

# 基于粒子群优化 SVR-ARMA 组合模型频率预测\*

刘哲<sup>1</sup>, 丁阳<sup>1,2</sup>, 严加宝<sup>1,2</sup>

(1. 天津大学建筑工程学院 天津, 300072)

(2. 天津大学滨海土木工程结构与安全教育部重点实验室 天津, 300072)

**摘要** 为实现环境激励下复杂钢结构的损伤预警,提出一种基于粒子群优化(particle swarm optimization, 简称 PSO)的支持向量回归(support vector regression, 简称 SVR)-时间序列(auto-regressive and moving average model, 简称 ARMA)组合模型用于频率预测,并结合均值控制图法将其用于复杂钢结构的损伤预警中。所提出频率预测模型的准确性和有效性采用潍坊市白浪河摩天轮钢结构实测数据进行验证。验证结果表明:与基本 SVR 模型、SVR-ARMA 模型和 PSO-SVR 模型相比,所提模型具有更高的泛化能力和预测精度;在白浪河摩天轮钢结构的损伤预警中,基于粒子群优化的 SVR-ARMA 组合模型可检出由损伤造成模态频率轻微的异常变化,具有较强的损伤敏感性。研究成果可为环境激励下复杂钢结构的损伤预警提供参考。

**关键词** 粒子群优化; 模态频率; 支持向量回归-时间序列组合模型; 结构损伤预警

**中图分类号** TU391; TU12; TH825

## 引言

在复杂钢结构的损伤预警中,模态频率已成为最常用的损伤指标之一<sup>[1]</sup>。然而温度作用、风荷载和边界条件等因素的改变都有可能造成结构模态频率产生一定的变化。例如,在温度作用下水立方<sup>[2]</sup>和广州塔<sup>[3]</sup>的模态频率波动范围分别为 3% 和 7%;在风和温度影响下深圳地王大厦<sup>[4]</sup>的模态频率变化幅度为 6%。研究发现<sup>[5]</sup>环境因素改变引起的频率波动会将结构轻微损伤造成的频率波动掩盖,从而使对模态频率进行异常判别难以实现。因此,基于长期监测数据建立准确可靠的频率预测模型是环境激励下复杂钢结构损伤预警的关键。

目前,许多学者对结构模态频率的预测模型进行了研究。文献[6-7]采用多项式拟合法建立了润扬大桥模态频率-温度的预测模型,但该模型对环境激励下复杂的高维输入建模并不适用。邓扬等<sup>[8]</sup>采用的 BP(back propagation, 简称 BP)神经网络模型和王立新等<sup>[9]</sup>采用的 SVR 模型可用于高维的非线性回归,然而这种单一模型往往忽略频率数据中的线性变化。当监测周期较长时其预测精度不足,从而影响结构的损伤预警效果。针对以上问题,笔者

提出一种基于 PSO 的 ARMA 组合模型进行频率预测,并结合均值控制图法将其应用于复杂钢结构的损伤预警中。采用提出的模型首先对潍坊市白浪河摩天轮钢结构监测数据进行建模分析,然后对其模态频率的异常变化进行判别。

## 1 SVR-ARMA 组合预测模型

### 1.1 支持向量回归(SVR)模型

支持向量机技术(support vector machine, 简称 SVM)是基于统计学理论的一种新型机器学习算法。SVR 作为 SVM 的一种,具有很强的非线性处理能力,其原理<sup>[10]</sup>可表述如下:对于一组数据序列  $X = \{(x_i, y_i) \mid x_i \in \mathbf{R}, y_i \in \mathbf{R}, i = 1, 2, \dots\}$ , 其回归问题即寻找一个函数

$$f(x) = [\mathbf{w}, x] + b \quad (1)$$

其中:  $\mathbf{w}$  为权重矢量;  $b$  为阈值。

利用对偶原理并引入拉格朗日乘子  $\alpha_i$  和  $\alpha_i^*$ , 式(1)可转化为

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i, x_j) + b \quad (2)$$

其中:  $K(x_i, x_j) = \varphi(x_i)\varphi(x_j)$  为核函数。

\* 国家重点基础研究发展计划(“九七三”计划)资助项目(2011CB013606)

收稿日期:2018-04-03;修回日期:2018-09-25

文中采用的核函数为高斯径向基核函数(radial basis function, 简称 RBF),其表达式如下

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right) \quad (3)$$

其中:  $\sigma$  为数据标准差。

## 1.2 时间序列(ARMA)模型

ARMA 模型是一种时间序列模型,对于平稳序列  $u_t$ ,其 ARMA 模型的表达式<sup>[11]</sup>如下

$$u_t = c + \sum_{i=1}^p \varphi_i u_{t-i} + \varepsilon_t + \sum_{j=1}^q \varphi_j \varepsilon_{t-j} \quad (4)$$

