

DOI:10.3969/j.issn.1003-5060.2026.07.020

引水工程边坡位移 SABO-LSTM 监测模型及风险状态研究

黄 铭, 王鹏飞

(合肥工业大学 土木与水利工程学院, 安徽 合肥 230009)

摘 要:文章利用减法平均优化算法(subtraction-average-based optimizer, SABO)对长短期记忆网络(long short-term memory, LSTM)模型进行优化,建立 SABO-LSTM 引水工程边坡位移监测模型,实现了对边坡位移规律的准确预测。并以边坡各测点位移和位移速率为评估指标,根据各指标数据特征采用置信区间法对其进行风险状态分级,基于区间数距离计算得到各指标的基本概率分配;然后结合 D-S(Dempster-Shafer)证据理论对各指标基本概率进行融合,利用融合结果对边坡位移风险状态进行评估,并结合监测模型预测结果,实现了对边坡位移风险状态的预评估。该研究结果可为边坡位移预测及风险状态评估提供技术参考。

关键词:引水工程边坡; SABO-LSTM 模型; 置信区间法; D-S 证据理论; 风险状态

中图分类号:TV672; X820.4

文献标志码:A

文章编号:1003-5060(2026)07-0997-06

Study on SABO-LSTM monitoring model and risk state of slope displacement in water diversion projects

HUANG Ming, WANG Pengfei

(School of Civil and Hydraulic Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: In this paper, the subtraction-average-based optimizer(SABO) is used to optimize the long short-term memory(LSTM) model, and the SABO-LSTM-based slope displacement monitoring model of water diversion project is established, thus achieving the accurate prediction of slope displacement law. The displacement and displacement rate of each measuring point of slope are taken as evaluation indexes. According to the data characteristics of each index, the confidence interval method is used to classify the risk state, and the basic probability assignment(BPA) of each index is calculated according to the interval number distance. Then, the basic probability of each index is fused with the Dempster-Shafer(D-S) evidence theory, and the risk state of slope displacement is evaluated by using the fusion results. Combined with the prediction results of the monitoring model, the pre-evaluation of the risk state of slope displacement is achieved. The research results can provide technical reference for slope displacement prediction and risk state assessment.

Key words: water diversion project slope; subtraction-average-based optimizer-long short-term memory(SABO-LSTM) model; confidence interval method; Dempster-Shafer(D-S) evidence theory; risk state

我国地域地质极为复杂,边坡变形、失稳事故频发,造成重大的财产损失和人员伤亡^[1]。为保证边坡安全,实现提前预警,开展边坡位移监测模型及风险状态研究是边坡灾害预防控制的重要内容。

长短期记忆网络(long short-term memory,

LSTM)模型作为一种深度学习模型,具有记忆能力,在非线性时间序列数据预测研究上展现了优势,并已开始应用于水质^[2]、大坝^[3]等研究领域。边坡位移历史监测数据较多,且具有较强的非线性特点,适合应用 LSTM 模型。而 LSTM 模型

收稿日期:2024-03-22;修回日期:2024-05-06

基金项目:安徽省自然科学基金资助项目(2208085US01)

作者简介:黄 铭(1972—),男,江西乐平人,博士,合肥工业大学教授,博士生导师,通信作者,E-mail:Lsxhuangm@hotmail.com.

网络超参数的选择直接决定其网络拓扑结构和网络预测性能,但需要进行多次试验,时间精力成本较高^[4]。

本文提出将减法平均优化算法(subtraction-average-based optimizer, SABO)与 LSTM 模型相结合,旨在对神经网络中的超参数实现智能优化,避免多次试验费时费力及人为设定参数引起模型预测效果不准确等缺点,并充分发挥 SABO 算法全局搜索能力和 LSTM 模型预测时序数据的优势,以提高边坡位移预测的可行性及准确性;同时利用边坡位移实测资料,以位移量和位移速率为指标,结合 D-S(Dempster-Shafer)证据理论建立边坡位移风险状态评估模型,并根据 SABO-LSTM 模型预测结果进行边坡位移风险状态预评估。

