基于 LHS-WOA-ELM 的隧道围岩参数反演分析*

肖时辉[1,2]，王峰[3]，何柏延[1]，徐国元[1]，黄伟真[1]，李伟鹏[2]

（1.华南理工大学 土木与交通学院， 广东 广州 510641；
2.珠海大横琴股份有限公司， 广东 珠海市 519000；
3.中铁十八局集团第一工程有限公司， 河北 涿州市 072750）

摘要：为提高隧道围岩力学参数取值的合理性，依托珠海市某超大断面隧道工程提出一种新型围岩参数反演模型。基于拉丁超立方体抽样（LHS）产生初始样本后进行参数敏感性分析以确定围岩的关键参数和改进样本结构，然后利用鲸鱼优化算法（WOA）对极限学习机（ELM）的隐含层神经元节点数、初始权重和阈值进行优化进而组成 LHS-WOA-ELM 反演模型，将反演所得参数代入 FLAC3D 计算位移并与现场实测数据进行对比分析。结果表明：采用基于 LHS 进行的参数敏感性分析能够以较少的样本考察多参数共同变化的情况，并确定影响围岩位移的主要参数为弹性模量 E、黏聚力 c 和内摩擦角 φ；相比于 WOA、ELM、BP 算法模型，LHS-WOA-ELM 模型反演所获得的位移计算值与实测值相差更小，表明该反演分析方法能够很好地反映围岩参数与变形之间的非线性、不确定性特征，进一步提高围岩反演的精度和效率，可为地下硐室、矿业工程的设计参数确定提供参考。

关键词：超大断面隧道；围岩参数反演；拉丁超立方体抽样；鲸鱼优化算法；极限学习机

中图分类号：TD353；U459.2　　**文献标识码**：A　　**文章编号**：1005-2763(2025)03-0091-10

Inversion Analysis on Surrounding Rock Parameters of Tunnel Based on LHS-WOA-ELM

XIAO Shihui[1,2], *WANG Feng*[3], *HE Baiyan*[1], *XU Guoyuan*[1], *HUANG Weizhen*[1], *LI Weipeng*[2]

(1.School of Civil Engineering and Transportation, South China University of Technology, Guangzhou, Guangdong 510641, China;
2.Zhuhai Dahengqin Co., Ltd., Zhuhai, Guangdong 519000, China;
3.China Railway 18th Bureau Group No. 1 Engineering Co., Ltd., Zhuozhou, Hebei 072750, China)

Abstract: In order to improve the rationality of mechanical parameters of tunnel surrounding rock, a new inversion model of surrounding rock parameters was proposed based on a tunnel project with a super large-section in Zhuhai. After the initial samples were generated based on Latin hypercube sampling (LHS), the parameter sensitivity analysis was carried out to determine the key parameters of the surrounding rock and improve the sample structure. Then, the whale optimization algorithm (WOA) was used to optimize the number of hidden layer nodes, the initial weights and the thresholds of the extreme learning machine (ELM) to form the LHS-WOA-ELM inversion model. The inversion parameters were substituted into FLAC3D to calculate the displacement and compare with the field measured data. The results show that the parameter sensitivity analysis based on LHS can investigate the co-variation of multi-parameters with fewer samples, and determine the main parameters affecting the displacement of surrounding rock as elastic modulus E, cohesion c and internal friction angle φ. Compared with WOA, ELM and BP algorithm models, the difference between the calculated displacement values obtained by LHS-WOA-ELM inversion model and the measured displacement values is smaller, indicating that the inversion analysis method can well reflect the nonlinear and uncertain characteristics between the surrounding rock parameters and deformation, and further improve the accuracy and efficiency of the surrounding rock inversion in tunnels with super-large section, which can provide a reference for determining the design parameters of underground caverns and mining projects.

Key words: Tunnel with super large-section, Parameter inversion of surrounding rock, Latin hypercube sampling, Whale optimization algorithm, Extreme learning machine

---

* **收稿日期**：2024-04-28
基金项目：国家自然科学基金资助项目(51878296，12302502)
作者简介：肖时辉(1973—)，男，湖南邵阳人，硕士，教授级高级工程师，研究方向为隧道与地下工程。E-mail：1614878230@qq.com
通信作者：王峰(1982—)，男，河北张家口人，高级工程师，研究方向为隧道与地下工程。E-mail：314689725@qq.com

0 引言

在矿产资源开采、水利水电开发、地下结构物建设等众多岩土工程领域中,确定合理的岩体力学参数是重要的研究课题,直接关系到数值模拟、支护设计的正确性和可靠性[1]。目前围岩力学参数取值存在以下难点,一方面由于采用分部开挖施工对围岩产生了多次扰动,现场取样试验得到的围岩力学参数往往与实际工程中参数相差过大;另一方面由于相关设计施工规范尚不完善,技术人员在围岩力学参数取值时过于保守,使得支护设计时参数不够合理,造成一定的资源浪费。因此,有必要根据实际工程岩体监测数据,建立围岩的力学参数反演模型,对围岩进行稳定性评价。

围岩的力学参数和变形之间存在着复杂的非线性关系,基于变形值的力学参数反分析方法具有计算速度快、成本低等优势,成为围岩力学参数获取的有效手段[2]。GIODA 等[3]首次将反分析方法引入隧道工程,利用结构开挖过程中的位移、应力或应变的现场测试数据确定围岩的力学参数。随后,不同的反分析模型逐渐应用于地下硐室[4-5]、矿业开采[6-8]等工程。近年来,随着计算机技术的发展,人工智能方法逐渐应用到力学参数反演中,主流为 BP 神经网络[9-10],也有不少利用学习速度快且泛化能力好的极限学习机[11]对岩土力学参数进行反演的成功案例。为提高反演精度和计算速度,部分学者结合了参数敏感性分析与神经网络[12-13]优化试验样本,减少低敏感度因素对网络训练的影响;而另外一些学者通过引入元启发式智能算法来求解反分析优化问题[14-15],并均取得了一定的成就,但在实际应用中仍然存在以下不足:

(1) 传统的方法在生成反演模型的训练集时往往只考虑单一参数的变化,这与岩体真实情况不符;

(2) 在选择反演参数时具有一定的主观性和经验性,采用低敏感度参数进行反演不仅增加了计算量,还使得反演模型复杂化,容易陷入过拟合;

(3) 极限学习机与其他神经网络类似,受初始输入权重与阈值影响较大;

