

控制与决策

Control and Decision

基于小波变换与差分变异BSO-BP算法的大坝变形预测

陈俊风, 王玉浩, 张学武, 薛醒思

引用本文:

陈俊风, 王玉浩, 张学武, 等. 基于小波变换与差分变异BSO-BP算法的大坝变形预测[J]. *控制与决策*, 2021, 36(7): 1611-1618.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.1431>

您可能感兴趣的其他文章

Articles you may be interested in

[基于FWADE-ELM的短时交通流预测方法](#)

Short-term traffic flow forecasting based on hybrid FWADE-ELM

控制与决策. 2021, 36(4): 925-932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

[基于FWADE-ELM的短时交通流预测方法](#)

Short-term traffic flow forecasting based on hybrid FWADE-ELM

控制与决策. 2021, 36(4): 925-932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

[基于多维泰勒网的超前d步预测模型](#)

d-step-ahead predictive model based on multi-dimensional Taylor network

控制与决策. 2021, 36(2): 345-354 <https://doi.org/10.13195/j.kzyjc.2019.0722>

[基于偏态深度分类的高炉硅含量及波动预测](#)

Prediction of blast furnace silicon content and fluctuation based on skewness depth classification

控制与决策. 2021, 36(2): 491-497 <https://doi.org/10.13195/j.kzyjc.2019.1116>

[基于改进堆叠自动编码器的循环冷却水系统工艺介质温度预测控制方法](#)

Predictive control method of process medium temperature in circulating cooling water system based on improved stacked auto encoders

控制与决策. 2020, 35(12): 2835-2844 <https://doi.org/10.13195/j.kzyjc.2019.0694>

基于小波变换与差分变异BSO-BP算法的大坝变形预测

陈俊风^{1†}, 王玉浩¹, 张学武¹, 薛醒思²

(1. 河海大学物联网工程学院, 江苏常州 213022; 2. 福建工程学院
福建省汽车电子与电驱动重点实验室, 福州 350118)

摘要: 针对现有大坝变形预测模型的预测精度不高、BP神经网络的参数和结构很难确定且容易陷入局部极值等问题,通过引入小波变换理论把原始的大坝变形序列分解成多个子序列,然后对每个子序列使用头脑风暴优化算法(brain storm optimization, BSO)优化BP神经网络的参数和结构.同时,把差分变异思想引入BSO算法,建立一种基于小波变换和差分变异头脑风暴算法优化BP神经网络的大坝变形预测模型.实验结果表明,与其他预测模型相比,所提出的预测模型具有更高的预测精度.

关键词: 大坝变形; 预测; 小波变换; BP神经网络; 差分变异; 头脑风暴优化算法

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.1431

开放科学(资源服务)标识码(OSID):



引用格式: 陈俊风,王玉浩,张学武,等.基于小波变换与差分变异BSO-BP算法的大坝变形预测[J].控制与决策,2021,36(7):1611-1618.

Dam deformation prediction based on wavelet transform and differential mutation BSO-BP algorithm

CHEN Jun-feng^{1†}, WANG Yu-hao¹, ZHANG Xue-wu¹, XUE Xing-si²

(1. College of IoT Engineering, Hohai University, Changzhou 213022, China; 2. Fujian Key Lab for Automotive Electronics and Electric Drive, Fujian University of Technology, Fuzhou 350118, China)

Abstract: The existing dam deformation prediction model has low accuracy. It is difficult to determine the parameters and structure of the BP neural network and is easy to fall into the local extremum. Therefore, this paper introduces the wavelet transform theory to decompose the original dam deformation sequence into several subsequences, then uses the brain storm optimization (BSO) algorithm to optimize the parameters and structure of the BP neural network for each subsequence. At the same time, this paper applies the differential mutation idea to the basic BSO algorithm and establishes a dam deformation prediction model based on the wavelet transform and differential mutation BSO algorithm for optimizing the BP neural network. The results of the present study indicate that the proposed prediction model has higher prediction accuracy than other prediction models.

Keywords: dam deformation; prediction; wavelet transform; BP neural network; differential variation; brain storm optimization

0 引言

目前,中国已建成各类水库9.8万余座,是世界上拥有水库大坝最多的国家^[1].大坝安全不仅与人民生活息息相关,同时与国家安全紧紧相依.因此,大坝变形预测研究意义重大.

很多学者致力于大坝变形预测研究,提出了一些非常有价值的模型.这些大坝变形预测模型大致可分为3种类型:确定性模型^[2]、统计回归模型^[3]以及综合两者的混合模型^[4].由于大坝变形主要受水位、温度、地质条件等时变因素的影响,且这些因素常常

包括10多个甚至几十个因子,从而导致变量之间具有很强的相关性以及多重共线性等问题.上述模型的可行性在很大程度上取决于是否选择恰当的建模因子,以及是否建立大坝位移与各种因素之间合理的定量关系,而这些都是悬而未决的难题.

近年来,基于人工智能的大坝变形预测算法所涉及理论范围广,内容丰富,包括灰度模型(gray model, GM)、粗糙模糊理论、随机森林模型、小波理论、神经网络、支持向量机、极限学习机等.群体智能优化是人工智能的一个重要分支,具有自学习、自组织、自适

收稿日期: 2019-10-12; 修回日期: 2020-03-04.

基金项目: 国家重点研发计划项目(2018YFC0407101); 中央高校基本科研业务费专项资金项目(2019B22314).

[†]通讯作者. E-mail: chen-1997@163.com.

