

<https://doi.org/10.3799/dqkx.2022.499>



基于集成学习和 LEM 的折线型边坡稳定性评价方法

邓子昊^{1,2,3}, 张黎明^{1,2,4}, 徐兴华⁵, 吕庆^{1,2,3*}

1. 浙江大学建筑工程学院, 浙江杭州 310058
2. 浙江大学平衡建筑研究中心, 浙江杭州 310058
3. 浙江大学建筑设计研究院有限公司, 浙江杭州 310012
4. 贵州大学矿业学院, 贵州贵阳 550025
5. 浙江省地质矿产研究所, 浙江杭州 310007

摘要: 传统边坡稳定性力学分析方法计算效率有限且往往需要借助专业软件, 不利于推广. 机器学习作为一种高效分析手段可应用于边坡稳定性评价. 基于随机生成的大量折线型边坡样本, 通过极限平衡法 (LEM) 求解安全系数, 从而构建边坡安全系数数据库, 通过集成神经网络模型建立 LEM 代理模型. 分别采用 Bagging 和 AdaBoost.R2 两种算法构建集成神经网络, 建立折线型边坡安全系数预测模型, 通过实际边坡工程案例进行了验证, 并与单神经网络进行了对比. 通过 ROC 曲线分析法评价各个模型性能, 确定合理的安全系数阈值. 结果表明两种集成模型性能显著优于单神经网络模型, 其中单神经网络模型的 AUC 值为 0.826, AdaBoost.R2 模型为 0.893, Bagging 模型为 0.929, 更能准确辨别边坡的稳定性情况. 提出的方法能快速、准确地评价折线型边坡稳定性, 为区域性大量边坡的稳定性快速评价提供工具.

关键词: 集成神经网络; 极限平衡法; 折线型边坡; 边坡稳定性; ROC 曲线分析法; 滑坡; 工程地质.

中图分类号: P694

文章编号: 1000-2383(2024)11-4216-09

收稿日期: 2022-12-26

Evaluation for Broken Line Slope Stability Based on Ensemble Learning and LEM

Deng Zihao^{1,2,3}, Zhang Liming^{1,2,4}, Xu Xinghua⁵, Lü Qing^{1,2,3*}

1. College of Civil Engineering and Architecture, Zhejiang University, Hangzhou 310058, China
2. Center for Balance Architecture, Zhejiang University, Hangzhou 310058, China
3. Architectural Design & Research Institute of Zhejiang University, Hangzhou 310012, China
4. Mining College, Guizhou University, Guiyang 550025, China
5. Zhejiang Institute of Geology and Mineral Resources, Hangzhou 310007, China

Abstract: Conventional mechanical analysis methods for slope stability have limited computational efficiency and need professional software. Machine learning, as an efficient analysis method, can be applied to slope stability evaluation. Abundant broken line slope samples are randomly generated and the corresponding factors of safety are solved by the limit equilibrium method (LEM) in this paper, so as to build a slope factor of safety database, and the LEM surrogate model is established by integrating neural network models. Two ensemble algorithms, Bagging and AdaBoost.R2, are used to establish a neural network ensemble model to

基金项目: 浙江省重点研发计划(No.2021C03159); 国家自然科学基金面上项目(No.42277132); 浙江大学平衡建筑研究中心配套资金资助项目(No.K-20212721); 浙江省基础公益研究计划(No.LGF21D020001); 自然资源部浙江地质灾害野外观测研究站项目(No.ZJDZGCZ-2021).

作者简介: 邓子昊(1998-), 男, 博士研究生, 主要研究方向为降雨型滑坡预警. ORCID: 0000-0002-7052-9474. E-mail: dengzihao@zju.edu.cn

* **通讯作者:** 吕庆, ORCID: 0000-0003-0466-2936. E-mail: lvqing@zju.edu.cn

引用格式: 邓子昊, 张黎明, 徐兴华, 吕庆, 2024. 基于集成学习和 LEM 的折线型边坡稳定性评价方法. 地球科学, 49(11):4216-4224.

Citation: Deng Zihao, Zhang Liming, Xu Xinghua, Lü Qing, 2024. Evaluation for Broken Line Slope Stability Based on Ensemble Learning and LEM. *Earth Science*, 49(11):4216-4224.

predict factor of safety, which is verified by practical slope engineering cases, contrasting with single neural network model. The performances are evaluated by ROC curve analysis method, and reasonable threshold of factor of safety is determined. Results show that two ensemble models are significantly better than the single neural network model. While the AUC value of the single neural network model is 0.826, the AdaBoost. R2 model is 0.893, and the Bagging model can recognize slope stability situation better with value of 0.929. The proposed method can evaluate broken line slope stability quickly and accurately, providing a tool for rapid stability evaluation of a large number of regional slopes.

Key words: neural network ensemble; limit equilibrium method; broken line side slope; slope stability; ROC curve analysis; landslides; engineering geology.

0 引言

滑坡作为一种常见地质灾害现象,不仅破坏环境、资源,而且造成财产损失,甚至威胁人类生命安全(Zhang and Huang, 2018; 李振洪等, 2022). 对边坡稳定性的预测能够有效保护社会财产和生命安全. 边坡稳定性的定量分析通常采用安全系数法,常用的方法包括极限平衡法(张泰丽等, 2017)、强度折减法(曹伟等, 2018)等. 其中,极限平衡法(LEM)在国内外已有大量工程实践经验,是最流行和成熟的边坡安全系数计算方法. 然而,这类力学模型计算过程都较为复杂,需要依靠专业软件实现,并耗费较大算力(Liang and Zhang, 2010). 一方面,对于某些区域性滑坡研究,如对大范围自然斜坡区域进行稳定性评价,边坡建模的工作量大,力学分析效率低;另一方面,安全系数的计算过程相当依赖专业知识,对技术人员的专业性要求高,不利于应用推广.

