

DOI: 10.19650/j.cnki.cjsi.J1905081

融入复杂地层动态识别的盾构施工地表沉降预测方法研究*

宫思艺¹, 孔宪光¹, 刘丹², 仇峰涛², 常建涛¹

(1. 西安电子科技大学机电工程学院 西安 710071; 2. 中铁一局集团有限公司智能科技分公司 西安 710054)

摘要:针对盾构掘进过程中无法全面动态感知地质信息引发的难以精确预测地面沉降问题,提出了一种融入动态地层识别的地面沉降预测方法,该方法基于XGBoost动态地层识别模型,利用盾构施工参数对地层变动情况进行反向推演,明晰了地层变动时施工参数的变化规律;通过基于BP-SVR的地面沉降预测融合模型最终得到距开挖面不同距离处的地面沉降量与地层情况、掘进参数的内在关联关系,从而实现了复杂地层自适应的地面沉降量准确预测。在某地铁施工区间590环数据验证下,所提的地面沉降预测方法相比传统预测方法具有更高的预测精度。

关键词:盾构施工;地表沉降;地层识别;XGBoost;模型融合

中图分类号: TU42 TU94 TP3-05 TP312 **文献标识码:** A **国家标准学科分类代码:** 560.4530 520.20

An approach for predicting shield construction ground surface settlement of complex stratum using dynamical strata identification

Gong Siyi¹, Kong Xianguang¹, Liu Dan², Qiu Fengtao², Chang Jiantao¹

(1. School of Mechano-Electronic Engineering, Xidian University, Xi'an 710071, China;

2. Intelligent Technology Branch Co., Ltd of China Railway First Group Co., Ltd. Xi'an 710054, China)

Abstract: The geological information cannot be fully dynamically perceived in the shield tunneling process, which makes it difficult to accurately predict the ground settlement. To solve this problem, one kind of dynamical stratum identification model using the adaptive complex stratum changes is proposed in this paper. This method is based on the extreme gradient boosting (XGBoost) using shield construction parameters to implement the inverse deduction of stratum changes. In this way, the changing rule of construction parameters can be clarified when the stratum changes. The fusion model of error back propagation algorithm (BP) and support vector regression (SVR) for ground settlement prediction is formulated to obtain the intrinsic relationship of the ground settlement at different distances from the initial excavation face, stratum conditions and parameters of shield driving. The proposed method is validated by the 590-ring data of a metro construction. Compared with the traditional method, it can achieve higher prediction accuracy.

Keywords: shield tunneling; ground surface settlement; strata identification; XGBoost; model fusion

0 引言

盾构施工方法因施工机械结构原理复杂,施工环境恶劣多变,盾构法隧道施工会打破地层原有的应力平衡引起周围土体变形从而产生地面沉降等重大施工安全问题,对周边环境产生危害。目前,盾构施工采用地面沉降监控量测,绘制变形—时间(距离)关系曲线,掌握开挖

所引起地表动态变形,评估预判开挖面的稳定状态。但由于监测数据的采集频率相对较低且反馈不及时,因此研究一种及时预测地面沉降量的方法并提前采取控制措施显得尤为重要。

传统盾构施工地面沉降预测方法包括经验公式和数值模拟,其中经验公式主要包括Peck公式^[1]、随机介质理论^[2]、有限单元法^[3]等。采用经验公式计算时,因为土体损失及地面沉降槽宽度等关键参数与工程地质、水文

收稿日期:2019-04-30 Received Date:2019-04-30

* 基金项目:国家自然科学基金(51875432)、城市地下空间工程大数据智能分析与公共服务平台建设及示范应用项目(发改办高技(2017)461号)资助

地质、隧道施工方法、施工技术水平等因素相关,过于依赖地区经验,局限性比较大。数值模拟方法^[4]通过综合分析地质参数、掘进参数对地面沉降的影响,得到掘进过程中各参数变化对地面沉降的影响,但该类方法计算量较大,建模速度较慢且参数选取困难。近几年,利用人工神经网络模式识别和记忆能力提盾构施工数据集中的隐含关联关系成为研究主流。Ocak^[5]分别采用了人工神经网络,支持向量机以及高斯过程构建地面沉降预测模型对土压平衡盾构机掘进过程中引起的地面沉降进行预测。高攀科等^[6]采用改进BP神经网络对隧道软弱围岩进行位移反分析,分别从BP神经网络结构和算法两个方面进行改进。Xiong等^[7]运用时序分析和神经网络对软岩隧道变形分别进行了预测。支持向量机在解决非线性回归问题上也具有良好的性能,由此,支持向量机在地面沉降预测研究中得到了广泛使用。Yao等构建了支持向量机(support vector machines, SVM)模型和人工神经网络模型来预测地面沉降,并通过比较发现SVM模型比人工神经网络模型具有更高的预测精度^[8]。Wang等^[9]通过三维数值建模方式地面沉降主要影响参数进行筛选,在此基础上采用aSVM构建地面沉降实时预测模型。Mahdevari等^[10]采用SVM构建了地面沉降预测模型,并采用平方误差(R2)和均方误差(MSE)对预测模型进行评价。

