

DOI:10.11705/j.issn.1672-643X.2020.06.29

# 基于BP神经网络-加权马尔科夫模型的 泄水闸水平位移预测

丁倩<sup>1</sup>, 黄耀英<sup>1</sup>, 谢同<sup>1</sup>, 李峰<sup>1</sup>, 高磊<sup>2</sup>

(1. 三峡大学水利与环境学院, 湖北宜昌 443002; 2. 湖北汉江王甫洲水力发电有限责任公司, 湖北襄阳 430048;)

**摘要:** 针对传统变形统计模型和BP神经网络模型对水工建筑物变形预测精度欠佳的问题,建立了BP神经网络-加权马尔科夫模型。首先,采用均值-均方差法对BP神经网络模型拟合的相对误差序列进行状态分类,并检验状态序列的马氏性。然后计算各阶自相关系数和转移权重,利用加权和最大概率值预测未来的随机状态。最后以王甫洲水利枢纽泄水闸11#闸墩测点水平位移实测数据为例,分析比较逐步回归统计模型、BP神经网络模型和BP神经网络-加权马尔科夫模型的预测效果。结果表明:相比于逐步回归统计模型和BP神经网络模型,BP神经网络-加权马尔科夫模型的预测精度更高,说明BP神经网络-加权马尔科夫模型较为可靠。

**关键词:** 水平位移预测; 预测精度; BP神经网络; 加权马尔科夫模型; 马氏检验

中图分类号:TV61 文献标识码:A 文章编号:1672-643X(2020)06-0187-07

## Prediction of horizontal displacement of sluice gate based on BP neural network - weighted Markov model

DING Qian<sup>1</sup>, HUANG Yaoying<sup>1</sup>, XIE Tong<sup>1</sup>, LI Feng<sup>1</sup>, GAO Lei<sup>2</sup>

(1. College of Hydraulic & Environmental Engineering, China Three Gorges University, Yichang 443002, China;

2. Hubei Hanjiang Wangfuzhou Hydropower Co., Ltd., Xiangyang 430048, China )

**Abstract:** Aiming at the problem of poor prediction accuracy of traditional deformation statistical model and BP neural network model, this paper discussed the horizontal displacement prediction of BP neural network - weighted Markov model. First, the mean - mean square error method was used to classify the relative error sequence fitted by the BP neural network and to check the Markovity of the state sequence. Then, the autocorrelation coefficients and weights of each order were calculated, and the weighted and maximum probability values were used to predict the future random state. Finally, taking the measured horizontal displacement of the Gate Pier 11 of Wangfuzhou Water Control Project as an example, the prediction results of the stepwise regression statistical model, BP neural network model and BP neural network - weighted Markov model were compared. The results show that compared to the stepwise regression statistical model and BP neural network model, the BP neural network - weighted Markov model has higher prediction accuracy, which indicates that this model is more reliable.

**Key words:** horizontal displacement prediction; prediction accuracy; BP neural network; weighted Markov model; Markovity test

## 1 研究背景

大坝原型观测资料的正分析主要是建立统计模型、确定性或混合模型以及预测模型<sup>[1]</sup>。其中,变

形统计模型凭借其简单有效的优势,在工程实践中得到广泛应用。如顾冲时等<sup>[2]</sup>建立了碾压混凝土坝变形安全监控模型;李海枫等<sup>[3]</sup>通过变形回归模型分析特高拱坝施工期和蓄水初期变形的主要影响

收稿日期:2020-02-19; 修回日期:2020-06-05

基金项目:国家重点研发计划项目(2018YFC0407103),国家自然科学基金项目(51779130)

作者简介:丁倩(1997-),女,河南信阳人,硕士研究生,主要研究水工结构安全监控。

通讯作者:黄耀英(1977-),男,湖南郴州人,博士(后),教授,硕士生导师,主要从事水工结构安全监控的研究及教学工作。

因素;万智勇等<sup>[4]</sup>利用碾压混凝土坝坝体及坝基多点变形统计模型分离出用于材料参数反演的水压分量;赵程等<sup>[5]</sup>以白鹤滩水电站坝基监测数据为例,建立了考虑体形影响的特高拱坝施工期坝基变形统计模型;朱赵辉等<sup>[6]</sup>运用稳健估计的思想,得到具有抗差性的大坝变形统计模型。但目前常用变形统计模型预报量与预报因子之间一般都是线性关系,由于实际工程问题十分复杂,预报量与预报因子之间的关系往往是非线性的,这导致常用统计模型的预测精度具有较大局限性。

