

DOI:10.11705/j.issn.1672-643X.2021.06.24

基于混沌理论的混凝土裂缝开合度改进混合预测模型

徐小枫¹, 黄耀英¹, 徐耀², 何一洋¹, 颜剑³

(1. 三峡大学 水利与环境学院, 湖北 宜昌 443002; 2. 中国水利水电科学研究院 材料研究所, 北京 100038; 3. 湖北汉江王甫洲水力发电有限责任公司, 湖北 襄阳 430048)

摘要: 针对传统混凝土裂缝开合度统计模型对温度非线性因素和残差特性考虑不足导致预测效果不佳的问题, 首先考虑温度非线性因素, 建立裂缝开合度改进统计模型, 进而借助混沌理论与相空间重构理论对改进统计模型的残差时间序列进行混沌特性分析与相空间重构, 采用遗传算法优化的BP神经网络对残差进行预测, 最后集成获得改进混合预测模型对混凝土裂缝开合度进行预测。结合某泄水闸检修门库裂缝实测开合度, 对比分析了传统统计模型、改进统计模型和改进混合预测模型的预测效果。结果表明:改进混合预测模型的预测误差更小, 能有效改善裂缝开合度的预测效果。

关键词: 混凝土裂缝开合度; 非线性因素; 混沌理论; 神经网络; 改进混合预测模型

中图分类号: TV698.1 文献标识码: A 文章编号: 1672-643X(2021)06-0178-08

An improved hybrid prediction model for concrete crack opening based on chaos theory

XU Xiaofeng¹, HUANG Yaoying¹, XU Yao², HE Yiyang¹, YAN Jian³

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

2. Department of Materials, China Institute of Water Resources and Hydropower Research, Beijing 100038, China;

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

Abstract: In view of the poor prediction performance of conventional statistical models of concrete crack opening due to the insufficient consideration of temperature nonlinear factors and residual errors, an improved statistical model for the prediction of concrete crack opening was established incorporated with the temperature nonlinear factors. Then the residual error time series of the model was analyzed using chaos theory and its phase-space was reconstructed, meanwhile the residual error was predicted using BP artificial neural network optimized by genetic algorithm. Finally, an improved hybrid prediction model was established to predict concrete crack opening. Based on the monitored crack opening data of a drainage gate reservoir, the prediction results of the conventional statistical model, the improved statistical model and the improved hybrid prediction model were compared and analyzed. The result shows that the improved hybrid prediction model has smaller prediction error and can effectively improve the prediction accuracy.

Key words: concrete crack opening; nonlinear factor; chaos theory; artificial neural network; improved hybrid prediction model

1 研究背景

裂缝是水工混凝土结构常见病害之一。对于带宏观裂缝运行的水工混凝土结构, 裂缝的工作性态直接关系到整个结构的安全状况, 是判定结构稳定

性的一个重要指标。为了掌握混凝土裂缝的工作性态, 工程上常通过安装裂缝计组对裂缝的开合度和错动量进行实时监测。由于工程现场条件复杂, 实际混凝土裂缝会受到水压、温度和时效等多种因素的综合影响。因此, 建立准确的混凝土裂缝开合度

收稿日期: 2021-05-12; 修回日期: 2021-06-23

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); 三峡大学硕士学位论文培育基金项目(2021SSPY002)

作者简介: 徐小枫(1995-), 男, 四川成都人, 硕士研究生, 主要从事水工程安全监控方面的研究。

通讯作者: 黄耀英(1977-), 男, 湖南郴州人, 博士, 教授, 主要从事水工程长效服役实验、数值计算及调控等方面的教学和科研工作。

数学监控模型,对裂缝开合度性态进行定量分析评价和预测具有重要的意义。

目前,基于传统混凝土变形统计模型^[1]所建立的数学监控模型被广泛应用于变形预测^[2]、参数反演^[3]等工作中。其模型形式通常包含了温度分量、水压分量和时效分量等。然而,由于传统统计模型一般只考虑温度的线性影响而忽略了实际效应量与环境因子之间复杂的非线性关系,导致温度分量存在欠拟合的问题^[4-5]。研究表明,温度荷载是使大体积混凝土产生裂缝的主要驱动力^[6-7],混凝土裂缝的形成和扩展对温度变化十分敏感^[1]。然而,关于考虑温度非线性影响的混凝土裂缝开合度统计模型的研究很少。此外,近年来,为进一步对统计模型的预测性能进行改进,相关学者探索了利用混沌理论对统计模型的残差序列进行分析预测的方法^[8-10],并认为残差时间序列含有混沌特性,从而通过建立混合模型来改善统计模型的预测效果。其中文献^[8]将混沌理论应用到混凝土裂缝开合度预测中,取得了良好的预测效果。

