

文章编号: 1001-0920(2009)06-0802-05

## 基于混沌优化支持向量机的轧制力预测

陈治明, 罗 飞, 黄晓红, 许玉格

(华南理工大学 自动化科学与工程学院, 广州 510640)

**摘 要:** 针对带钢热连轧轧制力的精确预测问题, 提出一种基于最小二乘支持向量机模型的预测算法. 在分析最小二乘支持向量机数学预测模型的基础上, 提出一种改进的结合遗传算法的变尺度混沌优化方法, 以进行最优模型参数的搜索. 利用实测在线数据对模型进行训练并进行轧制力预测. 仿真结果表明, 利用该方法可使轧制力预测精度得到提高, 平均误差率从 BP 神经网络的 10% 降到 5% 以下, 为进一步提高热连轧厚度控制精度提供了一种有效方法.

**关键词:** 热连轧; 轧制力预测; 支持向量机; 混沌优化

中图分类号: TG335

文献标识码: A

## Rolling force prediction based on chaotic optimized support vector machine

CHEN Zhi2ming, LUO F ei, H UANG Xiao2hong, XU Yu2ge

(College of Automation Science and Engineering, South China University of Technology, Guangzhou 510640, China.

Correspondent: CHEN Zh2ming, E2mail: z\_m\_chen@163.com)

**Abstract:** Aiming at the exact prediction problem of rolling force in hot strip rolling mills, a prediction algorithm based on least square support vector machine is proposed. The prediction model of least square support vector machine is mathematically analyzed. And an improved multiscale chaotic optimization algorithm combined with the genetic algorithm is proposed to optimize the model parameters. By using online data obtained from the factory, the model is trained and used for rolling force prediction. Simulation results show that the prediction accuracy is improved, and the average error rate decreases from 10% achieved by the BP neural network to less than 5% by using the proposed algorithm. This algorithm provides a new method to improve the thickness control of hot strip rolling.

**Key words:** Hot rolling; Rolling force prediction; Support vector machine; Chaotic optimization

### 1 引 言

轧制力的精确预测在薄板坯连铸连轧生产过程中具有重要作用. 预测精度的提高能有效地提高带钢厚度控制的精度, 增大薄规格带钢的生产比例. 传统的轧制力预测方法中主要依靠数学模型进行计算. 但由于连铸连轧生产线体系庞大、机理复杂, 并且生产现场环境恶劣, 存在各种系统干扰, 其数学模型是在各种假设下建立的, 故其计算精度有限, 影响了带钢厚度控制精度的进一步提高.

随着智能控制技术的发展, 人们开始应用人工神经网络对热连轧过程轧制力进行预测<sup>[1,2,7]</sup>, 同时也有将神经网络与其他智能信息处理方法相结合的研究.

如文献[2]中与遗传算法(GA)相结合; [5]中与粒子群算法相结合; [6]中与模糊逻辑相结合等, 或者采用小脑模型神经网络和小波神经网络模型<sup>[7]</sup>等, 均取得了较好的结果. 但人工神经网络存在收敛速度慢、训练耗时、网络结构选择的随机性较大以及容易陷入局部极小化等问题. 并且神经网络方法采用的是一种经验风险最小化的学习训练方式, 导致其网络推广能力受到较大的限制. 上述因素都限制了神经网络在轧制过程建模和轧制力预测中的应用.

Vapnik 等<sup>[8]</sup>提出的支持向量机(SVM)算法是一种基于结构风险最小化学习训练的方法, 与人工

收稿日期: 2008-06-01; 修回日期: 2008-09-19.

基金项目: 国家自然科学基金项目(60774032); 教育部高等学校博士学科点专项科研基金项目(20070561006); 广州市科技攻关重点项目(2007Z2D0121).

作者简介: 陈治明(1981), 男, 广西北海人, 博士生, 从事智能控制技术的研究; 罗飞(1957), 男, 广西柳州人, 教授, 博士生导师, 从事智能控制技术和控制系统分析与集成等研究.