综上所述,BP神经网络和支持向量机已被广泛应用到地面沉降预测中,构建了具有较高准确率的地面沉降预测模型,并在模型优化方面做了研究。但是在盾构实际掘进过程中,地质情况复杂多变,隧道开挖前调查获取的地质资料只能提供局部区域的有限地质情况尚未实现对开挖面地质情况的实时监测和分析。所以现有研究都忽略了复杂地层下动态地层变化与地面沉降量预测之间的强关联关系,对复杂地层难以实现全面精确有效预测。因此,本文提出了一种融入动态地层识别的地面沉降预测方法,在复杂地质情况下利用盾构施工参数对地层变动情况进行反向推演,得到了地层变动时施工参数的变化规律;构建了不同地层下距开挖面不同距离地面沉降量与地质情况、施工参数的耦合关系,从而实现了复杂地层自适应的多点地面沉降量的准确预测。

1 融入动态地层识别的地面沉降预测方法研究

地面沉降监测点一般分为纵向沉降监测点和横向沉降监测点^[11]。其中,纵向沉降监测点布置于隧道轴线正上方,一般每隔3~5 m设置一个监测点,用来监测开挖线路正上方的地面沉降量。根据地面沉降监测点布置方

案,确定沉降预测范围为距开挖面后方20 m和前方10 m,如图1所示。

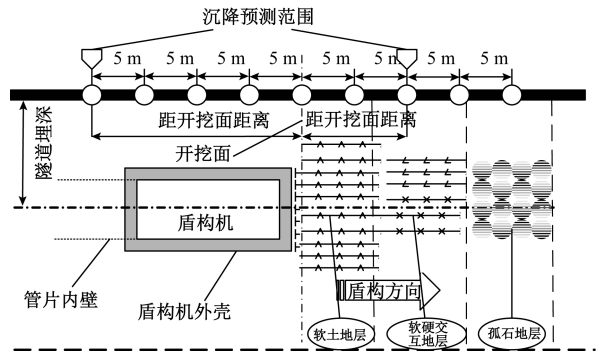


图1 地面沉降场景

Fig.1 The ground surface settlement scenario

基于上述业务场景,融入动态地层识别的地面沉降预测方法的实现步骤如下,如图2所示。

1) 动态地层识别。动态地层识别模型对地层类型进行识别,将识别结果分别输入到地面沉降影响因素分析模型和分地层地面沉降预测模型。

2) 关键影响因素提取。利用地面沉降影响分析因素模型对不同地层下的掘进参数进行筛选,结合地层识别结果得到相应地层下的地面沉降关键影响因素集,将筛选结果输入到分地层地面沉降预测模型。

3) 地面沉降预测。利用动态地层识别结果筛选相应地层下的地面沉降预测模型,以地面沉降关键影响因素集作为地面沉降预测模型的输入,对距开挖面不同距离处的地面沉降量进行预测。

融入动态地层识别的地面沉降预测方法涉及了工程地质、风险监测和施工操作因素,需要利用同一时刻的地层类型和掘进参数,是一个典型的地层类型、掘进参数和地面沉降量之间的三者耦合关系求解问题。由此,设计了求解三者之间耦合关系的数学表达式:

$$S_d = f_t(X^{(t)}) \quad (1)$$

式中: S_d 表示距开挖面不同距离处的沉降量, d 表示距开挖面不同距离, d 取-20,-15,-10,-5,0,5,10 m; t 表示地层类型, t 取1,2,3,其中1=软土地层,2=软硬交互地层,3=孤石地层); $X^{(t)}$ 表示不同地层类型下地面沉降关键影响因素集; f_t 表示地面沉降关键影响因素 $X^{(t)}$ 与距开挖面不同距离的地面沉降量 S_d 之间的映射关系。

1.1 基于XGBoost的动态地层识别模型研究

地层识别属于典型分类问题,所以为保证分类速度并提高分类正确率,本文采用XGBoost构建地层识别模型。XGBoost^[12]是一种设计良好的梯度增强决策树(GBDT),能够高效处理稀疏数据,灵活实现分布式并行计算,适用于大规模数据集,其高效的运算速度可以很好

