

# 基于自适应采样和代理模型的滑带土参数反演

高 玮, 李培远, 赵志浩, 张林, 钱宇晨  
(河海大学土木与交通学院, 南京 210098)

**摘 要:** 针对当前反演中为代理模型构建训练样本时采样方法的不足, 引入 CV-Voronoi 自适应序列采样法进行训练样本的生成, 采用麻雀搜索算法 (SSA) 优化孪生支持向量回归 (TSVR) 模型得到 SSA-TSVR 代理模型, 以 SSA 作为优化算法, 提出新的反演技术。以白水河滑坡滑带土抗剪强度参数反演为例对新反演方法进行了工程应用验证, 比较了不同样本生成方法 (自适应序列采样法、正交设计和均匀设计) 及代理模型 (SVR、TSVR、SSA-SVR 及 SSA-TSVR) 对反演结果的影响。结果表明自适应序列采样方法有明显优势, 使得反演误差降低了一半以上, 其不仅能够显著改善反演效果, 还能够用更少样本达到更高的精度。采用的 SSA-TSVR 代理模型具有更高的反演精度和计算速度, 为岩土工程力学参数反演提供了一种新的思路。

**关键词:** 强度参数; 自适应序列采样; 反演; SSA-TSVR 代理模型; 滑带土

**文献标识码:** A

**作者简介:** 高玮(1971—), 男, 教授, 博士生导师, 主要从事人工智能在岩土工程中的应用、岩石力学、隧道工程等方面的教学与科研工作。E-mail: wgaowh@163.com。

## Parameter Inversion of Slip Zone Soil Based on Adaptive Sampling and Surrogate Models

GAO Wei, LI Peiyuan, ZHAO Zhihao, ZHANG Lin, QIAN Yuchen  
(College of Civil and Transportation Engineering, Hohai University, Nanjing 210098, China)

**Abstract:** To solve the shortcomings of sampling methods for constructing training dataset of surrogate models in current inverse analysis, this study introduces the CV-Voronoi adaptive sequential sampling method for generating training samples. This sampling method does not require the determination of the sample size in advance and can adaptively add new samples based on the information of the existing sample points. Moreover, the sparrow search algorithm (SSA) is employed to optimize the twin support vector regression (TSVR) model, and the SSA-TSVR surrogate model is then generated. Based on the adaptive sequential sampling method and SSA-TSVR model, using SSA as the optimization algorithm, a new inversion technique is proposed. Using the shear strength parameter inversion of the Baishui River landslide slip zone soil as an example, the new inversion method was validated through engineering application. The effects of different sample generation methods (adaptive sequential sampling, orthogonal design, and uniform design) and surrogate models (SVR, TSVR, SSA-SVR, and SSA-TSVR) on the inversion results were compared. The results showed that the adaptive sequential sampling method has a significant advantage, reducing the inversion error by more than half. This method not only significantly improves the inversion performance, but also achieves higher accuracy with fewer samples. The SSA-TSVR surrogate model offers higher inversion accuracy and computational speed, providing a new approach for inversion analysis of geotechnical engineering mechanical parameters.

**Key words:** Strength parameters; Adaptive sequential sampling; Inverse analysis; SSA-TSVR surrogate model; Slip zone soil

## 1 引言

在滑坡治理工程中, 岩土材料的非线性使数值方法比解析法更为常用。但数值方法求解需要事先确定材料模型及其参数, 尤其是对滑坡稳定性和支护设计至关重要的滑带土抗剪强度参数。虽然室内试验和原位测试也能确定滑带土试样的力学参数, 但岩土体非均质性和空间变异性使试验结果不能代表整个滑带的力学参数, 可能使数值模型模拟结果与实际情况相差较大。位移反演法通过现场实测位移信息来反演数值

模型中的参数, 能解决上述问题, 故在岩土工程中得到了广泛应用。因此, 基于监测位移信息进行滑带土参数反演的研究对滑坡治理工程具有重大意义。

位移反演法根据是否考虑量测信息和岩土体的不确定性分为确定性反演和不确定性反演。后者 (如贝叶斯反演) 虽能更好地处理不确定性问题, 但计算复杂度, 结果解释困难<sup>[1]</sup>, 目前应用较少。相反, 确定

性反演是目前研究的主流，主要分为正反演（优化反演法）及逆反演两种。正反演采用优化技术寻求与实测位移误差最小的参数向量，需多次正向分析计算<sup>[2-5]</sup>。逆反演则通过拟合参数向量与位移的关系进行反演，操作较简单<sup>[6]</sup>。但对于复杂非线性问题并伴随监测噪声时，通常只能采用优化反演法来寻求满意解。

由于优化反演法需多次进行耗时的正分析计算，建立代理模型来代替数值计算已成为主要思路<sup>[2-4]</sup>。相关研究集中于算法的改进或者引入新算法或代理模型<sup>[2-3]</sup>、利用非位移信息<sup>[4]</sup>及改进反演目标函数<sup>[5]</sup>。这些方法通常基于数值模型，利用正交或均匀设计（一次采样法）构建训练样本，训练代理模型并通过反演算法得到反演参数。但一次采样法需事先固定样本量并均匀布点<sup>[7]</sup>，难以针对复杂非线性问题在高误差区域增加样本密度。自适应序列采样法能克服此局限，无需预设样本量，可根据已有样本信息自适应添加新样本点，可以保证非线性区域的样本密度<sup>[8]</sup>，从而以较低成本构建更精确的代理模型<sup>[9]</sup>。其中基于交叉验证（Cross-Validation, CV）的自适应序列采样法使用运行成本低廉的交叉验证过程估计预测误差，可用于位移反演中的多种代理模型。Xu等<sup>[10]</sup>提出鲁棒性强的 CV-Voronoi 自适应序列采样法，利用 Voronoi 图对数据空间进行划分，结合交叉验证找出误差最大的 Voronoi 单元并在其中添加样本点，可以获得较好的预测效果<sup>[11-12]</sup>。