随着计算技术快速发展,人工神经网络得到了广泛应用。近年来,不少研究者引入更适合处理非线性数据的人工神经网络来建立预测模型,其中,BP神经网络因其简便性,在实际工程中采用较多。如赵斌等<sup>[7]</sup>将BP神经网络模型引入到大坝安全监测数据的预报方面;苏怀智等<sup>[8]</sup>用遗传算法改进的BP神经网络建立大坝安全监控预报模型;赵新瑞等<sup>[9]</sup>构建进化神经网络模型以预测堆石坝沉降变形和面板挠度;齐银峰等<sup>[10]</sup>利用改进粒子群算法优化大坝变形预测的BP神经网络模型;王雪红等<sup>[11]</sup>以重力坝坝顶顺河向位移实测数据为例,建立了预测精度较高的BP神经网络模型;潘洁晨<sup>[12]</sup>采用附加动量法和自适应学习效率改进BP神经网络模型,以分析哈尔滨西泉眼水库大坝变形规律。BP神经网络虽然在处理非线性数据时具有很大优势,却有易陷入局部最优及隐含层选取等诸多限制,预测结果有时并不理想。近年来有些学者提出利用马尔科夫链修正大坝变形模型预测结果,如张英豪<sup>[13]</sup>等利用马尔科夫修正灰色模型预测结果,使预测相对误差缩小到11%以内;何启等<sup>[14]</sup>针对样本数据波动性大的问题,用加权马尔科夫修正灰色神经网络大坝变形监控模型;周子东等<sup>[15]</sup>提出偏最小二乘-马尔科夫链大坝位移预测模型,解决了传统回归模型数据波动的问题;董丹丹等<sup>[16]</sup>根据马尔科夫链原理,修正GACO-BP模型拟合值的相对误差,进而提出GACO-BP-MC模型。但上述文献或是默认马氏链具有时齐性,或是漏掉了对随机序列的马氏检验,或是未考虑不同滞时相依关系强弱不同。另外,虽然马尔科夫链用于水文序列预测的研究相对丰富,但是报道水工建筑物安全监测数据分析的文献不多,而将BP神经网络与马尔科夫链相结合的研究相对更少。

基于以上研究的不足,本文结合王甫洲水利枢纽泄水闸水平位移的实测数据,将BP神经网络与

加权马尔科夫链相结合,建立BP神经网络-加权马尔科夫模型。最后与逐步回归统计模型和BP神经网络模型的预测效果相比较,以分析加权马尔科夫链能否提高模型精度。

## 2 水工建筑物变形预测模型原理

### 2.1 基于BP神经网络模型的水工建筑物变形预测

统计模型是水工建筑物变形预测的实用工具,但它假设干扰项数学期望为零,近似假设其服从正态分布<sup>[17]</sup>,而实际问题不一定满足该条件,其模型精度取决于预报因子的选择,且在变形相关因子中,时效的影响因素众多,不宜拟定明确的表达式<sup>[7]</sup>。另外,水工建筑物结构行为往往呈现非线性特征<sup>[18]</sup>,而BP神经网络可自学习、自适应<sup>[19]</sup>,在处理非线性数据方面具有很大优势。由于单隐含层网络能满足水工建筑物变形预测要求,本文拟采用经典的3层网络结构。其中,输入层节点是与水工建筑物变形相关的因子,输出层节点是水工建筑物变形效应量。影响水工建筑物变形的因素比较复杂,本文主要分析水压分量、温度分量和时效分量,采用的变形表达式<sup>[1]</sup>如下:

$$\delta = a_0 + \sum_{i=1}^4 a_i H_i + \sum_{i=1}^2 (b_{1i} \sin \frac{2\pi it}{365} + b_{2i} \cos \frac{2\pi it}{365}) + c_1 \theta + c_2 \ln \theta \quad (1)$$

式中: $\delta$ 为变形量,mm; $H_1$ 、 $H_2$ 和 $H_3$ 分别为上游水深的一次方、二次方和三次方, $H_4$ 为下游水深,m; $t$ 为观测日至始测日的天数; $\theta$ 等于观测日至始测日的天数除以100; $a_0$ 、 $b_{1i}$ 、 $b_{2i}$ 、 $c_1$ 和 $c_2$ 为常数项和回归系数,可由逐步回归分析法得到。