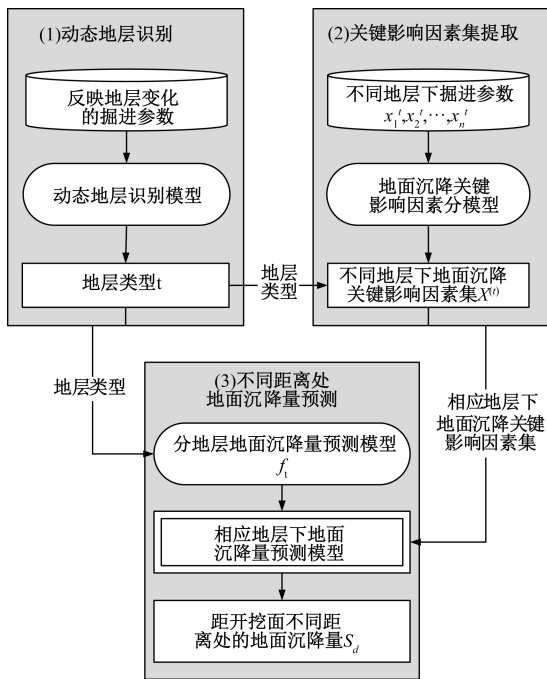


图2 融入动态地层识别的地面沉降量预测方法

Fig.2 Prediction method of ground surface settlement incorporated into dynamical strata identification

地应用于工程领域中,能够在保证一定速度的情况下提高分类的正确率。

盾构掘进参数蕴含着开挖隧道的地质情况与盾构相互作用信息,是一定地质条件的外在表征。传统经验知识^[13]认为盾构机总推力、刀盘扭矩、刀盘转速、推进速度和螺旋机转速掘进参数可反映地层变动。因此,本文将上述反映地层变化的主要掘进参数作为特征向量,地层类型作为标签值,利用 XGBoost 进行地层分类模型训练,构建动态地层识别模型实现对开挖面地层类型的动态识别。

1.2 基于随机森林的地面沉降关键影响因素分析

影响地面沉降量的因素众多,筛选出关键影响因素并对其进行更深层次的挖掘是进行地面沉降准确预测的重要前提。随机森林算法具有分析复杂相互作用分类特征的能力,对于噪声数据和存在缺失值的数据具有很好的鲁棒性,并且具有较快的学习速度,其变量重要性度量可以作为高维数据的特征选择工具,近年来已经被广泛应用于各种分类、预测^[14]、特征选择^[15]以及异常点检测问题中,本文利用随机森林筛选得到地面沉降关键影响因素。通过文献查阅总结地面沉降影响因素,将经验知识和重要度分数作为重要度排序的评判标准最终得到地面沉降关键影响因素。

1.3 基于BP-SVR分地层地面沉降预测模型研究

由于BP神经网络与SVR的建模思想截然不同,侧

重点各不一样,利用数据信息的角度也不同,决定了单一模型预测准确率也会有所不同。因此,本文将得到的BP神经网络模型与SVR模型进行融合。该模型融合中的权值确定采用网格搜索法进行,利用网格搜索法遍历所有权值组合,通过遍历步长控制权值寻优精度和算法运行复杂度。该融合模型涉及的单模型个数较少,因此采用网格搜索法并不会对算法效率产生太大影响。

该模型融合方法具体步骤如下。

1) 单一模型构建

(1)在BP神经网络的构建中综合考虑全局收敛和计算速度问题,BP神经网络模型构建步骤具体如下:

- 准备训练数据(输入和输出);
- 对连接权值和阈值赋初值;
- 计算实际输出与目标值之间均方误差;如果误差满足要求则结束模型训练;否则,进入下一步;
- 从输出层到隐层,依次计算误差梯度,并由此计算权值、阈值调整量,最后根据参数调整量进行网络参数调整;
- 重复以上步骤,直至误差符合要求停止模型训练。

(2)SVR模型构建步骤具体如下:

- 准备训练数据(输入和输出);
- 对核函数参数 γ 和惩罚因子 C 赋初值;采用交叉验证法,利用测试集误差作为评价指标,对更新的核函数参数 γ 和惩罚因子 C 进行选择;
- 计算实际输出与目标值之间均方误差;如果误差满足要求则结束模型训练;否则,更新核函数参数 γ 和惩罚因子 C ,采用交叉验证法,利用测试集误差作为评价指标,对更新的核函数参数 γ 和惩罚因子 C 进行选择;
- 重复以上步骤,直至误差符合要求停止模型训练。

