

基于灰色最小二乘支持向量机的大坝变形预测

任 超^{1,2} 梁月吉^{1,2} 庞光锋^{1,2} 蓝 岚^{1,2}

1 桂林理工大学测绘地理信息学院,桂林市建干路 12 号,541004

2 广西空间信息与测绘重点实验室,桂林市建干路 12 号,541004

摘 要: 提出一种基于灰色最小二乘支持向量机的大坝变形预测新算法。通过对原始大坝序列进行一次累加,弱化序列中随机扰动的影响,增强数据的规律性,进而建立最小二乘支持向量机预测模型,并采用网格搜索法选取最优参数。算法充分利用了最小二乘支持向量机泛化能力强、非线性拟合性好等优良特性,避免了灰色方法及模型存在的理论缺陷。与灰色 GM(1,1)和单一最小二乘支持向量机对比表明,新算法能保证较优的局部预测值和较好的全局预测精度,应用于短期大坝变形预测是可行的。

关键词: 大坝变形;灰色模型;最小二乘支持向量机;网格搜索算法;精度评定

中图分类号:P258

文献标识码:A

大坝在施工或运行过程中会由于各种原因发生不同程度的形变,及时掌握大坝变形的演变规律并作出准确预报,对大坝安全具有重大意义。大坝变形与水压、温度、时效因素之间具有复杂密切的关系,而这些因素往往具有较强的随机性和难以解析的非线性,导致大坝变形较为复杂,难以直接建立较为准确的变形量与影响因素之间的非线性关系模型。针对这一问题,国内外学者已研究出多种模型,如时间序列模型、回归分析模型、灰色模型、神经网络和支持向量机等^[1]。但每一种模型都存在自身的局限性,难以全面考虑负荷的变化趋势和影响因素,直接通过建立单一模型进行变形预测不易得到令人满意的结果。灰色模型提供了在贫信息情况下解决系统问题的新途径,通过自身“累加生成”的特点,能够将复杂的原始数据化为较符合客观规律的时间序列数据,但不足之处是仅适合解决呈指数增长趋势的实际问题。而实际的大坝变形规律往往与指数规律差别较大,不利于灰色模型的建立和预测,且模型参数的求解也存在一定的理论缺陷^[2]。支持向量机(support vector machine, SVM)是 Cortes 等^[3]提出的一种机器学习算法,能较好地解决小样本、非线性和高维模式识别等实际问题,已在变形预测中得到广泛应用。Suykens 等^[4]在 Vapnik 统

计学习理论的基础上提出最小二乘支持向量机(least square support vector machines, LS-SVM),将 SVM 的二次规划问题转换为求解线性方程组的问题,降低了计算的复杂性,提高了求解速度。

基于上述研究,本文提出基于灰色最小二乘支持向量机的大坝变形预测新算法,通过利用灰色预测方法中的“累加生成”原理对原始序列进行预处理,以削弱序列中随机扰动因素的影响,得到规律性较强的新序列,进而建立 LS-SVM 预测模型。同时,考虑到 LS-SVM 的参数优化问题,采用网格搜索法^[5](grid search)进行寻优,该方法用于小样本数据预测时比遗传算法、混沌优化算法较有优势。通过两个算例,并与灰色 GM(1,1)和单一最小二乘支持向量机对比分析,验证该算法的可行性和有效性。

1 灰色最小二乘支持向量机预测模型

1.1 灰色最小二乘支持向量机原理

设大坝原始位移时间序列为:

$$\{x_1^0, x_2^0, \dots, x_n^0\} \quad (1)$$

式中, n 为大坝位移的监测期数。首先对原始位移序列进行一次累加:

$$x_i^1 = \sum_{k=1}^i x_k^0, (i = 1, 2, \dots, n) \quad (2)$$

收稿日期:2014-07-10

项目来源:国家自然科学基金(41461089);广西自然科学基金(2014GXNSFAA118288);广西“八桂学者”岗位专项经费;广西空间信息与测绘重点实验室课题(130511407);大地测量与地球动力学国家重点实验室开放基金(SKLGED2014-3-8-E)。