1 研究方法

1.1 SABO-LSTM 位移预测模型构建

1.1.1 LSTM 模型

LSTM 模型是对传统的循环神经网络模型的扩展和改进^[5],其结构设计使其在处理长时序数据时展现出优越的性能^[6]。LSTM 模型依靠记忆细胞结构中的遗忘门、输入门及输出门实现记忆功能。遗忘门负责决定哪些信息从单元状态中被保留或遗忘。其工作原理是先接收上一时间步的隐藏层输出和当前时间步的输入,然后通过这些信息计算一个介于 0 到 1 之间的值。具体来说,遗忘门会将这些输入经过一个 sigmoid 函数处理,输出一个对应的“保留概率”,这个概率值决定了上一个时间步的哪些信息会被保留下来。这样通过遗忘门,LSTM 模型可以有效地筛选出对当前任务有用的历史信息,而舍弃那些不再重要的信息。计算公式为:

$$f_t = \sigma(W_f(h_{t-1}, x_t) + b_f) \quad (1)$$

其中: f_t 为遗忘门的输出值; h_{t-1} 为模型 $t-1$ 时刻输出值; x_t 为模型输入值; W_f 为遗忘门的权重矩阵; b_f 为偏置量; σ 为 sigmoid 激活函数。

输入门的功能是控制训练时新增信息的添加,由 sigmoid 函数层和 tanh 函数层共同完成。其中,sigmoid 函数层决定新信息的选择度,而 tanh 函数层则产生一个代表能学习内容的候选记忆单元 $\bar{a}_t$,计算公式为:

$$i_t = \sigma(W_i(h_{t-1}, x_t) + b_i) \quad (2)$$

$$\bar{a}_t = \tanh(W_c(h_{t-1}, x_t) + b_c) \quad (3)$$

其中: i_t 为输入门的输出值; W_i 、 W_c 分别为对应于

sigmoid 函数层和 tanh 函数层权重矩阵; b_i 、 b_c 分别为 sigmoid 函数和 tanh 函数的偏置项,tanh 为双曲正切激活函数。

同时,基于前一时刻的单元状态以及当前时刻的输入信息,单元状态会通过遗忘门和输入门进行相应更新,更新公式为:

$$C_t = f_t C_{t-1} + i_t \bar{a}_t \quad (4)$$

其中, C_t 、 C_{t-1} 分别为单元 t 、 $t-1$ 时刻的状态。

输出门的作用是从当前单元状态中筛选重要的信息以形成新的模型输出值。首先使用 sigmoid 函数来确定当前单元状态应该输出的部分,接着,通过 tanh 函数对该状态进行调整,最终得到新的模型输出值 h_t ,其计算公式为:

$$h_t = O_t \tanh C_t \quad (5)$$

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (6)$$

其中: O_t 为 t 时间步下输出门输出的结果; W_o 为输出门的权重矩阵; b_o 为偏置量。

综上,LSTM 模型当前时刻的模型输出 h_t 和细胞状态 C_t 共同由上一时刻的模型输出 h_{t-1} 、细胞状态 C_{t-1} 与当前时刻的输入 x_t 协同决定。

1.1.2 SABO 算法优化 LSTM 模型

SABO 算法是一种新的元启发式算法^[7]。该算法主要是使用所有搜索代理的算术平均位置,而不是仅仅使用如最佳或最差搜索代理的位置来更新所有搜索代理的位置,其特点是 SABO 算法计算算术平均值的概念是完全独特的,由于其基于特殊运算“ $-_v$ ”,称为搜索代理 B 从搜索代理 A 的 v 减法,其定义为:

$$A -_v B = \text{sign}(F(A) - F(B))(A - v * B) \quad (7)$$

其中: v 为 m 维(m 等于决策变量的数量)向量,其中分量为从集合 $\{1, 2\}$ 生成的随机数;运算符“ $*$ ”表示 2 个向量的 Hadamard 乘积; $F(A)$ 和 $F(B)$ 分别为搜索代理 A 和 B 的目标函数。

