

DOI:10.3876/j.issn.1000-1980.2018.04.011

基于改进 M5'-主成分模型树的高心墙堆石坝沉降变形预测

王 飞,张宗亮,王佳俊,佟大威,任炳昱

(天津大学水利工程仿真与安全国家重点实验室,天津 300072)

摘要: 针对高心墙堆石坝沉降变形过程动态非线性特点,建立基于改进 M5'-主成分模型树的高心墙堆石坝沉降变形分析模型,在采用相关性分析甄选沉降变形影响因素和采用主成分分析将高维影响因素空间进行降维的基础上,利用该全局分段非线性模型对高心墙堆石坝沉降过程进行分析。通过与沉降量实测值对比,验证了改进 M5'-主成分模型树的有效性。通过绝对差值和均方根误差 2 个指标对比分析改进 M5'-主成分模型树与 M5'模型树、多元线性回归模型、主成分回归分析模型的预测结果,表明改进 M5'-主成分模型树预测沉降量具有更高的精度。

关键词: 心墙堆石坝;沉降预测;M5'模型树;相关性分析;主成分回归分析

中图分类号:TV641.4⁺¹ 文献标志码:A 文章编号:1000-1980(2018)04-0353-07

Forecasting of the settlement deformation for high core rock-fill dam based on the improved M5'-PCR model tree

WANG Fei, ZHANG Zongliang, WANG Jiajun, TONG Dawei, REN Bingyu

(State Key Laboratory of Hydraulic Engineering Simulation and Safety, Tianjin University, Tianjin 300072, China)

Abstract: Considering the nonlinear and dynamic characteristics of settlement deformation, a global piecewise nonlinear analysis model of settlement deformation is proposed based on the modified M5'-principal component (M5'-PCR) model tree, to analyze the settlement process by selecting the influence factors with correlation analysis and reducing the dimension of high dimensional influence factors with principal component analysis method. The the improved M5'-PCR model tree is verified by comparing with the measured settlement. By comparing the prediction results of improved M5'-PCR model tree, M5' model tree, multiple linear regression, and principal component regression analysis model through the absolute difference and the root mean square error, the results show that improved M5'-PCR model tree has a higher precision in settlement prediction and provides a new approach for the analysis of dam settlement deformation.

Key words: core rock-fill dam; settlement forecast; M5' model tree; correlation analysis; principal component regression

大坝变形能够综合反映坝体和坝基的物理力学性态效应,是重要的安全监控和安全预警指标^[1]。由于大坝变形通常是由多种随机和非线性因素耦合作用引起,如自重、水压力等,使得大坝变形预测较困难^[2-4]。大坝变形预测的传统方法主要有统计模型、确定性模型和混合模型方法^[5]。目前,时间序列模型、灰色系统理论模型及人工神经网络模型等方法的引入丰富了大坝变形分析方法^[6-8]。回归分析是变形分析中的一种

基金项目: 国家自然科学基金创新群体基金(51621092);国家重点基础研究发展计划(973 计划)(2013CB035906);国家自然科学基金(51339003)

作者简介: 王飞(1986—),男,博士研究生,主要从事水利水电工程施工质量评估与大坝安全分析研究。E-mail:yishuixiaohan@tju.edu.cn

引用本文: 王飞,张宗亮,王佳俊,等. 基于改进 M5'-主成分模型树的高心墙堆石坝沉降变形预测[J]. 河海大学学报(自然科学版),2018,46(4):353-359.

WANG Fei, ZHANG Zongliang, WANG Jiajun, et al. Forecasting of the settlement deformation for high core rock-fill dam based on the improved M5'-PCR model tree[J]. Journal of Hohai University(Natural Sciences), 2018, 46(4):353-359.