(4) 典型优化算法如遗传算法等仍存在易陷入局部最优解、稳定性差的问题。

综合先前学者的研究成果,本文基于拉丁超立方体抽样(LHS)的参数进行敏感性分析,结合鲸鱼优化算法(WOA)改进的极限学习机(ELM)方法,构建 LHS-WOA-ELM 模型并将其应用于珠海市超大断面隧道工程进行围岩力学参数反演,验证该方法的可靠性和工程应用效果。

1 基本方法与理论

1.1 拉丁超立方体抽样

拉丁超立方体抽样作为一种先进的抽样技术,它能以较少迭代次数的抽样准确地重建输入分布,有效避免蒙特卡罗法大量反复的抽样工作[16]。与随机抽样不同,LHS 通过尽可能地使每一个边缘分布分层,达到全覆盖每一个变量范围。在 n 维向量空间里抽取 m 个样本,其主要流程[17]为:

(1) 将每一维分成互不重叠的 M 个区间,每个区间有相同的概率;

(2) 在每一维里的各个区间中随机抽取一个点;

(3) 从每一维里随机抽出流程(2)中选取的点,按照随机顺序组成预测值变量。

其中每个变量划分的区间数建议取 $M \geqslant 1.33n$。

1.2 参数灵敏度分析方法

在实际岩土工程中各参数之间相互关联,单一参数变化而保持其他参数不变的情况是不可能存在的,用随机模拟的方法进行参数灵敏度分析的优势在于能同时考虑所有参数共同改变的情况。因此,本文按照文献[18]的方法,引入 Spearman 秩相关系数 r_s来衡量两个随机变量之间的相关性,即:

$$r_s=\frac{\sum_{i=1}^{N}R_iQ_i-\frac{N}{4}(N+1)^2}{\sqrt{\sum_{i=1}^{N}R_i^2-\frac{N}{4}(N+1)^2}\sqrt{\sum_{i=1}^{N}Q_i^2-\frac{N}{4}(N+1)^2}} \tag{1}$$

式中,R_i、Q_i 分别为随机变量样本值 X_i、Y_i 在样本区间$(X_1,\cdots,X_N)$和$(Y_1,\cdots,Y_N)$中的"秩",$1 \leqslant i \leqslant N$;$N$ 为样本数量。

1.3 鲸鱼优化算法

鲸鱼优化算法是基于座头鲸的"气泡网络"捕食策略而提出的新型群体智能优化算法[19-20],具有调整参数少和跳出局部最优解能力较强的优势,被不少学者应用于非线性优化、故障诊断等领域[21-22],但是目前该方法在隧道工程中应用较少,主要算法步骤如下。

(1) 包围猎物。

将当前鲸群中最佳候选个体位置视为目标猎物

位置,然后根据该最佳候选个体的位置更新鲸群中其他个体位置。即:

$$\boldsymbol{D}=|\boldsymbol{C}\cdot\boldsymbol{X}^{*}(t)-\boldsymbol{X}(t)| \tag{2}$$

$$\boldsymbol{X}(t+1)=\boldsymbol{X}^{*}(t)-\boldsymbol{A}\cdot\boldsymbol{D} \tag{3}$$

式中:$\boldsymbol{D}$ 为当前搜索个体与当前最优解的距离;$\boldsymbol{X}$ 为当前解的位置向量;$\boldsymbol{X}^{*}$ 为当前获得的鲸鱼群中最优解的位置向量;$\boldsymbol{A}$ 和 $\boldsymbol{C}$ 为系数向量;t 为迭代次数。

$\boldsymbol{A}$ 和 $\boldsymbol{C}$ 通过下式计算确定:

$$\boldsymbol{A}=2\boldsymbol{a}\boldsymbol{r}-\boldsymbol{a} \tag{4}$$

$$\boldsymbol{C}=2\boldsymbol{r} \tag{5}$$

式中:$\boldsymbol{r}$ 为区间[0, 1]的任意向量,$\boldsymbol{a}$ 随迭代次数的增加从 2 线性递减到 0。

(2) 螺旋气泡网攻击。

计算鲸鱼个体与猎物之间的距离,然后鲸鱼以螺旋形状游向猎物并收缩包围圈:

$$\boldsymbol{D}'=|\boldsymbol{X}^{*}(t)-\boldsymbol{X}(t)| \tag{6}$$

$$\boldsymbol{X}(t+1)=\boldsymbol{D}'\cdot e^{bl}\cdot\cos(2\pi l)+\boldsymbol{X}^{*}(t) \tag{7}$$

式中:l 为区间[0, 1]的随机数;b 为描述螺旋形状的常量系数,可取 1。

(3) 随机搜索猎物。

在群体捕食的同时,若满足 $|\boldsymbol{A}|>1$,鲸群将根据相互的位置进行随机游动以提高算法的全局搜索能力。即:

$$\boldsymbol{D}=|\boldsymbol{C}\cdot\boldsymbol{X}_{\text{rand}}-\boldsymbol{X}| \tag{8}$$

$$\boldsymbol{X}(t+1)=\boldsymbol{X}_{\text{rand}}-\boldsymbol{A}\cdot\boldsymbol{D} \tag{9}$$

式中,$\boldsymbol{X}_{\text{rand}}$ 为当前鲸群随机选择的位置向量。

1.4 极限学习机及其优化

极限学习机是基于单隐含层前馈神经网络提出的新算法[23-24],具有学习速度快、泛化性能好等优点。在训练中只需设置隐含层神经元节点的个数,算法便会随机产生输入层与隐含层间的连接权值及隐含层神经元的阈值,以此得到唯一的全局最优解。对于 N 个样本中的 n 维输入向量 $\boldsymbol{X}_i$ 与 m 维输出向量 $\boldsymbol{T}_i$,其中 $1\leqslant i\leqslant N$,当隐含层神经元节点数为 l' 时,ELM 网络可以表示为:

$$\sum_{f=1}^{l'}\boldsymbol{\beta}_f g(\boldsymbol{W}_f\cdot\boldsymbol{X}_i+\boldsymbol{b}_f)=\boldsymbol{O}_i \tag{10}$$

式中:$\boldsymbol{O}_i$ 为单隐含层输出函数;$g(x)$ 为激活函数;$\boldsymbol{W}_f$ 为输入和输出之间的权重向量;$\boldsymbol{\beta}_f$ 为第 f 个隐含层和输出之间的权重向量;$\boldsymbol{b}_f$ 为偏置向量。