神经网络相比具有一些显著的优点, 较少的支持向量数便能获得统计意义上较好的推广能力, 因此在分类和函数回归、预测上获得了广泛的应用。

目前, SVM 算法在冷热轧轧制力预测中的应用研究还较少。文献[9]提出将 SVM 算法应用于 30MnSi 钢的变形抗力预测, 提高了预测精度。

本文提出一种将 SVM 算法应用于热轧精轧轧制力预测的方法。由于 SVM 算法的性能与其参数的选择具有重要关系, 不少学者进行了相关的研究<sup>[10]</sup>。考虑到混沌变量的不重复遍历性和规律性的优点, 采用一种混沌优化方法对 SVM 最优参数进行搜索, 同时为了加快搜索速度, 引入变尺度方法和遗传算法对混沌优化方法进行改进<sup>[11,12]</sup>。仿真实验表明, 所提出的基于混沌优化 SVM 的轧制力预测算法能进一步提高预测的精度。

## 2 基于 SVM 的轧制力预测模型

### 2.1 最小二乘 SVM

Vapnik 等学者提出的 SVM 算法是一种以有限样本统计学习理论为基础, 依据结构风险最小化原则, 在非线性情形下将输入样本映射到高维特征空间, 通过二次规划求取样本最优分类面的机器学习方法。因为算法设计为凸二次规划问题, 所以可避免多解性。但其计算速度在样本数增加时, 会随着解二次规划问题变复杂而变慢, 并且标准 SVM 算法抵制训练样本噪声能力较差。而热连轧过程影响因素众多且关系复杂, 学习需要的样本数较多, 现场所采集的各种信号噪声较大。

最小二乘 SVM(LS2SVM)是 Suykens 等<sup>[13]</sup>提出的一种改进的 SVM 算法。LS2SVM 将标准 SVM 中的不等式约束改为等式约束, 以误差平方和作为训练样本的损失函数, 从而将二次规划问题转化为求解线性方程组问题。

对于训练集  $\{(x_i, y_i)\}_{i=1}^l \in \mathbb{R}^n \times \mathbb{R}$ , 其中  $l$  为样本数, 在非线性情形下引入映射  $\phi: \mathbb{R}^n \rightarrow \mathbb{R}^m$ , 则 LS2SVM 回归问题可表达为

$$\min J(X, N) = \frac{1}{2} X^T X + \frac{1}{2} C \sum_{i=1}^l N_i^2,$$

$$\text{s. t. } y_i = X(\phi(x_i)) + b + N_i, \quad i = 1, 2, \dots, l. \quad (1)$$

其中:  $N$  为松弛变量,  $C$  为用于平衡拟合误差和模型复杂度的正则化参数。

对于优化问题(1), 引入 Lagrange 函数进行求解, 有

$$L(X, b, N, A) = J - \sum_{i=1}^l A_i [X(\phi(x_i)) + b + N_i - y_i], \quad (2)$$

其中  $A_i (i = 1, 2, \dots, l)$  是 Lagrange 因子。为求取最

优  $A$  和  $b$ , 由 KKT 条件可得线性方程组

$$\begin{bmatrix} 0 & e^T \\ e & Q + C^{-1}L \end{bmatrix} \begin{bmatrix} b \\ A \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix}. \quad (3)$$

式中:  $e = (1, 1, \dots, 1)^T$ ,  $A = (A_1, A_2, \dots, A_l)^T$ ,  $y = (y_1, y_2, \dots, y_l)^T$ ,  $Q_{ij} = \langle \phi(x_i) | \phi(x_j) \rangle = K(x_i, x_j)$  是满足 Mercer 条件的对称函数(核函数)。

应用最小二乘法求出  $A$  和  $b$ , 得到 SVM 函数回归的结果为

$$f(x) = \sum_{i=1}^l A_i K(x_i, x) + b. \quad (4)$$

在实际轧制力预测应用中, 核函数选取为 RBF 核函数, 即

$$K(x_i, x) = \exp(- (x_i - x)^2 / 2R^2),$$

其中  $R$  是核宽度。

正则化参数  $C$  和核宽度  $R$  是 LS2SVM 应用时必须调整的两个参数, 其选取直接影响算法的训练结果和泛化性能, 在热连轧轧制力预测中, 采用试凑法选择参数的效果并不理想。因此本文提出一种改进的结合遗传算法的混沌优化方法以实现这两个参数的最优选取。

