

DOI: 10. 20040/j. cnki. 1000-7709. 2023. 20221369

# 考虑不确定性概念的高面板堆石坝动力参数反演分析

宋子屹<sup>1</sup>, 韩鹏举<sup>1</sup>, 马 聪<sup>1</sup>, 张宏洋<sup>1,2</sup>

(1. 华北水利水电大学水利学院, 河南 郑州 450046; 2. 水资源高效利用与保障工程河南省协同创新中心, 河南 郑州 450046)

**摘要:** 针对目前动本构模型参数反演方法大多未考虑参数不确定性的问题, 将自适应云变换算法(AGCT)与RBF神经网络(RBFNN)相结合, 构建了自适应云神经网络参数反演模型(AGCTNN), 将不确定性概念转换为定量数值, 较好地考虑了大坝系统间的随机性与模糊性对动力参数反演的影响。对比分析 AGCT 与 K-Means、SOM、DBSCAN 三种传统聚类算法, 验证了算法的优越性与可行性, 而后利用 AGCTNN 与 RBFNN 两种反演模型对工程实例进行了反演分析。结果表明, 提出的反演模型正耦合计算结果与实测值一致性更好, 测点峰值加速度实测值与反演值的误差范围由 8.73%~25.17% 降至 2.31%~8.16%, 印证了该反演模型的合理性与应用于实际工程中的可能性。

**关键词:** 土石坝; 等效线性模型; 反演分析; 自适应云神经网络; 云变换算法; RBF 神经网络

**中图分类号:** TV641.1      **文献标志码:** A      **文章编号:** 1000-7709(2023)04-0118-05

## 1 引言

在西部地区水利工程建设中, 约 60% 以上为土石坝, 如紫坪铺、两河口等。目前, 我国西部高土石坝普遍面临地质条件复杂多变、地震烈度高、频率高等问题, 失事后果严重。筑坝材料本构模型的参数准确性决定了有限元分析结果。常见的参数获取方法多以室内试验或实际工程资料为主, 但受取样代表性、材料粒径缩尺等因素影响, 参数值与材料真实物理特性存在一定误差。为此, 构建一种基于坝体实测数据的参数反演模型更好地研究土石坝动力响应十分必要。目前, 参数反演模型中应用较为广泛的算法有遗传算法<sup>[1]</sup>、PSO 粒子群算法<sup>[2]</sup>等。传统深度学习反演模型的反演结果易受到初始权值的影响, 从而陷入非要求的局部极值。此外, 现有反演模型少有考虑材料参数不确定性的影响或无法定量分析其不确定性。为此, 本文将自适应云变换算法(AGCT 算法)与 RBF 神经网络(RBFNN)相结合, 建立了使不确定性概念更清晰的 AGCTNN 参数反演模型, 使反演参数值成为一个集模糊性与随机性的综合体, 以进一步提高反演模型的反演精度与效率, 从而更好地预测土石坝动力响应, 为评估坝体抗震安全与稳定提供理论支撑。

## 2 模型与研究方法

### 2.1 等效线性模型

土层地震动力分析中等效线性模型利用动剪切模量比、阻尼比与动剪切应变的关系来反映土体在动力条件下的非线性与滞后性。并将模量与阻尼比表示为动应变幅的函数<sup>[3]</sup>, 通过大量试验, 堆石料的最大动剪切模量  $G_{\max}$  及其等效阻尼比  $\lambda$  可分别表示为:

$$G_{\max} = kP_a (\sigma'_m / P_a)^n \quad (1)$$

$$\lambda = \frac{1}{4\pi} \frac{\Delta W}{W} = \frac{2k_1}{\pi} \left(1 - \frac{G}{G_{\max}}\right) \quad (2)$$

其中  $\sigma'_m = (\sigma'_1 + \sigma'_2 + \sigma'_3) / 3$   
式中,  $k, n$  分别为等效线性模型参数, 由动三轴试验确定;  $\sigma'_1, \sigma'_2, \sigma'_3$  均为动三轴试验中的第一、二、三有效主应力;  $P_a$  为工程大气压;  $\Delta W$  为一个动力循环周期内耗能;  $W$  为一个周期内的总能量;  $k_1$  为常数;  $G$  为动剪切模量。

### 2.2 不确定性反演分析法

#### 2.2.1 云理论

云模型为定量数值和定性概念相互转换的认知模型<sup>[4]</sup>, 其特性通过云数字特征  $E_x$  (期望)、 $E_n$  (熵)、 $H_c$  (超熵) 来体现, 其中  $E_x$  为定性概念量化后的均值;  $E_n$  为对不确定性定性概念的度量,

