



湖南大学
HUNAN UNIVERSITY

硕士学位论文

基于星载 InSAR 与多源异构数据融合 的城市地表沉降区域风险筛查研究

作者姓名	刘迎澳
指导教师	周云教授 谭忠坤教授级高工
培养单位	土木工程学院
专业类别	土木水利
专业领域	结构工程

学校代码 _____
学 号 S2301W0155
密 级 公开

湖南大学硕士学位论文

基于星载 InSAR 与多源异构数据融合的城市地表沉降风险筛查研究

作 者 姓 名：刘迎澳
指 导 教 师：周云教授 谭忠坤教授级高工
培 养 单 位：土木工程学院
专 业 类 别：土木水利
专 业 领 域：结构工程
论文提交日期：2026 年 4 月
论文答辩日期：2026 年 5 月
答辩委员会主席：

Investigation on Urban Land Subsidence Risk Screening Based on Spaceborne InSAR and Multi-Source Heterogeneous Data Fusion

by

Liu Yingao

B.E.(Hunan University of Science and Technology)2022

A dissertation submitted in partial fulfillment of the

requirements for the degree of

Master of Engineering

in

Civil and Hydraulic

in the

Graduate School

of

Hunan University

Supervisors

Professor ZHOU Yun, Senior Engineer TAN Zhongkun

May,2026

湖 南 大 学

学位论文原创性声明

本人郑重声明：所呈交的论文是本人在导师的指导下独立进行研究所取得的研究成果。除了文中特别加以标注引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写的成果作品。对本文的研究做出重要贡献的个人和集体，均已在文中以明确方式标明。本人完全意识到本声明的法律后果由本人承担。

作者签名：

日期： 年 月 日

学位论文版权使用授权书

本学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅和借阅。本人授权湖南大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

涉密学位论文在解密后适用本授权书。

作者签名：

日期： 年 月 日

导师签名：

日期： 年 月 日

摘 要

地面沉降是城市化进程中最具隐蔽性、累积性和持续性的地质环境问题之一。随着地下空间开发、轨道交通建设、城市更新及高强度工程扰动不断增强,城市地表形变逐渐演化为影响基础设施安全、土地利用效率和建筑使用性能的重要风险来源。传统水准测量和 GPS 等方法虽具有较高局部监测精度,但在广域、连续、低成本的城市建筑群风险排查任务中仍存在覆盖范围有限、组织实施复杂和监测效率不足等局限。近年来,星载合成孔径雷达干涉测量技术(Interferometric Synthetic Aperture Radar, InSAR)凭借覆盖范围广、观测效率高、全天时全天候及非接触式获取等优势,为城市地表沉降监测与建筑群安全风险排查提供了新的技术路径。然而,受其空间分辨率及 PS 点稀疏性的制约,离散形变结果仍难以直接支撑城市建筑群区域连续沉降识别与单栋建筑精细风险评估。为此,本文围绕“由离散 InSAR 形变观测向区域沉降预测、连续沉降场构建及建筑风险排查拓展”这一主线开展研究,以长沙市为研究对象,提出面向城市建筑群安全风险排查的沉降预测与连续场精细化构建方法。本文的主要研究内容如下:

(1) 提出面向区域沉降预测的离散沉降监督信息优化方法。结合旁瓣效应剔除与温度变形剔除,解决了 PS-InSAR 结果难以直接作为可靠沉降监督标签的问题。具体而言,本文针对低层建筑密集区 PSI 结果中易出现的伪散射体和虚假 PS 点问题,引入基于旁瓣效应剔除的 PSI 处理流程,并利用 Sentinel-1 与 COSMO-SkyMed 两类卫星影像开展交叉验证,以提高离散沉降观测结果的可靠性。在此基础上,考虑建筑上部结构温度效应对形变观测的影响,对显著温度相关变形点进行识别与剔除,并以筛选后的累计观测值作为沉降监督标签;围绕地形水文、地表覆盖、工程扰动及土体物性等方面构建 21 个沉降驱动因子,经皮尔逊相关分析与共线性筛查后保留 19 个有效输入因子,最终通过局部邻域图结构表达空间关系,构建融合 GraphSAGE 与图注意力网络的图神经网络沉降预测模型,为后续区域尺度沉降异常识别与风险区域筛查奠定基础。

(2) 提出面向城市尺度沉降异常识别的图神经网络沉降预测模型。解决 Sentinel-1 数据的 PS-InSAR 观测结果在空白区沉降值缺失问题。具体而言,本文围绕所构建沉降预测模型的输入合理性、网络结构有效性及预测结果可靠性开展系统研究。首先,基于驱动因子共线性分析结果设置筛查前后两组输入组合,对比不同因子体系下模型预测效果,验证驱动因子优化的必要性;其次,围绕 GraphSAGE 网络深度及多头图注意力网络设置多组对照实验,检验所构建混合网络在空间特征提取与复杂关系建模中的优越性;同时,结合连续沉降场结果、COSMO-SkyMed 高分辨率 PSI 结果及现场踏勘情况,对典型区域开展综合验证。

