

DOI: 10.16544/j.cnki.cn43-1494/u.2022072524061979

文章编号: 1674-599X(2024)03-0117-11

引用格式: 黄戡, 张文杰, 李宇健. 基于 PSO-RF 混合算法的盾构参数预测研究[J]. 交通科学与工程, 2024, 40(3): 117-127.

Citation: HUANG Kan, ZHANG Wenjie, LI Yujian. Research on shield parameter prediction based on the PSO-RF hybrid algorithm[J]. J Transp Sci Eng, 2024, 40(3): 117-127.

基于 PSO-RF 混合算法的盾构参数预测研究

黄戡, 张文杰, 李宇健

(长沙理工大学 土木工程学院, 湖南 长沙 410114)

摘 要: 复合地层是盾构隧道施工过程中常见的地层类型, 但关于复合地层盾构掘进参数的研究相对较少。为研究不同盾构参数间的相关性, 依托长沙轨道交通 6 号线湖白区间隧道工程, 利用随机森林算法(random forest, RF)构建了盾构掘进参数预测模型, 结合数理统计和基于随机森林算法(RF)的 PSO-RF 混合算法模型对盾构掘进参数进行预测, 并对预测结果进行误差验证。研究结果表明: 将盾构隧道区间的地质物理参数与盾构掘进参数分别作为输入参数和输出参数, 导入 PSO-RF 混合算法模型中进行训练学习, 结果显示 5 种盾构参数预测值与实际值之间的平均绝对百分比误差大多在 20% 以内, 即预测结果达到了泛化能力与预测能力的验证要求。

关键词: 盾构隧道; 掘进参数; 随机森林; 粒子群算法

中图分类号: U45

文献标志码: A

Research on shield parameter prediction based on the PSO-RF hybrid algorithm

HUANG Kan, ZHANG Wenjie, LI Yujian

(School of Civil Engineering, Changsha University of Science & Technology, Changsha 410114, China)

Abstract: Composite strata is a common type of strata during the process of shield tunnelling. However, there is relatively little research on shield tunneling parameters in composite strata. In order to study the correlation between different shield parameters, in this paper, based on the Changsha Rail Transit Line 6 Hubai interval tunnel project, the shield tunnelling parameter prediction model was constructed using the random forest (RF) algorithm. The shield tunnelling parameters was predicted using the PSO-RF hybrid algorithm model combining the mathematical statistics and the RF. And the prediction results were verified for errors. The results of the study show that the stratigraphic parameters of the shield tunnel intervals are combined with the shield tunneling parameters. Two types of parameters are used as input and output parameters, which are imported into the PSO-RF hybrid algorithm model for training and learning, 5 predicted shield tunneling parameters are obtained. The mean absolute percentage error between the predicted and actual values of those parameters is generally less than 20%, which indicate that the prediction results meet the requirements of generalisation and prediction ability.

Key words: shield tunnel; tunneling parameter; random forest; particle swarm optimization

收稿日期: 2022-07-25

基金项目: 国家自然科学基金资助项目(52078060); 湖南省自然科学基金资助项目(2020JJ4606); 湖南省教育厅科学研究重点项目(18A127); 长沙理工大学“双一流”科学研究国际合作拓展项目(2018IC19); 长沙理工大学土木工程优势特色重点学科创新性项目(18ZDXK05)

通信作者: 黄戡(1979—), 男, 副教授, 主要从事城市轨道交通、隧道和岩土工程方面的研究工作。E-mail: hk_616@sina.com

投稿网址: <https://jtkxygc.csust.edu.cn/jtkxygc/home>

当前,盾构法广泛应用于修建隧道,但在复合地层中盾构机施工须特别注意盾构掘进参数的控制。若控制不当,可能引发地层扰动、盾构机姿态控制及纠偏不及时、管片受力不均匀等问题。针对这些问题,部分学者^[1-4]对盾构参数开展了深入研究,并提出多项有效措施,如优化设计线路、加强地质探测、处理不良地层、改进结构设计、选用适配刀具、优化盾构掘进参数,并强化监测和应急预案工作^[5]。

除了基于工程经验的解决方法,学术界还提出了将机器学习应用于盾构施工的研究思路^[6-7]。李超等^[8]建立了BP神经网络模型,并将其应用于预测复合地层条件下的盾构掘进参数。陈仁朋等^[9]对比了BP和RF智能算法的拟合能力,并据此构建了人工神经网络算法模型来预测地层沉降。ZHANG等^[10]提出了基于随机森林算法的PSO-RF混合算法来预测隧道施工沉降、估算盾构注浆压力,并验证了其可行性和适用性。仇文岗等^[11]提出了一种基于随机森林的预测模型,并结合粒子群优化算法(particle swarm optimization, PSO)、遗传算法(genetic algorithm, GA)、差分算法(differential evolution, DE)、贝叶斯优化(Bayesian optimization, BO)等超参数优化算法来提升预测模型的性能。李兴春等^[12]基于神经网络数据自适应能力和模糊系统知识表达性能的自适应神经模糊推理系统ANFIS,建立了地表最大沉降预测模型,证实了该模型预测地表沉降的效果较好。林荣安等^[13]建立了RS-SVR模型用于预测地表沉降,并发现经过优化后的模型性能显著提升。李洛宾等^[14]将两种传统的RNN模型(LSTM、GRU模型)的沉降预测能力与经典BP模型的进行对比,在结果精度和整体稳定性方面,RNN模型相较于经典BP神经网络模型展现出了显著优势。WANG等^[15]运用小波平滑相关向量机,构建了预测土压平衡盾构施工引起的地表沉降的模型。相较于支持向量机(support vector machine, SVM),该模型不仅具有更精准的预测结果,还具有良好的泛化性能。

