

doi:10.12068/j.issn.1005-3026.2024.12.012

基于Optuna-XGBoost的砂土地层盾构渣土改良剂预测

曹秀梅¹, 赵文¹, 王志国¹, 何鹏²

(1. 东北大学 资源与土木工程学院, 辽宁 沈阳 110819; 2. 沈阳盾构设备工程有限公司, 辽宁 沈阳 110819)

摘要: 渣土改良是解决土压平衡盾构施工过程中刀盘“结泥饼”、刀具磨损等施工难题的有效措施。采用机器学习模型预测随地质条件变化的改良剂用量不仅可以降低上述施工风险,还弥补了试验法确定改良剂用量的滞后性。依托沈阳地铁四号线区间盾构项目,对1396环砂土地层掘进数据进行预处理,将扭矩切深指数(TPI)和场切深指数(FPI)作为渣土改良效果判据并选择出优良数据集,建立Optuna-XGBoost改良剂预测模型。研究表明,Optuna算法在超参数优化上与其他算法相比有明显的优势;Optuna-XGBoost与其他5种预测模型相比,在地质条件变化的情况下可实现更高精度预测。

关键词: 土压平衡盾构;渣土改良;掘进参数;地层参数;预测模型

中图分类号: TU 93 文献标志码: A 文章编号: 1005-3026(2024)12-1769-09

Prediction of Soil Conditioners for Sandy Soil Shield Based on Optuna-XGBoost

CAO Xiu-mei¹, ZHAO Wen¹, WANG Zhi-guo¹, HE Peng²

(1. School of Resources & Civil Engineering, Northeastern University, Shenyang 110819, China; 2. Shenyang Shield Equipment Engineering Co., Ltd, Shenyang 110819, China. Corresponding author: ZHAO Wen, E-mail: zhaowen@mail.neu.edu.cn)

Abstract: Soil conditioning is an effective measure to solve the problems in the construction process of earth pressure balance (EPB) shield, such as cutter clogging and cutter abrasions. The use of machine learning models to predict soil conditioners varying with geological conditions can not only reduce the aforementioned construction risks, but also make up for the lag in determining the amount of modifier by test method. Based on the shield project of Shenyang Metro Line 4, the excavation data of 1396 ring are preprocessed, and torque penetration index (TPI) and field penetration index (FPI) are used as the criteria for the soil conditioning effect to select good datasets. The Optuna-XGBoost model is established to predict the soil conditioners. The results show that Optuna algorithm owns obvious advantages over other methods in hyperparameters optimization. Compared with the other five prediction models, Optuna-XGBoost model owns higher accuracy under changeable geological conditions.

Key words: earth pressure balance shield; soil conditioning; tunneling parameters; geological parameter; prediction model

土压平衡盾构机由于其控制技术先进、对周围环境影响小、施工安全性高等优点,广泛应用于城市隧道施工。然而,由于工程地质、水文条件复杂,盾构机掘进过程中存在刀盘“结泥饼”、土舱内渣土固结、刀具磨损、螺旋输送机出口喷涌

等施工风险。渣土改良是解决上述施工难题的有效辅助措施,通过向刀盘前方、土舱和螺旋输送机内注入改良剂,可使渣土具有良好的塑流性、较低的抗剪强度和黏附强度、较小的渗透系数和一定的压缩性,从而降低施工风险^[1-3]。

收稿日期: 2023-07-12

作者简介: 曹秀梅(1998-),女,山东济南人,东北大学硕士研究生;赵文(1962-),男,辽宁沈阳人,东北大学教授,博士生导师。

常用的盾构渣土改良剂有泡沫剂、膨润土等,泡沫剂^[4]可改善渣土塑流性、抗渗性、压缩性,对各种地层具有通用性;膨润土^[5]通过改善渣土黏聚力,从而增加渣土的塑流性,适用于缺乏细粒的地层。目前,针对渣土改良剂用量判断主要依靠试验法,包括评价塑流性的坍落度试验;评价渗透性的渗透试验;评价黏附性的滑动试验、搅拌黏附试验;评价抗剪强度的直剪试验、锥入度试验等^[6]。试验法确定了砂^[7-8]、砂卵石^[9]、富水砂^[10]等地层的渣土改良方案。然而,对于地层条件复杂多变的地区,需针对不同地质土样进行多组试验,工作量大、耗时长,且盾构掘进时渣土力学状态十分复杂,很难模拟真实工况。因此,亟需一种适应地层和工况变化的高精度、高效率渣土改良参数决策方案。

