

doi:10.3969/j.issn.2097-0013.2025.02.011

基于 InSAR 与 Transformer-SVM 模型的珠海市 软土地面沉降监测分析及预测研究

江金进¹, 刘佳^{2*}, 赵风顺¹, 江山¹, 赖波¹

JIANG Jin-Jin¹, LIU Jia^{2*}, ZHAO Feng-Shun¹, JIANG Shan¹, LAI Bo¹

1. 广东省珠海工程勘察院, 广东珠海 519002; 2. 广东省地质局珠海地质调查中心, 广东珠海 519002

1. Zhuhai Engineering Survey Institute of Guangdong Province, Zhuhai 519002, Guangdong, China;

2. Zhuhai Geological Survey Center of Guangdong Geological Bureau, Zhuhai 519002, Guangdong, China

摘要: 受快速城市化、临港工业集群建设及近海养殖业扩张等多重因素驱动, 珠海市软土广泛分布地区地面沉降频发, 已成为制约该地区可持续发展的重大地质环境问题之一。通过集成多时序 InSAR 监测与机器学习算法, 能够系统揭示珠海软土地面沉降问题的时空特征及演化规律。基于 Sentinel-1 卫星影像数据, 联合使用 SBAS-InSAR、PS-InSAR 技术获取珠海市 2015—2018 年、2021—2023 年两个时期高精度沉降数据, 分析发现, 珠海市地面沉降较为发育且呈增大趋势, 地面累积沉降量波动与当地产业分布、工程活动密切相关。针对传统模型在非线性沉降预测中的局限性, 研究构建了融合 Transformer 模型与支持向量机(SVM)的预测模型。预测结果表明, 预测值与真实值曲线高度拟合, 误差控制在 ± 4 mm 范围内精度占比达 97% 以上, 模型展现出预测精确高、可靠性强的特点。InSAR 监测存在局限, 需融合多源数据及优化模型构架来进一步提升预测的精确度和可靠性。本文预测结果可为城市的规划与基础设施建设提供科学依据。

关键词: 软土; 沉降; Transformer 模型; 支持向量机(SVM); 预测; 珠海市

中图分类号: P642.26

文献标识码: A

文章编号: 2097-0013(2025)-02-0362-12

Jiang J J, Liu J, Zhao F S, Jiang S and Lai B. 2025. Research on Monitoring, Analysis and Prediction of Soft Soil Ground Settlement in Zhuhai City Based on InSAR and Transformer-SVM Models. *South China Geology*, 41(2): 362–373.

Abstract: Driven by multiple factors such as rapid urbanization, the construction of industrial clusters near the port, and the expansion of offshore aquaculture, the widespread distribution of soft soil in Zhuhai has led to frequent ground subsidence, which has become one of the major geological and environmental problems restricting the sustainable development of the region. By integrating multi-temporal InSAR monitoring and machine learning algorithms, the spatiotemporal characteristics and evolutionary patterns of soft soil subsidence in Zhuhai can be systematically revealed. Based on Sentinel-1 satellite imagery data, high-precision subsidence data from 2015 to 2018 and 2021 to 2023 were obtained using SBAS-InSAR and PS-InSAR techniques. Analysis shows that land subsidence in Zhuhai is well-developed and exhibits an increasing annual trend, with fluctuations in cumulative land subsidence closely related to local industrial

收稿日期: 2025-02-08; 修回日期: 2025-02-21

基金项目: 珠海市财政项目 [440401-2022-02369(MZCD-2201-008)]

第一作者: 江金进(1988—), 男, 高级工程师, 主要从事地质灾害防治研究, E-mail: 527077109@qq.com

通讯作者: 刘佳(1984—), 男, 高级工程师, 主要从事地质灾害防治研究, E-mail: 461962869@qq.com

distribution and engineering activities. Aiming at the limitations of traditional models in nonlinear subsidence prediction, a predictive model integrating the Transformer model and Support Vector Machine (SVM) was developed. Prediction results demonstrate highly consistent curves between predicted and actual values, with over 97% of the errors controlled within ± 4 mm, indicating the model's high prediction accuracy and reliability. However, InSAR monitoring has limitations, which make integrating multi-source data and optimizing model architecture be necessary to further improve prediction accuracy and reliability. The prediction of this study provide scientific basis for urban planning and infrastructure construction.

Key words: soft soil; subsidence; Transformer model; Support Vector Machine (SVM); prediction; Zhuhai City

在粤港澳大湾区高强度开发背景下, 珠海市近年来城市化、工业化和水产养殖业快速发展。大规模的工程建设、地下水过度开采及海平面上升等状况叠加, 导致珠海市软土地面沉降问题愈发严峻。软土地面沉降不仅威胁城市道路、桥梁与地下管线等基础设施安全, 还会加剧沿河(海)区域的洪涝与风暴潮灾害风险, 对珠海市可持续发展构成挑战。

精确掌握地面沉降状况, 能为城市规划、工程建设提供科学依据, 避免因地面沉降导致的基础设施失效和建筑物损坏, 保障人民生命财产安全。利用合成孔径雷达干涉测量(InSAR)技术对珠海市的软土地面沉降进行监测和深入分析, 有助于了解区域地质环境变化, 为城市的规划与基础设施建设提供重要的科学依据和数据支持。国外在地面沉降研究方面起步早, 监测技术成熟, 如美国、日本等利用高精度水准测量、InSAR 等技术进行长期监测, 并建立了完善的地面沉降模型(曹炳强等, 2021)。国内对地面沉降的研究也取得显著成果, 长三角、珠三角等经济发达地区, 已构建了“三维立体、多技术手段融合”的综合监测网络, 并积极开展涉及地质学、地理学、水文学等多学科联合研究(Ao Z R et al., 2024)。在预测领域, 针对传统模型在非线性沉降预测中的局限性, 通过不断改进模型, 并融入人工智能算法, 提高了对复杂地质条件下地面沉降的预测能力, 如孟雪等(2018)等提出了基于灰色 GM(1,1) 和神经网络组合模型对基坑周边地面沉降预测, 陈媛媛等(2024)提出基于 LSTM 模型对长江沿江区域的地表形变预测, 黄茂庭和徐金明(2024)使用 CNN-

LSTM 联合神经网络预测盾构隧道施工引起的地面沉降, 李华蓉等(2024)提出基于 InSAR 监测和 PSO-SVR 模型的高填方区沉降预测, 彭文祥和张德英(2024)提出基于 LSTM 与 Transformer 的地面沉降智能预测方法研究, 以上模型均取得较好的预测结果。但目前未见 Transformer 与 SVM 组合的模型对地面沉降预测研究的相关报道, 因此, 探索利用 Transformer-SVM 模型研究地面沉降的预测具有非常重要的现实意义。