其中:  $t=1, 2, \dots, T$ ;  $c$  为常数;  $\varphi_i$  为  $p$  阶自回归模型系数;  $\varphi_j$  为  $q$  阶移动平均模型的系数;  $\varepsilon_t$  为均值为 0、方差为  $\sigma$  的白噪声序列。

如果数据  $u_t$  未通过非平稳检验,可首先采用  $d$  次差分使非平稳序列转为平稳序列  $I_t$ ,然后再用 ARMA 模型进行建模。

## 1.3 SVR-ARMA 组合模型

对于环境激励下复杂钢结构模态频率的预测,仅仅依靠传统的单一模型并不能将频率的线性和非线性特征完全诠释。通过大量实际问题的预测研究发现<sup>[12]</sup>,组合模型可以减少预测失败的风险,与单一模型相比其预测能力表现的更强。因此,笔者采用 SVR-ARMA 组合模型对未知状态下结构模态频率进行建模并预测,其步骤如下。

1) 已知给定的结构模态频率数据样本序列  $F=(f_1, f_2, \dots, f_{n+m})$ ,对其进行训练从而建立基本的 SVR 模型。训练数据的拟合序列为  $\bar{F}_T=(f_{T1}, f_{T2}, \dots, f_{Tn})$ ,预测序列为  $\bar{F}_P=(f_{P1}, f_{P2}, \dots, f_{Pm})$ 。

2) 基于所建立的 SVR 模型求出数据的训练样本残差  $E_T=F-\bar{F}_T=(e_1, e_2, \dots, e_n)$ ,然后建立其 ARMA 模型。

3) 依据建立训练样本残差的 ARMA 模型,求出其预测序列  $E_P=(e_1, e_2, \dots, e_m)$ 。将 SVR 的预测样本序列  $\bar{F}_P$  和 ARMA 的预测序列  $E_P$  相加,即可得最终的预测频率  $F_P$ 。SVR-ARMA 组合模型进行频率预测的表达式如下

$$F_P = \bar{F}_P + E_P = \sum_{i=1}^l (a_i - a_i^*) K(x_i - x_i) + b + \sum_{i=1}^p \varphi_i \cdot e_{t-i} + \varepsilon_t + \sum_{j=1}^q \varphi_j \cdot \varepsilon_{t-j} \quad (5)$$

由以上可以看出,SVR-ARMA 模型具有两个单一模型的特点,既可以反映频率数据中的非线性特征,又可以反映频率数据中的线性特征。然而,SVR-ARMA 模型也存在一定的缺陷,如果 SVR 模

型不是最优的,那么基于 SVR 模型训练残差所建立的 ARMA 模型就不能正确反映数据的线性特征,达不到提高预测精度的目的。所以,建立结构模态频率的预测模型就需要选取最优的参数组合来使 SVR 模型预测值和实际值之间的残差最小。

## 2 粒子群优化的 SVR-ARMA 模型

SVR 模型的泛化能力和预测精度与其参数有很大关系,但在建立 SVR 模型时的参数选取尚未有一致认可的最佳方法。目前人们通常采用网格遍历搜索方法(grid search method, 简称 GSM)进行参数选取,即首先定义惩罚系数  $C$ 、不敏感损失函数误差系数  $\varepsilon$  和数据标准差  $\sigma$  的取值范围从而获得数据训练集,然后进行计算获得不同参数下训练集验证分类的准确率,训练验证分类准确率最高的那组参数即为最佳参数。然而,采用 GSM 方法可能有很多组参数对应于最高的分类准确率,从而无法得到最优的 SVR 模型。智能寻优算法的出现可用于解决此类问题。

在智能寻优算法中,粒子群优化算法不需要对求解函数进行任何求导等操作,能够克服传统优化算法在计算中碰到的由于梯度矩阵病态或奇异而使计算无法收敛的现象。与其他算法相比<sup>[13]</sup>,粒子群算法保留了针对种群的全局搜索策略,它特有的记忆使其可以动态跟踪当前的搜索情况调整其搜索策略。同时,由于粒子群算法所采用的速度-位移模型操作简单,因此文中采用粒子群算法对 SVR 模型进行参数寻优。

### 2.1 粒子群优化(PSO)算法原理

PSO 算法是根据鸟群的觅食行为所建立的,主要应用于问题的优化选择。PSO 原理<sup>[14]</sup>描述如下:

假设存在一个由  $n$  个粒子组成的  $D$  维种群  $\mathbf{X}=(X_1, X_2, \dots, X_n)$ ,其中第  $i$  个粒子表示  $D$  维的向量  $\mathbf{X}_i=[x_{i1}, x_{i2}, \dots, x_{iD}]^T$ ,代表第  $i$  个粒子在  $D$  维搜索空间中的位置。寻优时即定义一个目标函数然后求出每个粒子位置  $\mathbf{X}_i$  对应的适应度值。求解时设第  $i$  个粒子的速度为  $\mathbf{V}_i=[V_{i1}, V_{i2}, \dots, V_{iD}]^T$ ,极值为  $\mathbf{P}_i=[P_{i1}, P_{i2}, \dots, P_{iD}]^T$ ,种群的全局极值为  $\mathbf{P}_g=[P_{g1}, P_{g2}, \dots, P_{gD}]^T$ 。根据新种群中粒子适应度值更新个体极值和群体极值,依次迭代计算从而获得最优的参数。粒子的速度和位置更新公式为

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id}^k - X_{id}^k) + c_2 r_2 (P_{gd}^k - X_{id}^k) \quad (6)$$

其中:  $\omega$  为惯性权重;  $d=1, 2, \dots, D$ ;  $i=1, 2, \dots, n$ ;  $k$  为粒子的迭代次数;  $V_{id}$  为粒子的速度;  $c_1, c_2$  为加

速度因子,其值大于0;  $r_1, r_2$  为小于1的随机正数。

为提高计算效率,通常将粒子的位置和速度定义在  $[-X_{\max}, X_{\max}]$  和  $[-V_{\max}, V_{\max}]$  范围内。

## 2.2 PSO-SVR-ARMA 组合预测模型

笔者采取 PSO 算法对 SVR 建模中的参数进行优化选择,从而建立起最优的 SVR-ARMA 组合预测模型。PSO-SVR-ARMA 建模具体流程如图 1 所示,其步骤如下。

1) 对原始数据进行归一化处理,然后将归一化的数据进行一次累加,归一化公式为

$$x_{i,j}^* = \frac{x_{i,j} - x_{\min}}{x_{\max} - x_{\min}} \quad (7)$$

其中:  $x_{i,j}$  表示原始数据的第  $i$  行  $j$  列的样本点;  $x_{\max}$  和  $x_{\min}$  分别表示数据的最大值和最小值。

2) 采用 PSO 算法进行参数寻优。首先初始化粒子和速度,然后计算粒子适应度值,通过迭代计算寻找最优的个体极值和群体极值。

3) 基于步骤 2 所得参数建立数据的 SVR 模型,并进行拟合和预测。

4) 将所得训练样本的拟合结果与原始训练数据相减求出 SVR 模型的训练残差。基于训练残差建立 ARMA 模型,然后对残差进行预测。

5) 将 SVR 模型预测值和 ARMA 模型的残差预测值相加即可得到最终的频率预测值。

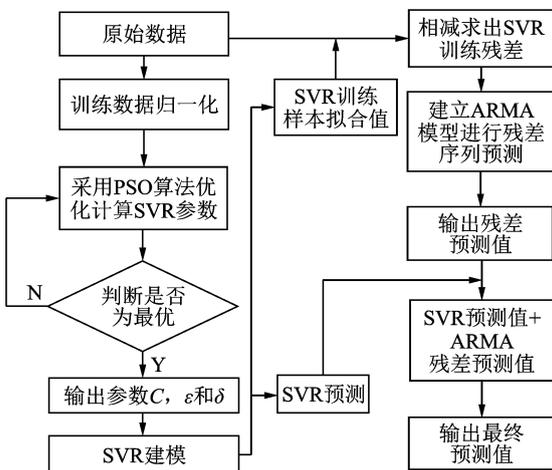


图 1 PSO-SVR-ARMA 组合预测模型

Fig. 1 PSO-SVR-ARMA combination forecasting model

## 3 基于 PSO-SVR-ARMA 组合预测模型的结构损伤预警

### 3.1 均值控制图原理

建立结构模态频率的预测模型后,可采用基于

统计的方法对结构未知状态下的模态频率进行检测从而实现损伤预警。目前使用最为广泛的是均值控制图法,其原理<sup>[15]</sup>如下:对于一组数据,如果其满足正态分布,那么可以对其中的小概率事件设定一个异常警戒限值。当超出警戒限值时,说明小概率事件发生,即可证明之前的数据存在异常。均值控制图的限值包括上控制限  $L_U$ 、中心线  $L_C$  和下控制限  $L_L$ ,分别由下式进行计算

$$L_U = \text{mean}(e_i) + Z_{\alpha/2} \frac{\text{std}(e_i)}{\sqrt{n}} \quad (8)$$

$$L_C = \text{mean}(e_i) \quad (9)$$

$$L_L = \text{mean}(e_i) - Z_{\alpha/2} \frac{\text{std}(e_i)}{\sqrt{n}} \quad (10)$$

