

DOI: 10.20040/j.cnki.1000-7709.2023.20230211

混凝土特高拱坝变形监测的智能优化支持向量机模型

王 鹏¹, 康 飞¹, 张忠举²

(1. 大连理工大学水利工程学院, 辽宁 大连 116023; 2. 中国水利水电第十工程局有限公司, 四川 成都 610000)

摘要: 拱坝变形监测模型是拱坝健康监测中最常用的方法。针对特高拱坝的变形监测问题,提出了一种混凝土特高拱坝的智能优化支持向量机变形监测模型。采用粒子群算法(PSO)优化支持向量机(SVM)的惩罚因子、核函数参数及容忍偏差,建立基于 PSO-SVM 的混凝土特高拱坝变形监测模型,分析了时效因子对模型性能的影响。工程实例表明,混凝土特高拱坝的 PSO-SVM 变形监测模型有着良好的预测精度及泛化能力,适用于特高拱坝的变形监测。

关键词: 特高拱坝; 支持向量机; 变形监测; 时效因子

中图分类号: TV698.1

文献标志码: A

文章编号: 1000-7709(2023)11-0073-04

1 引言

在长期运行过程中特高拱坝的安全状况对整个水利工程至关重要^[1]。而变形是反映大坝运行状况的直观体现,因此建立合理的特高拱坝变形监测模型有重要意义。目前,特高拱坝变形监测模型主要有多元回归变形监测模型^[2]、神经网络变形监测模型^[3]等。多元回归模型多适用于大样本、线性关系条件,神经网络模型易出现学习时间长、过拟合等问题。而支持向量机可处理小样本、多维度、非线性关系且泛化能力强,因此在大坝安全监测中应用广泛^[4]。特高拱坝变形条件复杂,除水压、温度、地震及混凝土和地质构造外,河谷收缩、地壳运动等因素也会引起特高拱坝变形。因此,本文引入支持向量机用于特高拱坝的变形监测,但支持向量机参数不易确定,故引入粒子群优化算法对支持向量机模型进行参数寻优,建立特高拱坝支持向量机变形监测模型;同时,分析了影响特高拱坝支持向量机变形监测模型预测精度的主要因素;最后,通过实例分析验证了该方法的可行性。

2 特高拱坝变形监测多元回归模型

特高拱坝位移除受库水压力影响外,还受温

度、渗流、周围环境及时效等因素影响。因此,需从诸多影响因素中,寻找出最主要的影响因素并建立数学表达式。大坝上任意一点的位移均主要由水压力、扬压力、泥沙压力和温度荷载引起^[5]。按照不同影响因素可将 t 时刻的位移 $\delta(t)$ 分为水压分量 $\delta_H(t)$ 、温度分量 $\delta_T(t)$ 、时效分量 $\delta_\theta(t)$ 即:

$$\delta(t) = \delta_H(t) + \delta_T(t) + \delta_\theta(t) \quad (1)$$

拱坝的水压分量取 H 、 H^2 、 H^3 、 H^4 四项为水压因子。水压分量取用正余弦温度分子,构成拱坝的水压—季节—时间(HST)安全监控模型;温度分量取用大坝内传感器实测温度,构成拱坝的水压—温度—时间(HTT)安全监控模型;时效分量成因复杂,采用指数函数的形式来表达,时效因子的表达式为:

$$\delta_\theta = C_1 [1 - \exp(-Ct)] \quad (2)$$

式中, C_1 、 C 分别为常数、时效影响参数。

最终拱坝 HST 变形监测模型与 HTT 变形监测模型自变量因子设计分别为:

$$\delta = \sum_{i=1}^4 a_i H^i + b_0 + \sum_{i=1}^n \left(b_{1i} \sin \frac{2\pi i t}{365} + b_{2i} \cos \frac{2\pi i t}{365} \right) + C_1 [1 - \exp(-Ct)] \quad (3)$$

$$\delta = \sum_{i=1}^4 a_i H^i + \sum_{i=1}^M b_i T_i + C_1 [1 - \exp(-Ct)] \quad (4)$$

式中, H 为水压因子,取上游水深; b_0 为回归常

收稿日期: 2023-02-17, 修回日期: 2023-03-20

基金项目: 国家重点研发计划(2022YFB4703400); 国家自然科学基金项目(52079022, 51979027); 中央高校基本科研业务费项目(DUT21TD106)