### 2.2 混沌优化 LS2SVM

以均方误差(MSE)

$$\frac{1}{l} \sum_{i=1}^l (y_i - f(x_i))^2$$

来描述轧制力实际值和 LS2SVM 预测值之间的偏差。参数优化的目标是使得 LS2SVM 回归预测具有最小的均方误差。

考虑 Logistic 映射

$$x_{k+1} = Lx_k(1 - x_k), \quad (5)$$

其中  $x_k \in (0, 1)$  且  $x_k \in \{0.25, 0.5, 0.75\}$ 。当  $L = 4$  时, 迭代系统(5) 处于完全混沌状态。利用系统(5) 的遍历特性, 设置两个初始值相异的变量  $x_1$  和  $x_2$ , 再将  $x_1$  和  $x_2$  分别映射到  $C$  和  $R$  的取值空间, 则可在  $C$  和  $R$  的取值空间内进行遍历, 寻找  $C$  和  $R$  的全局最优值。

混沌遍历在搜索空间较大时遍历速度较慢。为克服这个缺点, 本文引入遗传算法的并行处理方法, 并采用变尺度搜索方式, 得到一种改进的混沌优化方法。其步骤如下:

Step1: 初始化混沌变量种群  $\{x_{i,j}^k\}$  和  $\{x_{2,j}^k\}$ ,  $k$  为迭代步数(此时  $k = 0$ ),  $j = 1, 2, \dots, M$ ,  $M$  为种群大小。并将 MSE 初始化为一个足够大的数值。

Step2: 利用式(5) 迭代混沌变量, 将  $\{x_{i,j}^k\}$ ,  $\{x_{2,j}^k\}$  映射到  $C$ ,  $R$  的取值区间  $(a_i, b)$  ( $i = 1, 2, \dots$ ), 得到  $\{z_{1,j}^k\}$  和  $\{z_{2,j}^k\}$ , 即

$$z_{i,j}^k = a_i + x_{i,j}^k (b_i - a_i). \quad (6)$$

Step3: 根据映射得到的  $C$  和  $R$ , 利用训练集运行 LS2SVM 算法, 并计算种群的均方误差 (MSE), 记为  $f_1(x_{i,j})$ .

Step4: 按照 GA 算法对种群以概率  $p_c$  进行交叉操作.

Step5: 按照 GA 算法对种群以概率  $p_m$  进行变异操作.

Step6: 利用训练集训练 LS2SVM, 计算种群适应度的 MSE, 记为  $f_2(x_{i,j})$ . 若  $f_2(x_{i,j}) < f_1(x_{i,j})$ , 则接受 GA 算法新种群个体; 否则接受 Step3 中的高适应度个体. 新种群中保留性能较好的种群, 并从中标记出性能最好个体, 记为  $z_i^*$ .

Step7: 利用式 (6) 的逆映射将新种群映射到混沌变量区间, 重复 Step2 ~ Step6, 直到最小 MSE 在一定步数内保持不变为止. 最佳个体记为  $z_i^*$ .

Step8: 缩小变量的搜索范围, 即

$$a_i^{r+1} = z_i^* - K(b_i^r - a_i^r),$$

$$b_i^{r+1} = z_i^* + K(b_i^r - a_i^r).$$

其中:  $K \in (0, 0.5)$ ,  $r$  是缩小搜索范围的操作次数. 为使变量落入正确取值区间, 应作以下限定: 若  $a_i^{r+1} < a_i^r$ , 则令  $a_i^{r+1}$  取值  $a_i^r$ ; 若  $b_i^{r+1} > b_i^r$ , 则令  $b_i^{r+1}$  取值  $b_i^r$ .

Step9: 按照缩小了的搜索范围产生新种群, 执行 Step2 ~ Step7.

Step10: 重复执行 Step8, Step9. 若最优值在若干次内保持不变, 则结束寻优操作. 得到的  $z_i^*$  ( $i = 1, 2$ ) 对应于 LS2SVM 的  $C$  和  $R$  参数优化值.

变尺度方法首先在较大范围内进行粗搜索, 确定参数的次优值; 然后在缩小的范围内进行细搜索以确定参数的最优值, 并与遗传算法相结合, 引入了并行操作的优点, 以加快搜索速度. 与其他混沌优化方法相比, 本文方法在 Step6 中对迭代一步后种群个体和引入 GA 算法后种群个体适应度进行了比较, 并选择适应度较高的个体形成新种群. 这种选择方式能更好地融合混沌遍历和遗传优化, 避免将混沌遍历和遗传算法机械地串联使用.

### 3 轧制力预测

#### 3.1 样本数据选择

轧制力预测的样本数据来自某钢铁厂的实时生产数据记录数据库. 针对轧制力预测, 需要进行适当的样本数据项选取.