结果表明,该模型能够较好识别沉降异常区的位置及其空间分布格局,可用于城市尺度沉降风险区域的快速筛查与空间判别。

(3) 提出考虑数据自相关性的建筑尺度连续沉降场构建方法。解决在构建高分辨率连续沉降场时由于 PS 点分布不均与局部聚集导致的连续场偏差问题。具体而言,本文进一步在预测识别出的典型沉降风险区域内,基于高分辨率 COSMO-SkyMed 影像 PSI 结果获取建筑周边离散沉降信息,并在剔除显著温度相关变形点后,提出考虑数据自相关性的反距离加权插值方法,构建适用于建筑尺度的高分辨率连续沉降场。随后,结合传统 IDW 与普通克里金方法开展精度与效率对比分析,验证所提方法在建筑尺度连续沉降场构建中的优越性;并进一步从结构损伤风险与整体变形风险两个层面建立建筑综合评估方法,实现研究区域内建筑风险分级与典型建筑风险特征分析。

本文围绕城市建筑群安全风险排查需求,构建了由星载 InSAR 离散沉降观测、图神经网络区域沉降预测、建筑尺度连续沉降场精细化构建到单栋建筑风险评估的技术路线。研究结果表明,所提出的方法能够在较低成本和较大覆盖范围条件下实现沉降异常区的有效识别,并进一步支撑典型风险区域内单栋建筑的精细化风险排查,为星载 InSAR 技术在城市地表沉降监测、建筑群安全风险筛查及后续建筑风险评估中的推广应用提供了方法支撑。

关键词: 星载 InSAR; 地表沉降预测; 图神经网络; 连续沉降场; 区域风险评估

Abstract

Land subsidence is one of the most concealed, cumulative, and persistent geo-environmental problems in the process of urbanization. With the continuous intensification of underground space development, rail transit construction, urban renewal, and high-intensity engineering disturbances, urban surface deformation has gradually become an important risk source affecting infrastructure safety, land-use efficiency, and building service performance. Although conventional leveling and GPS methods can provide relatively high local monitoring accuracy, they still suffer from limited spatial coverage, complicated field implementation, and insufficient monitoring efficiency in large-scale, continuous, and low-cost risk screening of urban building clusters. In recent years, spaceborne Interferometric Synthetic Aperture Radar (InSAR), with the advantages of wide coverage, high observation efficiency, all-weather capability, and non-contact acquisition, has provided a new technical approach for urban land subsidence monitoring and building-cluster safety risk screening. However, constrained by spatial resolution and the sparsity of PS points, discrete deformation observations still cannot directly support continuous subsidence identification at the urban building-cluster scale or refined risk assessment of individual buildings. Therefore, this study focuses on the extension from discrete InSAR deformation observations to regional subsidence prediction, continuous subsidence field construction, and building risk screening. Taking Changsha as the study area, a subsidence prediction and refined continuous-field construction method for urban building-cluster safety risk screening is proposed. The main research contents are as follows:

(1) A discrete subsidence supervision information optimization method for regional subsidence prediction is proposed.

By integrating sidelobe-effect elimination and temperature-related deformation removal, the problem that PS-InSAR results cannot be directly used as reliable subsidence supervision labels is addressed. Specifically, for the pseudo-scatterer and false-PS problems that easily occur in PSI results over dense low-rise building areas, a PSI processing workflow based on sidelobe-effect elimination is introduced. Sentinel-1 and COSMO-SkyMed SAR images are further used for cross-validation to improve the reliability of discrete subsidence observations. On this basis, considering the influence of temperature effects of upper building structures on deformation observations, points with significant temperature-related deformation are identified and removed, and the filtered

cumulative observations are used as subsidence supervision labels. Furthermore, 21 subsidence-driving factors are constructed from the perspectives of terrain and hydrology, land cover, engineering disturbance, and soil physical properties. After Pearson correlation analysis and collinearity screening, 19 effective input factors are retained. Finally, spatial relationships are represented through local neighborhood graph structures, and a graph neural network-based subsidence prediction model integrating GraphSAGE and a graph attention network is established, providing a data foundation for subsequent regional-scale subsidence anomaly identification and risk-area screening.

(2) A graph neural network-based subsidence prediction model for urban-scale subsidence anomaly identification is proposed.