近年来,机器学习算法因具有表达能力强、准确率高等优点得到迅速发展。在渣土改良方面,展超^[11]采用BP神经网络预测富水砂层改良渣土的内摩擦角、渗透系数,平均预测误差在5%以内。部分学者采用机器学习对施工数据进行分析。Lin等^[12]建立了贝叶斯优化的随机森林模型,采用盾构掘进参数、地质条件参数预测泡沫剂参数,实现了多变地质条件下泡沫用量的实时、高精度预测。李琛等^[13]提出一种CSDnet改良渣土

塑流性检测方法,确定了渣土塑流性形态的划分。

现有研究大多通过试验或图像判断改良效果,对掘进数据与改良效果内在联系的研究较少。本文提出随地层和工况变化的泡沫剂、膨润土决策方案。首先,筛选出正常掘进的数据并进行异常值处理、数据平滑,根据不同地层TPI-S、FPI-S曲线筛选出改良效果较好的数据集;然后,对筛选出的盾构机运行数据与勘探得到的地层参数进行相关性分析与数据降维;最后,建立Optuna-XGBoost改良剂预测模型,将低维特征作为输入,实现改良剂参数(泡沫原液、泡沫浓度、膨润土泥浆)的实时预测。

1 工程概况

本文数据来自沈阳地铁四号线市府大路站—太原街站区间左线隧道工程,全程约1 882 m,隧道盾构掘进面先后经过圆砾、砾砂、中粗砂、粉细砂、粉质黏土地层。根据地质勘探报告,得到各地层物理力学性质如表1所示。盾构机主要设备参数如表2所示。盾构机装有掘进数据采集系统,10 s采集一次,区间有效采集到1 396环掘进数据,部分数据如表3所示。

表1 各地层性质
Table 1 Different geological properties

地层	标准贯入击数	动弹性模量 E_d/MPa	动剪切模量 G_d/MPa	天然密度 $\rho_0/(\text{g}\cdot\text{cm}^{-3})$	黏聚力 C/kPa	内摩擦角 $\varphi/(\text{°})$	渗透系数 $K/(\text{m}\cdot\text{d}^{-1})$	变形模量 E_0/MPa
圆砾	31.3	675.7	229.4	2.00	0	35	90	35
砾砂	27.4	723.0	250.0	2.00	0	32	65	32
中粗砂	25.1	579.0	198.0	1.99	0	31	30	26
粉细砂	23.1	283.1	102.2	2.00	0	28	6	15
粉质黏土	8.5	273.7	92.0	1.94	21	16	0.02	16

表2 盾构机设备参数
Table 2 Shield machine equipment parameters

参数	值	参数	值
开挖直径/m	6.28	推进油缸数量	32
刀盘转速/($\text{r}\cdot\text{min}^{-1}$)	0~3.7	最大推力/kN	40 860
刀盘最大扭矩/($\text{kN}\cdot\text{m}$)	7 200	推进速度/($\text{mm}\cdot\text{min}^{-1}$)	0~100
刀盘开口率/%	55	螺旋输送机转速/($\text{r}\cdot\text{min}^{-1}$)	0~19
功率/kW	1 799		

2 数据筛选

2.1 参数选择

1) 掘进参数。渣土改良的最终目的是保证盾

构机安全顺利地掘进,改良效果应经得起掘进参数的检验^[6]。国内外学者验证了改良剂与刀盘扭矩、总推力、掘进速率等有着高相关性^[14-16]。刀盘扭矩在一定程度上反映了开挖地层的软硬程度和地层阻力,未改良的渣土与刀盘摩擦力大、塑

流性差,易凝结成块,扭矩随之增大;改良渣土塑性得以改善,土体更容易被切削,相应的刀盘扭矩减小^[7,17].同时,改良渣土和盾构机机械部件之间的摩擦力变小,螺旋输送机扭矩随之降低.此外,改良渣土在土舱内被搅拌得更均匀,能更好地传递顶推力,在降低总推力的同时,土舱压力更加稳定^[9];盾构掘进得更顺利,掘进速度随之提升.综上,掘进参数能在一定程度上反映渣土改良的效果.将刀盘扭矩、土舱压力、螺旋输送机扭矩、总推力、掘进速度、刀盘转速、螺旋输送机转速,共7个掘进参数作为模型备选输入参数.

2) 地层参数.地层性质对改良剂用量和盾构机排土效率有显著影响^[18],地层参数考虑了隧道

几何参数和地质条件参数.

隧道几何参数包括隧道直径、隧道埋深,在同一区间内隧道直径不变,故仅考虑隧道埋深作为输入参数.本文选取标准贯入击数、动弹性模量、动剪切模量、天然密度、黏聚力、内摩擦角、渗透系数、变形模量共8个地质条件参数作为模型备选输入参数.钻孔处的地层信息由勘察测得,结果较为准确,计算各钻孔处掌子面中线的各地层占比(见图1),根据占比获取各地层参数的加权平均值,见式(1).两钻孔之间的地层参数采用线性插值获取,最终将地层参数对应到掘进环中.

