DOI:10.14188/j.1671-8844.2025.0155 文章编号:1671-8844(XXXX)XX-0001-15

融合不同机器学习的库岸边坡时变可靠度分析方法

田密[1,2],常红君[1],钟儒泽[1],谢世平[3],杨帆[4]

(1. 湖北工业大学 土木建筑与环境学院,湖北 武汉 430068; 2. 河湖健康智慧感知与生态修复教育部重点实验室,武汉 430068; 3. 长沙矿山研究院有限责任公司,湖南 长沙 410012; 4. 长江水利水电开发集团(湖北)有限公司,湖北 武汉 430014)

摘要: 基于机器学习代理模型的边坡可靠度分析可有效减少确定性分析的计算次数而降低计算量、提高效率。目前采用机器学习分析边坡可靠度通常基于不同机器学习代理模型的预测性能选择最优的单个机器学习。然而,选择单一机器学习无法充分利用其他算法的优点,且存在泛化能力不足的问题。为此,本文提出了一种融合不同机器学习的考虑岩土体参数空间变异性的库岸边坡时变可靠度分析方法。首先,采用拉丁超立方抽样技术产生输入参数(包含岩土体抗剪强度参数、水位降速)的随机样本;基于支持向量机(SVM)和多元自适应回归(MARS)算法分别构建库岸边坡稳定性分析等效代理模型获取边坡安全系数确定性预测;然后基于贝叶斯模型平均提出融合SVM和MARS算法的库岸边坡稳定性分析集合代理模型。最后,通过蒙特卡洛模拟方法计算库岸边坡时变可靠度,给出边坡安全系数不确定性预测区间,并对比单一机器学习代理模型与集合代理模型计算库岸边坡稳定性的准确性。本文以三峡库区重庆段某库岸边坡为例,阐明了融合不同机器学习的库岸边坡时变可靠度分析方法的有效性。结果表明:相比于单一机器学习代理模型,融合SVM和MARS算法的库岸边坡稳定性分析集合概率模型预测的边坡安全系数更接近于数值模型计算值,其均方误差和平均绝对误差平均降低3.6%和15.6%。所构建的边坡稳定性集合代理模型不仅能准确高效地计算边坡时变失效概率,而且能合理考虑代理模型的预测不确定性,可为库岸边坡可靠度问题计算提供有效的分析方法。

关键词: 库岸边坡;时变可靠度;贝叶斯模型平均;预测不确性;机器学习

中图分类号: TU43 **文献标志码:** A

Time-varying reliability analysis method for reservoir slopes based on ensembles of different machine learning algorithms

TIAN Mi[1,2], CHANG Hongjun[1], ZHONG Ruze[1], XIE Shiping[3], YANG Fan[4]

(1. School of Civil Engineering, Architecture and Environment, Hubei University of Technology, Hubei Wuhan 430068;
2. Key Laboratory of Intelligent Health Perception and Ecological Restoration of Rivers and Lakes, Ministry of Education, Hubei Wuhan 430068;
3. Changsha Institute of Mining Research Co., LTD, Hunan Changsha 410012;
4. Changjiang Water Resources and Hydropower Development Group Co., LTD, Hubei Wuhan 430014)

Abstract: Machine learning (ML) based surrogate models can effectively reduce the number of deterministic simulation analyses, reduce computational costs and improve computational efficiency. At present, ML based

收稿日期: XXXX-XX-XX

作者简介: 田密(1988-),女,副教授,主要从事岩土工程可靠度分析与地质灾害风险评估方面的研究工作。E-mail: mitian-hbut@hbut.com。

基金项目: 国家自然科学基金项目(52009037);湖北省自然科学基金项目(2024AFB796);中国五矿集团有限公司全国重点实验室专项资金项目(WKZB2412BJ0402105);湖南省应急管理科技项目(yjtkjxm_202405)。

本文引用格式: 田密,常红君,钟儒泽,等.融合不同机器学习的库岸边坡时变可靠度分析方法[J].武汉大学学报(工学版),XXXX,XX(XX):1-15.

Citation: TIAN Mi, CHANG Hongjun, ZHONG Ruze, et al. Time-varying reliability analysis method for reservoir slopes based on ensembles of different machine learning algorithms[J]. Engineering Journal of Wuhan University, XXXX, XX(XX):1-15.

slope reliability analysis usually selects an optimal single model among alternative surrogate models based on their predictive performance. However, selecting a single ML model cannot completely employ the advantages of other algorithms and may suffer from limited generalization capability. To address this issue, this study proposes a time-varying reliability analysis method for reservoir slopes by integrating different machine learning models while considering the spatial variability of geotechnical parameters. Firstly, Latin hypercube sampling (LHS) is used to generate random samples of input parameters (including shear strength parameters and the water level drawdown). Then, surrogate models for slope stability analysis are constructed based on support vector machines (SVM) and multivariate adaptive regression splines (MARS), respectively. Subsequently, deterministic predictions of slope safety factors by SVM and MARS are integrated by the Bayesian model averaging (BMA) approach to generate an ensemble surrogate model for slope stability analysis. Finally, the time-varying reliability of reservoir slope is calculated by Monte Carlo simulation method and the uncertainty prediction intervals for slope safety factors are also provided. The prediction accuracy of single ML models and the ensemble model are also investigated. A slope in Chongqing section of the Three Gorges reservoir area is taken as an example to illustrate the proposed method. Results show that, compared with single ML models, the slope safety factors estimated from the BMA ensemble model are closer to the numerical simulation results. Furthermore, the mean squared error (MSE) and mean absolute error (MAE) of the ensemble model are reduced by an average of 3.6% and 15.6%, respectively. The proposed BMA ensemble model can not only accurately estimate the time-varying failure probability of slopes, but also reasonably account for the predictive uncertainty of surrogate models. This approach provides an effective analytical method for addressing the reliability of reservoir slopes.

Key words: Reservoir slope; Time-varying reliability; Bayesian model average; Predictive uncertainty; Machine learning

三峡库区库水位每年在175m与145m水位之间周期性波动,水库蓄水及库水位周期性变化改变了库区的水文地质环境[1]。在库水位下降阶段,岸坡中的地下水形成滞后的渗透力,使得坡体的下滑力急剧增加,继而引发滑坡灾害,这不仅威胁到库区居民的生命财产安全,还影响到三峡库区水电站的安全运营[2-5]。合理的库岸边坡稳定性分析是三峡库区滑坡防治的重要前提。由于岩土工程中存在各种不确定性(如岩土体空间变异性、模型不确定性等)[6],采用可靠度分析方法评价库岸边坡稳定性分析具有重要的理论意义和工程价值。

传统的边坡可靠度分析主要采用蒙特卡洛模拟(MCS)方法,通过成千上万次边坡非饱和渗流及稳定性分析计算边坡失效概率,计算量大、效率较低。近年来,随着人工智能的快速发展,机器学习算法在解决非线性复杂问题上体现出了独特的优势,已广泛应用于边坡可靠度分析中。如武梦婷等[7]采用随机森林和XGBoost两种学习算法搭建边坡安全稳定性评估模型,根据预测效果的对比分析选取最优评价模型进行边坡稳定性评价和防护措施。姬建等[8]通过卷积神经网络(CNN)建立随机场图像与边坡功能函数值之间隐式关系,进而计算边坡的失效概率。Wang等[9]通过XGBoost机器学习算法构建边坡安全系数计算等效代理模型,分析了考虑土体参数空间变异性的边坡可靠度。Liu等[10]采用多元自适应回归(MARS)和MCS模拟方法,研究了土壤性质多尺度变异性对失效概率的影响。张天龙等[11]采用主动学习径向基函数结合蒙特卡洛模拟计算了边坡的系统失效概率。基于机器学习代理模型的边坡可靠度分析可有效减少确定性分析的计算次数而降低计算量、提高计算效率。目前机器学习分析边坡可靠度通常基于不同种机器学习代理模型的预测性能从中选择最优的单一机器学习,而舍弃其他算法。然而,单一机器学习可能对特定数据集预测性能较好,但在其他数据集可能表现不佳,存在泛化能力不足的问题。并且,不同算法具有不同的优势,选择单一机器学习无法充分利用其他算法的优点,其预测稳定性和准确性有限。如Zhang等[12]集成了XGBoost和LightGBM两种机器学习算法进行八子门滑坡时变失效概率评估,但其并未考虑机器学习代理模型预测的不确定性。现有机器学习代理模型均是构建一个

近似的功能函数计算边坡安全系数,代理模型必然存在由于模型假设、超参数选取、优化算法等而带来的模型不确定性,导致边坡安全系数预测存在显著不确定性。而现有机器学习代理模型均提供的是确定性预测值,尚未考虑代理模型不确定性。

为此,本文提出了一种融合不同机器学习的库岸边坡时变可靠度分析方法,该方法采用拉丁超立方抽样技术产生输入参数(包含岩土体抗剪强度参数、水位降速)的样本点,基于支持向量机(SVM)和多元自适应回归(MARS)算法分别构建库岸边坡稳定性分析代理模型获取边坡安全系数确定性预测,然后基于贝叶斯模型平均和DREAM$_{(ZS)}$算法提出融合SVM和MARS的库岸边坡稳定性分析集合代理模型;最后,通过蒙特卡洛模拟方法计算水位骤降作用下边坡时变可靠度,并对比单一机器学习代理模型与集合代理模型的预测精度。本文以三峡库区重庆段某库岸边坡为例,研究了所提库岸边坡可靠度分析贝叶斯模型平均集合概率预测方法的有效性。