This model addresses the problem of missing subsidence values in blank areas of Sentinel-1 PS-InSAR observations. Specifically, this study systematically investigates the rationality of model inputs, the effectiveness of the network architecture, and the reliability of prediction results. First, based on the collinearity analysis of subsidence-driving factors, two groups of input combinations before and after factor screening are designed to compare the prediction performance under different factor systems and verify the necessity of driving-factor optimization. Second, multiple comparative experiments are conducted by varying the depth of the GraphSAGE network and the configuration of the multi-head graph attention network, so as to examine the superiority of the proposed hybrid network in spatial feature extraction and complex relationship modeling. Meanwhile, the predicted continuous subsidence field, high-resolution COSMO-SkyMed PSI results, and field investigation observations are combined to comprehensively validate typical areas. The results show that the proposed model can effectively identify the locations and spatial distribution patterns of subsidence anomaly areas, and can be used for rapid screening and spatial discrimination of urban-scale subsidence risk areas.

(3) A building-scale continuous subsidence field construction method considering data autocorrelation is proposed.

This method addresses the continuous-field bias caused by uneven and locally clustered PS point distributions when constructing high-resolution continuous subsidence fields. Specifically, within the typical subsidence risk areas identified by the prediction model, high-resolution COSMO-SkyMed PSI results are used to obtain discrete subsidence information around buildings. After removing points with significant temperature-related deformation, an inverse distance weighting interpolation method considering data autocorrelation is proposed to construct a high-resolution continuous subsidence field suitable for building-scale analysis. Then, comparative analyses of

accuracy and computational efficiency are carried out against conventional IDW and ordinary kriging methods, verifying the superiority of the proposed method in building-scale continuous subsidence field construction. Furthermore, a comprehensive building assessment method is established from the perspectives of structural damage risk and overall deformation risk, realizing building risk grading and typical building risk characteristic analysis in the study area.

In summary, this study establishes a technical route for urban building-cluster safety risk screening, covering discrete subsidence observation based on spaceborne InSAR, regional subsidence prediction using graph neural networks, refined construction of building-scale continuous subsidence fields, and individual building risk assessment. The results show that the proposed method can effectively identify subsidence anomaly areas under conditions of relatively low cost and large spatial coverage, and can further support refined risk screening of individual buildings within typical risk areas. This study provides methodological support for the broader application of spaceborne InSAR in urban land subsidence monitoring, building-cluster safety risk screening, and subsequent building risk assessment.

Keywords: spaceborne InSAR; land subsidence prediction; graph neural network; continuous subsidence field; regional risk assessment

目 录

摘 要	II
Abstract	IV
目 录	VII
附图索引	X
附表索引	XIII
第 1 章 绪 论	1
1.1 研究背景及意义	1
1.2 国内外研究现状	3
1.2.1 InSAR 技术的起源与研究进展	3
1.2.2 城市建筑群区域 PS 点识别难点	4
1.2.3 区域沉降预测研究现状	7
1.2.4 城市区域多源异构大数据研究现状	9
1.2.5 图神经网络研究现状	10
1.2.6 InSAR 离散形变场连续化研究现状	12
1.3 已有研究不足	14
1.4 本文研究内容	15
第 2 章 星载 InSAR 技术基本原理	17
2.1 引言	17
2.2 SAR 卫星概述	17
2.3 星载 InSAR 对地形变观测技术	19
2.3.1 星载 InSAR 技术基本原理	19
2.3.2 PS-InSAR 技术检测原理	22
2.4 PSI 变形分解原理	26
2.4.1 PS-InSAR 结果 LOS 向变形组成原理	26
2.4.2 基于 GNSS 的 LOS 向垂直变形提取	27
2.4.3 基于升降轨联合观测的垂直向形变提取	27
2.4.4 忽视水平向形变的传统近似分解方法	28
2.5 本章小结	28
第 3 章 基于多源异构大数据与图神经网络的沉降预测模型研究	30
3.1 引言	30
3.2 融合多头图注意力的图神经网络沉降预测模型设计	30
3.2.1 沉降预测问题的图结构表达	30
3.2.2 基于图神经网络的沉降预测模型总体架构	32