根据公式(1),网络的输入节点数为10,输出节点数为1。

选取隐含层节点数时,通常先用经验公式计算初始节点数,再依次递增或递减,试算出较优隐含层节点数。设输入层节点数为 $m$ ,输出层节点数为 $n$ ,则隐含层节点数 $N$ 可按式<sup>[20]</sup>计算:

$$N = \sqrt{0.43mn + 0.12n^2 + 2.54m + 0.77n + 0.35} + 0.51 \quad (2)$$

### 2.2 基于加权马尔科夫模型的水工建筑物变形预测

水工建筑物变形实测数据具有波动性,在水库蓄水初期尤为明显,而马尔科夫链适合处理随机波动性大的数据<sup>[21]</sup>,在水工建筑物变形预测方面已有应用。常见的马尔科夫模型有3种,基于绝对分布的马尔科夫模型、叠加马尔科夫模型和加权马尔科

夫模型<sup>[22]</sup>。加权马尔科夫预测模型不受马氏链时齐性的限制,且考虑了不同滞时相依关系的强弱,充分挖掘了样本数据包含的信息,精度一般比基于绝对分布的马尔科夫预测模型和叠加马尔科夫模型要高<sup>[23]</sup>,其模型建立的步骤如下:

(1)状态分类。拟采用均值-均方差法将随机序列指标值划分成 5 个状态区间<sup>[14]</sup>。

(2)马氏性检验。对于离散型的水工建筑物变形序列,可构造卡方统计量来检验马氏性<sup>[14]</sup>。

(3)状态转移概率矩阵。先计算不同滞时(步长为  $k$ ) 的一步状态转移频数矩阵  $f_{ij}^{(k)}$ , 然后分别计算一步状态转移概率矩阵  $p_{ij}^{(k)}$ 。

(4)各阶自相关系数和转移权重。选取滞时,分别计算各阶自相关系数  $r_k$  和转移权重  $w_k$ <sup>[14]</sup>。

(5)预测表编制。分别以预测年之前若干年的水平位移作为初始状态,再结合相应滞时的转移概率矩阵,得到预测年的各阶状态概率。然后对同一状态的各年预测状态概率加权求和,即为预测年处于各状态的平均概率。上述计算可编制成预测表,取预测表中最大概率值对应状态,用加权马尔科夫模型进行预测。

### 2.3 基于 BP 神经网络-加权马尔科夫模型的水工建筑物变形预测

BP 神经网络能很好处理非线性问题,马尔科夫链则适于预测波动性较大的随机序列,BP 神经网络-加权马尔科夫模型综合二者的优势,可用于水工建筑物变形数据处理。首先利用 BP 神经网络模型的训练结果,将实测值与拟合值进行比较,得到误差序列之后,再按 2.2 节的步骤建立加权马尔科夫模型,最终得到的模型即为 BP 神经网络-加权马尔科夫模型。图 1 为 BP 神经网络-加权马尔科夫模型的计算流程。

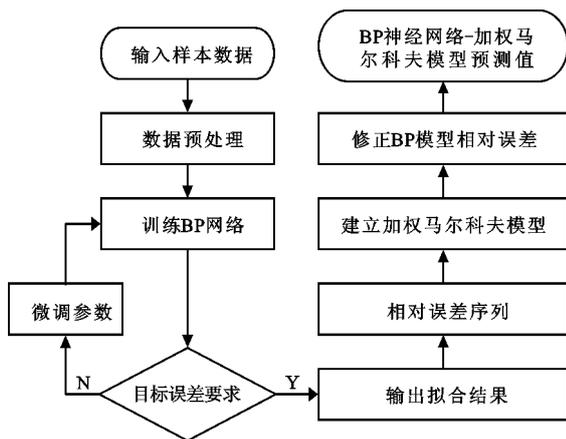


图 1 BP 神经网络-加权马尔科夫模型计算流程

## 3 实例应用

### 3.1 工程概况

王甫洲水利枢纽泄水闸共 23 孔,每孔净宽 14.50 m,闸底板高程 76.23 m。泄水闸外部上、下游向水平位移采用 1 条引张线和 2 台伸缩仪监测。此外,还在泄水闸右岸 1# 闸墩、左岸 24# 闸墩顶部上游侧分别布置 IP4、IP5 两个倒垂孔观测闸体内部水平位移。泄水闸只在汛期泄洪时打开,其他时间起挡水作用,在上下游水位差、温度和扬压力等因素作用下,闸墩顺河向会产生水平位移,方向以向下游为正,向上游为负。本文采用位于泄水闸中部的 11# 闸墩测点水平位移的实测数据,分别使用 BP 神经网络模型和 BP 神经网络-加权马尔科夫模型进行预测,并结合逐步回归统计模型的预测结果,对比 3 种模型的相对误差,验证本文建立的 BP 神经网络-加权马尔科夫模型的可靠性。图 2 为王甫洲水利枢纽泄水闸模型的纵剖面图。

