文章编号:2096-5052(2026)03-0115-07　　DOI:10.19952/j.cnki.2096-5052.2026.03.11

粉质黏土地层超大直径盾构掘进诱发地表变形智能预测研究

钟建敏[1],张晓平[2*],张亮亮[3],吴柯[2],唐少辉[4],鲁婧轲[2],陈鹏[5],游少强[5]

(1.济南城市建设集团有限公司, 山东 济南 250014;
2.武汉大学土木建筑工程学院 岩土与结构工程安全湖北省重点实验室, 湖北 武汉 430072;
3.中铁第四勘察设计院集团有限公司, 湖北 武汉 430063; 4.广西大学土木建筑工程学院, 广西 南宁 530004;
5.中铁十四局集团大盾构工程有限公司, 江苏 南京 211899)

摘要:为精准感知粉质黏土地层超大直径盾构掘进诱发的地表变形情况,有效控制开挖面前方地表变形风险,本研究考虑地层厚度和隧道埋深等因素,对土体物理力学参数进行修正;采用 MATLAB 软件建立反向传播(back propagation, BP)神经网络、支持向量机(support vector machine, SVM)和随机森林(random forest, RF)3 种地表变形预测模型;并通过交叉验证法、网格搜索法和经验公式确定地表变形预测模型的最优超参数组合。依托济南黄河济泺路粉质黏土地层超大直径隧道工程,对盾构掘进诱发地表变形进行智能预测分析,并采用均方误差(mean square error, E_{MS})、均方根误差(root mean square error, E_{RMS})、平均绝对值误差(mean absolute error, E_{MA})和决定系数(coefficient of determination, R^2)对预测结果的准确性进行评价。研究结果表明,随机森林模型预测误差最小,BP 模型预测误差次之,支持向量机模型预测误差最大且泛化能力相对较弱。相关研究成果可为类似工程地质条件下超大直径盾构掘进诱发地表变形智能预测提供借鉴参考。

关键词:盾构隧道;地表变形;机器学习;预测模型
中图分类号:U456.3; TU45　　**文献标志码**:A

引用格式:钟建敏,张晓平,张亮亮,等. 粉质黏土地层超大直径盾构掘进诱发地表变形智能预测研究[J]. 隧道与地下工程灾害防治,2026,8(3):115-121. Zhong Jianmin, Zhang Xiaoping, Zhang Liangliang, et al. Research on intelligent prediction of surface deformation induced by super-large diameter shield tunneling in silty clay ground[J]. Hazard Control in Tunnelling and Underground Engineering, 2026, 8(3):115-121.

Research on intelligent prediction of surface deformation induced by super-large diameter shield tunneling in silty clay ground

Zhong Jianmin[1], Zhang Xiaoping[2*], Zhang Liangliang[3], Wu Ke[2],
Tang Shaohui[4], Lu Jingke[2], Chen Peng[5], You Shaoqiang[5]

(1. Urban Construction Group Co., Ltd., Jinan 250014, Shandong, China;
2. Key Laboratory of Safety for Geotechnical and Structural Engineering of Hubei Province, School of Civil and Architecture Engineering, Wuhan University, Wuhan 430072, Hubei, China;
3. China Railway Siyuan Survey and Design Group Co., Ltd., Wuhan 430063, Hubei, China;
4. School of Civil Engineering and Architecture, Guangxi University, Nanning 530004, Guangxi, China;
5. Large Diameter Shield Engineering Co., Ltd., China Railway 14th Bureau Group, Nanjing 211899, Jiangsu, China)

收稿日期:2026-04-27;**修回日期**: 2026-05-19; **接受日期**:2026-05-27;**出版日期**:2026-09-20
基金项目:济南城市建设集团有限公司科技开发计划项目(2020W003);中铁第四勘察设计院集团有限公司科技研究项目(TSYSDY-JLLCHSD[2020]-04)
第一作者简介:钟建敏(1987—),男,山东济南人,工程师,主要研究方向为工程管理。E-mail:649854249@ qq.com
*通信作者简介:张晓平(1982—),男,江西九江人,教授,博士生导师,博士,主要研究方向为地下工程、岩土力学以及工程地质。E-mail:jxhkzhang@ 163.com

Abstract: To accurately predict surface deformation induced by super-large-diameter shield tunneling in silty clay, an intelligent prediction model based on machine learning was developed. The physical and mechanical parameters of the soil were corrected by considering stratum thickness and tunnel burial depth. Three surface-deformation prediction models, namely, a back-propagation (BP) neural network, a support vector machine (SVM), and a random forest (RF), were established in MATLAB. The optimum hyperparameter combinations were determined by cross-validation, grid search, and empirical formulas. Using data from the Jiluo Road Yellow River Tunnel in Jinan, the surface deformation induced by shield tunneling was predicted. Model accuracy was evaluated using mean square error (E_{MS}), root mean square error (E_{RMS}), mean absolute error (E_{MA}), and the coefficient of determination (R^2). The results showed that the RF model produced the smallest prediction error, followed by the BP neural-network model, whereas the SVM model produced the largest error and had relatively weak generalization ability. The proposed model provided a reference for predicting surface deformation induced by super-large-diameter shield tunneling under similar engineering-geological conditions.