3.2.3 输入层设计	33
3.2.4 特征提取模块设计	35
3.2.5 决策层与优化目标设计	36
3.3 研究区域与数据集预处理	38
3.3.1 长沙市区域概况	38
3.3.2 数据集来源	38
3.3.3 基于旁瓣效应剔除的 PS-InSAR 技术流程	40
3.3.4 PS-InSAR 结果交叉验证	41
3.3.5 PSI 结果温度变形剔除与监督信号构建	43
3.4 沉降驱动因子分析与构建	45
3.4.1 基于 DEM 构建的沉降驱动因子	46
3.4.2 年均归一化植被指数变化量	49
3.4.3 基于欧氏距离创建的沉降驱动因子	50
3.4.4 基于土壤分布构建的沉降驱动因子	52
3.5 模型训练示例	55
3.6 本章小结	57
第 4 章 基于图神经网络的沉降预测模型验证与分析	58
4.1 引言	58
4.2 驱动因子相关性分析	58
4.3 实验设计与结果分析	60
4.3.1 实验环境与参数设置	60
4.3.2 实验评价指标	61
4.3.3 沉降驱动因子消融实验	61
4.3.4 网络结构消融实验	63
4.4 模型性能评估与驱动因子重要性排序	67
4.4.1 模型性能评估	67
4.4.2 沉降驱动因子重要性排序	68
4.5 模型预测结果与验证	71
4.6 本章小结	77
第 5 章 区域沉降场精细化构建与变形风险评估研究	79
5.1 引言	79
5.2 传统插值方法原理与局限性	79
5.2.1 反距离加权法原理与局限性	79
5.2.2 克里金插值原理	81
5.3 考虑数据自相关性的反距离加权法	82

5.3.1 考虑数据自相关性的反距离加权法原理	82
5.3.2 全局常数与局部变化指数的确定方法	84
5.3.3 基于考虑数据自相关性 IDW 的四种插值模型	86
5.4 研究区域与实验设计	87
5.4.1 研究区域及数据	87
5.4.2 实验设计	88
5.4.3 实验结果	88
5.5 基于连续沉降场的建筑变形风险评估	95
5.5.1 基于连续沉降场的建筑变形风险评估方法	95
5.5.2 建筑风险评估结果与空间分布特征	97
5.5.3 典型建筑风险特征分析	99
5.6 本章小结	103
结论与展望	104
参考文献	106
附录 A（长沙市主要城市区域沉降预测结果展示图）	120
致 谢	126

附图索引

图 1.1 城市沉降的全国分布情况 ^[1]	1
图 1.2 不同入射角度下某建筑物的 SAR 影像图 ^[29]	4
图 1.3 (a) 根据平屋顶建筑模型模拟的点状散射体; (b)根据具有不同屋顶形态 和高度变换的建筑模型模拟的点状散射体 ^[30]	5
图 1.4 地面沉降形成机理及主要影响因素示意图	7
图 1.5 图神经网络模型典型设计图	10
图 1.6 研究内容	16
图 2.1 主要 SAR 成像模式	18
图 2.2 Sentinel-1 与 COSMO-SkyMed 卫星图	18
图 2.3 InSAR 观测原理几何示意图	20
图 2.4 PS-InSAR 计算流程图	22
图 2.5 卫星 LOS 观测几何与形变分解示意图	26
图 3.1 城市地表沉降预测问题的图结构表达模式示意图	32
图 3.2 Patch 图样本的 SAGEGAT 特征提取与中心节点回归结构示意图	32
图 3.3 边连接关系示意图	33
图 3.4 节点特征矩阵示意图	35
图 3.5 COSMO-SkyMed SAR 影像覆盖范围示意图	39
图 3.6 SAR 影像旁瓣效应	40
图 3.7 伪散射体产生的虚假 PS 点	41
图 3.8 基于旁瓣效应剔除的 PSI 流程图	41
图 3.9 长沙市河西地区 PSI 结果示意图	42
图 3.10 PSI 结果交叉验证区域	42
图 3.11 Sentinel-1 与 COSMO-SkyMed 数据 PSI 交叉验证结果	43
图 3.12 高层建筑下 PS 点变形速率与热变形分布图 ^[174]	43
图 3.13 监督信号数据集划分	44
图 3.14 基于 DEM 派生的沉降驱动因子	47
图 3.15 年均 NDVI 变化量	50
图 3.16 基于欧氏距离创建的沉降驱动因子	51
图 3.17 土壤相关因子	53
图 4.1 沉降驱动因子的皮尔逊相关系数热力图	59
图 4.2 强相关驱动因子散点图	60
图 4.3 C1 与 C2 组预测模型的损失函数曲线图	62