机器学习作为一种高效的分析手段,已被大量应用于滑坡风险评价研究. 滑坡的发育过程及其稳定性状态受地质条件及岩土参数控制,不少学者采用数据驱动方法,以收集的滑坡数据库为基础,通过机器学习算法构建地质参数与边坡响应间的非线性映射关系,包括滑坡易发性区划(李文彬等, 2021; 吴润泽等, 2021)、滑坡位移预测(姜宇航等, 2022)、滑坡水文预测(Pham *et al.*, 2022)等. 其中,集成学习作为一种先进的模型优化算法,已被国内外学者应用于提升滑坡易发性评价模型的精度(Pham *et al.*, 2017; Dou *et al.*, 2020; Di Napoli *et al.*, 2020; 周超等, 2020). 安全系数作为最基本、最直观的边坡稳定性评判指标,近年来其预测模型与机器学习算法的结合也获得了重视(张伟龙, 2020; Chen *et al.*, 2022). 如陈昌彦等(2001)和 Ahour *et al.* (2020)采用神经网络预测边坡安全系数, Li and Zhang (2021)将支持向量机应用于不同水文

工况下的岩质边坡稳定性评价. 上述研究证实了采用机器学习算法开展边坡稳定性评价是可行的.

已有的基于机器学习的边坡稳定性评价模型主要通过收集现实中的边坡案例并记录其安全系数或稳定性情况,忽略了物理力学过程分析,直接通过机器学习算法建立边坡参数及稳定性情况的映射关系. 由于样本数量有限、不确定因素多、不同样本分析方法不统一等原因,其预测结果缺乏明确物理意义,其结果对于实际工程的参考价值有限. 此外,大量自然边坡具有典型的坡形,如浙江省的滑坡有相当大的比例发生在凸型坡或凹型坡(陈列等, 2009; 麻土华等, 2010). 然而已有研究大多忽视边坡的坡形特征,将边坡概化为简单的直线型边坡,限制了预测模型的适用范围.

本文将集成学习算法和极限平衡法(LEM)相结合来预测折线型边坡的稳定性. 本文首先随机生成大量折线型边坡样本并通过LEM求解相应的安全系数,构建边坡安全系数数据库. 然后,利用人工神经网络模型建立力学计算代理模型. 采用Bagging和AdaBoost.R2两种集成学习的方法对人工神经网络模型的泛化性能进行提升(周志华和陈世福, 2002),获得准确且高效率的边坡安全系数预测模型,从而进行稳定性评价. 采用实际边坡案例对模型进行应用验证.

1 集成学习算法

本文采用人工神经网络(ANN)作为基础学习器,构建集成模型.

1.1 人工神经网络

目前,人工神经网络在地质灾害领域已经得到了广泛应用(陈建平等, 2021). 神经网络由以权重值相连接的若干个神经元构成,根据神经元在结构中的位置可分为输入层,隐含层和输出层. 在对训练集进行学习的过程

中,神经网络通过调整各个权重值,使模型输出尽可能接近目标输出(如降低均方误差),从而实现对函数关系的拟合(Lü *et al.*, 2012).

本文建立的BP人工神经网络结构如图1所示,采用三层BP神经网络,为8-d-1结构,即输入层包含8个神经元,隐含层神经元数量为d,输出层包含1个神经元.输入层包含折线型边坡的坡形参数及物理指标,通过LEM计算出的安全系数则为输出层结果.隐含层神经元数量d的取值需要在训练过程中确定.最终获得的神经网络模型可视作LEM的代理模型.

1.2 集成学习

在有监督的机器学习算法中,往往很难获得一个稳定的且各个方面表现都好的模型,仅能得到多个有不同偏好的模型.集成学习算法通过组合多个弱监督模型以期获得一个更好更全面的强监督模型(周超等, 2020),可以有效降低预测模型的误差和不确定性,已成为机器学习的一个研究热点.在各种集成思路中,Bagging和Boosting算法是最流行的两类集成策略,本文选用这两种算法构建集成神经网络模型.

1.3 Bagging算法

Bagging算法示意如图2所示(Breiman, 1996).在Bagging算法中,为了获得多个有差异的基础学习器,通过N次Bootstrap法抽样,得到N个平行的子训练集,进而得到N个不同的预测模型.本文采用简单平均的方法实现这N个模型的集成,即对于同一组输入值x,将N个模型分别输出的预测值 $f_i(x)$ 的算数平均值当作集成模型的最终输出:

$$f_{\text{fin}}(x) = \frac{1}{N} \sum_{i=1}^N f_i(x). \tag{1}$$




图1 边坡稳定性预测模型的BP网络拓扑结构
Fig.1 Topological structure of BP network of slope stability prediction model

1.4 AdaBoost.R2算法

Boosting算法作为最流行的集成策略之一,已发展出若干种子算法.本文选用回归问题中常用的AdaBoost.R2算法(Drucker, 1997),其步骤如下(孙凤琪, 2009):

(1) 输入: 给定n个训练样本: $S = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$.