作者简介: 王鹏(1996-),男,硕士研究生,研究方向为大坝安全监测与数值分析,E-mail: wangpeng134987@163.com

通讯作者: 康飞(1982-),男,教授、博导,研究方向为大坝安全监测与数值分析,E-mail: kangfei@dlut.edu.cn

数; b_{1t}, b_{2t} 均为回归系数; n 为 1 或 2; t 为自监测日起至始测日的天数除以 365; T 为传感器实测温度数据; M 为传感器个数。

3 特高拱坝变形监控的智能优化支持向量机模型

3.1 支持向量机 SVM

设给定训练样本 $(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i) \in \mathbf{R}^m \times \mathbf{R}$, 将低维空间通过非线性映射 $\varphi(x)$ 映射到高维空间, 并在高维空间中构造线性回归函数 $f(x) = \omega^T \varphi(x) + b$ 。以结构风险最小化原则寻求 ω, b , 即:

$$\min \left(\frac{1}{2} \|\omega\|^2 + c \sum_{i=1}^l \xi_i + \xi_i^* \right) \quad (5)$$

$$\text{s. t.} \begin{cases} y_i - \omega^T \varphi(x_i) - b \leq p + \xi_i \\ \omega^T \varphi(x_i) + b - y_i \leq p + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (6)$$

式中, ω 为权向量; b 为常数; c 为惩罚因子, $c > 0$; ξ_i, ξ_i^* 均为松弛变量; p 为线性回归函数两侧间距, 容忍偏差; l 为训练样本数。

通过引入 Lagrange 乘子将上述优化问题转化为对偶问题:

$$\max L(\alpha_i, \alpha_i^*) = -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \cdot$$

$$K(x_i, x_j) - p \sum_{i=1}^l (\alpha_i + \alpha_i^*) + \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) \quad (7)$$

$$\text{s. t.} \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0 \quad 0 \leq \alpha_i, \alpha_i^* \leq 0 \quad (8)$$

式中, α_i, α_i^* 均为 Lagrange 乘子; $K(x_i, y_i)$ 为径向基核函数。

核函数公式为:

$$K(x_i, y_i) = \exp(-g \|x_i - x_j\|^2) \quad (9)$$

式中, g 为核参数。

SVM 的回归函数可表示为:

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i, y_i) + b \quad (10)$$

上述过程满足 KKT (Karush-Kuhn-Tucker) 条件, 有且只有在式(10)中 $(\alpha_i - \alpha_i^*)$ 为非零值时, 才可确定决策函数。

3.2 参数寻优

采用粒子群优化算法对 c, g, p 进行寻优。

粒子群速度—位置更新公式为:

$$v_{id}^{k+1} = v_{id}^k + c_1 r_1 (p_{id}^k - x_{id}^k) + c_2 r_2 (p_{gd}^k - x_{id}^k) \quad (11)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (12)$$

式中, v_{id}^k, x_{id}^k 分别为 d 维中粒子 i 在第 k 次迭代中的速度和位置; c_1, c_2 分别为个体学习因子、社会学习因子; r_1, r_2 均为 0~1 间的随机数; p_{id}^k 为粒子 i 在 d 维的个体极值; p_{gd}^k 为粒子群在 d 维中的全局极值。

3.3 特高拱坝变形监测支持向量机模型建模步骤

采用绝对最大误差 ($A_{AE_{\max}}$)、平均绝对误差 ($A_{AE_{\text{mean}}}$)、均方根误差 (R_{RMSE})、决定系数 R^2 评估模型效果。 $A_{AE_{\max}}, A_{AE_{\text{mean}}}, R_{\text{RMSE}}$ 的值越小则模型性能越好, R^2 的范围为 $[0, 1]$, 其值越接近 1 则模型各因子间相关性越强。具体的特高拱坝 PSO-SVM 变形监测模型建立步骤如下。