基于混沌理论的残差序列预测方法是在 Takens 嵌入定理^[11]的基础上,确定最佳延迟时间与最小嵌入维数,从而将一维时间序列重构为与原动力系统具有相同拓扑意义的多维相空间,进而利用其内部非线性映射关系,将一维时间序列的外延转为多维相空间的内插,并结合 Lyapunov 指数的性质,便可实现对混沌时间序列的识别和短期预测^[9,12]。目前,有关最佳延迟时间计算方法的研究表明,平均位移法^[13](average displacement method,简称 AD 法)在计算最佳延迟时间时,克服了自相关系数法^[14]的主观性和其对非线性系统的不适用性^[15]以及互信息法^[16]计算时的繁杂性等,且能有效避免延迟时间取值不当导致的信息冗余或延迟坐标的完全不相关。Cao 法^[17]在计算最小嵌入维数时,改善了几何不变量法^[11]的不抗噪性以及虚假邻近点法^[18]的主观性。此外,AD 法和 Cao 法均能适应较小的数据集。目前,应用 AD 法和 Cao 法对混凝土结构位移统计模型的残差序列进行相空间重构收到了良好成效,但在混凝土裂缝开合度方面的应用却鲜有文献报道,且组合应用 AD 法与 Cao 法来重构相空间的报道也较少。近年来,随着人工神经网络的发展,针对基于人工神经网络确定非线性映射关系的方法也得到了发展应用^[19-21]。研究表明^[20-21],BP(back propagation)神经网络具有较强的非线性映射能力与自适应学习能力,在混沌时间序列的预测中表现

出良好的适应性与稳定性,但单一的神经网络存在收敛速度慢,容易陷于局部极小值和过拟合等不足^[21],Ding 等^[22]的研究表明遗传算法(genetic algorithm, GA)对 BP 神经网络有明显的改善。因此,相空间重构理论结合 GA-BP 神经网络可实现混沌残差时间序列较为有效的预测^[21]。

本文为提高混凝土裂缝开合度预测精度,首先对传统统计模型的温度分量形式进行改进,然后在混沌理论基础上,对残差时间序列进行相空间重构,建立 GA-BP 神经网络对残差进行预测,最终建立改进混合预测模型对混凝土裂缝开合度进行预测。

2 模型建立

2.1 混凝土裂缝开合度改进统计模型

根据文献^[1]建立裂缝开合度统计模型(简称传统统计模型)为:

$$\begin{aligned} \delta(t) &= \delta_T(t) + \delta_H(t) + \delta_\theta(t) + \delta_\varepsilon(t) \\ &= a_0 + \sum_{i=1}^K a_i T_i + \sum_{i=1}^4 b_i H^i + c_1 \theta + c_2 \ln \theta + \delta_\varepsilon(t) \end{aligned} \quad (1)$$

式中: $\delta(t)$ 为裂缝开合度实测值,mm; $\delta_T(t)$ 、 $\delta_H(t)$ 和 $\delta_\theta(t)$ 分别为温度分量、水压分量和时效分量,mm; $\delta_\varepsilon(t)$ 为残差,mm; T_i 为第*i*个测点实测温度,℃; K 为温度测点总数; H 为水深,m; $\theta = t/100$, t 为时间,d; a_0, a_i, b_i, c_1, c_2 均为回归系数。

基于变形统计模型的相关研究^[2,8-9,21],通常情况下只考虑了温度的线性影响,而研究表明^[4],公式(1)中的温度分量表达式没有考虑温度非线性因素影响,忽略了环境量的复杂性,将会出现欠拟合现象。为此,文献^[5]考虑温度滞后效应,并建立了考虑温度非线性影响的位移统计模型,但其形式复杂,实现过程较为繁冗。因此,针对混凝土开合度随温度变化的非线性过程,综合考虑温度非线性影响与模型的简洁性,建立混凝土开合度的改进温度分量统计模型(简称改进统计模型)为:

$$\delta(t) = \delta_T(t) + \delta_H(t) + \delta_\theta(t) + \delta_\varepsilon(t) = a_0 + \sum_{p=1}^L \sum_{i=1}^K a_{ip} T_i^p + \sum_{i=1}^4 b_i H^i + c_1 \theta + c_2 \ln \theta + \delta_\varepsilon(t) \quad (2)$$

式中: L 为反映非线性温度影响的温度多项式的最高阶次,通常为正整数,通过试算确定; a_{ip} 为第*i*个测点实测温度的*p*次方对应的回归系数;其余符号含义同前。

2.2 残差时间序列预测模型

2.2.1 残差时间序列相空间重构 研究表明^[8,11],

对于一维残差时间序列 $x(t) = \{x(t_i) | i = 1, 2, \dots, N\}$, 可以将其重构为如下形式的 m 维相空间:

$$X(t_i) = [x(t_i), x(t_i + \tau), \dots, x(t_i + (m-1)\tau)]^T \quad (3)$$

$(i = 1, 2, \dots, M)$

式中: M 为相点数, $M = N - (m-1)\tau$; m 为嵌入维数, 取正整数; τ 为延迟时间。

由公式(3)可知, 相空间重构的关键在于延迟时间 τ 和嵌入维数 m 的确定, 其计算方法分述如下。

(1) 延迟时间的计算。

采用 AD 法^[13] 计算延迟时间。在 2-范数下定义平均位移 $S_2(m, \tau)$ 为:

$$S_2(m, \tau) = \frac{1}{M} \sum_{i=1}^M \sqrt{\sum_{l=1}^{m-1} [x(t_i + l\tau) - x(t_i)]^2} \quad (4)$$

当给定不同的嵌入维数 $m (m \geq 2)$ 时, $S_2(m, \tau)$ 会随 τ 的增加而趋于稳定。为此, 文献[13] 建议最佳延迟时间可以根据不同嵌入维数 m 下的 $S_2(m, \tau) - \tau$ 图形来确定, 即当 $S_2(m, \tau) - \tau$ 斜率衰减为初始斜率的 40% 时, 对应的 τ_0 为最佳延迟时间。