表3 1~1396环掘进数据
Table 3 Tunneling data of 1~1396 ring

环号	记录时刻	刀盘扭矩 kN·m	刀盘转速 r·min ⁻¹	总推力 kN	推进速度 mm·min ⁻¹	螺旋输送机扭矩 kN·m	螺旋输送机转速 r·min ⁻¹	土舱压力 bar
1	15:45:00	1 020.251	1.174	2 290.500	0.318	0	0.090	1.16
1	15:45:10	964.438	1.176	2 579.734	1.591	0	0.090	1.17
1	15:45:20	1 016.740	1.175	4 023.811	11.140	0	0.009	1.24
1	15:45:30	995.710	1.172	5 367.500	14.004	5.608	5.608	1.29
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1 396	6:30:10	3 184.901	1.179	12 252.636	95.487	33.701	13.012	1.84
1 396	6:30:20	3 412.209	1.175	12 148.345	97.714	35.439	13.064	1.89
1 396	6:30:30	3 681.826	1.153	12 279.574	91.985	34.129	13.125	1.86
1 396	6:30:40	3 857.941	1.144	12 409.705	93.257	34.746	13.030	1.85




图1 地层占比示意图

Fig. 1 Stratigraphic proportion diagram

$$\alpha = \frac{h_1}{D} \cdot \alpha_1 + \frac{h_2}{D} \cdot \alpha_2 \quad (1)$$

式中: α 表示地质条件参数加权平均值; α_1, α_2 表示不同地层的地质参数; h_1, h_2 表示不同地层厚度; D 表示开挖直径.

3) 改良剂参数.本项目区间地层大多为砂土,极少为粉质黏土,采用的渣土改良剂为泡沫剂、膨润土泥浆.其中,泡沫剂、膨润土泥浆、泡沫剂体积比(泡沫原液体积与泡沫溶液体积比值)随地层变化;膨润土质量与膨润土泥浆质量比值

固定为20%,将每环累计泡沫原液用量、泡沫剂体积比、膨润土泥浆用量作为输出参数.

2.2 盾构掘进数据预处理

盾构机并非一直处于掘进状态,如图2a所示,以第401~404环刀盘扭矩为例,盾构机在每完成1环的推进后,都会待机进行管片拼接,这时盾构机的很多状态参数均为0,没有预测价值,需剔除.

如图2b所示,盾构机从待机状态到正常掘进状态是一个逐渐变化的过程,这部分数据变化较大难以反映正常掘进状态,且会极大增加预测模型误差,因此需舍弃.通过观察数据情况,认为启动时前2 min内(即前12组原始数据)为启动阶段.

由于人工控制失误或机械故障等原因,难以避免采集到异常值,这会影响预测模型拟合精度,因此本文采用箱型图法检测并删除异常值,如图2c所示.考虑到研究区间掘进参数变化较大,采用箱型图对区间整体数据处理会误删有效

数据,而单环地质变化不大,故逐环剔除异常值.

最后将经上述处理后的掘进参数以环为单位进行平均,区间整体刀盘扭矩如图 2d 所示.为

避免数据波动影响模型效率,采用相邻均值法进行数据平滑,当设置窗口点数为 5 时平滑效果较好,平滑后数据如图 2e 所示.




图 2 数据预处理

Fig. 2 Data preprocessing

(a)—原始数据; (b)—删除停机值; (c)—异常值检测; (d)—删除启动值、异常值; (e)—数据平滑.

原始数据中各数据量级和单位差异较大,会影响有效信息的提取和机器学习模型计算效率,因此需进一步作标准化处理,标准化计算公式为

$$z = \frac{x - \mu}{\sigma} \quad (2)$$

式中: z 为标准化后的数值; x 为数据值; μ 为均值; σ 为标准差.

2.3 优良数据选取

本文研究目的是预测随掘进参数与地质条件变化的最佳改良剂用量,相应地在训练模型时也应选用改良效果相对较好的数据集.改良效果相对较好的评价指标在掘进参数角度以现有的理论知识难以定量分析,大多是对比改良前后掘进参数的变化情况,根据已有研究^[7]和现场施工反馈,最值得关注的掘进参数是刀盘扭矩和总推力.