本文通过对珠海市历史 InSAR 监测数据的深入分析, 总结出珠海市软土地面沉降的主要特征。在此基础上, 利用 Matlab 软件构建 Transformer-SVM 模型预测珠海市软土地面沉降, 结果显示模型预测精确高、可靠性强, 预测结果能为城市的规划与基础设施建设提供重要的科学依据和数据支持。

1 研究区概况

珠海市位于广东省南部, 珠江口西岸, 濒临南海, 地处北纬 $21^{\circ}48' \sim 22^{\circ}27'$, 东经 $113^{\circ}03' \sim 114^{\circ}19'$ 之间。珠海市软土分布范围广泛, 占陆地总面积的 55% 以上。珠海市软土厚度一般在 $0.3 \sim 50$ m, 最大厚度大于 60 m, 主要分布在白蕉镇、乾务镇、红旗镇、横琴粤澳深度合作区等地的冲洪积平原和滨海平原(图 1), 呈“近山薄、近河(海)厚”的特点(江金进等, 2020, 2024)。

2 InSAR 技术原理及数据获取

合成孔径雷达干涉测量(InSAR)是一种高效

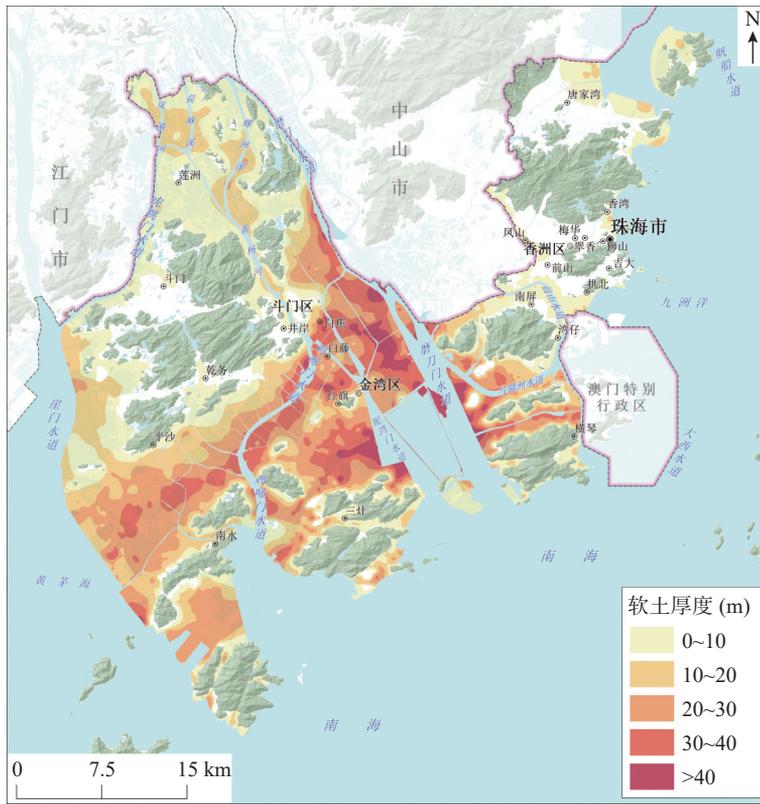


图 1 珠海市软土厚度分布图

Fig. 1 Distribution of soft soil thickness in Zhuhai City

的遥感技术,利用从卫星或飞机上搭载的雷达传感器获取地表高精度位置信息(丁晓利等, 2000)。通过对比不同时间获取的雷达影像, InSAR 可以精确地测量地表的微小位移。该技术具有覆盖范围广、分辨率高和工作效率高等显著优点,非常适合用于监测大面积地区的地面沉降情况,尤其是在城市区域(阳中磊, 2023; 严天笑, 2024)。

为详细了解珠海市软土地面沉降发育、演化状况,通过收集研究区内雷达卫星数据及其精密轨道、DEM 数据和相关遥感影像、地理信息数据等,联合使用 D-InSAR、PS-InSAR、SBAS-InSAR 等多种方法,以 SBAS-InSAR 方法中图像对选取策略选择时空基线较优的图像和以 D-InSAR 技术方法生成干涉图集,在选取稳定散射相干目标点的基础上,对相干目标点相位信息进行解算,从而获取研究区内相干目标点上的地面沉降信息(图 2)。同时利用 GIS 软件进行地面沉降监测数据的后处理与综合分析,编制研究区地面沉降相关图件。

从欧空局哥白尼(Copernicus)数据平台获取

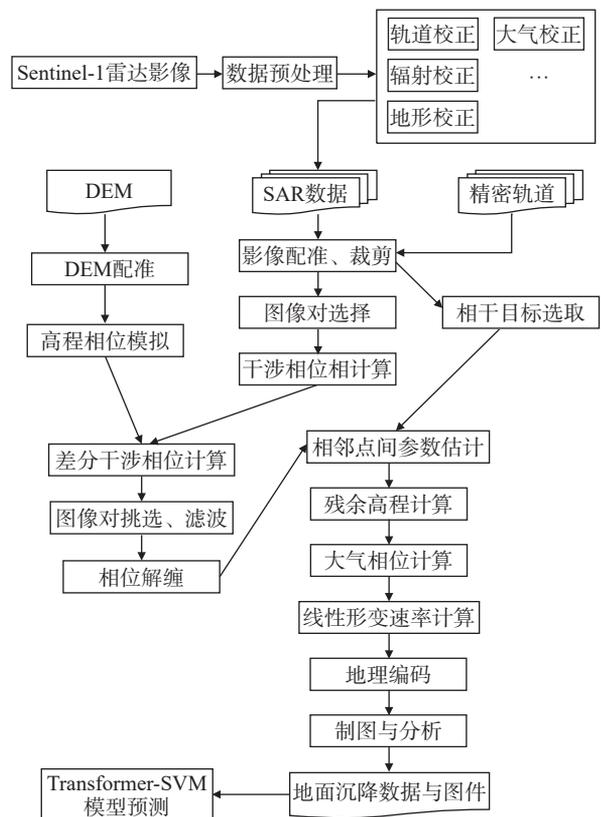


图 2 InSAR 监测技术路线图

Fig. 2 Roadmap for InSAR monitoring technology

研究区 2015 年 6 月至 2018 年 6 月、2022 年 1 月至 2023 年 12 月的 Sentinel-1 雷达影像数据。数据采用干涉宽幅(IW)模式获取,极化方式为 VV 单极化,搭载 C 波段(波长 5.6 cm)雷达传感器,重访周期为 12 天。影像详细参数详见表 1。