(2) 嵌入维数的计算。采用 Cao 法^[17] 计算嵌入维数。当给定一个最佳延迟时间后, 在 m 维相空间中定义如下几个参数。

定义参数 $a(i, m)$ 为:

$$a(i, m) = \frac{\|X_i(m+1) - X_{n(i,m)}(m+1)\|_\infty}{\|X_i(m) - X_{n(i,m)}(m)\|_\infty} \quad (5)$$

$$X_i(m) = [x(t_i), x(t_i + \tau), \dots, x(t_i + (m-1)\tau)]^T \quad (6)$$

$(i = 1, 2, \dots, N - (m-1)\tau)$

式中: $\|X_i(m) - X_{n(i,m)}(m)\|_\infty$ 为无穷范数下定义的距离; $X_{n(i,m)}(m)$ 为相点 $X_i(m)$ 的最邻近点^[18] (下标 $n(i, m)$ 表示最邻近点)。

$a(i, m)$ 的均值 $E(m)$ 定义为:

$$E(m) = \frac{1}{N - m\tau} \sum_{i=1}^M a(i, m) \quad (7)$$

当嵌入维数由 m 升到 $m+1$ 时, 定义 $E_1(m)$ 为:

$$E_1(m) = \frac{E(m+1)}{E(m)} \quad (8)$$

文献[17] 的研究表明, 如果残差时间序列存在定点吸引子, 当嵌入维数 m 大于某一个 m_0 时, $E_1(m)$ 将停止变化, 此时, $m_0 + 1$ 即为最小嵌入维数 m_e , 其可由 $E_1(m) - m$ 图形分析确定。

在实际计算中, 很难判断 $E_1(m)$ 是缓慢增长还是随着 m 的增长而停止变化。对于一组随机的残差序列, $E_1(m)$ 原则上会随着 m 的增加而不断增加; 对于确定性残差序列, $E_1(m)$ 一定能收敛。因此, 有必要引入另外一个参数 $E_2(m)$ 来区分随机残差序

列与确定性残差序列, $E_2(m)$ 定义如下:

$$E_2(m) = \frac{E^*(m+1)}{E^*(m)} \quad (9)$$

$$E^*(m) = \frac{1}{N - m\tau} \sum_{i=1}^M |x(t_i + m\tau) - x(t_{n(i,m)} + m\tau)| \quad (10)$$

对于随机残差序列, $E_2(m)$ 对于任何 m 均等于 1; 对于确定性残差序列, $E_2(m)$ 与 m 相关, 一定存在一些 m 使得 $E_2(m) \neq 1$ 。为此, 文献[17] 建议同时计算 $E_1(m)$ 和 $E_2(m)$ 来确定最小嵌入维数以及区分随机残差序列和确定性残差序列。为方便表述, 以下分别用 E_1 、 E_2 表示 $E_1(m)$ 、 $E_2(m)$ 。

2.2.2 Lyapunov 指数 最大 Lyapunov 指数 λ_1 对于混沌特性的判断具有十分重要的意义^[9,12], 对于一个时间序列, 当 λ_1 大于 0 时, 认为该系统存在混沌特性。同时, 最大 Lyapunov 指数的倒数 λ_1^{-1} 定义了最大预测步长^[12], 可以作为短期预报的可靠性指标^[23]。本文运用 Rosenstein 法^[24-25] 计算最大 Lyapunov 指数。

2.2.3 GA-BP 神经网络预测残差

(1) 基于混沌理论的非线性预测原理。文献[8] 指出, 在残差时间序列重构的相空间中, 存在唯一的映射关系有:

$$X(t + P_t) = F(X(t)) \quad (11)$$

式中: P_t 为预测时间, 映射关系 F 可由相空间中的所有相点逼近求得。本文采用 GA-BP 神经网络进行全域法近似构造该非线性映射关系^[20]。

(2) GA-BP 神经网络。魏博文等^[21] 的研究表明, BP 神经网络在求解非线性映射关系时具有一定的优势, 同时利用遗传算法建立的 GA-BP 神经网络对典型的混沌时间序列具有较好的非线性拟合能力和更高的短时预测准确性, 预测性能优于 BP 神经网络。为此, 本文将采用遗传算法对 BP 神经网络进行优化, 建立 GA-BP 神经网络进行预测, 并在关于遗传算法相关应用研究的基础上^[21-22], 参考 Xu 等^[26] 的研究, 选择如下形式的适应度函数:

$$Fitness = 1000 \times \frac{R^2}{RMSE} \quad (12)$$

公式(11) 综合考虑拟合误差与拟合优度两个重要的评价标准, 当 R^2 越大、 $RMSE$ 越小时, 则适应度越大, 当适应度不再随进化代数发生变化时, 即得到最优适应度。其中, R^2 和 $RMSE$ 的计算公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^{N_t} (\delta_i - \hat{\delta})^2}{\sum_{i=1}^{N_t} (\delta_i - \bar{\delta}_i)^2} \quad (13)$$

$$RMSE = \left[\frac{1}{N_t} \sum_{i=1}^{N_t} (\delta_i - \hat{\delta})^2 \right]^{\frac{1}{2}} \quad (14)$$