单隐含层 ELM 的学习目标为:

$$\sum_{i=1}^{N}\|\boldsymbol{O}_i-\boldsymbol{T}_i\|=0 \tag{11}$$

即需求得一组 $\boldsymbol{W}_f$、$\boldsymbol{\beta}_f$、$\boldsymbol{b}_f$,使得:

$$\boldsymbol{H}\boldsymbol{\beta}=\boldsymbol{T} \tag{12}$$

式中:$\boldsymbol{H}$ 为隐含层输出矩阵;$\boldsymbol{\beta}$ 为输出权重矩阵;$\boldsymbol{T}$ 为期望输出矩阵。

通常地,采用最小二乘法求解出式(12)中的输出权重矩阵 $\boldsymbol{\beta}$,即:

$$\min_{\boldsymbol{\beta}}=\|\boldsymbol{H}\boldsymbol{\beta}-\boldsymbol{T}\| \tag{13}$$

由上可知,ELM 网络的初始输入权重与隐含层阈值由网络随机生成,同时网络的最佳隐含层神经元节点个数通常是经过经验公式试算出来的,而模型的精度往往受三者的影响较大。为提高其寻优精度,通过 WOA 对网络的隐含层神经元个数、初始输入权重与隐含层阈值进行优化,构建 WOA-ELM 优化模型,其网络结构如图 1 所示。

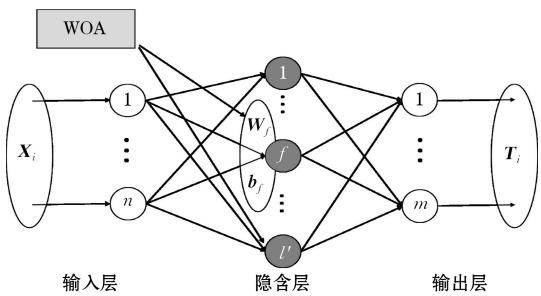


图 1 WOA-ELM 网络结构

Fig.1 The network structure of WOA-LEM

2 围岩力学参数反演模型的建立

本文基于上述介绍的原理,提出了一种适用于超大断面隧道的围岩力学参数 LHS-WOA-ELM 反演模型,以此更好地表达输入层(围岩变形)与输出层(围岩力学参数:包括弹性模量 E、泊松比 μ、黏聚力 c、内摩擦角 φ、容重 γ)之间的复杂非线性映射关系。模型选取初始样本时,首先结合了工程地质勘察报告及规范《公路隧道设计细则》(JTG/T D70—2010)确定待反演的围岩力学参数的基准值和变化范围,然后使用拉丁超立方抽样生成一组围岩力学参数,代入 FLAC3D 建立的正演模型,计算获得围岩变形值,最后将围岩力学参数及其位移计算值组成一组样本,选取合适的样本数量,并进行参数敏感性分析,将敏感度高的围岩力学参数作为输出层,相应的围岩关键测点位移计算值作为输入层,构建前述的 WOA-ELM 模型的学习样本。WOA 算法随机生成初始鲸鱼群位置向量,然后将所有关键测点的位移计算值与预测值之间的差值平方和作为目标

函数对位置向量进行寻优,经过多次迭代后确定ELM算法的最优隐含层神经元个数、初始权重和阈值,以此完成对围岩力学参数的反演。模型构建总体思路如下:

(1) 根据实际情况及相关规范,利用LHS方法生成初始样本,对各围岩力学参数与变形进行敏感性分析;

(2) 选取敏感度高的参数,构建LHS-WOA-ELM网络学习样本;

(3) 通过WOA算法确定ELM模型中的隐含层神经元个数、优化输入权重与隐含层阈值;

(4) 利用实测数据(围岩变形)作为输入层代入训练好的模型得到围岩力学参数;

(5) 将反演得到的围岩力学参数输入正分析模型并进行误差分析,验证模型的合理性。

模型具体流程如图2所示。

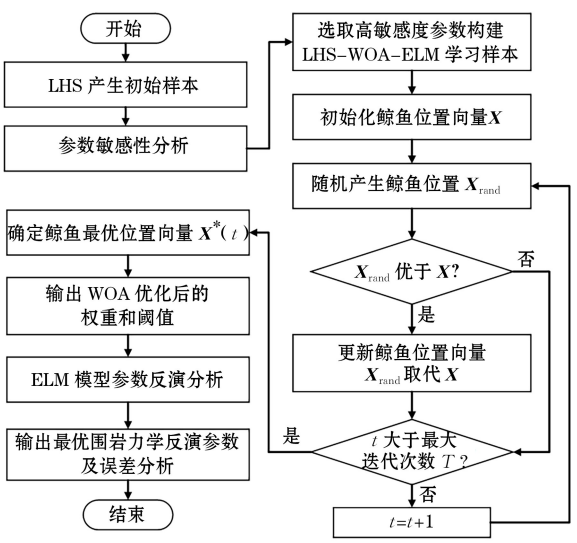


图2 围岩力学参数反演模型流程

Fig.2 Process for the inversion model of mechanical parameters of surrounding rock

在LHS-WOA-ELM模型反演过程中,激活函数选择Sigmoid函数,初始种群规模为30只,最大迭代次数为100代;同时,保持网络设置参数一致,将LHS-WOA-ELM反演结果与GWO-ELM(灰狼优化算法改进极限学习机模型)、ELM(极限学习机)、BP神经网络进行对比,引入平均绝对误差(MAE)、均方误差(MSE)、均方根误差(RMSE)和计算时间作为评价反演模型效果优劣指标,其计算方法如下:

$$MAE=\frac{1}{N}\sum_{i=1}^{N}\mid y_i-\hat{y}_i\mid \tag{14}$$

$$MSE=\frac{1}{N}\sum_{i=1}^{N}(y_i-\hat{y}_i)^2 \tag{15}$$

$$RMSE=\sqrt{\frac{1}{N}\sum_{i=1}^{N}(y_i-\hat{y}_i)^2} \tag{16}$$

式中:y_i 为第 i 个样本的真实值;$\hat{y}_i$ 为模型对第 i 个样本的预测值。

3 工程实例分析

3.1 工程概况

珠海市某公路隧道北起珠海大道,穿越黑白面将军山,南至南琴路,直通横琴新区,线路全长约3.86 km,其中隧道左线长3 645 m,右线长3 735 m。隧道右线出口大跨段(YK4+880)~(YK4+840)断面最大开挖宽度为23.44 m,开挖高度为14.06 m,净空有效面积为146.14 m^2,为超大断面隧道。该段围岩多为强-中风化石英闪长岩,拱部及侧壁自稳性差,加上浅埋偏压的作用,开挖时易坍塌。根据地质勘察报告和工程施工方案判定该段隧道围岩等级为Ⅴ级,采用双侧壁导坑法施工,待左线出口所挖的边坡稳定后再施工隧道主体工程,其断面尺寸如图3所示。