其中:  $\text{mean}(e_i)$  和  $\text{std}(e_i)$  分别表示数据的均值和标准差。

在损伤预警中,结构模态频率的数据样本为  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ , 其概率为

$$P\left(\left|\frac{(\bar{X} - \mu)}{\sigma} \cdot \sqrt{n}\right| < Z_{\alpha/2}\right) = 1 - \alpha \quad (11)$$

其中:  $\mu$  为数据的平均值;  $\sigma$  为数据标准差;  $\alpha$  为显著性水平;  $Z_{\alpha/2}$  为标准正态分布上  $\alpha/2$  分位点。

当显著性水平为  $\alpha$  时,样本均值取值范围为  $(\mu - Z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}}, \mu + Z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}})$ 。当进行结构损伤预警时,应保证所有异常数据都被检出,即尽量将上下限范围缩减。当异常状态下的频率数据经其他检测手段确定结构并未发生损伤时,可将此异常数据纳入正常数据并更新均值控制图的上下限。

### 3.2 损伤预警的实现

通过 PSO-SVR-ARMA 组合模型对频率进行预测并采用均值控制图可初步实现结构的损伤预警。首先定义结构异常指标为

$$\beta = F - F_P \quad (12)$$

其中:  $F$  为模态频率实测值;  $F_P$  为 PSO-SVR-ARMA 组合模型的频率预测值。

当  $\beta$  超出均值控制图的上下限值时则说明结构频率异常,从而判别结构的状态。结构损伤预警的步骤描述如下。

1) 根据结构健康状态下的监测数据样本建立模态频率的 PSO-SVR-ARMA 组合预测模型,经概率密度函数(probability density function, 简称 PDF)检验后计算各样本点的结构异常指标  $\beta$ , 然后绘制均值控制图并确定健康状态的上、下限值范围。

2) 将未知状态下结构模态频率作为待检验样本。首先将环境数据输入 PSO-SVR-ARMA 模型

得到频率预测值,然后计算异常指标  $\beta$  并将其绘制到均值控制图中。

3) 若异常指标  $\beta$  落在健康状态下均值控制图中的上下限范围内,则判定该结构处于健康状态;反之,若异常指标偏离均值控制图中的中心线且超出上下限范围,则判定结构发生异常。

结构损伤预警流程如图 2 所示。

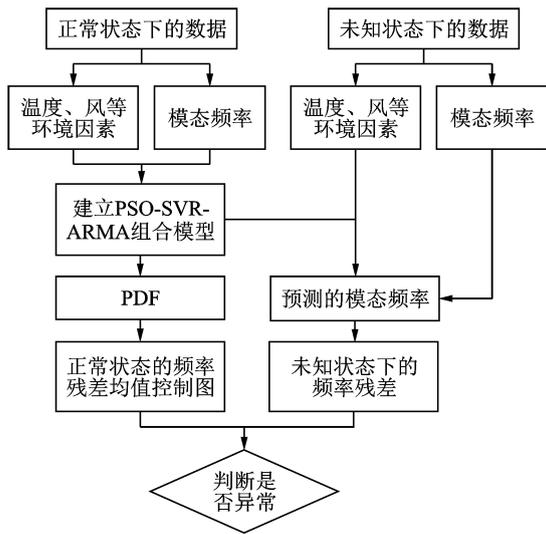


图 2 结构损伤预警流程图

Fig. 2 Flow chart of structural damage alarming

## 4 工程实测数据分析

### 4.1 工程概况及数据获取

为验证所提模型的有效性,下面对白浪河摩天轮钢结构工程监测数据进行分析。白浪河摩天轮<sup>[16]</sup>位于潍坊市白浪河大桥上,是采用编织网格形式的无轴式摩天轮,其俯视图如图 3(a)所示。摩天轮的轮盘结构是由钢管构件按照网状编织形式所形成的圆环,外圆直径为 125 m。下部斜柱和两侧拉索与基础相连为摩天轮提供竖向和侧向支撑。该结构杆件众多且运营时所受环境激励复杂。振动监测时采用三向加速度传感器,根据该结构振型分布特点布置传感器,具体测点位置如图 3(b)中  $A_1 \sim A_6$  所示。

采用峰值法对该结构进行模态参数识别,即取自功率谱密度图上峰值的横坐标作为结构模态频率值。测点  $A_4$  监测所得加速度信号如图 4(a)所示,经频谱变换后的数据如图 4(b)所示。从中可知该结构面外 1 阶振动频率为 0.44 Hz,面内 1 阶竖向振动频率为 1.21 Hz。