应、并行处理等特点,是求解复杂非线性优化问题的有效途径.将群体智能与神经网络进行有机结合,利用群体智能优化神经网络结构、权值、阈值和参数,有助于提高神经网络对大坝变形预测的精度.

本文首先梳理基于群体智能神经网络的大坝变形预测背景;其次,针对大坝监测数据的非平稳时序特性,采用小波变换对原始数据进行分解和重构,形成基于小波变换的大坝预测通用模型;再次,提出差分变异的头脑风暴优化(brain storm optimization, BSO)变体,使其更适合BP神经网络的参数优化;最后,以一个实际大坝变形预测问题为例,对比增强型BSO-BP模型和BSO-BP模型的预测性能,全面展示各预测模型的逼近情况、预测误差以及稳定性.

1 相关背景

人工神经网络,简称神经网络(neural network, NN),具有强大的预测功能,但网络结构和参数优化本身是一个非线性复杂问题.大量研究表明,将群体智能与神经网络进行有机结合,有助于提高神经网络的预测精度.对于大坝变形分析问题,也有少数学者对基于群体智能的神经网络预测进行了初步探讨.

1.1 遗传算法优化神经网络的大坝变形预测

文献[5]将遗传算法与BP神经网络相结合,用遗传算法优化BP神经网络的参数,解决了传统BP模型收敛速度慢和泛化能力弱的问题,提高了预报的效率和精度.文献[6]基于遗传算法全局搜索的特性,建立了遗传算法优化Elman神经网络的预测模型.文献[7]开发了一种基于遗传算法和神经网络的大坝运行建模自调整系统,此系统已成功应用于Grancarevo案例.文献[8]从编码、选择、交叉和变异4个方面改进遗传算法,用改进的遗传算法优化神经网络的参数和结构,并成功地应用于大坝变形监测.文献[9]进一步分析和改进遗传算法,建立了多种群遗传算法的BP网络预测模型,并与传统回归模型和BP模型作比较,证明了所提出模型的优越性.文献[10-11]使用遗传算法和Vogl快速算法组合优化神经网络的结构和权值:文献[10]在遗传算法中加入最优保留、多种群演化和混合演化等策略,以三峡茅坪溪土石坝为例验证了该模型的有效性;文献[11]建立了智能位移反分析模型,并使用茅坪溪和公伯峡两个大坝进行了预测验证.文献[12]将均匀设计理论引入改进的遗传算法BP模型中,提出了大坝位移反分析的方法.为克服传统BP模型收敛慢和训练时间长的缺点,文献[13-14]使用数值优化中的LM算法改进BP模型,再用遗传算法优化LMBP模型的权值和阈值,并成功地应用

于小浪底大坝3维变形预测和中国丹江口预测.文献[15]首先用遗传神经网络算法回归提取残差序列,再使用混沌理论对残差序列进行数值分析,实验表明,该模型可用于其他的水工建筑物的短期预测.文献[16]提出用遗传-模拟退火混合算法组合优化BP网络的参数,并验证了所提出的预测模型适用于降雨和地下水变化对位移影响的敏感性分析.文献[17]使用混合遗传-蚁群算法训练BP网络,对预测得到的结果再使用马尔科夫链进一步优化.文献[18]基于集合经验模态分解理论,开发了EEMD-GA-BP的预测模型.

1.2 粒子群优化神经网络的大坝变形预测

文献[19]引入粒子群优化算法,构建了基于粒子群优化的预报模型.文献[20]提出使用粒子群算法优化RBF神经网络及BP神经网络的权值和阈值.文献[21]在粒子群算法中引入领域最优粒子策略、非线性递减惯性权值策略和动态调整学习因子策略,再使用改进的粒子群算法优化BP网络,并将其应用在丰满大坝中.文献[22]将所开发的基于粒子群-神经网络的预测系统用于预测均匀斜坡的安全系数.文献[23]引入线性递减惯性权值策略,建立了改进的粒子群优化BP网络的权阈值.文献[24]在粒子群算法中加入动态权重策略,用改进的粒子群算法优化RBF神经网络的参数,再采用AdaBoost算法集成,构建了基于WPSO-RBF-AdaBoost的预测模型.文献[25]将神经模糊推理系统与粒子群优化算法相结合,开发了一种新的群优化的神经模糊推理系统.

1.3 其他群智能优化神经网络的大坝变形预测

文献[26]讨论用蚁群算法优化RBF神经网络的参数,并将其应用在堆石坝参数的反演求解中.文献[27]结合蚁群算法与BP神经网络,建立了基于蚁群优化神经网络的模型.文献[28]把小生境技术与蚁群算法相结合,用小生境蚁群优化BP神经网络.文献[29]将聚类思想引入蚁群算法,提出了蚁群聚类优化RBF网络模型.文献[30]基于种群策略的全局优化搜索算法,提出了差分进化优化前馈神经网络的方法,通过实验说明了该预测模型的有效性.文献[31]把人工鱼群算法引入大坝变形预测领域,构建了人工鱼群算法优化BP网络的预测模型.文献[32]把人工蜂群算法与Elman神经网络相结合,通过案例证明了其适用性和可移植性.