在 SABO 算法中,任何搜索代理 X_i 在搜索空间中的位置是通过每个搜索代理 X_j ($j=1, 2, \dots, N$) 的“ $-_v$ ”减法的算术平均值来计算的。因此,计算每个搜索代理的新位置计算公式为:

$$X_i^{\text{new}} = X_i + r_i * \frac{1}{N} \sum_{j=1}^N (X_i -_v X_j), \quad i = 1, 2, \dots, N \quad (8)$$

其中: X_i^{new} 为第 i 个搜索代理 X_i 的新位置; N 为搜索代理的总数; r_i 为 m 维向量,其值位于区间 $[0, 1]$ 。

然后,判断提出的新位置是否提高了目标函数的值,若目标函数值提高了,则相应代理的新位

置是可接受的,其判断式为:

$$\mathbf{X}_i = \begin{cases} \mathbf{X}_i^{\text{new}}, & F_i^{\text{new}} < F_i; \\ \mathbf{X}_i, & \text{其他} \end{cases} \quad (9)$$

其中, F_i 和 F_i^{new} 分别为搜索代理 $\mathbf{X}_i$ 和 $\mathbf{X}_i^{\text{new}}$ 的目标函数值。

$$\mathbf{X} = \begin{bmatrix} \mathbf{X}_1 \\ \vdots \\ \mathbf{X}_i \\ \vdots \\ \mathbf{X}_N \end{bmatrix} = \begin{bmatrix} x_{1,1} & \cdots & x_{1,d} & \cdots & x_{1,m} \\ \vdots & & \vdots & & \vdots \\ x_{i,1} & \cdots & x_{i,d} & \cdots & x_{i,m} \\ \vdots & & \vdots & & \vdots \\ x_{N,1} & \cdots & x_{N,d} & \cdots & x_{N,m} \end{bmatrix} \quad (10)$$

$$x_{i,d} = b_{ld} + r_{i,d}(b_{ud} - b_{ld}), \quad i = 1, \dots, N; d = 1, \dots, m \quad (11)$$

其中: $\mathbf{X}$ 为 SABO 算法种群矩阵; $\mathbf{X}_i$ 为第 i 个搜索代理; $x_{i,d}$ 为其在搜索空间中的第 d 维所在的位置; N 为搜索代理的数量; m 为决策变量的数量; $r_{i,d}$ 为区间 $[0, 1]$ 中的随机数; b_{ld} 和 b_{ud} 分别为第 d 个决策变量的上界和下界。

在 LSTM 网络中,影响其预测精度的关键性指标为初始学习率、神经网络隐藏层个数及正则化参数。因此,本文通过 SABO 算法对 LSTM 模型的 3 个参数进行自动寻优,具体步骤如下。

1) 确定 LSTM 模型网络结构,设定 SABO 算法的搜索代理数量 N 和最大迭代次数 T 。

2) 从搜索空间中,利用式(11)随机生成与搜索代理数量总量相同的初始代理位置,对应网络中待优化参数,采用全局误差作为算法目标函数的评估值。

3) 位置更新,根据目标函数评估值找到搜索代理的最佳位置,并利用式(8)、式(9)更新搜索代理位置。

4) 按照目标函数的评估值对最佳搜索代理位置进行寻找,若达到迭代次数或满足设定最小误差则停止搜索。

5) 将得到的最佳参数组合代入 LSTM 模型中进行建模。

1.2 边坡位移风险状态评估模型建立

D-S 证据理论是 20 世纪 60 年代由美国数学家 Dempster 提出的,后来 Shafer 引入信任函数的概念,对证据理论作出了进一步的研究,形成了基于“证据”和“组合”来处理问题的数学方法^[8]。D-S 证据理论采用 Dempster 合成规则将不同专家或数据源的知识、数据综合起来,可以聚焦相同问题的不同描述和判断中的一致性信息,排除矛盾信息,在信息融合、专家系统、多属性决策等多