Keywords: shield TBM; surface deformation; machine learning; prediction model

Received: 2026-04-27; **Revised**: 2026-05-19; **Accepted**: 2026-05-27; **Published**: 2026-09-20

0 引言

近年来随着城市建设不断推进和国民经济蓬勃发展,市政道路交通拥堵、地面空间负荷过大等问题逐渐显现,城市轨道交通、越江跨海隧道等地下空间的开发利用项目日益增加。隧道与地下工程建设过程中,盾构法以其掘进速度快、安全性能好、自动化程度高等优点,已经成为市政隧道建设中广泛使用的施工方法[1]。随着市政地下空间需求日趋大型化,超大直径水下隧道工程与日俱增,盾构施工正朝着大断面和长距离的方向发展[2]。国内外隧道工程案例表明,超大直径盾构掘进过程中极易诱发地表过度变形,严重影响自身结构稳定和地表建筑结构安全,容易造成工程安全事故和作业人员伤亡,造成严重的经济损失和不良社会影响。文献调研结果表明,针对超大直径盾构掘进引起地表变形问题的研究方法主要包括机器学习法、经验公式法、理论解析法、数值模拟法和模型试验法[3]。考虑到盾构掘进引起地表变形问题是一个典型的单变量多影响因素的非线性映射数学回归问题,采用机器学习模型具有不受计算理论中边界条件和本构关系的约束,具有较好的预测准确率[4]。目前,国内外许多学者通过建立机器数据智能预测模型对隧道地表变形进行了研究[5-6]。Suwansawat 等[7]通过人工神经网络(artificial neural network, ANN)建立注浆量、土压力等参数与地表变形量间的映射,并分析模型的预测能力以及局限性。Chen 等[8]结合长沙地铁四号线案例比较分析了 BP 神经网络(back propagation, BP)、径向基函数(radial basis function, RBF)神经网络以及广义回归神经网络(general regression neural network, GRNN)的预测准确性,并基于隧道几何条件修正土体物理力学参数。崔童[9]通过遗传算法优化得到 BP 神经网络的最优交叉率和变异率组合。Wang 等[10]通过 Monte Carlo 模拟建立了最小二乘支持向量机(least squares support vector machine, LS-SVM),并通过蚁群算法确定最优的超参数组合。李方毅等[11]通过粒子群算法选取并优化支持向量机(support vector machine, SVM)模型的超参数。Dindarloo 等[12]通过隧道埋深、直径和体积损失等参数建立决策树和随机森林模型并分析研究超参数的最优组合。此外,相关学者结合工程案例研究常用机器学习模型的预测准确性和适应性,如表 1 所示。

表 1 常用机器学习模型

Table 1 Several common machine learning models

模型名称	优缺点	超参数
ANN	非线性映射能力较强;易陷入局部最小值,收敛速度偏慢	隐含层数、节点个数
SVM	对小样本数据、高维数据处理分析能力较强;处理大数据样本时效率低	惩罚系数、核函数系数
决策树和随机森林(random forest, RF)[13]	处理高维非线性数据样本能力强;对异常值容忍度较好;模型训练效率较低	决策树数量、决策树特征数
自适应神经模糊系统(adaptive neuro-fuzzy inference system, ANFIS)[14]	具有人工神经网络和模糊理论系统优点,模型分析效率高	前件参数

综上所述,目前常用的地表变形预测模型有 BP、SVM 和 RF,不同智能预测模型的适用性存在差异,且机器学习超参数的选择对预测模型的准确度具有一定影响。此外,由于样本数据的数量和精确度不同,相关研究在粉质黏土地层中适用性仍需要进一步验证。因此,本研究针对超大直径盾构掘进诱发隧道地表变形,建立 3 种基于机器学习的智能预测分析模型,同时优化分析不同模型的最优超参数组合。依托济南黄河济泺路粉质黏土地层超大直径隧道,对盾构掘进诱发地表变形进行智能预测,并采用均方误差(mean square error, E_{MS})、均方根误差(root mean square error, E_{RMS})、平均绝对值误差(mean absolute error, E_{MA})和决定系数(coefficient of determination, R^2)对预测结果的准确性进行评价分析。

