

DOI:10.16031/j.cnki.issn.1003-8035.2020.03.01

基于改进极限学习机模型的岩质边坡 稳定性评价与参数反演

邓超¹, 胡焕校^{1,2}, 张天乐³, 余童⁴

(1. 中南大学地球科学与信息物理学院, 湖南长沙 410083; 2. 湖南有色资源与地质灾害探查
湖南省重点实验室, 湖南长沙 410083; 3. 中南大学数学与统计学院, 湖南长沙 410083;
4. 长沙理工大学, 湖南长沙 410076)

摘要: 岩质边坡的稳定性评价与参数确定是岩土工程领域的经典难题。基于大数据智能计算的优点, 提出了一种结合变量遗忘因子的正则化在线序列极限学习机模型(FOS-ELM)的岩质边坡稳定性评价和参数确定方法。根据收集的1235例岩质边坡的几何力学与Hoek-Brown模型参数, 应用贝叶斯信息准则(BIC)优选基于岩体强度指标(GSI)、扰动因子(D)、岩石材料常数(m_i)、单轴抗压强度(σ_{ci})、岩体重度(γ)、坡高(H)、坡角(β)的最优输入组合预测边坡稳定安全系数(F), 并建立7个模型对最优输入组合进行评价, 论证模型的预测精度, 结果表明全参数输入组合精度最高, 但输入参数并不是越多越好。同经典的极限学习机模型(ELM)相比, 该模型具有预测精度高、预测速度快、后期增加边坡数据无须重新训练等优点。并采用不同赋值的全参数输入模型(FOS-ELM-M₇)建立边坡参数反演模型, 结果表明该模型对边坡单参数和双参数的反演计算速度快、精度高, 为获取岩体边坡参数提供了一种快捷的新方法。

关键词: 岩质边坡稳定性; Hoek-Brown准则; 极限学习机模型; 贝叶斯信息准则; 稳定安全系数; 参数反演

中图分类号: TU43

文献标识码: A

文章编号: 1003-8035(2020)03-0001-10

Stability evaluation and parameter inversion of rock slope using modified extreme learning machine model

DENG Chao¹, HU Huanxiao^{1,2}, ZHANG Tianle³, YU Tong⁴

(1. School of Geo-sciences and Info-Physics, Central South University, Changsha, Hunan 410083, China;
2. Hunan Key Laboratory of Nonferrous Resources and Geological Hazards Exploration, Changsha, Hunan
410083, China; 3. School of Mathematics and Statistics, Central South University, Changsha, Hunan
410083, China; 4. Changsha University of Science & Technology, Changsha, Hunan 410076, China)

Abstract: The stability evaluation and parameter determination of rock slope are the classical and difficult problem in the field of geotechnical engineering. This study investigates a new regularized online sequential extreme learning machine, incorporated with the variable forgetting factor (FOS-ELM), based on advantages of intelligence computation to predict the factor of safety (F) and invert parameters of rock slopes. The Bayesian information criterion (BIC) is applied to establish seven input combinations based on the parameters of the Hoek-Brown criterion and geometrical and mechanical parameters of the slope, such as the geological strength index (GSI), disturbance factor (D), rock material constant (m_i), uniaxial compressive strength

收稿日期: 2019-07-15; 修订日期: 2020-03-15

基金项目: 中南大学中央高校基本科研业务费专项资金资助(2017zzts178; 2018zzts322)

第一作者: 邓超(1989-), 男, 湖北广水人, 博士研究生, 主要从事岩土边坡稳定性评价及治理方面的研究工作。E-mail: dc8888@csu.edu.cn

通讯作者: 胡焕校(1968-), 男, 博士(后), 教授, 博导, 主要从事岩土工程方面的教学与研究工作。E-mail: 2124571883@qq.com

(σ_{ci}), unit weight of the rock mass (γ), slope height (H) and slope angle (β). Seven models are established and evaluated to determine the optimal input combination. Various statistical indicators were calculated for the prediction accuracy examination. Compared to the classical extreme learning machine (ELM) model predictions of F , the results of the applied FOS-ELM model demonstrate a better prediction accuracy and are more effective when accounting for an increase in data. The FOS-ELM model with all seven input parameters (FOS-ELM- M_7) is used to establish inversion model, the results show that the inversion calculation of one or two slope parameters is fast and accurate, which provides a new method for obtaining rock slope parameters.

Keywords: rock slope stability; Hoek-Brown criterion; FOS-ELM; Bayesian information criterion; safety factor; parameter inversion

0 引言

滑坡是边坡物质与能量释放的一种动力学形式。滑坡每年导致的生命财产损失高于泥石流、洪水、风暴等自然灾害,且超出我们的普遍认知^[1-2]。世界范围内经报道的巨大滑坡主要集中在发展中国家。在发展中国家,滑坡导致的损失约是国民生产总值的0.5%^[3]。我国山岭坡地众多,地质环境复杂,滑坡已成为我国严重的地质灾害之一。根据中国地质调查局官网信息,每年可预测的滑坡占滑坡总量不足20%,因此迫切需要一种简单、快捷、可靠、低成本的方法来判断边坡的稳定性。岩质边坡滑坡能量更巨大,破坏性更强,因此岩质边坡稳定性评价成为专家学者们共同关注的焦点之一^[4-6]。