1 研究方法

1.1 拉丁超立方抽样

拉丁超立方抽样由McKay等[13]于1979年提出,目前,拉丁超立方抽样方法在边坡可靠度分析中得到了广泛应用[14-15]。本文采用拉丁超立方抽样技术产生输入参数样本点作为基本变量配点,构建边坡稳定性分析代理模型时,输入参数样本点的选择至关重要,它直接影响代理模型的计算效率和精度[14]。考虑到拉丁超立方抽样(LHS)可以对多元参数进行均匀分层抽样,并且可以有效的覆盖输入参数概率分布的上下限值。因此,本文采用拉丁超立方抽样方法在独立标准正态空间中分别产生N_{tr}训练和N_{te}组测试样本点$\boldsymbol{\xi}_{ij}$:

$$\xi_{ij}=\Phi^{-1}\left[F_{Rj}(R_{ij})\right] \tag{1}$$

式中:$\Phi^{-1}(\cdot)$为标准正态累积分布的逆函数;R_{ij}为第j变量第i次拉丁超立方抽样取值;$F_{Rj}(\cdot)$为各个区间中每个拉丁超立方样本点的累计概率分布函数值。与传统蒙特卡洛抽样不同,LHS方法能够确保每一个变量范围的全覆盖。生成参数样本点后将N_{tr}和N_{te}组样本点带入到SEEP/W和SLOPE/W模块进行边坡非饱和渗流和安全系数计算。

1.2 边坡非饱和渗流及稳定性分析

本文在SEEP/W模块中进行边坡非饱和渗流稳定分析,瞬态条件下边坡非饱和渗流控制方程为[16]:

$$\frac{\partial}{\partial x_i}\left[K_{ij}^{s}k_r(h_c)\frac{\partial h_c}{\partial x_j}+K_{i3}k_r(h_c)\right]+Q=\left[C(h_c)+\frac{\theta}{n}S_s\right]\frac{\partial h_c}{\partial t} \tag{2}$$

式中,K_{ij}^{S}为饱和渗透张量;i、j为虚坐标;k_r为相对透水率;h_c为压力水头;K_{i3}为渗透系数;$i3$表示iz方向;Q为源汇项;$C(h_c)$为容水度;θ为与压力水头相关的函数;n为土体内部的孔隙率;S_s为单位贮水量;t为时间。本文运用Fredlund & Xing模型[17]描述土体基质吸力与含水率之间关系。本文不考虑渗透系数的不确定性,渗透系数计算公式参考文献[17]。

在SEEP/W模块中进行边坡非饱和渗流计算得到孔隙水压力分布,在此基础上采用SLOPE/W模块的Morgenstern-Price方法[18]进行边坡稳定性分析,得到边坡安全系数:

$$F_S=\frac{\sum_{i=1}^{n_t}\tau_i\cdot l_i}{\sum_{i=1}^{n_t}(W_i+L_{i-1}+L_i)\sin\beta_i+\sum_{i=1}^{n_t}(G_i-G_{i-1})\cos\beta_i} \tag{3}$$

式中,n_t为土条数目;τ_i为土条i的非饱和抗剪强度;l_i为土条i的滑弧长度;W_i为土条i的自重;G_{i-1}、G_i和L_{i-1}、L_i为土条i的水平和竖向条间力;β_i为土条i的边坡倾角。

1.3 基于不同机器学习的边坡安全系数确定性预测

本文采用支持向量机和多元自适应回归算法训练数据,从而得到边坡安全系数预测的代理模型及其确定性预测值。

1.3.1 支持向量机(SVM)

支持向量机(SVM)是由Cortes and Vapnik[19]提出的一种监督学习方法。其基本思想是利用核函数将输入样本空间映射到高维特征空间,在这个高维空间中求得一个最优分类超平面,最大化不同类别样本间的分类间隔,从而实现高效分类。SVM的最优分类超平面为:

$$\begin{cases}\min_{\psi,b}\dfrac{1}{2}\|\boldsymbol{\psi}\|^2+K\sum_{i=1}^{n}\lambda_i\\ y_i\left(\boldsymbol{\psi}^T\cdot x+b\right)-1\geqslant 0 \quad i=1,2,\ldots n\end{cases} \tag{4}$$

式中,K为惩罚因子;λ_i为松弛变量;x为输入参数;y_i为样本类别标签;$\boldsymbol{\psi}$、b分别为超平面的法向量和

截距。SVM通过引入核函数将样本数据映射到高维特征空间,然后进行线性分类。而边坡安全系数预测是一个非线性问题,故在SVM中引入核函数将输入空间非线性地转换为高维特征空间,然后在高维特征空间应用线性分割方法。本文使用径向基函数作为核函数:

$$\kappa(x\cdot x_i)=\exp\left(-\frac{\|x-x_i\|^2}{2\sigma^2}\right) \tag{5}$$

式中,$\kappa(x\cdot x_i)$为核函数,表示原始空间中样本在高维空间的内积; 为核函数参数。

1.3.2 多元自适应回归(MARS)

多元自适应回归样条(MARS)是由美国统计学家Friedman[20]于1991年提出的一种非线性回归算法。该方法无需假设输入变量与输出变量之间的函数关系,而是自适应地选取结点将训练数据集划分为独立的不同梯度的分段线段。MARS的每个分段线段为基函数,各段的端点称为结点。基函数由MARS通过逐步搜索生成,结点位置由自适应回归算法选取。基于MARS算法,可以采用基函数及其相互作用的线性组合预测输出变量y,则输出变量的MARS模型$g(\boldsymbol{X})$可以表示为:

$$g(\boldsymbol{X})=\alpha_0+\sum_{k=1}^{N_m}\alpha_k\eta_k(\boldsymbol{X}) \tag{6}$$

式中:$\boldsymbol{X}$为输入参数;α_0为常数;N_m为基函数的个数;$\eta_k(\boldsymbol{X})$为第k个基函数;α_k为第k个基函数的系数,通过最小二乘法确定。基函数的个数N_m通常为预设最大基函数个数,一般可取为最终MARS模型基函数数量的2倍,再由后向剪枝过程删减[20]。基函数$\eta_k(\boldsymbol{X})$可以用一个样条函数或几个现有样条函数的乘积表示,包括分段线性函数和分段三次函数。为了简便,本文采用分段线性函数来表征样条函数,样条函数可以表示为:

$$\max(0,x-c_t)=\begin{cases}x-c_t & x\geqslant c_t\\ 0 & x<c_t\end{cases} \tag{7}$$

式中:c_t为输入参数的结点取值。

MARS模型根据训练数据集自动选择基函数和结点,在前向选择中选择使得训练模型误差减小最大的基函数,当基函数数目达到预定的最大项数N_m停止前向选择过程,此过程将产生一个过拟合的模型。为选择并剔除多余基函数,基于广义交叉验证(GCV)方法对无关变量和贡献最小的基函数进行删除,防止过拟合现象[21]。GCV值越小,模型越优,GCV计算方法为:

$$GCV=\frac{\frac{1}{N_c}\sum_{i=1}^{N_c}\left[y_i-g(x_i)\right]^2}{\left[1-\frac{N_m+d_c\times(N_m-1)/2}{N_c}\right]^2} \tag{8}$$

式中:N_c为样本数量;y_i为样本实测数据值;$g(x_i)$为MARS模型预测值;d_c为惩罚因子,一般取为3[21]。MARS算法包括前向选择和后向剪枝两个步骤。前向选择是对输入的样本进行划分处理,用样条函数代替划分的小区间拟合得到新的基函数,继而得到一个拟合模型。后向剪枝用于删除拟合模型中对模型贡献度较小的基函数,常采用广义交叉验证法剔除重要度较低的基函数,避免过拟合现象,确保选取的MARS模型具有较好的泛化能力。此外,最大基函数N_m是事先预设的,若预设值不合理,可能导致最终的模型并不是最优模型。N_m需要通过尝试多组预设值,并对比MARS模型预测性能确定最终的最大基函数个数。

1.4 基于贝叶斯模型平均的边坡安全系数集合概率预测

1.4.1 贝叶斯模型平均方法

贝叶斯模型平均方法(BMA)是一种将模型自身不确定性考虑在内的统计分析方法[22],BMA以后验概率密度函数为权重对单一模型进行加权平均,通过加权平均不同模型的预测值来获取更可靠的综合预测值,同时利用集合后验概率密度函数表征模型组合的不确定性[22-24]。

假设FS_t为第t天的边坡安全系数,$Data$为Geostudio软件数值模型计算的边坡安全系数,采用不同机器学习模型$M_t=[M_t^1,M_t^2,\cdots,M_t^N]$预测第$t$天的边坡安全系数,可得到相应的预测结果$FS_t^1$,$FS_t^2,\cdots,FS_t^N$,则基于BMA的边坡安全系数集合概率预测可表示为[25]:

$$P(FS_t|Data)=\sum_{k=1}^{N}\omega_k P_k(FS_t|M_t^k,Data) \tag{9}$$

式中:ω_k为第k个机器学习M_t^k在给定数据$Data$条件下的后验概率,其为BMA第k个模型的权重系数。ω_k取值范围位于0和1之间,所有权重系数之和等于1。$P_k(FS_t|M_t^k,Data)$为给定数据样本与机器学习模型M_t^k条件下预测第t天边坡安全系数的FS_t后验概率分布。根据BMA方法,假设$P_k(FS_t|M_t^k,Data)$为正态分布[26],则:

$$P_k\left(FS_t|M_t^k,Data\right)\sim N(FS_t^k,\sigma_\varepsilon^2),k=1,2,\ldots,N \tag{10}$$