图 4.4 不同 GraphSAGE 层数预测模型损失函数曲线.....	64
图 4.5 A1 至 A6 组损失函数曲线.....	65
图 4.6 沉降驱动因子重要性排序	70
图 4.7 长沙市沉降预测结果	72
图 4.8 区域 A1 的模型预测结果与 CSK 影像 PSI 结果.....	73
图 4.9 区域 A1 现场勘探结果	73
图 4.10 区域 A2 的模型预测结果与 CSK 影像 PSI 结果.....	74
图 4.11 区域 A3 的模型预测结果与 CSK 影像 PSI 结果.....	75
图 4.12 区域 A2 与 A3 的现场勘探结果	75
图 4.13 B1 与 B2 区域的模型预测结果.....	76
图 4.14 区域 B1 与 B2 的现场勘探结果.....	77
图 4.15 长沙市主要城市区域沉降预测结果位置分布图	77
图 5.1 反距离权重插值原理	80
图 5.2 不均匀 PS 点分布情况下 IDW 产生的错误估计.....	81
图 5.3 考虑数据自相关性的反距离加权法机制图	83
图 5.4 全局常数指数的选取流程图	85
图 5.5 局部变化指数的选取流程图	86
图 5.6 研究区域 PS 点分布情况.....	87
图 5.7 插值模型 1 的 p_1 与 p_2 等值线图	89
图 5.8 不同 p_1 指数下插值模型 2 估算值的相关解释精度 a) MAE; b) MSE; c)RMSE; d) R^2	90
图 5.9 不同 p_2 指数下插值模型 3 估算值的相关解释精度 a) MAE; b) MSE; c)RMSE; d) R^2	90
图 5.10 最佳距离衰减强度指数 $p_1^*(x_0)$ 的空间分布特征.....	91
图 5.11 最佳聚集修正强度指数 $p_2^*(x_0)$ 的空间分布特征	92
图 5.12 六种插值方法在 100 个验证 PS 点处的估算值与实际值的散点图...	93
图 5.13 基于不同插值方法的连续沉降场构建结果	94
图 5.14 建筑沉降示意图 ^[166]	96
图 5.15 研究区域建筑白膜矢量示意图	98
图 5.16 基于插值模型 4 的研究区域近半年沉降增量场	98
图 5.17 建筑沉降变形风险评估图	99
图 5.18 建筑沉降曲线	100
图 5.19 建筑局部横倾角	100
图 5.20 典型建筑风险评估结果	101
图 5.21 典型建筑现场实景	102

附表索引

表 1.1 地面沉降监测的主要方法	2
表 2.1 两类星载 SAR 数据的主要参数	18
表 3.1 沉降驱动因子源数据概况	39
表 3.2 沉降驱动因子与源数据对应关系	45
表 3.3 图神经网络单个训练样本的输入与标签构成示例	55
表 4.1 共线性分析前后驱动因子输入的消融实验设计	61
表 4.2 共线性分析前后驱动因子输入的模型评价指标	62
表 4.3 不同 GraphSAGE 层数下预测模型的评价指标	63
表 4.4 注意力网络消融实验设置	64
表 4.5 A1 至 A6 组的评价指标	65
表 4.6 传统插值方法在测试集上的评价指标	67
表 4.7 模型输入层权重范数与验证集置乱检验结果	69
表 5.1 基于考虑数据自相关性 IDW 的四种插值模型设计	87
表 5.2 六种插值方法的精度与计算时间	92
表 5.3 风险评估指标占比 ^[166]	97
表 5.4 研究区域内相对综合风险值的百分位分级结果	99
表 5.5 典型建筑相对风险百分位评估结果	101

第1章 绪 论

1.1 研究背景及意义

地面沉降通常是指在自然因素与人类活动共同作用下，地表标高在较大范围内持续缓慢降低的现象，具有隐蔽性^[171]、累积性^[172]和持续性^[173]等特征，是城市化进程中典型的地质环境问题之一。与滑坡、崩塌等突发性地质灾害不同，地面沉降多表现为缓慢发展和长期累积，其工程危害往往通过地基附加变形、建筑物差异沉降、道路及地下管线损伤等形式逐步显现。随着地下水开采、地下空间开发、工程降排水、轨道交通建设、城市更新及其他高强度工程活动持续推进，城市地表沉降的影响范围已由局部工程场地逐步扩展至片区乃至城市尺度，并进一步演化为影响城市基础设施安全、土地利用效率和可持续发展的重要风险来源^{[1][2][9]}。2021年 Science 发表的研究表明，全球约 19%的人口可能面临较高地面沉降风险；如图 1.1 所示，针对中国主要城市的全国尺度评估进一步指出，我国主要城市中约 45%的城市用地正在发生沉降，约 16%的城市用地沉降速率超过 10mm/年^{[1][2]}。由此可见，地面沉降已成为制约城市安全运行与高质量发展的重要现实问题。




图 1.1 城市沉降的全国分布情况^[1]

对于城市建筑环境而言，真正具有工程破坏意义的并不只是地表高程的整体

降低,而是不均匀沉降在建筑单体及建筑群尺度上的集中释放。当差异沉降持续累积时,往往会进一步诱发房屋开裂、倾斜、基础失稳^[3],建筑低层会出现显著非线性响应,并且部分构件已消耗安全储备、处于接近失效的边缘^[4]。2022 年湖南长沙“4·29”特别重大居民自建房倒塌事故共造成 54 人死亡、9 人受伤;事故调查认定,违法违规加层扩建、结构不合理且稳定性差和安全治理失守是导致事故发生的重要原因^[6]。事故发生后,住房和城乡建设部随即部署开展全国自建房安全专项整治,建筑安全风险排查已经上升为城市安全治理中的紧迫任务^[7]。在这一背景下,如何以更大范围、更高效率、更低成本的方式识别潜在高风险建筑群,已成为土木工程、遥感监测与城市治理交叉领域亟待解决的重要问题。