鉴于线性的 Mohr-Coulomb (M-C) 准则不能准确的反映岩体破坏的非线性特性^[7],因此广义的非线性 Hoek-Brown (H-B) 经验准则在岩质边坡稳定性分析中广泛应用^[8]。但在工程实践中,岩质边坡稳定性分析还存在许多问题,如现有的适用于岩质边坡稳定性分析的软件一般基于 M-C 准则而不够准确、快捷^[9]。HOEK E 等^[10-11]为使 H-B 准则适用于各种岩土工程软件,对非线性 H-B 准则进行修正,求解岩体的等效黏聚力和摩擦角,虽可采用 M-C 准则对边坡稳定性进行分析,但转换过程稍显复杂。因此,本文采用 H-B 准则参数作为岩质边坡稳定性分析的参量。

大数据智能计算技术以其高效、快速的自主学习和准确的预测能力等优点得到飞速发展,并在各个领域广泛应用^[12]。世界上每年都有大量的边坡需要进行稳定性评价及滑坡防治,这些工程和研究实例提供了大量有价值的经验数据和研究数据。因此,许多专家学者利用这些有价值的信息,基于智能计算技术,对边坡稳定性进行评价和预测^[13-15]并反演未知的边坡

参数^[16],以提高边坡稳定性评价的精确性和效率。一般以反映边坡综合性状的安全系数(F)来作为边坡稳定性评价的重要指标。智能计算模型依赖于获取的一系列反映边坡综合性状的参数,并以边坡参数作为输入变量,以安全系数 F 作为输出变量。LI 等^[16]和 DENG 等^[17]的研究表明基于极限学习机模型(ELM)的智能计算对边坡变形和稳定性分析具有明显的优势。本文基于 ELM 模型结合变量遗忘因子(FOS),提出一种正则化的在线序列极值学习机模型(FOS-ELM),应用贝叶斯信息准则(BIC)优选 H-B 准则参数及边坡几何力学参数来预测边坡稳定安全系数(F)的最优输入组合,对岩质边坡稳定性进行评价和预测。FOS-ELM 算法无须预设控制变量,对优化问题的影响很小,且随着边坡输入数据的增加无需重新训练,具有更好的泛化能力,避免了异常点和过度拟合问题,克服了其他智能计算模型的缺点。对比分析了 ELM 与 FOS-ELM 模型预测岩质边坡稳定性的精确性,论证了输入变量 7 因素 BIC 最优组合的科学性,为大数据智能计算在岩质边坡稳定性评价中的应用提供了一种新方法。鉴于岩土勘察仅能获得有限的试验数据,具有费用高、周期长^[18],测量不确定性、转换模型不确定性^[19]等缺点,且难以真实反映岩体参数的空间变异性^[20],采用不同赋值的全参数输入模型(FOS-ELM- M_7)作为边坡参数反演计算模型,对岩质边坡的参数进行反演计算,为岩质边坡的参数快速估计提供了一种新的方法。

1 模型设计

1.1 确定变量

控制岩质边坡稳定性的主要因素是岩体中具有不同力学性质和规模的结构面。HOEK 等^[8]提出了最新版本的节理岩体强度的广义经验准则,可表示为:

$$\sigma_1 = \sigma_3 + \sigma_{ci} \left(m_b \frac{\sigma_3}{\sigma_{ci}} + s \right)^a \quad (1)$$

式中: σ_1 、 σ_3 ——分别表示为岩石破坏过程中的最大、最小主应力;

σ_{ci} ——岩石单轴抗压强度;

m_b 、 s 和 a ——岩体材料常数;

m_b 和 s ——岩体的经验参数;

s ——用于量化岩体的破碎程度指标。

m_b 、 s 和 a 可由下式得到:

$$m_b = m_i \exp[(GSI - 100)/(28 - 14D)] \quad (2)$$

$$s = \exp[(GSI - 100)/(9 - 3D)] \quad (3)$$

$$\alpha = 1/2 + 1/6(e^{-GSI/15} - e^{-20/3}) \quad (4)$$

m_b 、 s 的值取决于地质强度指标 (GSI) 与岩体扰动因子 (D), a 的值仅取决于 GSI 。 GSI 的值 ($10 \leq GSI \leq 100$) 采用节理化岩体强度与力学参数估计的地质强度指标 GSI 法确定; D 值大小取决于工程经验 ($0 \leq D \leq 1$), 原状未扰动岩体 $D = 0$, 扰动岩体 $D = 1$; m_i ($1 \leq m_i \leq 35$) 是一个与岩石类型有关的材料常数, 可通过岩石三轴试验拟合得到, 也可以根据岩石类型确定。

如前所述, H-B 准则具有非线性特征, 能较好地反映节理岩体的强度特性, 但其应用也具有一定的局限性^[21-22]。基于 GSI 指标的 H-B 准则适用于图 1 中 I 组和 III 组的岩体, 即完整岩体和节理组数不少于 3 的岩体^[9]。文中搜集的 1 235 例岩质边坡均为重节理岩体, 属第三类。