第一作者简介:任超,教授,主要从事 GPS 高精度数据处理及其应用研究,E-mail:renchao@foxmail.com。

通讯作者:梁月吉,硕士生,主要从事变形监测与数据处理研究,E-mail:lyjayq@163.com。

得到规律性更强的新序列:

$$\{x_1^1, x_2^1, \dots, x_n^1\} \quad (3)$$

然后,以新序列的前 m 期为训练集,后 $(n-m)$ 期为测试集,利用拟合能力更好的 LS-SVM 建立预测模型。设样本训练集为 $\{(x_i, y_i) \mid i = 1, 2, \dots, m\}$,其中, $x_i \in R^n$ 为输入向量, $y_i \in R$ 为输出向量,用非线性映射 $\varphi(\cdot)$ 将样本输入从原空间映射到高维特征空间,构造出 LS-SVM 的回归函数为^[4,6]:

$$f(x) = \mathbf{w}^T \varphi(x) + b \quad (4)$$

式中, $\varphi(x)$ 为满足 Mercer 条件的核函数, \mathbf{w} 为超平面的权值向量, b 为偏置项。

在 LS-SVM 估计中,回归问题可以等价于最小化下面泛函:

$$\begin{cases} \min Q(\mathbf{w}, \mathbf{e}) = \frac{1}{2} \|\mathbf{w}\|^2 + \frac{\gamma}{2} \sum_{i=1}^l e_i^2 \\ \text{s. t. } y_i = \mathbf{w}^T \varphi(x_i) + b + e_i \quad (i = 1, 2, \dots, l) \end{cases} \quad (5)$$

式中, γ 为正则化参数, e_i 为误差项。构造式(5)的 Lagrange 函数为:

$$L(\mathbf{w}, b, \mathbf{e}, \mathbf{a}) = \frac{1}{2} \|\mathbf{w}\|^2 + \frac{\gamma}{2} \sum_{i=1}^l e_i^2 - \sum_{i=1}^l a_i (\mathbf{w}^T \varphi(x_i) + b + e_i - y_i) \quad (6)$$

式中, $\mathbf{a} = [a_1, a_2, \dots, a_l]^T$ 。根据 KKT (Karush-Kuhn-Tucker) 条件,对 Lagrange 函数求偏导获得最优解:

$$\begin{cases} \frac{\partial L}{\partial \mathbf{w}} = 0 \rightarrow \mathbf{W} = \sum_{i=1}^l a_i \varphi(x_i) \\ \frac{\partial L}{\partial b} = 0 \rightarrow -\sum_{i=1}^l a_i = 0 \\ \frac{\partial L}{\partial e_i} = 0 \rightarrow \gamma e_i = a_i \\ \frac{\partial L}{\partial a_i} = 0 \rightarrow \mathbf{w}^T \varphi(x_i) + b + e_i - y_i = 0 \end{cases} \quad (7)$$

式(7)消去 \mathbf{w} 和 e_i 得到线性方程组:

$$\begin{bmatrix} 0 & \mathbf{A}^T \\ \mathbf{A} & K(x_i, y_i) + \gamma^{-1} \mathbf{I} \end{bmatrix} \begin{bmatrix} -b \\ \mathbf{a} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix} \quad (8)$$

其中, $\mathbf{y} = [y_1, y_2, \dots, y_l]^T$, $\mathbf{A} = [1, \dots, 1]^T$, \mathbf{I} 为单位矩阵, $K(x_i, y_i)$ 为满足 Mercer 条件的核函数。