步骤 1 根据大坝安全监测系统, 将其分为训练样本、测试样本两大类, 将样本进行归一化至 $[0, 1]$ 范围。

步骤 2 使用粒子群算法优化种群参数, 同时设置种群规模、惯性权重因子、迭代次数等各项参数^[6]。

步骤 3 计算粒子适应度值, 更新粒子速度、位置等参数。粒子适应度值越小, 代表此时粒子位置最优。

步骤 4 判断最优参数的结束条件, 判断迭代次数能否满足设定值或适应度值是否达到设定数值, 若达到, 优化算法结束; 否则, 参数优化继续^[7]。

步骤 5 使用基于步骤 1~4 得到的优化参数, 建立基于支持向量机的拟合模型。

步骤 6 训练支持向量机模型, 对特高拱坝进行性能预测。

4 实例分析

西南某特高拱坝最大坝高 285.5 m, 坝顶轴线长 678.65 m, 大坝于 2014 年完工。坝体自左岸至右岸均匀分为 31 个坝段。根据监测数据选取坝体径向位移较大的[#]15、[#]22 坝段, 并以[#]15 坝段的 PL15-1 测点及[#]22 坝段的 PL22-1 测点的实测径向位移监测数据为例来进行分析。其中[#]15 坝段 PL15-1 测点选取 2014 年 7 月 4 日至 2018 年 3 月 31 日共 585 组数据作为训练样本, 2018 年 4 月 2 日至 2018 年 12 月 31 日共 138 组数据作为测试样本; [#]22 坝段 PL22-1 测点取 2014 年 7 月 6 日至 2018 年 3 月 31 日共 583 组数据作为训练样本, 2018 年 4 月 2 日至 2018 年 12 月 31 日共 138 组数据作为测试样本。由于实测

数据中无[#] 15 坝段温度监测资料,故取用相邻的[#] 16 坝段上传感器测点数据。由于温度测点较多,故取其中有代表性的温度传感器,挑选后[#] 15 坝段为 15 个温度因子,[#] 22 坝段为 19 个温度因子。测点布置情况见图 1,拱坝测点(正垂线)布置图见图 2。




图 1 温度与应力应变传感器布置图

Fig. 1 Temperature and stress-strain sensor layout




图 2 拱坝径向位移测点正垂线布置图

Fig. 2 Vertical line layout of the radial displacement measurement points of the arch dam

在特高拱坝蓄水初期,时效变形相差较大,故讨论时效参数 C 在 $[0.1, 1]$ 范围内 SVM 变形监测模型的表现。通过 PSO-SVM 模型寻优,找到在不同时效参数 C 下的 c, g, p 的最优值,使得对应的时效参数 C 值时的变形监测模型性能最佳。最终特高拱坝 HST 支持向量机变形监测模型与 HTT 支持向量机变形监测模型输入量分别为:

$$X = [H, H^2, H^3, H^4, \sin 2\pi t + \cos 2\pi t, \sin 4\pi t + \cos 2\pi t, 1 - \exp(-Ct)] \quad (13)$$

$$X = [H, H^2, H^3, H^4, T_1, \dots, T_M, 1 - \exp(-Ct)] \quad (14)$$

式中, H 为坝前水深; t 为监测日至始测日的天数除以 365; T 为温度因子; M 为所选取的温度传感器个数。

[#] 15、[#] 22 坝段不同 C 值下的 SVM 变形监测模型评价指标见表 1。

表 1 [#] 15、[#] 22 坝段支持向量机 HST、HTT 模型时效分量参数影响分析

Tab. 1 Influence analysis of time component parameters of SVM-HST and SVM-HTT model in [#] 15 and [#] 22 dams