1　工程背景概况

1.1　工程地质概况

济南黄河济泺路隧道是国内首条穿越黄河的超大直径泥水平衡盾构隧道,采用了市政道路交通与城市轨道交通 2 号线合建方案,隧道设计开挖直径为 15.7 m。如图 1 所示,盾构沿线穿越居民区建筑群、黄河南北两岸大堤、绕城高架等多处建筑结构,因此合理调控施工参数,严格控制地表变形量,保证沿线建构筑物安全是本工程中的一个重难点。

沿线地质条件多为粉质黏土地层,其中夹杂有粉砂、细砂地层以及钙质结核,其中第四系全新统时期的粉质黏土呈软塑~可塑状,压缩性偏高,承载力偏低,工程性质一般;第四系上更新统时期的粉质黏土呈可塑~硬塑状,且局部富集钙质结核,工程性质相对较好。考虑到隧道所承受的最大水压为 6.5 bar 以及工程地质条件,本工程中选择抵抗高水压能力更好、地层适应性更广、压力调控更精准的泥水平衡盾构。

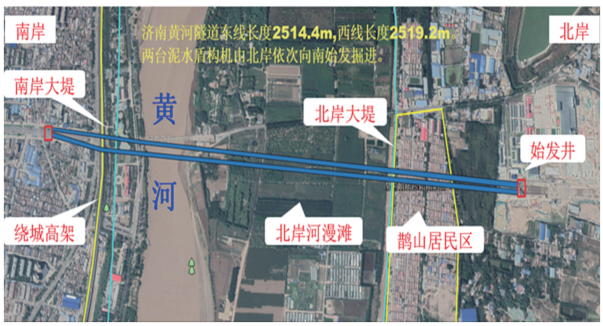


图 1　隧道线路平面示意图
Fig.1　Tunnel line plane diagram

1.2　变形监测方案

隧道横向监测断面垂直于东、西线隧道中心轴线布设,如图 2 所示。隧道横向监测断面的间距为 10 m,盾构始发及穿越建筑结构时按照 5 m 间距加密布设。地表变形监测点采用钻孔方式将螺纹钢打入地层的埋设方案。地表变形的监测频率为 2 次/天,盾构始发、穿越构筑物以及变形数据变化较大时调整为 2~4 次/天。

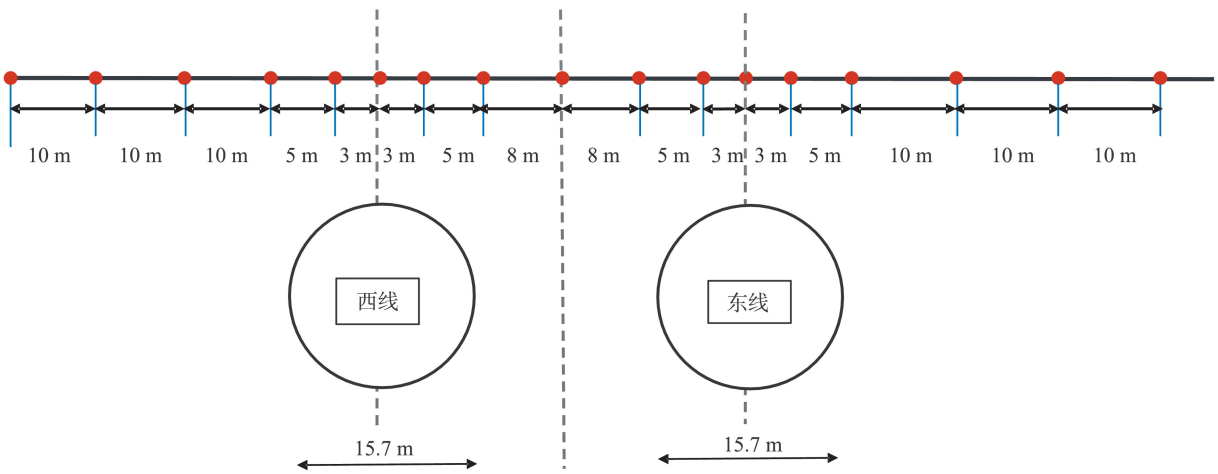


图 2　横向监测断面示意图
Fig.2　Horizontal monitoring section diagram

2　预测模型搭建流程

本研究使用 MATLAB 软件建立了 BP、SVM 和 RF 等 3 种机器学习算法模型,地表最终变形量预测模型的一般搭建流程如图 3 所示。

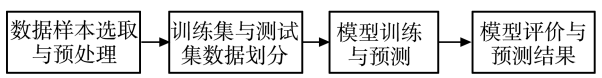


图 3　预测模型搭建流程
Fig.3　Prediction model building process

2.1 数据样本选取与预处理

盾构法施工中引起地表最终沉降变形的影响因素主要可以分为 3 类:隧道几何设计参数、工程地质参数以及盾构施工参数。结合相关文献研究中地表变形与施工参数相关性分析[15],最终选取 11 个参数作为模型的输入,地表最终变形量作为模型的输出,如图 4 所示。