尽管中国在复合地层条件下采用盾构法修筑地下铁道的工程众多,但对复合地层盾构掘进参数的研究相对较少。目前,盾构掘进参数的选取多依赖于现场经验,这不利于将其应用于沉降预测。因此,本文基于RF随机森林算法,建立了PSO-RF混

合算法盾构掘进参数预测模型,并对其可靠性进行验证。同时,对优化前后误差进行对比分析,以期提升预测精度和工程应用的可靠性。

1 复合地层盾构参数预测模型

1.1 随机森林(RF)神经网络基本理论

随机森林由众多决策树组成,每个决策树模型都是单独计算的。对于回归问题,利用bagging集成策略,在给定输入和输出样本时,每次通过有放回的随机抽样方式生成训练集,对训练集中的样本输入决策树进行分类学习,将 n 个决策树的回归结果进行算术平均,得到模型的最终输出结果。

随机森林的优点是可以随机处理数据样本,有效避免算法的计算过程陷入过拟合,并具有优秀的抵抗噪声的能力。该算法参数较少,建模过程相对简单。但也存在不足,比如当所选特征值跨度较大,区域划分较多时,可能对随机森林内的决策树产生干扰,从而影响随机森林模型的整体性能。

1.1.1 随机森林(RF)神经网络结构及算法

随机森林是通过运用bagging集成策略对决策树算法进行优化的算法模型,它成功地利用bagging集成策略,解决了单个决策树算法容易陷入过拟合的问题。

随机森林算法最终的输出为:

$$y = \frac{1}{n_{\text{tree}}} \sum_{i=1}^{n_{\text{tree}}} y_i(x) \quad (1)$$

式中: $y_i(x)$ 为输入向量对应的模型输出值; n_{tree} 为决策树的数量(n 个)。

其中,超参数 n_{tree} 和bootstrap集合中特征数量 m_{try} 是影响随机森林模型计算速度与预测准确性的两个关键参数。由于本文数据样本大小合适,可仅调整决策树的数量来控制预测的准确性,而无需调整 m_{try} ,可将其按默认值设为5。

1.1.2 决策树算法

本研究的盾构掘进参数均为采集的离散数据,因此采用分类树生成决策树的数量。在构建分类树的过程中,利用基尼指数来选择最优特征,并同时确定该特征的最优二值切分点。

在分类问题中,假设有 K 个类别,样本点属于第 k 类的概率为 p_k ,则可通过基尼指数定义概率分布,即:

$$f_{\text{Gini}}(p) = \sum_{k=1}^K p_k(1-p_k) = 1 - \sum_{k=1}^K p_k^2 \quad (2)$$

对于给定的样本集合 D ,其基尼指数可表示为:

$$f_{\text{Gini}}(D) = 1 - \sum_{k=1}^K \left(\frac{|C_k|}{|D|} \right)^2 \quad (3)$$

式中: C_k 为 D 中属于第 k 类的样本子集。

如果样本集合 D 根据特征 A 的某个值 a 把 D 分成 D_1 和 D_2 ,即:

$$\begin{cases} D_1 = \{(x, y) \in D \mid A(x) = a\} \\ D_2 = D - D_1 \end{cases} \quad (4)$$

那么,在特征 A 的条件下,集合 D 的基尼指数为:

$$f_{\text{Gini}}(D, A) = \frac{|D_1|}{|D|} f_{\text{Gini}}(D_1) + \frac{|D_2|}{|D|} f_{\text{Gini}}(D_2) \quad (5)$$

对于基尼指数, $f_{\text{Gini}}(D)$ 表示集合 D 的不确定性; $f_{\text{Gini}}(D, A)$ 表示经 $A=a$ 分割后,集合 D 的不确定性。它们的值越大,样本集合的不确定性就越大。

1.2 粒子群优化算法结构及具体算法

粒子群优化算法是由 EBERHART 和 KENNEDY 受大自然中鸟群觅食的启发后,于1995年提出的进化算法。粒子群优化算法具有设置方便、计算速度快、可有效寻找整体最优解的特点。粒子迭代过程如图1所示。