个领域得到了广泛应用。D-S 证据理论的基本分析过程如下。

1) 识别框架。在 D-S 证据理论中,识别框架为所有可能发生的假设集合 $\Theta = \{A_1, A_2, \dots, A_n\}$, 其中 Θ 的幂集为 $\Omega = 2^\Theta = \{\emptyset, \{A_1\}, \dots, \{A_n\}, \{A_1, A_2\}, \dots, \Theta\}$, 且所有假设集合之间是可穷尽并相互独立的,共 2^n 个假设集合。

2) 基本概率分配(basic probability assignment, BPA)。 Θ 是识别框架, Θ 的幂集构成命题集合 2^Θ , 基本概率分配函数 m 是一个从集合 2^Θ 到 $[0, 1]$ 的映射, A 表示识别框架 Θ 的任一子集, 记作 $A \subseteq \Theta$, 并满足:

$$\begin{cases} \sum_{A \subseteq \Theta} m(A) = 1, \\ m(\emptyset) = 0 \end{cases} \quad (12)$$

则称函数 $m(A)$ 为 A 的基本概率分配函数,称为 mass 函数,表示对于事件 A 的可信度。式(12)中 2 个式子分别表示所有事件可信度的和为 1, 不可能事件的可信度为 0。

3) 合成规则。D-S 证据理论中多个证据的融合方式为:

$$\begin{cases} m(A) = (m_1 \oplus m_2 \oplus \dots \oplus m_n)(A) = \\ \frac{1}{1-k} \sum_{A_1 \cap A_2 \cap \dots \cap A_n = A} m_1(A_1) \dots m_n(A_n), \\ m(\emptyset) = 0 \end{cases} \quad (13)$$

其中: $A_1, A_2, \dots, A_n$ 为焦元; k 为冲突系数。

$$k = \sum_{A_1 \cap \dots \cap A_n = \emptyset} m_1(A_1) m_2(A_2) \dots m_n(A_n) \quad (14)$$

2 工程实例分析

2.1 工程背景

本文以新疆尼勒克一级水电站工程引水渠道北侧边坡 K6+680 断面为研究对象。根据该断面实际监测情况和监测资料的完整度,以断面 NLK-1 测点和 NLK-2 测点水平方向位移监测数据为基础,建立边坡位移监测模型并对其风险状态进行研究。

2.2 位移监测模型建立及结果分析

本文以上述边坡各测点 2019 年 9 月 1 日到 2020 年 6 月 25 日每天的位移监测数据作为样本。首先,采用函数 premnmx 对样本数据进行归一化处理,函数表达式为:

$$T_k = 2 \times \frac{C_k - C_{\min}}{C_{\max} - C_{\min}} - 1 \quad (15)$$

其中: T_k 为归一化后的样本数据; C_k 为原始样本


数据; $C_{\max}$ 、 $C_{\min}$ 分别为原始样本数据中的最大值和最小值。

利用滑动窗口拆分数据,由于滑动窗口长度较大时,会使预测结果出现滞后效应,而长度较小时,会因训练数据不足导致预测准确性降低^[9],因此本文根据相关研究^[10],对比不同滑动窗口长度下模型拟合值与实测值的均方根误差,结果表明当滑动窗口长度取 15 时,模型拟合效果最好,即将前 15 d 的边坡位移数据作为 LSTM 的输入参数,当天的位移监测数据作为 LSTM 的输出参数,由此形成模型训练样本,然后将其输入到 SABO-LSTM 模型中,建立 SABO-LSTM 边坡位移预测模型。使用均方根误差和平均绝对百分比误差作为模型性能的评价指标^[11-13],计算式分别为:


$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{k=1}^n (Y_k - C_k)^2} \quad (16)$$

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{k=1}^n \left| \frac{Y_k - C_k}{C_k} \right| \times 100\% \quad (17)$$