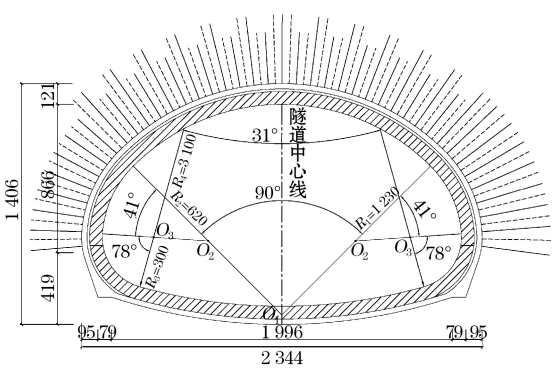


图3 洞口大跨段断面(单位:cm)

Fig.3 Large-span section of tunnel portal (Unit:cm)

3.2 正演模型的建立

3.2.1 模型概况

大跨段隧道为浅埋偏压山岭隧道,邻近出口,根据现场勘察报告,该段可不考虑地应力场。为减少边界尺寸的影响,总体模型计算区域的选取以隧道直径的2~3倍以上、竖直向2~3倍以上为原则,计算模型几何尺寸 x、y、z 分别为160 m、40 m、100 m。

利用Midas GTS NX建立几何体并划分三维网格,导入FLAC3D进行计算分析。底面边界为固

定约束，顶面上边界为自由面，左右边界施加 x 水平方向约束，前后边界施加 y 纵向方向约束。计算模型采用 Mohr-Coulomb 屈服准则，其中围岩、挡土墙和注浆加固区等采用三维实体单元，管棚采用 beam 单元，系统锚杆与锁脚锚杆采用 cable 单元，初期支护与临时支护采用 shell 单元模拟。共建立 180 000 个实体单元和 20 000 个结构单元，正演总体模型如图 4 所示。

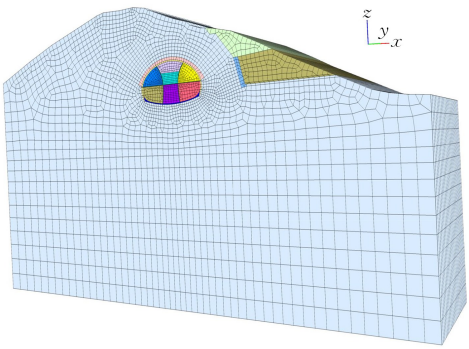


图 4　隧道正演总体模型

Fig.4　The general model of tunnel forward analysis

3.2.2　模型参数的确定

超前支护范围为拱部 120°，采用长 10 m、直径 89 mm 的注浆管棚和长 4.5 m、直径 42 mm 的小导管，环向间距均为 40 cm。管棚的模量[25]按照公式(17)计算；注浆小导管采用形成注浆加固区模拟[26]。

$$E_p=(E_{s1}I_{s1}+E_mI_m)/(I_{s1}+I_m) \tag{17}$$

式中：E_p、E_{s1}、E_m分别为管棚等效模量、钢管弹性模量、管内充填砂浆弹性模量；I_{s1}、I_m为钢管和充填砂浆的惯性矩。

对于初期支护和临时支护中的钢拱架、钢筋网的各物理参数采用公式(18)折算到喷射混凝土中[27]：

$$E_l=E_c+\frac{E_{s2}A_{s2}}{A_c} \tag{18}$$

式中：E_l为支护等效模量；E_c为喷射混凝土弹性模量；E_{s2}为钢材弹性模量；A_c为喷射混凝土截面面积；A_{s2}为钢材截面面积。

最终各支护结构基本力学参数见表 1。

表 1　支护结构基本力学参数

Table 1　Basic mechanical parameters of support structure

类别	内容	单元类型	容重 γ/(kN·m^{-3})	弹性模量 E/GPa	泊松比 μ
超前支护	拱部 120°、Φ89 mm 管棚	beam	33.2	93.9	0.2
初期支护	C25 喷射砼＋双层 Φ8 mm 钢筋网＋HW250@50 cm 钢拱架	shell	24.0	30.4	0.2
临时支护	C25 喷射砼＋Φ8 mm 钢筋网＋I20b@50 cm 钢拱架	shell	24.8	32.5	0.2
二次衬砌	C40 钢筋混凝土	实体	25.5	32.5	0.2
锚杆	拱部 90°、Φ25 mm 中空锚杆、涨壳锚杆，交错布置，边墙外侧 Φ22 mm 砂浆锚杆，内侧 Φ25 mm 涨壳锚杆，钢架处设 8 根 Φ42 mm 锁脚锚杆。	cable	78.5	210	0.2

3.3　围岩参数敏感性分析

结合工程地质勘察报告及相关规范[28]，确定围岩力学基准参数见表 2，对弹性模量 E、泊松比 μ、黏聚力 c、内摩擦角 φ、容重 γ 进行参数敏感性分析。在正演分析模型中选取模型开挖 15 m 处(对应实际里程 YK4＋865)断面布置测点，如图 5 所示。采用拉丁超立方体抽样获取 25 组抽样值，并代入正演仿真模型获得该断面关键测点的位移值，见表 3。

表 2　围岩参数取值

Table 2　Parameters of surrounding rock

项目	弹性模量 E/GPa	泊松比 μ	黏聚力 c/MPa	内摩擦角 φ/(°)	容重 γ/(kN·m^{-3})
基本参数	1.0	0.3	0.2	30	25
变化范围	0.7～1.3	0.25～0.35	0.1～0.3	20～40	20～30
假设分布	均匀	均匀	均匀	均匀	均匀