为完善反演的采样方法并提高反演计算效率，本文引入 CV-Voronoi 自适应序列采样法进行样本生成，使用麻雀搜索算法（Sparrow Search Algorithm, SSA）优化的孪生支持向量回归（Twin Support Vector Regression, TSVR）作为代理模型来建立滑坡滑带土抗剪强度参数与监测点位移的映射关系，并采用 SSA 寻找最终反演结果，从而提出基于自适应序列采样法及新代理模型的位移反演方法。最后，基于白水河滑坡的基本工程信息对所提出方法进行了工程应用验证。

## 2 基本算法

### 2.1 孪生支持向量回归

TSVR 是类比孪生支持向量机设计思想提出的<sup>[13]</sup>，比支持向量回归训练速度更快，泛化能力更强。

TSVR 的基本原理为：针对训练集  $\{A_i, n_i\}_{i=1}^l$  ( $A_i \in \mathbb{R}^n$  为输入特征， $n_i$  为输出值)，TSVR 寻找两个非平行超平面来确定回归函数的上边界和下边界，超平面形式分别为：

$$f_1(v) = w_1^T v + b_1 \quad (1)$$

$$f_2(v) = w_2^T v + b_2 \quad (2)$$

其中， $v$  是输入特征向量； $f_1(v)$ 、 $f_2(v)$  为超平面预测值； $w_1^T$ 、 $w_2^T$  是输入数据点特征权重的向量； $b_1$ 、 $b_2$  是偏置项。约束条件确保样本点位于超平面两侧的不敏感带内：

$$n_i \leq f_1(A_i) + \xi_i, \quad \forall i = 1, 2, \dots, l \quad (3)$$

$$n_i \geq f_2(A_i) - \xi_i - \eta_i, \quad \forall i = 1, 2, \dots, l \quad (4)$$

其中，惩罚因子  $C_1, C_2 > 0$ ；不敏感带宽度  $\epsilon_1, \epsilon_2 \geq 0$ ； $\xi$  和  $\eta$  为松弛变量，用于允许一些样本点偏离间隔边界。引入拉格朗日乘子，将原二次规划问题映射到对偶空间转化为更易求解的线性方程组形式：

$$\begin{cases} \alpha = (G^T G)^{-1} (f - G^T H \gamma) \\ \gamma = (H^T H)^{-1} (g - H^T G \alpha) \end{cases} \quad (5)$$

其中， $\alpha$ 、 $\gamma$  为拉格朗日乘子， $G = [A \ e]$ ， $f = N - e\epsilon_1$ ， $g = N + e\epsilon_2$ 。求解  $\alpha$ 、 $\gamma$ ，得到两个超平面，从而最终得到目标回归函数  $f(v) = (f_1(v) + f_2(v))/2$ 。对于非线性问题， $f_1(v) = w_1^T K(v^T, A^T) + b_1$  和  $f_2(v) = w_2^T K(v^T, A^T) + b_2$ 。求解二次规划问题时，令  $A = K(A, A^T)$ ，其中  $K$  为核函数。

### 2.2 麻雀搜索算法

麻雀搜索算法是一种群智能优化算法<sup>[14]</sup>，研究证明<sup>[15]</sup>，与其他 5 种典型算法（蝙蝠算法、蜻蜓算法、蝗虫算法、鲸鱼算法及灰狼算法）相比，麻雀搜索算法对的全局搜索能力与迭代速度都有明显优势。SSA 根据麻雀的习性将种群中的个体分为三类（发现者、加入者及警戒者），通过一定策略不断更新个体位置进行寻优（如图 1 所示）。

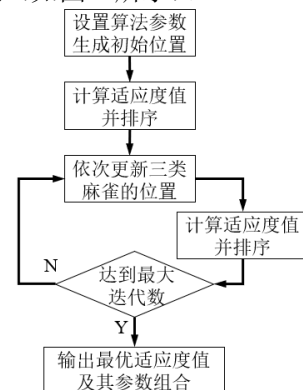


图 1 SSA 算法流程图

Fig.1 Flow chart of SSA

SSA 的具体计算流程为：

(1) 设置目标函数、最大迭代次数、种群规模和三类麻雀占种群的比值，随机生成初始个体位置（待优化参数组合）；

(2) 计算个体适应度值，将麻雀位置按目标函数数值从小到大排序；

- (3) 依次更新发现者、加入者、警戒者位置；
- (4) 计算新个体目标函数值，重新排序；
- (5) 判断是否满足停止条件（达到最大迭代次数）：满足则退出，并输出最优目标函数值及个体位置，否则返回（3）。

个体位置的更新方法为：

- 1) 发现者个体位置更新采用式（6）确定：

$$W_{i,j}^{t+1} = \begin{cases} W_{i,j}^t \cdot \exp\left(-\frac{i}{\alpha \cdot \text{item}_{\max}}\right) & R_2 < ST \\ W_{i,j}^t + Q \cdot L & R_2 \geq ST \end{cases} \quad (6)$$

其中，个体数量  $i=1,2,\dots,n$ ；问题维数  $j=1,2,\dots,d$ ； $W_{i,j}^t$  表示第  $i$  只麻雀在第  $j$  个维度的位置； $t$  表示当前迭代次数； $\alpha \in (0,1]$  为随机数； $\text{item}_{\max}$  是最大迭代次数； $R_2 \in [0,1]$  为随机数，表示警戒者发布警报的预警值； $ST \in [0.5,1]$  是安全数，其在计算开始之前确定； $Q$  为服从正态分布的随机数； $L$  表示  $1 \times d$  元素均为 1 的矩阵。

- 2) 加入者个体位置更新采用式（7）确定：

$$W_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{W_{\text{worst}} - W_{i,j}^t}{t^2}\right) & i > \frac{n}{2} \\ W_{\min}^{t+1} + |W_{i,j}^t - W_p^{t+1}| \cdot B^+ \cdot L & i \leq \frac{n}{2} \end{cases} \quad (7)$$

其中， $W_{\text{worst}}$  为全局目标函数值最大个体的位置； $W_{\min}^{t+1}$  为单次迭代中目标函数值最小个体的位置； $B^+ = B^T(BB^T)^{-1}$ ，其中， $B$  表示一个  $1 \times d$  的矩阵，矩阵每个元素随机赋值为 1 或 -1。