其中,输入向量为不同地层下地面沉降关键影响因素集,输出向量为距开挖面10、5、0、-5、-10、-15和-20m(“-”表示开挖面后方)处的地面沉降量。

由此,分别得到BP神经网络地面沉降预测模型 M_1 和支持向量机地面沉降预测模型 M_2 。

2) 模型融合

(1)利用测试数据集代入到以上模型中,得到测试输出 A 和测试输出 B ;

(2)利用网格搜索法遍历所有权值组合,得到测试输出 A 的权值 α_1 和测试输出 B 的权值 $1-\alpha_1$;

(3)计算融合模型的测试输出 $O=\alpha_1A+\alpha_2B$,计算该测试输出与真实观测值之间的误差,并记录;

(4)判断是否遍历完毕,如果为否,则返回步骤(3)步;如果是,则所有可能权值组合遍历完毕,输出使融合模型误差最小的权值组合: $\alpha_{1_best}, \alpha_{2_best}$;

(5)根据 $\alpha_{1_best}, \alpha_{2_best}$,得到融合后的模型 $O=\alpha_{1_best}M_1+\alpha_{2_best}M_2$ 。

2 实例验证

实例分析所用数据集来自某市盾构施工项目,包括盾构掘进参数数据、地层类型数据以及地面沉降监测数据。根据区域地质资料,该地区为复杂地层类型,盾构区间穿越孤石地层、软土地层以及软硬交互地层等。实例共有 590 环数据样本,其中掘进相关数据

12 列,地质相关数据 6 列,地面沉降量相关数据 7 列,共有 25 个属性,如表 1 所示。数据样本按照 4:1 的比例进行划分,表 2 所示为训练集,共有 471 环数据(1~471 环);验证集共有 119 条数据(472~590 环),如表 3 所示,与训练样本不同的是,验证数据没有地层类型属性标签。其中训练集用来进行地层分类模型和分地层地面沉降量预测模型训练与测试,验证集用来对本文提出的方法进行效果验证。

表 1 原始数据
Table 1 Original Data

环号	土仓压力/ MPa	螺旋机 转速/ (r·min ⁻¹)	螺旋机 扭矩/ kN·M	千斤顶总 推力/ kN	刀盘转速/ (r·min ⁻¹)	刀盘扭矩/ (kN·M)	推进速度/ (mm·min ⁻¹)	盾构机 埋深/ mm	...	距开挖面后 20 m 处的地表沉降 量/mm	地层 类型
1	0.91	6.30	35.00	2 120.40	1.08	1 234.8	54.88	23 982.69	...	38.06	3
2	0.91	6.49	47.11	2 211.60	0.59	1 020.6	48.70	23 946.11	...	35.39	3
...
589	0.92	5.30	66.23	2 319.14	1.17	1 121.4	61.84	23 920.46	...	35.63	NA
590	0.9	6.91	68.76	2 196.78	0.63	961.8	51.79	23 916.13	...	35.97	NA

表 2 训练数据
Table 2 Training Data


环号	土仓压力/ MPa	螺旋机 转速/ (r·min ⁻¹)	千斤顶 总推力/ kN	刀盘转速/ (r·min ⁻¹)	刀盘扭矩/ (kN·M)	推进速度/ (mm·min ⁻¹)	注浆压力/ MPa	注浆量/ m ³	...	距开挖面后 20 m 处的地面 沉降量	地层 类型
1	0.92	5.58	2 563.10	1.22	1 104.6	61.07	0.20	0.68	...	37.12	3
2	0.91	9.66	2 359.04	0.99	1 184.4	50.25	0.19	0.66	...	37.18	2
...
470	0.89	6.30	2 171.32	1.13	1 146.6	55.66	0.2	0.78	...	36.33	3
471	0.91	3.74	2 721.94	1.02	1 020.6	65.71	0.21	0.58	...	35.49	1

表 3 验证数据
Table 3 Validation Data


环号	土仓压力/ MPa	螺旋机转速/ (r·min ⁻¹)	千斤顶总 推力/kN	刀盘转速/ (r·min ⁻¹)	刀盘扭矩/ (kN·M)	推进速度/ (mm·min ⁻¹)	注浆压力/ MPa	注浆量/ m ³	距开挖面后 20 m 处的 地表沉降量/mm
472	0.91	6.30	2 120.40	1.08	1 234.8	54.88	0.2	0.64	38.06
473	0.91	6.49	2 211.60	0.59	1 020.6	48.70	0.18	0.78	35.39
...
589	0.92	5.3	2 319.14	1.17	1 121.4	61.84	0.2	0.79	35.63
590	0.90	6.91	2 196.78	0.63	961.8	51.79	0.17	0.69	35.97