式中:FS_t^k根据数据样本和机器学习模型M_t^k预测的

第 t 天的安全系数。σ_ε 为机器学习模型 M_t^k 的标准差，以此表征第 k 个机器学习代理模型 M_t^k 估计边坡安全系数的计算误差，即模型不确定性。

由式(9)与式(10)可知，对单一机器学习代理模型预测的边坡安全系数加权平均，即为BMA平均预测值：

$$E\left[FS_t|Data\right]=\sum_{k=1}^{N}\omega_k\cdot E\left[P_k\left(FS_t|M_t^k,Data\right)\right]=\sum_{k=1}^{N}\omega_k FS_t^k \tag{11}$$

BMA预测的方差为：

$$Var\left[FS_t|Data\right]=\sum_{k=1}^{N}\omega_k\left(FS_t^k-\sum_{i=1}^{N}\omega_i FS_t^i\right)^2+\sigma_\varepsilon^2 \tag{12}$$

式(12)中BMA预测方差由两项组成，一部分来自于集合预测，另一部分来自于单一机器学习代理模型的自身误差。由于假定不同机器学习模型预测的边坡安全系数为正态分布，基于BMA预测的边坡安全系数也为正态分布，其均值根据公式(11)计算，方差根据公式(12)计算，即可得到其集合后验概率密度函数。由式(12)可知，确定权重系数 w_k 和模型误差 σ_ε 是构建边坡安全系数集合概率预测模型的关键一步。

以 $\Theta=\{\omega_k,\sigma_\varepsilon,k=1,2,...,N\}$ 表示待求的BMA参数，则关于 $\boldsymbol{\Theta}$ 的似然函数的对数形式可以表示为：

$$l(\boldsymbol{\Theta})=\log\left[\sum_{k=1}^{N}\omega_k P_k\left(FS_t|M_k,data\right)\right] \tag{13}$$

式中涉及高维求解，本文涉及权重系数与方差结果的不确定性，为了得到可靠的权重系数，因此采用自适应演化差分算法DREAM$_{(ZS)}$算法求解BMA中的未知参数[23]。DREAM$_{(ZS)}$算法是由Vrugt等[27-28]提出的一种多个马尔科夫链的并行采样方法，可以有效解决高维求解等问题。DREAM$_{(ZS)}$算法基本步骤为：

(1) 定义 T 条长度为 N_D 的马尔科夫链 $\boldsymbol{\Theta}^j$ (j=1, 2, T)；

(2) 初始化 $\boldsymbol{\Theta}^0=[\omega_1{}^0,\omega_2{}^0,\cdots,\omega_N{}^0,\sigma_\varepsilon{}^0]$；

(3) 采用混合跳转算法(包括并行方向和斯诺克更新)产生第 j 条链的建议样本 $\boldsymbol{\Theta}^j_{\text{prop}}$：

$$\boldsymbol{\Theta}^j_{\text{prop}}=\boldsymbol{\Theta}^j+\left(1_{d^*}+\boldsymbol{e}_{d^*}\right)\gamma_{d^*}\left[\mathbf{z}_j^{r_1}-\mathbf{z}_j^{r_2}\right]+\varepsilon_{d^*} \tag{14}$$

式中，d^* 为更新的维度数量，位于1和总维度数 d 之间；1_{d^*} 为长度为 d^* 的单位矢量；$\boldsymbol{e}_{d^*}$ 和 ε_{d^*} 分别从均匀分布 $\boldsymbol{U}_{d^*}(-c,c)$ 和正态分布 $N_{d^*}(0,c^*)$ 随机产生，c 和 c^* 与目标分布的宽度相比较小；$\mathbf{z}_j^{r_1}$ 和 $\mathbf{z}_j^{r_2}$ 是从不同马尔科夫链随机抽取的随机参数；γ_{d^*} 为跳转率，一般取为 $\gamma_{d^*}=\dfrac{2.38}{\sqrt{2\delta d^*}}$，$\delta$ 为产生建议样本的马尔科夫链的对数。

(4) 计算建议样本的接受率 α

$$\alpha=\frac{P\left(\boldsymbol{\Theta}^j_{\text{prop}}|\ \ d\right)}{P\left(\boldsymbol{\Theta}^j|\ \ d\right)} \tag{15}$$

(5) 产生均匀分布(0, 1)上的一个随机数 u，若 $u\leqslant\min(r,1)$，则接受 $\boldsymbol{\Theta}^j_{\text{prop}}$；否则保持当前样本；

(6) $j=j+1$，回到步骤(2)，直至 j 等于设定的马尔可夫链链数 T。

DREAM$_{(ZS)}$算法参数 $\boldsymbol{\Theta}$ 的马尔科夫链MCMC随机样本可以认为是目标分布(即式(13))的抽样，从而避免直接求解式(13)。根据参数 $\boldsymbol{\Theta}$ 的随机样本可以分别估计其统计特征，如后验均值、后验标准差或后验概率密度函数等。参数 $\boldsymbol{\Theta}$ 的后验概率可以描述BMA参数的不确定性。获得BMA模型参数如 ω_k 和 σ_ε 后，可构建融合不同机器学习的边坡安全系数集合概率预测模型。

1.4.2 模型预测性能指标

根据测试数据集，采用3个指标定量评价单个机器学习和BMA集合预报的预测精度。其中，用决定系数(R^2)、均方误差(MSE)、平均绝对误差(MAE)衡量边坡安全系数确定性预测的精度[23-24]，其计算方法如下：

$$R^2=1-\frac{\sum_{l=1}^{N_c}\left[FS_{t,true}^l-FS_{t,predict}^l\right]^2}{\sum_{l=1}^{N_c}\left[FS_{t,true}^l-\overline{FS}_{t,true}^{\,l}\right]^2} \tag{16}$$

$$MSE=\frac{\sum_{l=1}^{N_c}\left[FS_{t,true}^l-FS_{t,predict}^l\right]^2}{N_c} \tag{17}$$

$$MAE=\frac{\sum_{l=1}^{N_c}\left|FS_{t,true}^l-FS_{t,predict}^l\right|}{N_c} \tag{18}$$

式中：$FS_{t,true}^l$ 为边坡安全系数 FS_t 的实际计算值；$FS_{t,predict}^l$ 为单一机器学习或BMA集合预测值；$\overline{FS}_{t,true}^{\,l}$ 为边坡安全系数 FS_t 的实际计算值的平均值；N_c 为样本数量。

1.5 边坡时变失效概率计算

根据贝叶斯模型平均和DREAM$_{(ZS)}$算法提出融合不同机器学习的集合概率预测方法，建立不同时间边坡安全系数代理模型，可以直接采用蒙特卡洛模拟方法(MCS)计算边坡时变失效概率：

$$P_f{}^t=\frac{1}{N_P}\sum_{i=1}^{N_P}I\left[FS_t(X_i)<1.0\right],t=1,2,\ldots,T \tag{19}$$

式中:P_f^t为某一时刻t边坡失效概率,N_P为MCS模拟次数;$I[\cdot]$为失效区域的指示性函数;X_i为第i组输入参数随机样本;FS_t为依据输入参数X_i计算的t时刻边坡安全系数;T为计算时间。综上,提出方法的计算流程如图1所示,具体步骤如下:

(1)确定边坡岩土体抗剪强度参数的统计特征(包括均值、标准差、取值区间及概率分布)及水位下降速率波动范围;

(2)将岩土体抗剪强度参数及水位降速视为输入变量,采用LHS方法独立生成N_{tr}个训练样本和N_{te}个测试样本;

(3)将随机产生的岩土体抗剪强度参数及水位降速样本赋给边坡有限元模型,通过Geostudio SEEP/W模块进行边坡非饱和渗流稳定分析,在此基础上通过SLOPE/W模块进行边坡稳定性计算,获取不同时刻边坡安全系数FS_t;

(4)采用支持向量机(SVM)和多元自适应回归样条(MARS)构建不同时刻边坡安全系数代理模型,以步骤(2)中LHS方法生成的N_{tr}个训练样本作为输入,以步骤(3)中计算的不同时刻边坡安全系数FS_t作为输出,以此生成训练模型及确定性预测结果;采用步骤(2)中LHS方法独立生成的N_{te}个测试样本测试不同时刻边坡安全系数支持向量机和多元自适应回归样条代理模型的准确性;

(5)根据支持向量机(SVM)和多元自适应回归样条(MARS)两种机器学习的边坡安全系数确定性预测,利用贝叶斯模型平均将其组合加权平均,构建集合预测模型;

(6)针对组合的集合预测模型,采用$\mathrm{DREAM}_{(ZS)}$算法得到服从目标分布的BMA参数$\boldsymbol{\Theta}$的MCMC样本,并统计BMA参数$\boldsymbol{\Theta}$的后验估计(如均值、标准差、后验分布等);

(7)根据步骤(6)所确定的集合预测模型权重系数及模型误差,采用公式(11)和公式(12)构建边坡安全系数集合概率预测模型,并根据SVM和MARS两种机器学习的训练模型采用测试数据集得到每一天边坡安全系数预测值,结合式(11)和(12)获取边坡安全系数集合概率预测模型;

(8)基于测试数据集评估SVM模型、MARS模型与BMA集合概率预测模型的性能指标;

(9)采用MCS方法产生N_c组输入参数随机样本,代入不同时刻边坡安全系数集合概率预测模型,计算不同时刻N_c个边坡安全系数,采用蒙特卡洛模拟方法统计计算边坡不同时刻失效概率P_f^t。