不同地层掘进难易程度不同,在评价渣土改良效果时,忽略地层条件,仅比较掘进参数是没有意义的.刀盘贯入度的大小可直观反映地层掘进难易程度^[19],贯入度作为推进速度与刀盘转速的比值,数值越大表明单圈切深越大,刀盘前方土体越容易被切削;数值越小表明单圈切深越小,刀盘前方土体越难以被切削.研究表明^[20],扭矩切深指数(torque penetration index, TPI)、场切

深指数(field penetration index, FPI)可间接反映渣土改良的有效性.TPI为单位掘进深度所需的刀盘扭矩,FPI为单位掘进深度所需的推力,两者反映了推进时的地层阻力,公式如下:

$$TPI = \frac{T}{S} \quad (3)$$

$$FPI = \frac{F}{S} \quad (4)$$

式中: T 为刀盘扭矩($\text{kN}\cdot\text{m}$); F 为刀盘主推力(kN); S 为刀盘贯入度($\text{mm}\cdot\text{r}^{-1}$).

TPI和FPI变化趋势见图 3a, TPI和FPI表现出较明显的波动性,其原因与地层变化有密切关系.根据地层不同,将区间划分为 3 部分,分别拟合 TPI-S, FPI-S 曲线,如表 4 所示.图 3b 为 0~442 环 TPI 随贯入度变化曲线, TPI 分布总体上随着刀盘贯入度的增大表现为负指数减小趋势.图 3c 为 0~442 环 FPI 随贯入度变化曲线, FPI 分布总体上表现出与图 3b 相似的变化趋势,与杨果林等^[19]研究具有相同变化趋势.图 3b 和图 3c 拟合曲线下方的数据表示在地层条件相似、贯入度相同、盾构机配制相同情况下,所需的刀盘扭矩与总推力更小,认为此刻的渣土改良效果相对更好,故将 TPI-S, FPI-S 拟合曲线下方的累计 618 环数据作为改良效果相对较好的数据,用于构建模型.

表 4 不同掘进段 TPI, FPI 拟合曲线
Fig.4 TPI and FPI fitting curves of different excavation sections

环数	地层	TPI	FPI
0~442	砾砂、中粗砂、圆砾、粉质黏土	$1\ 781.78 S^{-0.81}$	$3\ 635.77 S^{-0.65}$
443~976	砾砂、中粗砂、圆砾	$11\ 249.88 S^{-1.27}$	$933\ 821.73 S^{-1.9}$
977~1\ 396	砾砂、中粗砂、粉质黏土	$1\ 229.02 S^{-0.74}$	$64\ 252.37 S^{-1.36}$

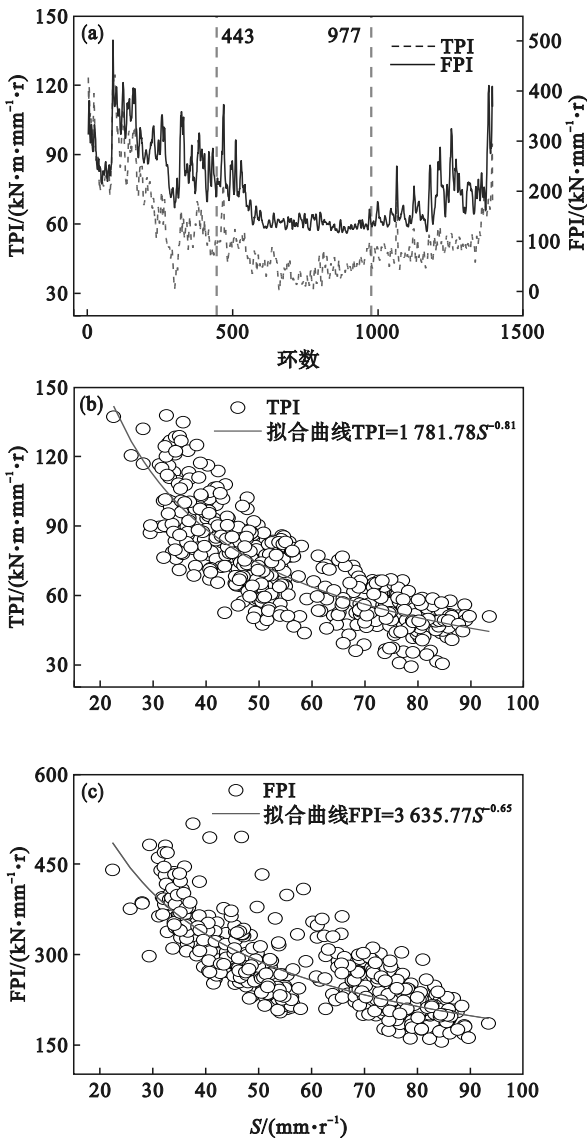


图 3 TPI 与 FPI 变化曲线

Fig. 3 TPI and FPI variation curves

(a)—TPI 和 FPI 随环数变化曲线; (b)—TPI-S 曲线;
(c)—FPI-S 曲线.