(2) 模型初始化

基础学习器f: 基于BP算法的人工神经网络;
权值初始化: 样本分布权重:

$$D_1(i) = 1/n. \tag{2}$$

式中,权重向量D的下标指迭代次数,i为样本号.

(3) 设定最大迭代次数N.采用AdaBoost.R2方法调用ANN的主循环过程($t = 1, \dots, N$),第t次循环时:

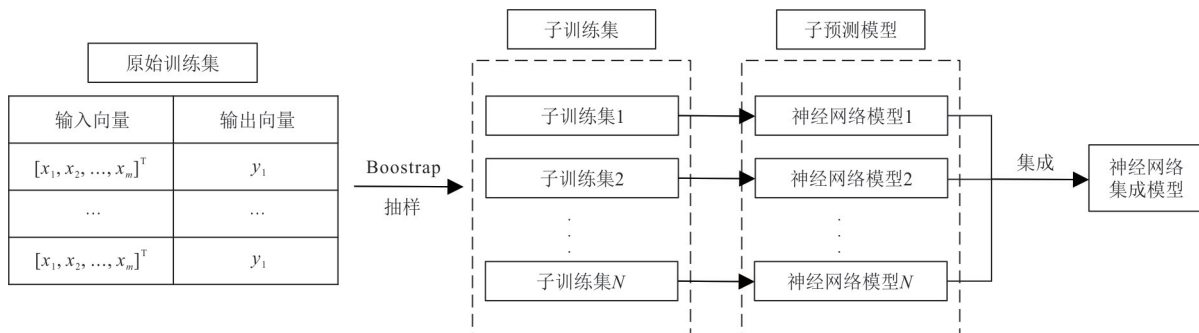


图2 Bagging集成算法示意

Fig.2 Schematic diagram of ensemble method using Bagging algorithm

① 根据样本分布权重 D_t 训练人工神经网络 ANN, 得到基础学习器 f_t ;

② 计算每个样本的相对误差 e'_t :

$$E_t = \max_{i=1, \dots, n} |y_i - f_t(x_i)| \quad (3)$$

$$e'_t = |y_i - f_t(x_i)| / E_t \quad (4)$$

③ 计算 f_t 的“伪误差” ϵ_t :

$$\epsilon_t = \sum_{i=1}^n e'_t D_t(i) \quad (5)$$

当 $\epsilon_t \geq 0.5$ 时, 停止迭代, 令 $N=t-1$;

④ 计算

$$\beta_t = \epsilon_t / (1 - \epsilon_t) \quad (6)$$

⑤ 更新样本分布权重:

$$D_{t+1}(i) = D_t(i) \beta_t^{1 - e'_t} / Z_t \quad (7)$$

其中 Z_t 为标准化因子. 令 $t=t+1$.

(4) 输出: N 次循环后, 得到最终学习器:

$$f_{\text{fin}}(x) = \inf \left\{ y \in Y: \sum_{t: f_t(x) \leq y} \log(1/\beta_t) \geq \frac{1}{2} \sum_t \log(1/\beta_t) \right\} \quad (8)$$

值得一提的是, AdaBoost.R2 算法中的基础学习器训练依赖于前一次迭代结果, 而 Bagging 算法中每个基础学习器的训练是独立的, 这是两种算法的主要区别. 在回归问题中, Bagging 方法主要通过降低误差方差 (Variance) 来降低泛化误差, 而 AdaBoost.R2 方法在大部分情况下主要通过降低误差偏差 (Bias) 来降低泛化误差 (Zhou *et al.*, 2002).

2 基于集成模型的安全系数预测

本文提出的边坡稳定性评价方法流程图见图 3.

2.1 样本的获取及分析

本文将凸型坡或凹型坡概化为如图 4 所示的均质折线型边坡, 直线型边坡可视为折线型边坡

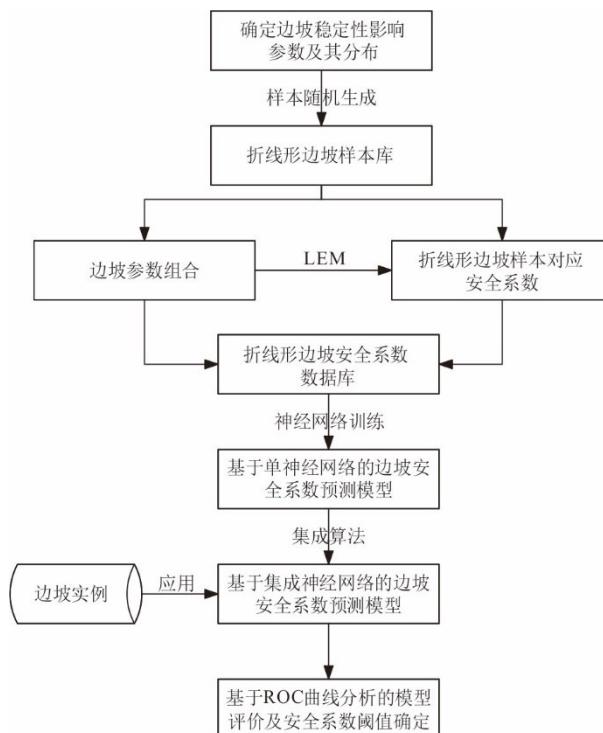


图 3 边坡稳定性评价模型构建流程

Fig.3 Flow chart of slope stability evaluation model construction

的特例. 本文仅考虑圆弧型滑动失稳破坏模式. 将上下两段边坡的坡高 H_1 、 H_2 , 坡角 α 、 β , 以及边坡岩土体的重度 γ , 黏聚力 c , 内摩擦角 φ , 孔隙水压力比 r_u 八个变量作为模型输入量, 边坡的安全系数 (FS) 作为模型输出量. 本文忽略地层和复杂水文特征的影响. 首先, 根据研究区的地质调研情况, 确定输入参数的范围及分布. 作为示例, 本文参考国内外文献以及工程经验 (陈新民和罗国煜, 1999; Sakellariou and Ferentinou, 2005), 设置各参数的取值范围如表 1 所示. 本文假设这 8 个参数相互独立, 采用均匀分布来准备样本参数, 目的是在样本参数空间中获得相对均匀的样本点, 避免模型存在侧重, 以期后续机器学习模