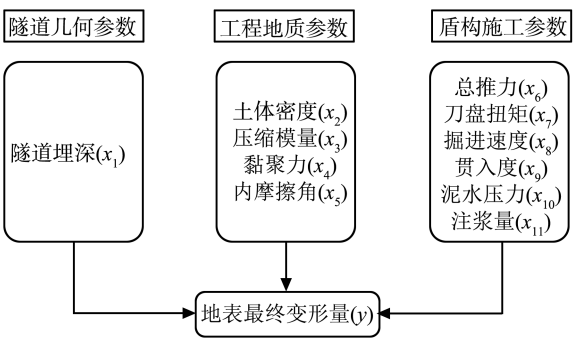


图 4 输入、输出参数分类与选取

Fig.4 Input and output parameter classification and selection

为综合考虑土层埋深位置以及厚度对地表变形的影响,本章引入修正因子[16]对土体的重度、压缩模量、黏聚力和内摩擦角进行修正,将每一层土体修正后求和得上覆地层修正后的土体物理力学参数。

$$\bar{a}_i = \frac{t_i}{h} \cdot \frac{h_i}{h} \cdot a_i , \tag{1}$$

$$\bar{a} = \sum_{i=1}^{n} \bar{a}_i , \tag{2}$$

式中:$\bar{a}_i$ 为第 i 层土体的修正后的物理力学参数;a_i 为第 i 层土体的原物理力学参数;t_i 为第 i 层土体的厚度,m;h_i 为第 i 层土体的埋深,m;h 为隧道埋深,m;$\bar{a}$ 为上覆土体修正后的物理力学参数,$\frac{t_i}{h} \cdot \frac{h_i}{h}$ 定义为修正因子。

该修正方法通过对不同埋深土层参数赋予与其埋深及厚度相关的权重,可更合理反映盾构扰动影响范围内上覆土体综合力学响应,该方法已在盾构沉降预测相关研究中得到验证[17]。

本研究选取济南黄河隧道先行东线 360~774 环区间中位于隧道轴线上方监测点处的地表最终变形量、盾构掘进参数、土体物理力学参数数据进行研究分析,共 68 组样本数据。选取 58 组数据进行预测模型训练,剩余 10 组数据用于地表变形的预测与分析。考虑到施工参数、地表最终变形量数据量纲和单位影响,为了提高神经网络模型的计算效率和准确性,借助 MATLAB 软件中的 mapminmax 函数进行归一化处理。考虑到工程监测数据获取成本较高及有效样本筛选要求严格,本研究采用交叉验证与独立测试集相结合的方法,以提升小样本条件下模型训练可靠性。

2.2 模型性能评价指标

采用数理统计中回归问题常用的回归模型评价指标 E_{MS}、E_{RMS}、E_{MA}、R^2 对盾构掘进诱发地表变形智能预测模型进行评价分析。

$$E_{\mathrm{MS}} = \frac{1}{n} \cdot \sum_{i=1}^{n} (y_i - y_i^*)^2 , \tag{3}$$

$$E_{\mathrm{RMS}} = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^{n} (y_i - y_i^*)^2} , \tag{4}$$

$$E_{\mathrm{MA}} = \frac{1}{n} \cdot \sum_{i=1}^{n} |y_i - y_i^*| , \tag{5}$$

$$R^2 = \frac{\sum (y_i^* - \bar{y}_i)^2}{\sum (y_i - \bar{y}_i)^2} , \tag{6}$$

式中:y_i 为实测地表变形量,mm;y_i^* 为预测地表变形量,mm;$\bar{y}_i$ 为样本的数据的平均值,mm,n 为样本数量。

3 超参数优化分析

3.1 BP 神经网络模型

BP 神经网络模型参数初始化中需要确定隐含层数和隐含层节点数这两个超参数,隐含层节点数过少模型会出现欠拟合,过多则会出现过拟合。相关文献研究指出单隐含层结构的神经网络就可以映射所有的连续函数,单隐含层模型中隐含层节点个数可根据以下公式进行估算[18]:

$$l < \sqrt{m+n} + a , \tag{7}$$

式中,l 为隐含层节点个数,m 为输出层节点个数,n 为输入层节点个数,a 为 1~10 之间的自然数。

根据式(7)初步确定隐含层节点数目的搜索区间范围为 4~13;当节点数大于 13 时,模型开始过拟合。使用 MATLAB 软件建立 BP 神经网络模型,采用留一法对样本数据进行训练,得出不同隐含层节点个数下预测模型的 E_{MS} 和 E_{MA}。为消除初始权重和阈值差异影响,各节点数重复训练 100 次,取平均误差,结果见图 5。可以得到隐含层节点个数大于 6 时,模型误差随着隐含层节点个数的增加而增加,当隐含层节点个数为 5 时,模型误差最小,E_{MA} = 1.28 mm, E_{MS} = 17.36 mm^2。

