

基于改进粒子群优化 LS-SVM 的卫星钟差 预报研究

刘继业, 陈西宏, 刘 强, 孙际哲
(空军工程大学防空反导学院, 西安 710051)

摘 要: 针对导航卫星短期钟差预报精度和稳定度不高的问题, 提出了一种基于改进粒子群优化 (PSO) 最小二乘支持向量机 (LS-SVM) 的卫星钟差预报方法。通过引进自适应改变的惯性权重和学习因子来提高粒子群算法的寻优能力, 并将其应用到 LS-SVM 的参数优化中, 避免人为选择参数的盲目性, 提高了 LS-SVM 的泛化能力和预报精度。选取国际 GPS 服务组织 (IGS) 产品中四颗典型卫星的钟差数据, 分别采用 LS-SVM 模型、神经网络模型和灰色系统模型进行短期钟差预报, 计算结果表明: LS-SVM 模型的预报精度优于其它两种模型, 为导航卫星短期高精度钟差预报提供了新的思路。

关键词: 粒子群优化; 惯性权重; 学习因子; 最小二乘支持向量机; 卫星钟差

中图分类号: P228 **文献标识码:** A **文章编号:** 1000-1328(2013)11-1509-07

DOI: 10.3873/j.issn.1000-1328.2013.11.014

LS-SVM Based on Improved PSO for Prediction of Satellite Clock Error

LIU Ji-ye, CHEN Xi-hong, LIU Qiang, SUN Ji-zhe

(Air and Missile Defense College, Air Force Engineering University, Xi'an 710051, China)

Abstract: Aiming at the poor performance of short term prediction of navigation satellite clock error, a method based on the least square support vector machine (LS-SVM) and improved particle swarm optimization (PSO) is proposed for prediction of satellite clock error. Adaptive inertia weigh and learning factor are introduced to improve the ability of PSO to find the best swarm. Then it is used to choose the parameters of LS-SVM, for avoiding the man-made blindness and enhancing the efficiency of online forecasting. The four typical GPS satellites clock data of IGS are chosen and respectively used in three models to predict short term clock error. The results show that the accuracy of LS-SVM model is superior to the other models, and the work provides a new way for short term prediction of navigation satellite clock error.

Key words: PSO; Inertia weigh; Learning factor; LS-SVM; Satellite clock error

0 引 言

时间同步是卫星导航系统的关键技术, 直接影响系统导航、定位和授时精度^[1-3]。为提高时间同步的精度, 卫星星载原子钟采用高稳定性的原子钟, 而且卫星钟定期与地面系统标准时钟进行比对, 以给出各卫星钟在比对时刻相对标准钟的钟差和钟速修正参数, 但卫星在空间轨道上飞行时, 卫星钟与地面时间基准的比对不能连续进行, 在地面监测站观

测不到的弧段内, 卫星钟与系统时间之间的同步只能由卫星钟自己维持, 这就需要根据卫星钟的运行性能, 建立精确的卫星钟差预报模型^[1]。

长期以来, 人们对卫星钟差预报进行了大量的研究, 文献[2]建立了卫星钟差 ARIMA 时间序列模型, 计算结果表明 ARIMA(0, 2, q) 模型预报精度高于二次多项式模型。文献[3]以较少的钟差数据建立了灰色预测模型, 计算结果表明灰色模型短期预报精度与二次多项式模型相当, 长期预报精度明显