式中: N_t 为测试集样本数; δ_i 为实测值; $\hat{\delta}$ 为预测值; $\bar{\delta}$ 为实测值的平均值。

在 GA - BP 神经网络中,输入向量和输出向量分别为:

$$X(t) = [x(t), x(t - \tau), \dots, x(t - (m - 1)\tau)]^T \quad (15)$$

$$X(t + P_t) = [x(t + P_t), x(t + P_t - \tau), \dots, x(t + P_t - (m - 1)\tau)]^T \quad (16)$$

由分离出的残差时间序列进行神经网络模型优化训练,获得 GA - BP 神经网络模型的权值和阈值,进而进行残差时间序列的预测。

2.3 裂缝开合度改进混合预测模型

集成裂缝开合度改进统计模型公式(2)与GA - BP 神经网络残差预测结果公式(16),得到裂缝开合度改进混合预测模型(简称改进混合模型)为:

$$\delta(t + P_t) = \delta_T(t + P_t) + \delta_H(t + P_t) + \delta_\theta(t + P_t) + x(t + P_t) \quad (17)$$

式中: $\delta_T(t + P_t)$ 、 $\delta_H(t + P_t)$ 和 $\delta_\theta(t + P_t)$ 分别为预测时间为 P_t 的温度分量、水压分量和时效分量, mm; $x(t + P_t)$ 为 GA - BP 神经网络残差预测模型的预测值, mm。

建立裂缝开合度改进混合预测模型的流程图如图 1 所示。

3 实例分析

3.1 工程概况

王甫洲水利枢纽位于湖北省老河口市近郊的汉江干流上,是一座以发电为主,结合航运,兼有灌溉、养殖、旅游等综合利用的大(2)型水利枢纽工程。枢纽由位于主河道的泄水闸、主河床土石坝、谷城段土石坝及位于老河道的电站厂房、船闸、混凝土重力坝和两岸围堤土石坝组成。现场巡视检查发现,泄水闸左岸门库上游交通桥顶部出现 3 条裂缝对门库挡水形成威胁。为了对泄水闸检修门库的裂缝进行工作性态诊断,安装了 9 套振弦式双向裂缝计组(记作 Mkj - 1 ~ Mkj - 9)进行监测,如图 2 所示。其中, Mkj - 1、Mkj - 2 安装在门库上游侧面; Mkj - 3、Mkj - 4、Mkj - 5 安装在门库顶靠近上游面; Mkj - 6、Mkj - 7 安装在门库内靠近上游面; Mkj - 8、Mkj - 9 安装在门库顶靠近下游面。于 2020 年 6 月 12 - 19 日,对 9 套双向裂缝计进行了安装调试。选择典型裂缝计 Mkj - 3 作为分析对象。

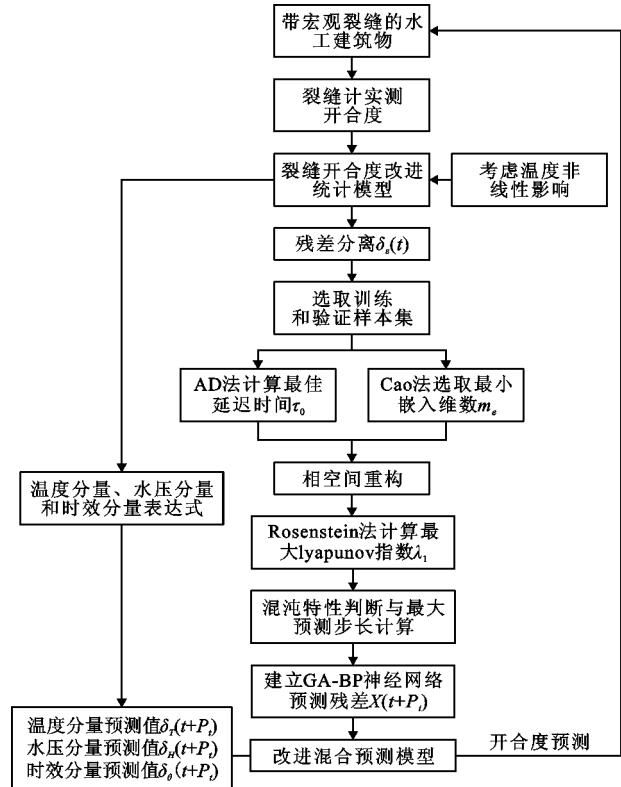


图 1 裂缝开合度改进混合预测模型建立流程图

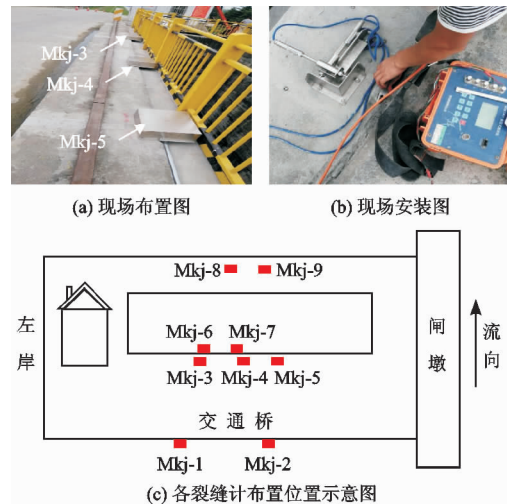


图 2 实例工程双向裂缝计布置示意图

2020 年 6 月 23 日至 2021 年 2 月 14 日典型裂缝计 Mkj - 3 实测开合度及温度过程线如图 3 所示。




图 3 裂缝计 Mkj - 3 实测裂缝开合度及温度过程线

由图3可见,泄水闸门库裂缝开合度与温度变化呈明显的负相关,温度升高时,裂缝闭合,温度降低时,裂缝张开。以下结合该裂缝计实测裂缝开合度建立裂缝开合度改进混合预测模型,然后进行分析评价。