表 1 研究区 SAR 数据参数

Table 1 SAR data parameters in the research area

参数	数值
卫星类型	Sentinel-1
波段	C
成像模式	宽幅干涉 (IW)
空间分辨率	20 m
相对轨道号	11
极化方式	VV
数据级别	SLC级别
监测时间	2015年06月至2018年06月; 2021年01月至2023年12月

Sentinel-1 雷达卫星数据应用前需进行轨道校正、辐射校正、斑点噪声滤波、地形校正、大气校正等 SAR 数据预处理。在时序 InSAR 分析中,通过设定相干性阈值(如 >0.3)筛选高质量像元,排除因植被覆盖或地表变化导致的低相干区域。通过上述流程,显著地提升了数据几何精度、辐射一致性及噪声抑制效果,为后续沉降预测提供高质量输入。

为了更深入地验证 InSAR 数据的可靠性,选取 4 个地面监测站的数据进行对比,其中 CJC01、CJC09 和 CJC15 为 GNSS 监测站,CJC04 为拉杆式沉降监测站,以上地面监测站均于 2023 年建成,并且设备运行状态稳定。经验证,InSAR 监测数据与地面监测数据的拟合度较高,相关系数 R^2 达到了 0.96,平均绝对误差(MAE)为 3.50 mm,平均绝对百分比误差(MAPE)为 8.42%,均方误差(MSE)为 21.03 mm²,均方根误差(RMSE)为 4.59 mm。

3 软土地面沉降监测分析

通过上述数据处理,获得珠海市 2015—2018 年、2021—2023 年两期 InSAR 监测数据,深入分析发现珠海市软土地面沉降具有以下特征:

(1)珠海市软土地面沉降较为发育且呈规模增大趋势。珠海市软土地面沉降东、西区发育不均,主要集中发育在西部(斗门区和金湾区)地区,如斗门区白蕉镇、乾务镇南部、莲洲镇北部以及金湾区红旗镇西部、平沙镇与南水镇西部和南部,而在东部地区的香洲区、高新区、横琴粤澳深度合作区软土地面沉降不显著,仅在唐家湾镇北部、南屏镇南部、横琴北部发育有影响面积较小的沉降区。

2015—2018 年,珠海市软土地面沉降相对较小,最大沉降速率在 -40 mm/a 以上的沉降中心仅 2 个,沉降速率在 -30 mm/a 以上的区域面积达 7.1 km²,沉降速率在 -10 mm/a 以上的区域面积达 185.3 km²(图 3,表 2)。2021—2023 年,珠海市软土地面沉降有所加剧,最大沉降速率在 -40 mm/a 以上的沉降中心增加至 9 个,沉降速率在 -30 mm/a 以上的区域面积达 31.5 km²,沉降速率在 -10 mm/a 以上的区域面积达 365.9 km²(图 4,表 2)。

(2)地面沉降区与软土分布区基本一致。地面沉降区主要分布于螺洲河、荷麻溪等河流及其入海水道(磨刀门水道、鸡啼门水道)两岸,以上区域分布有不同厚度的软土层,地面沉降区与软土层分布区在空间分布上具有高度一致性。沉降量与软土层厚度不直接相关,受地下水开采、工程建设等外部应力影响显著。

(3)地下水过度开采是诱发西部水产养殖区地面沉降的主要因素。在斗门区白蕉镇、井岸镇与乾务镇以南、莲洲镇以北和金湾区联港工业区以北、平沙镇以西主要为水产养殖开采地下水,以上区域地下水开采量大,地面沉降呈大范围、片状分布(图 5a、5b、5c 区)。在水产养殖区内任一点处的地面累积沉降量变化呈现出比较一致的规律性波动:地表呈现出波动性下降,在每年 8 月、9 月底、11 月底出现明显的地面回弹,在 1 月、4 月或 5 月地面表现为明显的下沉(图 6)。在水产养殖过程中池塘中的水需要保持一定的温度和盐度且需要勤换水,当地养殖户一般抽取地下水来保持养殖池中水的温度和盐度,因此,水产养殖抽取地下水的时间与 InSAR 监测的地面累积沉降量变化基本一致。

(4)地面累积沉降量波动与当地工程活动密

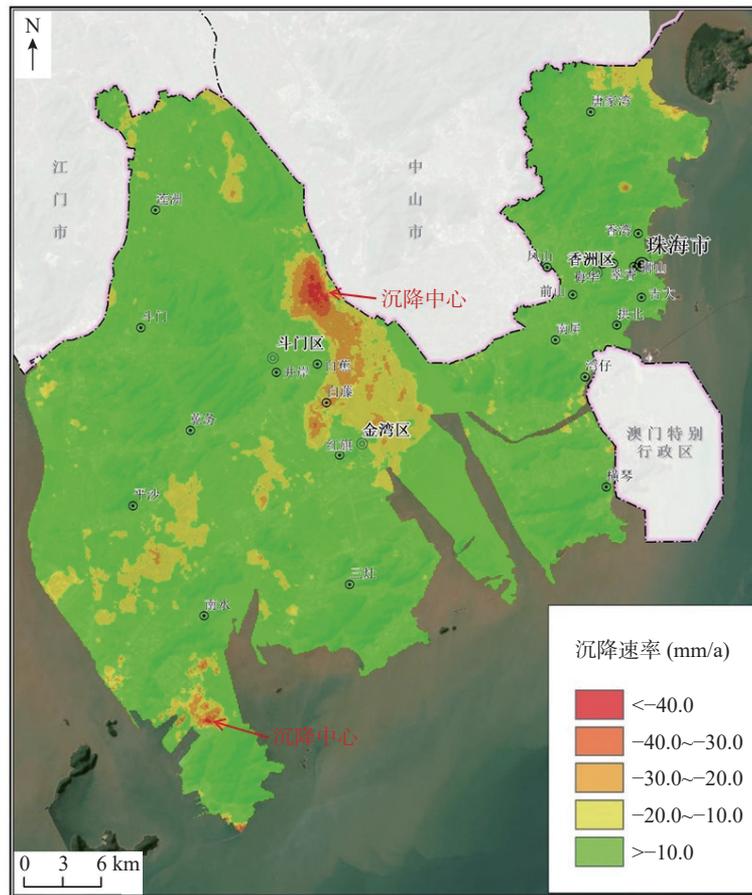


图3 InSAR 监测栅格图 (2015—2018 年)

Fig. 3 InSAR monitoring grid map (2015 ~ 2018)

表 2 各级沉降速率影响范围统计表

Table 2 Statistical of the impact range of settlement rates at various levels

序号	沉降速率 (mm/a)	2015—2018年影响面积 (km ²)	2021—2023年影响面积 (km ²)
1	-50.0 ~ -40.0	1.8	1.5
2	-40.0 ~ -30.0	5.3	30.0
3	-30.0 ~ -20.0	29.7	81.7
4	-20.0 ~ -10.0	148.5	252.7
5	-10.0 ~ 10.0	1287.0	1106.6
6	合计	1472.3	1472.3