2.4 相关性分析与降维

本文采用 Pearson 相关系数法进行相关性分析, Pearson 相关系数用于度量 2 个变量之间的线性相关性. 相关系数取值范围介于 -1~1 之间, 其绝对值越接近 1, 表示 2 个变量之间相关性越强; 越接近 0, 表示 2 个变量之间相关性越弱. 由图 4 可知, 初选的 16 个特征之间存在很强的相关性,

说明数据中有高度重复、冗余信息, 因此需作降维处理. 主成分分析 (principal component analysis, PCA) 是一种常用数据降维方法, 在保留更多的有效信息的同时, 有效避免了冗余特征影响模型计算效率. 本文对初步筛选的 16 个数据作主成分分析, 结果如图 5 所示, 当主成分个数为 7 时, 累计方差贡献率大于 0.95, 故选取前 7 个主成分作为模型输入参数, 舍弃方差贡献率低的数据.

3 基于 Optuna-XGBoost 的改良剂用量预测模型

3.1 XGBoost 算法

本文采用 XGBoost (极限梯度提升) 算法预测盾构渣土改良剂用量, XGBoost 是 Chen 等^[21]提出的一个梯度提升的开源框架, 属于集成决策树模型, 具有高效性和灵活性. XGBoost 算法的目标函数定义为

$$Obj = \sum_{i=1}^N L(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k). \quad (5)$$

式中: y_i 为实际值; \hat{y}_i 为预测值; $L(y_i, \hat{y}_i)$ 为损失函数, 表示预测值和真实值之间的差异; f_k 表示每棵回归树的基学习器模型; $\Omega(f_k)$ 为正则化项, 用于降低目标函数的复杂度; N 为样本总数; K 为集成模型迭代次数. 正则化项:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \omega^2. \quad (6)$$

式中: γ 为用于控制叶节点的数量; T 为叶子节点的数量; λ 为 L2 正则化系数; ω 为叶子节点的分数. 定义预测函数为

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i). \quad (7)$$

当生成第 t 棵回归树时, 预测结果如式 (8) 所示, 此时的目标函数可变换为式 (9).

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + f_t(x_i), \quad (8)$$

$$Obj^{(t)} = \sum_{i=1}^N L(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t). \quad (9)$$

对目标函数优化, 方法是对损失函数进行二阶泰勒展开, 计算后的目标函数为

$$Obj^{(0)} = \sum_{j=1}^T \left[\omega_j G_j + \frac{1}{2} \omega_j^2 (\lambda + H_j) \right] + \gamma T. \quad (10)$$

式中： G_j 为第 j 个节点里所有样本一阶梯度和； H_j 为第 j 个节点里所有样本二阶梯度和.此时目标函数的优化转化为寻找二次函数最小值的过程.整理公式后,得到目标函数最小时对应的叶子节点分数:

$$\omega_j^* = -\frac{G_j}{H_j + \lambda}. \quad (11)$$

此时优化函数可表示为

$$Obj^{(0)} = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T. \quad (12)$$

树结构节点是否继续分裂取决于信息增益,信息增益即节点分裂前与分裂后目标函数的差值.若分裂当前节点,信息增益 >0 ,则进行分裂;反之不分裂,通过确定最佳特征和分裂点来获得树结构.




图4 Person相关性分析
Fig. 4 Person correlation analysis




图5 各主成分贡献率
Fig. 5 The contribution rates of each principal component

3.2 Optuna 优化算法

超参数优化是机器学习中的关键过程,会显

著影响机器学习模型的预测性能. Optuna作为一个自动超参数优化框架,可通过迭代和评估不同参数值的目标函数来获得最优解^[22].

Optuna 优化步骤如下:

1) 定义目标函数,设置超参数搜索范围,以及最大迭代次数.本文优化目标为返回最小RMSE,最大迭代次数设置为100.

2) 在定义参数值范围的函数内选择一组个体,根据修剪条件使用修剪器自动终止无望个体,以及确定未计算个体总数的目标函数的值.

3) 对循环重复上述步骤,直至达到最大迭代次数.

4) 将RMSE最小时的超参数组合作为最优超参数并输出.

3.3 评价指标

均方根误差(RMSE),决定性系数(R^2),平均绝对误差(MAE)反映了预测值和实际值的误差情况,本文采用RMSE作为超参数选择评价指标,采用 R^2 ,MAE作为模型精度评价指标.其中, R^2 越接近1,RMSE,MAE越小,模型预测表现越好,计算公式为

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}, \quad (13)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2}, \quad (14)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|. \quad (15)$$

式中 \bar{y}_i 表示实际值的平均值.

