

DOI:10.3969/j.issn.1672-1144.2019.01.028

基于 ELM 模型的混凝土坝坝基渗压预测

张 蒙, 喻和平, 陈玉江

(长沙理工大学 水利工程学院, 湖南 长沙 410004)

摘 要: 为更精确的预测某混凝土坝坝基渗压变化趋势以保证大坝安全, 利用混凝土重力坝渗压监测数据建立基于极限学习机(Extreme Learning Machine, ELM)的大坝基础渗压预测模型, 并与传统逐步回归和传统 BP 神经网络方法进行对比。结果表明: ELM 模型能够准确反映大坝坝基渗透系统的不确定性非线性关系, 相比于逐步回归模型, ELM 模型则可使 h_{mse} 减幅至少有 34.1%, 误差区间降低有 36.5%。ELM 模型在精度和稳定性上均优于其余 2 种模型, 其仿真曲线与测点渗压实测动态基本一致。该模型可作为渗透压力预测的推荐模型。

关键词: 混凝土坝; 渗透压力; 神经网络; 极限学习机; 预测

中图分类号: TV642

文献标识码: A

文章编号: 1672-1144(2019)01-0159-04

Seepage Pressure Prediction of Dam Foundation Based on ELM

ZHANG Meng, YU Heping, CHEN Yujiang

(School of Hydraulic Engineering, Changsha University of Science and Technology, Changsha, Hunan 410004, China)

Abstract: In order to more accurately predict the seepage pressure variation trend of a concrete dam foundation, the seepage monitoring data of concrete gravity dams are used to establish the extreme learning machine (ELM) model. ELM model is compared with traditional stepwise regression and BP neural network. The results showed that the ELM model could accurately reflect the uncertainty non-linear relationship of dam foundation seepage system, compared with stepwise regression model, ELM model can reduce the root mean square error (h_{mse}) by at least 34.1% and error interval by 36.5%. Obviously, the ELM model is better than the other 2 models in accuracy and stability, and its simulation curve is basically consistent with the measured seepage pressure. The ELM could be used as a recommended model to predict seepage pressure.

Keywords: concrete dam; seepage pressure; neural network; extreme learning machine; forecasting

坝基渗透压力是影响混凝土坝稳定的一个重要因素, 准确可靠的渗透压力分析及预测是大坝安全评价及运行管理的重要组成部分^[1]。目前, 在渗压拟合方面应用较多的是集成时间序列(ITS)模型, 逐步回归分析法作为 ITS 中的代表性方法在渗压分析预报方面取得了不错的成绩^[2-4]。喻和平等^[5]依据小浪底大坝监测资料建立逐步回归统计模型, 验证了其对于大坝坝基渗压预测的可靠性。但逐步回归分析法具有数理统计方法的固有缺点, 如原始数据需满足平稳性假设, 计算时忽略外部驱动因子影响, 对

短时间序列的拟合效果差等^[4]。

相比于 ITS, 人工神经网络(Artificial Neural Network, ANN)对非线性系统拟合的优势已被证实^[6], BP 模型具有对非线性问题的高仿真性能, 适应性及拟合精度优于逐步回归方法^[7]。但传统的 ANN 亦存在固有的缺陷, 如需要较多的学习样本, 很难求得全局最优解等。极限学习机算法(Extreme Learning Machine, ELM)作为一种新型的单隐层前馈神经网络学习算法, 较好地克服了传统 ANN 模型的缺点^[8-9]。

收稿日期: 2018-09-13

修稿日期: 2018-10-09

基金项目: 湖南省大坝安全与病害防治工程技术研究中心开放基金资助项目(hndbgczx001)

作者简介: 张 蒙(1994—), 男, 湖南醴陵人, 硕士研究生, 研究方向为水工结构安全监测。E-mail: 814935387@qq.com

通讯作者: 喻和平(1972—), 女, 湖南长沙人, 博士, 副教授, 主要从事水利水电和岩土工程方面的研究工作。E-mail: 413702004@qq.com

本文利用重力坝实测资料建立基于 ELM 的渗透压力预测模型,以渗透压力作为研究指标进行实例预测,并与逐步回归分析法和 BP 神经网络方法进行对比,建立渗透压力的高精度预测模型,以期为水库运行管理及大坝渗透压力控制提供科学依据。

1 模型建立

1.1 极限学习机(ELM)