切相关。在马骝洲水道两岸(图 5d 区)、金湾区石油化工区(图 5e 区),地面沉降主要是由外部大规模荷载作用于软土或工程建设施工导致软土地层中水分流失土体压缩引起的,这些区域内任意一点的地面累积沉降量曲线表现为波动式下降且波动频率大,当外部工程施工扰动大时, D4、E4 和 E2 等曲线呈现明显的直线下降(图 7)。

综上所述,珠海市软土地面沉降发育,地面沉

降受多种因素共同作用,特别是地下水开采和工程活动对地面沉降的影响。

4 软土地面沉降预测

4.1 Transformer-SVM 模型

Transformer-SVM 模型是一种将 Transformer 的自注意机制和支持向量机(SVM)相结合的机器学习模型。SVM 在小样本、高维数据分类中表现良好,但依赖人工特征工程(Abdelrahim E M et al., 2024)。Transformer 能自动学习特征,但参数量大,易过拟合(郝建华, 2024; 赵玉妹等, 2024; 陈嘉俊等, 2025)。组合模型通过 Transformer 进行特征提取和降维,再输入 SVM 进行分类,以提高分类精度和泛化能力,同时增强特征提取和可解释性。

Transformer-SVM 模型主要流程为:(1)分别设定 Transformer 和 SVM 两个模型的优化方法,初始化优化超参数,优化参数的上下限,以及优化

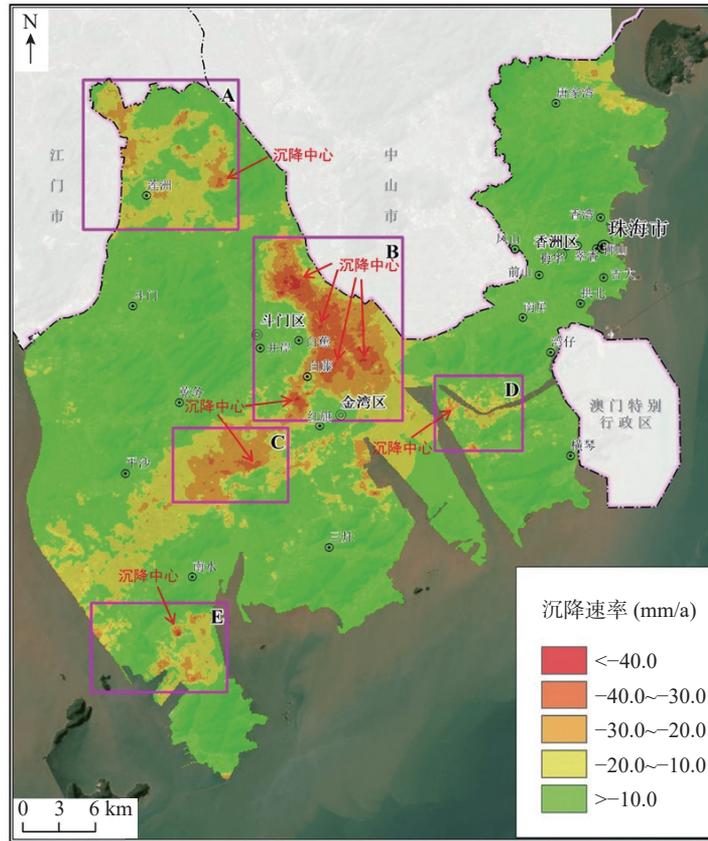


图 4 InSAR 监测栅格图 (2021—2023 年)

Fig. 4 InSAR monitoring grid map (2021—2023)

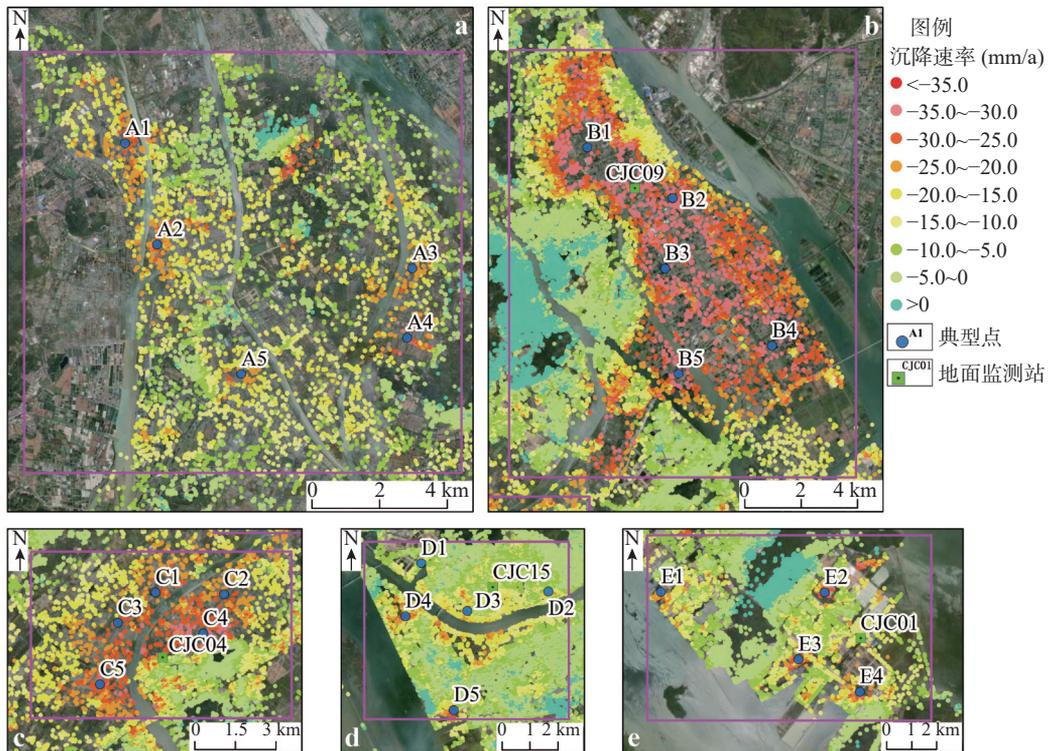


图 5 InSAR 监测典型点分布图

Fig. 5 Typical distribution map of InSAR monitoring points

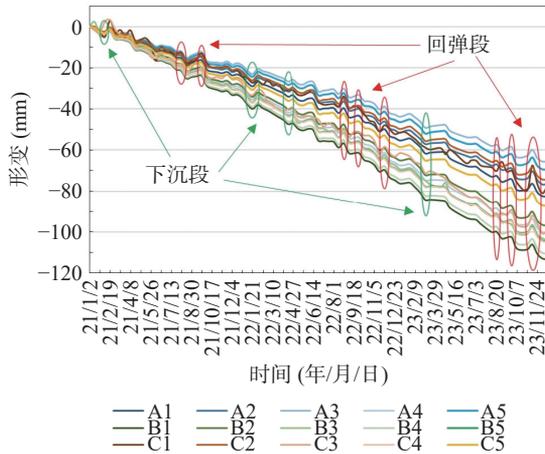


图6 水产养殖区典型点累积地面沉降量变动图

Fig. 6 Cumulative ground subsidence variation map of typical points in aquaculture area