在地面沉降监测领域,主要的监测方法如表 1.1 所示,但这些方法普遍存在点状采样、采样周期长和实施成本较高等问题,尚难兼顾城市尺度地面沉降监测所需的广域覆盖、连续观测以及精细化等要求,因此亟需引入覆盖范围更广、监测效率更高的技术手段作为支撑。

表 1.1 地面沉降监测的主要方法

监测方法	监测原理	优点	缺点
精密水准测量 ^[148]	通过不同时期重复观测 基准点高程差获取地表 垂向变形	垂向监测精度高	组织实施复杂,外业工作 量大,成本高,覆盖范围 有限
GNSS 测量 ^[8]	通过连续观测获取监测 点三维形变信息	可获得三维形变信息, 自动化程度较高	布置成本高,空间覆盖能 力有限
LiDAR ^[12]	通过不同时期点云差异 获取地表高程变化	空间分辨率高	数据获取成本较高,时间 连续性差
无人机摄影测量 ^[11]	基于多期无人机影像重 建点云,比较不同时期 地表高程变化	获取灵活,局部空间分 辨率高	覆盖范围有限,受航摄条 件和控制点布设影响较大

近年来,星载合成孔径雷达干涉测量技术(Interferometric Synthetic Aperture Radar, InSAR)的快速发展,为城市地表及建筑物形变监测提供了新的技术路径。该技术利用星载合成孔径雷达对同一区域进行重复观测,通过对不同时相获取的 SAR 影像进行干涉处理,并结合相位信息反演观测目标沿雷达视线方向的形变过程^[13]。相较于传统监测方法,星载 InSAR 具有覆盖范围广、观测效率高、全天候、非接触式获取以及形变反演精度较高等优势,能够在单景影像尺度上获取大范围区域的形变信息,并有效弥补传统方法在空间覆盖能力和连续监测能力方面的不足。尤其是多时相 InSAR 技术的发展,进一步提升了微小形变提取能力,使其在城市地面沉降监测、建筑群形变识别及安全风险评估等方面展现出良好的

应用前景^{[14][15]}。

基于上述背景，本章围绕 InSAR 技术发展、城市建筑群区域 PS 点识别、区域沉降预测、多源异构数据、图神经网络及离散形变场连续化等方面梳理国内外研究现状；在此基础上总结现有研究中仍存在的主要问题，进一步明确本文的研究内容、技术路线与章节安排，为后续模型构建、实验验证及建筑风险评估研究奠定基础。

1.2 国内外研究现状

1.2.1 InSAR 技术的起源与研究进展

合成孔径雷达干涉测量起源于雷达遥感与干涉测量理论的结合。1974 年，Graham 首次提出利用合成干涉雷达进行地形测绘的思想，标志着 InSAR 概念的正式形成^[16]。随后，Zebker 和 Goldstein 于 1986 年通过星载干涉观测验证了利用干涉 SAR 获取高分辨率地形信息的可行性，使 InSAR 从理论构想逐步走向对地观测实践^[17]。到 20 世纪 80 年代末 Gabriel 等提出差分干涉测量方法(Differential InSAR, D-InSAR)，通过对不同时相 SAR 影像进行差分处理提取地表微小形变信息，使 InSAR 实现了由地形恢复向地表形变监测的关键拓展^[18]。此后，相关综述研究又从干涉测量机理、误差来源及典型应用等方面对 InSAR 技术进行了系统总结，推动其逐步发展为定量化的大地测量工具^{[19][20]}。

尽管 D-InSAR 显著提升了地表微小形变探测能力，但其监测精度仍容易受到时空失相干、大气延迟、轨道误差及相位解缠误差等因素影响，在长时间序列和复杂地表环境中的适用性有限。为突破这一瓶颈，学者们逐步提出多时相 InSAR 方法。其中，永久散射体干涉测量(Persistent Scatterer InSAR, PS-InSAR)通过识别长时序中相位稳定的永久散射体，实现了城市区域毫米级形变监测^[21]；小基线集方法(Small Baseline Subset InSAR, SBAS-InSAR)则通过构建小时空基线干涉图网络，提高了技术在非线性形变和低相干区域中的适用能力^[22]。在此基础上，Hooper 提出融合 PS 与 SBAS 思路的多时相处理方法，进一步提高了可用测点数量和整体信噪比，使时序 InSAR 在复杂场景中的应用更加稳健^[23]。这些方法的提出，标志着 InSAR 技术由单对影像差分分析进入长时间序列精细反演阶段。