假设一个包含 N 个粒子的种群在 D 维空间中进行搜索,其中第 i 个粒子的位置可以表示为:

$$X_i = (x_{i1}, x_{i2}, \dots, x_{iD}), i = 1, 2, \dots, N \quad (6)$$

该粒子的速度记为:

$$V_i = (v_{i1}, v_{i2}, \dots, v_{iD}), i = 1, 2, \dots, N \quad (7)$$

该粒子搜索到的个体最优解记为:

$$P_{\text{best}} = (p_{i1}, p_{i2}, \dots, p_{iD}), i = 1, 2, \dots, N \quad (8)$$

整个粒子群搜索到的全局最优解记为:

$$G_{\text{best}} = (p_{g1}, p_{g2}, \dots, p_{gD}) \quad (9)$$

每次确定一个位置后,粒子判断该位置是否为最优解。之后,粒子会依据式(10)来更新自身的速度和位置:

$$v_{id}^{k+1} = \omega v_{id}^k + c_1 r_1 (p_{id}^k - x_{id}^k) + c_2 r_2 (p_{gd}^k - x_{id}^k) \quad (10)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (11)$$

式中: c_1, c_2 为加速常数,也可称为学习因子; r_1, r_2 为 $[0, 1]$ 范围内的均匀随机数; ω 为惯性值; k 为当前迭代代数; d 为对应的维度, $d = 1, 2, \dots, D$ 。

在惯性权重动态变化中,线性递减权值公式如下:

$$\omega(k) = \omega_{\text{start}} - (\omega_{\text{start}} - \omega_{\text{end}})(T_{\text{max}} - k)/T_{\text{max}} \quad (12)$$

式中: T_{max} 为最大进化代数; ω_{start} 为初始惯性值; ω_{end} 为最终代的惯性值。

经验取值通常为 $\omega_{\text{start}}=0.9, \omega_{\text{end}}=0.4$ 。




图1 粒子迭代过程

Fig. 1 Particle iteration process

1.3 PSO-RF混合算法

依照随机森林的结构,PSO-RF混合算法模型的预测步骤如下:

1) 导入数据。这些数据有:经过修正后的隧道上覆土的重度 γ_1 、黏聚力 c_1 、内摩擦角 φ_1 、变形模量 E_1 ;经过软硬土占比平均取值后的隧道开挖面土的重度 γ_2 、黏聚力 c_2 、内摩擦角 φ_2 、变形模量 E_2 ;隧道的埋深 H ;水位线 H_w ;5种盾构参数千斤顶总推力 F 、平均掘进速度 v 、刀盘扭矩 T 、土舱压力 P_1 和注浆压力 $P_{\text{注}}$ 。

2) 随机抽取总样本数的80%作为训练集,剩余的20%作为测试集。

3) 针对每种盾构参数,分别设置5套随机森林模型进行机器学习。在此过程中,需要设置超参数,包括决策树的数量(i 个)、bootstrap集合中特征数量(5个)。

4) 通过PSO优化算法调整超参数,并利用平均绝对误差来确定误差最小的决策树数量。

5) 运用学习过的5套随机森林模型对盾构参数进行预测。

6) 将预测结果与实际值进行对比,并采用平均绝对误差、均方根误差、平均绝对百分比误差进行误差分析,以评估模型的性能。

PSO-RF混合算法模型的预测流程如图2所示。

模型训练阶段 → 模型应用阶段

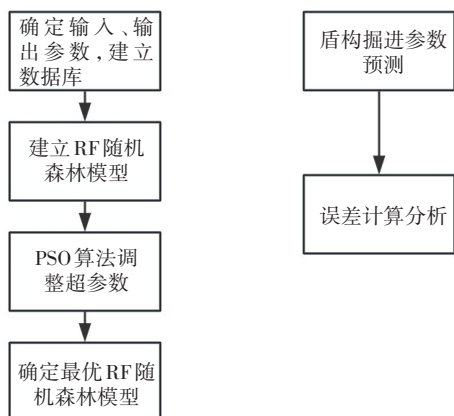


图2 PSO-RF算法盾构参数预测流程

Fig. 2 PSO-RF algorithm shield parameter prediction process

1.4 评价指标

为了评价随机森林模型的优化效果,本文采用平均绝对误差 E_{MAE} 、均方根误差 E_{RMSE} 、平均绝对百分比误差 E_{MAPE} 进行误差分析。

$$E_{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (13)$$

$$E_{MAPE} = \frac{100}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (14)$$

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (15)$$

式中: \hat{y}_i 为盾构参数实际值; y_i 为盾构参数预测值; n 为对比数据量。

2 盾构参数相关性

本文基于长沙轨道交通6号线湖南商学院站至白鸽咀站区间盾构隧道施工现场记录的掘进参数进行分析和研究。

2.1 工程概况

该盾构区间的地层主要可以分为4类:全风化板岩地层、强风化中风化板岩复合地层、全风化强风化板岩复合地层和强风化板岩地层。本文对这4类地层的掘进参数进行对比分析。该区间主要地层的物理力学指标见表1~2。