1) 动态地层识别结果


基于表2数据构建基于XGBoost的动态地层识别模型,基于Python的XGBoost分类的参数设置为:迭代次数为200,类别数目为3、分类器类型为gbtree、目标函数为multi:softmax、学习速率eta=0.3、树的最大深度max_depth=6。基于表3数据进行地层识别,该模型识别出3种地层类型,如图3所示,分别为软土地层,软硬交互地层和孤石地层,将模型识别结果与实测地质资料进行对比,总体预测精度达到98.90%,其中孤石地层识别准确率为100%,软硬交互地层为99.2%,软土地层识别为97.5%。该结果表明,盾构机总推力、刀盘扭矩、刀盘转速、推进速度和螺旋输送机转速之间耦合可全面反映地层变动情况,因此,本文提出的方法可对地层进行高精度动态识别。



(a) 孤石地层预测结果
(a) Prediction result of the boulder strata



(b) 软硬交互地层预测结果
(b) Prediction result of the soft-hard alternant strata



(c) 软土地层预测结果
(c) Prediction result of the soft soil strata

图3 基于XGboost的动态地层识别模型预测结果

Fig.3 Prediction result of the dynamical strata identification model based on XGBoost

2) 影响因素分析结果

基于表3数据,以不同地层下的地面沉降量为目标变量,从掘进参数中筛选关键影响因素,得到不同地层下影响因素重要度排序,如表4所示。

表4 不同地层下地面沉降影响因素重要度排序

Table 4 Importance order of influencing-factors under different stratum

地层类型 排序	软土地层		软硬交互地层		孤石地层	
	影响 因素	得分	影响 因素	得分	影响 因素	得分
1	螺旋机 转速	0.299 916	千斤顶 推力	0.461 516	土舱压力	0.461 441
2	千斤顶 推力	0.219 613	螺旋机 转速	0.116 334	千斤顶 推力	0.116 359
3	刀盘转速	0.161 720	推进速度	0.091 083	螺旋机 转速	0.091 084
4	刀盘扭矩	0.110 988	刀盘扭矩	0.085 621	刀盘转速	0.085 954
5	推进速度	0.073 657	刀盘转速	0.069 026	刀盘扭矩	0.069 117
6	注浆压力	0.072 600	注浆压力	0.065 430	推进速度	0.054 291
7	注浆量	0.061 505	注浆量	0.054 301	注浆量	0.041 876
8	土舱压力	0.060 305	土舱压力	0.041 750	注浆压力	0.021 129
9	螺旋机 扭矩	0.021 505	千斤顶 速度	0.021 188	螺旋机 扭矩	0.020 138
10	千斤顶 速度	0.020 208	螺旋机 扭矩	0.020 281	千斤顶 行程	0.019 455
11	螺旋机 压力	0.019 505	螺旋机 压力	0.019 466	千斤顶 速度	0.019 156
12	千斤顶 行程	0.001 505	千斤顶 行程	0.019 436	螺旋机 压力	0.008 754

实例结果表明,3种不同地层下地面沉降影响因素重要度得分不同,结合经验知识,将重要度排序前八位掘进参数列为3种地层下地面沉降关键影响因素集。

3) 分地层地面沉降预测模型训练

基于表2数据,利用BP神经网络和SVR分别构建软土地层地面沉降预测模型。模型训练过程各训练参数设置如下:BP神经网络模型的网络结构为[8, 15, 1],即输入层节点个数为8,单隐层节点个数为15,输出层节点个数为1,学习率为0.01,隐层激活函数为tansig函数,输出层激活函数为sigmoid函数。SVR模型中的核函数选用高斯径向基(radial basis function, RBF)函数,核函数参数和惩罚因子分别为0.1和1。

基于训练集分别用BP神经网络和SVR对距开挖面不同距离的地面沉降量进行建模,得到如表5所示模型。

表 5 距开挖面不同距离的地面沉降预测模型

Table 5 Models of ground surface settlement prediction at different distances from the initial excavation face