3.2 泄水闸裂缝开合度改进统计模型的建立

3.2.1 改进统计模型参数 L 的确定 不同测点受温度非线性的影响可能存在差异,为了合理确定改进统计模型公式(2)中的参数 L ,考虑9套裂缝计温度测值,对参数 L 的取值进行试算分析,分别建立 $L = 1, 2, 3, 4, 5$ 的裂缝开合度改进统计模型,然后进行回归分析,获得不同 L 取值对应的模型回归系数,进而计算得到不同改进模型对应的 R^2 和 $RMSE$,如图4所示。




图4 改进统计模型 R^2 、 $RMSE$ 值随 L 的变化曲线

由图4可见,当 L 从1增加到3时,改进统计模型的两个评价参数得到较明显的改善;当 $L \geq 3$ 时,两个评价参数逐渐趋于稳定。说明从统计模型的角度上看,温度对混凝土开合度的非线性影响是存在的。由此建立 $L = 3$ 时考虑温度非线性的改进统计模型,如公式(18)所示,此时 $R^2 = 0.891$, $RMSE = 0.04571$ mm。通过回归分析得到的公式(18)各回归系数数值如表1所示。

$$\delta(t) = a_0 + \sum_{p=1}^3 \sum_{i=1}^9 a_{ip} T_i^p + \sum_{i=1}^4 b_i H^i + c_1 \theta + c_2 \ln \theta + \delta_e(t) \quad (18)$$

式中各符号含义同前。

3.2.2 裂缝开合度改进统计模型分析 2020年6月23日至2021年2月14日裂缝开合度改进统计模型(公式(18))与传统统计模型(公式(1))拟合结果如图5所示。

分析图5可知:(1)传统统计模型只考虑了温度的线性影响,在极值附近的点拟合效果并不理想,如图5(a)中椭圆圈所示;(2)改进统计模型考虑了温度的非线性影响,拟合效果得到了改善,如图5(b)中椭圆圈所示,拟合曲线更接近于实测值,改进统计模型

的残差也更接近于0(图5(c));(3)由于统计模型本身的局限性,改进统计模型在某些时段仍然存在拟合不佳的状况(图5(b)、5(c)),这将在一定程度上影响预测效果,因而基于统计模型的预测方法仍有改进的空间。为此,进一步利用混沌理论对残差进行分析,建立改进混合预测模型以改善预测效果。

表1 裂缝开合度改进统计模型公式(18)各回归系数值

| 回归系数 | 系数值 | 回归系数 | 系数值 |
|----------|-------------------------|----------|-------------------------|
| a_{11} | -1.661×10^{-1} | a_{92} | 2.673×10^{-3} |
| a_{21} | 9.235×10^{-2} | a_{13} | 0 |
| a_{31} | 1.701×10^{-2} | a_{23} | 0 |
| a_{41} | 0 | a_{33} | 0 |
| a_{51} | 0 | a_{43} | -8.494×10^{-6} |
| a_{61} | 7.707×10^{-2} | a_{53} | -1.737×10^{-5} |
| a_{71} | 2.446×10^{-2} | a_{63} | 1.863×10^{-5} |
| a_{81} | 9.186×10^{-2} | a_{73} | 0 |
| a_{91} | -1.097×10^{-1} | a_{83} | 4.518×10^{-5} |
| a_{12} | 2.297×10^{-3} | a_{93} | -2.476×10^{-5} |
| a_{22} | -1.320×10^{-3} | b_1 | -6.393×10^{-2} |
| a_{32} | 0 | b_2 | -2.685 |
| a_{42} | 0 | b_3 | 0 |
| a_{52} | 1.158×10^{-3} | b_4 | 2.094×10^1 |
| a_{62} | -2.587×10^{-3} | c_1 | -2.537×10^{-1} |
| a_{72} | 0 | c_2 | 7.648×10^{-2} |
| a_{82} | -3.704×10^{-3} | a_0 | 2.931×10^{-1} |

3.3 残差时间序列预测

(1)嵌入维数和延迟时间确定。本文通过计算不同嵌入维数下的最佳延迟时间以及计算最佳延迟时间对应的嵌入维数来相互印证,并最终确定最佳延迟时间与最小嵌入维数。在裂缝开合度改进统计模型的基础上,由实测值分离获得残差时间序列,从残差时间序列中选取2020年6月23日22:00至2021年2月11日7:00的1825个样本作为重构数据集。依据平均位移法绘制嵌入维数分别为2、5、8、12时的 $S_2(m, \tau)$ 与延迟时间 τ 的关系曲线,最终根据Cao法绘制 E_1 、 E_2 与嵌入维数 m 的关系曲线,如图6、7所示。

由图6、7可见:(1)当嵌入维数一定时, $S_2(m, \tau) - \tau$ 的斜率随着 τ 的增大而逐渐趋于稳定,当 $S_2(m, \tau) - \tau$ 的斜率衰减为初始斜率的40%时,认为此时的 τ 是最佳延迟时间,由此得到最佳延迟时间为2;(2)在给定的最佳延迟时间下, E_2 并不是恒为1,且 E_1 随着嵌入维数的逐渐增大而渐趋稳定,由此获得 E_1 值趋于稳定时对应的嵌入维数,即最小嵌入维数为8。根据公式(3)对残差时间序列进行相空间重构。