其中: E_{RMSE} 为均方根误差; E_{MAPE} 为平均绝对百分比误差; n 为样本数量; Y_k 为模型输出值; C_k 为实测值。模型具体的训练结果如图 1 所示。计算可得评价指标见表 1 所列。



(a) NLK-1 测点



(b) NLK-2 测点


图 1 各测点 SABO-LSTM 模型训练结果

由图 1 可知,从整体上看 SABO-LSTM 模型


的训练曲线几乎与实测曲线重合,同时结合表 1 可知,NLK-1 和 NLK-2 两监测点模型的训练误差很小,取得较好的效果。将训练好的模型用于预测后一周的位移量,并与实测值进行对比,得到的结果如图 2 所示,评价指标见表 2 所列。

表 1 SABO-LSTM 模型训练结果分析

测点	$E_{\text{RMSE}}/\text{mm}$	$E_{\text{MAPE}}/\%$
NLK-1	0.29	0.18
NLK-2	0.30	0.26



(a) NLK-1 测点



(b) NLK-2 测点

图 2 各测点 SABO-LSTM 模型预测结果

表 2 SABO-LSTM 模型预测结果分析

测点	$E_{\text{RMSE}}/\text{mm}$	$E_{\text{MAPE}}/\%$
NLK-1	0.38	0.22
NLK-2	0.22	0.16

由图 2 和表 2 可知,模型对两测点后一周位移预测的均方根误差和平均绝对百分比误差均较小,可见 SABO-LSTM 模型取得了优异的预测性能,实现了边坡位移精确预测。

2.3 引水工程边坡位移风险状态评估

本文以新疆某引水工程边坡为例,采用前文提到的 D-S 证据理论,以位移和位移速率为评估指标对边坡位移风险状态进行评估。

2.3.1 框架确定及风险评估指标区间划分

目前边坡风险等级划分没有公认的确定方法,

主要有三级、四级、五级划分方式^[14]。本文采用四级划分法^[15-16],即引水工程边坡位移风险评估的辨识框架包括安全状态等级(I)、跟踪状态等级(II)、报警状态等级(III)、危险状态等级(IV)。

对于位移评估指标由实测数据表征,难以给出统一评判等级划分界限,但随着边坡的位移持续增大,边坡会逐渐失稳。采用置信区间估计方

法以 $\mu + k_i\sigma$ 为评判等级界限进行评判等级的划分^[17],其中: k_i 为参数; μ 和 σ 为监测数据的均值和均方差。同理,得到位移速率指标划分方式。

根据各测点 2018 年 12 月至 2020 年 6 月长期监测数据,计算出各指标的均值 μ 和均方差 σ , 参数 k_i 分别取^[18] $k_1 = 1$ 、 $k_2 = 2$ 、 $k_3 = 3$, 得到各指标划分结果见表 3 所列。

表 3 各指标风险等级基本划分

测点	评价指标	风险等级			
		I	II	III	IV
NLK-1	位移/mm	0~81.36	81.36~131.16	131.16~180.96	180.96~230.76
	位移速率/(mm/d)	0~0.27	0.27~0.55	0.55~0.83	0.83~1.11
NLK-2	位移/mm	0~58.03	58.03~91.14	91.14~124.25	124.25~157.36
	位移速率/(mm/d)	0~0.22	0.22~0.58	0.58~0.94	0.94~1.30

2.3.2 各指标基本概率分配

利用区间数距离计算得到各指标的基本概率分配^[19],区间数距离基本定义如下。

定义 1 设 $A = [a_1, a_2]$ 和 $B = [b_1, b_2]$ 为 2 个区间数,则两者距离的二次方 D^2 为:

$$D^2(A, B) = \left(\frac{a_1 + a_2}{2} - \frac{b_1 + b_2}{2} \right)^2 + \frac{[(a_2 - a_1) + (b_2 - b_1)]^2}{12} \quad (18)$$