图 1 H-B 准则的适用性

Fig. 1 Applicability of the Hoek-Brown criterion

考虑反映岩体特性的 H-B 准则参数与边坡的坡高 (H)、坡角 (β)、岩体重度 (γ) 等对边坡稳定性的影响, 故本文采用 GSI 、 m_i 、 D 、 σ_{ci} 、 γ 、 H 、 β 作为输入变量, 以边坡安全系数 F 作为输出变量。LI 等^[16]对基于 H-B 准则的 Bishop 方法与上、下限分析法计算的岩体边

坡的安全系数进行比较, 表明基于 H-B 准则的 SLIDE 软件的解更接近边坡稳定的真实解。因此, 以基于 H-B 准则的 Bishop 法的 GEOSLOPE 软件求解的边坡稳定安全系数作为真值。

1.2 变量选择

对于边坡稳定性预测, 变量选择是关键。已有研究表明, 选择相关性小的变量将导致预测精度显著降低。若选择无关或影响效应低的输入变量, 不仅影响输入变量间的相互关系, 而且可能增加地质勘察工作的工作量。在地质调查中, 若部分边坡参数难以获得, 可利用仅有的参数对边坡稳定性进行初步预测。因此, 对变量进行优化, 确定其相关性和预测误差具有重要的现实意义。

BIC^[23]是在主观概率估计的基础上, 利用贝叶斯公式对概率进行修正, 最后利用期望值和修正概率做出最优决策选择后验概率最大的模型。即以 BIC 值最小化的变量子集为最优, 因此, BIC 可用于优化边坡输入变量组合, 确定不同组合下的误差, 从而对边坡稳定性做出可靠的预测。BIC 的值可表示为:

$$BIC = -2\ln L + k\log n \quad (5)$$

式中: L ——估计模型似然函数的最大值;

k ——模型中估计参数的个数;

n ——样本量。

1.3 模型建立

ELM 模型是 2006 年提出的基于随机权重配置的单隐层模型, 后将 ELM 模型推广到广义单层前馈网络 (SLFNs) 中, 其中隐含层神经元不必相同^[24]。ELM 模型的单隐层前馈神经网络如图 2 所示。




图 2 ELM 模型的单隐层前馈神经网络图

Fig. 2 The network of classical ELM

给定一个包含 N 个不同样本的训练集, $\Gamma = \{(x_j, t_j) | x_j \in R^n, t_j \in R^m, j = 1, \dots, N\}$, 其中 x 为 n 维的输入变量, t 为 m 维的目标变量。具有 M 个隐藏神经元 SLFN 的数学模型的激励函数 $G(\cdot)$ 可表示为:

$$\sum_{i=1}^n \beta_i G(w_i, b_i, x_j), j = 1, 2, \dots, N \quad (6)$$

式中: w_i ——连接第 i 个隐藏节点和输出节点的随机分配的输入权向量;

b_i ——第 i 个隐藏节点的任意分配偏差;

$G(w_i, b_i, x_j)$ —— x_j 输入样本的第 i 个隐藏节点的输出结果,其作用是将输入层的数据由其原本的空间映射到 ELM 的特征空间。

当 SLFN 模型完全逼近样本数据,即当输出值与真值之间的误差为零,之间对应关系可表示为:

$$\sum_{i=1}^n \beta_i G(w_i, b_i, x_j) = t_j, j = 1, 2, \dots, N \quad (7)$$

式(7)可写成矩阵式:

$$H\beta = T \quad (8)$$

其中,

$$H = \begin{bmatrix} h_1^T & h_2^T & \cdots & h_N^T \end{bmatrix} = \begin{bmatrix} G(w_1, b_1, x_1) & \cdots & G(w_n, b_n, x_1) \\ \vdots & \ddots & \vdots \\ G(w_1, b_1, x_N) & \cdots & G(w_n, b_n, x_N) \end{bmatrix}_{N \times n} \quad (9)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \beta_2^T \\ \vdots \\ \beta_N^T \end{bmatrix}_{n \times m} \quad T = \begin{bmatrix} t_1^T \\ t_2^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m} \quad (10)$$

输出权值可利用式(8)通过寻找 SLFNs 最小二乘解得到,其表达式为:

$$\beta = H^+ T \quad (11)$$

其中 H^+ 为矩阵 H 的 Moore-Penrose 广义逆,若 $H^T H$ 为非奇异矩阵,那么式(11)可表示为:

$$\beta = H^+ T = (H^T H)^{-1} H^T T \quad (12)$$

ELM 算法的核心是求解输出权重使得误差函数最小,因此我们在 ELM 的 loss 函数中引入 $l-2$ 正则化约束提高模型的泛化能力和稳定性。式(12)可转化为:

$$\beta = \begin{cases} H^T \left(\frac{I}{C} + H^T H \right)^{-1} T & N \leq L \\ \left(\frac{I}{C} + H^T H \right)^{-1} H^T T & N > L \end{cases} \quad (13)$$

式中: C ——正则化系数;

I ——单位矩阵;

N ——样本个数;