随着高分辨率 SAR 卫星和长时间序列观测数据的不断积累，InSAR 技术研究进一步由经典 PS 点处理向分布式散射体利用、多源联合反演和多维形变恢复方向拓展。Ferretti 等于 2011 年提出 SqueeSAR 方法，可联合处理永久散射体与分布式散射体，显著提高非城市区和低相干区域的测点密度^[24]；Goel 和 Adam 则面向非城市场景提出了针对分布式散射体的高分辨率形变估计方法，进一步拓宽了时序 InSAR 的适用范围^[25]。在此基础上，Crosetto 等对 PSI 技术的算法体系、精度验证方法与典型应用进行了系统回顾，指出 PSI 已成为地表形变长期监测的重要技术

分支^[26]；Pepe 和 Calò 则进一步总结了多轨、多角度 InSAR 在三维形变获取方面的发展进展^[27]。总体来看，当前 InSAR 技术正由早期的二维地形恢复和一维视线向形变监测，向高密度、长时序、多平台、多维度联合观测方向持续演进。

相较于国外较早开展的理论研究与方法创新，国内 InSAR 研究起步稍晚，但发展迅速。朱建军等对 InSAR 形变监测方法及研究进展进行了系统梳理，指出 D-InSAR、PS-InSAR、SBAS-InSAR、DS-InSAR 以及 MAI 等方法已经形成较为完整的技术谱系，并在城市、矿山、地震、基础设施、冻土和滑坡等领域得到广泛应用^[28]。

1.2.2 城市建筑群区域 PS 点识别难点

永久散射体干涉测量（PS-InSAR）以长时间序列中相位稳定的强散射目标为基础，通过对永久散射体点进行参数估计实现地表微小形变反演^[21]。因此，PS 点的数量和空间分布在很大程度上决定了形变监测结果的有效性。Crosetto 等在综述中指出，PSI 在低反射率、表面过于平滑或相干性较差的区域往往难以获得足够测点^[26]。进一步面向建筑目标的研究表明，城市建筑中的 PS 点并不是简单均匀分布于屋顶和立面，而是具有极其复杂的散射特性。




图 1.2 不同入射角度下某建筑物的 SAR 影像图^[29]

如图 1.2 所示，在不同入射角条件下，同一建筑物的 SAR 亮点分布存在明显差异；对应的模拟结果及多次反射成分进一步表明，建筑边缘、立面与地面之间形成的多次散射机制会随观测几何变化而发生改变，从而导致强散射中心的位置、数

量及响应强度出现明显变化^[29]。这说明，同一建筑在不同成像条件下可被稳定识别的散射体并不固定，部分原本较强的稳定散射中心可能随入射角变化而减弱，甚至难以继续保持稳定散射特征。由此可见，城市建筑群区域内 PS 点的形成具有显著的几何依赖性，其数量并不单纯取决于建筑物是否存在，而与建筑立面结构、屋顶形态及其与雷达视线之间的相对几何关系密切相关。同时，Yang 等利用 RaySAR 技术进行城市建筑群区域的 PS 点模拟，发现具有不同屋顶形态和高度变换的建筑，其 PS 点的数量是平屋顶建筑的 1.58 倍左右^[30]。这意味着，城市建筑群区域内的 PS 点数量同时取决于建筑材料、结构构造以及建筑朝向与雷达入射角的几何关系等。对于低层建筑密集区和屋面结构简单的老旧街区中，PS 点往往会表现出数量不足、分布不均和连通性较差等问题。




图 1.3 (a) 根据平屋顶建筑模型模拟的点状散射体；(b)根据具有不同屋顶形态和高度变换的建筑模型模拟的点状散射体^[30]

上述研究表明，城市建筑群区域 PS 点稀疏并非单纯由数据处理精度不足引起，而是与 SAR 成像几何、建筑散射结构、屋顶形态及影像空间分辨率等因素共同相关。PS 点数量不足和空间分布不均会使 PS-InSAR 结果呈现明显离散性，部分建筑区域可能缺乏有效观测点，从而限制城市建筑群区域形变信息的完整获取。针对这一问题，现有研究主要从提高 SAR 影像空间分辨率、扩展可利用散射体类型以及多方法融合等方面展开，具体可归纳为以下三类技术路径。