- 3) 警戒者个体位置更新采用式（8）确定：

$$W_{i,j}^{t+1} = \begin{cases} W_{\text{best}}^t + \beta \cdot |W_{i,j}^t - W_{\text{best}}^t| & f_i > f_g \\ W_{i,j}^t + S \cdot \left( \frac{|W_{i,j}^t - W_{\text{worst}}^t|}{(f_i - f_w) + \varepsilon} \right) & f_i = f_g \end{cases} \quad (8)$$

其中， $W_{\text{best}}$  是全局目标函数值最小个体的位置； $\beta$  是服从平均数为 0、方差为 1 的正态分布随机数，其作用是控制步长； $S$  为随机数， $S \in [-1,1]$ ； $f_i$  是当前麻雀个体的目标函数值； $f_w$  和  $f_g$  分别为目前全局最差位置和最优位置对应个体的适应度值； $\varepsilon$  为一个足够小的常数，以免发生分母为 0 的情形，需要事先假定。

### 3 代理模型建立

在进行反演前需要建立待反演参数与实测位移之间的映射关系，可以通过上面介绍的 SSA 算法来优化 TSVR 的参数建立代理模型。

#### 3.1 多输出回归链模型

TSVR 为单输出回归模型。在实际工程中往往不止一个监测点，采用多个监测点会使结果更精确，因此，需要采用某种策略建立多输出回归模型，可以采

用问题转化法<sup>[16]</sup>将多目标回归问题转换为多个单目标回归问题。可以采用回归链模型将多个回归模型按顺序排列成一条链，每个模型不仅使用原始特征，还使用链中前面模型的预测结果作为额外特征，模型间的信息能充分利用，不会忽略每个输出量的内在联系。

回归链训练时，将输出变量随机排列成链，为每个输出变量建立单独的回归模型。假设  $X$  和  $Y$  是两个随机向量， $X$  为  $X$  的定义域，即输入空间。假设  $X$  有  $d$  个输入变量  $X_1, \dots, X_d$ ； $Y$  有  $m$  个输出变量  $Y_1, \dots, Y_m$ 。将输出变量随机排列成链  $I = \{Y_1, Y_2, \dots, Y_m\}$  ( $I$  表示有序集)，第一个模型对  $Y_1$  目标输出变量进行预测，具有形式  $h_1: X \rightarrow R$  (实数)。后续模型  $h_t$  ( $t > 1$ ) 在训练集  $D_t = \{(x_1^t, y_1^t), \dots, (x_n^t, y_t^t)\}$  中训练，训练时输入向量  $x_t^i = [x_1^i, \dots, x_d^i, y_1^i, \dots, y_{t-1}^i]$  为初始输入向量和先前模型的目标输出向量。对  $Y_t$  预测的模型形式为  $h_t: X \times R^{t-1} \rightarrow R$ 。

训练后的模型链，要获得训练集外的输入变量  $x^q$  的  $\hat{y}^q$ ，需要依次将  $x_t^q = [x_1^q, \dots, x_d^q, \hat{y}_1^q, \dots, \hat{y}_{t-1}^q]$  代入到  $h_t$  中，最终得到  $\hat{y}^q = [h_1(x^q), h_2(x_2^q), \dots, h_m(x_m^q)]$ 。上述回归链的训练和预测过程如图 2 所示。

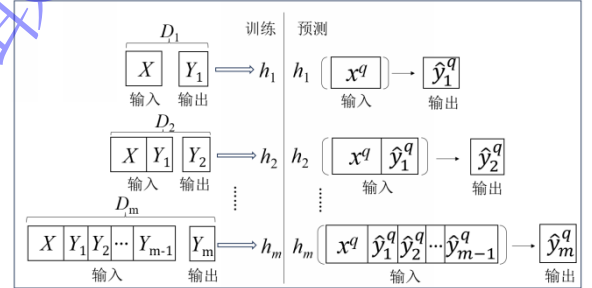


图 2 回归链模型建立示意图

Fig.2 Schematic diagram of regression chain model

#### 3.2 SSA-TSVR 回归链代理模型

滑带土参数反演属高度复杂非线性问题，难以解析表达。本文利用 TSVR 构建参数到监测位移的非线性映射关系：

$$\begin{cases} \text{TSVR}(Z): \mathbb{R}^m \rightarrow \mathbb{R} \\ U = \text{TSVR}(Z) \\ Z = (z_1, z_2, \dots, z_n) \end{cases} \quad (9)$$

其中， $Z = (z_1, z_2, \dots, z_n)$  为待反演参数向量， $\text{TSVR}(Z)$  为建立的代理模型， $\mathbb{R}^m$  为  $m$  维实数集， $\mathbb{R}$  为 1 维实数集， $U$  为关键点监测位移。

构建 TSVR 回归链代理模型需优化其超参数：不敏感参数 ( $\epsilon_1, \epsilon_2$ ) 和惩罚因子 ( $C_1, C_2$ )。本文采用 SSA 进行优化，流程如下：

- (1) 数据预处理。将 CV-Voronoi 采样生成的样本集按 4:1 随机划分为训练集和测试集，分别用于模



型训练与测试评价。对所有特征进行线性归一化处理（式 10），映射至[0, 1]范围：

$$x_{nom} = \frac{x_o - x_{min}}{x_{max} - x_{min}} \quad (10)$$

其中， $x_o$  为原始数据； $x_{min}$  及  $x_{max}$  为数据中的最小及最大值； $x_{nom}$  为归一化后的数据；

（2）确定算法参数。设置 SSA 算法种群数量、三类麻雀的比例和迭代次数等参数，确定 4 个参数  $\epsilon_1$ 、 $\epsilon_2$ 、 $C_1$ 、 $C_2$  的取值范围；

（3）SSA 参数寻优。为提高模型泛化能力，将 SSA 算法种群初始位置对应的反演参数代入到 TSVR 回归链模型中进行五折交叉验证，每轮训练完成后，使用该轮测试集进行预测，计算五轮测试集上的平均预测均方误差作为优化目标函数。根据 SSA 算法的策略，迭代更新参数，重复代理模型的交叉验证。记录每次迭代的均方误差及对应的参数，逐步找到使均方误差最小的参数，将其代入 TSVR 回归链模型进行训练，得到优化后的 SSA-TSVR 回归链代理模型。