优于二次多项式模型,但是不同指数系数的灰色模型对预报精度影响较大。文献[4]将卫星钟差的确定部分和随机部分纳入钟差预报模型,利用阿伦方差计算 Kalman 预报模型噪声方差阵参数,计算结果表明在有充足的钟差数据时,Kalman 预报模型短期预报精度最高。文献[5]提出了一种线性无偏预报方法,利用设计的 p 阶无偏 FIR 钟差预报器对钟差数据进行线性回归和无偏估计。文献[6]提出了基于径向基函数的神经网络钟差预报模型,取得了较高的预报精度,但是神经网络容易陷入局部极小值且需要的训练样本大。和神经网络同为统计学习中非线性分类器,支持向量机(Support Vector Machine, SVM)是一种基于结构风险最小化准则的机器学习方法,有效地解决了小样本、高维数、非线性、泛化能力不强等问题,可用于寻找全局最优解,解决了神经网络中容易陷入局部极小值问题,在模式识别和数据挖掘等领域显示了强大的优势。最小二乘支持向量机(LS-SVM)是对标准支持向量机的一种深化,降低了算法的计算复杂度,提高了求解速度,在预测领域得到了成功的应用^[7]。

文献[8]指出在 LS-SVM 算法中惩罚参数 c 与核宽度参数 σ 的选择与确定对预报结果有较大的影响,并且参数选择的恰当与否也会对样本数据的惩罚和训练误差带来很大的影响。基于此提出一种基于改进粒子群优化 LS-SVM 的卫星钟差预报方法。改进粒子群算法在每次迭代中,自适应改变惯性权重和学习因子,增强粒子群的搜索能力并且避免陷入局部最优,然后将其应用于卫星钟差预报 LS-SVM 方法惩罚参数 c 与核宽度参数 σ 优化中,以提高预报精度。

1 基于改进 PSO 优化的 LS-SVM 模型

1.1 LS-SVM 回归模型

在训练样本中, $\mathbf{x}_i \in \mathbf{R}^n$ 为样本的输入, $\mathbf{y}_i \in \mathbf{R}^n$ 为样本的输出, l 为样本训练个数。通过非线性映射 φ 可将输入数据 \mathbf{x}_i 映射到高维特征空间,并进行线性回归,即

$$F(\mathbf{x}) = \boldsymbol{\omega}^T \boldsymbol{\varphi}(\mathbf{x}) + \mathbf{b} \quad (1)$$

式中: $\boldsymbol{\omega}$ 为权向量; \mathbf{b} 为偏差。可根据结构风险最小化原理表示为一个等式约束的优化问题:

$$\min_{\boldsymbol{\omega}, \mathbf{b}, \boldsymbol{\xi}} \frac{1}{2} \boldsymbol{\omega}^T \boldsymbol{\omega} + \frac{c}{2} \sum_{i=1}^l \xi_i^2$$

$$\text{s. t. } \mathbf{y}_i - \boldsymbol{\omega}^T \boldsymbol{\varphi}(\mathbf{x}_i) - \mathbf{b} = \boldsymbol{\xi}_i \quad (2)$$

式中: c 为惩罚参数, $\boldsymbol{\xi}_i$ 为松弛变量。引入拉格朗日函数对其进行求解,可得:

$$L(\boldsymbol{\omega}, \mathbf{b}, \boldsymbol{\xi}, \boldsymbol{\alpha}) = \frac{1}{2} \boldsymbol{\omega}^T \boldsymbol{\omega} + \frac{c}{2} \sum_{i=1}^l \xi_i^2 - \sum_{i=1}^l \alpha_i [\boldsymbol{\omega}^T \boldsymbol{\varphi}(\mathbf{x}_i) + \mathbf{b} + \xi_i - \mathbf{y}_i] \quad (3)$$

式中, $\alpha_i (i = 1, 2, \dots, l)$ 为拉格朗日乘子,由 Karush-Kuhn-Tucher (KKT) 最优条件可得:

$$\begin{bmatrix} 0 & \mathbf{S}^T \\ \mathbf{S} & \mathbf{K} + \mathbf{I}/c \end{bmatrix} \begin{bmatrix} \mathbf{b} \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{Y} \end{bmatrix} \quad (4)$$