2 研究区概况

本研究边坡位于三峡库区重庆段,地跨东经105°11′~110°11′、北纬28°10′~32°13′之间的青藏高原与长江中下游平原的过渡地带,边坡地处北半球亚热带内陆的四川盆地东部,地处川东平行岭谷中。据寸滩水文站资料,由于受到库水位变化,该边坡常伴有浅层破坏。本文以该边坡为例说明所提BMA集合概率预测方法的有效性。边坡地质剖面如图2(a)所示,边坡长度为185m,坡高为220m。根据工程地质勘探资料,坡体出露的地层由新至老依次为第四系全新统(Q_4^{ml})素填土、残坡积层(Q_4^{el+dl})粉质粘土、强风化泥岩和泥岩。其中素填土材料主要采用动力触探试验进行判断,其余岩土体材料物理力学参数根据地勘资料和当地经验值取值,边坡岩土体物理力学参数,包括岩土体重度(γ),粘聚力(c),有效内摩擦角(φ)、饱和渗透系数(K_s)和水位降速(v)如表1所示,土水特征曲线拟合曲线采用Fredlund & Xing模型,参数依据经验取值。

本文基于SEEP/W进行边坡非饱和渗流分析,计算时间步为15天的边坡孔隙水压力分布,如图2(b)所示,边坡右侧181.60m水位以下为定水头边界,左侧定水头边界为220m,底部设置为不透水边界,然后利用SLOPE/W模块的Morgenstern-Price方法计算边坡安全系数FS_t,边坡渗流及稳定性分析结果如图2(b)所示,最小边坡安全系数为1.106。受到三峡水库调度影响,研究区内库水位每年汛期骤降,其边坡稳定性也随之变化。因此,本文主要考虑水位骤降条件下岩土体抗剪强度参数空间变异性的边坡可靠度分析,暂不考虑岩土体重度、饱和渗透系数空间变异性,同时也不考虑降雨强度不确定性。由于每年三峡水库动态调蓄,汛期水位下降并非以某一固定速率均匀下降。为此,本文将水位降速视为随机变量,假定其在取值区间范围内服从均匀分布,通过标准差表征其波动性。参考以往研究[29-30],假定边坡岩土体抗剪强度参数在其取值区间范围内服从对数正态分布,边坡稳定性分析模型参数统计特征如表1所示。

3 基于BMA集合代理模型的库岸边

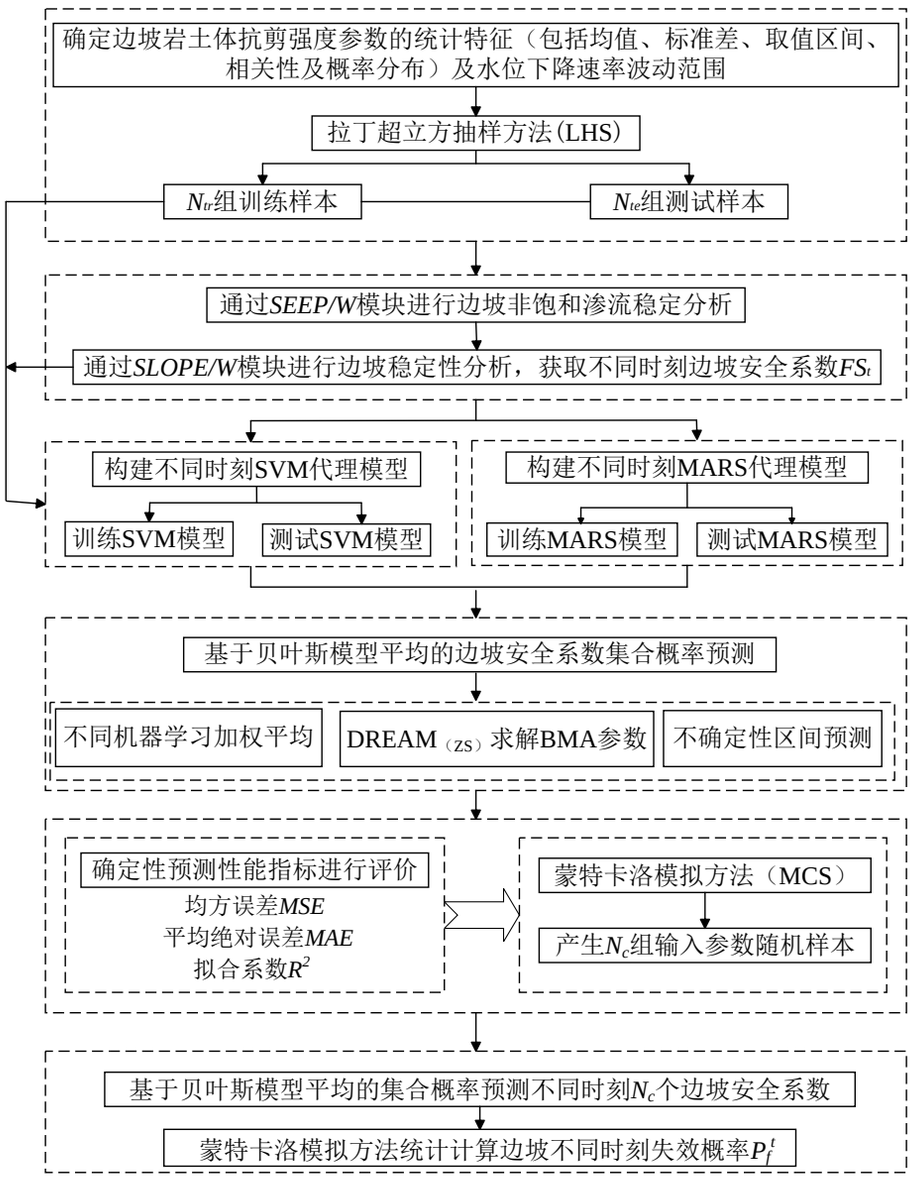
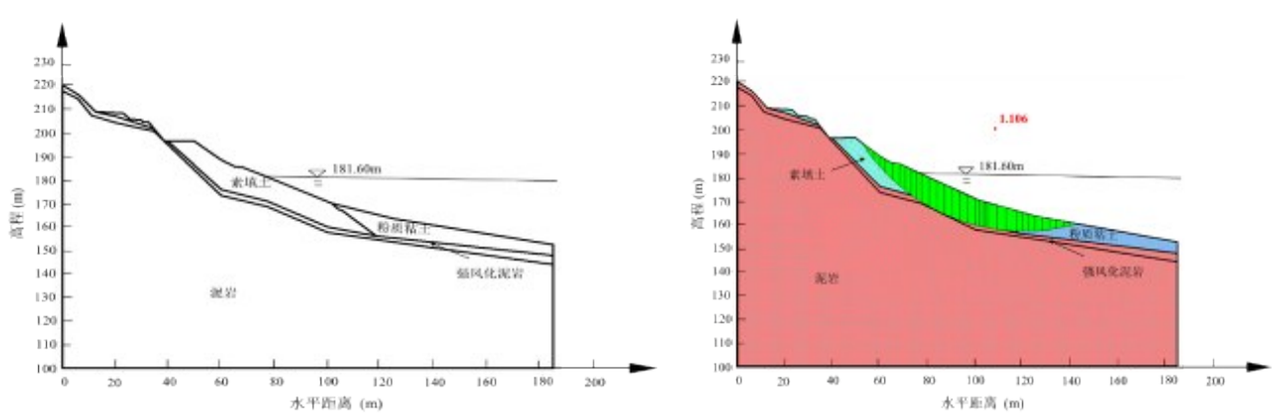


图 1　计算流程图

Fig. 1　Flow chart



(a)库岸边坡地质剖面　　(b)边坡稳定性确定性分析

图 2　库岸边坡地质剖面及边界条件

Fig. 2　Illustration of geometry and boundary conditions for the reservoir slope

表1 边坡岩土体抗剪强度与水位降速统计特征

Table1 Statistical information of shear strength of soils and rocks and water level drawdown

参数	均值	取值范围	变异性系数	分布类型	相关性
素填土重度γ_1(kN•m^{-3})	20.50	/	/	/	/
素填土黏聚力c_1(kPa)	4.03	(1.45, 10.74)	0.3	对数正态	−0.5
素填土有效内摩擦角φ_1(°)	40.92	(18.80, 85.53)	0.3	对数正态	
素填土饱和渗透系数K_{s1}(m/s)	3.15×10^{-6}	/	/	/	/
粉质粘土重度γ_2(kN•m^{-3})	19.90	/	/	/	/
粉质粘土黏聚力c_2(kPa)	22.75	(7.53, 68.33)	0.3	对数正态	−0.5
粉质粘土有效内摩擦角φ_2(°)	12.47	(5.03, 29.67)	0.3	对数正态	
粉质粘土饱和渗透系数K_{s2}(m/s)	6.31×10^{-7}	/	/	/	/
强风化泥岩重度γ_3(kN•m^{-3})	25.40	/	/	/	/
强风化泥岩黏聚力c_3(kPa)	22.44	(7.18, 58)	0.3	对数正态	−0.5
强风化泥岩有效内摩擦角φ_3(°)	21.80	(9.93, 47.80)	0.3	对数正态	
强风化泥岩饱和渗透系数K_{s3}(m/s)	7.34×10^{-7}	/	/	/	/
泥岩重度γ_4(kN•m^{-3})	25.40	/	/	/	/
泥岩黏聚力c_4(kPa)	355.88	(101.52, 922.28)	0.3	对数正态	−0.5
泥岩有效内摩擦角φ_4(°)	31.68	(12.86, 67.22)	0.3	对数正态	
泥岩饱和渗透系数K_{s4}(m/s)	3.67×10^{-7}	/	/	/	/
水位降速v(m/d)	2.50	(0,5)	0.5	均匀分布	/