收稿日期: 2022-07-05, 修回日期: 2022-07-27

作者简介: 宋子屹(1997-), 男, 硕士, 研究方向为水工结构工程, E-mail: songziyi\_2021@163.com

反映定性概念的模糊程度;  $H_e$  为对熵的不确定性度量,反映指标的稳定性。

### 2.2.2 正向云发生器

正向云发生器是从定性到定量的映射<sup>[4]</sup>,揭示了随机性和模糊性的内在关联。正向云发生器能够实现定性概念到定量数值的转化,其表达式为:

$$\mu = \exp\{- (x - E_x)^2 / [2(E_n')^2]\} \quad (3)$$

式中,  $\mu$  为概念隶属度。

本文材料动力参数将通过正向高斯云发生器产生各参数在各区间内的数据样本,为自适应式云神经网络(AGCTNN)反演提供所用训练样本。

### 2.2.3 自适应云变换(AGCT)算法原理

给定论域中某个数据属性  $X$  的频率分布函数  $f(x)$ ,根据  $X$  属性值频率的实际分布情况对不同的云  $C(E_{x_i}, E_{n_i}, H_{e_i})$  进行叠加,每个云代表一个离散的、定性的概念,这种从连续的数值区间到离散概念的转换过程,称为云变换<sup>[4]</sup>。其函数表达式为:

$$f(x) \rightarrow \sum_{i=1}^n a_i C(E_{x_i}, E_{n_i}, H_{e_i}) \quad (4)$$

式中,  $a_i$  为幅度系数;  $n$  为变换后生成离散概念的个数;  $C$  为定量数域中的定性概念。

算法结构由三部分组成,见图 1。图 1 中,

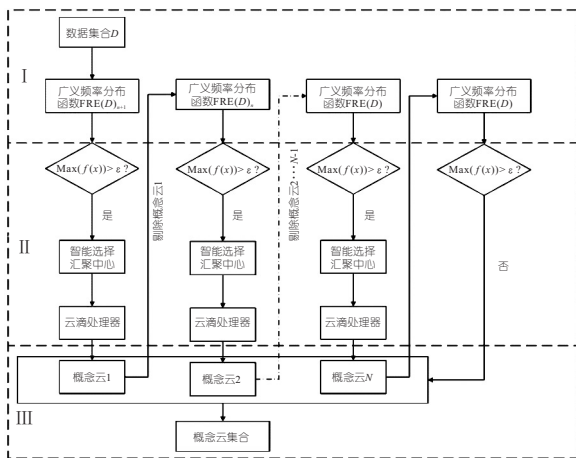


图 1 自适应式高斯云变换算法结构

Fig. 1 Algorithm structure of adaptive Gaussian cloud transform

I、II、III 分别为数据频率转换区、概念云迭代区、离散概念集合输出区。AGCT 算法首先对数据的频率分布进行归纳学习,频率分布中的局部最大值为整体数据的汇聚中心,对应云模型中云滴峰值(期望),算法将优先表达其定性概念,并从原数据样本频率分布中剔除该定性概念对应的数值部分,开始寻找新的数据汇聚中心,以此方式循环,直至数据频率分布中不存在新的汇聚中心时,云变换结束,最终生成若干个概念云及其对应云

数字特征值。

## 2.3 AGCTNN 反演模型

### 2.3.1 RBF 神经网络

在 RBF 神经网络中,输入层到隐含层的变换是非线性的,而从隐含层到输出层的变换是线性的,是一种前馈神经网络<sup>[5]</sup>,其拓扑结构由输入、隐含、输出共三层组成,其网络拓扑结构见图 2。




图 2 RBF 径向基神经网络拓扑图

Fig. 2 RBF neural network topology

高斯函数  $\varphi(x)$  为:

$$\varphi(x) = \exp(-x^2 / (2\sigma^2)) \quad (5)$$

式中,  $\sigma$  为激活函数的带宽参数,用来确定输入样本  $x_i$  与权重  $W_{ij}$  的距离相对应的径向基函数的宽度。

隐含层到输出层的线性变换关系由下式实现。

$$y_j = \sum_{n=1}^m W_{ij} \exp\left(-\frac{1}{2\sigma^2} \|x_i - c_i\|^2\right) \quad (6)$$