3.2 支持向量机模型

支持向量机模型中超参数包括惩罚系数 c 和核

函数参数 g,这里采用 5 折交叉验证和网格搜索法进行超参数的搜索寻优。网格搜索法中初步确定惩罚系数 c 和核函数参数 g 的搜索范围为[-2^{10}, 2^{10}],参数 c-step(为 c 取以 2 为底的对数)以及 g-step(为 g 取以 2 为底的对数)的单次步进幅度为 0.5,模型适应度值(E_{MA}误差)的单次步进幅度为 0.09。在搜索范围内计算不同 c 和 g 组合情况下模型误差变化情况,如图 6 所示。结果显示,当惩罚系数 c 和核函数参数 g 的取值分别为 0.353 55 和 8 时,模型 E_{MS} 误差值最小,为 0.163 8 mm^2。

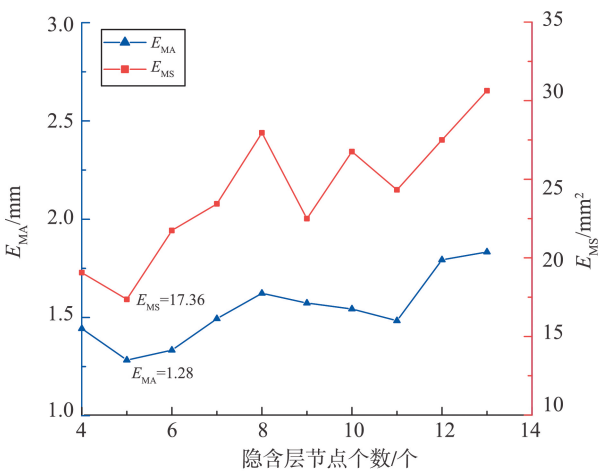


图 5　BP 神经网络性能与隐含层节点个数关系

Fig.5　Relationship between the performance of BP neural network and the number of hidden layer node

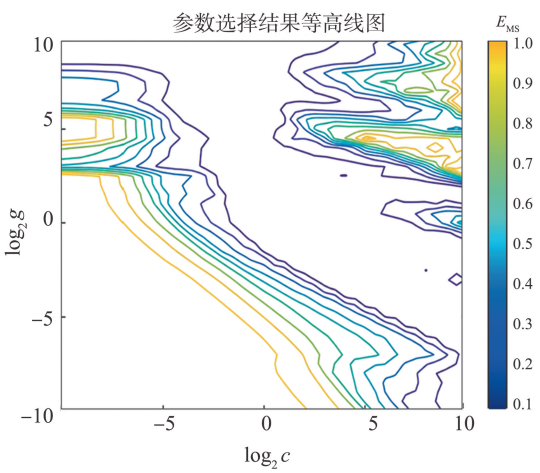


图 6　SVM 机器学习模型性能和超参数关系

Fig.6　SVM machine learning model performance and hyperparametric relationships

3.3　随机森林模型

随机森林模型中超参数包括决策树数量 n_{tree} 和变量特征数 a,提高决策树数量有利于提高模型预测精度和性能,但是决策树数量过大时会会降低模型的计算效率。变量特征数可根据以下公式进行估算[19]:

$$a=\log_2(m)+1, \tag{8}$$

式中,m 为模型输入变量的个数。

根据公式(8)确定变量特征数为 5,决策树的数量 n_{tree} 采用网格搜索法进寻优,初步确定搜索区间范围为 0~300,决策树数量单次步进幅度为 10。采用训练集的样本数据进行 100 次重复模型训练,对比分析不同决策树数量下模型的平均 E_{MA} 和平均 E_{MS},如图 7 所示。结果显示决策树数量在 0~50 个之间时模型的预测误差随着 n_{tree} 的增加而减少,继续增加决策树数量,模型预测精度的提升幅度有限,因此可以得到最优的决策树的数量为 170 个,此时模型的 E_{MA} 值为 0.49 mm,E_{MS} 值为 3.43 mm^2。当 n_{tree} 超过 170 后,模型误差下降趋于平缓,继续增加树数量仅带来有限精度增益,但会增加训练计算成本,因此选取 170 作为兼顾预测精度与计算效率的最优参数。