坝段	模型	C	$A_{AE_{max}}$		$A_{AE_{mean}}$		R_{RMSE}		R^2			
			训练	测试	训练	测试	训练	测试	训练	测试		
[#] 15	SVM-HST	0.1	4.221 2	1.621 9	0.506 3	0.568 0	0.739 6	0.669 4	0.998 8	0.998 1		
		0.3	3.686 2	1.523 6	0.480 9	0.536 5	0.682 2	0.633 4	0.999 0	0.998 4		
		0.5	3.451 1	1.592 3	0.442 7	0.529 6	0.626 9	0.645 0	0.999 2	0.998 2		
		0.6	3.607 9	2.255 9	0.391 9	0.542 9	0.602 1	0.726 8	0.999 2	0.997 8		
		0.65	2.971 0	2.204 1	0.421 5	0.573 0	0.566 4	0.766 8	0.999 3	0.997 9		
		0.7	3.569 7	2.838 1	0.365 9	0.582 8	0.572 9	0.851 9	0.999 3	0.997 2		
		0.8	3.010 9	3.134 4	0.340 7	0.627 2	0.510 8	0.972 2	0.999 4	0.996 4		
		1	3.061 5	4.361 3	0.267 9	0.824 8	0.411 3	1.296 7	0.999 6	0.994 4		
		[#] 15	SVM-HTT	0.1	2.537 6	1.925 3	0.361 2	0.547 7	0.469 5	0.674 4	0.999 5	0.998 1
				0.3	2.571 2	1.915 2	0.357 8	0.521 5	0.468 5	0.635 2	0.999 5	0.998 4
0.5	2.880 4			2.060 8	0.373 6	0.437 2	0.495 8	0.567 0	0.999 5	0.998 6		
0.6	2.824 8			1.920 5	0.388 8	0.423 1	0.511 8	0.547 4	0.999 4	0.998 7		
0.65	2.855 6			1.994 1	0.393 6	0.397 6	0.520 2	0.527 7	0.999 4	0.998 8		
0.7	2.834 5			2.045 3	0.394 6	0.408 2	0.520 6	0.546 0	0.999 4	0.998 7		
0.8	2.763 6			2.249 1	0.402 8	0.434 7	0.526 1	0.577 7	0.999 4	0.998 6		
1	2.816 5			2.600 6	0.408 8	0.516 0	0.532 9	0.700 4	0.999 4	0.997 9		
[#] 22	SVM-HST			0.1	5.193 9	2.094 3	0.931 0	0.701 9	1.220 9	0.861 8	0.995 6	0.996 3
				0.3	3.665 0	3.648 6	0.387 0	1.002 9	0.563 5	1.363 8	0.999 1	0.991 2
		0.5	4.413 8	2.190 5	0.619 3	0.777 9	0.915 0	0.976 2	0.997 5	0.997 1		
		0.6	4.371 8	2.294 5	0.607 3	0.884 9	0.897 6	1.073 0	0.997 6	0.997 3		
		0.65	4.365 5	2.428 7	0.599 6	0.973 9	0.885 5	1.162 6	0.997 7	0.997 3		
		0.7	4.348 5	2.507 5	0.594 9	1.056 4	0.879 0	1.231 9	0.997 7	0.997 5		
		0.8	1.619 9	4.629 9	0.140 7	1.092 1	0.222 5	1.451 8	0.999 9	0.989 4		
		1	1.333 6	4.995 7	0.110 0	1.027 1	0.185 6	1.432 9	0.999 9	0.990 8		
		[#] 22	SVM-HTT	0.1	2.364 1	2.628 1	0.452 3	0.849 9	0.552 6	1.028 4	0.999 1	0.994 4
				0.3	3.793 8	2.783 6	0.449 2	0.828 4	0.691 2	1.058 4	0.998 6	0.994 9
0.5	4.269 6			2.732 4	0.469 9	0.686 1	0.730 9	0.918 1	0.998 4	0.995 2		
0.6	2.388 8			2.991 9	0.497 7	0.799 1	0.618 9	0.996 7	0.998 9	0.993 9		
0.65	2.385 6			2.732 1	0.526 3	0.702 3	0.660 5	0.899 0	0.998 7	0.994 9		
0.7	2.334 8			3.007 2	0.499 0	0.763 7	0.630 8	0.968 5	0.998 8	0.995 1		
0.8	4.176 4			3.159 6	0.491 1	0.875 2	0.755 9	1.077 1	0.998 3	0.995 4		
1	2.790 4			3.517 5	0.517 6	1.067 1	0.671 4	1.308 9	0.998 7	0.993 5		

由表 1 得出,[#] 15、[#] 22 两坝段 HST 与 HTT 模型受时效参数的影响明显。为进一步分析 SVM 监控模型的性能,现给出在 HST、HTT 模型时效因子 $C=0.65$ 时 SVM 变形监测模型、逐步回归模型、多元回归模型的性能指标见表 2。

表 2 [#] 15 坝段不同方法 HST、HTT 模型的性能指标表

Tab. 2 The performance of different methods in HST and HTT model in [#] 15 dam

模型	方法	$A_{AE_{max}}$		$A_{AE_{mean}}$		R_{RMSE}		R^2	
		训练	测试	训练	测试	训练	测试	训练	测试
HST	多元回归	4.813 5	4.515 5	1.027 7	2.085 9	1.322 1	2.446 2	0.996 3	0.994 4
	逐步回归	4.373 5	4.976 1	1.002 4	2.108 2	1.300 5	2.506 5	0.996 4	0.994 0
	SVM	2.971 0	2.204 1	0.421 5	0.573 0	0.566 4	0.766 8	0.999 3	0.997 9
HTT	多元回归	3.994 2	3.736 6	0.807 7	1.020 5	1.039 2	1.326 8	0.997 7	0.996 9
	逐步回归	4.246 9	3.989 9	0.812 9	1.089 7	1.049 7	1.421 4	0.997 7	0.996 8
	SVM	2.855 6	1.994 1	0.393 6	0.397 6	0.520 2	0.527 7	0.999 4	0.998 8

取[#] 15 坝段 PL15-1 测点 $C=0.65$ 时的 HST 模型,作为 SVM 变形监测模型的代表(此时惩罚因子 $c=9.936 7$,核函数参数 $g=0.098$,容忍偏差 $p=0.001$),不同模型测点径向位移预测结果、误差分析见图 3。