### 4.2 模型建立

选取 2016 年 8 月~2017 年 4 月共 243 天的环

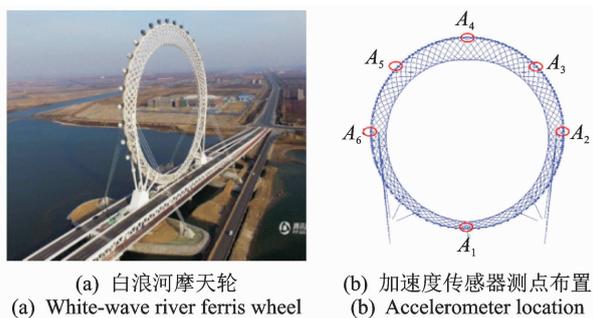
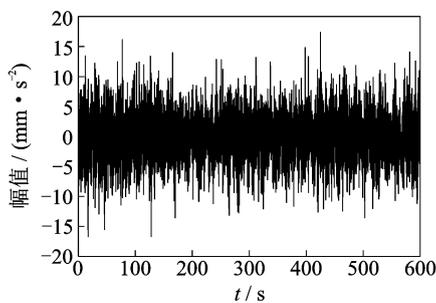
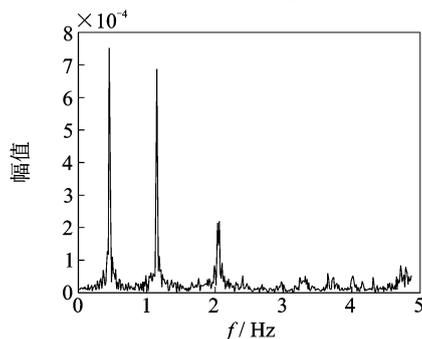


图 3 白浪河摩天轮及加速度传感器测点布置

Fig. 3 White-wave river ferris wheel and accelerometer location



(a)  $A_4$ 测点加速度信号  
(a) Acceleration signal at  $A_4$



(b) 自功率谱  
(b) Auto-power spectrum

图 4  $A_4$  测点加速度信号频谱分析(2017-07-30,6:00~6:10,  $T=20\text{ }^\circ\text{C}$ )

Fig. 4 Spectral analysis of acceleration signal at  $A_4$  (2017-07-30,6:00~6:10,  $T=20\text{ }^\circ\text{C}$ )

境数据和加速度数据进行分析,其中环境数据<sup>[3]</sup>为温度、风速和风向。分别计算环境数据的日平均值和结构模态频率的日平均值,共得到 243 组数据样本。其中风速曲线如图 5(a)所示,温度曲线如图 5(b)所示。由于环境因素对空间钢结构的竖向振型频率影响较大<sup>[2]</sup>,因此选取该结构面内 1 阶竖向振动频率为研究对象,其时程曲线如图 5(c)所示。

建模时选取前 213 组数据作为训练样本,后 30 组数据作为测试样本。PSO-SVR-ARMA 组合模型的初始参数设置如表 1 所示。

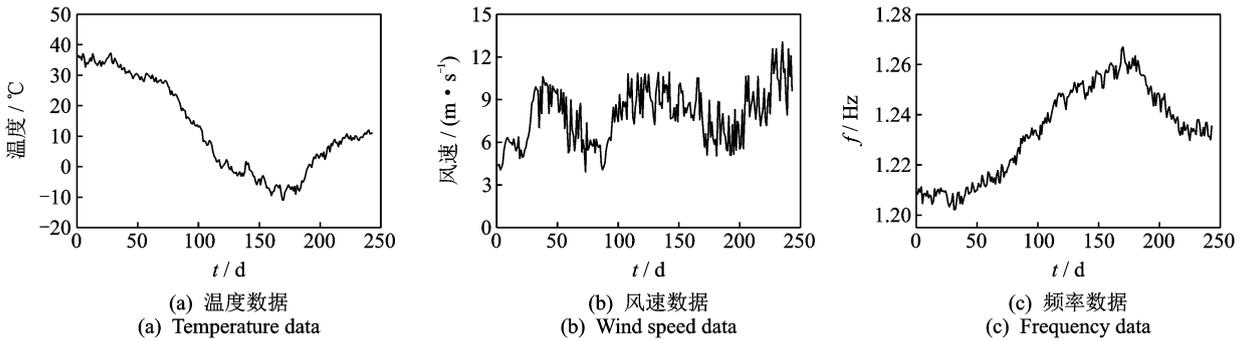


图5 监测数据

Fig. 5 Monitoring data

表1 初始参数设置  
Tab. 1 Initial parameter

算法	参数	取值范围
SVR	$C$	$[0, 100]$
	$\epsilon$	$[0.01, 0.50]$
	$\sigma$	$[0.01, 10]$
PSO	$\omega$	1.0
	$c_1, c_2$	1.5, 1.7
	$n, n_{max}$	20, 200