ELM 为单隐层前馈神经网络^[10],其典型的单隐层神经网络(SLFN)数学模型为:

$$t_j = \begin{bmatrix} t_{1j} \\ t_{2j} \\ \vdots \\ t_{mj} \end{bmatrix}_{m \times 1} = \begin{bmatrix} \sum_{i=1}^l \beta_{i1} g(\omega_i x_j + b_i) \\ \sum_{i=1}^l \beta_{i2} g(\omega_i x_j + b_i) \\ \vdots \\ \sum_{i=1}^l \beta_{im} g(\omega_i x_j + b_i) \end{bmatrix}_{m \times 1} \quad (j = 1, 2, \dots, D) \quad (1)$$

式中: $g(x)$ 为网络激活函数; b_i 为中间隐含层神经元的阈值; ω_{in} 为连接输入层和中间隐含层的权值; β_{im} 为连接中间隐含层和输出层的权值。

将式(1)转化为:

$$H\beta = T' \quad (2)$$

其中 T' 为 T 的转置, $T = [t_1, t_2, \dots, t_n]_{m \times D}$; H 为隐含层输出矩阵。

根据 ELM 算法定理:当 $l < D$ 时,SLFN 的训练误差可逼近任意 $\epsilon > 0$ 。即 $g(x)$ 无限可微时, ω_{in} 和 b_i 在训练前可随机选择,并始终不变^[11]。 β_{im} 可由式(3)进行求解。

$$\min_{\beta} \| H\beta - T' \| \quad (3)$$

1.2 BP 神经网络(BPANN)

BPANN 作为目前在渗压预测中运用最广泛的模型^[12-13]之一,是典型前馈型神经网络,其采用梯度下降法反复迭代计算并根据结果调整权值和阈值,使网络仿真结果与实测值之误差平方和不断减小至预设值。理论上三隐层 BPANN 模型可实现任意非线性函数的拟合^[14-15],本文遂采用三隐层 BPANN,其基本数学模型仍为 SLFN。

BPANN 详细原理与实现过程参见文献[16]。

1.3 逐步回归方法

根据传统渗压逐步回归拟合方法,考虑渗压主要驱动因子水压、降雨、温度和时效分量的影响,计算模型如下:

$$H = H_h + H_p + H_t + H_{\theta_1} + H_{\theta_2} = z + \sum_{i=1}^7 a_i (h_i - h_{0i}) + \sum_{i=1}^4 c_i (p_i - p_{0i}) + \sum_{i=1}^2 \left[b_{1i} \left(\sin \frac{2\pi it}{365} - \sin \frac{2\pi i t_0}{365} \right) + b_{2i} \left(\cos \frac{2\pi it}{365} - \cos \frac{2\pi i t_0}{365} \right) \right] + d_1 (\theta - \theta_0) + d_2 (\ln \theta - \ln \theta_0) \quad (4)$$

式中: a_i 为水压分量的回归系数; h_i 为监测日、监测日前 1 d、前 2 d ~ 4 d、前 5 d ~ 15 d、前 16 d ~ 30 d、前 31 d ~ 60 d、前 61 d ~ 100 d 的上下游水位差平均值; h_{0i} 为初始监测日上述各时段对应的上下游水位差平均值。 c_i 为水压分量的回归系数; p_i 为监测日、监测日前 1 d、前 2 d ~ 4 d、前 5 d ~ 8 d 的平均降雨量; p_{0i} 为初始监测日上述各时段对应的平均降雨量。 t 为监测日温度; t_0 为初始监测日温度; θ 为监测日天数; θ_0 为初始监测日天数。

1.4 评价指标

本文采用均方根误差 h_{mse} 、决定系数 (R^2)、绝对误差 (e) 和相对误差值 (δ) 对各模型计算结果和与实际观测值之间的误差及拟合程度进行科学评价,计算公式如下:

$$h_{\text{mse}} = \sqrt{\frac{1}{m} \sum_{i=1}^m (Y_i - X_i)^2} \quad (5)$$

$$R^2 = \frac{\left[\sum_{i=1}^m (X_i - \bar{X})(Y_i - \bar{Y}) \right]^2}{\sum_{i=1}^m (X_i - \bar{X})^2 \sum_{i=1}^m (Y_i - \bar{Y})^2} \quad (6)$$

$$e = |X_i - Y_i| \quad (7)$$

$$\delta = \frac{e}{X_i} \times 100\% \quad (8)$$

式中: m 为资料样本数; X_i 为实测坝基渗透压力值; Y_i 为模型计算值; \bar{Y} 为 Y_i 平均值; \bar{X} 为 X_i 平均值。 h_{mse} 愈小则仿真偏差愈小 R^2 愈靠近 1,分别表明模型的拟合程度愈高。