表 1 边坡各参数取值范围

Table 1 Value range of slope parameters

参数	坡高 H_1 (m)	坡高 H_2 (m)	坡角 α (°)	坡角 β (°)
最小值	0	0	15	15
最大值	200	200	75	75
参数	重度 γ ($\text{kN} \cdot \text{m}^{-3}$)	粘聚力 c (kPa)	内摩擦角 φ (°)	孔隙水压力比 r_u
最小值	15	0	5	0
最大值	30	150	45	0.6

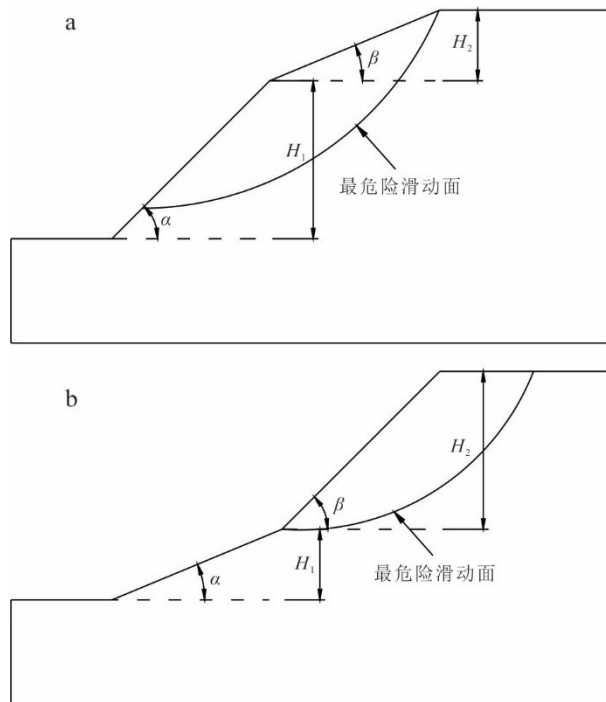


图 4 折线型边坡概化图

Fig.4 Sketched diagram of broken line slope

a. 凸型坡; b. 凹型坡

型能兼顾不同工程地质条件下不同边坡参数的安全系数预测. 基于概率分布随机采样, 获取 2 000 组参数, 对应 2 000 个随机边坡.

采用 GeoStudio 软件中的 SLOPE/W 计算模块, 基于 Morgenstern-Price 法对上述 2 000 个边坡的安全系数进行计算, 得到 2 000 组输入量和对应的输出量, 构成折线型边坡安全系数数据库. 计算获得的安全系数的分布如图 5 所示, 由图可见大部分边坡样本的安全系数在 0~0.5 之间, 这是由于边坡参数集的构建过程中忽视了参数间的相关性. 该部分安全系数过低的样本缺乏实际意义, 直接用于训练的话将导致模型错误地关注这些没有现实意义的样本. 为此, 本文仅选取 $FS \geq 0.5$ 的 811 个样本, 将其按 7:3 的比例划分为训练样本组和测试样本组.

2.2 集成神经网络模型的构建

构建人工神经网络的一个难题在于确定其结构. 本文选用三层 BP 神经网络, 采用 10 折交叉验证的方法确定隐含层神经元数 d 后, 针对该结构分别通过 Bagging 方法和 AdaBoost.R2 方法构建集成模型. 取 $10 \leq d \leq 50$, 对 d 的每个取值对应的单个神经网络模型分别进行 10 次 10 折交叉验证, 获得最终




图 5 2 000 个样本的安全系数分布直方图

Fig.5 Distribution histogram of factor of safety of 2 000 samples




图 6 不同结构模型的 10 次 10 折交叉验证结果

Fig.6 The results of 10 times 10-fold cross-validation on models with different structures

模型的平均均方误差 (\overline{MSE}) 和隐含层神经元数 d 的关系如图 6 所示. 对于单学习器, 当 $d=24$ 时性能最优, $\overline{MSE} = 0.018$. 采用该结构构建集成模型, 对于 Bagging 集成神经网络模型, $\overline{MSE} = 0.014$; 对于 AdaBoost.R2 集成神经网络模型, $\overline{MSE} = 0.012$, 如图 6 所示. 可见, 本文构建的集成神经网络模型可有效地代替 Morgenstern-Price 法, 实现折线型边坡安全系数的快速、实用计算.