坡时变可靠度分析

3.1 基于贝叶斯模型平均的边坡安全系数集合概率预测模型

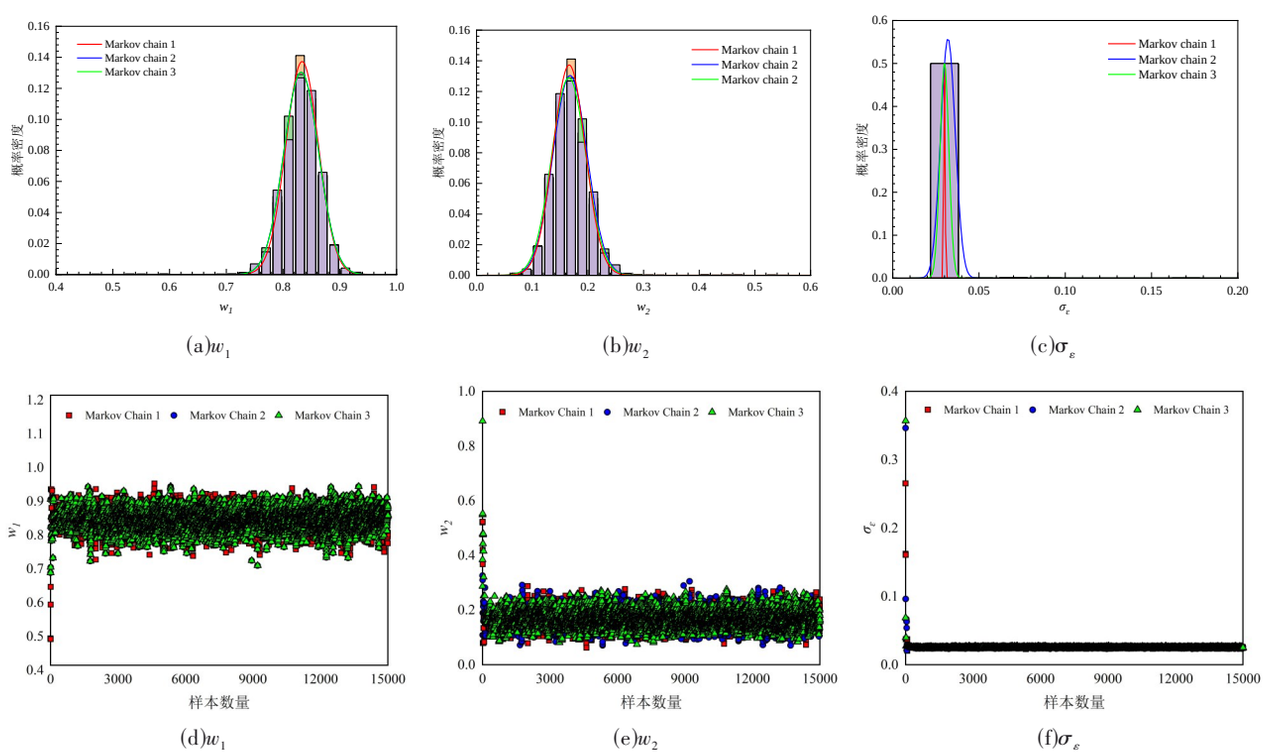
根据表1中边坡岩土体抗剪强度参数以及水位降速共9个输入参数的取值区间,采用LHS方法独立生成9个输入参数的训练样本和测试样本。综合考虑计算精度以及计算效率,本文采用LHS方法随机生成输入参数的1000组样本作为训练数据集,100组样本作为测试数据集。然后,将边坡岩土体抗剪强度参数以及水位降速共9个输入参数的训练样本赋值给边坡有限元模型,基于SEEP/W和SLOPE/W模块进行边坡非饱和渗流和稳定性分析,计算15天时间步内每天的边坡安全系数;将训练样本作为SVM和MARS模型的输入分别得到两种机器学习预测的边坡安全系数。本文在训练SVM模型的过程中,采用径向基函数作为核函数,通过网格搜索法并观察模型评价指标R^2、MSE和MAE变化,最终15天的SVM模型的惩罚因子为32,核系数为0.0625;在MARS模型建模过程中,通过不断调试基函数的预设个数,观察模型评价指标变化[21],最终15天MARS模型的最优预设最大基函数数目为32。表2所示为SVM和MARS两种机器学习的确定性预测结果。

根据SVM和MARS两种机器学习的训练数据集确定性预测结果,采用贝叶斯平均法构建边坡安全系数集合概率预测模型。将SVM和MARS训练学习得到的边坡安全系数确定性预测结果带入公式(4)进行加权平均。采用DREAM$_{(ZS)}$算法计算BMA模型中的未知参数w_1、w_2以及相应的模型误差σ_ε。以时间步第一天为例,采用SVM和MARS两种机器学习预测的边坡安全系数进行加权平均。由公式(4)和(5)可知,构建集合概率预测模型需要计算权重系数w_1、w_2以及相应的模型误差σ_ε。本文采用1000组训练数对SVM和MARS分别构建相应的预测模型,从而得到SVM和MARS两种机器学习的训练数据集确定性预测结果,并将其代入公式(4)。然后,采用DREAM$_{(ZS)}$算法结合权重系数和相应的模型误差,即表3中第一天边坡安全系数集合预测模型的w_1、w_2、σ_ε,可构建融合SVM和MARS两种机器学习的边坡安全系数集合概率预测模型。再利用100组测试数据集获取集合概率模型预测性能指标,即R^2、MSE、MAE,进而评估其准确性。本文DREAM$_{(ZS)}$算法中设置并行运行的马尔科夫链数目为3条,每条链上MCMC随机样本数为15000。如图3所示,为第七天集合预测模型权重系数和模型误差的样本数量统计结果和概率分布,其中w_1、w_2分别表示SVM和MARS模型的权重系数,σ_ε为模型误差,而且w_1、w_2、σ_ε服从正态分布。本文取单一模型权重系数分布函数的均值作为权重系数的最终取值。表3给出了时间步为15天的边坡安全系数集合概率预测的权重系数与模型不确定性。

表 2 SVM 和 MARS 确定性预测性能指标

Table 2 Performance metrics for deterministic prediction of SVM and MARS

时间(d)	训练						测试					
	SVM			MARS			SVM			MARS		
	R^2	*MSE*	*MAE*	R^2	*MSE*	*MAE*	R^2	*MSE*	*MAE*	R^2	*MSE*	*MAE*
1	0.98	0.0013	0.0188	0.99	0.000782	0.0182	0.96	0.0036	0.0296	0.96	0.0036	0.0292
2	0.98	0.0011	0.0177	0.98	0.0011	0.0234	0.97	0.0025	0.0307	0.95	0.0034	0.0343
3	0.98	0.000978	0.0173	0.98	0.0013	0.0262	0.96	0.0025	0.0298	0.95	0.003	0.0345
4	0.99	0.000662	0.0147	0.98	0.0012	0.0251	0.96	0.0019	0.0291	0.96	0.002	0.033
5	0.98	0.000834	0.0167	0.97	0.0014	0.0269	0.95	0.0021	0.0301	0.94	0.0026	0.0352
6	0.98	0.000993	0.018	0.97	0.0014	0.0270	0.94	0.0023	0.0313	0.93	0.0029	0.0364
7	0.98	0.00099	0.018	0.97	0.0013	0.0258	0.94	0.0022	0.029	0.93	0.0025	0.0331
8	0.98	0.000897	0.0172	0.97	0.0014	0.0263	0.94	0.0021	0.0281	0.94	0.0021	0.0302
9	0.98	0.000852	0.0167	0.97	0.0013	0.0258	0.94	0.0021	0.0276	0.94	0.0021	0.0314
10	0.98	0.00839	0.0168	0.97	0.0012	0.0248	0.94	0.002	0.0273	0.94	0.0019	0.0287
11	0.98	0.00079	0.0164	0.97	0.0012	0.0244	0.94	0.002	0.0261	0.94	0.0019	0.0287
12	0.98	0.000779	0.0162	0.97	0.0012	0.0246	0.93	0.0021	0.0255	0.92	0.0026	0.0336
13	0.98	0.000627	0.0142	0.97	0.0011	0.0242	0.93	0.0022	0.0264	0.93	0.0022	0.0302
14	0.98	0.000647	0.0144	0.97	0.0011	0.0242	0.92	0.0024	0.0266	0.93	0.0022	0.0305
15	0.99	0.000341	0.0104	0.97	0.0011	0.0235	0.94	0.0019	0.0262	0.93	0.002	0.0293



(a)w_1 (b)w_2 (c)σ_ε

(d)w_1 (e)w_2 (f)σ_ε

图 3 第七天集合概率模型权重系数和模型误差的后验样本

Fig. 3 Posterior samples of weight coefficients and model error for ensemble probabilistic model at the 7-th day

图 4 给出了 BMA 集合代理模型不确定性预测区间,15 天 BMA 集合代理模型预测的安全系数与数值模拟计算值很接近,本文所提方法构建的 15 天 BMA 集合概率预测模型预测的安全系数值均在不确定性区间内,由此可见,所提方法能提供准确的预测结果。结合表 3 和图 4 还可以看出,BMA 集合模型预测的不确定性越大,安全系数预测结果的不确定性越大,如第二天集合概率预测模型不确定性为 0.25,第十五天集合概率预测模型不确定性为 0.017,相应的第十五天边坡安全系数预测不确定性