L ——隐层神经元个数。

但传统的人工智能算法,如人工神经网络、支持向量机、极限学习模型等,在获取大量边坡新数据时,需

要同时收集新旧数据进行重新训练^[25]。因此,传统的人工智能算法很难解决大数据、非平稳、数变、时变等预测问题。为了有效地解决数据流的非平稳和数变问题,开发了在线顺序极值学习机模型(OS-ELM)。OS-ELM 的学习包括一个初始的 ELM 批量学习过程和一个连续的逐块学习过程。但当学习过程中隐含层输出矩阵的自相关矩阵是奇异的或病态的,OS-ELM 的泛化能力急剧退化。BOU-RABEE^[26]为克服 OS-ELM 的这一缺点将 Tikhonov 正则化与 OS-ELM 相结合,提出了一种正则化的 OS-ELM,以提高算法的稳定性和泛化能力。为解决样本增加在线学习过程中的时变性和量变性问题,故将遗忘因子(Forgetting Factor)^[27]引入到 OS-ELM 当中。R-ELM-FF 算法在理论等价于最小化下列基于 FF 和 $l-2$ 正则化的最小二乘误差函数:

$$J_{FR}(\beta_k) = \sum_{i=1}^k \lambda^{k-i} |t_i - h_i \beta_k|^2 + \delta \lambda^k \|\beta_k\|^2 \quad (14)$$

式中: λ ——新旧样本权重的 FF 参数;

δ ——提高算法稳定性和泛化能力的正则化参数。

基于递推计算式^[28],采用递推最小二乘法求解式(14), β_k 可推导为:

$$P_k = \frac{P_{k-1}}{\lambda} - \frac{P_{k-1} h_k^T h_k P_{k-1}}{\lambda(\lambda + h_k P_{k-1} h_k^T)} \quad (15)$$

$$\beta_k = \beta_{k-1} + P_k h_k^T (t_k - h_k \beta_{k-1})$$

然而,随着 k 的增加, $\delta \lambda^k \|\beta_k\|^2$ 呈指数递减趋于零,将导致正则化函数逐渐失效。因此,在 FOS-ELM 代价函数中引入一个新的常系数正则化项 $\delta \|\beta_k\|^2$ 代替指数正则化项 $\delta \lambda^k \|\beta_k\|^2$,其代价函数表示为:

$$J_{FR}(\beta_k) = \sum_{i=1}^k \lambda^{k-i} |t_i - h_i \beta_k|^2 + \delta \|\beta_k\|^2 \quad (16)$$

FOS-ELM 的运行如下:

设数据样本为数据流的形式,激励函数为 $G(w, b, x)$,隐藏神经元数为 n ,正则化参数为 δ ,遗忘因子为 λ 。

步骤 1:初始化。

给定初始训练子集 $\Omega_{k-1} = \{(x_j, t_j) | x_j \in R^n, |t_j \in R^m, j = 1, \dots, k-1\}$,执行下述操作:

(1) 随机生成隐藏层神经元参数 $(w_i, b_i), i = 1, 2, \dots, n$;

(2) 采用式(9)计算隐藏层输出矩阵 $H_{k-1} = [h_1^T \ h_2^T \ \cdots \ h_{k-1}^T]^T$;

(3) 计算初始输出权重矩阵 $\beta_{k-1} = P_{k-1} H_{k-1}^T T_{k-1}$; 其中, $P_{k-1} = (H_{k-1}^T H_{k-1} + \lambda I)^{-1}$, $T_{k-1} = [t_1 \ t_2 \ \cdots$

$t_{k-1}]^T$ 。

步骤2:在线学习与预测。

对新样本 (x_k, t_k) 执行以下操作:

- (1) 计算新样本输入 x_k : $h_k = [G(a_1, b_1, x_k) \cdots G(a_n, b_n, x_k)]$ 的隐含层输出向量;
- (2) 计算网络输出, 即 $t_k: \hat{t}_k = h_k \beta_{k-1}$ 的预测值;
- (3) 根据真值 t_k 调整输出权重。

$$P_k^* = \frac{1}{\lambda} P_{k-1} - \frac{\delta(1-\lambda)}{\lambda^2} P_{k-1} \left(I - \frac{\delta(1-\lambda)}{\lambda} P_{k-1} \right) P_{k-1}$$

$$P_k = P_k^* - \frac{P_k^* h_k^T h_k P_k^*}{1 + h_k P_k^* h_k^T}$$

$$\beta_k = \beta_{k-1} + P_k h_k^T (t_k - h_k \beta_{k-1}) - \delta(1-\lambda) P_k \beta_{k-1}$$

(4) 返回步骤2。

1.4 结果评估

采用多种统计指标对 FOS-ELM 模型和经典的 ELM 模型在岩质边坡稳定性安全系数 F 预测结果进行评估, 如式(17-19)所示。

(1) 相关系数(r)可表示为:

$$r = \left(\frac{\sum_{k=1}^n (F_{re} - \bar{F}_{re})(F_{pr} - \bar{F}_{pr})}{\sqrt{\sum_{k=1}^n (F_{re} - \bar{F}_{re})^2} \sqrt{\sum_{k=1}^n (F_{pr} - \bar{F}_{pr})^2}} \right) \quad (17)$$

(2) 均方根误差(RMSE)表示为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (F_{pr} - F_{re})^2} \quad (18)$$