2.3 性能比较

为更严格地比较各个模型, 采用 5×2 交叉验证和 t 检验对模型进行两两对比. 5×2 交叉验证是做 5 次 2 折交叉验证, 每次对两个学习器 A 和 B 都通过相同的训练集训练, 并通过相同的验证集计算均方误差. 将各自得到的 10 个均方误差分别进行求差,

第 i 次交叉验证得到的两个差值分别为 Δ_i^1, Δ_i^2 . 若两个学习器性能相同, 则每次交叉验证的差值均值应为 0, 以此来对“学习器 A 与 B 性能相同”这个假设进行 t 检验. 为缓解测试错误率的非独立性, 仅计算第一次 2 折交叉验证的两个差值的平均值 $\mu = 0.5(\Delta_i^1 + \Delta_i^2)$. 基于每次 2 折实验结果计算:

$$\sigma_i^2 = \left[\Delta_i^1 - (\Delta_i^1 + \Delta_i^2)/2 \right]^2 + \left[\Delta_i^2 - (\Delta_i^1 + \Delta_i^2)/2 \right]^2 \quad (9)$$

$$\tau_i = \frac{|\mu|}{\sqrt{0.2 \sum_{i=1}^5 \sigma_i^2}} \quad (10)$$

若变量 τ_i 小于双边检验的临界值 $t_{\alpha/2, 5}$, 则假设不能被拒绝, 即认为两个学习器的性能没有显著差别; 否则认为两个学习器性能有显著差别, 且平均错误率较小的学习器性能较优. 经检验, 从安全系数回归的角度, Bagging 集成神经网络模型和 AdaBoost.R2 集成神经网络模型性能均显著优于单神经网络模型 (置信度为 0.05), 而两种集成模型的性能并无显著区别.

模型在测试集上的安全系数预测误差情况如下: 对于单神经网络模型, 测试集均方误差 $MSE = 0.034$; 对于 Bagging 集成神经网络模型, 测试集 $MSE = 0.022$; 在使用 AdaBoost.R2 集成神经网络时, 测试集 $MSE = 0.021$. 相对误差分布情况如图 7 所示. 可见采用两种集成神经网络时误差更容易得到控制, 表现更加优秀, 大部分样本相对误差处于 $\pm 5\%$ 之内, 除异常值外, 相对误差也处于 $\pm 20\%$ 之内. 对于两种集成方法, Bagging 集成模型的 1.5IQR 内范围相对于 AdaBoost.R2 集成模型无明显差异, 但测试集内异常值更受控制.

通过以上分析, 可以发现两种集成模型的性能相对于一般人工神经网络模型有了显著的提升.

2.4 案例边坡应用验证

为验证本文模型的准确性及实用性, 本节选择文献中的 46 个实际边坡案例作为分析对象 (Sakellariou and Ferentinou, 2005). 这 46 个边坡仅考虑圆弧滑动失稳模式, 与本文模型一致. 其中 29 个边坡最终失稳, 另外 17 个则维持稳定状态.

在传统的边坡稳定性评价中, 通常取安全系数 $FS = 1.0$ 作为判断边坡稳定与否的阈值指标. 考虑到机器学习模型预测误差, 以及实际边坡与计算模型之间的差异, 应重新确定最优阈值. 因此, 分别采

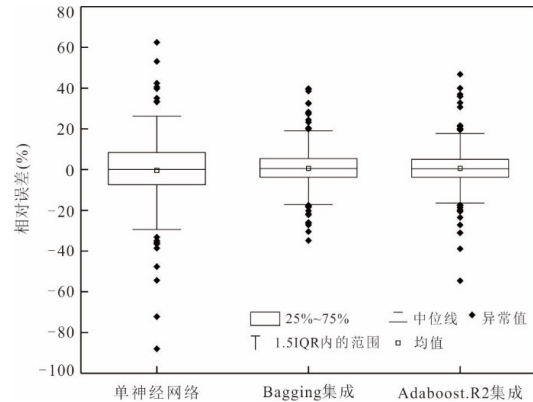


图 7 不同模型在测试集上的相对误差箱线图

Fig.7 Box diagram of relative error of different models on the test set

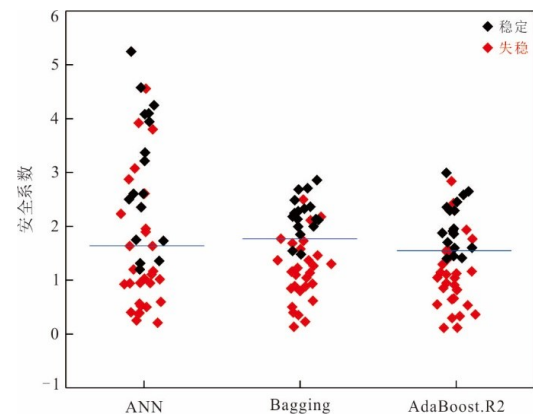


图 8 边坡案例安全系数预测结果

Fig.8 Prediction results of safety factor for slope cases
蓝线代表最优安全系数阈值

用 Bagging 集成模型、AdaBoost.R2 集成模型、单神经网络模型, 对这 46 个边坡的安全系数进行计算, 其中用机器学习模型计算获得的安全系数结果见图 8. 结合边坡实际稳定性状况, 应用受试者工作特征曲线 (Receiver Operating Characteristic Curve, ROC 曲线) 分析法对各种模型的稳定性预测性能进行评价和比较, 如图 9 所示. 对于单神经网络模型, 最优判断阈值为 $FS = 1.635$, AUC 值为 0.826; 对于 Bagging 集成神经网络模型, 最优判断阈值为 $FS = 1.769$, AUC 值为 0.929; 对于 AdaBoost.R2 集成神经网络模型, 最优判断阈值为 $FS = 1.557$, AUC 值为 0.893. 可见 Bagging 集成神经网络模型对于边坡稳定性的辨别能力最为准确, AdaBoost.R2 集成神经网络模型次之, 单神经网络模型效果明显低于集成模型. 结合前文可知, 虽然从安全系数预测误差的角度来看, Bagging 集成神经网络模型性