式中,  $y_j$  为输出值;  $c_i$  为汇聚中心。

### 2.3.2 AGCTNN 神经网络

AGCTNN 神经网络由输入层、云滴隶属层、软与层、归一化层、隐含层、输出层共 6 层组成。云滴隶属度层利用云发生器计算每个输入分量属于对应概念的隶属度  $\epsilon_i^j$ , 其节点函数分别为:

$$f_{ij}^{(2)} = -(x_i^{(1)} - E_{x_{ij}})^2 / E_{nn_{ij}}^2 \quad (7)$$

$$x_{ij}^{(2)} = \epsilon_i^j = e^{f_{ij}^{(2)}} = \exp\left(-\frac{(x_i^{(1)} - E_{x_{ij}})^2}{E_{nn_{ij}}^2}\right)$$

$$i = 1, 2, \dots, n; j = 1, 2, \dots, m \quad (8)$$

式中,  $x_i$  为输入分量值;  $E_{nn_{ij}}$  由  $E_{n_{ij}}$ 、 $H_{e_{ij}}$  确定。

软与层对每一个隶属度  $\epsilon_i^j$  通过下式计算其在  $[1, 0]$  内的取值:

$$\left\{ \begin{aligned} f_j^{(n)} &= \exp\left(-\left(\frac{(\epsilon_1^j - 1)^2}{E_{nn_1}^2} + \frac{(\epsilon_2^j - 1)^2}{E_{nn_2}^2} + \dots + \frac{(\epsilon_n^j - 1)^2}{E_{nn_n}^2}\right)\right) \\ C_m &= f_j^{(n)} \end{aligned} \right. \quad (9)$$

式中,  $C_m$  为概念规则适用度。

隐含层的输出权值由 AGCT 算法生成,并利用公式进行更新,具体节点函数可表达为:

$$\left\{ \begin{aligned} f(x) &\rightarrow \sum_{i=1}^n a_i C(E_{x_i}, E_{n_i}, H_{e_i}) \\ y &= \exp\{- (x - E_x)^2 / [2(E_n)^2]\} \end{aligned} \right. \quad (10)$$

### 2.4 算法对比分析

为验证 AGCT 算法较 K-Means、SOM、DBSCAN 三种经典数据聚类分析算法的优越性,采用随机生成的月牙状、圆环状、随机状三种不同类型的数据集进行聚类分析,数据集生成所用相关参数指标见表 1。最终结果见图 3。AGCT 算法较另外三种算法聚类与划分效果更清晰,耗时上较 K-Means 算法略慢,但总体上处于四种算法的平均值。体现了 AGCT 算法在数据聚类与划分方面的优越性。

表 1 相关参数指标

Tab. 1 Relevant parameter indicators

数据类型	样本点数	噪声因子	随机样本生成数量	比例因子
月牙状	750	0.10	5.0	
圆环状	750	0.10	3.0	0.50
随机型	300		5.0	

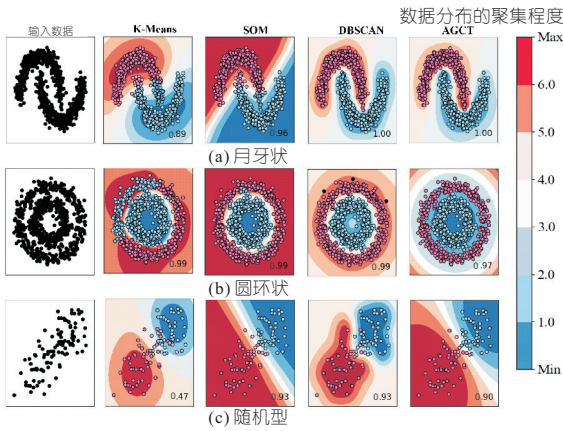


图 3 数据聚类分析各算法处理结果

Fig. 3 Results of data clustering analysis by algorithm

### 3 面板堆石坝材料动力参数反演过程

利用实测加速度峰值作为特征值进行反演时,可有效规避参数之间的耦合作用,综合反演精度、效率两方面考虑效果更优,因此本文利用加速度峰值作为特征值构造目标函数。AGCTNN 模型的坝体材料动力参数反演过程如下。

(1)生成样本集。利用实际工程资料或室内试验法确定参数样本范围,并通过正向云发生器生成有限元计算参数样本。

(2)对有限元计算结果进行数据概率曲线分布转换。利用 AGCT 法得到数据概率曲线图的  $E_x$ (期望)、 $E_n$ (熵)、 $H_e$ (超熵),作为网络的输入权值;利用正向云发生器对参数训练样本生成的云数字特征作为输出权值。