基本统计建模方法,它利用影响因素与变形量之间的回归关系对大坝变形进行分析及预测^[9]。灰色系统理论方面,苏观南等^[10]建立了卡尔曼滤波灰色模型,消除扰动误差,对变形进行灰色预测;神经网络方面,刘健等^[11]提出了基于遗传神经网络的大坝变形预测模型。此外,吴斌平等^[2]提出了考虑时间影响的神经网络组合模型,对灰色模糊模型和遗传神经网络模型进行组合,综合了大坝变形过程的灰色性和模糊性,充分考虑了大坝变形的不确定性,利用了遗传神经网络算法和灰色模糊算法具有全局搜索和非线性拟合等优点。Breiman等^[12]提出了 CART 系统,用分段常数逼近非线性函数,但此方法不适合对连续值进行预测。针对这个问题,Wu等^[13]提出了基于 M5 算法的模型树模型,此模型是一系列分段线性模型组合而成的全局非线性模型,可以用于连续数值的预测,而且节点处的线性模型会选择对因变量更具有意义的变量作为回归变量。在此基础上,Wang等^[14]改进 M5 算法,提出一阶线性的 M5'模型树,使模型树的结构更小,预测精度更高。M5'模型树能将输入变量空间自动划分,处理高维输入问题^[15-16]。目前 M5'模型树已经广泛应用于回归预测等问题^[17]。

高心墙堆石坝沉降变形是一个动态持续过程,然而上述变形分析模型常作为静态模型,使得模型缺乏灵活性,尤其是存在影响因素动态变化导致拟合效果不佳的问题。因此笔者提出基于改进 M5'-主成分模型树(M5'-PCR)的心墙堆石坝沉降分析模型,在叶节点处用主成分回归分析(PCR)代替多元线性回归(MLR),从而避免了变量间的多重共线性,并且动态更新建模数据集,将 M5'模型树改进为不断生长的模型,更贴近大坝沉降过程。

1 研究方法

1.1 高心墙堆石坝沉降变形分析数学模型

高心墙堆石坝沉降变形分析数学模型如式(1)所示:

S = F(X) (1)

{ F ∈ [F1, F2, F3, ...] S ∈ [S1, S2, ..., St, St+1, ...] X ∈ [X1, X2, ..., Xd, Xd+1, ...] Xd ⊆ [hd, lnθd, sinGd, sinGdcosGd, lw7d, lw7d, ...] (2)

其中 θd = d/100 Gd = 2πd/365

式中:S——累积沉降量集;St——t时刻的累积沉降量,mm;X——影响因素集;Xd——各影响因素及其表达式值;hd——测点以上填筑厚度,m;lnθd、sinGd、sinGdcosGd——时间因素;d——测点从初次读数到再次读数的累积时间,d;lw7d——对应d时间的水位,m;lw7d——7d平均水位,m;F——影响因素与累积沉降量之间函数关系,本文中为通过改进 M5'-主成分模型树模型获得的各子模型对应的函数关系。

1.2 M5'-主成分模型树改进步骤

a. 动态更新建模数据集。传统分析方法的建模数据集选定后不变,因此根据此数据集建立的影响因素与预测变量之间的关系也相对不变,然而这并不符合大坝沉降变形的实际过程;因此,笔者将新沉降数据及相关影响因素数据不断补充到建模数据集中,实现建模数据集更新,用以挖掘影响因素与大坝变形量之间关系的变化。

b. 动态更新 M5'模型树。根据 M5'模型树的建模方法,以每次更新后的数据集为基础依次建立一系列模型,在此过程中模型树将有新的节点产生,即挖掘出新的关系,可将此视为模型树在不断生长,从而完成 M5'模型树的更新。

c. 在叶节点用主成分回归模型替换多元线性模型,既避免了影响因素与其自身的系数解释相矛盾的现象,又避免了把部分具有实际意义的影响因素视为噪声剔除的情况,同时亦消除了变量之间可能存在多重共线性的影响。

改进的 M5'-主成分模型树结构如图 1 所示。图中 a、b、c 分别对应改进 M5'-主成分模型树的主要步骤。

1.3 改进 M5'-主成分模型树建模

M5'模型树是一种在叶节点采用线性回归模型的决策树。与决策树的 CART 系统使用分类数据相比,




图 1 改进 M5'-主成分模型树结构

Fig. 1 Structure of the improved M5'-PCR model tree

改进 M5'-主成分模型树还可以使用定量数据。改进 M5'-主成分模型树的建模需要 3 个阶段,即模型树劈分、模型树剪枝、模型树平滑。

1.3.1 模型树劈分

改进 M5'-主成分模型树将输入与输出变量之间的关系转换为分段线性关系。改进 M5'-主成分模型树根据样本方差削减 (standard deviation reduction, SDR) 进行劈分,SDR 准则详见文献[17]。