式中, $\mathbf{S} = [1, 1, \dots, 1]^T$, $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_l]^T$, $\mathbf{Y} = [y_1, y_2, \dots, y_l]^T$, $\mathbf{K} = \boldsymbol{\varphi}^T(\mathbf{x}_i) \boldsymbol{\varphi}(\mathbf{x}_j) = K(\mathbf{x}_i, \mathbf{x}_j)$ 是满足 Mercer 条件的核函数。采用常用的径向基函数: $K(\mathbf{x}, \mathbf{x}_i) = \exp(-\|\mathbf{x} - \mathbf{x}_i\|_2 / 2\sigma^2)$, 其中: σ 为核宽度。求解线性方程组式(4) 得出 $\boldsymbol{\alpha}, \mathbf{b}$, 可得 LS-SVM 回归模型为:

$$f(\mathbf{x}) = \sum_{i=1}^l \alpha_i K(\mathbf{x}, \mathbf{x}_i) + \mathbf{b} \quad (5)$$

在上述优化过程中,寻找合适的惩罚参数 c 和核宽度参数 σ 是整个优化问题的关键,它们的选取直接影响算法的学习和泛化能力。其中, c 决定了训练误差的大小和泛化能力的强弱; σ 反映了训练样本数据在高维特征空间分布的复杂程度。 σ 越大,得到的最优分类面结构风险越小,经验风险越大; σ 越小,得到的最优分类面经验风险越小,结构风险越大,容易造成过拟合现象。目前还没有统一的方法获取 LS-SVM 参数的最佳取值,常用的方法是网格搜索法,通过不断实验来得到满意的结果^[9]。为了减少搜索的盲目性,采用改进粒子群算法,优化选择 LS-SVM 回归模型中的两个重要参数,以提高模型的泛化性能。

1.2 PSO 算法

在 n 维空间中,设 $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{in})$ 、 $\mathbf{v}_i = (v_{i1}, v_{i2}, \dots, v_{in})$ 是第 $i (i = 1, 2, \dots, m)$ 个粒子的当前飞行位置和飞行速度,其搜索到的最优位置为 $\mathbf{p}_i = (p_{i1}, p_{i2}, \dots, p_{in})$, 整个粒子群搜索到的最优位置为 $\mathbf{p}_g = (p_{g1}, p_{g2}, \dots, p_{gn})$, PSO 算法的进化方程为:

$$\begin{cases} v_{id}(t+1) = wv_{id}(t) + c_1 r_1 [P_{id}(t) - x_{id}(t)] + \\ \quad c_2 r_2 [P_{gd}(t) - x_{id}(t)] \\ x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \end{cases} \quad (6)$$

式中: t 为进化代数; w 为惯性权重; r_1, r_2 是 $[0, 1]$ 上的随机数; c_1, c_2 是学习因子。

1.3 改进 PSO 算法

从 PSO 算法的模型中可以看出, 在算法求解过程中其多样性逐渐丧失, 粒子的追踪是粒子群逐渐趋同的过程, 容易造成未成熟收敛。粒子的更新速度主要是由惯性权重 w 和学习因子 c_1, c_2 决定的, 因此从 w 和 c_1, c_2 的角度改进粒子群算法, 使其避免过早陷入局部最优。

惯性权重使粒子保持运动惯性, 具有维护全局和局部搜索能力平衡的作用, 可通过调整其大小来改变搜索能力的强弱。惯性权重对算法的收敛性有重要影响, 较大的值有利于跳出局部最优, 而较小的值有利于加速算法的收敛。一般在迭代前期设置较大, 使粒子搜索较大的空间, 以较大的概率向自身最优和其它粒子学习; 在迭代后期设置较小, 使粒子以较大的概率向自身最优和全局最优学习。借鉴遗传算法自适应改变变异算子的方法^[10], 提出一种自适应调整的惯性权重法, 如式(7)所示。

$$w = \begin{cases} w_{\min} - \frac{(w_{\max} - w_{\min})(f - f_{\min})}{f_{\text{avg}} - f_{\min}}, & f < f_{\text{avg}} \\ w_{\max}, & f \geq f_{\text{avg}} \end{cases} \quad (7)$$