由表 1 可知,在蓄水初期,时效分量参数 C

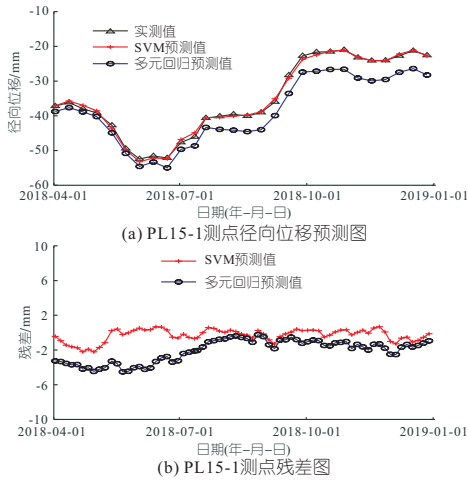


图 3 不同模型径向位移预测图、残差图

Fig. 3 Radial displacement prediction plot and residual plot of different models

对#15、#22两个坝段的变形有较大影响。以测试样本中的绝对最大误差、平均绝对误差作为主要参考,参数 C 在 $[0.1, 0.7]$ 范围时,SVM特高拱坝变形监测模型的性能较为理想。由表2可知,以最大绝对误差与均方根误差为参考,SVM特高拱坝监测模型回归精度明显优于多元回归监测模型回归精度。由图3可知,SVM特高拱坝变形监测模型拟合效果较好,预测结果与实测值几乎重合,而多元回归模型结果与实测值前期基本重合,后期出现了较大偏差;且SVM特高拱坝变形监测模型的残差在 $[-2, 1]$ 之间波动,而传统多元回归变形监测模型的残差在 $[-4, -1]$ 之间波动,残差明显更大。

5 结论

Intelligent Optimization Support Vector Machine Model for Concrete Extra-high Arch Dam Deformation Monitoring

WANG Peng¹, KANG Fei¹, ZHANG Zhong-ju²

(1. School of Hydraulic Engineering, Dalian University of Technology, Dalian 116023, China;

2. Sinohydro Bureau 10 Co., Ltd., Chengdu 610000, China)

Abstract: The arch dam deformation monitoring model is the most commonly used method for arch dam health monitoring. Aiming at the deformation monitoring problem of extra-high arch dams, this paper proposes an intelligent optimization support vector machine deformation monitoring model for concrete extra-high arch dams. Particle swarm optimization (PSO) was used to optimize the penalty factor, kernel function parameters of the support vector machine (SVM), and tolerate bias. The deformation monitoring model of concrete extra-high arch dam based on PSO-SVM was established, and the influence of aging factors on the model performance was analyzed. Engineering examples show that the PSO-SVM deformation monitoring model of concrete extra-high arch dam has good prediction accuracy and generalization ability, which is suitable for deformation monitoring of extra-high arch dam.

Key words: extra high arch dam; support vector machines; deformation monitoring; aging factor

a. PSO-SVM 变形监测模型在对特高拱坝变形进行预测分析时,体现出了良好的非线性拟合性和适应性,适用于特高拱坝的安全监测。

b. SVM 特高拱坝变形监测模型在预测精度方面优于传统多元回归模型,最大绝对误差与均方根误差有明显提升。

c. 时效因子 C 的变化对 SVM 特高拱坝变形监测模型精度影响明显,其中 C 在 $[0.1, 0.7]$ 范围内时,所求精度效果最佳。

参考文献:

- [1] 顾冲时,苏怀智. 混凝土坝工程长效服役与风险评定研究述评[J]. 水利水电科技进展, 2015, 35(5): 1-12.
- [2] 韩亚平,辛全才,庞先明,等. 务川沙坝变形监测回归分析[J]. 人民黄河, 2013, 35(7): 98-100.
- [3] 威丹,包腾飞,康业渊,等. 基于逐步回归-BP神经网络的大坝变形监测模型[J]. 水电能源科学, 2013, 31(8): 109-111, 98.
- [4] 苏怀智,温志萍,吴中如. 基于 SVM 理论的大坝安全预警模型研究[J]. 应用基础与工程科学学报, 2009, 17(1): 40-48.
- [5] 吴中如. 水工建筑物安全监控理论及其应用[M]. 北京:高等教育出版社, 2003.
- [6] MIRJALILI S. SCA: A sine cosine algorithm for solving optimization problems [J]. Knowledge-based systems, 2016, 96: 120-133.
- [7] KANG FEI, LI JUNJIE. Displacement model for concrete dam safety monitoring via Gaussian process regression considering extreme air temperature[J]. Journal of structural engineering, 2020, 146(1): 05019001.