2.2 PSO-RF输入参数选取

在机器学习算法中,为了更准确地考虑地质环境因素对盾构掘进的影响,需要对其进行统一量化处理。地层厚度及其所在位置会显著地影响地层物理力学性质对隧道施工的作用。本文采用的修

表1 各主要土层的常规物理力学指标

Table 1 Conventional physical and mechanical indices of the main soil layers

地层名称	天然密度/ ($\text{g} \cdot \text{cm}^{-3}$)	天然孔隙比	变形模量/MPa	内摩擦角/($^{\circ}$)	黏聚力/kPa
素填土	1.80	0.80	14	10	15
粉质黏土	1.85	0.75	14	11	22

表2 各主要岩层的常规物理力学指标

Table 2 Conventional physical mechanical indices of the main rock formations

地层名称	天然密度/ ($\text{g} \cdot \text{cm}^{-3}$)	变形模量/MPa	岩石弹性模量/MPa
全风化板岩	1.90	28	
强风化板岩	2.20	120	
中风化板岩	2.40		3 200

正因子综合考虑了土层深度、厚度对地层的物理力学参数的影响,具体表达形式如下^[16]:

$$S = \frac{t_i}{h} \cdot \frac{h_i}{h} \quad (16)$$

式中: $\frac{t_i}{h}$ 为地层厚度因子,表示第 i 层土的厚度权值; $\frac{h_i}{h}$ 为地层深度因子,表示第 i 层土层的深度权值; S 为修正因子,反映该土层的重要性。修正因子大,说明该土层对隧道的影响较大;修正因子小,说明该土层对隧道影响较小。地层剖面图如图3所示,其中, i 为第 i 层土, $i = 1, 2, \dots, n$; h_i 为第 i 层土的深度; t_i 为第 i 层土的厚度; h 为隧道埋深。




图3 地层剖面图

Fig. 3 Stratigraphic section

土层的重度 γ 、黏聚力 c 、内摩擦角 φ 、变形模量 E 经过修正后作为随机森林算法模型中的地质参数输入值。用PSO-RF混合算法预测盾构掘进参数的主要参数见表3。

表3 PSO-RF混合算法输入输出参数

Table 3 Input and output parameters of PSO-RF hybrid algorithm

输入参数	输出参数
上覆土的容重	千斤顶总推力
上覆土的黏聚力	平均掘进速度
上覆土的内摩擦角	刀盘扭矩
上覆土的变形模量	土舱压力
开挖面土的容重	注浆压力
开挖面土的黏聚力	
开挖面土的内摩擦角	
开挖面土的变形模量	
水位线深度	
隧道埋深	

注:开挖面土的属性按照软土占开挖面面积的比例取软硬土修正平均值。

由于掘进参数单位不同,数值差距大,直接采用这些数据进行训练会影响网络收敛速度与预测

准确性。因此,需要对掘进参数进行归一化处理,以优化网络性能。处理公式如下:

1) 千斤顶总推力: $F = \frac{F_i}{30\,000}$ (17)

2) 平均掘进速度: $v = \frac{v_i}{70}$ (18)

3) 刀盘扭矩: $T = \frac{T_i}{4\,500}$ (19)

4) 土舱压力: $P_i = \frac{P_{t_i}}{400}$ (20)

5) 注浆压力: $P_{\text{注}} = \frac{P_{\text{注}_i}}{400}$ (21)

2.3 盾构掘进参数与地层相关性分析

本文对这5项盾构掘进参数进行了统计分析,并研究了掘进参数与地层参数之间的相关性。在掘进过程中千斤顶推力的变化规律如图4所示。从图4可以看出,在复合地层条件下进行盾构施工时,随着开挖面土体属性的不断变化,盾构机在通过软硬交界面时,千斤顶的总推力会出现大幅度波动;而在均质地层中,土体属性均匀变化,千斤顶总推力变化较为稳定。尤其在275~475环的施工区间内,土层性质的跨度较大导致总推力变化明显。




图4 千斤顶总推力变化

Fig. 4 The change of total jack thrust

平均掘进速度变化规律如图5所示。从图5可以看出,平均掘进速度在强风化中风化复合地层中的波动最显著,开挖面硬岩复合比变化较大,导致掘进速度产生变化。在475环之后,地层为单一的全风化板岩与强风化板岩,故平均掘进速度趋于稳定,未发生较大波动。

盾构的刀盘扭矩与地层属性密切相关。如图6所示,在强风化中风化复合地层中,刀盘扭矩的平

均值达到最大,而在全风化强风化复合地层中,刀盘扭矩的平均值则为最小,通过对比分析可以得出结论:土体强度越大,刀盘扭矩也越大。

土舱压力主要受地质条件和埋深的影响,其变化规律如图7所示。从图7可以看出,当盾构机进入复合地层时,土舱压力会发生较大波动。在全风化板岩层中,土舱压力在大多数情况下会保持高压状态,这是因为开挖面的土体已经风化成土,稳