式中: w_{\min}, w_{\max} 分别为 w 的最大值和最小值; f 为当前的个体适应值; f_{avg} 和 f_{\min} 分别为当前所有粒子的平均适应值和最小适应值。

c_1 和 c_2 分别为自我学习因子和社会学习因子, 作用是调节自身经验和群体经验的权重, c_1 设置较大, 则会使粒子过多的局部搜索; c_2 设置较大, 则会使粒子过早收敛到局部最优。在基本 PSO 算法中, c_1 和 c_2 是固定不变的, 这将导致粒子群过早收敛于局部极值。而最好的情况是在算法初期, c_1 设置较大, c_2 设置较小, 这样粒子具有较大的自我学习能力和较小的社会学习能力, 可以使粒子在整个搜索空间飞行。在算法后期, c_1 设置较小, c_2 设置较大, 这样, 粒子具有较小的自我学习能力和较大的社会学习能力, 使粒子飞向全局最优解。因此为提高算法的收敛性能, 获得全局最优解, 必须自适应改变学习因子的大小。根据 c_1 和 c_2 大小要求, 可构造 c_1 为单调递减函数, c_2 为单调递增函数以实现动态调整。 c_1 和 c_2 的取值范围一般为 $(0.5, 2.5)$, 可构造最简洁的线性

函数如式(8)所示, 这样在几乎不增加计算复杂度的情况下, 提高了算法的收敛性能。

$$\begin{aligned} c_1 &= -2 \times t/T + 2.5 \\ c_2 &= 2 \times t/T + 0.5 \end{aligned} \quad (8)$$

式中, t 为当前迭代次数, T 为粒子群最大迭代次数。

1.4 改进 PSO 优化 LSSVM 钟差预报方法

为提高数据的利用率, LS-SVM 模型的训练使用滚动训练方式, 设有 m 个训练样本, 首先建立过去 p 个时刻的钟差值 $\{x_1, x_2, \dots, x_p\}$ 与 $\{x_{p+1}\}$ 之间的映射关系, 然后将训练窗口后移, 直到 $\{x_{m-p}, x_{m-p+1}, \dots, x_{m-1}\}$ 与预报的目标值 $\{x_m\}$ 之间的映射关系, 可以得到输入、输出矩阵:

$$\begin{aligned} X_{\text{SVM}} &= \begin{bmatrix} x_1 & x_2 & \dots & x_p \\ x_2 & x_3 & \dots & x_{p+1} \\ \vdots & \vdots & & \vdots \\ x_{m-p} & x_{m-p+1} & \dots & x_{m-1} \end{bmatrix}, \\ Y_{\text{SVM}} &= \begin{bmatrix} x_{p+1} \\ x_{p+2} \\ \vdots \\ x_m \end{bmatrix} \end{aligned}$$

得到训练样本之后, 利用改进粒子群算法求解出 LS-SVM 算法的惩罚参数 c 和核宽度参数 σ , 然后进行钟差预报, 具体流程如下:

步骤 1. 对钟差数据进行分析, 确定训练样本和测试样本, 构造输入和输出矩阵;

步骤 2. PSO 初始化。初始化算法参数, 包括设置群体规模、迭代次数, 随机生成粒子初始位置 x_{i0} 和粒子初始速度 v_{i0} , 将每个粒子的 p_i 设置为当前位置, 将 p_g 设置为群体中最好粒子的当前位置。初始化粒子个体对应支持向量机的惩罚参数 c 和核宽度参数 σ ;

步骤 3. 用训练样本训练 LS-SVM, 计算每个粒子个体的适应值 $f(x)$, 适应值函数为:

$$f(x) = 1 / \sum_{i=1}^l (y_i - x_i)^2 \quad (9)$$

式中, x_i 为第 i 个样本的实际值, y_i 为第 i 个样本的预测值, l 为测试样本个数。根据粒子的适应度值更新 p_i 和 p_g ;