2 基于小波变换的大坝预测模型

由于大坝变形数据是非平稳序列,而小波变换适用于非平稳信号或具有奇异性突变信号,本文采用小

波变换对原始的大坝变形数据进行分解和重构,提出一种基于小波变换的大坝预测通用模型。

2.1 小波分解与重构

定理1 设 $\psi(t) \in L^2(R)$, 其傅里叶变换为 $\hat{\psi}(\omega)$, 当 $\hat{\psi}(\omega)$ 满足如下允许条件(完全重构条件)时:

$$C_\psi = \int_R \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < \infty, \quad (1)$$

称 $\psi(t)$ 为一个基本小波或母小波。

将基本小波函数 $\psi(t)$ 伸缩和平移后得到小波序列

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right), \quad a, b \in R, a \neq 0. \quad (2)$$

其中: a 是伸缩因子, b 是平移因子. 对于任意函数 $f(t)$ 满足 $f(t) \in L^2(R)$, 其连续小波变换定义为

$$W_f(a,b) = \langle f(t), \psi_{a,b}(t) \rangle = \frac{1}{\sqrt{a}} \int_R x(t) \psi\left(\frac{t-b}{a}\right) dt. \quad (3)$$

将 a, b 同时离散化, 即令 $a = a_0^j, b = ka_0^j b_0$, 这里 $j \in Z$, 则 $f(t)$ 的离散小波函数 $\psi_{j,k}(t)$ 定义为

$$\psi_{j,k}(t) = a_0^{-\frac{j}{2}} \psi\left(\frac{t - ka_0^j b_0}{a_0^j}\right) = a_0^{-\frac{j}{2}} \psi(a_0^{-j} t - kb_0). \quad (4)$$

而离散化小波变换系数可以表示为

$$C_{j,k} = \int_{-\infty}^{\infty} f(t) \psi_{j,k}^*(t) dt = \langle f(t), \psi_{a,b}(t) \rangle. \quad (5)$$

其重构公式为

$$f(t) = C \sum_{-\infty}^{\infty} \sum_{-\infty}^{\infty} C_{j,k} \psi_{j,k}(t), \quad (6)$$

其中 C 是一个与信号无关的常数。

一个序列经过小波变换后, 会得到一个近似系数曲线和许多细节系数曲线. 近似系数曲线是序列的低频部分, 反映了序列的主体趋势; 细节系数曲线包含了序列的高频部分, 反映的是序列的非线性 and 波动性. 把得到的近似系数曲线和细节系数曲线再进行整合还原的过程是小波重构过程。

2.2 预测模型的整体框架

本文根据小波分解与重构的思想, 提出一种基于小波变换的大坝变形预测模型, 其基本框架如图1所示. 图中灰色阴影部分表示该框架的主要模块, 主要包括3个模块: 1) 小波分解与小波重构; 2) 群智能算法模型; 3) 子序列预测结果整合。

从图1可以看到: 预测模型首先把原始的大坝水平位移经过小波分解与小波重构得到一个近似系数序列和 m 个细节系数序列; 然后对得到的 $m+1$ 个子序列使用群智能算法模型分别进行优化与预测; 最后把各子序列预测得到的结果相加并输出最终的预

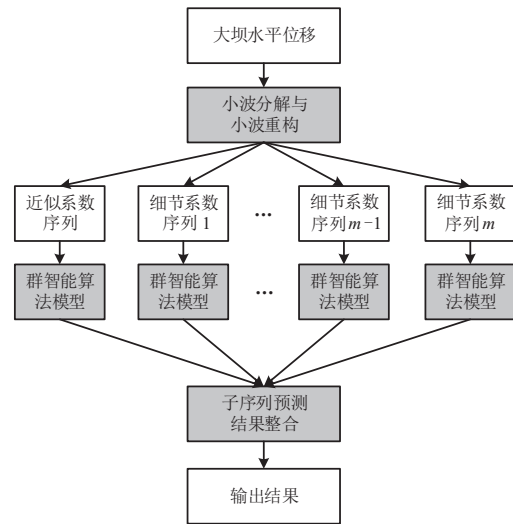


图1 基于小波变换的大坝变形预测模型的基本框架

测结果. 然而, 小波分解后得到的子序列的逼近程度与小波函数的选择有关, 且小波函数的类型很多, 比如 dbN 小波、Dmey 小波、Cgau 小波等. 因此, 为了提高小波重构的逼近精度, 要求得到的重构曲线光滑且重构误差最小, 本文选择具有高正则性的 dbN 小波函数. 在群智能算法模块中, 本文采用增强型 BSO-BP 模型分别预测得到的各个子序列。

3 差分变异BSO-BP算法

本节首先给出 BP 模型的结构; 然后在差分进化算法的基础上, 提出差分变异的头脑风暴优化变体; 最后给出使用差分变异 BSO 算法优化 BP 神经网络参数和结构的预测模型。

3.1 BP网络模型

BP 神经网络是一种多层前向网络, 其隐含层可以为一层或多层. 考虑包含一个隐含层的 BP 神经网络的拓扑结构 ($M-I-N$), 其中输入、隐含、输出层节点数分别是 M, I, N , 其输入为 $x = (x_0, x_1, \dots, x_m)$, 输出为 $y = (y_1, y_2, \dots, y_n)$ 。

隐含层第 i 个神经元的输入 $u_i^i(n)$ 、输出 $v_i^i(n)$ 分别为

$$u_i^i(n) = \sum_{m=0}^M \omega_{mi}(n) v_M^m(n), \quad (7)$$

$$v_i^i(n) = f(u_i^i(n)). \quad (8)$$

其中: ω_{mi} 为输入层与隐含层之间的连接权值; $f(\cdot)$ 为 sigmoid 函数, 即隐含层的传递函数。

输出层第 j 个神经元的输入 $u_j^j(n)$ 、输出 $v_j^j(n)$ 分别为

$$u_j^j(n) = \sum_{i=0}^I \omega_{ij}(n) v_i^i(n), \quad (9)$$

$$v_j^j(n) = g(u_j^j(n)). \quad (10)$$

其中: ω_{ij} 为隐含层与输出层之间的连接权值, $g(\cdot)$ 为输出层的传递函数.