(2) 预报步长的确定。运用 Rosenstein 法计算得到最大 Lyapunov 指数 $\lambda_1 = 0.025 > 0$, 这表明系统存在混沌成分, 进而计算其倒数, 得到最大预报步长为 40。为此, 本文取后验步长为 24 (即 2021 年 2 月 11 日 10:00 - 2021 年 2 月 14 日 7:00 的 24 个样本), 时长为 3 d。

(3) GA - BP 神经网络预测残差。根据前文 2.2.3 节中所述原理, 采用 GA - BP 神经网络对 2020 年 6 月 23 日 22:00 - 2021 年 2 月 11 日 7:00 的 1 825 个样本建立的重构相空间矩阵进行优化训练。其中 BP 神经网络结构为 8 - 12 - 8, 遗传算法最大进化次数为 30 次, 种群数量为 40, 交叉概率为 0.80, 变异概率为 0.10, 适应度随进化代数变化曲线如图 8 所示。




图 8 适应度随进化代数变化曲线

由图 8 可见, 当适应度不再明显变化且满足神经网络精度要求时, 用此时输出的权值、阈值参数建立优化后的 BP 神经网络, 对重构后的残差时间序列进行训练预测。根据建立的 GA - BP 神经网络残差预测模型, 分离获得残差时间序列的预测值为 $x(t + 1), x(t + 2), \dots, x(t + 24)$ 。

3.4 改进混合预测模型与预测结果评价

(1) 建立改进混合预测模型。由公式 (18) 集成得到改进混合预测模型为:

$$\delta(t + P_t) = a_0 + \sum_{p=1}^3 \sum_{i=1}^9 a_{ip} T_i^p + \sum_{i=1}^4 b_i H^i + c_1 \theta + c_2 \ln \theta + x(t + P_t) \quad (19)$$

式中: $\delta(t + P_t)$ 为预测时间为 P_t 的裂缝开合度预测值, mm, 其中 $P_t = 1, 2, \dots, 24$ 。

(2) 预测效果评价。引入均方误差 MSE 、平均绝对误差 MAE 和归一化误差 $NRMSE$ 对改进混合预测模型预测效果进行评价, 这 3 个评价指标的值越接近于 0, 说明预测效果越好, 其计算式如下:

$$MSE = \frac{1}{N_t} \sum_{i=1}^{N_t} (\delta_t - \hat{\delta})^2 \quad (20)$$

$$MAE = \frac{1}{N_t} \sum_{i=1}^{N_t} |\delta_t - \hat{\delta}| \quad (21)$$

$$NRMSE = \frac{1}{\sigma} \left[\frac{1}{N_t} \sum_{i=1}^{N_t} (\delta_t - \hat{\delta})^2 \right]^{\frac{1}{2}} \quad (22)$$

式中: σ 为实测值标准差, 其余符号含义同前。

由公式 (19) 得到改进混合预测模型从 2021 年 2 月 11 日 10:00 开始, 预测步长为 24 (即 3 d) 的预测值, 并与传统统计模型及改进统计模型的预测结果进行对比, 如图 9 所示。

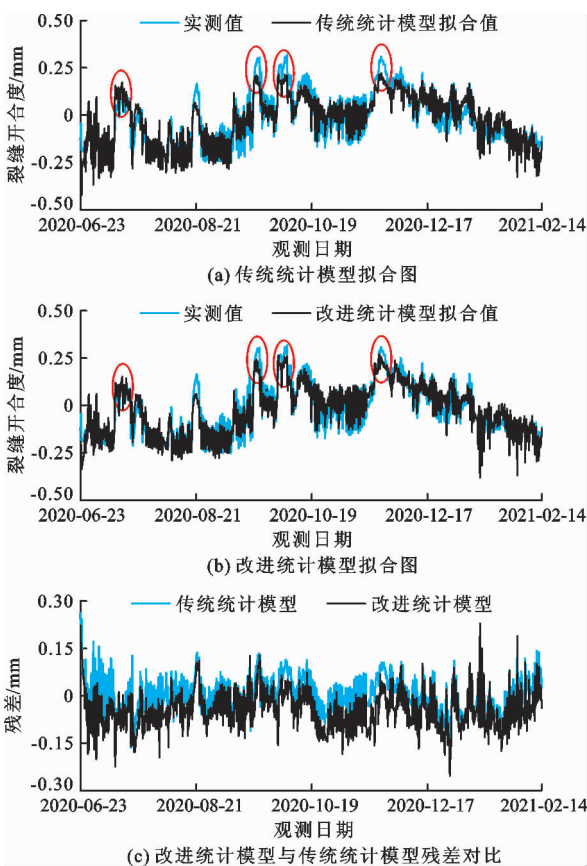


图 5 裂缝开合度改进统计模型与传统统计模型拟合结果对比




图 6 不同嵌入维数的 $S_2(m, \tau) - \tau$ 关系曲线




图 7 E_1, E_2 与嵌入维数 m 的关系曲线




图 9 不同模型对裂缝开合度的预测值与实测值过程线

不同预测模型对应的评价指标计算结果见表2。

由图9可见,相对传统统计模型的预测值来说,考虑温度非线性因素影响的改进统计模型预测值与实测值更接近,但在极值点附近,改善效果不明显;相对改进统计模型的预测值来说,改进混合模型预测值与实测值吻合效果更好,且在极值点附近的预测值与实测值的差值也明显减小。由表2可见,相对传统统计模型来说,改进统计模型的 MSE 、 MAE 和 $NRMSE$ 值分别减小了 51.1%、35.3%、30.0%,改进混合模型的 MSE 、 MAE 和 $NRMSE$ 值分别减小了 87.0%、68.5%、63.9%;相对改进统计模型来说,改进混合模型的 MSE 、 MAE 和 $NRMSE$ 值分别减小了 73.4%、51.4%、48.4%。结果表明,基于相空