由于 $\mathbf{B} = K(x_i, y_i) + \gamma^{-1} \mathbf{I}$ 为对称的正定矩阵,利用最小二乘运算求解式(8)可得:

$$\begin{cases} b = \frac{\mathbf{A}^T \mathbf{B}^{-1} \mathbf{y}}{\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A}} \\ \mathbf{a} = \mathbf{B}^{-1} (\mathbf{y} - b \mathbf{A}) \end{cases} \quad (9)$$

求解式(6)得到 LS-SVM 的估计函数为:

$$y(x) = \sum_{i=1}^l a_i K(x, x_i) + b \quad (10)$$

最后,计算累加序列的预测值 $y_{m+j}, j = 1, 2, \dots, n-m$, 并对其进行累减还原,得到原始序列的预测模型:

$$x_{m+j}^0 = y_{m+j} - y_{m+j-1} \quad (11)$$

1.2 LS-SVM 参数的优化

最小二乘支持向量机的性能很大程度上取决于核函数 $K(x, y)$ 、核参数 σ 和正则化参数 γ 的最优选择。目前,核函数主要有 3 类:多项式核函数、径向基核函数和线性核函数,其中径向基核函数能较好地反映模型的复杂程度,预测效果比较好。因此,选定其为 LS-SVM 的核函数。考虑到参数选取问题,采用网格搜索法进行参数优选。其基本原理是将 σ 和 γ 在一定的范围划分网格并遍历网格内所有点进行取值,对取定的 σ 和 γ 采用交叉验证方法^[7]获取训练均方误差作为网格点计算的目标函数,最终取训练集验证均方误差最低的那组 σ 和 γ 作为最佳参数。该方法寻优过程中各组参数相互解耦,较好地避免了由于参数多或参数之间可能出现耦合而引起的多解性问题,便于并行计算,且运行效率较高。具体步骤如下^[5]:

1) 设定参数 σ 和 γ 的选择范围和参数步长。本文寻优过程分为粗选和精选两步,设定 σ 的寻优区间为 $[0, 10^{10}]$, γ 的寻优区间为 $[0, 10^{10}]$;粗选格点数为 $10^{10} \times 10^{10}$,步长为 1;精选格点数为 $10^{10} \times 10^{10}$,步长为 0.1。

2) 由于寻优过程是一个遍历过程,因此,参数初始值的选取对结果没有影响。此搜索过程选取的初始值为 $\sigma = 0, \gamma = 1$,选择第一个交叉验证网眼位置,通过交叉验证方法获取训练均方误差 (MES) 作为网格点计算的目标函数,并计算所有的网格点。

3) 选取均方误差最低的一组 (σ, γ) 为最优参数。若选取的参数达不到精度要求,则以选择的参数为中心网格点,在较小的范围内构建新的二维网格平面重新计算目标函数,再次选取均方误差最低的参数。如果满足精度要求,则停止,否则继续重复以上步骤,最终获取精确的参数 σ 和 γ 作为最优值。

2 模型预测流程

某大坝在不同时间段的位移时间序列为 $\{x_1^0, x_2^0, \dots, x_n^0\}$, 对该序列数据进行一次累加得到新序列 $\{x_1^1, x_2^1, \dots, x_n^1\}$ 。以前 m 期的大坝变

形值为训练样本,建立 LS-SVM 预测模型,进而对后 $(n - m)$ 期进行预测,最后累减得到原始序列的预测值 $y_{m+j} (j = 1, 2, \dots, n - m)$ 。模型预测流程如图 1 所示。