定义 2 设 $A = [a_1, a_2]$ 和 $B = [b_1, b_2]$ 为 2 个区间数,则区间 A、B 的相似度 $S(A, B)$ 为:

$$S(A, B) = 1/[1 + \alpha D(A, B)] \quad (19)$$

其中: $\alpha > 0$ 为支持系数; $D(A, B)$ 为区间数 A 与 B 之间的距离。

采用区间求解基本概率分配的步骤为:① 将基本指标的划分结果转化为区间数形式;② 将各指标的监测数据取值转化为区间数形式;③ 根据式(18)计算待测样本与模型区间数的距离;④ 根据式(19)生成相似度;⑤ 对相似度进行归一化处理,得到基本概率赋值。

将 2020 年 6 月 25 日各测点的位移实测值代入到式(18)、式(19)得到各指标各个等级的基本概率分配,见表 4 所列。

表 4 2020 年 6 月 25 日各指标在各状态区间的概率分配

测点	评价指标	风险等级			
		I	II	III	IV
NLK-1	位移	0.078	0.187	0.578	0.157
	位移速率	0.213	0.386	0.247	0.154
NLK-2	位移	0.072	0.157	0.575	0.196
	位移速率	0.243	0.405	0.218	0.134

2.3.3 融合计算结果

从表 4 可以看出,不同指标单独评估时结果有所区别,为得到边坡位移整体评估结果,利用式(13)、式(14)对证据体进行融合,得到边坡位移整体风险评估结果,见表 5 所列。

表 5 边坡位移风险评估结果

风险等级	I	II	III	IV
概率分配	0.012	0.196	0.765	0.027

从表 5 可以看出,基本概率赋值最大为报警状态,按最大属性原则,可以判定该边坡位移的整体风险状态为“报警状态”。

2.4 引水工程边坡位移风险状态预评估

上节将已有的边坡实测数据代入模型进行评估,所得的边坡位移评估结果能确定评估时刻边坡位移风险状态,为实现对边坡位移风险状态预评估,利用本文建立的 SABO-LSTM 位移预测模型获取评估指标未来一段时间内的数据,并代入 D-S 证据风险评估模型中进行评估。

2.3 节建模评估时段截止时间为 2020 年 6 月 25 日,现以往后预测一周的位移为例,将 SABO-LSTM 模型中 2020 年 7 月 2 日的预测信息代入边坡风险评估模型中,进行边坡位移风险状态预评估。因为各指标风险等级划分过程所需的均值和方差由长时期监测序列获得,添加短时段的预测值对均值和方差影响较小,所以各指标的划分可利用前文的划分结果。

根据图 2 所示 SABO-LSTM 模型预测结果,将各测点 2020 年 7 月 2 日位移预测信息代入到

式(18)、式(19),得到各指标各个等级的基本概率分配,见表 6 所列。

表 6 2020 年 7 月 2 日各指标在各状态区间的概率分配

测点	评价指标	风险等级			
		I	II	III	IV
NLK-1	位移	0.075	0.174	0.590	0.161
	位移速率	0.187	0.324	0.309	0.180
NLK-2	位移	0.073	0.157	0.554	0.217
	位移速率	0.223	0.405	0.211	0.131

根据表 6 利用 D-S 证据理论合成规则得到边坡位移风险预评估结果见表 7 所列。

表 7 基于合成规则的边坡位移风险预评估结果

风险等级	I	II	III	IV
概率分配	0.009	0.138	0.821	0.032

由表 5、表 7 可知,根据最大属性原则,该边坡位移历史时刻评估结果与预判时刻评估结果基本一致,处于等级 III,属于“报警状态”。从数值上看,“报警状态”等级数值在增大,表明该边坡位移风险状态有朝着不利方向发展的趋势。从后期监测结果来看,该引水工程边坡的位移仍在继续发展,滑坡风险加大,与评估结果相符合。