图5 平均掘进速度变化

Fig. 5 The change of average digging speed




图6 刀盘扭矩变化

Fig. 6 The change of cutter torque

定性较差,强度较低,盾构机需较大的土舱压力来维持开挖面的稳定。

盾构掘进过程中的同步注浆压力变化如图8所示。从图8可以看出,各地层同步注浆压力的波动幅度均较大(200~300 kPa),并且波动频率较高。这是因为同步注浆压力参数容易受到平均掘进速度与盾构瞬时掘进速度的影响。一般来说,当盾构机的瞬时掘进速度降低时,同步注浆压力会增大。

2.4 Spearman相关性分析

斯皮尔曼相关系数(Spearman correlation coefficient)可以用单调函数来描述变量 X 、 Y 之间的相关性。当两个变量的集合中不包含重复元素时,可以用一个完全单调函数来表示两个变量之间的关系(即两个变量的变化趋势相同),其公式为:

$$\rho(X, Y) = 1 - \frac{6 \sum_{i=1}^N d_i^2}{N(N^2 - 1)} \quad (22)$$

式中: N 为变量 X 、 Y 中元素的个数; d_i 为变量 X 、 Y 中元素分别进行排序后,对应元素的排名差值,即: $d_i = x_i - y_i$; ρ 为相关系数, $-1 \leq \rho \leq 1$ 。

一般来讲,当 $\rho > 0$ 时, X 和 Y 正相关;当 $\rho < 0$ 时, X 和 Y 负相关;当 $\rho = 0$ 时, X 和 Y 不存在相关关系;当 $\rho = \pm 1$ 时, X 和 Y 完全相关。本文定义:当 $|\rho| \leq 0.3$ 时, X 和 Y 不相关;当 $0.3 < |\rho| \leq 0.5$ 时, X 和 Y 低度相关;当 $0.5 < |\rho| \leq 0.8$ 时, X 和 Y 显著相关;当 $|\rho| > 0.8$ 时, X 和 Y 高度相关。

根据式(22),计算各掘进参数之间的斯皮尔曼相关系数,结果见表4~7。




图7 土舱压力变化

Fig. 7 The change of soil compartment pressure




图8 同步注浆压力变化

Fig. 8 The change of synchronised grouting pressure

结合斯皮尔曼相关系数 ρ 值来判定全风化板岩层各盾构参数的相关性,得出以下结论:1) 土舱压力与平均掘进速度间存在低度正相关关系;2) 平均掘进速度与刀盘扭矩间存在低度正相关关系;3) 千斤顶总推力与刀盘扭矩间存在低度负相关关系。

结合斯皮尔曼相关系数 ρ 值来判定强风化中风化复合地层各盾构参数的相关性,得出以下结论:1) 土舱压力与平均掘进速度间存在高度正相关关系;2) 土舱压力与注浆压力间存在低度正相关关系;3) 平均掘进速度与注浆压力间存在低度正相关关系。

结合斯皮尔曼相关系数 ρ 值来判定全风化强风化复合地层各盾构参数的相关性,得出以下结论:1) 土舱压力与平均掘进速度间存在低度正相关关

系;2) 平均掘进速度与刀盘扭矩间存在低度正相关关系。

表4 全风化板岩层各盾构参数Spearman相关系数表

Table 4 The correlation coefficients of the Spearman for each shield parameter in fully weathered slate layer

掘进参数	土舱压力	平均掘进速度	千斤顶总推力	刀盘扭矩	注浆压力
土舱压力	1.000 0	0.441 2	0.012 6	0.156 8	0.081 8
平均掘进速度	0.441 2	1.000 0	-0.119 1	0.334 9	-0.036 8
千斤顶总推力	0.012 6	-0.119 1	1.000 0	-0.436 8	-0.039 7
刀盘扭矩	0.156 8	0.334 9	-0.436 8	1.000 0	-0.153 4
注浆压力	0.081 8	-0.036 8	-0.039 7	-0.153 4	1.000 0

表5 强风化中风化复合地层各盾构参数Spearman相关系数表

Table 5 The correlation coefficients of the Spearman for each shield parameter in strongly and moderately weathered composite strata

掘进参数	土舱压力	平均掘进速度	千斤顶总推力	刀盘扭矩	注浆压力
土舱压力	1.000 0	0.825 6	-0.052 1	-0.218 1	0.331 1
平均掘进速度	0.825 6	1.000 0	-0.138 8	-0.120 3	0.437 8
千斤顶总推力	-0.052 1	-0.138 8	1.000 0	-0.161 1	-0.057 4
刀盘扭矩	-0.218 1	-0.120 3	-0.161 1	1.000 0	0.155 9
注浆压力	0.331 1	0.437 8	-0.057 4	0.155 9	1.000 0

表6 全风化强风化复合地层各盾构参数Spearman相关系数表

Table 6 The correlation coefficients of the Spearman for each shield parameter in fully and strongly weathered composite strata