利用传统数学模型对轧制力进行计算时, 其计算公式为

$$P = B l_c Q_p K. \quad (7)$$

其中:  $P$  为轧制力,  $B$  为带钢宽度,  $l_c$  为考虑轧辊压扁后的接触弧水平投影长度,  $Q_p$  为应力状态系数,  $K$

为变形阻力.  $Q_p$  和  $K$  与带钢的化学成分、变形程度、变形速度、来料厚度以及温度等有关.

由于传统数学模型经过长期利用在线数据进行自学习调整, 模型已达到一定精度, 本文采用 SVM 模型和自学习数学模型相结合的方式对轧制力预测, 并将数学模型自学习的结果作为 LS2SVM 模型的部分输入项. 综合考虑式 (7) 和模型混合的要求, 最终选取模型设定轧制速度  $v$ , 轧出宽度设定  $B$ , 轧出厚度设定  $h$ , 精轧板坯来料温度  $T_0$ , 终轧温度设定  $T_n$ , 轧制力设定  $P$ , 压下率设定  $n\%$ , 辊缝设定值  $S_0$ , 上架辊缝实际值  $S$ ,  $C$  含量  $C\%$ ,  $Si$  含量  $Si\%$  以及  $Mn$  含量  $Mn\%$  作为 SVM 预测模型输入. 对于同种带钢预测, 化学成分含量可不作为输入.

在钢厂实际热连轧生产线中, 并非每个轧机机架都进行板坯入口温度和入口厚度的检测, 因此可以精轧板坯来料温度和上架辊缝实际值作为相应输入量.

#### 3.2 仿真与结果

利用建立起来的 LS2SVM 预测模型进行轧制力预测仿真. 预测模型结构如图 1 所示.

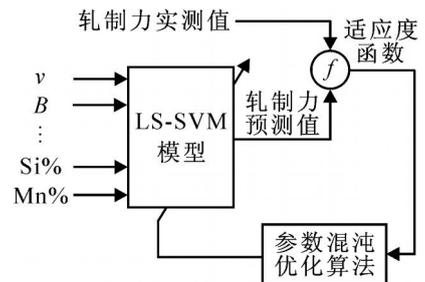


图1 轧制力预测模型结构

LS2SVM 模型输入向量为  $(v, B, h, T_0, T_n, P, n\%, S_0, S, C\%, Si\%, Mn\%)$ , 适应度函数为

$$\min \text{MSE} = \min \left\{ \frac{1}{l} \sum_{i=1}^l (y_i - f(x_i))^2 \right\}.$$

利用某钢铁厂六机架连铸连轧生产线(无粗轧)的在线数据, 选取其中第3机架典型数据点 6000 点(训练样本集  $l = 6000$ ) 对 LS2SVM 进行训练. 在训练前, 首先对样本数据进行预处理. 进行参数优化时, 设定种群大小  $M = 100$ . 利用训练好的预测模型, 对不在训练样本集中的带钢轧制力数据(3000 个数据点)进行预测. 其中一次预测的结果如图 2 所示.

为便于观察, 图 2 中只显示了部分预测数据点. 从图中可以看出, 与参数未优化 LS2SVM 相比, 混沌优化 LS2SVM 模型在板坯温度变化或厚度变化引起轧制力变化时, 在轧制力曲线变化剧烈和细微处能更好地进行跟踪, 预测精度也更高.

为了与神经网络预测模型进行比较, 文中利用

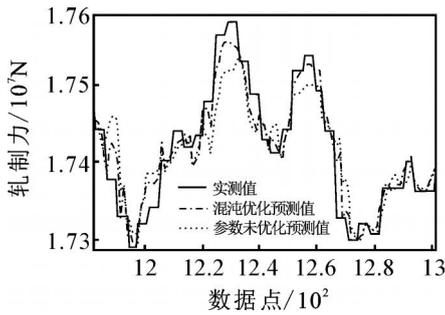


图 2 LS-SVM 模型轧制力预测结果

BP 神经网络建立模型并进行了预测. 其中一次预测结果如图 3 所示.

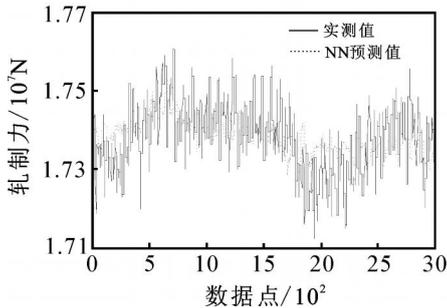


图 3 BP 神经网络轧制力预测结果

从图 3 可以看出, 采用 BP 神经网络进行预测时, 预测曲线总体上能跟随真实值变化, 但误差相对较大. 混沌优化 LS-SVM 模型和 BP 网络模型预测误差率的比较如图 4 所示.