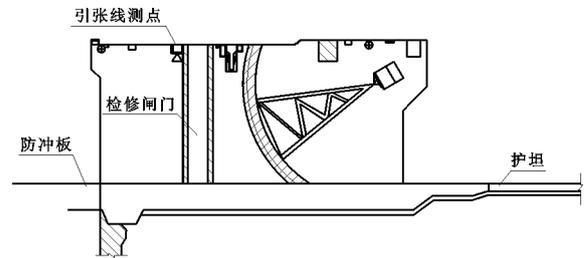


图 2 王甫洲水利枢纽泄水闸模型纵剖面图

### 3.2 BP 神经网络模型训练与预测

训练样本采用王甫洲泄水闸 11# 闸墩测点 2008 年 9 月至 2018 年 8 月的实测水平位移值,输入项为公式 (1) 中的 10 个因子,训练的目标误差设为 0.001,输出项为泄水闸 11# 闸墩测点的水平位移。预测样本采用王甫洲泄水闸 11# 闸墩测点 2018 年 9 月至 2019 年 2 月的实测水平位移值。图 3 为 BP 神经网络结构图。

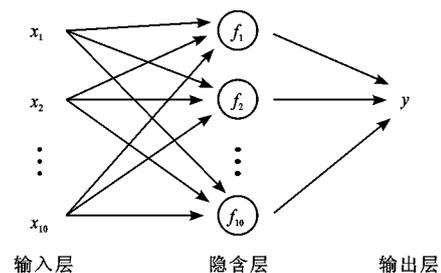


图 3 BP 神经网络结构图

图 4 为隐含层节点数与训练样本平均相对误

差<sup>[24]</sup>的关系曲线,图5为泄水闸11#闸墩测点水平位移实测值与BP神经网络模型拟合值过程线,表1为BP神经网络模型的预测结果与实测值对比。

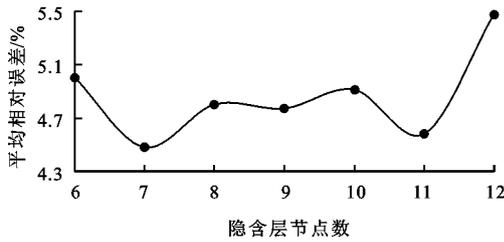


图4 隐含层节点数与训练样本平均相对误差关系曲线

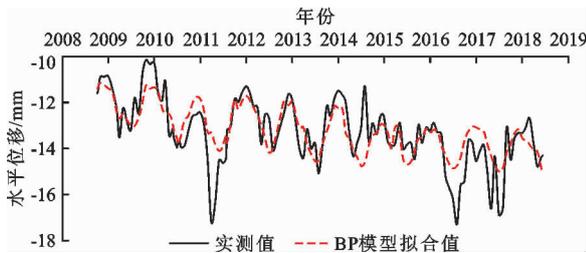


图5 闸墩测点水平位移实测值与BP神经网络模型拟合值过程线(2008年9月至2018年8月)

表1 闸墩测点水平位移BP神经网络模型预测结果与实测值对比

时间/(年-月)	实测值/mm	预测值/mm	相对误差/%
2018-09	-14.43	-14.36	-0.51
2018-10	-13.20	-14.19	7.46
2018-11	-14.39	-14.26	-0.90
2018-12	-14.66	-14.18	-3.26
2019-01	-15.45	-14.34	-7.20
2019-02	-13.84	-13.73	-0.79

由公式(2)可得,隐含层初始节点数为6,按逐次递增法试算,由图4可以看出,当隐含层节点数为7时,训练样本的平均相对误差最小,最小值为4.48%,因而隐含层节点数设置为7。由图5可以看出,除了数据跳动比较大的几个曲线尖点之外,

BP神经网络模型拟合值与实测值的变化趋势一致,平均相对误差绝对值为5.72%,模型的拟合效果较好。由表1可以看出,BP神经网络模型预测王甫洲泄水闸11#闸墩测点水平位移的相对误差绝对值在0.51%~7.46%范围内,平均相对误差绝对值为3.36%,预测效果较好。