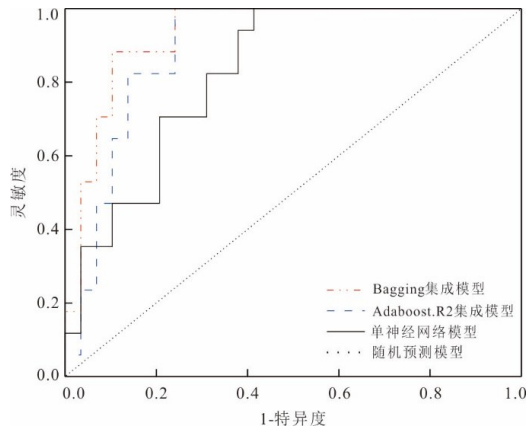


图9 不同模型预测实际边坡稳定性的ROC曲线

Fig.9 ROC curves of different models predicting stability of actual slopes

能与 AdaBoost.R2 集成神经网络模型的性能差别并不显著,但对现实边坡案例进行稳定性分类评价时,通过 ROC 曲线可以发现其性能要优于 AdaBoost.R2 集成神经网络模型(图 9)。

3 讨论

国内外不少学者曾尝试将机器学习运用于边坡稳定性预测问题,但其思路通常是首先收集现实中的边坡工程案例,再运用机器学习技术直接建立边坡各种地质和工程因素与稳定性情况之间的映射关系,其本质上采用了数据驱动的思想,是一种经验性模型.其优点在于计算效率高,成功建立模型后可以简单地交给非专业人士使用.其缺点包括:(1)样本获取难度大,有效样本数量有限;(2)样本数据准确度难以保证;(3)样本缺乏统一标准,例如,不同样本可能采用了不同的计算方法计算安全系数,下覆基岩产状可能不同,岩土体参数和坡面几何参数的确定方法可能不同,地质条件的空间变异性等.这些缺点将导致这些模型对工程的实际参考价值有限,很难应用推广.在工程中更常用的还是通过力学分析方法(极限平衡法、强度折减法)对边坡稳定性进行分析计算,其物理意义明确,技术人员可以据此评价边坡的实际稳定状态.但总体而言,这类方法存在计算效率低、实用性差的问题.

本文提出的模型本质上是将数据驱动和物理分析方法相结合,即通过集成神经网络模型构建 LEM 代理模型.代理模型将原计算过程中的隐式关系转变为显示表达,大幅提高计算效率的同时,降低了对计算软件的依赖,简化了计算分析流程.

在实践中,技术人员可以分析采用的力学分析方法和建模过程中的假定(如均质性)在该案例中是否适用,自主评估预测结果的参考价值.技术人员也可以根据研究地区的实际工程地质和地形情况选取更合适的参数分布构建边坡样本库,得到具有地区适应性的边坡稳定性评价模型.

作为简化,本文将孔隙水压力比参数作为边坡水文地质情况的表征.孔隙水压力比作为无量纲参数,能反映不同规模边坡中孔隙水压力对有效应力的折减比例,Bishop and Morgenstern (1960)的分析表明,孔隙水压力比作为预测因子对边坡安全系数进行预测是可行的.在实际应用中,可以测定边坡多个部分的局部孔隙水压力比,将平均值作为边坡整体的参数取值.

值得一提的是,根据 ROC 曲线确定的模型最优安全系数阈值与工程上常用阈值差异较大.这一方面由于实际边坡和模型假定间存在较大差异,特别是实际边坡的非均质性和地层分布,另一方面由于现实中边坡参数间存在复杂的相关性,人工样本的参数分布和实际存在一定差异.但通过 ROC 曲线可知,该模型依然能较准确地评判边坡稳定性情况,也证实了本文提出的方法具有较大的应用前景.

4 结论

滑坡灾害会造成巨大的生命和财产损失,高效且准确地预测滑坡灾害,对于地质灾害防治、预警预报意义重大.为了克服力学分析算力耗费大,对技术人员专业性要求高,不利于快速预测和推广应用等问题,本文探讨了通过机器学习方法建立代理模型以代替传统极限平衡法的可行性.本文考虑坡形的影响,将自然边坡概化为折线型边坡,建立边坡参数样本库并通过 LEM 计算对应安全系数,采用人工神经网络建立 LEM 代理模型得到边坡安全系数预测模型,并通过 Bagging 和 AdaBoost.R2 两种集成算法对模型泛化性进行提升,最终建立了一套折线型边坡稳定性评价方法,针对实际边坡案例进行验证.主要得出以下结论:

(1)采用 Bagging 技术、AdaBoost.R2 技术构建集成神经网络模型作为 LEM 代理模型,对折线型边坡安全系数进行预测,并构建单神经网络模型作为对比,最后针对现实中 46 个边坡进行验证性分析.结果表明,集成算法作为优化算法能极大地提高安全系数预测精

度及稳定性评价准确性,尤其是 Bagging 算法。

(2) 由于模型假定与实际边坡的差异较大,本文提出模型中用于区分边坡稳定与否的最优安全系数阈值 $FS=1.5\sim 1.8$, 远高于工程中常用阈值。但通过 ROC 曲线可知,该模型依然能较准确地判断边坡稳定性情况,也证实本文提出的方法具有较大的应用潜能。