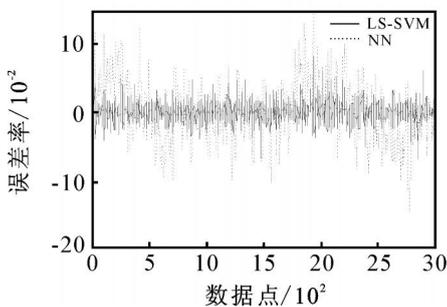


图 4 LS-SVM 和 BP 模型误差率比较

从图 4 可以看到, BP 网络模型平均误差率在 10% 左右, 而 LS-SVM 模型则低于 5%.

#### 4 结 论

在本文的轧制力预测研究中, 与神经网络建模预测方法相比, 支持向量机建模预测方法具有训练收敛速度快、模型泛化能力强、预测精度高的优点, 轧制力预测误差从 10% 减小到 5% 以下. 采用与遗传算法相结合的变尺度混沌优化方法, 能在全局范围内搜索支持向量机模型的最优参数, 并且搜索速度得到了提高.

采用支持向量机算法进行带钢热连轧轧制力预测的研究尚处于起步阶段. 仿真实验表明, 所支持向

量机预测方法具有较好的预测精度, 在实践中具有很大的应用潜力.

#### 参考文献 (References)

- [1] Cho S Z, Cho Y J, Yoon S C. Reliable roll force prediction in cold mill using multiple neural networks [J]. IEEE Trans on Neural Networks, 1997, 8(4): 8742882.
- [2] Son J S, Lee D M, Kim I S, et al. A study on online learning neural network for prediction rolling force in hot rolling mill [J]. J of Materials Processing Technology, 2005, 164/ 165: 161221617.
- [3] 张俊明, 刘军, 俞晓峰, 等. 轧制力预测中 RBF 神经网络的组合应用 [J]. 钢铁研究学报, 2008, 20(2), 332 36.  
(Zhang J M, Liu J, Yu X F, et al. Application of combination of RBF neural network to prediction of rolling force [J]. J of Iron and Steel Research, 2008, 20 (2): 33236.)
- [4] 胡贤磊, 王昭东, 于解民, 等. 结合模型自学习的 BP 神经网络的轧制力预报 [J]. 东北大学学报, 2002, 25 (11): 108921092.  
(Hu X L, Wang Z D, Yu J M, et al. Prediction of rolling load by BP neural networks integrating with self adaptation of traditional model [J]. J of Northeastern University, 2002, 25(11): 108921092.)
- [5] 丁敬国, 胡贤磊, 焦景民, 等. 变异 PSO 算法协同神经网络在轧制力预报中的应用 [J]. 钢铁研究学报, 2007, 19(12), 56259.  
(Ding J G, Hu X L, Jiao J M, et al. Application of adaptive mutation PSO with neural networks to rolling force prediction [J]. J of Iron and Steel Research, 2007, 19(12): 56259.)
- [6] 刘华强, 唐荻, 杨荃, 等. 模糊小脑模型神经网络在多辊冷连轧机轧制力预报模型中的应用 [J]. 北京科技大学学报, 2006, 28(10), 9692972.  
(Liu H Q, Tang D, Yang Q, et al. Rolling force prediction model of a multiroll cold tandem mill by fuzzy cerebellum model articulation controller [J]. J of University of Science and Technology Beijing, 2006, 28 (10): 9692972.)
- [7] 黄敏, 王建辉, 顾树生. 基于遗传小波神经网络的冷轧轧制力预报研究 [J]. 控制与决策, 2004, 19(10): 11221132.  
(Huang M, Wang J H, Gu S S. Study on cold mill rolling force prediction based on wavelet neural network with genetic algorithm [J]. Control and Decision, 2004, 19(10): 11221132.)
- [8] 许建华, 张学工, 李衍达. 支持向量机的新发展 [J]. 控制与决策, 2004, 19(5): 4812485.  
(Xu J H, Zhang X G, Li Y D. Advances in support