表3 BMA集合预测的模型参数

Table 3 Results of BMA model parameters

时间(d)	ω_1	ω_2	σ_ε
1	0.516	0.484	0.022
2	0.781	0.219	0.025
3	0.845	0.155	0.024
4	0.906	0.094	0.020
5	0.900	0.100	0.024
6	0.861	0.139	0.025
7	0.832	0.168	0.025
8	0.876	0.124	0.025
9	0.878	0.122	0.025
10	0.870	0.130	0.023
11	0.844	0.156	0.023
12	0.837	0.163	0.022
13	0.881	0.119	0.020
14	0.871	0.129	0.020
15	0.960	0.040	0.017

区间小于第二天集合概率预测结果。BMA集合预测模型不确定性预测区间有助于定量的考虑集合代理模型预测过程中的不确定性。

表4给出了集成SVM和MARS两种机器学习的15天库岸边坡安全系数集合概率预测模型的性能指标,即R^2、MSE、MAE。图5给出了15天BMA集合概率预测模型的训练和测试效果,可以看出训练数据中R^2均在0.9758以上,测试数据集中R^2均在0.9257以上。说明所训练的15天BMA集合概率预测模型训练和测试效果均较好。为了详细说明,图6给出了其中第7天BMA集合概率预测模型和边坡有限元渗流及稳定性分析计算的FS相关性图,可以看出,训练结果和测试结果中数据点基本都集中在45°线上,说明BMA集合概率预测模型能够精准的预测边坡安全系数FS。

表4 基于贝叶斯模型平均的集合概率预测模型的确定性预测性能指标

Table 4 Performance metrics for deterministic prediction of ensemble surrogate models based on Bayesian model average

时间	训练			测试		
(d)	R^2	MSE	MAE	R^2	MSE	MAE
1	0.9905	0.00079	0.017	0.9677	0.003	0.0268
2	0.9869	0.000909	0.0174	0.9673	0.0023	0.0295
3	0.985	0.000894	0.0173	0.9619	0.0022	0.0295
4	0.9881	0.000634	0.0147	0.9649	0.0018	0.0286
5	0.9835	0.000799	0.0167	0.9547	0.002	0.0297
6	0.9794	0.000926	0.0179	0.9468	0.0022	0.0303
7	0.9785	0.000912	0.0177	0.9456	0.0021	0.0278
8	0.979	0.000848	0.017	0.9438	0.002	0.0274
9	0.9792	0.000808	0.0165	0.9417	0.002	0.0272
10	0.9792	0.000784	0.0166	0.9431	0.0019	0.0265
11	0.9800	0.000734	0.0161	0.9419	0.0019	0.0258
12	0.9800	0.000712	0.0158	0.9384	0.002	0.0252
13	0.9830	0.000588	0.0141	0.9318	0.0021	0.0256
14	0.9823	0.000601	0.0142	0.9257	0.0022	0.026
15	0.9896	0.00034	0.0104	0.9379	0.0019	0.0257

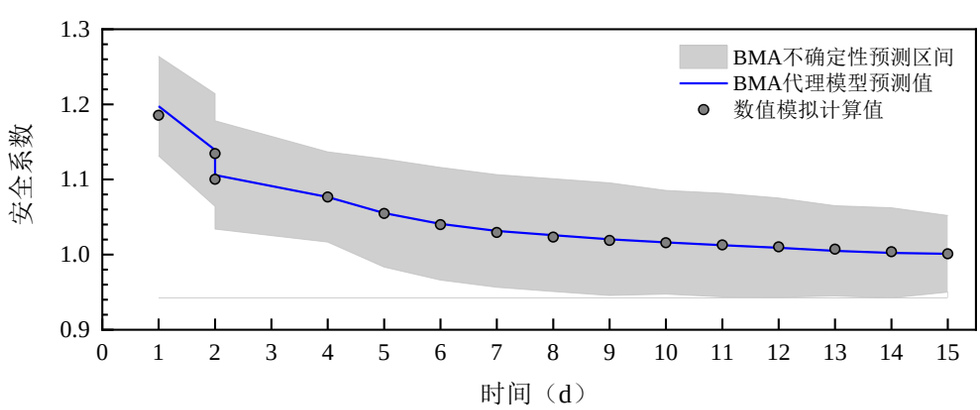


图4 集合预测模型不确定性区间

Fig. 4 Uncertainty intervals of ensemble prediction model

为了进一步说明所构建的15天边坡安全系数集合概率预测模型的准确性。本文对比100组测试样本分别采用BMA集合概率预测模型、单个机器学习预测模型和边坡非饱和渗流及稳定性分析获取的安全系数计算15天的失效概率,如图7所示,采用BMA集合概率预测模型估计的P_f和重复的边坡非饱和渗流及稳定性分析计算的P_f十分接近。如图8所示,15天BMA集合代理模型边坡失效概率估计的最大相对偏差为0.03,最小相对偏差为0,平均相对误差为0.012,标准差为0.0094。所构建的

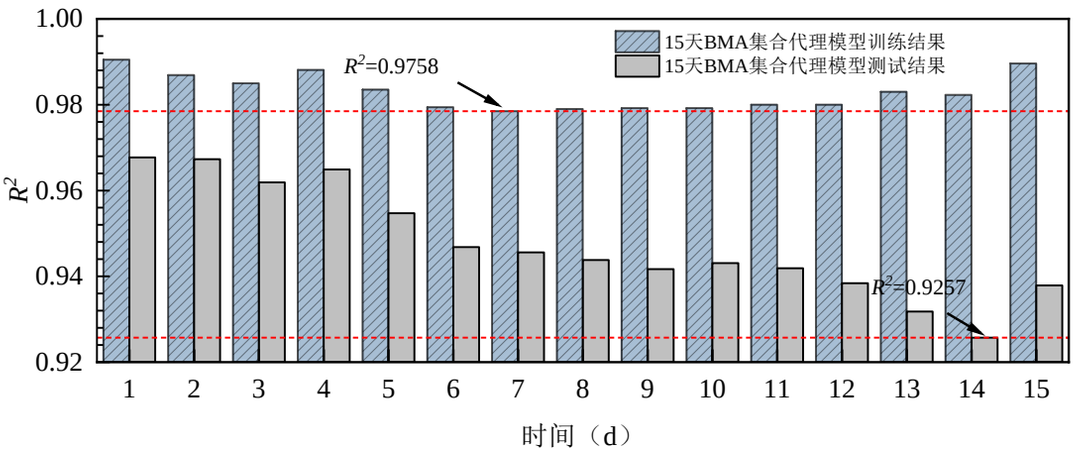
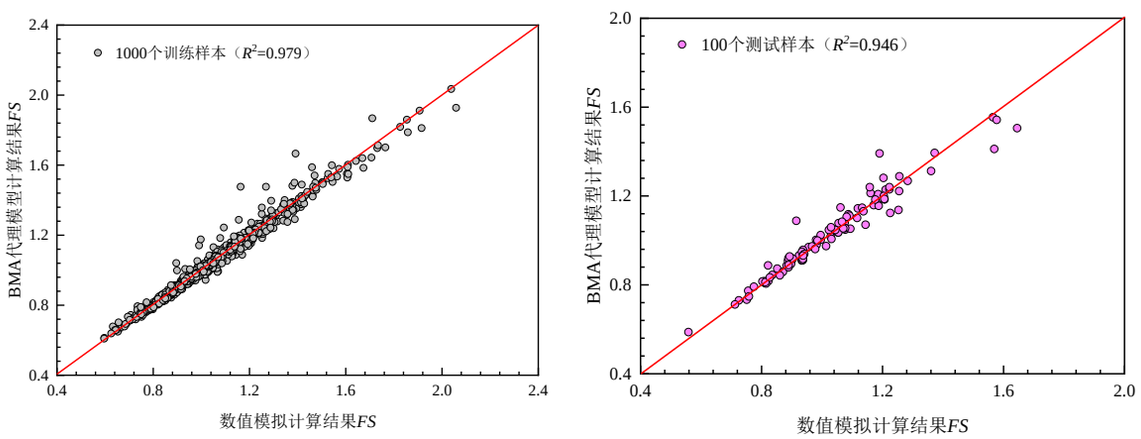


图5　15天边坡安全系数集合概率预测模型训练和测试结果

Fig. 5　Training and testing results of 15-day ensemble prediction model for slope safety factor



（a）训练结果　　（b）测试结果

图6　第七天边坡安全系数集合概率预测模型训练和测试结果

Fig. 6　Training and testing results of 7th day ensemble prediction model for slope safety factor

15天BMA集合概率预测模型预测整体偏差较小，准确性比单一机器学习模型高，可以代替成千上万次重复的边坡非饱和渗流及稳定性分析。

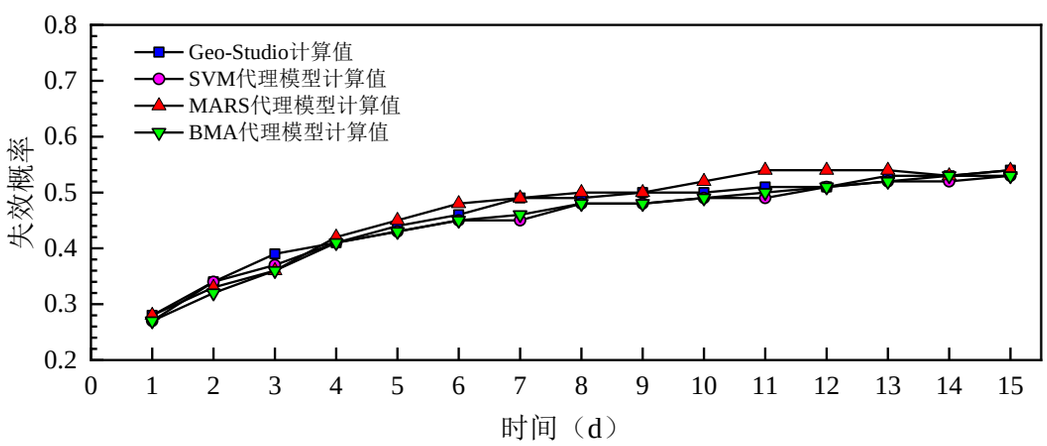


图7　BMA集合概率预测模型和边坡非饱和渗流及稳定性分析计算的边坡时变失效概率

Fig. 7　Time-varying failure probability of reservoir slope calculated by BMA ensemble probability prediction model and slope unsaturated seepage and stability analysis