步骤 4. 按式(6)更新种群中粒子的速度和位置, 按式(7)更新惯性权重, 按式(8)更新学习因子;

步骤 5. 判断适应度值是否满足要求或是否达到最大进化代数,如果不满足则返回步骤 3,如果满足条件,将全局最优粒子映射为优化的 LS-SVM 模型的参数;

步骤 6. 利用训练样本数据和步骤 5 得出的参数对 LS-SVM 进行求解,所得到的参数 α_i 和 b 代入式(5),预报出 x_{m+1} 的估计值 x_{m+1}^* ;

步骤 7. 由 $X_2 = \{x_{n-p+2}, \dots, x_m, x_{m+1}^*\}$ 预报出 x_{m+2}^* ;

步骤 8. 依次向前类推,得到钟差数据的 L 步预报值 x_{m+L}^* 。

2 算例与分析

2.1 实验数据分析

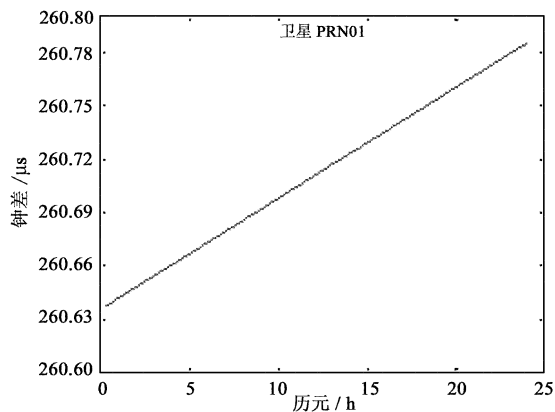
所使用数据为第 1692 周(2012 年 6 月 10 日 - 2012 年 6 月 16 日)国际 GPS 服务组织(International

GPS Service, IGS)精密钟差数据^[15]。目前 GPS 共有四种类型卫星钟,为便于比较,每种类型各取一颗,采用编号为 PRN01、PRN10、PRN15 和 PRN28 四颗卫星的卫星钟具体情况如表 1 所示。

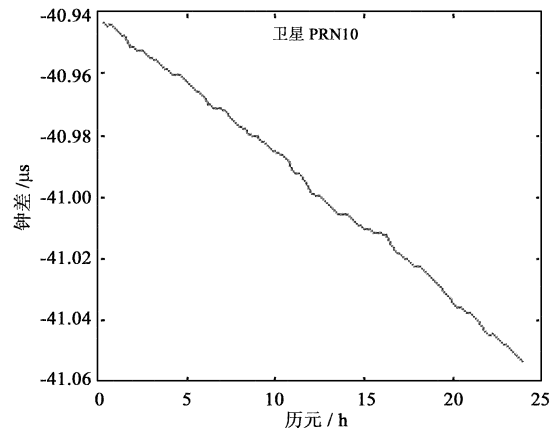
表 1 选取 GPS 卫星钟类型和卫星编号对照表
Table 1 The type and identification of GPS satellite clock

卫星编号	PRN01	PRN10	PRN15	PRN28
卫星钟类型	Block IIA 铷钟	Block IIA 铯钟	Block IIR-M 铷钟	Block IIR 铷钟


训练样本采用 2012 年 6 月 10 日 1 天的事后精密钟差数据,采样周期为 $\tau = 15\text{min}$,共有 96 个数据。IGS 快速预报钟差 6 小时更新一次,所以预报时长为 6 小时,共有 24 个数据,采用 2012 年 6 月 11 日的精密钟差数据(精度小于 0.1ns)作为真值,用于模型的检验。