(3) 平均绝对误差(MAE)表示为:

$$MAE = \frac{1}{n} \sum_{k=1}^n |(F_{pr} - F_{re})| \quad (19)$$

式中: F_{pr} 、 F_{re} ——分别表示岩质边坡稳定性安全系数预测值与真值;

$\bar{F}_{pr}$ 、 $\bar{F}_{re}$ ——表示相应均值, n 表示测试数据的数量。

1.5 预测过程

FOS-ELM 模型最优输入组合($GSI, m_i, \sigma_{ci}, D, \gamma, \beta, H$)的岩质边坡稳定安全系数 F 的预测及参数反演过程(图3)。




图3 FOS-ELM 模型预测 F 及参数反演过程示意

Fig. 3 Process diagram of the FOS-ELM model for predicting F and parameter inversion

2 测试结果与分析

如1.1所述,选用岩质边坡的 $GSI, m_i, \sigma_{ci}, D, \gamma, H$ 和 β 作为 FOS-ELM 模型的输入变量,安全系数作为输出变量(F_{pr})。因此,该模型选择7个输入量和1个输出量。从样本中随机抽取1085组数据作为训练集,其余150组数据作为验证集。利用 BIC 值进行变量组合优选,生成输入参数的最佳组合,建立了7种最优组合模型。在 Geo-slope 软件中基于 H-B 准则的极限平衡法计算真值(F_{re})。利用预测值(F_{pr})与真值(F_{re}) 在验证阶段的统计指标与误差分布对比分析 FOS-ELM 模型与经典的 ELM 模型。

2.1 BIC 值最优模型结果与分析

在 Matlab 中计算所有输入变量组合的 BIC 值,其

中 BIC 值最小的变量组合为最优。针对不同数量的输入变量,在最优输入组合的基础上建立了7种不同的模型($M_1, M_2, M_3, M_4, M_5, M_6, M_7$),包括所有输入变量的模型。基于 FOS-ELM 与经典 ELM 的7种模型对岩质边坡稳定性安全系数预测值(F_{pr})与真值(F_{re})线性关系如图4所示。

若预测值 F_{pr} 和真值 F_{re} 的相关关系可用线性方程 $y = kx$ 拟合,且指数系数 r^2 和斜率 k 接近1,说明该模型的预测性能好,拟合效果优。因此,本文在 Origin 软件中利用 $y = kx$ 的线性拟合 F_{pr} 和 F_{re} 。图4通过散点图分别显示了不同优选输入组合下的 FOS-ELM 与 ELM 模型的 F_{re} 和 F_{pr} 的拟合结果。所有参数作为最优输入组合的模型 M_7 , 图4(g)中指数系数 r^2 和斜率 k (FOS-ELM: $r^2 = 0.9913, k = 1.0059$; ELM: $r^2 = 0.9673$,




图4 基于FOS-ELM与ELM的7种输入组合模型对岩质边坡稳定性安全系数预测值(F_{pr})与真值(F_{re})关系

Fig. 4 The relationship between predicted F_{pr} and F_{re} of rock slope stability by seven models, FOS-ELM vs. ELM

$k = 1.0132$) 表明 FOS-ELM 模型的预测效果优于经典的 ELM 模型。同样,以六参数(GSI , σ_{ci} , m_i , D , H , β)最优输入组合的模型 M_6 , FOS-ELM 与 ELM 模型的指数系数 r^2 (FOS-ELM: $r^2 = 0.9045$; ELM: $r^2 = 0.7068$) 和斜率 k (FOS-ELM: $k = 0.9909$; ELM: $k = 0.9811$) 表明本文建立的 FOS-ELM 模型预测效果优于 ELM 模型。类似地,最优输入组合 M_5 , M_4 , M_3 , M_2 , M_1 模型的预测结果亦同上。对比图 4 (a) ~ (g) 表明基于 FOS-ELM 模型 M_7 预测效果最优,精度最高。同时,基于 FOS-ELM 模型的 M_5 预测效果仅次于 M_7 , 表明输入参量的个数对预测效果的优劣产生影响,即采用 FOS-ELM 模型进行岩质边坡稳定性安全系数预测时并不是确定的输入参量越多预测效果更优。

基于大数据智能计算预测是未来应用的方向之一,但 LI A J^[16] 等的研究表明 ELM 模型训练岩质边坡参量并预测稳定数 N_t , 这一过程需耗时数小时。同时,智能计算需要大量的数据以提高模型预测能力,工程实践的开展使得岩质边坡工程数据不断增加,新数据组增加的同时计算工作量也将增加,且须重新训练,这将大大降低预测工作的效率。而基于 FOS-ELM 模型的无需重新训练这一优点,将一定程度上提高预测效率(图 5),训练数据组增加到 500 时 FOS-ELM 的训练效果。因此,ELM 模型的预测效率较 FOS-ELM 模型低,且图 4 表明 FOS-ELM 预测精度较高,图 6 验证结果亦表明 FOS-ELM 的预测精度高这一优点。