2 模型实现

2.1 工程实例

某坝为混凝土重力坝,坝顶高程 253 m,最大坝高 57 m,坝顶长度 347.65 m。大坝正常蓄水位 250.00 m,设计洪水位 250.75 m,校核洪水位 252.43 m。坝基纵向扬压力监测选取基础廊道帷幕后的排水线作为监测断面,沿基础廊道 2#—15# 坝段的幕后排水线处布置 15 个测压管,编号 UP-1—UP-15,其中 UP-7、UP-8 布置于 8# 坝段,其余每个坝

段 1 个。选择位于 5 # 坝段的测压管 UP4(2014 年 5 月 7 日—2017 年 6 月 30 日)进行分析计算。在上述自动化监测时间序列里共有监测数据 1 146 组,将前 1 000 组数据作为训练及拟合样本,后 146 组数据作为预测样本。

为进行对比分析,同时使用 ELM、BPANN 及逐步回归法对样本数据进行拟合预测。神经网络模型输入变量与逐步回归模型因子一致 $X = [H_{h1}(t) \sim H_{h7}(t), H_{p1}(t) \sim H_{p4}(t), H_{i1}(t) \sim H_{i4}(t), H_{\theta1}(t), H_{\theta2}(t)]$, 输出样本为对应测点渗压 $Y = [H(t)]$ 。使用 MATLAB 2014b 及 SPSS19 分别建立神经网络及逐步回归模型,采用试错法对网络参数进行调试。最终确定模型结构:ELM 模型的神经元个数为 50,输入层节点数为 17,输出层为 1,激励函数为 sig; BPANN 结构为 17-20-30-15-1,激励函数为 tan-sig,学习率为 0.01;逐步回归使用 F 检验显著性概率,进入因子概率值为 0.15,剔除概率值为 0.15。

2.2 ELM、BPANN 及逐步回归模型拟合精度对比分析

输入确定的拟合样本及各模型结构参数,使用 ELM、BPANN 及逐步回归模型对 UP4 测点的拟合结果参数见表 1,拟合曲线见图 1。如表 1 所示,测点

的拟合结果显示 ELM 模型的 h_{mse} 最小,相比于 BP 模型至少可减少 33.3%,相比于逐步回归模型则减幅至少有 37.8%。3 个模型中 ELM 的 R^2 达到 0.94,表明 ELM 对测点渗压的拟合程度最高,其拟合曲线动势与实测动态基本贴合(见图 1),BPANN 模型次之, R^2 均大于 0.9,逐步回归模型拟合程度最差。比较各模型的误差值可知,ELM 模型的误差区间(e_{max} 与 e_{min} 的差值)均最低,为 0.76,与 BPANN 相比至少可减少 19.1%,与逐步回归相比至少可减少 24.0%,说明 ELM 稳定性最佳。同样,各模型中 ELM 的 δ_{max} 最小,逐步回归模型的 δ_{max} 小于 BP。显然,ELM 的整体拟合效果最佳,对渗压的非线性特征拟合情况最好,拟合曲线与实测曲线基本贴合。

逐步回归模型对测点的拟合最差,预测曲线不能紧随实测动态变化。由图 1 可以看出测点在 2014 年 8 月大坝泄水过程和 2015 年 5 月的大坝蓄水过程中,逐步回归模型的历时曲线平缓,未发生相应的变化,造成这种现象是因为逐步回归固有的数理统计法特点所致:在应变量和自变量关系显著,因子表达式明确条件下的表现较好,而应变量和自变量关系不明确的情况下则计算结果较差。




图 1 模型拟合值与实测值历时曲线图

表 1 模型拟合结果参数

部位(仪器)	计算模型	e_{max}/m	e_{min}/m	$\delta_{max}/\%$	$\delta_{min}/\%$	h_{mse}/m	R^2
UP4	ELM	0.76	≈ 0	0.38	≈ 0	0.28	0.94
	BP	0.94	≈ 0	0.46	≈ 0	0.42	0.91
	逐步回归	1.00	≈ 0	0.49	≈ 0	0.45	0.89

2.3 ELM、BPANN 及逐步回归模型预测精度对比分析

在上述拟合的基础上,使用训练好的神经网络

和回归模型对测点近 5 个月的渗压进行预测,其结果参数见表 2,预测曲线见图 2。

表 2 模型预测结果参数

部位(仪器)	计算模型	e_{max}/m	e_{min}/m	$\delta_{max}/\%$	$\delta_{min}/\%$	h_{mse}/m	R^2
UP4	ELM	0.47	≈ 0	0.23	≈ 0	0.27	0.92
	BP	0.70	≈ 0	0.34	≈ 0	0.29	0.87
	逐步回归	0.74	≈ 0	0.36	≈ 0	0.41	0.90