掘进参数	土舱压力	平均掘进速度	千斤顶总推力	刀盘扭矩	注浆压力
土舱压力	1.000 0	0.425 5	-0.261 6	0.167 8	0.103 2
平均掘进速度	0.425 5	1.000 0	-0.063 1	0.300 3	-0.092 9
千斤顶总推力	-0.261 6	-0.063 1	1.000 0	-0.023 8	-0.123 7
刀盘扭矩	0.167 8	0.300 3	-0.023 8	1.000 0	-0.235 2
注浆压力	0.103 2	-0.092 9	-0.123 7	-0.235 2	1.000 0

表7 强风化板岩层各盾构参数Spearman相关系数表

Table 7 The correlation coefficients of the Spearman for each shield parameter in strongly weathered slate layer

掘进参数	土舱压力	平均掘进速度	千斤顶总推力	刀盘扭矩	注浆压力
土舱压力	1.000 0	0.326 2	-0.308 9	0.028 0	0.359 2
平均掘进速度	0.326 2	1.000 0	-0.333 7	0.341 1	-0.237 1
千斤顶总推力	-0.308 9	-0.333 7	1.000 0	0.157 8	-0.298 8
刀盘扭矩	0.028 0	0.341 1	0.157 8	1.000 0	-0.290 9
注浆压力	0.359 2	-0.237 1	-0.298 8	-0.290 9	1.000 0

结合斯皮尔曼相关系数 ρ 值来判定强风化板岩各盾构参数的相关性,得出以下结论:1)土舱压力与平均掘进速度间存在低度正相关关系;2)土舱压力与千斤顶总推力间存在低度负相关关系;3)土舱压力与注浆压力间存在低度正相关关系;4)平均掘进速度与千斤顶总推力间存在低度负相关关系;


5)平均掘进速度与刀盘扭矩间存在低度正相关关系。

3 PSO-RF 混合算法模型预测结果验证


3.1 PSO-RF 预测结果

将本文所依托工程的588环盾构隧道区间地层物理参数与掘进参数的数据分别作为输入参数和输出参数,导入PSO-RF混合算法模型进行训练学习,最后得到了5种盾构参数的预测值与实际值之间的三种误差值,即平均绝对误差、均方根误差和平均绝对百分比误差。RF随机森林模型是采用随机抽取的方式生成训练集与测试集的,这种随机性导致得到的误差值可能会有所不同。因此,为了获得更可靠的误差分析参考值,本文取10次计算的误差值的平均值作为最终的误差分析参考值。误差分析如图9所示。


从图9可以看出,三种误差值基本保持在合理范围内。为更准确地比较不同盾构参数的预测误差,采用平均绝对百分比误差进行分析,以消除单位不同而导致的误差参照系差异。从图9可以得




(a) 千斤顶总推力




(b) 平均掘进速度



(c) 刀盘扭矩



(d) 土舱压力



(e) 注浆压力

图9 各盾构参数预测结果分布


Fig. 9 Distribution of predicted results for each shield parameter

到,千斤顶总推力、平均掘进速度、刀盘扭矩、土舱压力的 E_{MAPE} 均控制在20%以内。其中,千斤顶推力的误差值最小,仅为6.378%,而注浆压力的 E_{MAPE} 相对较高,达到了27.960%。考虑到在盾构掘进过程中,盾构参数受各种不可抗力因素的影响,预测值与实际值之间很难完全相同。因此,通过建立的PSO-RF混合算法模型能够将预测误差控制在允许范围内,其针对盾构掘进参数的预测结果满足工程


实际需求^[17]。

3.2 PSO-RF混合算法优化性能分析

基于随机森林算法与粒子群优化算法的混合算法在预测盾构参数时的误差值如图10所示。经过PSO优化后,刀盘扭矩和注浆压力分别减小至7.008 6 kN·m和13.394 3 kPa,土舱压力、掘进速度及千斤顶推力的平均绝对误差值都有不同程度的减小。注浆压力的均方根误差值经混合算法优化后,由2.245 7 kPa减小至1.781 4 kPa,相较于其他盾构参数,其优化效果最为明显。各掘进参数的百分比误差也均有不同程度的变化。其中,刀盘扭矩的均方根误差较优化前的提高了 7.142×10^{-6} ,千斤顶推力的百分比误差较优化前的提高了0.59%。这主要是由于随机森林算法中误差的主要影响因素是样本量,而本文因资源有限,输入的样本量稍显不足,以及随机森林本身的随机性使样本之间存在差异。但这两者带来的误差均处于极低水平,不影响模型预测结果整体的准确性。



(a) 盾构参数预测平均绝对误差



(b) 盾构参数预测均方根误差




图10 PSO-RF 算法优化前后误差对比

Fig. 10 Comparison of error before and after optimisation of the PSO-RF algorithm

4 结论

依托长沙轨道交通6号线湖白区间隧道工程,通过对不同掘进参数之间的相关性进行分析,建立了基于RF随机森林算法的PSO-RF混合算法模型。在该模型中,将地层物理力学参数与隧道几何设计参数设为输入值,将盾构掘进过程中的主要参数作为输出值。通过导入数据到PSO-RF混合算法模型中,使其充分训练后对掘进参数进行预测,计算预测值与实际值之间的误差。经过误差分析,得出结论:

1) 不同地层中,盾构掘进参数间的相关性有所不同,但土舱压力与平均掘进速度在所有地层中均表现出了相关性。在全风化板岩层、全风化强风化复合地层和强风化板岩层中,平均掘进速度与刀盘扭矩间具有低度正相关关系。此外,在盾构掘进参数中,土舱压力与平均掘进速度间呈高度正相关。

2) 将盾构隧道区间地层物理参数与掘进参数的数据分别作为输入和输出参数,导入PSO-RF混合算法模型进行训练。训练完成后,得到了5种盾构参数的预测值,并与实际值进行了比较,发现平均绝对误差、均方根误差、平均绝对百分比误差均在可控范围内。考虑到盾构参数可能存在波动,在实际工程计算中应采用具有良好泛化能力与预测能力的PSO-RF混合算法模型。

3) 该文构建的PSO-RF混合算法模型对盾构掘

进参数的预测效果较好。各参数的平均绝对百分比误差大多低于20%,预测数据的变化规律与实际数据的基本相近。土舱压力、平均掘进速度、千斤顶总推力、刀盘扭矩的平均绝对百分比误差分别为6.378%、10.571%、16.934%、12.281%,均满足盾构掘进的指标要求。虽然注浆压力的平均绝对百分比误差因输入样本量的限制达到了27.960%,但仍在可接受范围内。这些误差数据进一步验证了模型的泛化能力和预测准确性。

4) PSO-RF混合算法具有模型操作简易、泛化能力强、数据收集方便、预测准确性高等优点,能够快速有效地选取盾构掘进计算所需要的主要参数,为实际工程提供有力支持。

参考文献(References):

- [1] 魏新江, 周洋, 魏纲. 土压平衡盾构掘进参数关系及其对地层位移影响的试验研究[J]. 岩土力学, 2013, 34(1): 73-79. DOI: 10.16285/j.rsm.2013.01.025.
WEI Xinjiang, ZHOU Yang, WEI Gang. Research of EPB shield tunneling parameter relations and their influence on stratum displacement [J]. Rock and Soil Mechanics, 2013, 34(1): 73-79. DOI: 10.16285/j.rsm.2013.01.025.
- [2] 郑刚, 路平, 曹剑然. 基于盾构机掘进参数对地表沉降影响敏感度的风险分析[J]. 岩石力学与工程学报, 2015, 34(增刊1): 3604-3612.
ZHENG Gang, LU Ping, CAO Jianran. Risk analysis based on the parameters sensitivity analysis for ground settlement induced by shield tunneling [J]. Chinese Journal of Rock Mechanics and Engineering, 2015, 34(sup 1): 3604-3612.
- [3] 赵博剑, 周建军, 谭忠盛, 等. 复合地层盾构掘进参数及其与地层相关性分析[J]. 土木工程学报, 2017, 50(增刊1): 140-144. DOI: 10.15951/j.tmgcxb.2017.s1.025.
ZHAO Bojian, ZHOU Jianjun, TAN Zhongsheng, et al. Analysis of shield tunneling parameters in composite strata and their correlation with strata [J]. China Civil Engineering Journal, 2017, 50(sup 1): 140-144. DOI: 10.15951/j.tmgcxb.2017.s1.025.
- [4] 李宇健, 黄戡, 孙逸玮. 盾构参数对复合地层损失率和地表沉降的影响[J]. 交通科学与工程, 2022, 38(1): 70-78. DOI: 10.16544/j.cnki.cn43-1494/u.2022.01.010.
LI Yujian, HUANG Kan, SUN Yiwei. Effect of shield parameters on formation loss rate and surface subsidence in composite strata [J]. Journal of Transport Science and Engineering, 2022, 38(1): 70-78. DOI: 10.16544/j.cnki.cn43-1494/u.2022.01.010.
- [5] 吴波, 黄惟, 吴兵兵. 复合地层隧道稳定机理及量化评