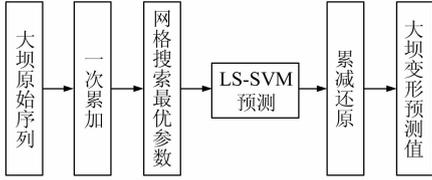


图 1 模型预测流程图

Fig. 1 Flow chart of model prediction

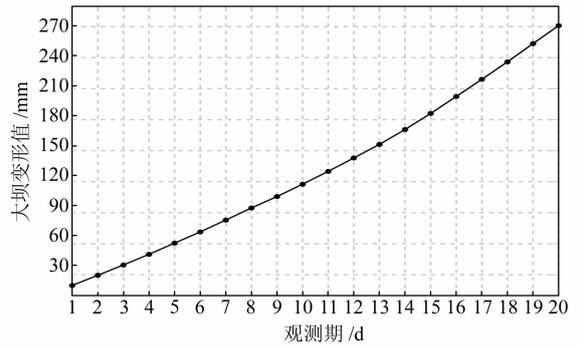


图 3 一次叠加结果

Fig. 3 The results of a superposition

3 算例分析

3.1 算例一

以文献[7]中某大坝径向变形监测数据进行实验。该大坝共布设 C06 和 C11 两个监测基准点,在大坝中部及其两侧分别布设 3 个监测变形点 OP03、OP04 与 OP05。各监测点的切向与径向定义为切向(t)和径向(r)坐标系。为充分反映大坝变形特征,本文采用位于拱坝圆弧顶部监测点 OP03 径向的变化数据(2001-12-31~2002-01-20),径向正轴方向指向雅砻江上游方向,如图 2 所示。

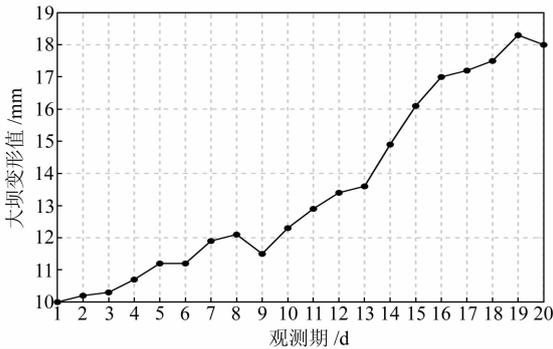


图 2 大坝变形径向位移序列

Fig. 2 Deformation of the dam radial displacement sequence

由图 2 可看出,该大坝位移序列总体呈增长趋势,只有第 6 期、第 9 期和第 20 期有所下降,波动性较弱,大坝最大变形值为 18 mm,最小为 10 mm,差值为 8 mm。采用灰色预测方法中的“累加生成”原理对序列进行一次累加得到如图 3 所示的结果。由图 3 可见,经一次累加生成的新序列曲线较为光滑,变化规律更为明显,有利于模型的建立和分析。

为验证本文提出的基于灰色最小二乘支持向量机在大坝变形预测中的可行性,建立 3 种方案进行算例分析比较:方案 1——灰色 GM(1, 1); 方案 2——单一 LS-SVM 预测模型;方案 3——灰色最小二乘支持向量机预测模型。各方案采用

前 12 期监测数据进行建模训练,后 8 期作为测试样本。经网格搜索法得到,方案 2 的最优参数 σ 为 45.265, γ 为 425 316.516;方案 3 的最优核参数为 10 648.167,正则化参数为 6 540 666.247。3 种方案的预测结果见表 1。

由表 1 可知,方案 1 预测不稳定,预测值和实际值偏差比较大,最大残差达到 -1.85 mm。方案 2 和方案 3 优于方案 1,而方案 3 的预测结果最好,残差最小值为 0.02 mm,最大值仅为 0.39 mm。

3.2 算例二

以文献[8]中某大坝水平位移变形监测数据为例(2003-01-06~2003-01-26)。该大坝共布设 7 个水平位移监测点,由于各点变化规律大致相同,本文仅选择 D4 点进行分析,如图 4 所示。