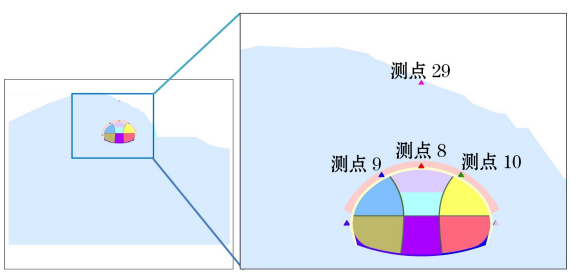


图 5　YK4＋865 断面测点布置

Fig.5　The measuring position in YK4＋865 section

对样本数据进行排秩并计算围岩变形 Spearman 相关系数，如图 6 所示。

影响测点 8 变形的敏感度顺序为：$E>c>\varphi>\gamma>\mu$；

影响测点 9 变形的敏感度顺序为：$E>c>\varphi>\gamma>\mu$；

表 3 LHS 结果及位移计算值

Table 3 LHS results and deformation calculation

组别	参数取值					位移计算值/mm			
	E/GPa	μ	φ/(°)	c/MPa	γ/(kN·m^{-3})	中拱顶(测点 8)	左拱顶(测点 9)	右拱顶(测点 10)	地表(测点 29)
1	1.27	0.28	37.56	0.28	27.38	−7.781	−6.565	−3.876	−5.783
2	0.70	0.31	36.15	0.17	28.39	−13.058	−11.305	−6.453	−10.131
3	1.01	0.33	27.58	0.26	23.32	−7.877	−6.728	−3.915	−5.916
4	1.12	0.26	33.04	0.23	20.99	−7.197	−6.037	−3.569	−5.334
5	0.78	0.33	20.00	0.15	22.78	−12.310	−10.808	−7.123	−9.917
6	1.24	0.33	29.97	0.19	24.44	−7.181	−6.164	−3.735	−5.380
7	1.07	0.27	23.44	0.24	23.87	−8.409	−7.190	−4.224	−6.328
8	1.16	0.28	28.03	0.12	28.71	−16.428	−13.807	−10.109	−14.633
9	0.95	0.30	34.84	0.14	20.75	−8.187	−7.025	−4.248	−6.229
10	1.10	0.31	22.33	0.29	26.68	−8.388	−7.204	−4.169	−6.313
11	0.89	0.32	24.75	0.14	21.51	−9.805	−8.532	−5.540	−7.712
12	0.76	0.32	29.10	0.21	27.74	−11.792	−10.247	−5.809	−9.081
13	0.86	0.27	24.96	0.25	21.97	−9.043	−7.687	−4.375	−6.831
14	0.97	0.28	33.85	0.30	26.29	−9.128	−7.750	−4.398	−6.873
15	1.18	0.35	40.00	0.20	30.00	−8.370	−7.224	−4.221	−6.290
16	0.83	0.30	20.84	0.11	24.85	−27.241	−23.549	−16.193	−25.138
17	0.90	0.34	22.78	0.10	20.00	−12.212	−10.377	−7.647	−10.421
18	1.23	0.26	32.04	0.18	22.10	−7.159	−6.049	−3.628	−5.312
19	1.03	0.31	26.34	0.17	25.36	−9.486	−8.234	−5.246	−7.348
20	1.30	0.30	39.03	0.26	24.09	−6.772	−5.710	−3.401	−5.012
21	0.72	0.35	37.78	0.23	23.15	−9.833	−8.384	−4.793	−7.462
22	1.16	0.25	31.27	0.21	28.81	−9.559	−8.200	−4.945	−7.241
23	1.05	0.29	35.37	0.16	26.86	−9.429	−8.108	−4.980	−7.213
24	0.81	0.29	26.96	0.13	29.58	−20.696	−17.633	−12.068	−18.241
25	0.94	0.25	31.08	0.27	25.81	−9.553	−8.100	−4.606	−7.198

影响测点 10 变形的敏感度顺序为:$E>c>\varphi>\gamma>\mu$;

影响测点 29 变形的敏感度顺序为:$E>c>\varphi>\gamma>\mu$。

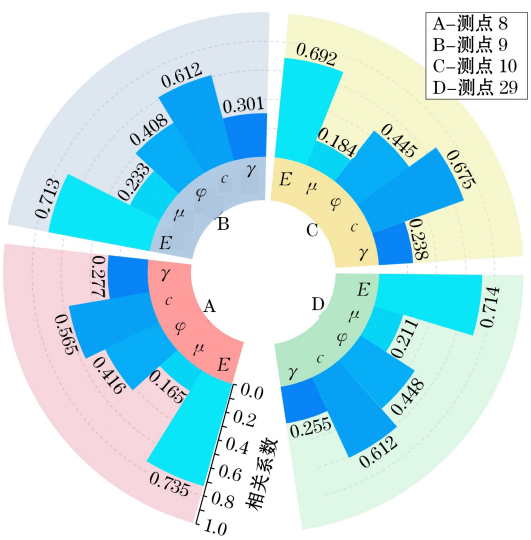


图 6 围岩变形 Spearman 相关系数

Fig 6 Spearman correlation coefficient of surrounding rock deformation

对于围岩变形,3 处拱顶沉降与地表沉降敏感度一致,弹性模量、黏聚力和内摩擦角影响较大,其中各测点弹性模量的 Spearman 相关系数均达到0.6以上;容重与泊松比 Spearman 相关系数处于 0.3 以下,说明围岩变形对拱顶与地表沉降的影响较小。

3.4 LHS-WOA-ELM 模型样本构造

根据参数敏感性分析结果,总体上容重与泊松比对于围岩竖向变形影响程度相对较少,因此,本文后续反演分析选取围岩的弹性模量、黏聚力和内摩擦角作为基本参数。以表 3 中 25 组样本数据构成 LHS-WOA-ELM 的训练集,另使用均匀试验生成 5 组样本作为模型的测试集,见表 4。

3.5 围岩力学参数反演

将构建好的训练集样本与测试集样本输入 LHS-WOA-ELM 模型中,经过多次迭代,确定了最佳隐含层神经元个数为 11 个,并获得一组最佳的输入权重与隐含层阈值。同时,通过平均绝对误差(MAE)、均方误差(MSE)、均方根误差(RMSE)和计算时间,将 LHS-WOA-ELM 反演结果与 GWO-ELM(灰狼优化算法改进极限学习机)模型、ELM(极限学

习机)、BP(神经网络)等算法进行对比,评价反演模型效果的优劣,各模型评价指标结果见表 5。

表 4 均匀试验抽样结果及位移计算值

Table 4 Results of uniform experiment sampling and deformation calculation

组别	参数取值			位移计算值/mm			
	E/GPa	φ/(°)	c/MPa	中拱顶(测点 8)	左拱顶(测点 9)	右拱顶(测点 10)	地表(测点 29)
1	0.70	30.00	0.25	−9.667	−8.177	−4.604	−7.349
2	0.85	20.00	0.20	−14.838	−13.090	−8.562	−12.049
3	1.00	35.00	0.15	−8.879	−7.609	−4.599	−6.743
4	1.15	25.00	0.10	−17.077	−14.339	−10.852	−15.516
5	1.30	40.00	0.30	−7.163	−6.124	−3.641	−5.329