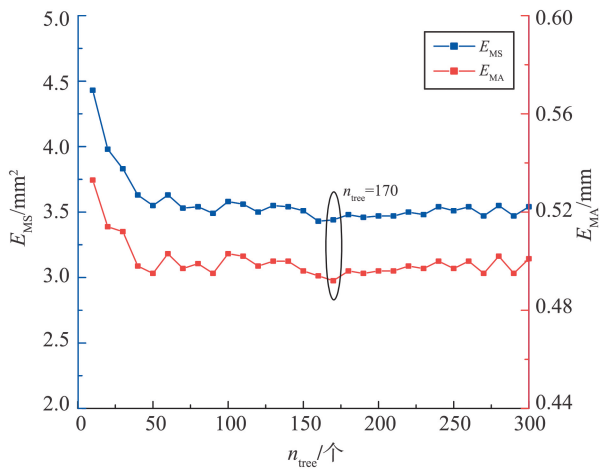
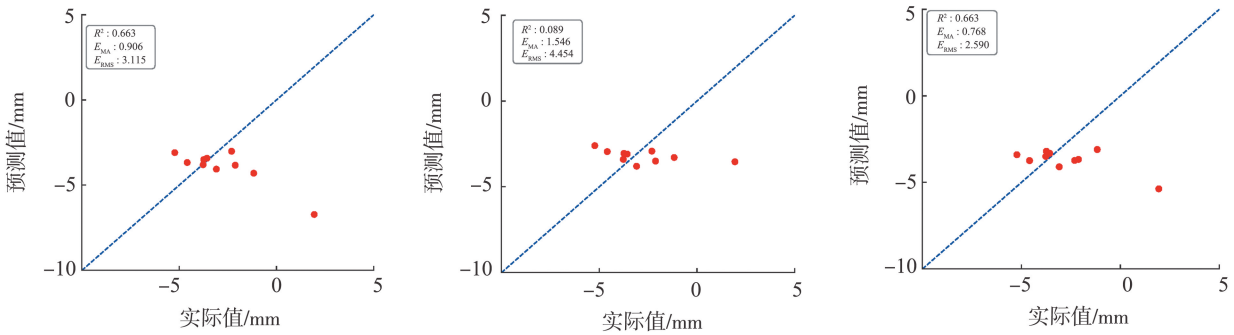


图 7　随机森林机器学习模型性能和决策树数量关系

Fig.7　Relationship between stochastic forest machine learning model performance and decision tree quantity

4　模型预测结果分析

基于 2.1 部分所述,从隧道轴线上方监测点数据中采用 58 组训练集样本确定 3 个机器学习模型的最优超参数组合后,利用该 58 组数据完成模型训练,并采用剩余的 10 组测试集样本对模型的预测准确度进行验证。如图 8 所示,BP 神经网络模型的预测结果为:R^2 = 0.663, E_{MA} = 0.906 mm, E_{RMS} = 3.115 mm;支持向量机模型的预测结果为:R^2 = 0.089, E_{MA} = 1.546 mm, E_{RMS} = 4.545 mm,结果显示随着样本复杂程度增加模型更易陷入过拟合状态,对偏离样本均值的数据无法进行有效预测,即模型的泛化能力相对较弱;随机森林模型的预测结果为:R^2 = 0.663, E_{MA} = 0.768 mm, E_{RMS} = 2.590 mm。相较于 BP 神经网络和支持向量机模型 SVM,随机森林模型的误差最小。



(a) BP模型预测结果 (b) SVM模型预测结果 (c) 随机森林模型预测结果

图 8 机器模型预测结果

Fig.8 Machine model prediction results

测试集中地表变形实际值与 3 种模型的预测值对比情况如图 9 所示，结合 R^2、E_{MA} 和 E_{RMS} 可知模型预测能力排序为：RF>BP>SVM。其中，随机森林模型预测能力最优，支持向量机在最优超参数组合情况下模型的泛化能力相对最弱。此外，3 种模型对于较大的沉降变形量以及隆起变形量预测能力均相对偏弱。