输出层第 j 个神经元的误差为

$$e_j(n) = d_j(n) - v_j^j(n), \quad (11)$$

其中 $d_j(n)$ 是网络的期望输出.

网络的总误差为

$$e(n) = \frac{1}{2} \sum_{j=1}^J e_j^2(n). \quad (12)$$

在确定了BP网络的结构之后,要通过输入和输出数据对网络进行训练,即对网络的阈值和权值进行学习和修正,这样才能根据输入得到正确的输出.

3.2 基于差分变异头脑风暴算法优化BP网络参数的模型

3.2.1 基本BSO算法原理

根据头脑风暴会议的过程,文献[33]提出了头脑风暴优化(BSO)算法.在BSO算法中,主要策略分别为聚类策略、生成策略和选择策略.其过程见算法1.

算法1 BSO算法.

step 1: 随机产生 n 个个体.

step 2: 将这 n 个个体聚为 m 类.

step 3: 评价 n 个个体的适应度.

step 4: 将个体排序,在每个聚类中选择适应度值最小的个体作为聚类中心.

step 5: 在 $0 \sim 1$ 之间随机生成一个数.如果该值小于概率 $p_replace$, 则:

1) 随机选择一个聚类中心;

2) 随机生成一个个体并取代所选择的聚类中心.

step 6: 生成新个体:

1) 在 $0 \sim 1$ 之间随机生成一个数.

2) 如果这个数比概率 p_one 小, 则:

① 在 m 个聚类中随机选择一个聚类;

② 在 $0 \sim 1$ 之间随机生成一个数;

③ 如果这个随机数比概率 p_one_center 小, 则选择该类的聚类中心加上一个随机数生成新个体;

④ 否则, 从该类中随机选择一个普通个体, 加上一个随机数生成新个体.

3) 否则, 在 m 个类中随机挑选两个聚类中心生成新个体:

① 在 $0 \sim 1$ 之间随机生成一个数;

② 如果这个随机数比概率 p_two_center 小, 则选择两个类的聚类中心, 将他们合并后再加上一个随机数生成新个体;

③ 否则, 从两个聚类中选择两个普通个体合并生成一个新个体.

4) 新产生的个体与当前个体相比较, 适应度值好的进入下一次迭代.

step 7: 如果产生 n 个新的个体, 则跳至 step 8; 如果没有则跳至 step 6.

step 8: 如果达到最大的迭代次数, 则算法结束; 否则跳至 step 2.

在算法1中: n 表示个体总数, m 表示聚类数, $p_replace$ 表示聚类中心被替换的概率, p_one 表示选择一个聚类还是两个聚类生成新个体, p_one_center 表示在一个聚类中选择聚类中心还是普通个体生成新个体, p_two_center 表示选择两个聚类的聚类中心合并还是两个聚类中的普通个体合并生成新个体.

3.2.2 改进的生成策略

在基本BSO算法中, 新个体的生成是在旧个体的基础上加上高斯变异值, 生成的新个体为

$$y_{i,d} = x_{od} + \xi \times n(\mu, \sigma). \quad (13)$$

其中 x_{od} 是根据概率参数 p_one 的大小, 判断是选择一个聚类还是选择两个聚类生成新的个体, 即

$$x_{od} = \begin{cases} x_{id}, & \text{one cluster;} \\ \omega_1 \times x_{id} + \omega_2 \times x_{jd}, & \text{two cluster.} \end{cases} \quad (14)$$

式(13)和(14)中: d 是维度; x_{od} 是当前个体; $n(\mu, \sigma)$ 是均值为 μ 、方差为 σ 的高斯随机值; ω_1 和 ω_2 是被选择的两个聚类的权重; ξ 是高斯随机值的权重系数, 即

$$\xi = \log \text{sig} \left(\frac{0.5 \times \max_iter - \text{curr_iter}}{k} \times \text{rand}() \right). \quad (15)$$

这里: $\log \text{sig}()$ 是取值范围在 $(0, 1)$ 的 sigmoid 传递函数取对数, \max_iter 和 curr_iter 分别是最大迭代次数和当前迭代次数, k 是用来改变 $\log \text{sig}()$ 函数的斜率, $\text{rand}()$ 是 $(0, 1)$ 内的随机数.

差分进化(differential evolution, DE)主要包括种群初始化、差分变异、重组操作以及交叉操作等, 其更新公式如下所示:

种群初始化

$$x_{i,j,0} = \text{rand}_j(0, 1) \cdot (b_{j,U} - b_{j,L}) + b_{j,L}. \quad (16)$$

差分变异和重组操作

$$v_{i,g} = x_{r_0,g} + F \cdot (x_{r_1,g} - x_{r_2,g}). \quad (17)$$

交叉操作

$$u_{i,g} = u_{j,i,g} = \begin{cases} v_{j,i,g}, & \text{rand}_j(0, 1) \leq C_r \text{ or} \\ & j = j_{\text{rand}}; \\ x_{j,i,g}, & \text{otherwise.} \end{cases} \quad (18)$$

式(16)中: $x_{i,j,0}$ 表示第0代第 i 个向量的第 j 个参数,

$\text{rand}_j(0, 1)$ 表示返回 $[0, 1)$ 区间内的随机数, 且下标 j 表示向量中的每一个参数产生一个随机数; $b_{j,U}$ 和 $b_{j,L}$ 表示的是两个初始向量, 下标 U 和 L 表示上界和下界. 式 (17) 中: 放缩因子 $F \in (0, 1^+)$, 主要负责控制种群的进化率; r_0 表示基向量索引, r_1 和 r_2 表示差分向量索引. 式 (18) 中: $u_{i,g}$ 是交叉操作后的试验向量, $u_{j,i,g}$ 是交叉操作后的第 j 个试验向量, C_r 是取值在 $[0, 1]$ 区间内的交叉率, 为随机数 $\text{rand}_j(0, 1)$ 小于等于交叉率 C_r 或者随机选取的索引 j 与当前的索引 j 相等时, 试验向量 $u_{i,g}$ 就继承变异向量 $v_{i,g}$, 否则保留初始的 $x_{i,g}$.