4 结果分析

4.1 Optuna-XGBoost 预测表现

得到优良数据集后,对其随机划分,约80%数据(494组)作为训练集,用于构建模型;约20%数据(124组)作为测试集,用于评价模型.采用Optuna算法优化XGBoost模型中7个重要的超参数,设置迭代100次,得到的最优超参数如表5所示.图6为预测泡沫原液时,超参数 learning rate, alpha, lambda 的优化过程.

表5 XGBoost超参数搜索空间及Optuna优化结果

Table 5 Search space hyperparameters of XGBoost and optimal Optuna results

超参数	含义	取值范围	泡沫原液用量	泡沫剂体积比	膨润土泥浆用量
max depth	树的最大深度	[5,20]	13	15	15
min child weight	最小叶子权重	(1,15)	5	9	5
learning rate	学习率	(0.01,0.2)	0.0763	0.1668	0.1465
gamma	复杂度的惩罚项	[0.1,1.0]	0.8	0.1	0.2
alpha	L1正则项的参数	(0.01,10.0)	1.1127	0.0322	0.0729
lambda	L2正则项的参数	(0.01,10.0)	0.0465	0.0018	4.4762
subsample	随机抽取样本比例	[0.1,1.0]	0.8	1	0.7




图6 超参数优化

Fig. 6 Hyperparameter optimization

(a)—learning rate; (b)—alpha; (c)—lambda.

确定最佳超参数后,采用XGBoost模型来预测泡沫原液用量、泡沫浓度、膨润土泥浆用量.图7对比了改良剂实际用量和优化模型在测试集上的表现,结果显示,预测值与实际值吻合程度较好,残差大多在零值附近呈正态分布,表明该模型能较好地反映土压平衡盾构机在掘进过程中改良剂用量的变化情况.泡沫原液最大预测残差为20 L,泡沫剂体积比最大预测残差为0.3%,膨润土泥浆最大预测误差为20 L,最大残差普遍低于改良剂正常值且出现的频率较低.总体上,

改良剂预测残差在可接受范围内.

4.2 不同超参数优化算法比较

为验证Optuna算法在超参数优化方面的优越性,将其与常用的贝叶斯优化(Bayesian optimization, BO)算法、网格搜索(grid search, GS)算法、粒子群优化(particle swarm optimization, PSO)算法进行比较.

表6给出了不同超参数优化算法下模型测试集的 R^2 ,MAE,Optuna超参数优化算法预测泡沫原液用量、泡沫剂体积比、膨润土泥浆用量得出

的 R^2 均值为 0.941 4, MAE 均值为 2.706 5; BO 算法对应 R^2 均值为 0.911 9, MAE 均值为 3.266 4; GS 算法对应 R^2 均值为 0.905 5, MAE 均值为 3.589 7; PSO 算法对应 R^2 均值为 0.926 4, MAE 均值为 5.172 8. 结果表明, Optuna 算法在超参数优化过程中表现最佳.

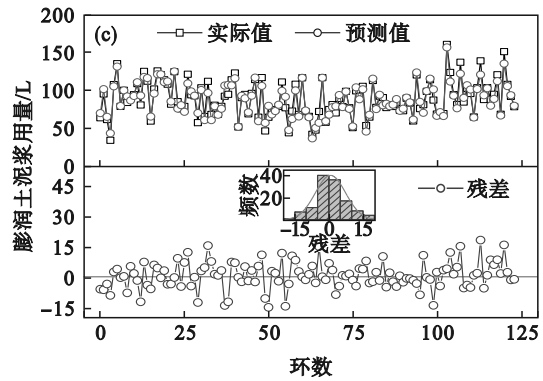
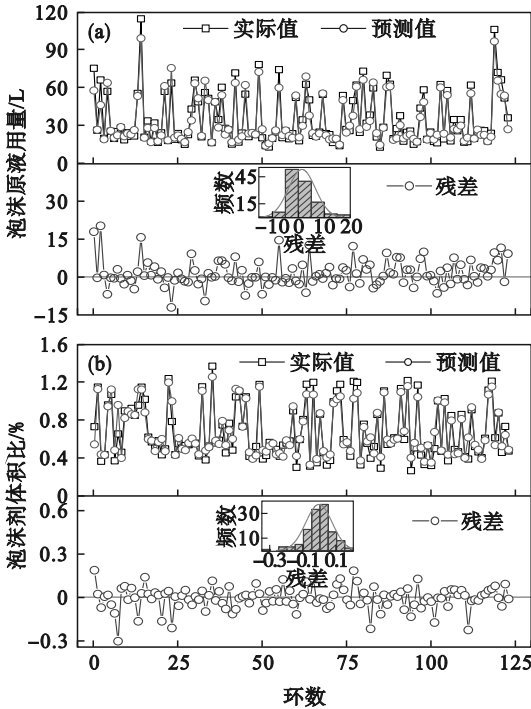


图 7 改良剂实际值和预测值

Fig. 7 Measured and predicted soil conditioners

(a)—泡沫原液用量; (b)—泡沫剂体积比;

(c)—膨润土泥浆用量.