图5 数据增加至 500 时 FOS-ELM 模型的训练效果

Fig. 5 Train performance using FOS-ELM model with data increased to 500

为进一步分析 FOS-ELM 模型预测的精确性,计算了训练数据从 500 增加至 1 085 组时的相关系数(r)、均方误差($RSME$)、平均绝对误差(MAE),与每个输入组合的 ELM 模型比较(表 1)。显然,训练集增加至 1 085 时七参量最优输入组合的 FOS-ELM 模型具有最




图6 ELM 与 FOS-ELM 模型 150 组数据验证效果
(训练数据增加至 500)

Fig. 6 Performance of 500 data trained by ELM and FOS-ELM with 150-validation data set

大的相关系数 (FOS-ELM: $r = 0.994$; ELM: $r = 0.987$), 最小的均方误差 (FOS-ELM: $RSME = 0.069$; ELM: $RSME = 0.100$) 和平均绝对误差 (FOS-ELM: $MAE = 0.060$; ELM: $MAE = 0.090$)。此外,训练集为 500 或 1 085 时,不同输入参量最优组合(M_1 , M_2 , M_3 , M_4 , M_5 , M_6)的 FOS-ELM 较 ELM 模型具有更大的相关系数(r),较小的均方误差($RSME$)和平均绝对误差(MAE) (数据集增加至 1 085 时 M_2 除外)。前述表明,提出的 FOS-ELM 模型是一种较经典的 ELM 模型更优的岩质边坡稳定性安全系数预测的智能工具。

2.2 参数反演

边坡参数反演法克服了室内实验与现场试验的缺点^[20],是获得岩土体参数的一种有效方法。2.1 节表明全参数最优输入的 FOS-ELM- M_7 模型具有较好的工作性能,因此基于该模型建立参数反演计算过程(图 3)。

针对工程实践中难以客观量化的地质强度指标 GSI 、边坡扰动因子 D 、材料常数 m_i 的反演结果分析反演模型的计算精度。在 Matlab 中实现该计算过程得到岩质边坡单未知参数、双未知参数、三未知参数。反演结果与文献^[16,29-30]工程例对比结果见表 2。为进一

步分析参数反演精度,分别对比反演结果与工程例参数(图7~图9)。

表1 七组输入组合模型下的边坡参量变化影响(三统计指标作为评价依据)

Table 1 The seven input combination models were constructed based on the variability influence of each slope parameter (Several statistical metrics are computed as determination factors)

模型	输入组合	数集增加至 500						数集增加至 1 085					
		FOS-ELM			ELM			FOS-ELM			ELM		
		RMSE	MAE	r	RMSE	MAE	r	RMSE	MAE	r	RMSE	MAE	r
M ₁	GSI	2.186	1.332	0.584	2.352	1.343	0.477	1.743	0.200	0.778	1.792	0.209	0.771
M ₂	GSI + σ_{ci}	0.899	0.264	0.643	0.924	0.293	0.622	0.471	0.178	0.843	0.399	0.213	0.767
M ₃	GSI + σ_{ci} + m_i	0.563	0.222	0.776	0.674	0.245	0.715	0.332	0.173	0.861	0.374	0.196	0.813
M ₄	GSI + σ_{ci} + m_i + D	0.421	0.203	0.804	0.436	0.217	0.787	0.330	0.163	0.866	0.349	0.169	0.827
M ₅	GSI + σ_{ci} + m_i + D + H	0.226	0.178	0.842	0.351	0.196	0.813	0.171	0.085	0.969	0.313	0.173	0.878
M ₆	GSI + σ_{ci} + m_i + D + H + β	0.251	0.144	0.855	0.291	0.173	0.833	0.181	0.093	0.957	0.291	0.158	0.884
M ₇	全部	0.109	0.109	0.929	0.134	0.111	0.906	0.069	0.060	0.994	0.100	0.090	0.987

注:加粗行代表最优输入组合。

表2 工程例参数(GSI、 m_i 、D)反演结果

Table 2 The inversion results of engineering case parameters (GSI、 m_i 、D)

工程例	编号-边坡类型	σ_{ci} / MPa	β / (°)	H/ m	γ / (kN·m ⁻³)	F	GSI	m_i	D	反演单参数			反演双参数			反演三参数		
										GSI	m_i	D	GSI	m_i	D	GSI	m_i	D
[16]	1-粉砂岩	23	48	157	27	5.41	65	7	0.7	66	6.5	0.7	63	8		45	20	0
	2-粉砂岩	25	48	110	27	1.74	40	7	0.7	39	5	0.7	39	6		38	10	1.0
	3-粉砂岩	23	48	157	27	3.75	65	7	1	63	6	0.95	66		1.0	50	15	0.7
	4-粉砂岩	25	48	110	27	0.80	40	7	1	40	6	0.90	37	10.0		41	8	0.7
[29]	5-片岩	5.2	36	14.2	22.2	0.86	21	9.5	0	21	10	0.00	23		0.3	30	5	0.7
[30]	6-片岩	5.2	34	20	22.2	0.97	16	7	0.7	15	8	0.80		7.5	0.7	21	8	1.0
	7-泥灰岩	40	60	80	21	1.14	37	9	1	38	10	1.00		10.0	1.0	34	12	1.0