间重构理论与混沌理论的改进混合模型可明显改善预测效果。

3.5 裂缝开合度动态预测分析

实际工程中预测预警是一个动态过程,随着时间推移,裂缝开合度不断演变,当获得新的监测数据后,需要重新确定预测模型的参数,进而进行动态预测。为此,为验证改进混合预测模型的可靠性,连续动态预测 10 次,每次预测的时间步长均为 24(即 3 d),进而分别对传统统计模型、改进统计模型和改进混合模型的 MSE 、 MAE 和 $NRMSE$ 进行统计分析。对于这 3 个指标采用与表 2 相同的方法,分别计算改进混合模型相对于传统统计模型和改进统计模型的提升率,并绘制箱线图进行对比分析,如图 10 所示。

表 2 不同模型对应的各评价指标计算结果及比较

| 评价指标 | 传统统计模型 M_1 | 改进统计模型 M_2 | 改进混合模型 M_3 | $\frac{M_1 - M_2}{M_1}/\%$ | $\frac{M_1 - M_3}{M_1}/\%$ | $\frac{M_2 - M_3}{M_2}/\%$ |
|-------------------|--------------|--------------|--------------|----------------------------|----------------------------|----------------------------|
| MSE/mm^2 | 0.006371 | 0.003118 | 0.000830 | 51.1 | 87.0 | 73.4 |
| MAE/mm | 0.074935 | 0.048492 | 0.023575 | 35.3 | 68.5 | 51.4 |
| $NRMSE$ | 0.001462 | 0.001023 | 0.000528 | 30.0 | 63.9 | 48.4 |

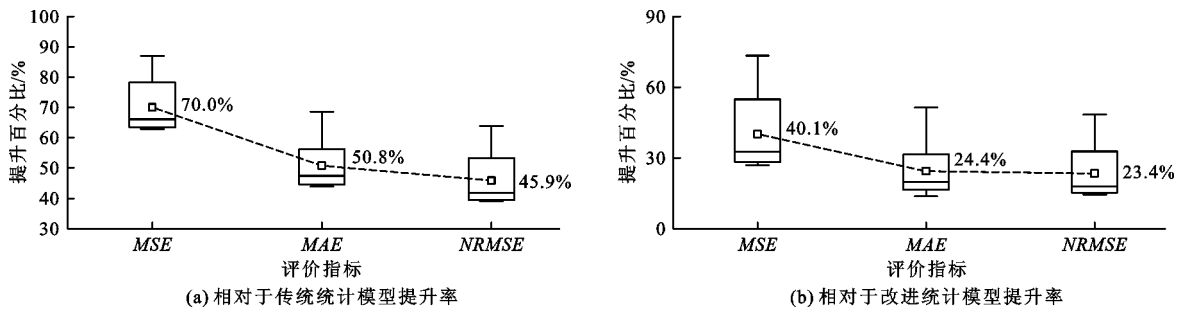


图 10 裂缝开合度改进混合预测模型动态预测效果评价

由图 10 可见,改进混合模型的 3 个评价指标相对于两类统计模型的改善效果明显。改进混合模型相对于传统统计模型的预测效果平均提升率在 45.9% ~ 70.0% 之间,其中 MSE 最大提升率达 80% 以上;改进混合模型相对于改进统计模型的预测效果平均提升率在 23.4% ~ 40.1% 之间,其中 MSE 最大提升率达 70% 以上,这表明基于改进统计模型的混合模型对单纯的统计模型的改进是合理有效的。

4 结论

本文针对数据量较小的数据集,分析了传统统计模型的适用性,并对传统统计模型进行改进,基于混沌理论与相空间重构理论对裂缝开合度的统计模型进行了客观的分析,并建立了基于改进统计模型和 GA-BP 神经网络的改进混合预测模型,对水工

建筑结构混凝土裂缝开合度进行了预测,结果表明:

(1)通过对传统统计模型建模分析得出,裂缝开合度会受到温度非线性的影响,传统统计模型无法准确提取温度分量,引入 2 阶和 3 阶温度分量后的改进统计模型能有效改善温度分量的拟合情况。

(2)改进统计模型的残差序列包含了裂缝演变的有用信息,通过计算其最大 Lyapunov 指数证明其中包含了混沌成分,通过对残差序列进行相空间重构,并结合 GA-BP 神经网络与改进统计模型建立改进混合模型进行预测,得到的模型预测精度相对较高,预测效果要优于单纯的统计模型。

(3)利用改进混合预测模型对裂缝开合度进行 10 次动态预测,并对其结果进行统计分析,结果表明运用本文建立的改进混合预测模型可以实现更为可靠的短期动态预测,对混凝土裂缝开合度的预测

预警具有一定的实用价值。

致谢:在泄水闸门库裂缝计安装调试过程中得到了南京南瑞水利水电科技有限公司张晨铖和王勇的帮助,在此表示感谢!