### 3.3 BP神经网络-加权马尔科夫模型建立与预测

为进一步提高BP神经网络模型的预测精度,现结合加权马尔科夫模型进行误差修正。利用3.2节BP神经网络模型2008年9月至2018年8月的拟合值,可得相对误差序列,其余计算步骤与结果分述如下。

(1)状态分类。相对误差序列的均值为75%,均方差为7.64%,划分为5个状态,对应区间分别为 $[-22.44\%, -9.16\%]$ 、 $(-9.16\%, -4.58\%]$ 、 $(-4.58\%, 3.07\%]$ 、 $(3.07\%, 7.65\%]$ 和 $(7.65\%, 24.20\%]$ 。

(2)马氏性检验。计算一步转移频数矩阵 $f_{ij}$ 、一步转移概率矩阵 $p^{(1)}$ 以及边际概率(见表2)和卡方统计量(见表3)。

$$f_{ij} = \begin{pmatrix} 8 & 6 & 1 & 1 & 0 \\ 3 & 3 & 10 & 2 & 1 \\ 4 & 7 & 29 & 8 & 4 \\ 0 & 3 & 10 & 3 & 4 \\ 1 & 0 & 3 & 6 & 6 \end{pmatrix}$$

$$p^{(1)} = p_{ij} = \begin{pmatrix} 0.500 & 0.3750 & 0.0625 & 0.0625 & 0.0000 \\ 0.1579 & 0.1579 & 0.5263 & 0.1053 & 0.0526 \\ 0.0769 & 0.1346 & 0.5577 & 0.1538 & 0.0769 \\ 0.0000 & 0.1500 & 0.5000 & 0.1500 & 0.2000 \\ 0.0625 & 0.0000 & 0.1875 & 0.3750 & 0.3750 \end{pmatrix}$$

表2 边际概率表

状态	1	2	3	4	5
$p_{.j}$	0.1301	0.1545	0.4309	0.1626	0.1220

表3 卡方统计量计算表

状态	$f_{i1} \left  \ln \frac{p_{i1}}{p_{.1}} \right $	$f_{i2} \left  \ln \frac{p_{i2}}{p_{.2}} \right $	$f_{i3} \left  \ln \frac{p_{i3}}{p_{.3}} \right $	$f_{i4} \left  \ln \frac{p_{i4}}{p_{.4}} \right $	$f_{i5} \left  \ln \frac{p_{i5}}{p_{.5}} \right $	合计
1	10.7704	5.3204	1.9307	0.9561	0.0000	18.9777
2	0.5810	0.0653	2.0000	0.8690	0.8413	4.3565
3	2.1032	0.9652	7.4804	0.4451	1.8461	12.8400
4	0.0000	0.0887	1.4873	0.2420	1.9772	3.7952
5	0.7331	0.0000	2.4963	5.0138	6.7374	14.9807
合计	14.1877	6.4396	15.3947	7.5260	11.4020	54.9500

由表 3 的计算结果可知,统计量  $\chi^2 = 2 \sum_{i=1}^m \sum_{j=1}^m f_{ij} \left| \ln \frac{p_{ij}}{p_{.j}} \right|$  的值为 109.9, 给定显著性水平  $\alpha = 0.01$ , 则  $\chi_{\alpha}^2 [(m-1)^2] = \chi_{0.01}^2 (16) = 32.0$ , 因为  $\chi^2 > \chi_{0.01}^2 (16)$ , 所以该随机序列的马氏性极显著, 可以用加权马尔科夫模型来预测。

(3) 状态转移概率矩阵。取 BP 神经网络模型 2008 年 9 月至 2018 年 8 月拟合值的相对误差作为随机序列, 得到步长分别为 2、3、4、5 的一步状态转移概率矩阵如下:

$$p^{(2)} = \begin{pmatrix} 0.4375 & 0.1250 & 0.3125 & 0.1250 & 0.0000 \\ 0.1053 & 0.3158 & 0.2105 & 0.2105 & 0.1579 \\ 0.0980 & 0.1765 & 0.4902 & 0.1373 & 0.0980 \\ 0.1000 & 0.0500 & 0.6000 & 0.1500 & 0.1000 \\ 0.0000 & 0.0625 & 0.4375 & 0.2500 & 0.2500 \end{pmatrix}$$

$$p^{(3)} = \begin{pmatrix} 0.3125 & 0.2500 & 0.3125 & 0.1250 & 0.0000 \\ 0.2105 & 0.1053 & 0.3684 & 0.1579 & 0.1579 \\ 0.1000 & 0.2000 & 0.4800 & 0.1000 & 0.1200 \\ 0.0500 & 0.1000 & 0.4500 & 0.2500 & 0.1500 \\ 0.0625 & 0.0625 & 0.5000 & 0.2500 & 0.1250 \end{pmatrix}$$