## 4 基于 CV-Voronoi 的自适应采样方法

代理模型建立后需要通过数值模拟或模型试验等方法来得到待反演参数与对应位移的数据来训练代理模型。本文使用 CV-Voronoi 采样完成上述过程，采样过程分为两部分：使用 Voronoi 图对空间进行区域划分；根据交叉验证确定新增样本点。

### 4.1 样本空间划分

Voronoi 图是由连续多边形组成的图形，每个多边形区域由相邻两点之间连线的垂直平分线围成。该方法从直观上定义了样本点在设计空间上的有效作用范围，为参数空间的每个样本点划分区域，从而在最敏感的区域增加样本点。假设样本点集合为  $p = \{p_1, p_2, \dots, p_m\}$ ，考虑采用 Voronoi 多边形将设计空间根据样本点划分成一系列的 Voronoi 单元  $c = \{c_1, c_2, \dots, c_m\}$ ，第  $i$  个 Voronoi 单元  $C_i$  的空间定义为：

$$dom(p_i, p_j) = \{p \in \mathbb{R}^d \mid \|p - p_i\| \leq \|p - p_j\|\} \quad (11)$$

$$c_i = \bigcap_{p_j \in P, j \neq i} dom(p_i, p_j) \quad (12)$$

其中， $dom(p_i, p_j)$  表示在样本空间内，距离样本点  $p_i$  比其它样本点  $p_j$  更近的点。

以二维空间为例（见图 3），任意一个 Voronoi 单元  $c_i$  内只存在一个样本点  $p_i$ ，且该样本点为该单元的中心，因此 Voronoi 单元  $c_i$  可以看作样本点  $p_i$  的有效影响范围。




图 3 二维空间样本点 Voronoi 划分

Fig.3 Voronoi partitioning of sample points in two-dimensional space

### 4.2 确定新增样本

划分空间区域后，需要对模型预测精度最差的区域添加样本点，通过 K-Fold 交叉验证来确定每个区域的预测误差<sup>[12]</sup>。K-Fold 交叉验证法将样本集随机分成  $k$  组 ( $k \leq n$ ) 互斥的子集  $\{V_1, V_2, \dots, V_k\}$ ，训练时轮流选取一组作为测试集，其余组作为训练集，分别计算各集中样本点的预测均方误差。多输出问题的表达式为：

$$e(V_i) = \sum_{j=1}^n \left( f(V_{i,j}) - \tilde{f}^i(V_{i,j}) \right)^2 / n \quad (i=1, 2, \dots, k; j=1, 2, \dots, n) \quad (13)$$

其中， $f(V_{i,j})$  为第  $i$  个集合  $V_i$  样本的第  $j$  个实际值， $\tilde{f}^i$  为由除集合  $V_i$  以外其它已知样本点构建的代理模型， $\tilde{f}^i(V_{i,j})$  为  $V_i$  所有样本的第  $j$  个预测值。

由此可以计算每个区域内中心样本点预测值的均方误差，均方误差最大的区域为采样点不足的区域。对于多维问题，Voronoi 单元难以用数学方法表示，可用蒙特卡洛方法生成随机点来代替单元<sup>[11]</sup>。滑带土抗剪强度参数反演问题为二维问题，每个单元的边界可以确定，故采用与均方误差最大单元中心样本点距离最远的单元顶点作为新增样本点。

### 4.3 自适应序列采样法流程

CV-Voronoi 采样方法主要思路为根据某种试验设计原则选取较少数量的初始点，初始点数量建议为  $5 \times n$ （参数维数）<sup>[10]</sup>。通过 Voronoi 图划分空间区域，采用交叉验证确定敏感区域并在其中选择新增点，直到达到误差要求。如图 4 所示，该方法具体流程为：

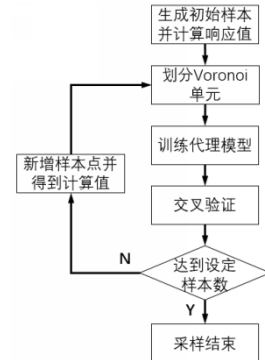


图 4 CV-Voronoi 自适应序列采样法流程图

Fig.4 CV-Voronoi adaptive sampling flowchart

(1) 采用均匀设计方法, 在参数空间内选取少量样本, 通过数值模型得到样本点的计算值;

(2) 为参数空间的样本点划分 Voronoi 单元;

(3) 采用当前样本点及其对应计算值训练代理模型;

(4) 用 K-Fold 交叉验证得到各样本点对应预测值和计算值的均方误差 (MSE);

$$MSE(\hat{\theta}) = E(\hat{\theta} - \theta)^2 \quad (14)$$

其中,  $\hat{\theta}$  为预测值,  $\theta$  为计算值。

(5) 判断是否达到设定的样本数, 如已达到则迭代结束。如未达到, 则将均方误差最大单元与其相邻均方误差最大单元的一个公共顶点作为新增样本点, 计算其对应的问题计算值并返回 (2)。

#### 4.4 采样方法验证

下面采用三个数值算例直观验证自适应序列采样方法, 选取常用的正交设计与均匀设计进行对比研究。

(1) Easom 函数 (图 5 (a))

$$y = -\cos(x_1)\cos(x_2)\exp(-(x_1 - \pi)^2 - x_2 - \pi^2) \quad (15)$$

其中,  $x_1 \in [0, 7]$ ,  $x_2 \in [0, 7]$ 。

(2) Trigonometric 函数 (图 5 (b))

$$y = \sin(x_1)\cos(x_2) \quad (16)$$

其中,  $x_1 \in [-3, 3]$ ,  $x_2 \in [-3, 3]$ 。

(3) Peaks 函数 (图 5 (c))

$$y = 3(1 - x_1)^2 \exp(-x_1^2 - x_2 + 1^2) - 10\left(\frac{x_1}{5} - x_1^3 - x_2^5\right) \exp(-x_1^2 - x_2^2) - \frac{1}{3} \exp(-x_1 + 1^2 - x_2^2) \quad (17)$$

其中,  $x_1 \in [-5, 5]$ ,  $x_2 \in [-5, 5]$ 。




图 5 数值算例函数图形

Fig.5 Functions of numerical examples

使用 CV-Voronoi 自适应序列采样法对以上三个算例进行采样, 初始样本点取 10 个, 添加 90 个样本点, 其分布如图 6 所示。作为比较, 采用正交设计和均匀设计各取 100 个样本点, 其分布如图 7、8 所示。