(a) PRN01 号卫星钟差图



(b) PRN10 号卫星钟差图



(c) PRN15 号卫星钟差图



(d) PRN28 号卫星钟差图

图 1 四种卫星钟差图

Fig. 1 The clock error of four GPS satellites

首先对钟差数据进行分析,钟差图如图 1 所示,可以看出钟差序列有明显的增长或递减趋势,为非平稳序列,因此对钟差数据做一阶差分运算。粒子群参数初始化时,根据多次试验,选择最优参数设定粒子群规模为 40,惯性权重范围为[0.4,0.9],算法达到停止条件为最大迭代次数为 500 或达到收敛精度 1×10^{-12} ,初始化 LS-SVM 模型参数 (c, σ) 的范围: $c = [0, 1000], \sigma = [0, 10]$,以避免盲目搜索。

2.2 三种预报算法性能对比

为了比较不同模型的预报精度,用同样的数据样本分别采用 BP 神经网络模型和灰色系统模型进

行钟差预报,BP 神经网络选用 3 层结构,输入节点、隐含层节点和输出节点的个数分别为 5、12、10,最大训练次数为 500 次。

采用平均误差 E_m (Mean Error) 和均方根误差 E_R (Root Mean Square Error) 进行比较,公式为:

$$E_m = \frac{1}{n} \sum_{i=1}^n |y_i - x_i|$$

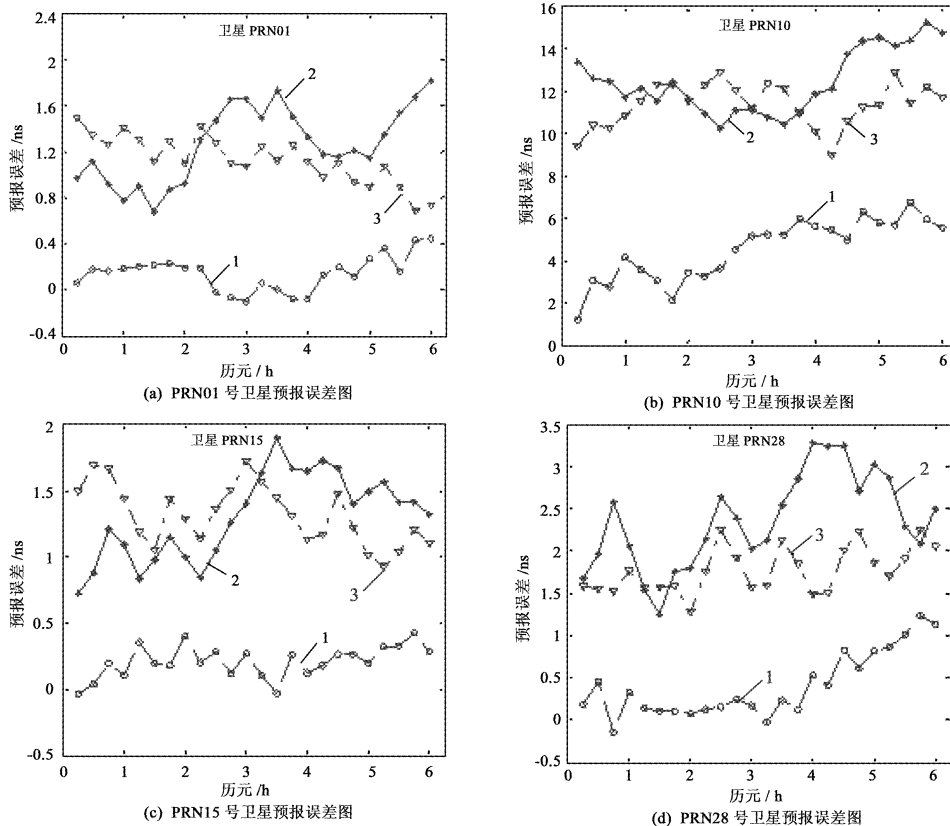
$$E_R = \left[\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2 \right]^{1/2} \quad (10)$$