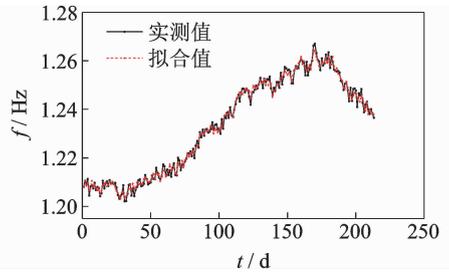


图6 PSO-SVR-ARMA 模型拟合结果

Fig. 6 Fitting result of PSO-SVR-ARMA model

为验证文中提出的频率预测模型的精度,建立SVR, SVR-ARMA, PSO-SVR这3种模型进行对比,其初始参数设置与PSO-SVR-ARMA模型相同。表2给出了不同模型选取的SVR参数 $C$ ,  $\epsilon$ 和 $\sigma$ 的最优组合。

表2 各个模型的参数优化结果

Tab. 2 Parameter optimization results of each model

模型	$C$	$\epsilon$	$\sigma$
SVR	11.962	0.097	7.052
SVR-ARMA	34.223	0.113	3.208
PSO-SVR	22.198	0.094	4.192
PSO-SVR-ARMA	65.321	0.107	0.126

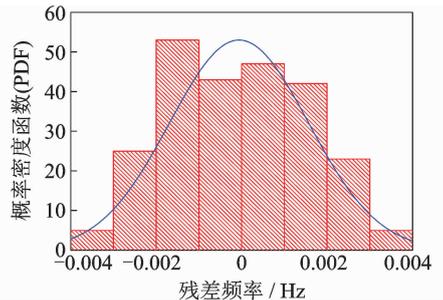


图7 PSO-SVR-ARMA 模型残差分布

Fig. 7 Residues distribution of PSO-SVR-ARMA model

图6给出了PSO-SVR-ARMA组合预测模型训练样本的拟合结果,从中可以看出拟合值与实测值吻合较好,说明该模型拟合性能良好。为检验模型的拟合质量,对其残差进行研究。图7为训练数据拟合残差的概率密度函数与其正态分布拟合的PDF曲线。可知训练样本拟合残差接近 $\mu = 0$ 的正态分布,说明该模型具有较高的拟合精度,能很好地反映环境激励下的频率变化特征。

图8为SVR, SVR-ARMA, PSO-SVR和PSO-SVR-ARMA模型的预测值和实测值比较。从中可以看出4种模型均可预测出模态频率的变化趋势,但其预测精度有所差别。采用均方误差 $e_{ms}$ 、平均

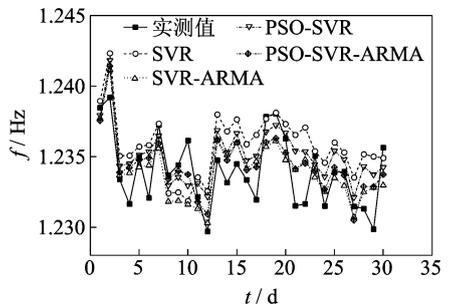


图8 不同模型预测结果

Fig. 8 Forecasting result of each model

绝对百分误差 $e_{map}$ 和均方根误差 $e_{rms}$ 作为评价指标对4种模型的预测精度进行检验。评价指标越小,说明预测精度越高。评价指标的计算公式如下

$$e_{ms} = \frac{1}{m} \sum_{i=1}^m (x_i^* - x_i)^2 \quad (13)$$

$$e_{map} = \frac{1}{m} \sum_{i=1}^m \left| \frac{x_i^* - x_i}{x_i} \right| \times 100\% \quad (14)$$

$$e_{rms} = \sqrt{\frac{1}{m} \sum_{i=1}^m \left( \frac{x_i^* - x_i}{x_i} \right)^2} \times 100\% \quad (15)$$

其中:  $x_i^*$  为预测值;  $x_i$  为实测值;  $m$  为预测样本总数。

4 类模型的预测评价指标值见表 3 所示,可知 SVR 模型的预测性能最差。PSO-SVR 模型的评价指标小于基本的 SVR 模型,说明采用 PSO 算法可提高 SVR 模型的精度。笔者提出的 PSO-SVR-ARMA 模型比 SVR,SVR-ARMA 和 PSO-SVR 模型的  $e_{map}$  分别减小了 22%,11% 和 12%,说明所提模型的泛化性能更好,预测精度更高。

表 3 不同模型的评价结果

Tab. 3 Evaluation results for each model

模 型	$e_{ms} / \times 10^{-3}$	$e_{map} / \%$	$e_{rms} / \%$
SVR	1.75	7.12	9.61
SVR-ARMA	1.60	6.24	9.22
PSO-SVR	1.65	6.32	9.15
PSO-SVR-ARMA	1.47	5.58	8.93