算法2 差分进化算法的过程.

step 1: 根据式 (16), 初始化种群;

step 2: 根据式 (17), 对种群进行差分变异和重组操作;

step 3: 根据式 (18), 完成交叉操作;

step 4: 选择目标函数值小的 (较优的) 个体进入下一次迭代;

step 5: 判断是否达到最大迭代次数或者精度要求, 若满足则算法结束.

本文使用差分进化算法中的差分变异和交叉操作替换基本 BSO 算法中的高斯变异. 在差分变异中, 首先生成一个 $0 \sim 1$ 之间的随机数 $\text{rand}()$; 然后比较该数与交叉参数 P_r 的大小, 其具体数学形式如下:

$$y_{id} = \begin{cases} \text{rand}(L_d, H_d), & \text{rand}() < P_r; \\ x_{od} + \text{rand}() \times (x_1 - x_2), & \text{otherwise.} \end{cases} \quad (19)$$

其中: H_d 和 L_d 分别是第 d 维的上界和下界; x_{od} 是当前解; x_1 和 x_2 是从当前类中随机选择的两个不同的解; $\text{rand}()$ 是 $(0, 1)$ 之间的随机数, 当这个随机数较大时可以跳出局部最优, 当这个随机数较小时可以进一步挖掘局部更优的解, 这样可以在局部搜索与全局搜索之间取得平衡. 为了保证生成新个体的多样性和防止陷入局部最优, 设置交叉参数 P_r 在 $[0.001, 0.01]$ 内, 本文取 P_r 为 0.005 .

从式 (19) 可以看出: 差分量 $(x_1 - x_2)$ 是随机从当代种群中选择的两个不同的个体, 算法可以根据当代种群内个体的分布情况自适应地调节新个体的位置; 其次, 与高斯变异相比, 差分变异中仅有随机函数、加减法和乘法的混合运算, 使得改进型 BSO 算法复杂性降低, 其计算量和运行时间也随之减少.

3.2.3 基于差分变异BSO-BP模型

由于 BP 神经网络参数多, 其参数优化是典型的非线性问题. 而 BSO 算法借助于其独特的聚类特性,

在解决非线性问题上表现良好. 本文首先使用增强型 BSO 算法迭代寻优找到最优解, 然后把最优解作为 BP 神经网络的权值和阈值. 于是, 增强型 BSO-BP 模型中的待优化的维度为

$$\text{Dim} = \text{input} \times \text{hid} + \text{hid} \times \text{output} + \text{hid} + \text{output}. \quad (20)$$

其中: Dim 为待优化维度, input、hid、output 分别是 BP 神经网络输入、隐含、输出层的节点数.

在增强型 BSO-BP 模型中, 本文选择均方误差作为适应度函数来评价训练结果. 首先, 确定 BP 神经网络的结构; 然后使用增强型 BSO 算法迭代寻优, 如果达到最大迭代次数, 则把得到的最优解作为 BP 神经网络的权值和阈值; 接着训练网络, 从网络第 1 层向后计算各神经元的输出, 比较输出值与期望输出计算误差, 从最后一层向前计算各个权值对总误差的影响, 再更新 BP 神经网络的权值; 最终使得 BP 网络的均方误差小于预先设定值; 最后进行网络预测并输出预测结果. 差分变异 BSO-BP 模型流程如图 2 所示.

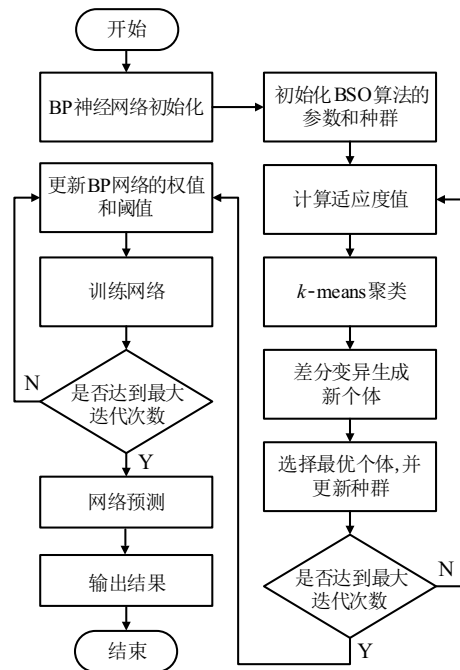


图2 差分变异BSO-BP大坝变形预测模型

4 基于小波变换的差分变异BSO-BP模型在大坝变形预测上的应用

4.1 模型参数选择

本文的实验数据来自丰满大坝一坝段钢筋混凝土重力坝^[21]. 影响大坝变形的因素包括: 水压分量 (H)、温度分量 (T_0)、时效分量 (θ)^[20-21,23]. 本文中, 网络预测模型的输入分别是水压分量及其二次方和三次方 H 、 H^2 、 H^3 , 当前温度及其前 7 天和前 15 天的平均温度 T_0 、 T_7 、 T_{15} , 时间分量及其对数 θ 和 $\ln(\theta)$, 输

出是大坝水平位移. 因此, BP神经网络模型的输入神经元为8个, 输出神经元为1个. 而隐含层的个数需要根据经验公式找到一个估计值, 然后通过实验选择误差最小所对应的层数作为隐含层数, 最后确定隐含层数为14. 因此, 本实验有 $8 \times 14 + 14 \times 1 = 126$ 个权值和 $14 + 1 = 15$ 个阈值需要优化. 一共有60组原始数据, 前40组数据作为训练数据, 后20组作为测试数据.