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] 丁倩, 黄耀英, 谢同, 等. 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[J]. 水资源与水工程学报[J]. 2020, 31(6): 187-193.
- [3] 丁宇, 袁斌, 黄耀英, 等. 基于实测钢筋应力的某大型渡槽力学参数反演分析[J]. 水资源与水工程学报, 2018, 29(5): 202-207.
- [4] 王建, 阳武, 郑东健. 监测数据回归分析中典型监测值欠拟合释因[J]. 武汉大学学报(工学版), 2003, 36(6): 9-12.
- [5] 沈晶鑫, 郑东健. 改进温度分量的拱坝变形时空分布模型[J]. 水利水电技术, 2018, 49(5): 38-43.
- [6] 黄耀英, 丁月梅, 吕晓曼, 等. 闸墩混凝土结构温控防裂措施智能优选研究[J]. 中国工程科学, 2014, 16(3): 59-63.
- [7] 刘茜, 张晓飞, 张昕, 等. 基于温度应力仿真的碾压混凝土拱坝诱导缝开裂分析研究[J]. 水资源与水工程学报, 2019, 30(1): 183-190+196.
- [8] 包腾飞, 吴中如. 混凝土裂缝开度混合预测模型[J]. 水利水电技术, 2005, 36(11): 52-55.
- [9] WEI Bowen, YUAN Dongyang, XU Zhenkai, et al. Modified hybrid forecast model considering chaotic residual errors for dam deformation[J/OL]. Structural Control and Health Monitoring, 2018: e2188. <https://doi.org/10.1002/stc.2188>.
- [10] SU Huaizhi, WEN Zhiping, CHEN Zhixin, et al. Dam safety prediction model considering chaotic characteristics in prototype monitoring data series[J]. Structural Health Monitoring, 2016, 15(6): 639-649.
- [11] TAKENS F. Detecting strange attractors in turbulence[J]. Lecture Notes in Mathematics, 1981, 898(1): 366-381.
- [12] ALFARO M, FUERTES G, VARGAS M, et al. Forecast of chaotic series in a horizon superior to the inverse of the maximum Lyapunov exponent[J]. Complexity, 2018, 2018: 1452683.
- [13] ROSENSTEIN M T, COLLINS J J, DE L C J. Reconstruction expansion as a geometry-based framework for choosing proper delay times[J]. Physica D Nonlinear Phenomena, 1994, 73(1-2): 82-98.
- [14] ABARBANEL H D I, BROWN R, SIDOROWICH J J, et al. The analysis of observed chaotic data in physical systems[J]. Reviews of Modern Physics, 1993, 65(4): 1331-1392.
- [15] 张淑清, 贾健, 高敏, 等. 混沌时间序列重构相空间参数选取研究[J]. 物理学报, 2010, 59(3): 1576-1582.
- [16] FRASER A M, SWINNEY H L. Independent coordinates for strange attractors from mutual information[J]. Physical Review A, 1986, 33(2): 1134-1140.
- [17] CAO Liangyue. Practical method for determining the minimum embedding dimension of a scalar time series[J]. Physica D Nonlinear Phenomena, 1997, 110(1-2): 43-50.
- [18] KENNEL M B, BROWN R, ABARBANEL H. Determining embedding dimension for phase-space reconstruction using a geometrical construction[J]. Physical Review A, 1992, 45(6): 3403-3411.
- [19] WEI Dengfeng. Network traffic prediction based on RBF neural network optimized by improved gravitation search algorithm[J]. Neural Computing & Applications, 2017, 28(8): 2303-2312.
- [20] WANG Bo, CHEN Bowen, WANG Gongqing, et al. Back propagation (BP) neural network prediction and chaotic characteristics analysis of free falling liquid film fluctuation on corrugated plate wall[J]. Annals of Nuclear Energy, 2020, 148: 107711.
- [21] 魏博文, 彭圣军, 徐镇凯, 等. 顾及大坝位移残差序列混沌效应的GA-BP预测模型[J]. 中国科学(技术科学), 2015, 45(5): 541-546.
- [22] DING Shifei, SU Chunyang, YU Junzhao. An optimizing BP neural network algorithm based on genetic algorithm[J]. Artificial Intelligence Review, 2011, 36(2): 153-162.
- [23] 刘传孝. 饱和嵌入维数确定最大Lyapunov指数的准则探讨[J]. 岩石力学与工程学报, 2005, 24(22): 4088-4093.
- [24] ROSENSTEIN M T, COLLINS J J, DE L C J. A practical method for calculating largest Lyapunov exponents from small data sets[J]. Physica D Nonlinear Phenomena, 1993, 65(1-2): 117-134.
- [25] ZHOU Shuang, WANG Xingyuan. Identifying the linear region based on machine learning to calculate the largest Lyapunov exponent from chaotic time series[J]. Chaos, 2018, 28(12): 123118.
- [26] XU Hongtao, CHEN Chunbo, ZHENG Hongwei, et al. AGA-SVR-based selection of feature subsets and optimization of parameter in regional soil salinization monitoring[J]. International Journal of Remote Sensing, 2020, 41(12): 4470-4495.