### 4.3 损伤预警仿真分析

基于 PSO-SVR-ARMA 组合预测模型建立的均值控制图如图 9 所示。已知数据均来自于健康状态,从图中也可以看出,其异常指标的数据点均处于控制限以内,数据均值接近于 0 且呈一条水平线。

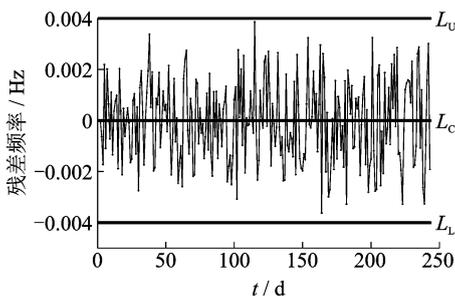


图 9 健康状态下均值控制图

Fig. 9 The healthy mean control chart

为考察 PSO-SVR-ARMA 频率预测模型应用于结构损伤预警中的效果,假设结构整体刚度下降从而模拟结构发生损伤。假定损伤时间发生在第 214 天,此时环境数据同实测数据保持一致,而后 30 天数据样本中结构模态频率发生变化。频率变化的计算公式<sup>[6]</sup>如下

$$f_i = f_i^a - \kappa \bar{f}_i^a \quad (16)$$

其中:  $f_i^a$  为第  $i$  阶模态频率的实测值;  $f_i$  为损伤后

的模态频率值;  $\kappa$  为结构模态频率的损伤程度;  $\bar{f}_i^a$  为第  $i$  阶模态频率实测的平均值。

按照式(16)求得后 30 天的模态频率值并计算频率预测残差,然后将其绘制在健康状态下的均值控制图中。当  $\kappa = 0.1\%$  时,该摩天轮结构模态频率的均值控制图如图 10 所示。从中可以看出,后 30 天数据样本呈现下降趋势,部分结果已经超出  $L_L$  范围,由此可判定结构频率数据异常,即结构已发生损伤。

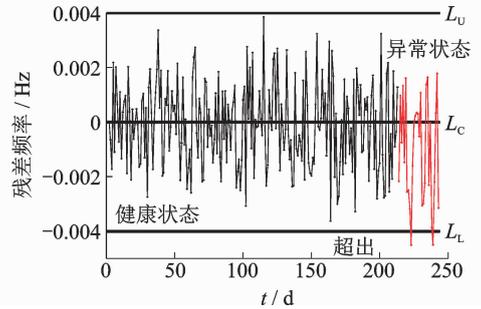


图 10 频率 0.1% 损伤的均值控制图

Fig. 10 The mean control chart of 0.1% damage

表 4 为 4 种不同的频率预测模型可检出的结构损伤程度,其中上下限值的确定是根据健康状态下不同模型的均值控制图所得。从表中可以看出,采用 PSO-SVR-ARMA 模型可识别出该结构由损伤引起的竖向 1 阶模态频率 0.08% 以上的异常变化,明显高于其他模型,具有良好的损伤预警精度。

表 4 不同模型检测结果

Tab. 4 Detection results for each model

模 型	频率上下限值 / Hz	损伤预警精度 / %
SVR	$\pm 6.01 \times 10^{-6}$	0.27
SVR-ARMA	$\pm 4.53 \times 10^{-6}$	0.15
PSO-SVR	$\pm 4.60 \times 10^{-6}$	0.14
PSO-SVR-ARMA	$\pm 4.03 \times 10^{-6}$	0.08

## 5 结 论

1) 采用 PSO 算法可以提高 SVR 模型的泛化能力和精度,基于 PSO 算法建立的 SVR-ARMA 组合模型具有较强的重构能力。

2) 提出了 PSO-SVR-ARMA 频率预测模型的建模方法并建立了摩天轮结构模态频率的预测模型。经检验,所提模型的预测精度与基本 SVR 模型相比提高了 22%。