- 价研究进展[J]. 科学技术与工程, 2020, 20(33): 13529-13537. DOI: 10.3969/j. issn. 1671-1815.2020.33.003.
- WU Bo, HUANG Wei, WU Bingbing. Review on stability mechanism and quantitative evaluation of tunnels in composite strata[J]. Science Technology and Engineering, 2020, 20(33): 13529-13537. DOI: 10.3969/j. issn. 1671-1815.2020.33.003.
- [6] 张亚洲, 温竹茵, 由广明, 等. 上软下硬复合地层盾构隧道设计施工难点及对策研究[J]. 隧道建设(中英文), 2019, 39(4): 669-676. DOI: 10.3973/j. issn. 2096-4498.2019.04.018.
- ZHANG Yazhou, WEN Zhuyin, YOU Guangming, et al. Difficulties and countermeasures in design and construction of shield tunnels in upper-soft and lower-hard stratum[J]. Tunnel Construction, 2019, 39(4): 669-676. DOI: 10.3973/j. issn. 2096-4498.2019.04.018.
- [7] 崔宏伟. 全断面岩石掘进机主参数及施工技术参数预测软件的开发[D]. 北京: 华北电力大学, 2006.
- CUI Hongwei. The development of forecasting software for host parameter of TBM and construction technical parameter [D]. Beijing: North China Electric Power University, 2006.
- [8] 李超, 李涛, 李正, 等. 基于BP神经网络的复合地层盾构掘进参数预测与分析[J]. 土木工程学报, 2017, 50(增刊1): 145-150. DOI: 10.15951/j. tmgcxb. 2017. s1. 026.
- LI Chao, LI Tao, LI Zheng, et al. Prediction and analysis of shield tunneling parameters in composite strata based on BP neural network [J]. China Civil Engineering Journal, 2017, 50(sup 1): 145-150. DOI: 10.15951/j. tmgcxb. 2017. s1. 026.
- [9] 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. DOI: 10.16339/j. cnki. hdxzbkb. 2021. 07. 013.
- 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. DOI: 10.16339/j. cnki. hdxzbkb. 2021. 07. 013.
- [10] ZHANG P, CHEN R P, WU H N. Real-time analysis and regulation of EPB shield steering using Random Forest [J]. Automation in Construction, 2019, 106: 102860. DOI: 10.1016/j. autcon. 2019. 102860.
- [11] 仇文岗, 唐理斌, 陈福勇, 等. 基于4种超参数优化算法及随机森林模型预测TBM掘进速度[J]. 应用基础与工程科学学报, 2021, 29(5): 1186-1200. DOI: 10.16058/j. issn. 1005-0930. 2021. 05. 009.
- ZHANG Wengang, TANG Libin, CHEN Fuyong, et al. Prediction for TBM penetration rate using four hyperparameter optimization methods and random forest model [J]. Journal of Basic Science and Engineering, 2021, 29(5): 1186-1200. DOI: 10.16058/j. issn. 1005-0930. 2021. 05. 009.
- [12] 李兴春, 李兴高. 基于神经模糊推理系统的盾构施工地表沉降预测[J]. 北京交通大学学报, 2018, 42(1): 18-24. DOI: 10.11860/j. issn. 1673-0291. 2018. 01. 003.
- LI Xingchun, LI Xinggao. Prediction of ground surface settlement induced by shield tunneling construction based on neural fuzzy inference system [J]. Journal of Beijing Jiaotong University, 2018, 42(1): 18-24. DOI: 10.11860/j. issn. 1673-0291. 2018. 01. 003.
- [13] 林荣安, 孙钰丰, 戴振华, 等. 基于RS-SVR的上软下硬地层盾构施工地表沉降预测[J]. 中国公路学报, 2018, 31(11): 130-137. DOI: 10.3969/j. issn. 1001-7372. 2018. 11. 014.
- LIN Rong'an, SUN Yufeng, DAI Zhenhua, et al. Predicting for ground surface settlement induced by shield tunneling in upper-soft and lower-hard ground based on RS-SVR [J]. China Journal of Highway and Transport, 2018, 31(11): 130-137. DOI: 10.3969/j. issn. 1001-7372. 2018. 11. 014.
- [14] 李洛宾, 龚晓南, 甘晓露, 等. 基于循环神经网络的盾构隧道引发地面最大沉降预测[J]. 土木工程学报, 2020, 53(增刊1): 13-19. DOI: 10.15951/j. tmgcxb. 2020. s1. 003.
- LI Luobin, GONG Xiaonan, GAN Xiaolu, et al. Prediction of maximum ground settlement caused by shield tunnel based on cyclic neural network [J]. China Civil Engineering Journal, 2020, 53(sup 1): 13-19. DOI: 10.15951/j. tmgcxb. 2020. s1. 003.
- [15] WANG F, GOU B C, QIN Y W. Modeling tunneling-induced ground surface settlement development using a wavelet smooth relevance vector machine [J]. Computers and Geotechnics, 2013, 54: 125-132. DOI: 10.1016/j. compgeo. 2013. 07. 004.
- [16] 王为乐. 长沙地铁复合地层盾构选型与掘进参数研究[D]. 长沙: 中南大学, 2012.
- WANG Weile. Study on the type selection of shield and tunneling parameters of shield method in the composite stratigraphy of the Changsha metro [D]. Changsha: Central South University, 2012.
- [17] 张品. 基于机器学习算法的盾构掘进地表沉降预测及控制[D]. 长沙: 湖南大学, 2019. DOI: 10.27135/d. cnki. ghudu. 2019. 000005.
- ZHANG Pin. Prediction and control of tunneling-induced settlement using machine learning algorithms [D]. Changsha: Hunan University, 2019. DOI: 10.27135/d. cnki. ghudu. 2019. 000005.

(责任编辑:罗容;英文编辑:陈璐)