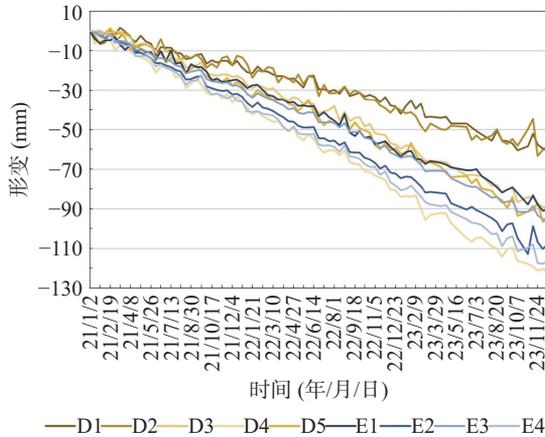


图7 工程活动区典型点累积地面沉降量变动图

Fig. 7 Cumulative ground subsidence variation map of typical points in the engineering activity area

迭代次数; (2)使用优化算法分别找到模型的最佳超参数模型,记录验证集在模型上的误差; (3)对不同模型在验证集上的误差进行判断,如果误差相差比较大的话,就选误差小的模型作为最终的模型,如果两个模型之间误差小于一定的阈值(θ),则对两个模型进行权重组合,最后的预测结果等于两个模型预测值的加权相加(图8)。

具体计算公式如下:

$$E_{\text{Tran}} = |Y_{\text{v}}^{\text{Tran}} - X_{\text{v}}| \quad (1)$$

$$E_{\text{SVM}} = |Y_{\text{v}}^{\text{SVM}} - X_{\text{v}}| \quad (2)$$

$$W_{\text{Tran}} = \frac{E_{\text{SVM}}}{E_{\text{Tran}} + E_{\text{SVM}}} \quad (3)$$

$$W_{\text{SVM}} = \frac{E_{\text{Tran}}}{E_{\text{Tran}} + E_{\text{SVM}}} \quad (4)$$

$$|E_{\text{Tran}} - E_{\text{SVM}}| / \max(E_{\text{Tran}}, E_{\text{SVM}}) < \theta \quad (5)$$

如果 $E_{\text{Tran}} > E_{\text{SVM}}$, 则 $W_{\text{SVM}} = 1, W_{\text{Tran}} = 0$

如果 $E_{\text{Tran}} < E_{\text{SVM}}$, 则 $W_{\text{SVM}} = 0, W_{\text{Tran}} = 1$

$$Y_{\text{T}}^{\text{Em}} = W_{\text{Tran}} \times Y_{\text{T}}^{\text{Tran}} + W_{\text{SVM}} \times Y_{\text{T}}^{\text{SVM}} \quad (6)$$

以上式中, X_{v} 为验证集的特征、 Y_{v} 为真实值、 $Y_{\text{v}}^{\text{Tran}}$ 和 $Y_{\text{v}}^{\text{SVM}}$ 分别为验证集上的预测值, $Y_{\text{T}}^{\text{Tran}}$ 和 $Y_{\text{T}}^{\text{SVM}}$ 为测试集上的预测值, Y_{T}^{Em} 为测试集上最终的预测结果。

4.2 模型构建与参数选择

利用 Matlab 软件平台, 构建一个 9 层深度学习网络架构, 其中第一层 input 为序列输入层, 第二层 pos-emb 为位置编码层, 主要用于输入序列添加位置信息; 第三层 add 为加法层, 是按元素方式添加来自多个神经网络层的输入, 有助于网络在训练过程中更好地传播梯度, 从而缓解梯度消失或爆炸问题; 第四层和第六层 selfattention 为自注意力层, 能够帮助模型在处理序列数据时, 对不同位置的信息进行适当的加权, 从而更好地捕捉序列中的关键信息; 第五层和第七层为 dropout 层, 可以缓解过拟合的现象; 第八层 fc 为全连接层, 最后一层 regressionoutput 为回归输出层。

选取典型地面监测站点 (CJC01、CJC04、CJC09、CJC15) 所在区域的 2021—2023 年 InSAR 监测数据进行单时间序列预测。每个典型点选取 85 组数据, 每组数据间隔时间为 12 天, 设置训练历史点个数为 10, 预测数据点个数为 6, 通过滑动窗口构造以 10 输入特征, 6 输出特征的多输入多输出数据集。

将各典型点数据集分别按 6 : 2 : 2 比例划分为训练集、验证集和测试集。模型训练过程中, 设定训练最大轮数为 1000, 并引入智能优化算法 (SSA 麻雀搜索算法) 进行超参数优化, 经反复试算, 最终确定最优超参数: 位置编码向量数为 8, 注意力机制头为 18, 注意力机制键为 32, 失活率为 0.26, 学习率为 0.009。