$$p^{(4)} = \begin{pmatrix} 0.2500 & 0.1875 & 0.3125 & 0.1875 & 0.0625 \\ 0.1053 & 0.1579 & 0.4737 & 0.0526 & 0.2105 \\ 0.1400 & 0.2200 & 0.3800 & 0.1800 & 0.0800 \\ 0.1579 & 0.0000 & 0.6316 & 0.1053 & 0.1053 \\ 0.0000 & 0.1250 & 0.5000 & 0.1875 & 0.1875 \end{pmatrix}$$

$$p^{(5)} = \begin{pmatrix} 0.1250 & 0.1875 & 0.4375 & 0.1875 & 0.0625 \\ 0.2105 & 0.1053 & 0.3684 & 0.1579 & 0.1579 \\ 0.1600 & 0.1800 & 0.4400 & 0.1200 & 0.1000 \\ 0.0526 & 0.2105 & 0.5263 & 0.1053 & 0.1053 \\ 0.0667 & 0.0667 & 0.4000 & 0.2667 & 0.2000 \end{pmatrix}$$

(4) 各阶自相关系数和转移权重。表 4 为计算所得各阶自相关系数( $r_k$ )和转移权重( $w_k$ )。

表 4 各阶自相关系数和转移权重表

项目	阶次				
	1	2	3	4	5
$r_k$	0.5647	0.3444	0.2309	0.1105	0.1417
$w_k$	0.4056	0.2474	0.1658	0.0794	0.1018

(5) 预测表编制。根据 BP 神经网络模型拟合的泄水闸 11# 闸墩测点水平位移 2018 年 4-8 月相对误差所处状态, 对相应的状态转移概率进行加权计算, 预测 2018 年 9 月的相对误差状态。表 5 为 2018 年 9 月相对误差状态加权预测结果。取预测表最大概率值对应状态  $S$ , 对应状态区间取中值  $E$ , 则修正后的预测值可按下式计算:

$$x_{BM} = x_{BP} / (1 + E) \tag{3}$$

式中:  $x_{BM}$  为 BP 神经网络-加权马尔科夫模型的预测值, mm;  $x_{BP}$  为 BP 神经网络模型的预测值, mm。

表 5 2018 年 9 月闸墩测点水平位移相对误差状态加权预测表

初始时间/ (年-月)	状态	滞时	权重	状态				
				1	2	3	4	5
2018-08	3	1	0.4056	0.0769	0.1346	0.5577	0.1538	0.0769
2018-07	3	2	0.2474	0.0980	0.1765	0.4902	0.1373	0.0980
2018-06	3	3	0.1658	0.1000	0.2000	0.4800	0.1000	0.1200
2018-05	4	4	0.0794	0.1579	0.0000	0.6316	0.1053	0.1053
2018-04	5	5	0.1018	0.0667	0.0667	0.4000	0.2667	0.2000
$P_i$ (加权和)				0.0913	0.1382	0.5179	0.1484	0.1041

同理, 分别将 2018 年 9、10、11 和 12 月及 2019 年 1 月的拟合误差加入到随机序列中, 按上述步骤分别计算 2018 年 10、11 和 12 月及 2019 年 1 和 2 月的预测表, 取预测表中 6 个加权和最大概率值, 分别为 0.517 9, 0.518 3, 0.478 1, 0.531 2, 0.463 9, 0.515 3, 均对应状态 3, 误差区间为  $(-4.58\%, 3.07\%)$ , 取区间中值  $-0.75\%$ , 得预测相对误差为

$-0.75\%$ , BP 神经网络-加权马尔科夫预测模型修正后的水平位移预测值分别为  $-14.46$ 、 $-14.29$ 、 $-14.37$ 、 $-14.29$ 、 $-14.45$ 、 $-13.83$  mm。

### 3.4 模型精度对比

根据 3.2 节和 3.3 节关于王甫洲泄水闸 11# 闸墩测点水平位移的计算成果, 并结合逐步回归统计模型的预测结果, 以 2018 年 9 月至 2019 年 2 月的