- vector machine[J]. Control and Decision, 2004, 19(5), 482-485.)
- [9] 陈爱玲, 杨根科, 吴智铭. 一种混合模型在30MnSi钢变形抗力预测中的应用[J]. 上海交通大学学报, 2006, 40(10): 1722-1726.  
(Chen A L, Yang G K, Wu Z M. Application of a hybrid model in the prediction of the flow stress of 30MnSi steel [J]. J of Shanghai Jiaotong University, 2006, 40(10): 1722-1726.)
- [10] 袁小芳, 王耀南. 基于混沌优化算法的支持向量机参数选取方法[J]. 控制与决策, 2006, 21(1): 1112-1114.  
(Yuan X F, Wang Y N. Selection of SVM parameters using chaos optimization algorithms [J]. Control and Decision, 2006, 21(1): 1112-1114.)
- [11] 张彤, 王宏伟, 王子才. 变尺度混沌优化方法及其应用[J]. 控制与决策, 1999, 14(3): 282-288.  
(Zhang T, Wang H W, Wang Z C. Mutative scale chaos optimization algorithm and its application [J]. Control and Decision, 1999, 14(3): 282-288.)
- [12] 李亚东, 李少远. 一种新的遗传混沌优化组合方法[J]. 控制理论与应用, 2002, 19(1): 143-145.  
(Li Y D, Li S Y. A new genetic chaos optimization combination method [J]. Control Theory and Applications, 2002, 19(1): 143-145.)
- [13] Suykens Johan A K, Gestel Tony Van, Brabanter Jos De. Least squares support vector machines [M]. Singapore: World Scientific Publishers, 2003.

(上接第807页)

- [14] Winston K G Seah, Hwee Xian Tan, Zheng Liu, et al. Multipath UUV approach for enhancing connectivity in underwater adhoc sensor networks [C]. OCEANS 2005 MTS/IEEE. Washington, 2005: 2262-2268.
- [15] Winston K G Seah, Hwee Xian Tan. Multipath virtual sink architecture for underwater sensor networks [C]. OCEANS 2006 ) Asia Pacific. Singapore, 2006: 126.
- [16] Ayers J. Underwater walking [J]. Arthropod Structure and Development, 2004, 33(3): 347-360.
- [17] Zhizhong Shen, Shuo Wang, Min Tan, et al. Robotfish-based underwater mobile sensor networks for environmental monitoring [C]. Proc of the 15th (2005) Int Offshore and Polar Engineering Conf. Seoul, 2005: 551-556.
- [18] 孙桂芝, 桑恩方, 王开玉. 水声通信网数据链路层协议仿真研究[J]. 声学技术, 2006, 25(2): 150-153.  
(Sun G Z, Sang E F, Wang K Y. The protocol simulation of data link layer of underwater acoustic networks [J]. J of Acoustic Technology, 2006, 25(2): 150-153.)
- [19] 蔡惠智, 刘云涛. 水声通信及其研究进展[J]. 物理, 2006, 35(12): 1038-1043.  
(Cai H Z, Liu Y T. Research improvement of underwater acoustic communication [J]. J of Physics, 2006, 35(12): 1038-1043.)
- [20] 李淑秋, 李启虎, 张春华. 水下声学传感网络的发展和  
应用[J]. 物理, 2006, 35(11): 942-952.  
(Li S Q, Li Q H, Zhang C H. Improvement and applications of underwater acoustic sensor networks [J]. J of Physics, 2006, 35(11): 942-952.)
- [21] Shuo Wang, Min Tan. Research on architecture for reconfigurable underwater sensor networks [C]. Proc of IEEE Conf on Networking, Sensing and Control. Arizona, 2005: 831-834.
- [22] Chao Lu, Shuo Wang, Min Tan. Design and realization of sensor nodes for dense underwater wireless sensor networks [C]. Proc of the 17th World Congress of the Int Federation of Automatic Control. Seoul, 2008: 1281-1284.
- [23] Injong Rhee, Ajit Warrier, Jeongki Min, et al. DRAND: Distributed randomized TDMA scheduling for wireless adhoc networks [C]. Proc of MobiHoc. Florence, 2006: 190-201.
- [24] Ajit Warrier, Mahesh Aia, Jeongki Min, et al. Z MAC: A hybrid MAC for wireless sensor networks [J]. IEEE/ACM Trans on Networking, 2008, 16(3): 511-524.
- [25] 孙利民, 李建中, 陈渝, 等. 无线传感网络 [M]. 北京: 清华大学出版社, 2005.  
(Sun L M, Li J Z, Chen Y, et al. Wireless sensor networks [M]. Beijing: Publishing House of Tsinghua University, 2005.)