(3) 本文提出的模型本质上是将数据驱动和物理分析方法相结合,即通过人工神经网络模型构建极限平衡法代理模型,在提高计算效率的同时,力学计算模型本身的物理意义得到保留。

References

- Ahour, M., Hataf, N., Azar, E., 2020. A Mathematical Model Based on Artificial Neural Networks to Predict the Stability of Rock Slopes Using the Generalized Hoek-Brown Failure Criterion. *Geotechnical and Geological Engineering*, 38(1): 587–604. <https://doi.org/10.1007/s10706-019-01049-y>
- Bishop, A. W., Morgenstern, N., 1960. Stability Coefficients for Earth Slopes. *Géotechnique*, 10(4): 129–153. <https://doi.org/10.1680/geot.1960.10.4.129>
- Breiman, L., 1996. Bagging Predictors. *Machine Learning*, 24(2): 123–140. <https://doi.org/10.1007/BF00058655>
- Cao, W., Li, W.J., Zhang, H.F., 2018. Comparative Study of Safety Factor Calculation for Slope by Finite Element Method. *Highway*, 63(6): 19–23 (in Chinese with English abstract).
- Chen, C.Y., Wang, S.J., Shen, X.K., 2001. Predicting Models to Estimate Stability of Rock Slope Based on Artificial Neural Network. *Chinese Journal of Geotechnical Engineering*, 23(2): 157–161 (in Chinese with English abstract).
- Chen, J.P., Wang, C.L., Wang, X.D., 2021. Coal Mine Floor Water Inrush Prediction Based on CNN Neural Network. *The Chinese Journal of Geological Hazard and Control*, 32(1): 50–57 (in Chinese with English abstract).
- Chen, L., Huang, X. Q., Shi, R. R., et al., 2009. Regionalizing Forecasting Disquisition of the Landslide in Zhejiang Province. *Bulletin of Science and Technology*, 25(5): 577–581 (in Chinese with English abstract).
- Chen, L. L., Zhang, W. G., Gao, X. C., et al., 2022. Design Charts for Reliability Assessment of Rock Bedding Slopes Stability against Bi-Planar Sliding: SRLEM and BPNN Approaches. *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards*, 16(2): 360–375. <https://doi.org/10.1080/17499518.2020.1815215>
- Chen, X.M., Luo, G.Y., 1999. Grey System Analysis and Evaluation of Slope Stability Based on Experience. *Chinese Journal of Geotechnical Engineering*, 21(5): 638–641 (in Chinese with English abstract).
- Di Napoli, M., Carotenuto, F., Cevasco, A., et al., 2020. Machine Learning Ensemble Modelling as a Tool to Improve Landslide Susceptibility Mapping Reliability. *Landslides*, 17(8): 1897–1914. <https://doi.org/10.1007/s10346-020-01392-9>
- Dou, J., Yunus, A. P., Bui, D. T., et al., 2020. Improved Landslide Assessment Using Support Vector Machine with Bagging, Boosting, and Stacking Ensemble Machine Learning Framework in a Mountainous Watershed, Japan. *Landslides*, 17(3): 641–658. <https://doi.org/10.1007/s10346-019-01286-5>
- Drucker, H., 1997. Improving Regressors Using Boosting Techniques. *Proceedings the Fourteenth International Conference on Machine Learning, Nashville*, 97: 107–115.
- Jiang, Y. H., Wang, W., Zou, L. F., et al., 2022. Research on Dynamic Prediction Model of Landslide Displacement Based on Particle Swarm Optimization-Variational Mode Decomposition, Nonlinear Autoregressive Neural Network with Exogenous Inputs and Gated Recurrent Unit. *Rock and Soil Mechanics*, 43(S1): 601–612 (in Chinese with English abstract).
- Li, F., Zhang, H. Y., 2021. Stability Evaluation of Rock Slope in Hydraulic Engineering Based on Improved Support Vector Machine Algorithm. *Complexity*, (1): 1–13. <https://doi.org/10.1155/2021/8516525>
- Li, W.B., Fan, X.M., Huang, F.M., et al., 2021. Uncertainties of Landslide Susceptibility Modeling under Different Environmental Factor Connections and Prediction Models. *Earth Science*, 46(10): 3777–3795 (in Chinese with English abstract).
- Li, Z.H., Zhang, C.L., Chen, B., et al., 2022. A Technical Framework of Landslide Prevention Based on Multi-Source Remote Sensing and Its Engineering Application. *Earth Science*, 47(6): 1901–1916 (in Chinese with English abstract).
- Liang, H. N., Zhang, H. Q., 2010. Identification of Slope Stability Based on the Contrast of BP Neural Network and SVM. 2010 3rd International Conference on Computer Science and Information Technology, Chengdu, 347–350. <https://doi.org/10.1109/ICCSIT.2010.5564502>
- Lü, Q., Chan, C. L., Low, B. K., 2012. Probabilistic Evaluation of Ground-Support Interaction for Deep Rock Exca-