3) 在 PSO-SVR-ARMA 频率预测模型的基础上结合均值控制图实现了复杂钢结构的损伤预警。

经检验,提出的方法能较好的识别出该结构由损伤引起频率 0.08% 的异常变化,具有较强的损伤敏感性。

## 参 考 文 献

- [1] SOHN H. Effects of environmental and operational variability on structural health monitoring[J]. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2007, 365 (1851): 539-560.
- [2] ZHANG D Y, BAO Y Q, LI H, et al. Investigation of temperature effects on modal parameters of the china national aquatics center[J]. Advances in Structural Engineering, 2012, 15(7): 1139-1153.
- [3] ZHOU H F, NI Y Q, KO J M. Eliminating temperature effect in vibration-based structural damage detection[J]. Journal of Engineering Mechanics, 2011, 137 (12): 785-796.
- [4] 郭西锐,王立新,姜慧,等.风和温度对地王大厦模态频率的影响研究[J].建筑结构,2016,46(16):113-120.  
GUO Xirui, WANG Lixin, JIANG Hui, et al. Study of wind and temperature influences on natural frequencies of Diwang Plaza [J]. Building Structures, 2016, 46(16): 113-120. (in Chinese)
- [5] KO J M, NI Y Q. Technology developments in structural health monitoring of large-scale bridges[J]. Steel Construction, 2005, 27(12): 1715-1725.
- [6] 孙君,李爱群,丁幼亮.润扬大桥悬索桥模态频率-温度的季节相关性研究及其应用[J].工程力学,2009,26(9):50-55.  
SUN Jun, LI Aiqun, DING Youliang, et al. Research on correlation of modal frequency and seasonal temperature of Runyang suspension bridge[J]. Engineering Mechanics, 2009, 26(9): 50-55. (in Chinese)
- [7] 余印根,宗周红,陈宝春,等.环境温度对连续刚构桥模态频率的影响[J].振动、测试与诊断,2014,34(1):69-77.  
YU Yingen, ZONG Zhouhong, CHEN Baochun, et al. Effects of environmental temperature on modal frequency of continuous rigid frame bridge[J]. Journal of Vibration, Measurement and Diagnosis, 2014, 34(1): 69-77. (in Chinese)
- [8] 邓扬,李爱群,刘扬,等.基于监测数据的大跨度悬索桥频率与环境条件的相关性模型[J].中南大学学报(自然科学版),2014,45(7):2401-2409.  
DENG Yang, LI Aiqun, LIU Yang, et al. Correlation models of modal frequencies and environmental conditions for a long-span suspension bridge based on monitoring data[J]. Journal of Central South University (Science and Technology), 2014, 45(7): 2401-2409.

(in Chinese)

- [9] 王立新,朱嘉健,姜慧.珠江黄埔大桥模态频率连续监测中的温度影响 II:温度影响及建模分析[J].震灾防御技术,2016,11(2):251-259.  
WANG Lixin, ZHU Jiajian, JIANG Hui. Temperature influence in modal frequency continuous monitoring of huangpu suspension bridge on the Zhujiang River: temperature influence and model analysis[J]. Technology for Earthquake Disaster Prevention, 2016, 11(2): 251-259. (in Chinese)
- [10] VAPNIK V N. The nature of statistical learning theory[M]. New York: Springer Verlag, 2000: 108-117.
- [11] OHTSUKA Y, OGA T, KAKAMU K. Forecasting electricity demand in Japan: a Bayesian spatial autoregressive ARMA approach [J]. Computational Statistics and Data Analysis, 2010, 54(11): 2721-2735.
- [12] BATES J M, GRANGER C W J. The combination of forecasts [J]. Operational Research Quarterly, 1969, 20(4): 451-468.
- [13] 姚卫红,方仁孝,张旭东.基于混合人工鱼群优化 SVR 的交通流量预测[J].大连理工大学学报,2015,55(6): 632-637.  
YAO Weihong, FANG Renxiao, ZHANG Xudong. Traffic flow forecasting based on optimized SVR with hybrid artificial fish swarm algorithm[J]. Journal of Dalian University of Technology, 2015, 55(6): 632-637. (in Chinese)
- [14] ZHANG Xiu, ZHANG Xin. Thinning of antenna array via adaptive memetic particle swarm optimization [J]. EURASIP Journal on Wireless Communications and Networking, 2017, 2017(1): 183.
- [15] 王真,程远胜.基于受控结构振动响应的控制图损伤识别[J].工程力学,2009,26(8):194-200.  
WANG Zhen, CHENG Yuansheng. The control chart damage identification based on the vibration response of controlled structure. [J]. Engineering Mechanics, 2009, 26(8): 194-200. (in Chinese)
- [16] 张高明,马明,宋涛.潍坊摩天轮节点参数化设计及计算分析[J].建筑结构,2016,46(3):65-69.  
ZHANG Gaoming, MA Ming, SONG Tao. Parametric design and analysis of the joint in the structure of the Weifang Sky Wheel [J]. Building Structures, 2016, 46(3): 65-69. (in Chinese)



第一作者简介:刘哲,男,1986年6月生,博士生。主要研究方向为钢结构设计理论研究及结构健康监测等。曾发表《环境温度对圆拱形钢结构模态频率的影响研究》(《天津大学学报(自然科学与工程技术版)》2019年第52卷第2期)等论文。

E-mail:liuzhe0624@126.com