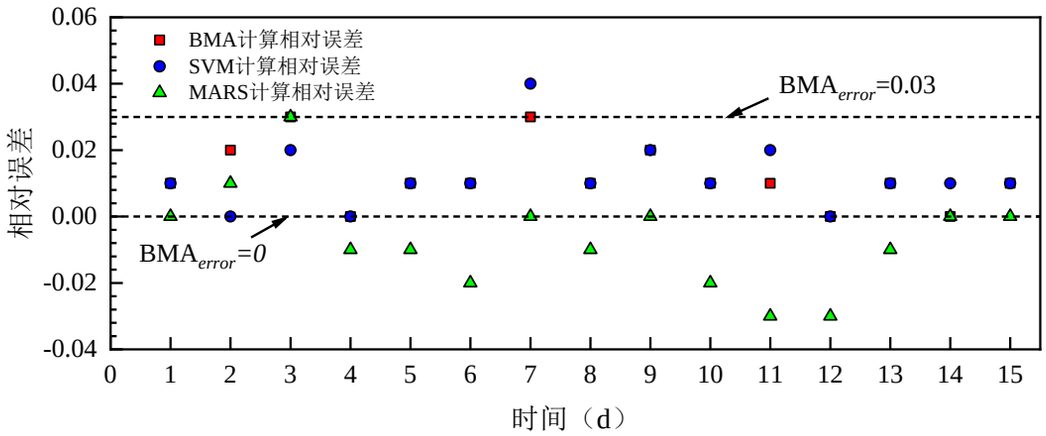


图8 BMA集合概率预测模型预测边坡时变失效概率的相对误差

Fig. 8 Relative error of time-varying slope failure probability calculated by BMA ensemble probability prediction model

3.2 BMA集合概率预测模型与单一机器学习代理模型预测精度对比

为了进一步评估BMA集合概率预测模型和单一机器学习代理模型(SVM、MARS)的预测性能,对比表2和表4可知,将SVM和MARS模型进行贝叶斯方法加权平均后,15天边坡安全系数集合概率预测的测试数据集拟合系数R^2均值为0.95,SVM和MARS两个机器学习预测的拟合系数R^2均值分别为0.94和0.94。15天边坡安全系数BMA集合概率预测的预测误差指标*MSE*取值范围为0.0018～0.003,平均值为0.0021。而SVM和MAR单个机器学习预测边坡安全系数*MSE*取值均介于0.0019～0.0036之间,平均值分别为0.0023和0.0025。显然,BMA集合概率预测的均方误差小于单一机器学习。对于预测误差指标*MAE*,15天边坡安全系数BMA集合概率预测的*MAE*取值范围介于0.025～0.030,平均值为0.027,而SVM和MARS单个机器学习预测的平均绝对误差分别介于0.026～0.031和0.029～0.036,平均值分别为0.028和0.032。相较于单个机器学习,BMA集合概率预测模型预测边坡安全系数的误差较低,其平均精度分别提高了3.6%和15.6%。

为了详细说明,图9给出了第七天边坡安全系数BMA集合概率预测模型与单一机器学习代理模型的预测性能指标。由图9可知,BMA集合概率预测模型的R^2=0.95,SVM和MARS的决定系数分别为0.94和0.93,集合两种机器学习后边坡安全系数预测的决定系数明显提高;对于*MSE*和*MAE*指标,SVM模型的数值分别为0.0022和0.0290,MARS模型的数值分别为0.0025和0.0331,而BMA集合预测模型的*MSE*和*MAE*指标分别为0.0021和0.0278,均小于单一机器学习代理模型。相比于单一的SVM模型,BMA集合概率预测模型的*MSE*和*MAE*指标分别降低了4.1%和4.5%。然而,相比于单一MARS模型,BMA集合概率预测模型的*MSE*和*MAE*指标均降低了16%。

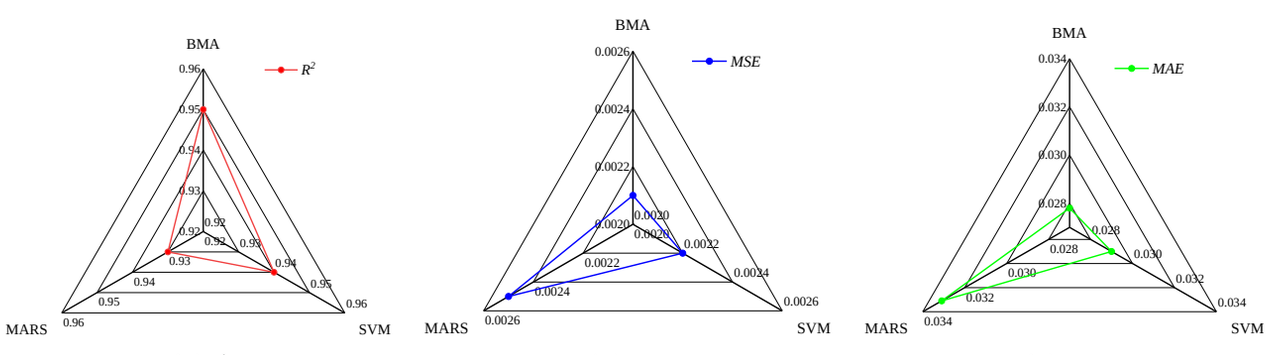


图9 第七天BMA集合概率预测模型与单一机器学习代理模型的预测性能指标的对比

Fig. 9 The calculated results of the prediction performance indexes of the models on the 7th

表5给出了15天BMA集合概率预测模型和单一机器学习模型失效概率的计算相对误差,其中,SVM模型计算相对误差范围介于0~0.04,MARS模型计算相对误差范围介于0.03~0.03,BMA模型计算相对误差范围介于0~0.03,显然,采用BMA集合概率预测模型预测的边坡失效概率的相对误差范围小于单一机器学习模型,这进一步说明通过BMA方法加权平均不同机器学习模型后,边坡失效概率的预测精度有所提高。需要注意的是,本研究仅集合了SVM和MARS两种机器学习方法的预测优势,所提方法也适用于集合其他机器学习算法。同时,边坡安全系数集合概率预测精度受集合的机器学习算法数量及其预测性能影响。为获取更准确、更可靠的边坡安全系数集合概率预测模型,如何选择最佳模型组合方法仍有待研究。

表5 单一机器学习模型与BMA集合概率预测模型失效概率计算相对误差对比

Table 5 Comparison of relative error of failure probability calculated by the single machine learning algorithm and BMA ensemble model

指标	SVM	MARS	BMA
最小偏差	0	−0.03	0
最大偏差	0.04	0.03	0.03
均值	0.012	−0.0067	0.012
标准差	0.0101	0.0154	0.0094

4 结 论

合理预测边坡安全系数是评估滑坡失效概率的关键,准确估计边坡安全系数并合理表征其预测不确定性对实现其精准预测至关重要。本文基于拉丁超立方抽样技术、贝叶斯模型平均、DREAM$_{(ZS)}$算法提出了融合不同机器学习的库岸边坡时变可靠度分析,以三峡库区重庆段某库岸边坡为例验证了所提集合概率预测模型的有效性。主要结论如下:

(1)本文所提融合不同机器学习的边坡时变可靠度分析方法包括拉丁超立方抽样、边坡有限元渗流及稳定性分析、BMA集合概率预测模型构建和时变失效概率计算,可以合理同时考虑水位降速不确定性与边坡岩土体抗剪强度参数空间变异性对边坡失效概率的影响。相对于单个机器学习,基于贝叶斯模型平均的边坡安全系数的集合预测误差指标*MSE*和*MAE*均有所降低,可为复杂库岸边坡失效概率计算提供有效的分析工具。

(2)本文所提的边坡安全系数BMA集合概率预测代理模型,综合了SVM和MARS的预测优势,提高了模型的整体预测精度。本文所构建的15天BMA集合概率预测模型预测的安全系数值均在不确定性预测区间内,能够定量表征考虑集合模型预测过程中的不确定性。

(3)融合不同机器学习的边坡安全系数集合概率预测模型相较于单一机器学习模型,预测的边坡安全系数更接近于数值模型计算值,且相对误差绝对值整体小于单一机器学习模型。BMA集合概率预测模型计算所提边坡时变失效概率相对误差均值为0.012,标准差为0.0094。

本文采用三峡库区库岸边坡验证了所提融合不同机器学习的库岸边坡时变可靠度分析方法的有效性,该方法同样适用于其他不同地质条件的边坡时变可靠度分析,此时需要针对不同边界条件构建合适的机器学习代理模型,进而采用BMA方法融合不同代理模型预测的边坡安全系数。同时,合适的机器学习集合成员会显著影响BMA集合概率预测模型的预测性能,本文仅考虑了SVM和MARS,为获取更准确、更可靠的边坡安全系数集合概率预测模型,可以考虑更多的机器学习算法,且如何选择最佳模型组合方法仍有待进一步研究。此外,本文所提方法是纯数据驱动方法,未来应当结合具有物理机制的边坡稳定性分析模型,构建具有可解释性与物理合理性的库岸边坡时变可靠度预测模型。