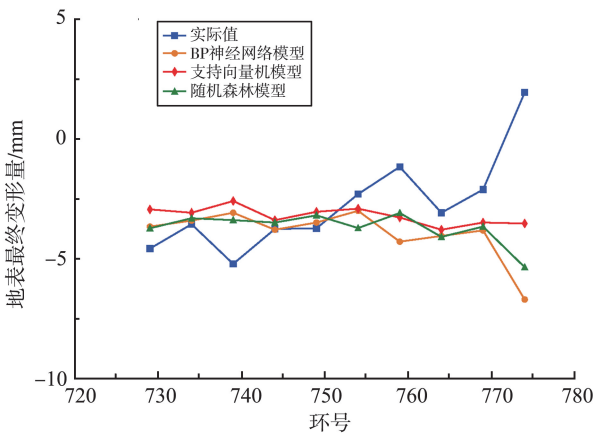


图 9 预测结果对比图

Fig.9 Comparison of prediction results

测试集样本三种模型的预测值与实际值的误差大小比较如图 10 所示。

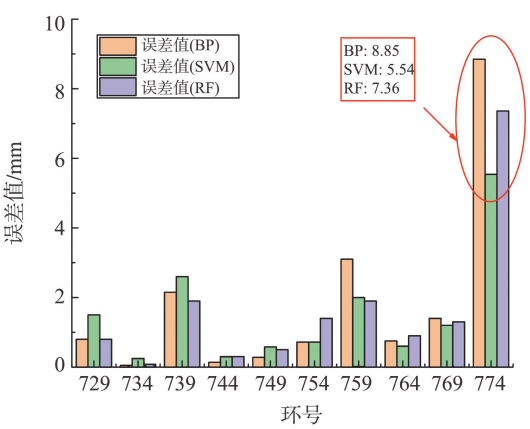


图 10 预测误差对比图

Fig.10 Comparison of prediction errors

由图 10 可知，前九组盾构施工环号对应的预测误差均在4 mm内，第十组数据样本的地表变形为隆起变形，各模型的预测误差值分别为 8.85，5.54 和 7.36 mm，预测模型误差值均较大，分析可得在训练集样本中隆起变形数据较少，机器学习模型无法充分识别输入参数与隆起变形量之间的规律，因此地表隆起变形量的预测能力较弱。

5 结论与展望

本研究通过建立 BP、SVM 和 RF 3 种地表变形智能预测模型，并确定地表变形预测模型的最优超参数组合。依托济南黄河济泺路隧道，对盾构掘进诱发地表变形进行智能预测。采用 E_{MS}、E_{RMS}、E_{MA} 和 R^2 对预测结果的准确性进行评价，结论如下：

（1）BP 神经网络最优隐含层节点数为 5，平均 $E_{MS}=17.36\ mm^2$。SVM 模型最优惩罚系数 $c=0.353\ 55$，核函数参数 $g=8$，平均 $E_{MS}=0.163\ 8\ mm^2$。随机森林模型决策树的最优数量为 170 个，平均 $E_{MS}=3.43\ mm^2$。

（2）测试集样本中 3 种盾构掘进诱发地表变形智能预测模型误差均小于 4 mm。其中，随机森林模型对地表最终变形量的预测误差最小，BP 神经网络模型预测误差次之，支持向量机模型预测误差最大且泛化能力相对较弱。

未来的研究工作将聚焦于以下 2 个方面：一是深度挖掘施工监测大数据，建立跨工区、多源异构的盾构掘进数据库，以突破小样本对模型泛化性能的制约；二是探索更具先进性的智能算法体系，尝试将贝叶斯优化、群智能寻优策略与深度集成学习框架相结合，旨在构建更高维度、具备强实时性的地表变形智能感知模型，从而为超大直径盾构安全掘进提供更为可靠的决策支撑。

参考文献：

[1] 王振峰. 卵石地层中地铁隧道盾构施工引起的地表沉降

研究[D]. 西安: 西安科技大学, 2013: 1-6.
Wang Zhenfeng. Study on ground surface settlement due to metro shield[D]. Xi′an: Xi′an University of Science and Technology, 2013: 1-6.

[2] 唐少辉, 张晓平, 刘浩, 等. 复杂地层水下盾构隧道工程难点及关键技术研究与展望[J]. 工程地质学报, 2021, 29(5): 1477-1487.
Tang Shaohui, Zhang Xiaoping, Liu Hao, et al. Engineering difficulties and key technologies for underwater shield tunnel in complex ground[J]. Journal of Engineering Geology, 2021, 29(5): 1477-1487.

[3] 赵辰洋, 罗毛毛, 邱静怡, 等. 盾构隧道施工引起地层变形预测方法综述[J]. 隧道与地下工程灾害防治, 2022, 4(3): 31-46.
Zhao Chenyang, Luo Maomao, Qiu Jingyi, et al. Prediction of shield tunnelling induced ground movements: the state-of-the-art[J]. Hazard Control in Tunnelling and Underground Engineering, 2022, 4(3): 31-46.

[4] 丁智, 李鑫家, 张霄. 基于机器学习的盾构掘进地表变形预测研究与展望[J]. 隧道与地下工程灾害防治, 2022, 4(3): 1-9.
Ding Zhi, Li Xinjia, Zhang Xiao. Research and prospect of surface deformation prediction of shield tunneling based on machine learning[J]. Hazard Control in Tunnelling and Underground Engineering, 2022, 4(3): 1-9.