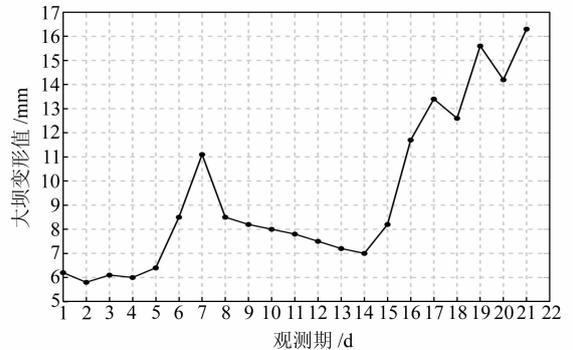


图 4 大坝变形水平位移序列

Fig. 4 Deformation of the dam horizontal displacement sequence

从图 4 可看出,该大坝水平位移序列的第 1~5 期和第 8~14 期变化都比较平缓,而第 6、7 期和第 15~21 期波动大。显然,如果用传统的预测模型,难以真实反映大坝变形的规律。对大坝原始位移序列进行一次累加得到如图 5 所示的结果。由图 5 可知,对于波动性较强、不稳定的大坝位移序列,经一次累加后变得较为光滑,有效减弱了原始序列的随机性,使离乱的原始数据中蕴涵的规律能够充分显露出来,突出了大坝变形规律。

表 1 各模型计算结果对比/mm
Tab.1 The contrast of each model calculation results/mm

| 观测期 | 大坝实测数据 | GM(1,1) | | LS-SVM | | 灰色最小二乘支持向量机 | |
|-----|--------|---------|-------|--------|-------|-------------|------|
| | | 预测值 | 残差 | 预测值 | 残差 | 预测值 | 残差 |
| 13 | 13.60 | 13.64 | 0.04 | 13.60 | 0.00 | 13.62 | 0.02 |
| 14 | 14.90 | 14.57 | -0.33 | 14.85 | -0.05 | 14.94 | 0.04 |
| 15 | 16.10 | 15.62 | -0.48 | 15.88 | -0.22 | 16.16 | 0.06 |
| 16 | 17.00 | 16.98 | -0.02 | 16.49 | -0.51 | 17.10 | 0.10 |
| 17 | 17.20 | 15.45 | -1.75 | 16.60 | -0.60 | 17.35 | 0.15 |
| 18 | 17.50 | 16.94 | -0.56 | 16.75 | -0.75 | 17.71 | 0.21 |
| 19 | 18.30 | 16.45 | -1.85 | 17.02 | -1.28 | 18.59 | 0.29 |
| 20 | 18.00 | 16.98 | -1.02 | 16.94 | -1.06 | 18.39 | 0.39 |

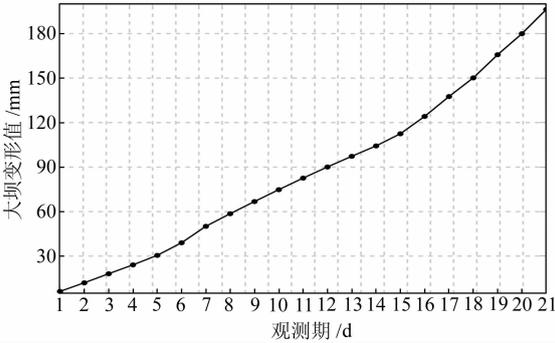


图 5 一次叠加结果

Fig. 5 The results of a superposition

同算例一,建立 3 种方案进行比较。采用前 12 期监测数据进行建模训练,后 9 期作为测试样

本。3 种方案的预测结果见表 2。同理得到,方案 2 的最优参数 σ 为 108.526, γ 为 25 412.613;方案 3 的最优核参数为 7 256.758,正则化参数为 5 625 282.435。预测结果见表 2。

从表 2 可看出,方案 1 和方案 2 预测不稳定,部分预测值和实际值偏差比较大,方案 1 最大残差达到 -2.11 mm,方案 2 残差最大为 -1.43 mm。方案 3 残差最小值为 0.01 mm,最大值仅为 0.53 mm。可见,对于波动较大和不稳定的大坝变形序列,灰色 GM(1,1)的预测结果已远远偏离监测值,单一最小二乘支持向量机的部分预测结果也不够稳定,而灰色最小二乘支持向量机模型的预测效果较好,能够保证较优的局部预测值。