(3)将有限元计算结果作为输入,参数训练样本作为输出,对网络进行训练,利用误差反向传播算法调整云推理的参数。直至满足设定要求后,训练结束。

误差代价函数为:

$$E = \frac{1}{2} \sum_{i=1}^r (t_i - y_i)^2 \quad (11)$$

式中,  $t_i$ 、 $y_i$  分别为期望输出、实际输出。

(4)选择一组实测数据代入该网络中,得到对应组的参数样本。

### 4 实例分析

紫坪铺面板堆石坝坝顶长 663.77 m,坝顶宽 12.0 m,坝顶高程 884.00 m,最大坝高 156 m,上游坡比 1:1.4,下游坡比分别为 1:1.5、1:1.4。正常蓄水位 877.00 m,震时水位 828.65 m,死水位 817.00 m,坝体主要由堆石料 I、堆石料 II 组成。坝体剖面共设有 4 个地震监测台站,选择具有代表性的 # T4 监测台站的加速度时程进行反演分析,大坝典型剖面图及监测台站分布见图 4。坝体三维有限元计算模型见图 5,共生成网格数 72 070 个,节点数 65 030 个。

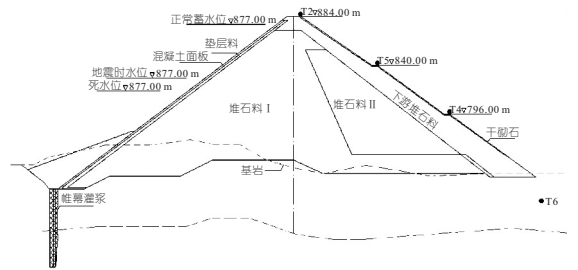


图 4 紫坪铺大坝典型剖面示意图

Fig. 4 Cross section of Zipingpu Dam




图 5 紫坪铺大坝三维有限元网格模型

Fig. 5 Finite element model of Zipingpu dam

采用朱晟等<sup>[6]</sup>推求的三向地震加速度峰值,即顺河向(NS)0.46g、竖直向(UD)0.43g、坝轴方向(EW)0.52g,选择距离坝址较近的绵竹清台(051MZQ)台站实测地震加速度时程(由中国地震局工程力学研究所提供的数据支持),进行等比例放缩后,得到紫坪铺大坝基岩的三向输入加速度曲线见图 6。

#### 4.1 动力参数反演分析

坝体的有限元静力计算是动力计算的基础,静力计算阶段采用邓肯一张 EB 模型,模型参数




图 6 三向加速度时程曲线

Fig. 6 Acceleration time histories of model

采用中国水利水电科学研究院室内静三轴试验<sup>[7]</sup>结果,对坝体分二十层进行逐级浇筑,并蓄水至地




图 7 #T4 峰值加速度云变换示意图

Fig. 7 Schematic diagram of #T4 peak acceleration cloud transformation

表 3 #T4 顺河向、竖直向、坝轴向峰值加速度云数字特征

Tab. 3 #T4 along river peak, vertical peak and axial peak acceleration cloud digital characteristics

云数字特征	顺河向			竖直向				坝轴向	
	1	2	3	1	2	3	4	1	2
$E_x$	0.653	0.846	1.077	0.585	0.731	0.879	1.035	0.983	1.217
$E_n$	2.170	5.120	4.920	2.840	3.190	5.270	1.450	8.620	3.780
$H_e$	0.065	0.960	0.365	0.490	0.330	0.660	0.330	1.201	0.535

注:表中 1,2,3,4 表示第  $n$  个云分布。如 1,就表示以下的云数字  $E_x$ 、 $E_n$ 、 $H_e$  属于第一个云分布。

### 4.2 反演结果分析

材料动力参数反演结果见表 4。

表 4 材料动力参数反演结果

Tab. 4 Inversion results of dynamic parameters of dam material for Zipingpu dam

材料	$k$			$n$		
	实测值	反演值	扩大倍数	实测值	反演值	扩大倍数
堆石料 I	3 784.4	5 939.1	1.67	0.416	0.423	1.01
堆石料 II	3 180.0	4 135.4	1.46	0.528	0.585	1.10

震时水位。动力计算阶段采用等效线性模型。

主要对坝料占比更多的堆石料 I、堆石料 II 进行反演。动力参数反演数据范围参考室内动三轴试验和工程资料,具体见表 2。

表 2 动力参数反演范围

Tab. 2 Dynamic parameter inversion range

材料	$k$	$n$
堆石料 I	3 200~5 800	0.22~0.48
堆石料 II	2 700~3 150	0.35~0.53

根据表 2 反演范围,利用 AGCT 方法共生成 100 组参数训练样本,前 80 组样本作为训练集,后 20 组作为测试集。对各参数组进行有限元计算后得到测点 #T4 的峰值加速度并对其进行云变换处理,结果见图 7,其不确定性程度的数值解见表 3。网络训练迭代至 92 次时,精度已趋于稳定,迭代至 107 次时精度达  $1.869 24 \times 10^{-7}$ ,满足误差代价函数设定。