如图 2 所示,以二维输入(X_1, X_2)、一维输出(Y)问题为例,输入空间被改进 M5'-主成分模型树算法劈分成 6 个子空间(即叶),并在每个子空间均建立一个子模型,每个子模型可以分别命名为 M5'-PCR_{*j*}。模型树细化模型的空间划分可以视为递归空间二分化问题:首先要确定分化规则,其次决定在何处劈分。解决上述 2 个问题后,输入变量空间按此规则递归划分。




图 2 改进 M5'-主成分模型树

Fig. 2 Improved M5'-PCR model tree

设 X_1 具有 n 个样本,分别按样本值排序,得到序列:

$$X_1^* = \{x_1^{(1)}, x_1^{(2)}, \dots, x_1^{(n)}\} \tag{3}$$

其中 $x_1^{(1)} < x_1^{(2)} < \dots < x_1^{(n)}$ 。

依次对 X_1^* 按照 $x_1^{(2)}, x_1^{(3)}, \dots, x_1^{(n-1)}$ 进行二分,共有 $n-2$ 种分法,可以得到 $n-2$ 个样本方差消减值,记其中最大值为 $S_{\text{DR,max}}(X_1^*)$,对应分割点 $x_1^{(X_1^*)}$ 。对 X_2 进行同样的处理,记其最大值为 $S_{\text{DR,max}}(X_2^*)$,分割点为 $x_2^{(X_2^*)}$ 。

若 $S_{\text{DR,max}}(X_1^*) \geq S_{\text{DR,max}}(X_2^*)$,则首先对 X_1 进行劈分,劈分点为 $x_1^{(X_1^*)}$;反之,则对 X_2 进行劈分,对应劈分点为 $x_2^{(X_2^*)}$ 。

按照上述步骤可以获得图 2(a) 所示的第一个空间分割线 $X_2=2$, 及图 2(b) 模型树的根节点 $X_2>2$ 。对分割后的平面按照上面的步骤即可以实现对平面的持续分割, 即模型树不断生长; 但是模型树不可能无限生长下去, 因此需要设定停止条件。当分割节点样本数量少于某一数量或节点的样本属性的标准差与总体样本属性标准差的比值小于某一限定值 δ (一般取值 0.05) 时即停止生长。本文模型树的生长结束条件选择前者, 树节点样本数量取 4。

综上所述, 对于本文中的多维输入问题, 模型树的劈分需要确定 2 个参数: 劈分输入分类属性和劈分阈值。模型树停止劈分的节点称为叶节点, 对各叶节点的样本, 利用主成分回归分析方法建立子模型。

1.3.2 模型树剪枝

为了提高模型树整体的简洁性和效率, 需要用叶节点取代某些子树, 为此需要利用主成分回归方法遍历模型树的各个节点, 并拟合出每个节点的主成分回归方程。剪枝的标准是预测误差减少量:

$$E_R = NR_{MSE} - N_L R_{MSEl} - N_R R_{MSEr}$$

(4)

式中: N ——根节点的样本数量; N_L ——左叶节点的样本数量; N_R ——右叶节点的样本数量; R_{MSE} ——该节点拟合的回归方程预测的均方根误差; R_{MSEl} ——该节点劈分后左叶节点预测的均方根误差; R_{MSEr} ——该节点劈分后右叶节点预测的均方根误差。

当 $E_R>0$ 时, 保留该子树; 反之, 则将该子树转变成叶节点, 并最终递归完成模型树的剪枝。

1.3.3 模型树平滑

模型树剪枝之后, 树的相邻叶节点处可能会出现一定程度的不连续性。对此, Quinlan 提出对叶节点回归模型的平滑方法^[13,18]。由于每个叶节点都已存在一个具有相同参数的回归方程, 因此子叶节点与父节点的 2 个回归方程可合成 1 个新的线性方程, 各个变量属性的系数通过式(5)计算:

$$f_j = \frac{np_j + kq_j}{n + k}$$

(5)