图 6 自适应序列采样样本点分布

Fig.6 Sample point distributions of adaptive sampling




图 7 正交设计样本点分布

Fig.7 Sample point distributions of orthogonal design




图 8 均匀设计样本点分布

Fig.8 Sample point distributions of uniform design

可以看出, 与正交设计和均匀设计相比, CV-Voronoi 自适应序列采样法可以搜寻到非线性区域并在其中设置更多样本点。将三组样本用 SSA-TSVR 代理模型进行训练, 并进行 5 折交叉验证, 得到每轮均方误差 (MSE) 的平均值及决定系数 ( $R^2$ ) 的平均值, 结果汇总如表 2 所示。

表 2 数值算例结果

Table 2 Results of numerical example

采样方法	评价指标	Easom 函数	Trigonometric 函数	Peaks 函数
自适应序列采样	MSE 平均值	$9.6 \times 10^{-3}$	$3.2 \times 10^{-6}$	$1.9 \times 10^{-2}$
	$R^2$ 平均值	0.79	0.99	0.34
正交设计	MSE 平均值	$7.5 \times 10^{-3}$	$8.8 \times 10^{-5}$	$8.9 \times 10^{-3}$
	$R^2$ 平均值	$-7.0 \times 10^7$	0.91	$-3.3 \times 10^8$
均匀设计	MSE 平均值	$8.4 \times 10^{-3}$	$1.5 \times 10^{-5}$	$9.8 \times 10^{-3}$
	$R^2$ 平均值	0.72	0.99	0.21

由表 2 可知, 对于较规则的 Trigonometric 函数, 三种采样方法训练出的代理模型拟合效果都较好,  $R^2$  均高于 0.90。自适应序列采样和均匀设计得到的样本训练出的代理模型拟合效果更好,  $R^2$  平均值高于 0.99, 优于正交设计; 对于非线性较强的 Easom 函数、Peaks 函数, 正交设计样本训练出的代理模型  $R^2$  小于 0, 原因为样本量较小, 且强非线性测试函数导致测试集上可能出现异常值。在 MSE 平均值相近的情况下, 自适应序列采样得到样本训练出的代理模型  $R^2$  平均值均大于均匀设计样本训练出的代理模型, 说明自适应序列采样相比一次采样提高了模型训练效果。综上, 对于所测试的不同函数, 自适应序列采样法均能获得最优的模型性能, 显著优于均匀设计与正交设计。

## 5 滑带参数反演

### 5.1 反演算法

本文提出的位移反演算法首先用自适应序列采样法和有限元计算构建训练样本, 再通过 SSA 优化 TSVR 参数, 建立描述滑坡滑带土抗剪强度参数与监测点位移映射关系的代理模型, 最后基于监测位移,

采用 SSA 搜索得到反演结果。算法流程如图 9 所示。




图 9 反演算法流程

Fig.9 Flow chart of inverse algorithm

反演方法的具体计算过程为：

(1) 根据勘察资料、试验数据等确定待反演参数的取值范围，采用 CV-Voronoi 自适应序列采样法结合有限元模拟进行正分析计算。构建代理模型所需的训练样本。将训练样本进行线性归一化；

(2) 基于训练样本，采用 SSA 对 TSVR 中的参数进行优化，以测试集上的均方误差为目标函数，迭代搜索找到拟合和泛化能力最好的参数组合及其对应的 TSVR 回归链模型。通过优化后的 SSA-TSVR 回归链模型建立待反演参数与监测点位移的映射关系；

(3) 基于 SSA-TSVR 回归链模型，根据实际监测位移，采用 SSA 搜寻抗剪强度参数，使所有监测点实际位移值与代理模型预测值的均方误差最小，从而得到反演参数计算结果。

## 5.2 计算模型

白水河滑坡位于三峡大坝上游 56km（秭归县境内）。自 2003 年三峡水库蓄水及降雨影响，该滑坡持续变形并多次预警。本文基于其监测数据<sup>[6]</sup>，采用所提位移反演算法反演滑带土粘聚力（ $c$ ）和内摩擦角（ $\phi$ ），以验证算法有效性。

选取 2007 年 2 月 6 日到 2007 年 3 月 18 日期间的监测资料进行研究，该年每月库水位变动及降雨情况如图 10 所示。三峡库区滑坡的变形主要受库水位变动与降雨的影响<sup>[18]</sup>，因此本文主要考虑降雨和库水位工况。需要说明的是，不同时间段内反演得到的参数是动态变化的，但本文研究目的为验证反演方法。为了研究方便，这里仅选取单个时段进行反演研究，实际上，考虑到参数的动态性可以选取多个时间段进行反演研究。




图 10 白水河滑坡 2007 年降雨量及长江水位

Fig.10 Rainfall and Yangtze River water level of Baishuihe landslide in 2007

如图 11 所示，选取了白水河滑坡 I - I' 和 II - II' 主滑方向两个剖面上变化规律较明显的监测点 XD02、XD04、ZG93、ZG118 的监测数据进行反演研究。

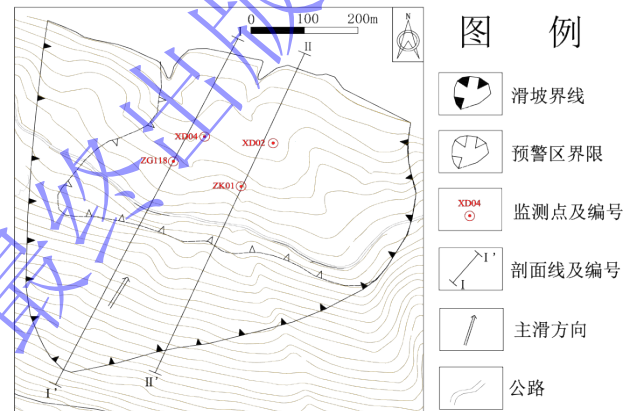


图 11 白水河滑坡平面图

Fig.11 Plan map of Baishuihe landslide

利用有限元方法建立预警区浅层滑坡的二维平面应变模型（图 12），滑带为最下一层单元，平均厚度 0.5m，其余单元为滑体。材料采用弹塑性 Mohr-Coulomb 模型，单元类型均为 CPE4P，I - I' 剖面模型的单元数为 6138 个，节点数为 6542 个（图 12a）。II - II' 剖面模型的单元数为 4575 个，节点数为 4939 个（图 12b）。模型包含了白水河滑坡的堆积层（碎块石土、粉质粘土、粘土）和浅层滑带（含碎石或含角砾粉质粘土）。滑体表面为自由渗出边界，滑带下设置为不透水边界，计算工况为库水位从 154 米下降到 151 米，通过设置多个分析步来模拟水位匀速下降，降雨分别取二月和三月的平均降雨强度。初始地应力采用软件的自动平衡法，使模型产生指定允许的位移变化来自动计算其自重应力（图 13），不考虑构造应力。