由表 4 可知,堆石料 I 与堆石料 II 的参数  $k$  值反演计算结果较室内试验结果偏大,堆石料 I、II 区反演值分别约为实际的 1.67、1.46 倍,这与朱晟等<sup>[6]</sup>的研究结果一致;对于参数  $n$ ,反演值与室内试验结果相比,变化相对较小,且均略低于实际值。为进一步验证本文反演模型的可靠性,分别利用 AGCTNN 与 RBFNN 两种反演模型得到的最优反演参数组对紫坪铺面板堆石坝进行正向耦合计算,结果见图 8。由图 8 可看出,测点 #T4 的实测加速度时程与反应谱曲线均与 AGCTNN 模型的反演值较为接近,反应谱随时间的分布情况一致。两种反演模型计算所得测点峰值加速度值误差范围分别为 8.73%~25.17%、2.31%~8.16%,最小、最大误差分别缩小了 73.5%、67.8%,AGCTNN 模型反演效果优于传统 RBFNN 模型,表明了该反演模型的可靠性与有效性。




图 8 # T4 实测与反演峰值加速度时程、反应谱曲线  
 Fig. 8 Simulated and actual monitoring acceleration time histories, response spectra and Fourier amplitude at # T4

## 5 结论

a. 联合云变换算法与 RBF 神经网络,提出了

# Inversion Analysis of Dynamic Parameters of High Panel Rockfill Dams Considering Concept of Uncertainty

SONG Zi-yi<sup>1</sup>, HAN Peng-ju<sup>1</sup>, MA Cong<sup>1</sup>, ZHANG Hong-yang<sup>1,2</sup>

(1. School of Water Conservancy, North China University of Water Resources and Electric Power, Zhengzhou 450046, China; 2. Collaborative Innovation Center of Water Resources Efficient Utilization and Protection Engineering of Henan Province, Zhengzhou 450046, China)

**Abstract:** Most existing parameter inversion methods of the dynamic constitutive model parameters do not take the concept of uncertainty into account. Therefore, the adaptive cloud transformation algorithm (AGCT) was combined with RBF neural network (RBFNN) to construct an adaptive cloud neural network parameter inversion model (AGCTNN), which converts the uncertainty concept into quantitative values and better takes into account the influence of the randomness and ambiguity between dam systems on the inversion of dynamic parameters. AGCT was compared and analyzed with three traditional clustering algorithms, K-Means, SOM and DBSCAN, to verify the superiority and feasibility of the algorithms. The inversion analysis was then carried out on engineering examples using two inversion models, AGCTNN and RBFNN. The results show that the positive coupling results of the proposed inversion model are in better agreement with the measured values, and the error range between the measured and inverse values of peak acceleration at measurement points is reduced from 8.73%-25.17% to 2.31%-8.16%, which confirms the reasonableness of the inversion model and the possibility of its application in practical engineering.

**Key words:** earth-rockfill dam; equivalent linear model; parameter inversion; adaptive cloud neural network; cloud transformation; RBF neural network

一种考虑不确定性的参数反演模型,实现了不确定性概念到具体数值的转化,使网络输出结果成为一个集模糊性与随机性的综合体。

b. 工程实例计算表明,坝体测点峰值加速度实测与反演值最小、最大误差分别缩小了 73.5%、67.8%,AGCTNN 模型有效地提升了传统 RBFNN 模型的反演精度,印证了该反演模型的合理性。

## 参考文献:

- [1] 刘振平,迟世春,任宪勇.基于土石坝动力特性的坝料动力参数反演[J].岩土力学,2014,35(9):2594-2601.
- [2] 汪旭,康飞,李俊杰.土石坝地震永久变形参数反演方法研究[J].岩土力学,2014,35(1):279-286.
- [3] 吴世明.土动力学[M].北京:中国建筑工业出版社,2000.
- [4] 李德毅,刘常显,杜鹃,等.不确定性人工智能[J].软件学报,2004(11):1583-1594.
- [5] NIE JINSUO, ELLINGWOOD B R. A new directional simulation method for system reliability. Part II: Application of neural networks[J]. Probabilistic engineering mechanics, 2004, 19(4): 437-447.
- [6] 朱晟,杨鸽,周建平,等.“5·12”汶川地震紫坪铺面板堆石坝静动力初步反演研究[J].四川大学学报(工程科学版),2010,42(5):113-119.
- [7] 刘小生,王钟宁,汪小刚,等.面板坝大型振动台模型试验与动力分析[M].北京:知识产权出版社,2005.