式中, n 表示预报点个数, y_i 表示预测值, x_i 表示实际值。

表 2 三种模型的卫星钟差预报误差统计结果

Table 2 Statistics for satellite clock error prediction of three models

卫星编号	LS-SVM 模型		神经网络模型		灰色系统模型	
	E_m /ns	E_R /ns	E_m /ns	E_R /ns	E_m /ns	E_R /ns
PRN01	0.0867	0.1039	1.3329	1.3531	1.2666	1.2756
PRN10	4.5239	4.7434	12.4573	12.5448	11.3781	11.4231
PRN15	0.2149	0.2405	1.3043	1.3630	1.3177	1.3266
PRN28	0.4179	0.5537	2.3581	2.4211	1.7723	1.7926



1—LS-SVM 模型; 2—神经网络模型; 3—灰色系统模型

图 2 四种卫星预报误差图

Fig. 2 Prediction error of four GPS satellites

表 2 为 3 种模型的卫星钟差预报误差统计结果,图 2 为 3 种模型的预报误差。分析并比较结果,可以得出以下结论:

(1) 由于星载原子钟的特性不同,短期内不同类型卫星钟差预报精度差别较大,不论采用哪一种方法,图(a)卫星 PRN01 和图(c)卫星 PRN15 预报精度比较高,预报误差在 2ns 内,图(b)卫星 PRN10 精度最差,预报误差最大可达到 15ns。

(2) 神经网络模型和灰色系统模型的预报精度相差不大,在图(d)卫星 PRN28 中神经网络模型的预报精度比灰色系统模型高,而在图(a)卫星 PRN01、(b)卫星 PRN10、(c)卫星 PRN15 中灰色系统模型和神经网络模型预报精度各有优劣。

(3) 采用改进 PSO 优化的 LS-SVM 模型预报精度明显比神经网络模型和灰色系统模型高,平均预报误差仅为神经网络模型和灰色系统模型的 10%~40%。

4 结 论

对 LS-SVM 模型在钟差预报中的应用进行了初步尝试与探索,利用改进 PSO 算法对其参数进行优化处理,避免了参数选择的盲目性。通过引入自适应惯性权重和学习因子,以提高 PSO 算法的寻优能力,改进 PSO 算法能够根据相应权重实时改变 LS-SVM 模型最优的惩罚参数和核宽度参数,进而提高了 LS-SVM 模型的泛化能力。基于改进 PSO 优化 LS-SVM 方法能够充分利用 LS-SVM 强大的回归能力,较之神经网络方法,不易陷入局部最优解。另外,采用滚动预报方式,实时选取最近时刻钟差数据进行构建模型,没有误差累积效应,由于 IGS 快速预报钟差 6 小时更新一次,只要原子钟不进行调整,可以保证 LS-SVM 预报模型有充足的数据进行预报。选取 IGS 钟差数据进行计算分析,结果表明:所提出方法的平均预报误差仅为神经网络模型和灰色系统模型的 10%~40%,证明了方法的可行性和有效性,为卫星短期高精度钟差预报提供了新的方法。

参 考 文 献

[1] 郭海荣. 导航卫星原子钟时频特性分析理论与方法研究[D]. 郑州: 信息工程大学测绘学院, 2006. [Guo Hai-rong. Study on the analysis theories and algorithms of the time and

frequency characterization for atomic clocks of navigation satellites[D]. Zhengzhou: Institute of Surveying and Mapping, Information Engineering University, 2006.]