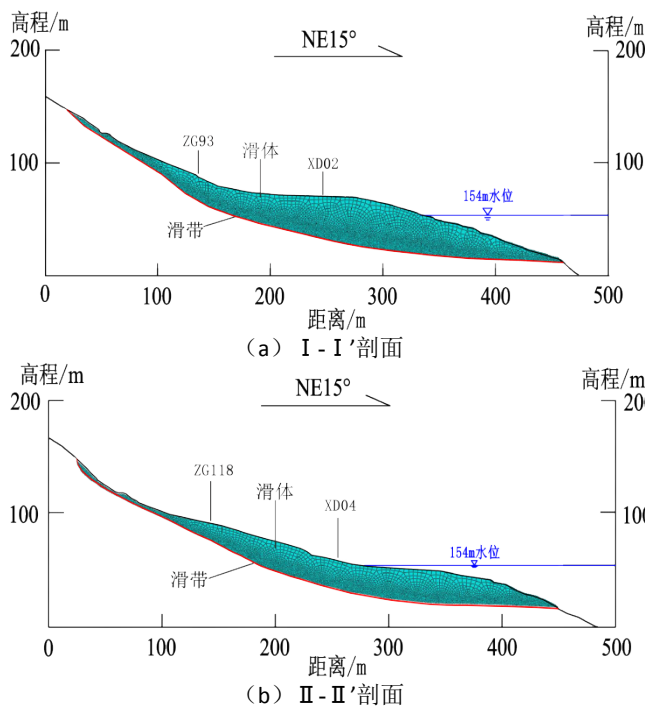


图 12 白水河滑坡 I - I' 和 II - II' 数值模型

Fig.12 Numerical model of sections I-I' and II-II' for Baishuihe landslide

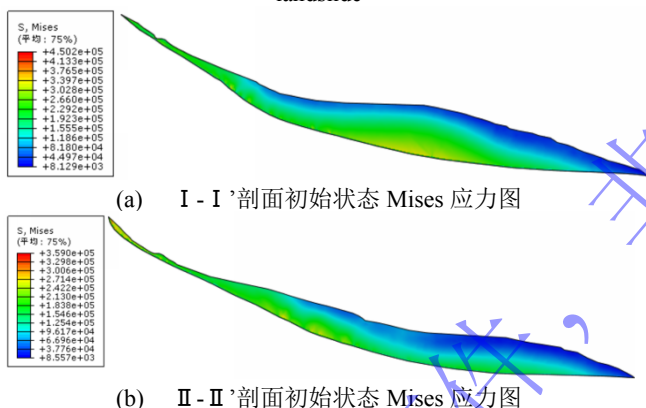


图 13 白水河滑坡 I - I' 和 II - II' 初始地应力状态计算结果  
Fig.13 Initial geo-stress states for sections I-I' and II-II' of the Baishuihe landslide

根据勘察资料和相关文献中滑体、滑带的土工试验等数据，通过经验及试错法对参数取值，使模型符合实际。数值模型的岩土体物理力学参数设置如表 3 所示。

表 3 岩土体物理力学参数

Table 3 Physical and mechanical parameters table of geotechnical materials

材料	干密度 /g/cm <sup>3</sup>	弹性模量 /kPa	泊松比	渗透系数 /m/d	摩擦角 /°	粘聚力 /kPa
滑体	1.68	36500	0.31	0.11	18	32
滑带	1.68	18800	0.3	0.056	待求	待求

### 5.3 代理模型样本的生成

为验证 CV-Voronoi 自适应序列采样方法的优势，将正交设计和均匀设计的一次采样方法作为对比。根据试验和现场资料，确定滑带土抗剪强度参数的取值范围：10kPa≤c≤20kPa，12°≤φ≤18°。

#### (1) CV-Voronoi 自适应序列采样法

如图 14 (a)，先采用均匀设计生成 10 个初始样本点（蓝色），再根据 CV-Voronoi 自适应序列采样法通过 5 折交叉验证结合有限元数值计算逐个生成 22 个补充样本点（红色），最终得到 32 组训练样本。其中，XD02、ZG93、XD04、ZG118 为监测点处的位移。

#### (2) 正交设计一次采样法

如图 14 (b)，每个因素设置 8 个水平。对 L64 正交设计表部分选取 32 组试验得到训练样本，确保每个水平出现 4 次。

#### (3) 均匀设计一次采样法

如图 14 (c)，根据均匀试验设计共 32 组试验，得到训练样本。




图 14 不同采样方法的样本点分布

Fig.14 Distribution of sample points using different sampling methods

### 5.4 反演结果验证

将训练样本在训练时进行交叉验证，计算每轮交叉验证的均方误差平均值。以输出位移值与实际位移值的均方误差为反演目标函数，使用 SSA 对 SSA-TSVR 回归链模型进行参数反演计算，所得反演结果如表 4 所示。

表 4 反演结果

Table 4 Results of inversion method

样本来源	C/(kPa)	φ/(°)
自适应序列应采样	10.211	15.361
正交设计	10.665	15.187
均匀设计	12.089	15.242

为了验证反演结果准确性，将反演结果代入到有限元模型得到计算位移，计算其与实测位移的相对误差，结果如表 5 所示。

表 5 反演结果精度对比

Table 5 Accuracy comparison of inversion results

	XD02 /mm	ZG93 /mm	XD04 /mm	ZG118 /mm	平均 相对 误差
实测值	13.914	15.405	12.752	7.345	
基于自适应采样的反演结果计算值	13.765	15.481	12.771	7.598	0.83%
基于正交设计的反演结果计算值	13.467	15.533	12.986	7.856	3.21%
基于均匀设计的反演结果计算值	13.533	15.287	12.434	7.296	1.67%