实测值作为预测对比依据,3种模型的预测结果及相对误差见图6、7和表6。其中,图6为闸墩测点水平位移预测值与实测值过程线对比,图7为闸墩

测点水平位移预测值的相对误差绝对值,表6为闸墩测点水平位移预测值相对误差对照,BM模型表示BP神经网络-加权马尔科夫模型。

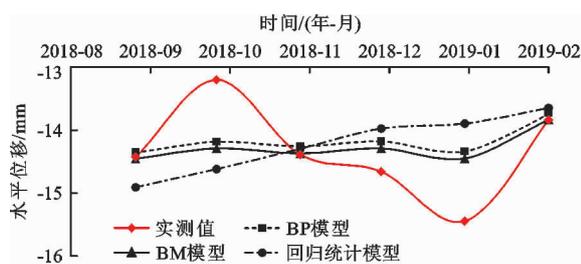


图6 3种模型预测的闸墩测点水平位移与实测值过程线对比(2018年9月至2019年2月)

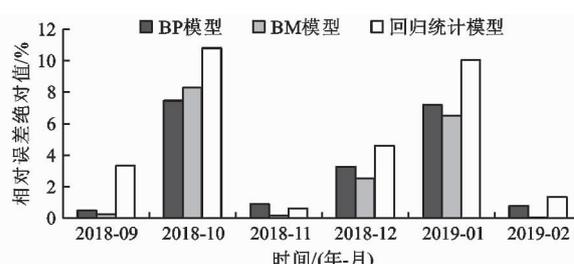


图7 3种模型预测的闸墩测点水平位移相对误差绝对值(2018年9月至2019年2月)

表6 3种模型预测的闸墩测点水平位移相对误差对照(2018年9月至2019年2月)

年月	实测值/mm	BP预测值/mm	BP误差/%	BM预测值/mm	BM误差/%	回归预测值/mm	回归误差/%
2018-09	-14.43	-14.36	-0.51	-14.46	0.24	-14.91	3.33
2018-10	-13.20	-14.19	7.46	-14.29	8.28	-14.62	10.79
2018-11	-14.39	-14.26	-0.90	-14.37	-0.16	-14.30	-0.63
2018-12	-14.66	-14.18	-3.26	-14.29	-2.53	-13.98	-4.61
2019-01	-15.45	-14.34	-7.20	-14.45	-6.50	-13.90	-10.05
2019-02	-13.84	-13.73	-0.79	-13.83	-0.04	-13.65	-1.35

由图6可知,泄水闸11#闸墩测点水平位移实测值随时间的变化是非线性的,且BP神经网络模型和BP神经网络-加权马尔科夫模型预测的水平位移与实测数据的变化趋势一致,但逐步回归统计模型预测的水平位移呈现与实测值不同的线性变化。再结合逐步回归统计模型的分析可知,11#闸墩测点水平位移主要受温度分量影响,随温度有周期性变化趋势,而逐步回归统计模型预测值不能反映监测物理量非线性的变化特征,在处理非线性数据方面,其预测效果不如BP神经网络模型和BP神经网络-加权马尔科夫模型。由图7和表6可知,在6个预测月份中,就模型预测相对误差而言,BP神经网络-加权马尔科夫模型整体上最小,而逐步回归统计模型整体上最大。逐步回归统计模型、BP神经网络模型和BP神经网络-加权马尔科夫模型的相对误差绝对值的平均值分别为5.13%、3.36%和2.96%,可见BP神经网络模型精度优于逐步回归统计模型,BP神经网络-加权马尔科夫模型精度优于BP神经网络模型。

## 4 结论

本文利用BP神经网络模型训练样本的拟合结

果得到相对误差随机序列,采用均值-均方差法进行状态分类,并检验随机序列的马氏性,建立BP神经网络-加权马尔科夫模型,结合王甫洲泄水闸水平位移实测数据,对比了逐步回归统计模型、BP神经网络模型和BP神经网络-加权马尔科夫模型预测的相对误差,主要结论如下:

(1)BP神经网络模型适于处理水工建筑物变形监测数据,能正确反映水工建筑物变形的非线性变化规律;逐步回归统计模型更适合处理线性问题;加权马尔科夫模型考虑了不同滞时相依关系的强弱,充分挖掘样本数据包含的信息,可以显著降低模型预测误差,提高模型预测精度,尤其适用于波动性较大的数据系列。本文建立的BP神经网络-加权马尔科夫模型比较合理,预测精度较高,能更好地描述水工建筑物变形规律,为水工建筑物安全监测数据处理提供一种新思路。

(2)由于本文所采用的实际数据资料系列的规律性较好,逐步回归统计模型和BP神经网络模型的预测精度较高,所以加权马尔科夫模型未充分发挥其修正误差的作用。当获得更多实测数据资料系列时,应及时训练和拟合预测模型,然后再进行后续的动态预测。