- [2] 徐君毅, 曾安敏. ARIMA (0,2,q) 模型在卫星钟差预报中的应用[J]. 大地测量与地球动力学, 2009, 29(5):116-120. [Xu Jun-yi, Zeng An-min. Application of ARIMA (0,2,q) model to prediction of satellite clock error [J]. Journal of Geodesy and Geodynamics, 2009, 29(5):116-120.]
- [3] 崔先强, 焦文海. 灰色系统模型在卫星钟差预报中的应用[J]. 武汉大学学报·信息科学版, 2005, 30(5):447-450. [Cui Xian-qiang, Jiao Wen-hai. Grey system model for the satellite clock error predicting[J]. Geomatics and Information Science of Wuhan University, 2005, 30(5):447-450.]
- [4] 朱祥维, 肖华, 雍少为, 等. 卫星钟差预报的 Kalman 算法及其性能分析[J]. 宇航学报, 2008, 29(3):966-970. [Zhu Xiang-wei, Xiao Hua, Yong Shao-hua, et al. The kalman algorithm used for satellite clock offset prediction and its performance analysis [J]. Journal of Astronautics, 2008, 29(3): 966-970.]
- [5] Yuriy S S. Linear unbiased prediction of clock errors[J]. IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control, 2009, 56(9): 2027-2029.
- [6] 郭承军, 滕云龙. 神经网络在卫星钟差短期预报中的应用研究[J]. 测绘科学, 2011, 36(4):198-200. [Guo Cheng-jun, Teng Yun-long. Application of neural network in satellite clock bias short-term prediction [J]. Science of Surveying and Mapping, 2011, 36(4): 198-200.]
- [7] 戴林超, 吴琳丽, 赵海娜, 等. 基于最小二乘支持向量机的故障预测法[J]. 中南大学学报(自然科学版), 2009, 40(1):253-257. [Dai Lin-chao, Wu Lin-li, Zhao Hai-na, et al. Error prediction based on least squares support vector machines [J]. Journal of Central South University (Science and Technology), 2009, 40(1):253-257.]
- [8] 朱红求, 阳春华, 王觉, 等. 基于混合 QPSO 的 LS-SVM 参数优化及其应用[J]. 中南大学学报(自然科学版), 2011, 42(4):1000-1004. [Zhu Hong-qiu, Yang Chun-hua, Wang Jue, et al. Hybrid-QPSO-based parameters optimization of LS-SVM and its application [J]. Journal of Central South University (Science and Technology), 2011, 42(4):1000-1004.]
- [9] 冯磊华, 桂卫华, 杨锋. 基于改进粒子群算法的电站锅炉 NOx 排放预测控制及优化[J]. 中南大学学报(自然科学版), 2011, 42(7):2018-2022. [Feng Lei-hua, Gui Wei-hua, Yang Feng. Predictive control and optimization of NOx emission in power plant boiler based on an improved particles swarm algorithm[J]. Journal of Central South University (Science and Technology), 2011, 42(7):2018-2022.]
- [10] 段玉倩, 贺家李. 遗传算法及其改进[J]. 电力系统及其自动化学报, 1998, 10(1):39-50. [Duan Yu-qian, He Jia-li.

- Genetic algorithm and its modification [J]. Proceedings of the EPSA, 1998, 10(1):39-50.]
- [11] Liu B, Wang L, Jin Y H, et al. Improved particle swarm optimization combined with chaos [J]. Chaos, Solitons and Fractals, 2005, 25(5):1261-1271.
- [12] Song Q S, Feng Z R. The hybrid forecasting model based on chaotic mapping, genetic algorithm and support vector machine [J]. Expert Systems with Applications, 2010, 37(2):1776-1783.
- [13] Lau K W, Wu Q H. Local prediction of non-linear time series using support vector regression [J]. Pattern Recognition, 2008, 41(5):1539-1547.
- [14] 李征航, 黄劲松. GPS 测量与数据处理 [M]. 武汉: 武汉大学出版社, 2010:261-274. [Li Zheng-hang, Huang Jin-song. GPS surveying and data processing [M]. Wuhan: Wuhan University Press, 2010:261-274.]

作者简介:

刘继业(1989-),男,硕士生,主要从事高精度时间同步技术方面的研究。

通信地址:西安市长乐东路甲字一号空军工程大学防空反导学院研二队(710051)

电话:152291013728

E-mail:liujiye899@163.com

(编辑:张宇平)