式中: f_j ——平滑后模型第 j 个变量的系数; n ——当前节点的样本数; p_j ——当前叶节点当前模型第 j 个变量的系数; k ——平滑系数(通常取值 15); q_j ——当前节点父节点模型的第 j 个变量的系数。

若当前节点采用合并的新模型后 R_{MSE} 变化小于某一设定的阈值, 则取代原叶节点的回归模型; 反之, 当前叶节点不进行平滑处理。

经过以上 3 个步骤完成改进 M5'-主成分模型树模型的建模。

2 工程实例

2.1 工程简介

A 水利水电工程由心墙堆石坝、左岸溢洪道和左岸引水系统组成; 心墙堆石坝最大坝高 261.5 m, 坝体总填筑量 3 360 万 m^3 , 总库容 237.03 亿 m^3 , 调节库容 113.35 亿 m^3 。

本文所采用的数据由三部分组成: 坝体内部监测仪器监测得到的大坝沉降数据、库水位监测数据和大坝碾压施工质量实时监控历史数据。考察埋设在坝体内的由监测设备组成的监测网, 选定心墙区距离心墙底部 116.0 m 的某监测点, 选取该监测点的大坝垂直位移序列 80 组, 同时获取并匹配上游库水位监测数据。此外, 通过分析统计 A 水电站心墙堆石坝施工碾压质量实时监控系^[19]记录的大坝施工历史数据, 可以获得沉降量和记录当天的大坝填筑厚度数据。

2.2 大坝沉降变形影响因素相关性分析

结合 A 水电站高心墙堆石坝心墙区选定的监测点沉降量序列对影响因素进行相关性分析。影响大坝沉降变形的因素主要有时间因素(即时效因素)、填筑因素(即自重因素)、水位变化因素(即水压因素)及温度因素, 由于堆石坝内部变形对温度并不敏感^[20], 因此本文只考虑时间因素、填筑因素与水位因素等 3 种影响因素; 此外区间段水位变化对沉降亦有影响^[21], 故影响大坝沉降变形的填筑因素由 h_d 、 h_d^2 、 h_d^3 、 h_d^4 表示; 水位因素由 l_{wd}^2 、 l_{wd}^3 、 l_{wd}^4 与 l_{w7d} 、 l_{w7d}^2 、 l_{w7d}^3 、 l_{w7d}^4 表示; 时间因素选取 θ_d 、 $\ln \theta_d$ 、 $\sin G_d$ 、 $\sin G_d \cos G_d$ 表示。填筑因素 h_d 和水位因素 l_{wd} 、 l_{w7d} 的各个表达式之间完全相关, θ_d 与 $\ln \theta_d$ 完全相关。因此对于完全相关的变量表达式, 则只保留一个作为改进 M5'-主成分模型树模型的输入。对沉降量与影响因素之间进行相关性分析, 结果表明: 大坝沉降影响因素变量的各表达值均通过了显著性 0.05 的检验。经剔除后的影响因素与大坝沉降变形量

S 在显著性水平 0.05 下均具有显著相关性。

2.3 基于改进 M5'-主成分模型树的大坝沉降变形分析

由大坝沉降量与影响因素相关性分析可知,选定的填筑因素 h ,水位因素 l_w 、 l_{w7} 和时间因素 $\ln \theta$ 、 $\sin G$ 、 $\sin G \cos G$ 是互不完全相关的独立自变量,可以作为改进 M5'-主成分模型树模型的输入变量。根据 M5'-主成分模型树建模方法,建立模型树树状图如图 3 所示。

从图 3 可以看出,改进 M5'-主成分模型树模型把影响因素与沉降的动态关系分成若干个线性模型。改进 M5'-主成分模型树模型中各子模型的各项参数如表 1 所示。

M5'模型树将除填筑厚度以外的时间因素和水位因素均视为噪声并将其排除在回归模型之外,这表明填筑因素在施工期对沉降起着主导作用;从表 1 可以看出,改进 M5'-主成分模型树将具有实际意义的水压因素与时间因素引入回归模型中,弥补了 M5'模型树在预测大坝沉降分析方面的不足,并且挖掘出新的模型关系。