[5] Chen Weizhong, Tan Xuyuan, Yang Jianping. Review of state-of-the-art in structural health monitoring of tunnel engineering[J]. Smart Underground Engineering, 2025, 1(1): 40-50.

[6] Liu Xian, Gu Kejie, Zhang Baichuan, et al. Automated quantification of longitudinal joint opening in shield tunnels using enhanced multi-modal YOLO and laser scanning[J]. Smart Underground Engineering, 2025, 1(2): 113-134.

[7] Suwansawat S, Einstein H H. Artificial neural networks for predicting the maximum surface settlement caused by EPB shield tunneling[J]. Tunnelling and Underground Space Technology, 2006, 21(2): 133-150.

[8] Chen R P, Zhang P, Kang X, et al. Prediction of maximum surface settlement caused by earth pressure balance (EPB) shield tunneling with ANN methods[J]. Soils and Foundations, 2019, 59(2): 284-295.

[9] 崔童. 大直径泥水平衡盾构施工过程中地层变形特征及地表沉降预测研究[D]. 上海: 上海交通大学, 2019: 65-74.
Cui Tong. Study on deformation characteristics and surface settlement prediction of large slurry balance shield during construction[D]. Shanghai: Shanghai Jiao Tong University, 2019: 65-74.

[10] Wang Y H, Zhao X Y, Wang B T. LS-SVM and Monte Carlo methods based reliability analysis for settlement of soft clayey foundation[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2013, 5(4): 312-317.

[11] 李方毅, 张晓平, 许丹, 等. 基于支持向量机的气压辅助掘进条件下盾构隧道地表变形预测研究[J]. 隧道建设(中英文), 2021, 41(7): 1159-1165.
Li Fangyi, Zhang Xiaoping, Xu Dan, et al. Prediction of surface deformation of a shield tunnel using air pressure-assisted tunneling based on support vector machine [J]. Tunnel Construction, 2021, 41(7): 1159-1165.

[12] Dindarloo S R, Siami-Irdemoosa E. Maximum surface settlement based classification of shallow tunnels in soft ground[J]. Tunnelling and Underground Space Technology, 2015, 49: 320-327.

[13] 刘凯. 随机森林自适应特征选择和参数优化算法研究[D]. 长春: 长春工业大学, 2018: 22-29.
Liu Kai. Research on adaptive feature selection and parameter optimization algorithm for random forest[D]. Changchun: Changchun University of Technology, 2018: 22-29.

[14] Ahangari K, Moeinossadat S R, Behnia D. Estimation of tunnelling-induced settlement by modern intelligent methods[J]. Soils and Foundations, 2015, 55(4): 737-748.

[15] 吴柯, 张晓平, 刘浩, 等. 粉质黏土地层超大直径泥水盾构隧道地表变形与施工参数相关关系研究[J]. 工程地质学报, 2021, 29(5): 1555-1566.
Wu Ke, Zhang Xiaoping, Liu Hao, et al. Correlation between surface deformation and construction parameters in silty clay ground tunneling with super large diameter slurry shield tbm[J]. Journal of Engineering Geology, 2021, 29(5): 1555-1566.

[16] 陈仁朋, 戴田, 张品, 等. 基于机器学习算法的盾构掘进地表沉降预测方法[J]. 湖南大学学报(自然科学版), 2021, 48(7): 111-118.
Chen Renpeng, Dai Tian, Zhang Pin, et al. Prediction method of tunneling-induced ground settlement using machine learning algorithms [J]. Journal of Hunan University (Natural Sciences), 2021, 48(7): 111-118.

[17] 杨益, 李兴高, 蒋兴起, 等. 粉质黏土地层盾构施工地表沉降关键参数分析与预测[J]. 城市轨道交通研究, 2021, 24(9): 98-103.
Yang Yi, Li Xinggao, Jiang Xingqi, et al. Analysis and prediction of key parameters of ground surface settlements due to shield tunneling in silty clay stratum[J]. Urban Mass Transit, 2021, 24(9): 98-103.

[18] 沈花玉, 王兆霞, 高成耀, 等. BP 神经网络隐含层单元数的确定[J]. 天津理工大学学报, 2008, 24(5): 13-15.
Shen Huayu, Wang Zhaoxia, Gao Chengyao, et al. Determining the number of BP neural network hidden layer units[J]. Journal of Tianjin University of Technology, 2008, 24(5): 13-15.

[19] Breiman L. Random forests[J]. Machine Learning, 2001, 45(1): 5-32.

(编辑:张延欢)