由表 5 可见，位移反演计算值与位移实测值的平均相对误差仅 0.83%，证明反演结果良好。另外，基

于自适应序列采样反演方法得到的位移计算值平均相对误差分别为基于正交设计和均匀设计反演结果的 25.9%和 49.7%，说明该方法能更准确地构建代理模型。

为验证 SSA 的优化效率，以交叉验证的平均均方误差为目标函数，使用 SSA、粒子群算法（PSO）、遗传算法（GA）分别优化 TSVR，并对其预测结果进行对比分析。其中，三种算法种群数量均为 50，迭代次数为 20，迭代过程最优目标函数值变化如图 15 所示。




图 15 三种优化算法优化过程

Fig.15 The optimization process of three optimization algorithms

由图 15 可见，SSA 的最优目标函数值为  $6.77 \times 10^{-4}$ ，PSO 的最优目标函数值为  $7.38 \times 10^{-4}$ ，GA 的最优目标函数值为  $11.37 \times 10^{-4}$ 。在迭代次数为 6 时，SSA 就搜索到最优目标函数值。因此，SSA 不仅全局搜索能力强，而且收敛速度快。

为验证代理模型的性能及优化效果，比较采用不同代理模型的反演结果（表 6）。TSVR 和 SVR 模型参数的惩罚因子均取 1，不敏感误差参数均取 0.1。将自适应采样法得到的样本划分为训练集（20 个）与测试集（5 个）。

表 6 不同代理模型的反演结果

Table 6 The inversion results of different surrogate models.

代理模型	XD02 /mm	ZG93 /mm	XD04 /mm	ZG11 8 /mm	平均相 对误差	平均单个 模型训练 时间/s
TSVR	13.710	15.673	12.637	7.486	1.51%	$0.86 \times 10^{-2}$
SSA-TSVR	13.765	15.481	12.771	7.598	0.83%	$0.88 \times 10^{-2}$
SVR	13.488	14.953	12.363	6.955	3.59%	$2.33 \times 10^{-2}$
SSA-SVR	14.012	15.559	12.857	7.454	1.00%	$2.30 \times 10^{-2}$

由表 6 可见，相同样本的情况下采用 TSVR 代理模型的反演结果误差约为 SVR 的 42%。而采用 SSA-SVR 及 SSA-TSVR 两种代理模型的反演误差大幅减小，其中 SSA-TSVR 代理模型的反演结果比 SSA-SVR 代理模型的结果更好。此外，TSVR 模型和 SSA-TSVR 模型的运行速度更快，其平均单个模型训练的时间是 SVR 和 SSA-SVR 代理模型的一半以下。这说明 SSA-TSVR 模型具有更高的反演精度和速度。

另外，自适应序列采样还可以在采样过程中得知模型训练情况。为观察在不同样本数时的反演效果，从第 16 个采样点开始每新增一个点就进行参数反演。将结果代入有限元模型得到计算位移，并计算其与实测位移的平均相对误差，结果如图 16。




图 16 不同样本数时平均相对误差变化

Fig.16 Changes in average relative error with different sample sizes

由图 16 可见，样本数为 31 时，增加样本数，结果精度几乎不再变化，可以视为采样临界点，而一次采样法则难以确定采样临界点，不利于实际应用。生成 29 个样本点后，平均相对误差降低到 1% 以下，此时不仅样本点数目小于正交设计与均匀设计的一次采样法构建的样本，反演所得位移平均相对误差也更小。这说明，基于自适应序列采样法的参数反演技术能够用更少的样本达到比一次采样法更高的精度，因而计算量更小，再加入 TSVR 作为代理模型，在实际应用中可以进一步提高反演速度。

## 6 结论与展望

本文使用 CV-Voronoi 自适应序列采样方法生成代理模型样本来训练 SSA-TSVR 代理模型，根据实测位移，基于 SSA 搜索最佳参数，提出了力学参数反演的新方法。以白水河滑坡为例对其进行验证，并与采用一次采样方法生成代理模型样本的反演方法进行了对比分析。所得结论如下：

(1) CV-Voronoi 自适应采样法能够寻找待求解问题空间非线性较强的区域，并在其中添加更多样本点。通过三个数值算例的研究表明，自适应序列采样法效果优于常用的一次采样法（均匀设计与正交设计）。

(2) 将新反演方法得到的反演参数代入有限元模型中计算监测点位移值，经过 SSA 对 TSVR 的参数优化后，计算值与实测值的平均相对误差由 1.51% 下降到 0.83%，计算速度提升了将近 2 倍。说明新方法具有较高的反演精度和速度。



(3) 基于自适应序列采样法的反演方法得到的位移计算值平均相对误差分别是基于正交设计和均匀设计反演的 25.9%和 49.7%，反演效果最好。该方法还能用更少的样本达到比一次采样法更高的精度。

自适应采样方法在岩土工程中的应用前景广阔，除了能够应用于岩土工程反分析，还能够用于任何需要构建代理模型的岩土工程问题（如边坡稳定性分析），可以提高数据采集效率和代理模型的预测精度。另外，由于新反演方法的计算效率更高，采用该方法可以对滑坡的失稳状态进行更早的预测和评价，从而其研究成果可以更好的应用于滑坡动态预警工作中。