表 1 改进 M5'-主成分模型树中各子模型变量系数
Table 1 Coefficients of linear models for M5'-PCR model tree

模型	h	$\ln \theta_d$	$\sin G_d$	$\sin G_d \cos G_d$	l_{wd}	l_{w7d}	常数项
M5'-PCR ₁	0.431	1.560	6.486	9.650	-0.155	0.199	-23.695
M5'-PCR ₂	0.397	0	24.452	-13.425	0.152	0.165	-207.116
M5'-PCR ₃	0.190	0	0	-1.548	0.071	0.340	-244.532
M5'-PCR ₄	0.280	0	57.802	0	0.155	0.417	-407.428
M5'-PCR ₅	1.127	0	-61.859	0	0.623	1.749	-1 550.710
M5'-PCR ₆	0.459	19.765	-10.217	20.080	0.328	0.332	-370.169

通过将填筑因素、水位因素和时间因素数据作为 M5'-主成分模型树模型的输入,从而对大坝沉降变形进行拟合,并与沉降量实测值进行对比,结果如图 4 所示。

从图 4 可以看出,改进 M5'-主成分模型树对沉降变形的拟合结果在整体趋势和细节上都符合沉降过程,尤其对于观测时间间隔比较短的序列(如 0~30 序列),改进 M5'-主成分模型树拟合结果与沉降实测值吻合程度很高;此外,上游库水位与沉降量、填筑厚度与沉降量之间整体呈正相关。0~50 d 上游水位基本稳定,沉降过程受填筑厚度的影响明显;50~100 d 上游水位的增长率超过了填筑厚度的增长率,上游水位的快速上涨进一步促进了沉降过程的发展。同时可知,改进 M5'-主成分模型树拟合值与实测值比较吻合。

2.4 不同大坝沉降模型预测对比分析

通过对比 M5'模型树、多元线性回归模型及主成分回归分析模型的分析关联度 R ,对比评估指标绝对差值率 R_{MAE} 和均方根误差率 R_{MSE} 等值,从而深入讨论改进 M5'-主成分模型树预测大坝沉降变形的优势与不足。关联度 R 表示模型与真实关联函数的相似程度,越接近 1 表明模型越接近真实关联函数; R_{MAE} 用评判预测值与真实值之间的差异程度,反映个体样本的预测效果程度,取值越小说明预测效果越好; R_{MSE} 则反映样本总体的预测效果,其值越小越好。

改进 M5'-主成分模型树与 M5'模型树、多元线性回归模型及主成分回归模型对高心墙堆石坝施工期沉降量的预测结果如表 2 所示,不同模型的评估指标如表 3 所示。




图 3 改进 M5'-主成分模型树树状图
Fig. 3 Diagram of the improved M5'-PCR model tree




图 4 改进 M5'-主成分模型树拟合大坝沉降量
Fig. 4 Settlement fitting based on the improved M5'-PCR model tree

表2 M5'-主成分模型树与其他模型的预测沉降量对比

Table 2 Prediction comparison between M5'-PCR and other models

mm

实测沉降量	沉降量预测值			
	M5'模型树模型	多元线性回归模型	主成分回归模型	改进 M5'-主成分模型树模型
113.02	113.958	115.102	114.001	112.116
115.51	118.039	118.593	115.659	115.007
117.19	120.198	120.215	116.695	116.986
122.08	126.203	124.441	119.254	122.215
129.20	129.644	123.017	121.959	131.244

从表3可以看出,改进 M5'-主成分模型树模型拟合沉降量与实测沉降量之间的关联度最大(为0.999),说明该模型预测结果与真实沉降情况最接近,并且绝对差值和均方根误差都最小(分别为0.758、1.030),其后顺次为 M5'模型树模型、主成分回归分析模型与多元线性模型,这说明改进 M5'-主成分模型树模型对沉降过程的预测更精确。综上所述,利用改进 M5'-主成分模型树模型可有效地对高心墙堆石坝沉降变形进行分析。