实验中, 为了减少初始解对算法性能的影响, 同一参数设置保证相同, BP模型、PSO算法和BSO算法中的关键参数设置分别如表1所示.

表1 模型参数

BP参数	训练次数	学习率	训练目标	动量因子
BP取值	1000	0.1	0.1	0.9
PSO参数	迭代次数	种群规模	c_1	c_2
PSO取值	50	50	1.494 45	1.494 45
BSO参数	迭代次数	种群规模	聚类数	$p_replace$
BSO取值	50	50	5	0.1
BSO参数	p_one	p_one_center	p_two_center	P_r
BSO取值	0.5	0.3	0.2	0.005

4.2 各模型实验结果对比与分析

设置好各模型的参数之后, 把60组数据分别输入到BP模型、PSO-BP模型、BSO-BP模型、差分变异BSO-BP模型、基于小波变换与差分变异BSO-BP模型中, 分析其预测精度和稳定性.

4.2.1 差分变异BSO-BP模型与基本BSO-BP模型

图3是BP模型、PSO-BP模型、BSO-BP模型、差分变异BSO-BP模型预测阶段的预测结果与期望值对比曲线, 横坐标是观测期数, 纵坐标是大坝水平位移(mm). 观察预测结果的逼近情况, 与其他预测模型相比, 本文使用头脑风暴优化变体对BP网络的初始权值和阈值进行优化, 其波动性最小, 更接近期望值.

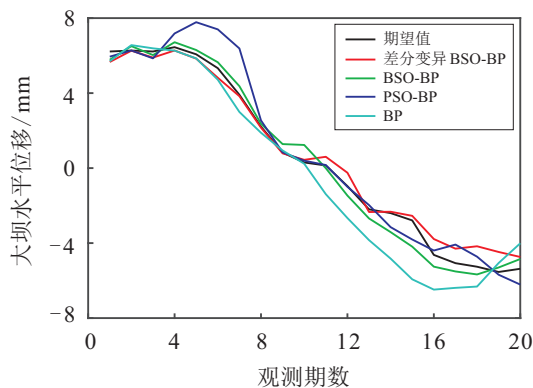


图3 差分变异BSO-BP与其他各模型的预测对比

4.2.2 基于小波变换和差分变异BSO-BP模型与其他各模型对比

为了进一步提高大坝变形预测模型的预测性能, 本文采用小波变换对原始的大坝水平位移作分解与

重构. 本文选用db4小波函数对大坝水平位移进行分解与重构, 并对其进行三级小波分解, 得到3个小尺度的细节系数曲线($d_1 \sim d_3$), 反映了序列的非线性和波动性; 以及1个大尺度的近似系数曲线(a_3), 反映了曲线的变化趋势, 如图4所示.




图4 使用db4小波分解后的曲线

分解完毕之后, 对高频子序列($d_1 \sim d_3$)和低频子序列(a_3)分别使用差分变异BSO-BP模型预测, 可以得到4个子序列的预测值, 将预测值相加, 再与期望值对比, 最终得到各个模型的预测误差如图5所示.

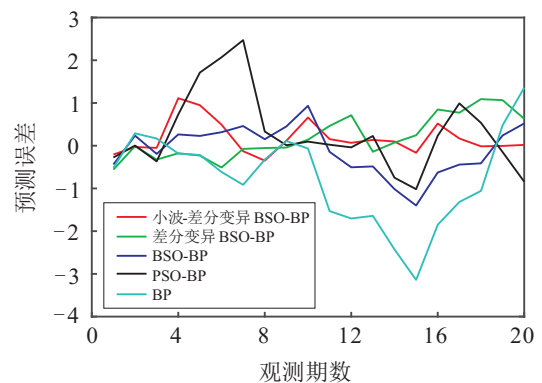


图5 各模型的预测误差对比

从图5中可以看出, 原始的BP模型和PSO-BP模型的预测误差波动最大, 预测误差分别达到了-3和3. 图中红色曲线表示的是本文提出的先对原始大坝数据进行小波分解和重构, 再用差分变异BSO-BP模型预测的方法, 其误差波动微小, 优于BSO-BP模型以及差分变异BSO-BP模型.

5 结 论

本文针对大坝变形预测问题,引入小波分解与重构的思想,提出了一种基于小波变换的大坝变形预测模型.将原始的大坝变形序列分解成若干个子序列,在基本的头脑风暴优化算法的基础上,引入差分变异的生成策略,并使用差分变异BSO算法优化BP神经网络的权值和阈值,最终建立了基于小波变换与差分变异BSO-BP算法的大坝变形预测方法.实验结果表明:与基本的BSO-BP模型相比,差分变异BSO-BP算法探索最优解的性能更好,其使用差分变异生成新个体的方式增强了种群多样性,可防止种群陷入局部最优解;与其他的预测模型相比,小波变换理论的引入能增强BSO算法优化BP神经网络的性能,其预测误差最小.综合评价来看,本文提出的基于小波变换与差分变异BSO-BP算法的预测精度更高,性能更好.