注:单参数反演时,即该反演参数未知,其他为已知参量;双参数反演时,即该反演双参数未知,其他为已知参量;三参数反演时,即反演三参数未知,其他为已知参量。




图7 GSI反演结果

Fig. 7 The inversion results of GSI

由图7~9知,该模型对1~2个未知参数反演计算与工程例参数接近,反演精度较高。其中单参数和双参数GSI反演的偏差绝对值分别为0%~6.5%、1.5%~9.5%,反演精度最高。单参数 m_i 反演偏差绝对值为0%~28.5%,单参数D反演偏差绝对值为0%~14.3%,由于 m_i 在取值是通过地质工程师根据岩石种类半经验主观确定参数,同时D值




图8 m_i 反演结果

Fig. 8 The inversion results of m_i

取值根据H-B准则经验取值均为0、0.7、1.0,故在FOS-ELM训练数据中同类岩体 m_i 取值幅度较小及D值取值相对固定,这就导致模型的学习效果欠佳,对于 m_i 、D的个别反演结果偏差分别达28.5%和14.3%。由于模型训练数据有限,三参数的反演计算结果偏差较大。




图9 D反演结果

Fig. 9 The inversion results of D

3 结论

本文拓展了大数据智能计算在岩质稳定性预测及参数反演中的应用,提出了一种结合 ELM 模型的变量遗忘因子正则化在线序列极值学习机模型(FOS-ELM),并将其应用于岩质边坡稳定性预测和边坡参数的反演。主要结论如下:

(1)采用7变量组合,边坡安全系数的预测精度最高,但预测精度并不随输入变量个数增加成正比。

(2)与经典的 ELM 模型比较,FOS-ELM 模型具有高效和精确的优点。

(3)FOS-ELM 模型试图更新网络的输出权值,并随着数据的增加对网络模型进行自“修正”,以达到更高的预测精度,为处理数据增长问题提供了一种新的方法。

(4)基于 FOS-ELM 模型的参数反演,1~2个未知参数反演精度较高,其中 GSI 反演精度最高,反演偏差绝对值分别为 0%~6.5%、1.5%~9.5%。

参考文献:

- [1] GUZZETTI F, CARRARA A, CARDINALI M, et al. Landslide hazard evaluation: a review of current techniques and their application in a multi-scale study, Central Italy[J]. Geomorphology, 1999, 31 (1/2/3/4): 181-216.
- [2] 黄润秋. 20世纪以来中国的大型滑坡及其发生机制[J]. 岩石力学与工程学报, 2007, 26(3): 433-454. [HUANG R Q. Large-scale landslides and their sliding mechanisms in China since the 20th century[J]. Chinese Journal of Rock Mechanics and Engineering, 2007, 26(3): 433-454. (in Chinese)]

- [3] CHUNG C J F, FABBRI A G. Validation of spatial prediction models for landslide hazard mapping[J]. Natural Hazards, 2003, 30(3): 451-472.
- [4] 司马丹琪, 李元松, 姜成潼, 等. 西部“三高”地区高速公路边坡稳定性系数与失稳概率关系探讨[J]. 中国地质灾害与防治学报, 2018, 29(5): 32-37. [SIMA D Q, LI Y S, JIANG C T, et al. Relationship between highway slope's factor of safety and its failure probability in "Three High" Region of Western China[J]. The Chinese Journal of Geological Hazard and Control, 2018, 29(5): 32-37. (in Chinese)]
- [5] 周子涵, 陈忠辉, 张凌凡, 等. 基于能量原理的露天矿边坡开挖稳定性突变研究[J]. 岩土力学, 2019, 40(12): 4881-4889. [ZHOU Z H, CHEN Z H, ZHANG L F, et al. Catastrophe study of the stability of open-pit slope excavation based on energy principle[J]. Rock and Soil Mechanics, 2019, 40(12): 4881-4889. (in Chinese)]
- [6] JOHARI A, MEHRABANI LARI A. System probabilistic model of rock slope stability considering correlated failure modes [J]. Computers and Geotechnics, 2017, 81: 26-38.
- [7] EBERHARDT, E. The Hoek-Brown failure criterion [J]. Rock Mechanics and Rock Engineering, 2012, 45(6): 981-988.
- [8] HOEK E, BROWN ET. The Hoek-Brown failure criterion and GSI-2018 edition [J]. Journal of Rock Mechanics and Geotechnical Engineering, 2019, 11(3): 445-463.
- [9] A J LI, MERIFIELD R S, LYAMIN A V. Stability charts for rock slopes based on the Hoek-Brown failure criterion[J]. International Journal of Rock Mechanics & Mining Sciences, 2008, 45(5): 689-700.
- [10] HOEK E, CARRANZA-TOMES C, CORKUM B. Hoek-Brown Failure criterion - 2002 edition. In: Proceedings of the North American Rock Mechanics Symposium Toronto, 2002.
- [11] CLAUSEN J, DAMKILDE L. An exact implementation of the hoek - brown criterion for elasto-plastic finite element calculations [J]. International Journal of Rock Mechanics and Mining Sciences, 2008, 45(6): 831-847.
- [12] HOU M Z, ZHANG T L, WENG F T, et al. Global solar radiation prediction using hybrid online sequential extreme learning machine model [J]. Energies, 2018, 11(12): 3415.