#### 参考文献：

- [1] 蒋水华,魏博文,黄劲松. 考虑参数空间变异性的失稳边坡参数概率反分析[J]. 岩土工程学报,2017, 39(3): 475-485. (JIANG Shui-hua, WEI Bo-wen, HUANG Jin-song. Probabilistic back analysis of slope failure considering spatial variability of soil properties[J]. Chinese Journal of Geotechnical Engineering, 2017,39(3):475-485. (in Chinese))
- [2] 胡斌, 汤琦, 李京, 等. 基于 RF-PSO 混合算法的边坡软弱夹层力学参数反演应用研究[J]. 金属矿山, 2022, (06): 167-172. (HU Bin, TANG Qi, LI Jing, et al. Application research on back analysis of mechanical parameters of slope weak interlayer based on RF-PSO hybrid algorithm[J]. Metal Mine, 2022, (06): 167-172. (in Chinese))
- [3] 毛伟琦, 李小珍, 王翔, 等. 基于 LSSVM 和 GWOPSO 算法的桥岸边坡位移反演方法研究[J]. 铁道科学与工程学报, 2023, 20(11): 4299-4310. (MAO Wei-qi, LI Xiao-zhen, WANG Xiang, et al. Inversion method of bridge abutment slope displacement based on LSSVM and GWOPSO algorithm[J]. Journal of Railway Science and Engineering, 2023, 20(11):4299-4310. (in Chinese))
- [4] 江巍, 欧阳晔, 闫金洲, 等. 边坡岩土体抗剪强度的逆向迭代修正反演方法[J]. 岩土力学, 2022, 43(08): 2287-2295. (JIANG Wei, OUYANG Ye, YAN Jin-zhou, et al. Inversion iterative correction method for estimating shear strength of rock and soil mass in slope engineering[J]. Rock and Soil Mechanics, 2022, 43(08): 2287-2295. (in Chinese))
- [5] 袁维, 籍晓蕾, 王东坡, 等. 降雨和库水位变动联合作用下滑坡位移加权反分析及监测预警方法[J]. 测绘学报, 2024, 53(05): 917-932. (YUAN Wei, JI Xiao-lei, WANG Dong-po, et al. Landslide displacement weighted inverse analysis and monitoring and warning method under the combined action of rainfall and reservoir water level[J]. Acta Geodaetica et Cartographica Sinica, 2024, 53(05): 917-932. (in Chinese))
- [6] 阮永芬, 余东晓, 吴龙, 等. DE-GWO 算法优化 SVM 反演软土力学参数[J]. 岩土工程学报, 2021, 43(S1): 166-170. (RUAN Yong-fen, YU Dong-xiao, WU Long, et al. DE-GWO algorithm to optimize SVM inversion mechanical parameters of soft soil[J]. Chinese Journal of Geotechnical Engineering, 2021, 43(S1): 166-170. (in Chinese))
- [7] Crombecq K, Gorissen D, Deschrijver D, et al. A novel hybrid sequential design strategy for global surrogate modeling of computer experiments[J]. Siam Journal On Scientific Computing. 2011, 33: 1948-1974.
- [8] Liu, H T, Ong Y S, Cai, J F. A survey of adaptive sampling for global metamodeling in support of simulation-based complex engineering design[J]. Structural and Multidisciplinary Optimization. 2018, 57: 393-416.
- [9] Xiao N C, Zuo M J, Zhou C N. A new adaptive sequential sampling method to construct surrogate models for efficient reliability analysis[J]. Reliability Engineering & System Safety, 2018, 169: 330-338.
- [10] Xu S L, Liu H T, Wang X F, et al. A robust error-pursuing sequential sampling approach for global metamodeling based on voronoi diagram and cross validation[J]. Journal of Mechanical Design, 2014, 136(7): 071009.
- [11] 李正良, 彭思思, 王涛. 基于 k-fold 交叉验证的代理模型序列采样方法[J]. 计算力学学报, 2022, 39(02): 244-249. (LI Zheng-liang, PENG Si-si, WANG Tao. A sequential sampling method of surrogate model based on k-fold cross validation[J]. Chinese Journal of Computational Mechanics, 2022, 39(02): 244-249. (in Chinese))
- [12] Duchanoy C A, Calvo H, Moreno-Armendáriz M.A. ASAMS: An adaptive sequential sampling and automatic model selection for artificial intelligence surrogate modeling[J]. Sensors, 2020, 20(18): 5332.
- [13] PENG X J. TSVR: An efficient Twin Support Vector Machine for regression[J]. Neural Networks, 2010, 23(3): 365-372.
- [14] 薛建凯. 一种新型的群智能优化技术的研究与应用: 麻雀搜索算法[硕士论文 D]. 上海: 东华大学, 2020. (XUE Jian-kai. Research and application of a novel swarm intelligence optimization technique: Sparrow Search Algorithm[D]. Shanghai: Donghua University, 2020. (in Chinese))
- [15] 李雅丽, 王淑琴, 陈倩茹等. 若干新型群智能优化算法的对比研究[J]. 计算机工程与应用, 2020, 56(22): 1-12. (LI Ya-li, WANG Shu-qin, CHEN Qian-ru, et al. Comparative study of several new swarm intelligence optimization algorithms[J]. Computer Engineering and Applications, 2020, 56(22): 1-12. (in Chinese))
- [16] Borchani H, Varando G, Bielza C, Larrañaga P. A survey on multi-output regression[J]. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 2015, 5(5): 216-233.
- [17] 易武, 黄海峰. 长江三峡库区白水河滑坡、八字门滑坡、

树坪滑坡、新滩滑坡、链子崖危岩体专业监测年报汇编  
(2007 年). 国家冰川冻土沙漠科学数据中心(<http://www.ncdc.ac.cn>),2016.<https://cstr.cn/CSTR:11738.11.ncdc.Sanxia.2020.74>.(YI wu, HUANG Hai-feng. Compilation of

annual reports on professional monitoring of Baishuihe landslide, Bazimen landslide, Shuping landslide, Xintan landslide and Lianziya dangerous rock mass in the Three Gorges Reservoir area of the Yangtze River (2007). National Cryosphere Desert Data Center (<http://www.ncdc.ac.cn>), 2016. <https://cstr.cn/CSTR:11738.11.ncdc.Sanxia.2020.74>. (in Chinese))

- [18] 邓茂林, 周剑, 易庆林, 等. 三峡库区靠椅状土质滑坡变形特征及机制分析[J]. 岩土工程学报, 2020, 42(7): 1296-1303. (DENG Mao-lin, ZHOU Jian, YI Qing-lin, et al. Characteristics and mechanism of deformation of chair-shaped soil landslides in Three Gorges Reservoir area[J]. Chinese Journal of Geotechnical Engineering, 2020, 42(7): 1296-1303. (in Chinese))

非最终出版稿

录用稿件，