3 结 论

本文通过 SABO 算法优化 LSTM 模型中的初始学习率、神经网络隐藏层个数、正则化参数 3 个参数,避免了人工设置参数带来的不确定性,提高了模型精度,并将其用于建立引水工程边坡位移监测模型,实例表明,所构建 SABO-LSTM 监测模型可以很好地反映边坡位移变化规律,且模型计算精度高。同时利用该边坡实测资料,以位移和位移速率为指标,结合 D-S 证据理论建立了边坡位移风险状态评估模型,并根据 SABO-LSTM 模型预测信息实现了边坡位移风险状态预评估,应用表明,该边坡目前处于“报警状态”,且有着朝不利方向发展的趋势,与边坡现场情况相符,表明本文提出的风险评估方法合理可行。

展[J]. 清华大学学报(自然科学版),2023,63(6):849-864.

- [2] 秦文虎,陈溪莹. 基于长短时记忆网络的水质预测模型研究[J]. 安全与环境学报,2020,20(1):328-334.
- [3] 欧斌,吴邦彬,袁杰,等. 基于 LSTM 的混凝土坝变形预测模型[J]. 水利水电科技进展,2022,42(1):21-26.
- [4] 刘丹,吕倩,胡少华,等. 大坝变形 GA-LSTM 组合预测模型研究[J]. 安全与环境学报,2023,23(7):2246-2253.
- [5] Greff K, Srivastava R K, Koutnik J, et al. LSTM: a search space odyssey[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 28(10): 2222-2232.
- [6] Borgia G. Bower destruction and sexual competition in the satin bowerbird (ptilonorhynchus violaceus)[J]. Behavioral Ecology and Sociobiology, 1985, 18(2): 91-100.
- [7] Trojovský P, Dehghani M. Subtraction-average-based optimizer: a new swarm-inspired metaheuristic algorithm for solving optimization problems [J]. Biomimetics, 2023, 8(2): 149.
- [8] Mogaii K A, Lim H S. Application of dempster-Shafer theory of evidence model to geoelectric and hydraulic parameters for groundwater potential zonation[J]. NRIAG Journal of Astronomy and Geophysics, 2018, 7(1): 134-148.
- [9] 张磊,巨能攀,何朝阳,等. 滑坡裂缝时序数据实时异常检测分析[J]. 岩石力学与工程学报, 2024, 43(1): 206-215.
- [10] 熊延. LSTM 模型改进研究及在滑坡垂直位移预测中的应用[D]. 重庆:重庆交通大学, 2023: 39-56.
- [11] 吴俊男. 基于深度学习的滑坡地质灾害预测方法研究[D]. 成都:电子科技大学, 2022: 47-60.
- [12] 董洁. 基于 CEEMDAN-LSTM 的边坡位移预测与失稳特征分析[D]. 长沙:中南大学, 2022: 42-58.
- [13] 易黄智,高飞. 基于 GA-BP 神经网络的地铁变形预测模型[J]. 合肥工业大学学报(自然科学版), 2021, 44(11): 1513-1517.
- [14] 曹晨旭. 通定高速公路湿陷性黄土边坡综合风险研究[D]. 石家庄:石家庄铁道大学, 2023: 47-73.
- [15] 刘旭,黄铭,余舟. 基于区间数理论的引水渠道边坡模糊评判方法研究[J]. 工程与建设, 2023, 37(3): 804-807.
- [16] 李明. 基于安全监测的水库岸坡故障预测与健康评价研究[D]. 合肥:合肥工业大学, 2019: 53.
- [17] 汪涵. 基于实测资料的高填方地基安全评判方法研究[D]. 合肥:合肥工业大学, 2016: 32-40.
- [18] 刘旭. 基于监测资料的引水渠道边坡区间数模糊评判及趋势预测[D]. 合肥:合肥工业大学, 2022: 30-45.
- [19] 康兵义,李娅,邓勇,等. 基于区间数的基本概率指派生成方法及应用[J]. 电子学报, 2012, 40(6): 1092-1096.

(责任编辑 吴 亮)

[参 考 文 献]

- [1] 邓李政,袁宏永,张鸣之,等. 滑坡变形监测预警技术研究进