. Study on least squares support vector machines algorithm and its application[C]. *Proc. of International Conference on Tools with Artificial Intelligence, Hong Kong, China*, 2005: 686-688.
- [15] JIA Y F, DONG T L, SHI J. Analysis on energy cost for wireless sensor networks[C]. *Proc. of Second International Conference on Embedded Software and Systems, Xian, China*, 2005: 144-151.

作者简介:



刘桂雄(1968—),男,广东揭阳人,教授,博士生导师,1990年、1995年在重庆大学分别获得学士和博士学位,主要从事智能传感技术、现代检测技术与网络化控制的研究。E-mail: megxliu@scut.edu.cn



周松斌(1978—),男,广东潮州人,博士,副研究员,2005年、2008年于华南理工大学分别获得硕士和博士学位,主要从事智能检测与网络化控制、无线传感器网络及人工智能的研究。E-mail: zhousongbin@126.com



张晓平(1981—),男,山西大同人,博士研究生,2003年于武汉大学获得学士学位,2007年于太原理工大学获得硕士学位,主要从事无线传感器网络目标跟踪的研究。E-mail: whuicerain@sina.com

●下期预告

压电陶瓷管微位移测量与非线性校正简易方法

董维杰¹,宋志杨¹,崔岩²

- (1. 大连理工大学电子与信息工程学院,辽宁大连 116023;
2. 大连理工大学辽宁省微纳米技术及系统重点实验室,辽宁大连 116023)

为了对 AFM 中压电陶瓷管扫描位移进行非线性校正,提出了一种微位移测量与校正方法。采用涡流位移传感器测量微位移,通过 100 倍放大提高检测灵敏度;产生 X/Y 方向控制电压的 D/A 和采集微位移信号的 A/D 均为 16 位,最高位移分辨率计算值为 0.4 nm。根据原子力显微镜中压电陶瓷管的工作特点,利用确定扫描范围下测量得到的位移-电压关系,通过对等间隔像素点施加所对应的非等间隔控制电压序列的方法进行非线性校正,依据像素点精度要求通过插值算法获得了控制电压序列。系统采用 LabVIEW 虚拟仪器技术,校正后压电陶瓷管最大位移滞回偏差从 10.1% 降为 0.4%。实验表明:扫描频率和扫描像素分辨率调节方便,同时校正算法复杂度也有所降低。