## 参考文献:

- [1] 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.
- [2] 顾冲时, 李云, 宋敬衡. 碾压混凝土坝变形安全监控模型研究[J]. 计算力学学报, 2010, 27(2): 286-290.
- [3] 李海枫, 张国新, 周秋景. 特高拱坝施工及初次蓄水期变形回归模型研究[J]. 水利水电技术, 2015, 46(1): 70-75.
- [4] 万智勇, 黄耀英, 朱赵辉, 等. 高寒地区碾压混凝土坝运行期力学参数反演分析[J]. 水利水电技术, 2017, 48(12): 50-55.
- [5] 赵程, 李倩, 郑晓红. 考虑体形影响的特高拱坝施工期坝基变形统计模型研究[J]. 水力发电, 2019, 45(12): 42-46.
- [6] 朱赵辉, 刘健, 李新, 等. 基于稳健估计的大坝变形监测统计模型分析[J]. 中国水利水电科学研究院学报, 2018, 16(2): 105-112.
- [7] 赵斌, 吴中如, 张爱玲. BP模型在大坝安全监测预报中的应用[J]. 大坝观测与土工测试, 1999, 23(6): 1-4.
- [8] 苏怀智, 吴中如, 温志萍, 等. 遗传算法在大坝安全监控神经网络预报模型建立中的应用[J]. 水利学报, 2001(8): 44-48.
- [9] 赵新瑞, 吕晓曼, 黄耀英, 等. 基于进化神经网络模型的面板堆石坝沉降和面板挠度预测[J]. 水力发电, 2017, 43(3): 68-71.
- [10] 齐银峰, 谭荣建. 基于改进粒子群优化算法的BP神经网络在大坝变形分析中的应用[J]. 水利水电技术, 2017, 48(2): 118-124.
- [11] 王雪红, 刘晓青, 陶海龙, 等. 优化BP神经网络的位移预测模型[J]. 水利水运工程学报, 2014(2): 38-42.
- [12] 潘洁晨. 基于Matlab的土石坝变形分析BP神经网络模型的建立—以哈尔滨西泉眼水库大坝为例[J]. 水资源与水工程学报, 2012, 23(3): 166-169.
- [13] 张英豪, 刘晓青, 宁昕扬. 灰色-马尔科夫模型在南俄5水电站大坝变形预测中的应用研究[J]. 水利水电技术, 2018, 49(2): 139-143.
- [14] 何启, 戴波. 基于灰色神经网络-加权马尔可夫链的大坝变形监控模型及预报研究[J]. 中国农村水利水电, 2016(10): 146-150.
- [15] 周子东, 郑东健, 蒋明, 等. 偏最小二乘-马尔科夫模型在大坝位移预测中的应用[J]. 三峡大学学报(自然科学版), 2015, 37(3): 15-18.
- [16] 董丹丹, 祖安君, 孙雪莲. 基于GACO-BP-MC的大坝变形监控模型[J]. 长江科学院院报, 2019, 36(7): 48-54.
- [17] 徐晖, 李钢. 基于Matlab的BP神经网络在大坝观测数据处理中的应用[J]. 武汉大学学报(工学版), 2005, 38(3): 50-53.
- [18] SU Huaizhi, CHEN Zhixin, WEN Zhiping. Performance improvement method of support vector machine-based model monitoring dam safety [J]. Structural Control Health Monitoring, 2016, 23(2): 252-266.
- [19] 万臣, 李建峰, 赵勇, 等. 基于新维BP神经网络-马尔科夫链模型的大坝沉降预测[J]. 长江科学院院报, 2015, 32(10): 23-27+32.
- [20] 翁静君, 华锡生. 改进的BP神经网络在大坝安全监控中的应用[J]. 水电自动化与大坝监测, 2006, 30(4): 62-65.
- [21] 郑旭东, 陈天伟, 邓捷利, 等. 熵权法并联组合模型在大坝变形监测中的应用[J]. 水力发电, 2019, 45(3): 115-119.
- [22] 孙红霞. 黑龙江省西部半干旱区干旱特性及预测模型研究[D]. 哈尔滨: 东北农业大学, 2010.
- [23] 夏乐天, 朱元胜. 马尔可夫链预测方法的统计试验研究[J]. 水利学报, 2007(S1): 372-378.
- [24] 赵玲. 基于马尔可夫链的道路交通事故预测研究及应用[D]. 西安: 长安大学, 2013.