表 5 各模型评价指标计算结果

Table 5 Calculation results of valuation indexes for each model

模型	*MAE*	*MSE*	*RMSE*	计算时间/s
LHS-WOA-ELM	1.604 4	10.516 7	3.242 9	62
GWO-ELM	1.915 6	12.002 0	3.464 4	70
ELM	2.329 1	22.416 6	4.794 6	55
BP	2.095 5	15.429 1	3.928 0	92

综合分析上述评价指标,预测精度由高至低依次为 LHS-WOA-ELM、GWO-ELM、BP、ELM。尽管未经优化的 ELM 在反演预测精度上落后于 BP 神经网络,但其所消耗时间较少,仅用 55 s,这是因为 ELM 模型是单隐含层前馈神经网络,网络结构简单,无需进行参数迭代,因此其计算效率更高。而经过 WOA 优化的 ELM 网络在精度和效率上都具有良好的表现,证明 LHS-WOA-ELM 模型可用于超大断面隧道围岩反分析。

对现场实测数据进行曲线拟合获取围岩最终位移变形值。为进一步反映模型反演结果的准确性,将 YK4+865 断面现场沉降实测值代入训练好的 LHS-WOA-ELM 模型中,得到地层力学参数反演结果:E=1.01 GPa,黏聚力 c=1.25 MPa,内摩擦角 φ=25°,将得到的围岩力学参数反演结果重新输入 FLAC3D 正演模型中,并与其他 3 种训练模型计算结果进行比较,计算所得的位移见表 6。

表 6 4 种模型计算结果对比

Table 6 Comparison of caculation results of four models

测点	现场实测值/mm	LHS-WOA-ELM		GWO-ELM		ELM		BP	
		正演值/mm	相对误差/%	正演值/mm	相对误差/%	正演值/mm	相对误差/%	正演值/mm	相对误差/%
8	−14.10	−13.81	2.06	−13.33	5.46	−16.38	16.17	−15.61	10.71
9	−11.80	−11.89	0.76	−11.15	5.51	−13.80	16.95	−12.56	6.44
10	−9.30	−9.13	1.83	−8.55	8.06	−8.01	13.87	−8.13	12.58
29	−12.10	−11.80	2.48	−13.10	8.26	−14.23	17.60	−13.23	9.34

由表 6 可知,未经过优化的 ELM 和 BP 模型总体计算结果相对误差较大。相比 GWO-ELM 模型,LHS-WOA-ELM 模型相对误差更小,优化效果更为显著。利用 LHS-WOA-ELM 模型进行围岩力学参数反演时,拱顶位移与地表沉降正演值与实测值吻合良好,最大相对误差为 2.48%;总体上可认为 LHS-WOA-ELM 反演结果良好,后续将继续针对 YK4+865 断面的拱顶位移与地表沉降进行分析。

3.6 围岩位移结果分析

图 7 与图 8 分别为 YK4+865 断面关键施工步竖向位移云图与曲线图。

在隧道开挖过程中,位于隧道拱顶正上方的地表沉降与中部拱顶沉降趋势类似,最终约达到 −11.80 mm;受隧道浅埋偏压影响,拱顶沉降并非呈现完全中心对称分布,在大跨段隧道全断面,中部拱顶最终沉降最大,达到 −13.81 mm,左导洞次之,为 −11.89 mm,右导洞沉降最少,约为 −9.13 mm,围岩整体变形稳定,均小于施工预留变形量。受双侧壁导坑工法施工顺序影响,左导洞拱顶最先沉降,但在中部上导洞上台阶土体开挖后,整个拱顶失去其下土体的约束,竖向位移均明显增大,中部拱顶沉降速率最大,最终超过其他两侧拱顶。因此,中部上导洞开挖时应密切关注围岩变形,必要时预留核心土。