- vation Using Artificial Neural Network and Uniform Design. *Tunnelling and Underground Space Technology*, 32: 1—18. <https://doi.org/10.1016/j.tust.2012.04.014>
- Ma, T. H., Sun, L. L., Li, W., et al., 2010. Landslide Types and Causal Factors in Zhejiang Region, China. *The Chinese Journal of Geological Hazard and Control*, 21(3): 17—23, 42 (in Chinese with English abstract).
- Pham, B. T., Tien Bui, D., Prakash, I., et al., 2017. Hybrid Integration of Multilayer Perceptron Neural Networks and Machine Learning Ensembles for Landslide Susceptibility Assessment at Himalayan Area (India) Using GIS. *CATENA*, 149: 52—63. <https://doi.org/10.1016/j.catena.2016.09.007>
- Pham, K., Kim, D., Le, C. V., et al., 2022. Dual Tree-Boosting Framework for Estimating Warning Levels of Rainfall-Induced Landslides. *Landslides*, 19(9): 2249—2262. <https://doi.org/10.1007/s10346-022-01894-8>
- Sakellariou, M. G., Ferentinou, M. D., 2005. A Study of Slope Stability Prediction Using Neural Networks. *Geotechnical & Geological Engineering*, 23(4): 419—445. <https://doi.org/10.1007/s10706-004-8680-5>
- Sun, F. Q., 2009. New Rock Burst Prediction Modeling Based on Ensemble Neural Network. *Journal of Jilin University (Information Science Edition)*, 27(1): 79—84 (in Chinese with English abstract).
- Wu, R.Z., Hu, X.D., Mei, H.B., et al., 2021. Spatial Susceptibility Assessment of Landslides Based on Random Forest: A Case Study from Hubei Section in the Three Gorges Reservoir Area. *Earth Science*, 46(1): 321—330 (in Chinese with English abstract).
- Zhang, F. Y., Huang, X. W., 2018. Trend and Spatiotemporal Distribution of Fatal Landslides Triggered by Non-Seismic Effects in China. *Landslides*, 15(8): 1663—1674. <https://doi.org/10.1007/s10346-018-1007-z>
- Zhang, T.L., Zhou, A.G., Sun, Q., et al., 2017. Characteristics of the Groundwater Seepage and Failure Mechanisms of Landslide Induced by Typhoon Rainstorm. *Earth Science*, 42(12): 2354—2362 (in Chinese with English abstract).
- Zhang, W. L., 2020. Research on Slope Stability Analysis Based on Machine Learning (Dissertation). Taiyuan University of Technology, Taiyuan (in Chinese with English abstract).
- Zhou, C., Yin, K.L., Cao, Y., et al., 2020. Landslide Susceptibility Assessment by Applying the Coupling Method of Radial Basis Neural Network and AdaBoost: A Case Study from the Three Gorges Reservoir Area. *Earth Science*, 45(6): 1865—1876 (in Chinese with English abstract).
- Zhou, Z.H., Chen, S.F., 2002. Neural Network Ensemble. *Chinese Journal of Computers*, 25(1): 1—8 (in Chinese with English abstract).
- Zhou, Z. H., Wu, J. X., Tang, W., 2002. Ensembling Neural Networks: Many could be Better Than All. *Artificial Intelligence*, 137(1—2): 239—263. [https://doi.org/10.1016/S0004-3702\(02\)00190-X](https://doi.org/10.1016/S0004-3702(02)00190-X)

中文参考文献

- 曹伟, 李文静, 张红芬, 2018. 边坡安全系数的有限元计算方法对比研究. *公路*, 63(6): 19—23.
- 陈昌彦, 王思敬, 沈小克, 2001. 边坡岩体稳定性的人工神经网络预测模型. *岩土工程学报*, 23(2): 157—161.
- 陈建平, 王春雷, 王雪冬, 2021. 基于 CNN 神经网络的煤层底板突水预测. *中国地质灾害与防治学报*, 32(1): 50—57.
- 陈列, 黄新晴, 石蓉蓉, 等, 2009. 浙江省滑坡分区预报研究. *科技通报*, 25(5): 577—581.
- 陈新民, 罗国煜, 1999. 基于经验的边坡稳定性灰色系统分析与评价. *岩土工程学报*, 21(5): 638—641.
- 姜宇航, 王伟, 邹丽芳, 等, 2022. 基于粒子群-变分模态分解、非线性自回归神经网络与门控循环单元的滑坡位移动态预测模型研究. *岩土力学*, 43(S1): 601—612.
- 李文彬, 范宣梅, 黄发明, 等, 2021. 不同环境因子联接和预测模型的滑坡易发性建模不确定性. *地球科学*, 46(10): 3777—3795.
- 李振洪, 张成龙, 陈博, 等, 2022. 一种基于多源遥感的滑坡防灾技术框架及其工程应用. *地球科学*, 47(6): 1901—1916.
- 麻土华, 孙乐玲, 李炜, 等, 2010. 浙江滑坡类型、成因和环境控制因素与影响因素. *中国地质灾害与防治学报*, 21(3): 17—23, 42.
- 孙凤琪, 2009. AdaBoost 集成神经网络在冲击地压预报中的应用. *吉林大学学报(信息科学版)*, 27(1): 79—84.
- 吴润泽, 胡旭东, 梅红波, 等, 2021. 基于随机森林的滑坡空间易发性评价: 以三峡库区湖北段为例. *地球科学*, 46(1): 321—330.
- 张泰丽, 周爱国, 孙强, 等, 2017. 台风暴雨条件下滑坡地下水渗流特征及成因机制. *地球科学*, 42(12): 2354—2362.
- 张伟龙, 2020. 基于机器学习的边坡稳定性分析研究(硕士学位论文). 太原: 太原理工大学.
- 周超, 殷坤龙, 曹颖, 等, 2020. 基于集成学习与径向基神经网络耦合模型的三峡库区滑坡易发性评价. *地球科学*, 45(6): 1865—1876.
- 周志华, 陈世福, 2002. 神经网络集成. *计算机学报*, 25(1): 1—8.