图 2 模型预测值与实测值历时曲线图

如表 2 所示,预测结果参数与拟合参数相似,测点的预测结果均显示 ELM 模型的 h_{mse} 最小,相比于 BP 模型至少可减少 6.9%,相比于逐步回归模型则减幅至少有 34.1%。3 个模型中 ELM 的 R^2 最大,表明 ELM 对测点渗压的预测与实际动态最为吻合(见图 2),逐步回归模型次之,BPANN 模型预测值与实测动态差异最大(见图 2)。比较各模型的误差值可知,两侧点 ELM 模型的误差区间均最低(0.47),与 BPANN 相比至少可减少 32.9%,与逐步回归相比至少可减少 36.5%,说明 ELM 稳定性最佳,BPANN 模型次之,逐步回归模型的误差区间稳定性最差。同样,各模型中 ELM 的 δ_{max} 最小,BPANN 模型预测的 δ_{max} 小于逐步回归模型。显然,ELM 的整体预测精度最高,误差最小;BPANN 模型预测曲线动态与实测吻合度及模型整体精度较逐步回归模型低,而模型稳定性则较逐步回归模型要高。

结合图 1 和图 2 可知,ELM 模型对测点渗压动态的拟合及预测均与实测动态基本吻合,BPANN 模型的拟合曲线与实测动态也比较贴合,但拟合过程有较大幅度的波动现象,且部分转折处过于急促,模型稳定性不好,且其对测点后两个月的预测值有明显的低估现象。分析造成此种现象的原因为:因各项环境资料使用的是外部平均值,而测点所在地由于地质情况及各方面差异,其实际环境量与外部平均值相差较大,导致输入参数存在难以避免的误差,而这种误差必将对模型计算结果带来不同程度的影响。

3 结 论

针对混凝土坝坝基渗压监测数据,建立了 ELM 模型,通过与传统 BP 神经网络方法和逐步回归模型进行对比分析,得出如下结论:

(1) ELM 模型能够准确反映大坝坝基渗透系统的不确定性非线性关系,能在输入主要环境影响因子的情况下对历史渗压数据进行准确拟合,并实现

对未来渗压的高精度预测。

(2) ELM 与 BPANN、逐步回归模型对比分析表明,ELM 模型拟合及预测表现最佳(h_{mse} 低于 0.28 m,预测 δ_{max} 低于 0.23,拟合曲线 R^2 达到 0.94,拟合水平显著,预测曲线 R^2 超过 0.9)。

(3) ELM 可有效降低输入参数误差影响,大幅提高模型稳定性和准确性,可用于监测数据较长条件下的渗压拟合和预测。

参考文献:

- [1] 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,2006:64-74.
- [2] 陈 兰,陈浙新,王少伟.古田溪四级大坝坝基扬压力综合分析[C]//中国水力发电工程学会大坝安全监测专委会年会暨学术交流会议论文集,2012:351-354.
- [3] 杜京浓,王健平,宋汉周,等.日调节水库大坝基础扬压力的改进统计模型及其应用[J].水电与抽水蓄能,2015,39(1):33-37.
- [4] 梅一韬,何 鹏.3种混凝土坝坝基扬压力监控模型比较[J].河海大学学报(自然科学版),2010,38(S2):352-355.
- [5] 喻和平,张 聪,郭 英,等.小浪底大坝心墙渗透压力预测模型研究[J].人民黄河,2015,37(1):130-132.
- [6] Das S K. Artificial neural networks in geotechnical engineering: modeling and application issues[C]//Metaheuristics in Water, Geotechnical and Transport Engineering, Netherlands: Elsevier Inc. 2013:231-270.
- [7] 董梦思.基于 BP 神经网络的混凝土坝安全监测统计模型研究[D].昆明:昆明理工大学,2015.
- [8] 朱创家,季 昀,李同春,等.基于极限学习机的面板堆石坝施工期沉降预测模型及应用[J].水电能源科学,2014,32(6):69-71.
- [9] Huang Guangbin, Zhang Hongming, Ding Xiaojian, et al. Extreme learning machine for regression and multiclass classification[J]. IEEE Transactions on Systems Man and Cybernetics Part B: Cybernetics, 2012,42(2):513-529.