表3 M5'-主成分模型树与不同模型的评估指标对比

Table 3 Assessment index comparison between M5'-PCR and other models

模型	R	R_{MAE}	R_{MSE}
M5'模型树模型	0.972	2.208	2.258
多元线性回归模型	0.822	3.347	3.655
主成分回归模型	0.992	2.338	3.511
改进 M5'-主成分模型树模型	0.999	0.758	1.030

3 结 语

结合大坝沉降变形动态非线性特点,针对传统模型存在影响因素数据动态变化导致拟合和预测精度不高的问题,提出基于改进 M5'-主成分模型树的高心墙堆石坝沉降变形分析模型,并应用于高心墙堆石坝沉降变形分析。分析得出以下结论:

- a. 通过动态更新建模数据集、动态更新 M5'模型树和用主成分回归模型替换多元线性模型,建立了改进 M5'-主成分模型树,可以充分利用具有实际意义的影响因素信息。
- b. 将改进 M5'-主成分模型树模型应用于大坝施工期沉降变形分析,充分发挥了 M5'模型树算法对数据拟合的优势。通过绝对差值和均方根误差的对比分析,表明改进 M5'-主成分模型树模型比 M5'模型树模型、多元线性回归模型、主成分回归分析模型具有更高的精度。本文方法为高心墙堆石坝沉降变形分析提供了新的途径。

参考文献:

[1] 邱莉婷,沈振中,聂柏松. 基于逐步回归分析-马尔科夫链模型的大坝变形预测[J]. 水电能源科学, 2014, 32(5):51-55. (QIU Liting, SHEN Zhenzhong, NIE Baisong. Deformation prediction of dam based on stepwise regression analysis-Markov chain model[J]. Water Resources and Power, 2014,32(5):51-55. (in Chinese))

[2] 吴斌平,岳攀,鄢玉玲,等. 考虑时间影响的神经网络组合模型对心墙堆石坝变形的研究[J]. 水力发电学报, 2016,35(9):78-86. (WU Binping, YUE Pan, YAN Yuling, et al. Prediction of core rock-fill dam deformation by artificial neuralnetwork combination models considering time factor[J]. Journal of Hydroelectric Engineering, 2016,35(9):78-86. (in Chinese))

[3] 徐伟,何金平. 基于多尺度小波分析的大坝变形自回归预测模型[J]. 武汉大学学报(工学版), 2012, 45(3):285-289. (XU Wei, HE Jinping. Forecast model of dam deformation based on multi-scale wavelet analysis and autoregressive method [J]. Engineering Journal of Wuhan University, 2012, 45(3):285-289. (in Chinese))

[4] 张豪,许四法. 基于经验模态分解和遗传支持向量机的多尺度大坝变形预测[J]. 岩石力学与工程学报, 2011,30(增刊2):3681-3688. (ZHAGN Hao, XU Sifa. Multi-scale dam deformation prediction based on empirical mode decomposition and genetic algorithm for support vector machines (GA-SVM)[J]. Chinese Journal of Rock Mechanics and Engineering, 2011,30(Sup2):3681-3688. (in Chinese))

[5] 顾冲时,吴中如. 大坝与坝基安全监控理论和方法及其应用[M]. 南京:河海大学出版社,2006.

[6] 兰孝奇,杨永平,黄庆,等. 建筑物沉降的时间序列分析与预报[J]. 河海大学学报(自然科学版), 2006, 34(4):426-

429. (LAN Xiaoqi, YANG Yongping, HUANG Qing, et al. Time series analysis and forecast[J]. Journal of Hohai University (Natural Sciences), 2006, 34(4):426-429. (in Chinese))

[7] 王穗辉, 潘国荣. 基于 MATLAB 多变量灰色模型及其在变形预测中的应用[J]. 土木工程学报, 2005, 38(5):24-27. (WANG Suihui, PAN Guorong. Multivariate grey model and application in deformation prediction based on MATLAB[J]. Journal of Civil Engineering, 2005, 38(5):24-27. (in Chinese))