距开挖面距离	BP 神经网络	SVR
-20 m 处地面沉降预测模型	模型 NN-1	模型 SVR-1
-15 m 处地面沉降预测模型	模型 NN-2	模型 SVR-2
-10 m 处地面沉降预测模型	模型 NN-3	模型 SVR-3
-5 m 处地面沉降预测模型	模型 NN-4	模型 SVR-4
0 m 处地面沉降预测模型	模型 NN-5	模型 SVR-5
5 m 处地面沉降预测模型	模型 NN-6	模型 SVR-6
10 m 处地面沉降预测模型	模型 NN-7	模型 SVR-7

利用测试集对全部模型进行测试,各模型测试相对误差均值如表 6 所示。

表 6 模型测试误差结果对比

Table 6 Comparison of model error results

模型	NN-1	NN-2	NN-3	NN-4	NN-5	NN-6	NN-7
相对误差均值/%	4.96	5.16	4.89	2.09	5.52	4.67	5.94
模型	SVR-1	SVR-2	SVR-3	SVR-4	SVR-5	SVR-6	SVR-7
相对误差均值/%	3.61	3.17	3.72	3.94	3.39	2.29	4.43

4) 地面沉降预测模型融合

采用网格搜索法来暴力寻找组合模型的最优权值组

合,将网格搜索法中的权值步长设置为 0.05,对 7 组模型的输出进行融合得到对应 7 组模型权值组合。各组模型权值组合及各融合模型的相对误差如表 7 所示。

表 7 各组模型权值组合

Table 7 Weight combinations of each group model

融合模型	模型 1	模型 权值	模型 2	模型 权值	相对误差/%
模型 EM-1	模型 NN-1	0.40	模型 SVR-1	0.60	1.53
模型 EM-2	模型 NN-2	0.20	模型 SVR-2	0.80	1.84
模型 EM-3	模型 NN-3	0.80	模型 SVR-3	0.2	1.89
模型 EM-4	模型 NN-4	0.75	模型 SVR-4	0.25	1.95
模型 EM-5	模型 NN-5	0.20	模型 SVR-5	0.80	2.12
模型 EM-6	模型 NN-6	0.65	模型 SVR-6	0.35	1.57
模型 EM-7	模型 NN-7	0.35	模型 SVR-7	0.65	1.71

表 6 和 7 表明,软土地层下,SVR 模型的相对误差总体上低于 BP 神经网络模型的相对误差,融合模型的相对误差总体上低于 SVR 模型的相对误差。

为进行模型效果对比,利用验证数据集对模型效果进行验证,其准确率和具体模型说明如表 8 所示。

表 8 对比分析模型

Table 8 Models of comparison analysis

模型名称	准确率/%	使用算法	模型说明
SVR-0	92.23	SVR	基于原始数据集(表 1)训练得到,即未进行地面沉降关键影响因素分析。
NN-1	95.04	BP 神经网络	基于 BP 神经网络构建的开挖面后方 20 m 处的软土地层地面沉降预测模型
SVR-1	95.39	SVR	基于 SVR 构建的开挖面后方 20 m 处的软土地层地面地面沉降预测模型
EM-1	97.86	BP+ SVR	NN-1 和 SVR-1 地面沉降预测模型融合
EM1-Type1	98.87	BP+ SVR+XGBoost	基于表 3 所示数据,融入动态地层识别,构建的软土地层地面沉降预测融合模型
EM1-Type2	99.02	BP+SVR +XGBoost	基于表 3 所示数据,融入动态地层识别,构建软硬交互地层地面沉降预测融合模型
EM1-Type3	98.64	BP+SVR +XGBoost	基于表 3 所示数据,融入动态地层识别,构建孤石地层地面沉降预测融合模型

2.1 地面沉降关键影响因素分析模型效果对比

基于表 3 数据进行了距开挖面后方 20 m 处的沉降量预测,如图 4 所示,将未进行地面沉降关键影响因素分析的预测模型(SVR-0)和基于 SVR 的预测模型 SVR-1 的预测效果进行对比,SVR-0 模型预测精度为 92.23%,SVR-1 模型的预测精度为 95.39%,因此,SVR-1 具有更好的预测效果。

2.2 模型融合效果对比

基于表 2 数据进行了软土地层下距开挖面后方 20 m 处的沉降量预测,将基于 BP 神经网络的预测模型 NN-1、

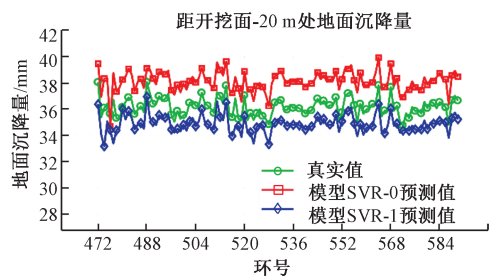


图 4 地面沉降关键影响因素分析模型结果对比 Fig.4 Comparison analysis of the prediction effect integrated into influencing-factors analysis