4.3 预测结果与分析

4.3.1 预测精度和可靠性分析

对各典型点预测结果的定量评估(表3)表明, Transformer-SVM 模型在 MAE(1.8±0.8 mm)、MA-

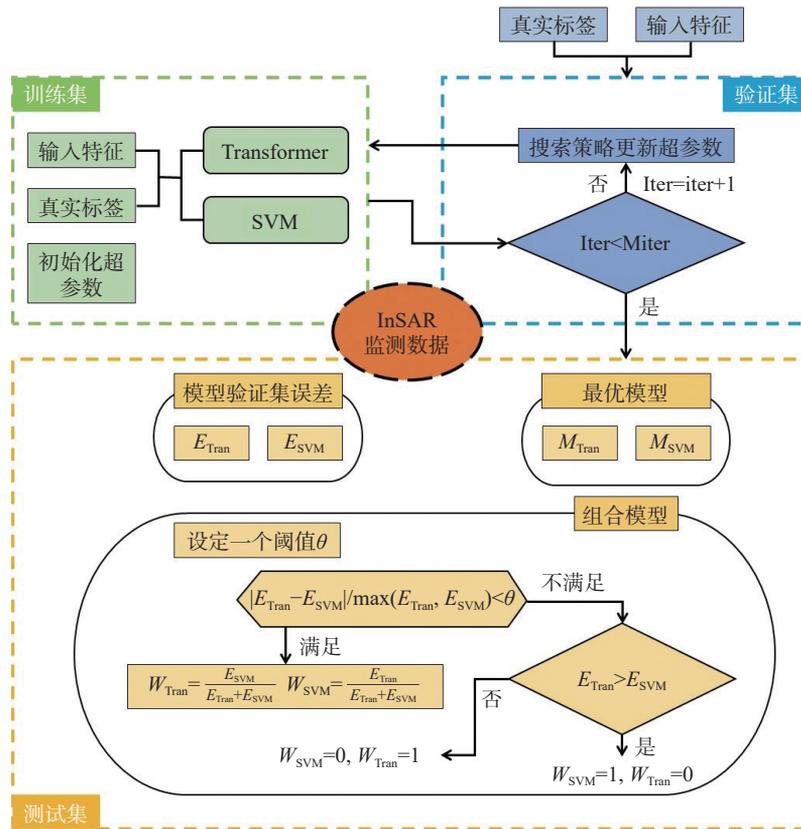


图 8 Transformer-SVM 模型主要流程图

Fig. 8 Main flowchart of Transformer-SVM model

表 3 训练模型预测精度

Table 3 Prediction accuracy of training model

监测点	评价指标	训练集	验证集	测试集
CJC01	MAE	1.1156	1.238	1.1683
	MAPE	0.10684	0.047721	0.034159
	MSE	1.8714	2.2859	2.3498
	RMSE	1.368	1.5119	1.5329
	R ²	0.96267	0.85611	0.89544
CJC04	MAE	1.6451	2.1158	2.0495
	MAPE	0.13558	0.063012	0.044121
	MSE	4.2337	6.5444	6.0258
	RMSE	2.0576	2.5582	2.4548
	R ²	0.92754	0.72312	0.81431
CJC09	MAE	1.5899	1.6102	3.0375
	MAPE	0.050058	0.023977	0.034038
	MSE	3.6731	3.6852	13.5464
	RMSE	1.9165	1.9197	3.6805
	R ²	0.99203	0.91833	0.79068
CJC15	MAE	1.5606	2.3048	2.7556
	MAPE	0.18318	0.12151	0.11083
	MSE	3.6326	7.4481	11.6024
	RMSE	1.9059	2.7291	3.4062
	R ²	0.90497	-0.11906	0.22652

PE(7.0±5.0%)、MSE(5.2±4.6 mm²)及 RMSE(2.2±0.9 mm)等核心误差指标上均有较出色的表现。

图 9a、9b、9c 及图 9d 的对比曲线显示,模型预测值与监测值线性拟合度高,平均绝对偏差为

1.5 mm, 其中 97.4% 的预测点误差控制在 ± 4 mm 置信区间内, 验证了模型的高精度特性。值得注意的是, 在时间序列预测中, 模型对相位突变点的捕捉误差不超过 5.3 mm, 展现出良好的动态响应

能力。

通过建立预测值与实测值的线性回归模型(图 9e、9f、9g、9h), 除 CJC15 监测站 ($R^2=0.8865$) 外, 其余 3 个监测站的 R^2 系数均达到 0.98