表 2 各模型计算结果对比/mm
Tab.2 The contrast of each model calculation results/mm

| 观测期 | 大坝实测数据 | GM(1,1) | | LS-SVM | | 灰色最小二乘支持向量机 | |
|-----|--------|---------|-------|--------|-------|-------------|------|
| | | 预测值 | 残差 | 预测值 | 残差 | 预测值 | 残差 |
| 13 | 7.2 | 7.13 | -0.07 | 7.19 | -0.01 | 7.21 | 0.01 |
| 14 | 7.0 | 7.10 | 0.10 | 6.99 | -0.01 | 7.02 | 0.02 |
| 15 | 8.2 | 7.40 | -0.80 | 8.20 | 0.00 | 8.24 | 0.04 |
| 16 | 11.7 | 9.59 | -2.11 | 11.65 | -0.05 | 11.76 | 0.06 |
| 17 | 13.4 | 13.98 | 0.58 | 13.08 | -0.32 | 13.51 | 0.11 |
| 18 | 12.6 | 14.65 | 2.05 | 12.44 | -0.16 | 12.76 | 0.16 |
| 19 | 15.6 | 13.99 | -1.61 | 14.53 | -1.07 | 15.86 | 0.26 |
| 20 | 14.2 | 14.96 | 0.76 | 13.67 | -0.53 | 14.57 | 0.37 |
| 21 | 16.3 | 15.79 | -0.51 | 14.87 | -1.43 | 16.83 | 0.53 |

为进一步综合评定本文算法的性能,采用均方根误差和平均绝对误差两项指标进行评定(表 3)。

表 3 各模型精度对比/mm

Tab.3 The contrast of each model precision/mm

| 预测模型 | 算例一 | | 算例二 | |
|------------|-------|--------|-------|--------|
| | 均方根误差 | 平均绝对误差 | 均方根误差 | 平均绝对误差 |
| 灰色 GM(1,1) | 1.01 | 0.76 | 1.27 | 1.01 |
| LS-SVM | 0.71 | 0.56 | 0.44 | 0.27 |
| 灰色 LS-SVM | 0.20 | 0.16 | 0.18 | 0.13 |

由表 3 可知,灰色 GM(1,1)的预测精度较低,两个算例的均方根误差分别为 1.01 mm 和 1.27 mm,单一最小二乘支持向量机表现出较好的预测精度,优于灰色 GM(1,1)。而本文算法的预测精度明显较高,均方根误差分别为 0.20 mm

和 0.18 mm,平均绝对误差分别仅为 0.16 mm 和 0.13 mm。可见,灰色最小二乘支持向量机预测模型在一定程度上保证了较好的全局预测精度。综上,新算法通过采用灰色原理对原始序列进行预处理,能有效削弱原始序列的随机性并增加规律性,利用最小二乘支持向量机优良的学习性能,能紧跟数据的变化规律。同时,对于不同尺度变化的大坝变形预测,效果都比较好。新算法无论是预测结果还是预测精度,都优于灰色 GM(1,1)和单一最小二乘支持向量机,能在一定程度上有效解决复杂的大坝变形问题,当直接建立 LS-SVM 预测模型无法满足精度要求时,可以采用此算法。

4 结 语

针对大坝变形具有随机性和非线性等特点, 本文将灰色理论和最小二乘支持向量机相结合引入到大坝变形短期预测。经理论和算例分析, 并与灰色 GM(1,1) 和单一最小二乘支持向量机对比表明, 传统的灰色 GM(1,1) 预测模型由于自身存在的理论缺陷, 预测效果和实际偏差较大, 难以解决复杂的变形问题; 单一最小二乘支持向量机的预测效果和实际值较为接近, 体现出 LS-SVM 在解决小样本、贫信息和多维数的复杂非线性问题中的优势; 而本文新算法不仅引入灰色预测方法独特的数据生成方式, 增加原始数据的规律性, 减少数据的随机性, 且充分发挥了 LS-SVM 强大的非线性映射能力, 预测精度优于灰色 GM(1,1) 和单一最小二乘支持向量机。同时, 采用网格搜索方法可快速地选取 LS-SVM 的最佳参数。