[8] 魏健, 胡吉平, 谭衢霖, 等. BP 神经网络在高层建筑沉降预测中的应用[J]. 北京测绘, 2013, 2(4):25-27. (WEI Jian, HU Jiping, TAN Qulin, et al. High rise building settlement prediction using BP neural network[J]. Beijing Surveying, 2013, 2(4):25-27. (in Chinese))

[9] 卢俊, 戴吾蛟, 张浙涛. 大坝变形系数回归建模[J]. 武汉大学学报(信息科学版), 2015, 40(1):139-142. (LU Jun, DAI Wujiao, ZHANG Zhetao. Modeling dam deformation using varying coefficient regression[J]. Geomatics and Information Science of Wuhan University, 2015, 40(1):139-142. (in Chinese))

[10] 苏观南, 郑东健, 孙斌斌. 卡尔曼滤波灰色模型在大坝变形中的应用[J]. 水电能源科学, 2014, 32(4):37-40. (SU Guannan, ZHENG Dongjian, SUN Binbin. Application of Kalman filtering gray model in prediction of dam deformation [J]. Water Resources and Power, 2014, 32(4):37-40. (in Chinese))

[11] 刘健, 蔡建军, 程森. 基于遗传神经网络的大坝变形预测模型研究[J]. 山东大学学报(工学版), 2006, 36(2):62-66. (LIU Jian, CAI Jianjun, CHENG Sen. Research on dam displacement forecast model based on genetic algorithm neural network [J]. Journal of Shandong University(Engineering Science), 2006, 36(2):62-66. (in Chinese))

[12] BREIMAN L, FRIEDMAN J H, OLSHEN R, et al. Classification and regression trees[J]. Biometrics, 1984, 40(3):358.

[13] WU X, KUMAR V, QUINLAN J R, et al. Top 10 algorithms in data mining[J]. Knowledge & Information Systems, 2008, 14(1):1-37.

[14] WANG Y, FRANK E, INGLIS S, et al. Using model trees for classification[J]. Machine Learning, 1998, 32(1):63-76.

[15] RAHIMIKHOOB A. Comparison of M5 model tree and artificial neural network's methodologies in modelling daily reference evapotranspiration from NOAA satellite images[J]. Water Resour Manage, 2016, 30(9):3063-3075.

[16] WANG L, KISI O, ZOUNEMAT Kermani M, et al. Prediction of solar radiation in China using different adaptive neuro-fuzzy methods and M5 model tree[J]. International Journal of Climatology, 2016, 37(3):265-279..

[17] 章坚民, 刘登涛, 吴光中, 等. 采用 M5'模型树和测量数据识别抽气式机组气耗量特性[J]. 中国电机工程学报, 2011, 31(23):21-26. (ZHANG Jianmin, LIU Dengtao, WU Guangzhogn, et al. Working condition characteristics identification for extraction unit by using M5' model tree and measured data[J]. Proceedings of CSEE, 2011, 31(23):21-26. (in Chinese))

[18] ETEMAD-SHAHIDI A, MAHJOobi J. Comparison between M5' model tree and neural networks for prediction of significant wave height in lake superior[J]. Ocean Engineering, 2009, 36(15): 1175-1181.

[19] 钟登华, 刘东海, 崔博. 高心墙堆石坝碾压质量实时监控技术及应用[J]. 中国科学:技术科学, 2011, 41(8):1027-1034. (ZHONG Denghua, LIU Donghai, CUI Bo. Real-time compaction quality monitoring of high core rockfill dam[J]. Scientia Sinica(Technologica), 2011, 41(8):1027-1034. (in Chinese))

[20] 宋志宇. 基于智能计算的大坝安全监测方法研究[D]. 大连:大连理工大学, 2007.

[21] 李红祥, 岳东杰, 李立瑞. 基于主成分回归的大坝位移模型[J]. 水电自动化与大坝监测, 2008, 32(5):61-64. (LI Hongxiang, YUE Dongjie, LI Lirui. Dam displacement model based on principal component regression [J]. Hydropower Automation and Dam Monioring, 2008, 32(5):61-64. (in Chinese))

(收稿日期:2017-06-18 编辑:高建群)