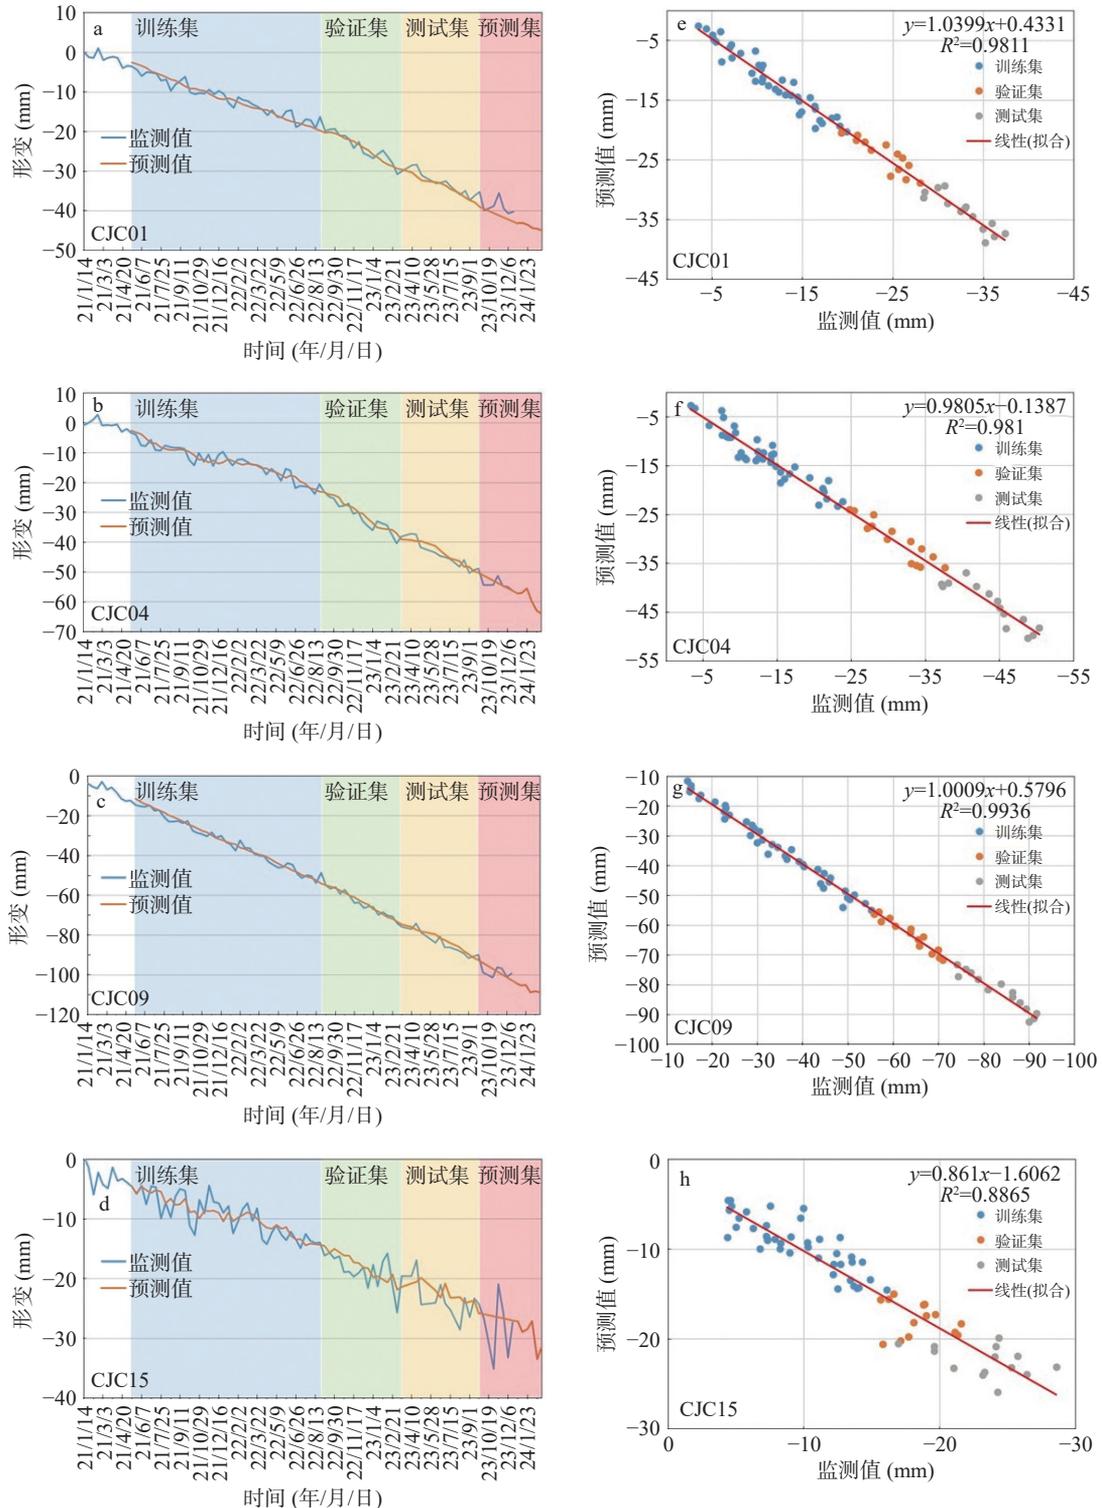


图9 典型监测站点预测结果对比

Fig. 9 Comparison of prediction results for typical monitoring stations

以上, 这种高相关性表明模型能够有效捕捉地面沉降的非线性时空演化规律。特别在沉降加速阶段(年沉降量 >30 mm), 模型预测精度仍保持稳定, 如 CJC09 监测点的相对误差未超过 5%。

在可靠性验证方面, 模型预测的沉降速率与地面监测站数据具有良好的一致性(图 10a、10b、

10c、10d)。83.3% 的沉降速率数据差异小于 ± 5 mm/a, 最大偏差为 9.3 mm/a, 出现在 CJC15 监测点所在区域。这一偏差与该区域近期市政道路工程施工导致的局部形变异常有关。施工活动会对地表产生额外的附加压力, 导致局部沉降速率加快, 从而影响监测数据的准确性。

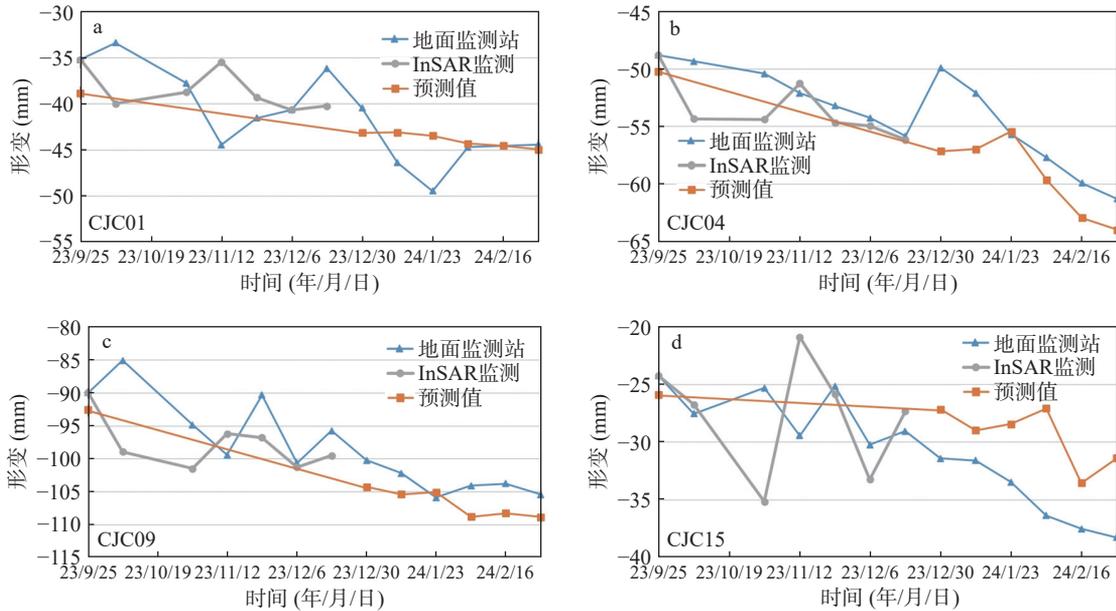


图 10 预测结果验证

Fig. 10 Prediction result verification

4.3.2 误差分析

(1) InSAR 监测数据固有误差

Transformer-SVM 模型的预测精度直接受 InSAR 监测数据质量制约。作为地面沉降监测的主流技术, InSAR 虽具有广域覆盖(单景覆盖数百平方千米)与毫米级精度的优势, 但在差异沉降场景中存在一定局限(相位解缠误差、大气延迟干扰及失相干现象), 特别是在严重差异沉降区域, 可能会因为地表不均匀沉降导致的相位差异而产生误差, 测得的沉降速率值偏大或偏小, 从而影响预测模型的准确性。

(2) 时空尺度失配效应

Sentinel-1 卫星重访周期为 12 天, 而地面监测站采样频率高达小时级, 两者时间分辨率相差三个数量级, 造成对短周期动态变化(例如抽水引起的沉降与回弹)的捕捉不足。同时, InSAR 的 30 m 空间分辨率使得单个像元内融合了约 900 m²

的地表信息, 难以准确反映地下管网、基坑等点源形变细节, 局部产生的误差可为地面监测站数据的 1.2 ~ 1.5 倍。

4.3.3 模型局限性及改进方向

模型局限性主要体现在处理沉降数据的固有特性和模型架构方面。首先, 地面沉降时间序列通常表现出非平稳性, 包含趋势变化、周期性波动以及随机扰动(施工扰动), 这些因素复合存在使得直接建模时容易产生误导性的回归结果(侯景鑫等, 2024)。其次, 沉降现象中存在多尺度时间耦合, 如长期的构造沉降、季节性的地层变化和日常的潮汐效应, 这些不同时间尺度的相互作用对传统方法来说难以分解。虽然 Transformer 模型中的自注意力机制在理论上能够捕捉任何长度的依赖关系, 但在处理有限样本数据(如 <5 年的监测数据)时, 往往会出现信息过度平滑的问题。最后, 模型还面临着噪声敏感性的挑战, 由于 InSAR