参考文献

[1] 马文涛. 基于小波变换和 GALSSVM 的边坡位移预测[J]. 岩土力学, 2009, 30(2): 394-398 (Ma Wentao. The Slope Displacement Prediction Based on Wavelet Transform and GALSSVM[J]. Rock and Soil Mechanics, 2009, 30(2): 394-398)

[2] 张大海, 江世芳, 史开泉. 灰色预测公式的理论缺陷及改进[J]. 系统工程理论与实践, 2002, 22(8): 1-3 (Zhang Dahai, Jiang Shifang, Shi Kaiquan. Theoretical Defect of

Grey Prediction Formula and Its Improvement[J]. System Engineering Theory and Practice, 2002, 22(8): 1-3)

[3] Cortes C, Vapnik V. Support Vector Networks [J]. Machine Learning, 1995, 20(3): 273-297

[4] Suykens J A K, Vandewalle J. Least Squares Support Vector Machine Classifiers[J]. Neural Processing Letters, 1999, 9(3): 293-300

[5] Liu X L, Jia D X, Li H. Research on Kernel Parameter Optimization of Support Vector Machine in Speaker Recognition[J]. Science Technology and Engineering, 2010, 10(7): 1 669-1 673

[6] Brabanter K, Brabanter J, Suykens J A K, et al. Approximate Confidence and Prediction Intervals for Least Squares Support Vector Regression[J]. IEEE Transactions on Neural Networks, 2010, 22(1): 110-120

[7] Ito K, Nakamo R. Optimizing Support Vector Regression Hyperparameters Based on Crossvalidation[C]. International Joint Conference on Neural Networks, 2003

[8] 蒋廷臣, 张勤, 周立, 等. 基于小波方法的非线性回归模型研究[J]. 测绘学报, 2006, 35(4): 337-341 (Jiang Tingchen, Zhang Qin, Zhou Li, et al. The Nonlinear Regression Model Based on Wavelet Method Research [J]. Acta Geodactica et Cartographica Sinica, 2006, 35(4): 337-341)

[9] 焦明连, 蒋廷臣. 基于小波分析的灰色预测模型在大坝安全监测中的应用[J]. 大地测量与地球动力学, 2009, 29(2): 115-117 (Jiao Minglian, Jiang Tingchen. The Grey Prediction Model Based on Wavelet Analysis in the Application of Dam Safety Monitoring[J]. Journal of Geodesy and Geodynamics, 2009, 29(2): 115-117)

Dam Deformation Prediction Based on Grey Least Square Support Vector Machines

REN Chao^{1,2} LIANG Yueji^{1,2} PANG Guangfeng^{1,2} LAN Lan^{1,2}

1 College of Geomatics and Geoinformation, Guilin University of Technology, 12 Jiangan Road, Guilin 541004, China

2 Guangxi Key Laboratory of Spatial Information and Geomatics, 12 Jiangan Road, Guilin 541004, China

Abstract: A new algorithm based on gray least squares support vector machine for dam deformation prediction is presented. First, the algorithm of the original dam sequence is summed to weaken the impact of the random disturbance factors sequence and enhance the data regularity. Second, the least squares support vector machine model is established. The grid search method is used to select the optimal parameters. This method makes full use of least squares support vector machine generalization ability; the nonlinear fitting of good quality characteristics avoids defects of the theoretical methods and gray models. The calculation result is analyzed and compared with GM(1, 1) and a single least squares support vector machine. The results show that the new algorithm can guarantee the optimum value of the local forecasts and better overall prediction accuracy in dam deformation. It is feasible to apply the model in short-term forecasts.

Key words: dam deformation; grey model; least square support vector machines; grid search algorithm; accuracy assessment