基于SVR的预测模型SVR-1以及融合模型EM-1的预测精度进行对比。如图5所示,经过模型融合之后的预测误差有了较大幅度的减小,模型融合取得了显著优化效果。




图5 模型融合的地面沉降预测结果对比

Fig.5 Comparison analysis of the prediction effect taking model fusion

2.3 融入动态地层识别模型效果对比

基于表3数据,利用基于XGBoost的动态地层识别模型进行地层分类,基于地层分类结果分别将不同地层类型下的关键影响因素集输入到模型EM1-Type1、EM1-Type2、EM1-Type3中,进行分地层地面沉降预测,3种地层地面沉降预测模型误差如表9所示。

表9 模型预测误差对比

Table 9 Comparison of model prediction errors

地层类型	软土地层	软硬交互地层	孤石地层	验证集总体误差
模型	EM1-Type1	EM1-Type2	EM1-Type3	(融入地层识别)
相对误差均值/%	1.13	0.98	1.36	1.16
模型	EM-1	EM-1	EM-1	验证集总体误差
相对误差均值/%	1.13	3.07	2.97	(不进行地层识别)

从上述结果可看出,融入动态地层识别的地面沉降预测结果整体上要优于传统的不进行地层识别的预测情况,地面沉降预测准确性有显著提高。

2.4 地面沉降预测方法效果对比

利用表3数据进行了距开挖面后方20m到前方10m范围内的沉降量预测,将文献[10]提出的基于SVM算法的地面沉降预测方法和本文提出的融入动态地层的地面沉降预测方法的预测结果进行对比。文献[10]提出的预测方法是基于SVM算法,将地质信息数据包含:含水量、土的比重、弹性模量、弹性模量的反映、内摩擦角和粘聚力作为输入,将沉降量作为输出构建预测模型。如图6所示,文献[10]的平均预测准确率为94.1%,而本文的预测准确率为98.84%,结果显示本文提出的预测方法具有更高的预测精度。




图6 地面沉降预测方法效果对比

Fig.6 Comparison analysis of the prediction effect using different methods

在实际施工过程中,隧道开挖前获得的地质资料只能提供局部有限的地质条件,无法实现对开挖面地质条件的实时监测和分析,无法实时获取含水量、土的比重、弹性模量、弹性模量的反映、内摩擦角和粘聚力等地质信息数据。因此,基于地质信息数据的地面沉降预测方法在现阶段施工过程中无法实现全面精确的预测。而本文提出的融入动态地层识别的预测方法可以实现地层的动态识别,能够实现在未采用这些信息的情况下保证较高的预测精度。

3 结论

本文设计了一种融入动态地层识别的地面沉降预测方法,该方法能够实现复杂地层自适应的多点地面沉降预测。为全面获取地层信息,设计了基于XGBoost的动态地层识别模型,总体地层识别预测准确率为98.90%;考虑到采用单一模型难以全面拟合复杂非线性系统的全局特性,本文通过有效方法将两种回归模型进行融合,设

计了基于 BP-SVR 模型融合的分地层地面沉降预测模型,其与地层识别模型的动态结合提高模型预测精度和模型泛化能力,通过实例验证,该方法的地面沉降预测准确率为 98.84%。