和地面监测站的噪声水平不同,这种异质的噪声分布会影响模型的广泛适用性。

改进方向:数据预处理方面,采样小波变换与EMD混合方法(石安平等,2022)处理多尺度问题,构建多源数据时空对齐框架,结合水准测量、激光雷达及地面监测站点等多种监测手段验证InSAR数据,确保数据精度与可靠性。模型架构方面,设计门控注意力机制提升特征提取,引入物理约束项(如Terzaghi固结方程)增强沉降演化规律的解释性,构建迁移学习框架(吴智博,2023),利用历史数据进行预训练,提升模型泛化能力。通过这些改进,模型在应对复杂地质环境和区域差异时表现出更高的精确度和可靠性,为地面沉降预测提供更准确、更可靠的解决方案。

5 结论

(1)通过对珠海市2015—2018年和2021—2023年两个时期的InSAR监测数据进行对比分析,发现珠海市地面沉降较为发育且呈规模增大趋势。沉降区域与软土广泛分布区高度吻合,且地面累积沉降量的波动与当地产业布局及工程活动密切相关。

(2)本研究基于InSAR监测数据,借助Matlab平台构建了Transformer-SVM模型,经过系统的训练和智能化超参数调优,该模型预测值与真实值曲线高度拟合,误差控制在 ± 4 mm范围内精度占比达97%以上,测试集 R^2 系数高达0.9以上,展现出高精确度和高可靠度。预测结果可为城市的规划与基础设施建设提供科学依据。

(3)InSAR监测虽具有广域覆盖和毫米级精度的优势,但在差异沉降场景中使用存在局限性,如相位解缠误差等会影响预测准确性;此外,时空尺度失配效应、沉降数据的非平稳性、多尺度时间耦合以及模型的噪声敏感性等因素也对监测精度带来挑战;改进方向包括数据预处理、模型架构优化,如采用小波变换、增强特征提取、引入物理约束等以提升模型精确度和可靠性。

参考文献:

曹炳强,刘智强,简程航,鲁泽宇,张双成,罗强.2021.北京市

地面沉降监测高精度数据处理及分析[J].导航定位学报,9(6):125-129+138.

陈嘉俊,刘波,林伟伟,郑剑文,谢家晨.2025.基于Transformer的时间序列预测方法综述[J].计算机科学,52(6):96-105.

陈媛媛,赵秉琨,王慧,郑加柱,高业,何敏.2024.基于LSTM模型的时序InSAR地表形变预测[J].人民长江,55(3):146-152.

丁晓利,陈永奇,李志林,刘国祥,章国宝.2000.合成孔径雷达干涉技术及其在地表形变监测中的应用[J].紫金山天文台台刊,(2):100-109.

郝建华.2024.基于深度学习的时间序列预测算法研究[D].山东师范大学博士学位论文.

侯景鑫,许兵,韦佳,李志伟,朱焱,毛文祥,刘维正.2024.顾及序列非平稳性的InSAR形变序列噪声分离与精化[J].地球物理学报,67(11):4077-4088.

黄茂庭,徐金明.2024.使用CNN(卷积神经网络)-LSTM(长短期记忆)联合神经网络预测盾构隧道施工引起的地面沉降[J].城市轨道交通研究,27(6):166-171.

江金进,刘佳,吴舒天,江山,赖波,李俊生.2020.珠海市软土分布特征及软土沉降风险评价[J].地质灾害与环境保护,31(2):68-74.

江金进,刘佳,江山,赵风顺,赖波,吴舒天,陈桂丽.2024.软土地面沉降调查评价和机理研究成果报告[R].广东省地质局第一地质大队(广东省珠海地质灾害应急抢险技术中心).

李华蓉,戴双璘,郑嘉欣.2024.基于InSAR监测和PSO-SVR模型的高填方区沉降预测[J].中国地质灾害与防治学报,35(2):127-136.

孟雪,赵燕容,黄小红,徐晓.2018.基于灰色GM(1,1)和神经网络组合模型的基坑周边地面沉降预测分析[J].勘察科学技术,(6):39-44.

彭文祥,张德英.2024.基于LSTM与Transformer的地面沉降智能预测方法研究——以上海市为例[J].时空信息学报,31(1):94-103.

石安平,周吕,王成,李欣益,马俊,黄玲.2022.结合EMD与小波阈值去噪的GB-RAR桥梁监测信号去噪[J].测绘通报,(S2):227-232+240.

吴智博.2023.基于深度迁移学习的桥梁裂缝检测与数据集扩充方法研究[D].湖南大学硕士学位论文.

严天笑.2024.基于时序InSAR技术和深度学习的建筑物沉降监测和预测[D].防灾科技学院硕士学位论文.

阳中磊.2023.基于InSAR技术的城市沉降监测及时空分

- 析 [D]. 中国矿业大学硕士学位论文.
- 赵玉妹,王大鹏,王昭然,白翔宇.2024.基于 Transformer 系列模型的高压线铁塔区域沉降预测方法 [J]. 电工技术,(15):76-80.
- Ao Z R, Hu X M, Tao S L, Hu X, Wang G Q, Li M J, Wang F, Hu L T, Liang X Y, Xiao J F, Yusup A, Qi W H, Ran Q W, Fang J Y, Chang J F, Zeng Z Z, Fu Y S, Xue B L, Wang P, Zhao K F, Li L, Li W K, Li Y M, Jiang M, Yang Y H, Shen H H, Zhao X, Shi Y, Wu B, Yan Z B, Wang M J, Su Y J, Hu T Y, Ma Q, Bai H, Wang L J, Yang Z Y, Feng Y H, Zhang D H, Huang E H, Pan J M, Ye H Y, Yang C, Qin Y W, He C Q, Guo Y P, Cheng K, Ren Y, Yang H T, Zheng C Y, Zhu J L, Wang S P, Ji C J, Zhu B, Liu H Y, Tang Z Y, Wang Z H, Zhao S Q, Tang Y H, Xing H F, Guo Q H, Liu Y, Fang J Y. 2024. A national-scale assessment of land subsidence in China's major cities[J]. *Science*, 384(6693): 301-306.
- Abdelrahim E M, Hashim H, Atlam E S, Osman R A, Gad I. 2024. TMS: Ensemble Deep Learning Model for Accurate Classification of Monkeypox Lesions Based on Transformer Models with SVM[J]. *Diagnostics*, 14(23): 2638.