参考文献(References)

- [1] 中华人民共和国水利部. 2016年全国水利发展统计公报[M]. 北京:中国水利水电出版社, 2017: 4-8.
(Ministry of Water Resources. 2016 National water development statistics bulletin[M]. Beijing: China Water Conservancy and Hydropower Press, 2017: 4-8.)
- [2] Liang G H, Hu Y, Li Q B. Safety monitoring of high arch dams in initial operation period using vector error correction model[J]. *Rock Mechanics and Rock Engineering*, 2018, 51(8): 2469-2481.
- [3] Juan M T, Tavares de Castro A, Sada Costa J. Constructing statistical models for arch dam deformation[J]. *Structural Control and Health Monitoring*, 2014, 21(3): 423-427.
- [4] Salazar F, Toledo M A, Oñate E, et al. An empirical comparison of machine learning techniques for dam behaviour modelling[J]. *Structural Safety*, 2015, 56: 9-17.
- [5] Majidi A, Beiki M. Evolving neural network using a genetic algorithm for predicting the deformation modulus of rock masses[J]. *International Journal of Rock Mechanics and Mining Sciences*, 2010, 47(2): 246-253.
- [6] 刘雄峰, 李博, 李俊. 基于遗传算法的Elman神经网络模型在大坝位移预测中的应用[J]. *水资源与水工程学报*, 2014, 25(3): 152-156.
(Liu X F, Li B, Li J. Application of Elman neural network model in prediction of dam deformation based on genetic algorithms[J]. *Journal of Water Resources and Water Engineering*, 2014, 25(3): 152-156.)
- [7] Stojanovic B, Milivojevic M, Milivojevic N, et al. A self-tuning system for dam behavior modeling based on evolving artificial neural networks[J]. *Advances in Engineering Software*, 2016, 97: 85-95.
- [8] 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 J, Cai J J, Cheng S. Research on dam displacement forecast model based on genetic algorithm neural network[J]. *Journal of Shandong University: Engineering Science*, 2006, 36(2): 62-66.)
- [9] Wang X Y, Yang K, Shen C S. Study on MPGA-BP of gravity dam deformation prediction[J]. *Mathematical Problems in Engineering*, 2017, 6: 1-13.
- [10] 张丙印, 袁会娜, 李全明. 基于神经网络和演化算法的土石坝位移反演分析[J]. *岩土力学*, 2005, 26(4): 547-552.
(Zhang B Y, Yuan H N, Li Q M. Displacement back analysis of embankment dam based on neural network and evolutionary algorithm[J]. *Rock and Soil Mechanics*, 2005, 26(4): 547-552.)
- [11] Yu Y Z, Zhang B Y, Yuan H N. An intelligent displacement back-analysis method for earth-rockfill dams[J]. *Computers and Geotechnics*, 2007, 34(6): 423-434.
- [12] 李端有, 甘孝清, 周武. 基于均匀设计及遗传神经网络的大坝力学参数反分析方法[J]. *岩土工程学报*, 2007, 29(1): 125-130.
(Li D Y, Gan X Q, Zhou W. Back analysis on mechanical parameters of dams based on uniform design and genetic neural network[J]. *Chinese Journal of Geotechnical Engineering*, 2007, 29(1): 125-130.)
- [13] 王新志, 陈伟. 基于GA-LMBP网络模型的小浪底大坝3维变形预报分析[J]. *测绘与空间地理信息*, 2012, 35(7): 95-97.
(Wang X Z, Chen W. 3D deformation forecast and analysis of Xiaolangdi dam based on GA-LMBP network model[J]. *Geomatics & Spatial Information Technology*, 2012, 35(7): 95-97.)
- [14] Miao X Y. An evolutionary neural network approach to simple prediction of dam deformation[J]. *Journal of Information and Computational Science*, 2013, 10(5): 1315-1324.
- [15] 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.
(Wei B W, Peng S J, Xu Z K, et al. The GA-BP prediction model considering chaos effect of dam displacement residual[J]. *Scientia Sinica (Technologica)*, 2015, 45(5): 541-546.)
- [16] Chen H Q, Zeng Z G. Deformation prediction of landslide based on improved back-propagation neural network[J]. *Cognitive Computation*, 2013, 5(1): 56-62.
- [17] 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.
(Dong D D, Zu A J, Sun X L. Model of dam deformation monitoring based on genetic ant colony optimization and back propagation improved by Markov chain[J]. *Journal of Yangtze River Scientific Research Institute*, 2019, 36(7): 48-54.)
- [18] 晏红波, 周斌, 卢献健, 等. 基于EEMD-GA-BP模型的大坝变形监测数据预测[J]. *长江科学院院报*, 2019, 36(9): 58-63.
(Yan H B, Zhou B, Lu X J, et al. Prediction of dam