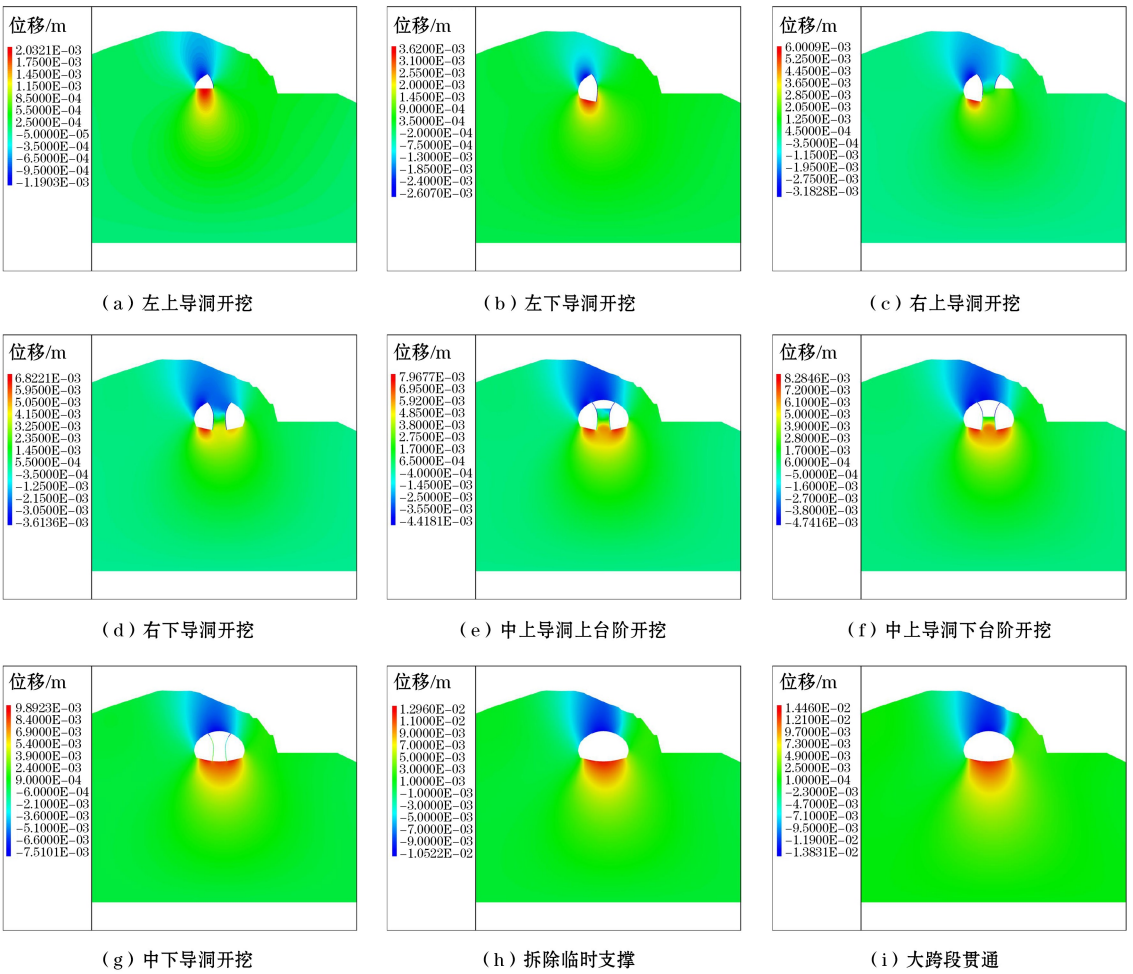


图 7 YK4+865 断面关键施工步竖向位移云图

Fig.7 Vertical deformation nephograms of key construction steps at YK4+865 section

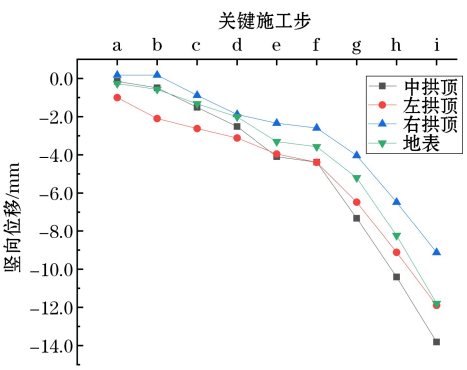


图 8 YK4+865 断面关键施工步竖向位移曲线

Fig.8 Vertical deformation curves of key construction steps at YK4+865 section

4 结论

本文融合了拉丁超立方体抽样和经过鲸鱼优化算法改进的极限学习机各自的优点，构建了 LHS-WOA-ELM 反演模型并将其应用于珠海市某大断面隧道工程进行围岩物理参数反演，成功验证了该方法的可靠性。

（1）基于 LHS 形成的初始样本能够考察所有参数的共同变化，同时能够保证每一个变量范围的全覆盖，更加符合超大断面隧道围岩力学参数的实际情形。

（2）通过非参数统计方法进行参数敏感性分析，确定了本隧道工程中地层物理力学参数对隧道断面拱顶沉降及地表变形的敏感度，其敏感度按从高到低的顺序为：$E>c>\varphi>\gamma>\mu$。后续选取地层的弹性模量 E、黏聚力 c 和内摩擦角 φ 作为反演分析基本参数，降低了反演模型的参数维度，减少了计算量。

（3）通过 WOA 算法对 ELM 模型的隐含层神经单元个数、初始输入权重与隐含层阈值进行优化，形成鲁棒性较强的 LHS-WOA-ELM 模型，并与其他模型进行对比，在保持较快的运算速度下显著地

提升了反演精确度,而 MSE 和 RMSE 都处于较低水平,表明了 LHS-WOA-ELM 模型训练效果良好。

(4) 将本文方法应用于珠海市超大断面隧道位移反分析中,获得了较为可靠的围岩参数反演结果,其中弹性模量 $E=1.01$ GPa,黏聚力 $c=1.25$ MPa,内摩擦角 $\varphi=25°$,验证了模型的实用性,提高了人工智能算法在岩土工程领域的工程应用价值,为相关的地下工程、矿业工程的岩体力学参数确定提供参考。

参考文献(References):

[1] 黄世顶,刘尧,邓红卫,等.基于修正 Mathews 稳定图法与 FLAC3D 的采场结构参数优化研究[J].矿业研究与开发,2024,44(4):10-18.
HUANG Shiding, LIU Yao, DENG Hongwei, et al. Optimization of stope structure parameters based on modified Mathews stability diagram method and FLAC3D [J]. Mining Research and Development,2024,44(4):10-18.

[2] 王述红,董福瑞.基于变形预测和参数反演的山岭隧道围岩稳定性分析[J].岩土工程学报,2023,45(5):1024-1035.
WANG Shuhong, DONG Furui. Stability analysis of surrounding rock of mountain tunnels based on deformation prediction and parameter inversion[J]. Chinese Journal of Geotechnical Engineering,2023,45(5):1024-1035.

[3] GIODA G, MAIER G. Direct search solution of an inverse problem in elastoplasticity: Identification of cohesion, friction angle and in situ stress by pressure tunnel tests[J]. International Journal for Numerical Methods in Engineering,1980,15(12):1823-1848.

[4] ZHANG Yan, SU Guoshao, LI Yao, et al. Displacement back-analysis of rock mass parameters for underground caverns using a novel intelligent optimization method[J]. International Journal of Geomechanics,2020,20(5):04020035.

[5] GHORBANI E, MOOSAVI M, HOSSAINI M F, et al. Determination of initial stress state and rock mass deformation modulus at Lavarak HEPP by back analysis using ant colony optimization and multivariable regression analysis [J]. Bulletin of Engineering Geology and the Environment,2021,80(1):429-442.

[6] 吴根水,余伟健,刘泽,等.软岩巷道岩体力学参数反演方法及工程应用[J].工矿自动化,2018,44(11):41-48.
WU Genshui, YU Weijian, LIU Ze, et al. Inversion method of mechanical parameter of rock mass in soft rock roadway and its engineering application industry and mine automation [J].Journal of Mine Automation,2018,44(11):41-48.

[7] 刘先珊,乔士豪,李俊平,等.鸡冠咀矿区岩体力学参数的确定及数值模拟反演分析[J].安全与环境学报,2023,23(7):2254-2263.
LIU Xianshan, QIAO Shihao, LI Junping, et al. Determination and numerical simulation inversion analysis of rock mechanics parameters in the Jiguanzui mining area[J]. Journal of Safety and Environment,2023,23(7):2254-2263.

[8] 王康伟,王文杰,张鹏强,等.金川三矿区巷道围岩松动圈厚度的确定及支护试验[J].矿业研究与开发,2024,44(1):125-131.
WANG Kangwei, WANG Wenjie, ZHANG Pengqiang, et al. Determination of the loose circle thickness of roadway surrounding rock and supporting test in Jinchuan No. 3 mining area[J]. Mining Research and Development,2024,44(1):125-131.