4.3 不同模型预测性能比较

为验证 Optuna-XGBoost 模型渣土改良预测效果,对比了极度梯度提升树(XGBoost),支持向量回归(support vector regression, SVR),随机森林(RF), Optuna-XGBoost, Optuna-SVR, Optuna-RF 这 6 种预测算法在测试集上的表现,如表 7 所示. 比较 6 种算法发现, Optuna-XGBoost 算法表现最好,证明本算法对于改良剂预测有效. Optuna 算法超参数优化后模型精度普遍提升,再次验证了该算法的有效性,可为实际施工中改良剂用量决策提供参考.

表 6 超参数优化算法对比

Table 6 Comparison of hyperparameter optimization algorithms

优化算法	泡沫原液用量		泡沫剂体积比		膨润土泥浆用量	
	R^2	MAE	R^2	MAE	R^2	MAE
Optuna	0.951 3	2.338 1	0.948 1	0.027 7	0.924 7	5.753 6
BO	0.912 3	2.862 9	0.921 3	0.057 9	0.902 1	6.878 5
GS	0.922 7	3.130 0	0.917 4	0.024 5	0.876 5	7.614 5
PSO	0.933 6	2.870 0	0.925 5	6.324 0	0.920 0	6.324 4

表 7 6 种模型拟合精度分析

Table 7 The analysis results of the fitting accuracy for 6 models

模型	泡沫原液用量		泡沫剂体积比		膨润土泥浆用量	
	R^2	MAE	R^2	MAE	R^2	MAE
XGBoost	0.918 1	4.669 1	0.857 7	0.079 4	0.895 4	8.213 6
SVR	0.915 6	4.603 6	0.851 9	0.081 1	0.885 9	7.276 9
RF	0.901 1	2.796 7	0.837 1	0.080 7	0.860 3	7.938 9
Optuna-XGBoost	0.951 3	2.338 1	0.948 1	0.027 7	0.924 7	5.753 6
Optuna-SVR	0.922 7	2.882 9	0.889 5	0.066 8	0.900 8	6.438 5
Optuna-RF	0.943 3	2.057 9	0.901 2	0.057 9	0.919 9	6.267 5

5 结 论

1) 本文提出在渣土改良智能化预测中应选

择的输入参数;通过 PCA 算法实现降维,消除了输入特征中的冗余信息.

2) 对比了 Optuna, BO, GS, PSO 优化算法对模型预测性能的影响,使用 Optuna 优化的

XGBoost 模型表现出更好的预测性能。

3) Optuna-XGBoost 改良剂预测模型, 预测值与实际值吻合程度良好, 可为实际施工提供决策参考。

参考文献:

- [1] 魏康林. 土压平衡式盾构施工中“理想状态土体”的探讨[J]. 城市轨道交通研究, 2007(1): 67-70.
(Wei Kang-lin. On the “Ideal Soil” in the earth pressure balanced shield tunneling[J]. *Urban Mass Transit*, 2007(1): 67-70.)
- [2] Messerklinger S, Zumsteg R, Puzrin A M. A new pressurized vane shear apparatus [J]. *Geotechnical Testing Journal*, 2011, 34(2): 112-121.
- [3] Vinai R, Oggeri C, Peila D. Soil conditioning of sand for EPB applications: a laboratory research [J]. *Tunnelling and Underground Space Technology*, 2008, 23(3): 308-317.
- [4] Thewes M, Budach C. Soil conditioning with foam during EPB tunnelling [J]. *Geomechanik Und Tunnelbau*, 2010, 3(3): 256-267.
- [5] 魏康林. 土压平衡盾构施工中泡沫和膨润土改良土体的微观机理分析[J]. 现代隧道技术, 2007(1): 73-77.
(Wei Kang-lin. Micro-mechanism analysis for the soil improvement by foam and bentonite in EPB shield tunneling [J]. *Modern Tunnelling Technology*, 2007(1): 73-77.)
- [6] 王树英, 刘鹏飞, 胡钦鑫, 等. 盾构隧道渣土改良理论与技术研究综述[J]. 中国公路学报, 2020, 33(5): 8-34.
(Wang Shu-ying, Liu Peng-fei, Hu Qin-xin, et al. State-of-the-art on theories and technologies of soil conditioning for shield tunneling [J]. *China Journal of Highway and Transport*, 2020, 33(5): 8-34.)
- [7] Li S C, Wan Z E, Zhao S S, et al. Soil conditioning tests on sandy soil for earth pressure balance shield tunneling and field applications [J]. *Tunnelling and Underground Space Technology*, 2022, 120: 104271.
- [8] Cheng C H, Liao S M, Huo X B, et al. Experimental study on the soil conditioning materials for EPB shield tunneling in silty sand [J]. *Advances in Civil Engineering*, 2020, 2020: 8856569.
- [9] Zhen Z, Ge X S, Zhang J. Soil conditioning tests on sandy and cobbly soil for shield tunneling [J]. *KSCCE Journal of Civil Engineering*, 2021, 25(4): 1229-1238.
- [10] Wang S Y, Liu P F, Gong Z Y, et al. Auxiliary air pressure balance mode for EPB shield tunneling in water-rich gravelly sand strata: feasibility and soil conditioning [J]. *Case Studies in Construction Materials*, 2022, 16: e00799.
- [11] 展超. 基于 BP 神经网络的富水砂层渣土改良试验效果预测[J]. 隧道建设(中英文), 2020, 40(7): 988-996.
(Zhan Chao. Experimental effect prediction of ground conditioning of water-rich sandy stratum based on BP neural network [J]. *Tunnel Construction*, 2020, 40(7): 988-996.)
- [12] Lin L, Guo H, Lyu Y C, et al. A machine learning method for soil conditioning automated decision-making of EPBM: hybrid GBDT and random forest algorithm [J]. *Maintenance and Reliability*, 2022, 24(2): 237-247.
- [13] 李琛, 骆汉宾, 刘文黎, 等. 基于改进 Faster R-CNN 法的盾构渣土流塑性自动识别研究[J]. 隧道建设(中英文), 2022, 42(2): 268-274.
(Li Chen, Luo Han-bin, Liu Wen-li, et al. Automatic recognition of flow plasticity of conditioned soil based on improved faster R-CNN [J]. *Tunnel Construction*, 2022, 42(2): 268-274.)
- [14] Lin S S, Shen S L, Zhang N, et al. Modelling the performance of EPB shield tunnelling using machine and deep learning algorithms [J]. *Geoscience Frontiers*, 2021, 12(5): 101177.
- [15] Mokhtari S, Mooney M A. Predicting EPBM advance rate performance using support vector regression modeling [J]. *Tunnelling and Underground Space Technology*, 2020, 104: 103520.
- [16] Kong X X, Ling X Z, Tang L, et al. Random forest-based predictors for driving forces of earth pressure balance (EPB) shield tunnel boring machine (TBM) [J]. *Tunnelling and Underground Space Technology*, 2022, 122: 104373.
- [17] Qu T M, Wang S Y, Hu Q X. Coupled discrete element-finite difference method for analysing effects of cohesionless soil conditioning on tunneling behaviour of EPB shield [J]. *KSCCE Journal of Civil Engineering*, 2019, 23(10): 4538-4552.
- [18] 刘明阳, 余宏淦, 陶建峰, 等. 基于盾构机运行参数的局部切空间排列与 XGBoost 融合的地质类型识别[J]. 中南大学学报(自然科学版), 2022, 53(6): 2080-2091.
(Liu Ming-yang, Yu Hong-gan, Tao Jian-feng, et al. Geological-type identification with LTSA and XGBoost algorithm based on EPB shield operating data [J]. *Journal of Central South University (Science and Technology)*, 2022, 53(6): 2080-2091.)
- [19] 杨果林, 张沛然, 陈亚军, 等. 长沙典型地层土压平衡盾构掘进参数及表现预测[J]. 中南大学学报(自然科学版), 2020, 51(8): 2069-2080.
(Yang Guo-lin, Zhang Pei-ran, Chen Ya-jun, et al. Excavation parameters and performance prediction of earth pressure balance shield in typical strata of Changsha [J]. *Journal of Central South University (Science and Technology)*, 2020, 51(8): 2069-2080.)
- [20] Xu Q W, Zhang L Y, Zhu H H, et al. Laboratory tests on conditioning the sandy cobble soil for EPB shield tunnelling and its field application [J]. *Tunnelling and Underground Space Technology*, 2020, 105: 103512.
- [21] Chen T Q, Guestrin C. XGBoost: a scalable tree boosting system [C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco, 2016: 785-794.
- [22] Srinivas P, Katarya R. hyOPTXg: OPTUNA hyper-parameter optimization framework for predicting cardiovascular disease using XGBoost [J]. *Biomedical Signal Processing and Control*, 2022, 73: 103456.