- deformation monitoring data based on EEMD-GA-BP model[J]. Journal of Yangtze River Scientific Research Institute, 2019, 36(9): 58-63.)
- [19] 王伟, 沈振中, 王连庆. 基于粒子群仿生算法的混凝土坝变形预报模型[J]. 水利水电科技进展, 2008, 28(4): 11-14.
(Wang W, Shen Z Z, Wang L Q. Concrete dam deformation forecasting model based on PSO bionic algorithm[J]. Advances in Science and Technology of Water Resources, 2008, 28(4): 11-14.)
- [20] 吕蓓蓓, 杨远斐. PSO-RBF在大坝变形监测中的应用[J]. 水电能源科学, 2012, 30(8): 77-79.
(Lv B B, Yang Y F. Application of PSO-RBF in dam deformation monitoring[J]. Water Resources and Power, 2012, 30(8): 77-79.)
- [21] 胡纪元, 文鸿雁, 周吕, 等. 基于IPSO-BP模型的大坝多源监测数据预报与反演[J]. 大地测量与地球动力学, 2014, 34(4): 67-70.
(Hu J Y, Wen H Y, Zhou L, et al. Study on dam prediction and inversion with multi-source monitoring data based on IPSO-BP model[J]. Journal of Geodesy and Geodynamics, 2014, 34(4): 67-70.)
- [22] Gordan B, Jahed Armaghani D, Hajihassani M, et al. Prediction of seismic slope stability through combination of particle swarm optimization and neural network[J]. Engineering with Computers, 2016, 32(1): 85-97.
- [23] 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.
(Qi Y F, Tan R J. Application of improved particle swarm optimization algorithm-based BP neural network to dam deformation analysis[J]. Water Resources and Hydropower Engineering, 2017, 48(2): 118-124.)
- [24] 沈晶鑫, 房彬, 郑东健, 等. 基于AdaBoost集成的WPSO-RBF大坝变形监控模型[J]. 长江科学院院报, 2018, 35(5): 57-62.
(Shen J X, Fang B, Zheng D J, et al. Dam deformation monitoring by radial basis function model optimized by particle swarm optimization with inertia weight and AdaBoost[J]. Journal of Yangtze River Scientific Research Institute, 2018, 35(5): 57-62.)
- [25] Bui K T T, Tien Bui D, Zou J G, et al. A novel hybrid artificial intelligent approach based on neural fuzzy inference model and particle swarm optimization for horizontal displacement modeling of hydropower dam[J]. Neural Computing and Applications, 2018, 29(12): 1495-1506.
- [26] 康飞, 李俊杰, 许青. 堆石坝参数反演的蚁群聚类RBF网络模型[J]. 岩石力学与工程学报, 2009, 28(S2): 3639-3644.
(Kang F, Li J J, Xu Q. Ant colony clustering radial basis function network model for inverse analysis of rockfill dam[J]. Chinese Journal of Rock Mechanics and Engineering, 2009, 28(S2): 3639-3644.)
- [27] 牛景太, 魏博文. 基于蚁群优化神经网络的混凝土坝位移安全监控模型[J]. 甘肃水利水电技术, 2012, 48(7): 39-41.
(Niu J T, Wei B W. Concrete dam displacement safety monitoring model based on ant colony optimization neural network[J]. Gansu Water Resources and Hydropower Technology, 2012, 48(7): 39-41.)
- [28] 魏玮, 陈晨, 邵晨飞, 等. 小生境蚁群-BP神经网络在大坝变形监测中的应用[J]. 水电能源科学, 2014, 32(8): 85-87.
(Wei W, Chen C, Shao C F, et al. Deformation monitoring model of dam based on NACA-BP neural network[J]. Water Resources and Power, 2014, 32(8): 85-87.)
- [29] 黄潇霏, 顾昊. 大坝变形蚁群聚类径向基函数神经网络安全监控预测模型[J]. 三峡大学学报: 自然科学版, 2014, 36(6): 33-36.
(Huang X F, Gu H. Ant colony clustering radial basis function neural network model for safety monitoring of dam deformation[J]. Journal of China Three Gorges University: Natural Sciences, 2014, 36(6): 33-36.)
- [30] 刘福深, 刘耀儒, 杨强. 基于差异进化算法的前馈神经网络在大坝变形监测中的应用[J]. 岩土力学, 2006, 27(4): 597-600.
(Liu F S, Liu Y R, Yang Q. Application of feed-forward neural networks to dam deformation monitoring based on differential evolution algorithm[J]. Rock and Soil Mechanics, 2006, 27(4): 597-600.)
- [31] 杨红, 陈向阳, 张飞, 等. AFSA-BP神经网络在大坝变形预测中的应用[J]. 地理空间信息, 2012, 10(6): 131-132.
(Yang H, Chen X Y, Zhang F, et al. Application of AFSA-BP neural network in dam displacement prediction[J]. Geospatial Information, 2012, 10(6): 131-132.)
- [32] 李鹏鹏, 苏怀智, 郭芝韵, 等. 基于人工蜂群算法与Elman神经网络的大坝变形监控模型[J]. 水利水电技术, 2017, 48(3): 104-108.
(Li P P, Su H Z, Guo Z Y, et al. Artificial bee colony algorithm and Elman neural network-based model for dam deformation monitoring[J]. Water Resources and Hydropower Engineering, 2017, 48(3): 104-108.)
- [33] Ma L B, Cheng S, Shi Y H. Enhancing learning efficiency of brain storm optimization via orthogonal learning design[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems. DOI: 10.1109/TSMC.2020.2963943.

作者简介

陈俊风(1979—), 女, 副教授, 博士, 从事群体智能与不确定优化等研究, E-mail: chen-1997@163.com;

王玉浩(1996—), 男, 硕士生, 从事群体智能和协同进化的研究, E-mail: wangyh_159@163.com;

张学武(1973—), 男, 教授, 博士生导师, 从事物联网技术与应用等研究, E-mail: zhangxw@hhu.edu.cn;

薛醒思(1981—), 男, 教授, 博士, 从事人工智能与知识工程等研究, E-mail: jack8375@gmail.com.

(责任编辑: 李君玲)