参 考 文 献:

[1] 苏爱军. 湖北省三峡库区滑坡防治地质勘察与治理工程技术规定[M]. 武汉: 中国地质大学出版社, 2003.
Su A J. Technical regulation of geological investigation and engineering design for landside in Three Gorges Reservoir, Hubei Province[M]. Wuhan: China university of Geosciences press, 2003. (in Chinese with English abstract)

[2] 李长冬, 龙晶晶, 姜茜慧, 等. 水库滑坡成因机制研究进展与展望[J]. 地质科技通报, 2020, 39(1): 67-77.
Li C D, Long J J, Jiang X H, et al. Advance and prospect of formation mechanism for reservoir landslide[J]. Bulletin of Geological Science and Technology, 2020, 39(1): 67-77. (in Chinese with English abstract)

[3] 仉文岗, 王尉, 高学成. 库区水位下降对库岸边坡稳定性的影响[J]. 武汉大学学报(工学版), 2019, 52(1): 21-26.
Zhang W G, Wang W, Gao X C. Influences of reservoirs water level drawdown on slope stability[J]. Engi-

neering Journal of Wuhan University, 2019, 52(1): 21-26. (in Chinese with English abstract)

[4] 刘新喜, 夏元友, 张显书, 等. 库水位下降对滑坡稳定性的影响[J]. 岩石力学与工程学报, 2005, (08): 1439-1444.
Liu X X, Xia Y Y, Zhang X S, et al. Effects of drawdown of reservoir water level on landslide stability. [J]. Chinese Journal of Rock Mechanics and Engineering, 2005, (08): 1439-1444. (in Chinese with English abstract)

[5] 廖红建, 盛谦, 高石夯, 等. 库水位下降对滑坡体稳定性的影响[J]. 岩石力学与工程学报, 2005, (19): 56-60.
Liao H J, Sheng Q, Gao S H, et al. Influence of drawdown of reservoir water level on landslide stability. [J]. Chinese Journal of Rock Mechanics and Engineering, 2005, (19): 56-60. (in Chinese with English abstract)

[6] 李典庆, 蒋水华, 周创兵, 等. 考虑参数空间变异性的边坡可靠度分析非侵入式随机有限元法[J]. 岩土工程学报, 2013, 35(08): 1413-1422.
Li D Q, Jiang S H, Zhou C B, et al. Reliability analysis of slopes considering spatial variability of soil parameters using non-intrusive stochastic finite element method. [J]. Chinese Journal of Geotechnical Engineering, 2013, 35(08): 1413-1422. (in Chinese with English abstract)

[7] 武梦婷, 陈秋松, 齐冲冲. 基于机器学习的边坡安全稳定性评价及防护措施[J]. 工程科学学报, 2022, 44(02): 180-188.
Wu M T, Chen Q S, Qi C C. Slope safety, stability evaluation, and protective measures based on machine learning[J]. Chinese Journal of Engineering, 2022, 44(02): 180-188. (in Chinese with English abstract)

[8] 姬建, 姜振, 殷鑫, 等. 边坡随机场数字图像特征CNN深度学习及可靠度分析[J]. 岩土工程学报, 2022, 44(08): 1463-1473.
Ji J, Jiang Z, Yin X, et al. Slope reliability analysis based on deep learning of digital images of random fields using CNN[J]. Chinese Journal of Geotechnical Engineering, 2022, 44(08): 1463-1473. (in Chinese with English abstract)

[9] Wang L, Wu C, Tang L, et al. Efficient reliability analysis of earth dam slope stability using extreme gradient boosting method[J]. Acta Geotechnica, 2020, 15: 3135-3150.

[10] Liu L L, Zhang S H, Cheng Y M, et al. Advanced reliability analysis of slopes in spatially variable soils using multivariate adaptive regression splines. Geosci Front 10 (2): 671 - 682[J]. 2019.

[11] 张天龙, 曾鹏, 李天斌, 等. 基于主动学习径向基函数的边坡系统可靠度分析[J]. 岩土力学, 2020, 41(09): 3098-3108.
Zhang T L, Zeng P, Li T B, et al. System reliability analyses of slopes based on active-learning radial basis function[J]. Rock and Soil Mechanics, 2020, 41(09): 3098-3108. (in Chinese with English abstract)

[12] Zhang W G, Wu C Z, Tang L B, et al. Efficient time-variant reliability analysis of Bazimen landslide in the Three Gorges Reservoir Area using XGBoost and LightGBM algorithms[J]. Gondwana Research, 2023, 123: 41-53.

[13] Mckay M D, Beckman R J, Conover W J. A comparison of three methods for selecting values of input variables in the analysis of output from a computer code[J]. Technometrics, 1979, 21(2): 239-245.

[14] 蒋水华, 李典庆, 周创兵. 基于拉丁超立方抽样的边坡可靠度分析非侵入式随机有限元法[J]. 岩土工程学报, 2013, 35(S2): 70-76.
Jiang S H, Li D Q, Zhou C B. Non-intrusive stochastic finite element method for slope reliability analysis based on Latin hypercube sampling[J]. Chinese Journal of Geotechnical Engineering, 2013, 35(S2): 70-76. (in Chinese with English abstract)

[15] 吴振君, 王水林, 葛修润. LHS方法在边坡可靠度分析中的应用[J]. 岩土力学, 2010, 31(4): 1047-1054.
Wu Z J, Wang S L, Ge X R. Application of Latin hypercube sampling technique to slope reliability analysis [J]. Rock and Soil Mechanics, 2010, 31(4): 1047-1054. (in Chinese with English abstract)

[16] Fredlund D G, Rahardjo H, Fredlund M D. Unsaturated soil mechanics in engineering practice[M]. John Wiley & Sons, 2012.

[17] Fredlund D G, Xing A. Equations for the soil-water characteristic curve[J]. Canadian geotechnical journal, 1994, 31(4): 521-532.

[18] Chen Z Y , Morgenstern N R. Extensions to the generalized method of slices for stability analysis[J]. Canadian geotechnical journal, 1983, 20(1): 104-119.

[19] Cortes C, Vapnik V. Support-vector networks[J]. Machine Learning, 1995, 20: 273-297.

[20] Friedman J H. Multivariate adaptive regression splines [J]. Annals of Statistics, 1991, 19: 1-67.

[21] 仉文岗, 洪利, 黎泳钦. 基于多元自适应回归样条的高维岩土工程问题分析[J]. 河海大学学报(自然科学版), 2019, 47(4): 359-365.
Zhang W G, Hong L, Li Y Q. Analysis of multi-dimensional geotechnical engineering problems based on multivariate adaptive regression splines[J]. Journal of

Hohai University(Natural Sciences), 2019, 47(4): 359-365.

[22] 董磊华, 熊立华, 万民. 基于贝叶斯模型加权平均方法的水文模型不确定性分析[J]. 水利学报, 2011, 42(9): 1065-1074.
Dong L H, Xiong L H, Wan M. Uncertainty analysis of hydrological modeling using the Bayesian Model Averaging Method[J]. Shuili Xuebao, 2011, 42(9): 1065-1074. (in Chinese with English abstract)

[23] 田密, 熊自民, 李丽华. 基于多机器学习融合的泥石流冲出距离贝叶斯集合概率预测方法[J]. 武汉大学学报(工学版): 1-18, 2024. (网络首发)
Tian M, Xiong Z M, Li L H. Bayesian ensemble probabilistic prediction method for debris-flow inundated area based on ensembles of multiple machine learning algorithms[J]. Engineering Journal of Wuhan University: 1-18, 2024. (in Chinese with English abstract)

[24] 仉文岗, 顾鑫, 刘汉龙, 等. 基于贝叶斯更新的非饱和土坡参数概率反演及变形预测[J]. 岩土力学, 2022, 43(04): 1112-1122.
Zhang W G, Gu X, Liu H L, et al. Probabilistic back analysis of soil parameters and displacement prediction of unsaturated slopes using Bayesian updating[J]. Rock and Soil Mechanics, 2022, 43(04): 1112-1122. (in Chinese with English abstract)

[25] Vrugt J A, Robinson B A. Treatment of uncertainty using ensemble methods: Comparison of sequential data assimilation and Bayesian model averaging[J]. Water Resources Research, 2007, 43(1).

[26] Vrugt J A, Diks C G H, Clark M P. Ensemble Bayesian model averaging using Markov chain Monte Carlo sampling[J]. Environmental fluid mechanics, 2008, 8: 579-595.

[27] Vrugt J A, Ter Braak C J F, Clark M P, et al. Treatment of input uncertainty in hydrologic modeling: Doing hydrology backward with Markov chain Monte Carlo simulation[J]. Water Resources Research, 2008, 44(12).

[28] Vrugt J A. Markov chain Monte Carlo simulation using the DREAM software package: Theory, concepts, and MATLAB implementation[J]. Environmental Modelling & Software, 2016, 75: 273-316.

[29] Tan X H, Hu N, Li D, et al. Time-variant reliability analysis of unsaturated soil slopes under rainfall[J]. Geotechnical & Geological Engineering, 2013, 31: 319-327.

[30] Wu Y P, Miao F S, Li L W, et al. Time-varying reliability analysis of Huangtupo Riverside No. 2 Landslide in the Three Gorges Reservoir based on water-soil coupling[J]. Engineering Geology, 2017, 226 (2): 267 - 276.