参考文献

- [1] FANG Y, HE C, NAZEM A, et al. Surface settlement prediction for EPB shield tunneling in sandy ground[J]. *KSCE Journal of Civil Engineering*, 2017, 21(7): 2908-2918.
- [2] SHI CH H, CAO CH Y, LEI M F. An analysis of the ground deformation caused by shield tunnel construction combining an elastic half-space model and stochastic medium theory[J]. *KSCE Journal of Civil Engineering*, 2017, 21(5): 1933-1944.
- [3] KAVVADAS M, LITSAS D, VAZAIOS L, et al. Development of a 3D finite element model for shield EPB tunnelling [J]. *Tunnelling and Underground Space Technology*, 2017, 65: 22-34.
- [4] LIANG R ZH, WU W B, YU F, et al. Simplified method for evaluating shield tunnel deformation due to adjacent excavation [J]. *Tunnelling and Underground Space Technology*, 2018, 71: 94-105.
- [5] OCAK L, SEKER S E. Calculation of surface settlements caused by EPBM tunneling using artificial neural network, SVM, and Gaussian processes [J]. *Environmental Earth Sciences*, 2013, 70(3): 1263-1276.
- [6] 高攀科, 谢永利. 隧道软弱围岩的改进 BP 神经网络位移反分析[J]. *郑州大学学报(工学版)*, 2013, 34(1): 23-26.
- GAO P K, XIE Y L. Displacement back analysis of tunnels in soft and weak rocks based on improved BP neural network method [J]. *Journal of Zhengzhou University(Engineering Science)*, 2013, 34(1): 23-26.
- [7] XIONG X W, MENG ZH C. Forecasting method of the deformation of soft rock roadways based on time series' analysis and BP neural networks and its application[J]. *Journal of Transport Science Engineering*, 2012, 28(2): 53-60, 100.
- [8] YAO B ZH, YANG CH Y, YU B, et al. Applying support vector machines to predict tunnel surrounding rock displacement[J]. *Applied Mechanics and Materials*, 2010, 29: 1717-1721.
- [9] WANG F, GOU B C, ZHANG Q L, et al. Evaluation of ground settlement in response to shield penetration using numerical and statistical methods: a metro tunnel construction case [J]. *Structure and Infrastructure Engineering*, 2016, 12(9): 1024-1037.
- [10] MAHDEVARI S, HAGHIGHAT H S, TORABI S R. A dynamically approach based on SVM algorithm for prediction of tunnel convergence during excavation[J]. *Tunnelling and Underground Space Technology*, 2013, 38: 59-68.
- [11] KOHESTANI V R, BAZARGANLARI M R, MARNANI J A. Prediction of maximum surface settlement caused by earth pressure balance shield tunneling using random forest[J]. *Journal of AI and Data Mining*, 2017, 5(1): 127-135.
- [12] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system [C]. *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*, 2016: 785-794.
- [13] ZHOU X W, XIA Y M, XUE J. Neural network strata identification based on tunneling parameters of shield machine [C]. *International Conference on Intelligent Robotics and Applications*, 2009: 392-401.
- [14] 熊鹏文, 林虹, 宋爱国, 等. 基于随机森林回归的手臂末端力的软测量方法[J]. *仪器仪表学报*, 2017, 38(10): 2400-2406.
- XIONG P W, LIN H, SONG AI G, et al. Soft measurement method of end-of-arm force based on random forest regression [J]. *Chinese Journal of Scientific Instrument*, 2017, 38(10): 2400-2406.
- [15] YAO D J, YANG J, ZHAN X J. Feature selection algorithm based on random forest[J]. *Journal of Jilin University*, 2014, 44(1): 137-141.

作者简介



孔宪光,1997年于西北工业大学获得学士学位,2000年于西北工业大学获得硕士学位,2005年于西北工业大学获得博士学位,现为西安电子科技大学智能制造与工业大数据研究主任、教授、博导,主要研究方向为面向智能制造(建造)的工业大数据与数字孪生技术。

E-mail: kongxianguang@xidian.edu.cn

Kong Xianguang received his B. Sc. degree, M. Sc. degree and Ph. D. degree all from Northwestern Polytechnical University in 1997, 2000 and 2005, respectively. He is currently a professor and the director of Research Center of Intelligent Manufacturing & Industrial Big Data at Xidian University. His main research interests include industrial big data and digital twin technologies for intelligent manufacturing (construction).



宫思艺,2017年于沈阳工业大学获得学士学位,2017年至今就读于西安电子科技大学,现为西安电子科智能制造与工业大数据研究中心成员,参与国家发改委大数据专项:城市地下空间工程大数据智能分析与公共服务平台项目,主要研究方向为基于工业大数据的智慧建造以及数字孪生。

E-mail: 2735504792@qq.com

Gong Siyi received her B. Sc. degree from Shenyang University of Technology in 2017. She is currently a student in the Research center of Intelligent Manufacturing & Industrial Big Data at Xidian University. She is serving as the project manager of shield construction big data analysis direction for Research Center of Intelligent Manufacturing & Industrial Big Data and participating in the Project of National Development and Reform Commission; Big Data Intelligent Analysis and Public Service Platform Construction for Urban Underground Space Engineering. Her main research interests include intelligent building, industrial big data and digital twin.



刘丹,2007年于西北工业大学获得学士学位,现为中铁一局智能科技分公司高级工程师,主要研究方向为智慧建造与工业大数据。

E-mail: 22814199@qq.com

Liu Dan received his B. Sc. degree from Northwestern Polytechnical University in 2007. He is currently a senior engineer at Intelligent Technology Branch Co., Ltd of China Railway First Group Co., Ltd. His main research interests include industrial big data and intelligent construction.