[9] 李步遥,司马军.基于 MEC-BP 神经网络的基坑水平位移反演分析[J].铁道科学与工程学报,2021,18(7):1764-1772.
LI Buyao, SIMA Jun. Horizontal displacement back-analysis for deep excavation using MEC-BP neural network [J]. Journal of Railway Science and Engineering,2021,18(7):1764-1772.

[10] 刘春,周义舒,刘海壮,等.基于改进 BP 神经网络的隧道位移反分析研究[J].公路,2021,66(9):385-392.
LIU Chun, ZHOU Yishu, LIU Haizhuang, et al. Research on back analysis of tunnel displacement based on improved BP neural network[J]. Highway,2021,66(9):385-392.

[11] 王述红,董福瑞,朱宝强,等.山岭隧道围岩参数智能反演及稳定性分析[J].应用基础与工程科学学报,2021,29(5):1171-1185.
WANG Shuhong, DONG Furui, ZHU Baoqiang, et al. Parameters intelligent inversion and stability analysis of surrounding rock of mountain tunnel[J]. Journal of Basic Science and Engineering,2021,29(5):1171-1185.

[12] 李林峰.基于位移反分析的拓宽路基差异沉降预测[J].公路交通科技,2015,32(1):57-62+109.
LI Linfeng. Prediction of differencial settlement of widened subgrade based on displacement back analysis[J]. Journal of Highway and Transportation Research and Development,2015,32(1):57-62+109.

[13] 肖明清,刘浩,彭长胜,等.基于神经网络的深厚软土地层参数反演分析[J].地下空间与工程学报,2017,13(1):279-286.
XIAO Mingqing, LIU Hao, PENG Changsheng, et al. Back analysis of deep soft soil parameters based on neural network[J]. Chinese Journal of Underground Space and Engineering,2017,13(1):279-286.

[14] 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(增刊 1):166-170.
RUAN Yongfen, YU Dongxiao, WU Long, et al. DE-GWO algorithm to optimize SVM inversion mechanical parameters of soft soil[J]. Chinese Journal of Geotechnical Engineering,2021,43(Suppl.1):166-170.

[15] 宋威,刘开云,梁军平,等.基于免疫多输出支持向量回归算法的隧道工程位移反分析新方法[J].铁道学报,2022,44(2):126-134.
SONG Wei, LIU Kaiyun, LIANG Junping, et al. New method for back analysis of tunnel displacement based on immune multiple output support vector regression algorithm [J]. Journal of the China Railay Society, 2022, 44(2): 126-134.

[16] 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,2000,42(1):55-61.

[17] 伍国军,陈卫忠,谭贤君,等.基于拉丁超立方抽样的有限元可靠度程序开发及应用[J].岩土力学,2015,36(2):550-554.
WU Guojun, CHEN Weizhong, TAN Xianjun, et al. Program development of finite element reliability method and its application based on Latin hypercube sampling[J]. Rock and Soil Mechanics,2015,36(2):550-554.

[18] 贾善坡,陈卫忠,李香玲.基于非参数统计的泥岩水-力耦合参数敏感性分析[J].地下空间与工程学报,2008(5):830-834.
JIA Shanpo, CHEN Weizhong, LI Xiangling. Parameter sensitivity analysis for seepage-stress couping model of boom clay based on non-parameter statistics[J]. Chinese Journal of Underground Space and Engineering,2008(5):830-834.

[19] SEYEDALLI M, ANDREW L. The whale optimization algorithm[J]. Advances in Engineering Software,2016,95:51-67.

[20] 许嘉琳.改进鲸鱼算法在矿井风量智能调控中的研究[D].徐州:中国矿业大学,2023.
XU Jialin. Research on improved whale algorithm in intelligent control of mine air volume[D]. Xuzhou: China University of Mining and Technology, 2023.

[21] 汪恩良,田雨,刘兴超,等.基于 WOA-BP 神经网络的超低温冻土抗压强度预测模型研究[J].力学学报,2022,54(4):1145-1153.
WANG Enliang, TIAN Yu, LIU Xingchao, et al. Prediction model of compressive strength of ultra low temperature frozen soil based on woa-bp neural network[J]. Chinese Journal of Theoretical and Applied Mechanics,2022,54(4):1145-1153.

[22] 卢雪琴,李长安,吴忠强.基于鲸鱼算法优化极限学习机的微电网故障诊断[J].智慧电力,2022,50(2):15-21.
LU Xueqin, LI Chang'an, WU Zhongqiang. Microgrid fault diagnosis based on extreme learning machine optimized by whale algorithm[J]. Smart Power,2022,50(2):15-21.

[23] LIANG Nanying, HUANG Guangbin, SARATCHANDRAN P, et al. A fast and accurate online sequential learning algorithm for feedforward networks[J]. IEEE Transactions on Neural Networks,2006,17(6):1411-1423.

[24] MALIHA A, YUSOF R, SHAPIAI M I. Extreme learning machine for structured output spaces[J]. Neural Computing and Applications,2018,30(4):1251-1264.

[25] 台启民,张顶立,房倩,等.软弱破碎围岩隧道超前支护确定方法[J].岩石力学与工程学报,2016,35(1):109-118.
TAI Qimin, ZHANG Dingli, FANG Qian, et al. Determination of advance supports in tunnel construction under unfavourable rock conditions[J]. Chinese Journal of Rock Mechanics and Engineering,2016,35(1):109-118.

[26] 伍振志,傅志锋,王静,等.浅埋松软地层开挖中管棚注浆法的加固机理及效果分析[J].岩石力学与工程学报,2005(6):1025-1029.
WU Zhenzhi, FU Zhifeng, WANG Jing, et al. Study of support mechanism and effect of shedgrouting technology for tunneling construction in shallow-buried soft stratum[J]. Chinese Journal of Rock Mechanics and Engineering,2005(6):1025-1029.

[27] 孙亚奇.超大断面公路隧道初期支护结构研究[D].上海:上海交通大学,2017.
SUN Yaqi. Study on primary support scheme of super-long-span highway tunnel[D]. Shanghai: Shanghai Jiao Tong Univesity,2017.

[28] 中华人民共和国交通运输部.公路隧道设计细则:JTG/T D70—2010[S].北京:人民交通出版社,2010.
Ministry of Transport of the People's Republic of China. Guidelines for design of highway tunnel:JTG/T D70—2010[S]. Beijing:China Communications Press,2010.