- [13] ERZIN Y, CETIN T. The prediction of the critical factor of safety of homogeneous finite slopes using neural networks and multiple regressions [J]. Computers & Geosciences, 2013, 51: 305–313.
- [14] LIU Z B, SHAO J F, XU W Y, et al. An extreme learning machine approach for slope stability evaluation and prediction [J]. Natural Hazards, 2014, 73(2): 787–804.
- [15] 徐哲, 胡焕校, 邓超. K-means 聚类神经网络在边坡稳定性评价中的应用探究[J]. 水资源与水工程学报, 2017, 28(3): 198–204. [XU Z, HU H X, DENG C. Study on the application of K-means clustering algorithm and neural network in slope stability evaluation [J]. Journal of Water Resources and Water Engineering, 2017, 28(3): 198–204. (in Chinese)]
- [16] LI A J, KHOO S, LYAMIN A V, et al. Rock slope stability analyses using extreme learning neural network and terminal steepest descent algorithm [J]. Automation in Construction, 2016, 65: 42–50.
- [17] DENG J H, LEE C F. Displacement back analysis for a steep slope at the Three Gorges Project site [J]. International Journal of Rock Mechanics and Mining Sciences, 2001, 38(2): 259–268.
- [18] 吴松, 魏作安, 杨永浩. 基于 Hoek-Brown 准则的岩体力学参数估算及其工程应用[J]. 中国地质灾害与防治学报, 2019, 30(1): 119–125. [WU S, WEI Z A, YANG Y H. Estimation of mechanical parameters of rock mass by Hoek-Brown criterion and its engineering application [J]. The Chinese Journal of Geological Hazard and Control, 2019, 30(1): 119–125. (in Chinese)]
- [19] 蒋水华, 魏博文, 张文举, 等. 基于多源试验数据空间变异土体参数概率反演及边坡可靠度更新[J]. 岩土力学, 2018, 39(4): 1491–1499. [JIANG S H, WEI B W, ZHANG W J, et al. Probabilistic back analysis of spatially varying soil properties and reliability updating of slopes with multiple sources of test data [J]. Rock and Soil Mechanics, 2018, 39(4): 1491–1499. (in Chinese)]
- [20] 邓东平, 李亮. 极限平衡理论下边坡强度参数反演及加固稳定性分析[J]. 工程地质学报, 2016, 24(1): 10–18. [DENG D P, LI L. Inversion of strength parameters and stability analysis of reinforced slope with limit equilibrium theory [J]. Journal of Engineering Geology, 2016, 24(1): 10–18. (in Chinese)]
- [21] SONMEZ H, ULUSAY R. Modifications to the geological strength index (GSI) and their applicability to stability of slopes [J]. International Journal of Rock Mechanics and Mining Sciences, 1999, 36(6): 743–760.
- [22] MARINOS V, MARINOS P, HOEK E. The geological strength index: applications and limitations [J]. Bulletin of Engineering Geology and the Environment, 2005, 64(1): 55–65.
- [23] SCHWARZ G. Estimating the dimension of a model [J]. The Annals of Statistics, 1978, 6(2): 461–464.
- [24] HUANG F M, HUANG J S, JIANG S H, et al. Landslide displacement prediction based on multivariate chaotic model and extreme learning machine [J]. Engineering Geology, 2017, 218: 173–186.
- [25] CRISOSTO C, HOFMANN M, MUBARAK R, et al. One-hour prediction of the global solar irradiance from all-sky images using artificial neural networks [J]. Energies, 2018, 11(11): 2906.
- [26] BOU-RABEE M, SULAIMAN S A, SALEH M S, et al. Using artificial neural networks to estimate solar radiation in Kuwait [J]. Renewable and Sustainable Energy Reviews, 2017, 72: 434–438.
- [27] PALEOLOGU C, BENESTY J, CIOCHINA S. A robust variable forgetting factor recursive least-squares algorithm for system identification [J]. IEEE Signal Processing Letters, 2008, 15: 597–600.
- [28] KUMAR M, RAGHUWANSHI N S, SINGH R, et al. Estimating evapotranspiration using artificial neural network [J]. Journal of Irrigation and Drainage Engineering, 2002, 128(4): 224–233.
- [29] 孙志彬, 杨小礼, 黄阜. Hoek-Brown 准则下岩质边坡的 GSI 反演[J]. 中南大学学报(自然科学版), 2013, 44(6): 2515–2519. [SUN Z B, YANG X L, HUANG F. Back analysis of rock slope GSI magnitude under Hoek-Brown criterion [J]. Journal of Central South University (Science and Technology), 2013, 44(6): 2515–2519. (in Chinese)]
- [30] 孙超伟, 柴军瑞, 许增光, 等. 基于 Hoek-Brown 强度折减法的边坡稳定性图表法研究[J]. 岩石力学与工程学报, 2018, 37(4): 838–851. [SUN C W, CHAI J R, XU Z G, et al. Stability charts for rock slopes based on the method of reduction of Hoek-Brown strength [J]. Chinese Journal of Rock Mechanics and Engineering, 2018, 37(4): 838–851. (in Chinese)]