方法一：提高 SAR 影像空间分辨率

针对城市建筑群区域 PS 点稀疏问题，国外研究较早从提高 SAR 影像空间分

分辨率入手。相较于中等分辨率 SAR 数据,极高分辨率 SAR 影像能够更细致地表征建筑边缘、角隅及立面等散射特征,从而增加城市区域可稳定识别的散射体数量,提高单体建筑及局部构筑物的可观测性^[31]。在此基础上,相关研究进一步结合米级 TerraSAR-X 数据、升降轨点云融合及层析 SAR 等方法,实现了单体建筑尺度的形变监测与叠掩散射体分离,并在多轨高分辨率数据条件下开展了城市基础设施三维形变监测^{[32]-[34]}。总体来看,提高影像空间分辨率并结合多视几何或层析反演,能够在一定程度上提升建筑目标的测点密度与结构表达能力,是缓解城市建筑群区域 PS 点稀疏问题的重要技术路径。然而,这类方法通常依赖商业高分辨率 SAR 数据,虽然在目标分辨能力和局部监测精度方面具有优势,但在大范围、长时序和低成本常态化监测中的应用仍存在一定限制。

方法二: 散射体类型扩展与联合处理

随着研究的深入,学者们逐渐认识到,单纯依靠更高分辨率数据并不能从根本上解决城市建筑群中测点稀疏和覆盖不连续的问题,因此开始转向散射体类型扩展与联合处理。Ferretti 等提出的 SqueeSAR 方法将永久散射体与分布式散射体(DS)联合纳入处理框架,被认为是提升测点密度的重要里程碑^[24]。Wang 等针对城市区域提出基于极高分辨率 SAR 数据的 DS 相位历史反演方法,使 DS 不再只能以像元集合形式参与处理,而可以实现更细粒度的散射体利用^[35]。Lv 等提出的 Joint-Scatterer Processing 进一步拓展了时间序列 InSAR 中可利用散射体的类型^[36]。Jiang 等围绕统计同质像元(SHP)选择提出快速估计方法,为 DS-InSAR 中协方差矩阵稳定估计提供了关键支撑^[37]。Even 和 Schulz 的综述则从方法谱系层面总结指出,DS 预处理和时空滤波已使其能够像 PS 一样参与参数估计,从而显著扩大空间覆盖范围^[38]。在此基础上,Shamshiri 等利用 Sentinel-1 数据将经双样本 t 检验识别的 DS 与 PS 进行集成,有效提高了可用监测点数量^[39]。Azadnejad 等通过双极化 Sentinel-1 和 TerraSAR-X 数据的极化优化,进一步提升了 PS-InSAR 的可识别点数和相干性水平^[40]。近年,Chen 等又从 SHP 识别流程入手提出顺序式同质像元筛选算法,以进一步提升 DS 处理稳定性和监测点密度^[41]。

方法三: 多方法融合与协同应用

除通过提高影像空间分辨率以及扩展可利用散射体类型外,多方法融合与协同应用也逐渐成为缓解城市建筑群区域 PS 点稀疏问题的重要方向。Budillon 等将 PSI 与 SAR 层析技术同时应用于 Sentinel-1 城市监测,指出在中分辨率开放数据条件下,TomoSAR 可补充 PSI 难以充分表达的多散射体信息,并带来额外测量密度增益^[42]。Zhang 等通过集成 PS-InSAR 与 SBAS-InSAR,利用前者的高精度优势和后者的空间连续性优势,提升了差异沉降区的连续监测能力^[43]。

1.2.3 区域沉降预测研究现状

地面沉降的形成通常与地下水活动、工程扰动、地层与土体条件以及地形与地表环境变化等因素有关，其本质上是多种自然条件与人类活动共同作用下的地表变形响应过程。不同控制因素可通过改变孔隙水压力、附加应力及地层受力条件，引起有效应力重新分配，进而导致土体压缩、固结变形及地层差异响应，最终表现为区域整体沉降或局部不均匀沉降。为便于概括地面沉降的主要影响因素及其形成机理，本文将归纳如图 1.4 所示。




图 1.4 地面沉降形成机理及主要影响因素示意图

方法一：基于机理约束与统计分析的沉降预测方法

沉降预测研究起步较早，早期主要依赖地下水—含水层压缩—地表沉降之间的物理联系，通过地下水—沉降耦合数值模型分析不同开采情景下的沉降响应，并据此推演区域未来沉降趋势^{[44][45]}。在这一阶段，研究重点主要放在沉降形成机理表达、参数敏感性分析以及不同工况下的情景模拟上。为了将离散观测拓展到区域尺度表达，也有研究将 InSAR 形变图、GPS 观测和地质条件结合起来，利用插值方法实现沉降信息的空间化表达^[46]。此外，部分研究基于统计学原理，利用 PS-InSAR 的时序监测结果构建统计时序数学模型，实现沉降时间序列预测^[47]。此类方法以沉降形成的物理机制或已有观测序列规律为基础，能够较好反映沉降过程的机理约束特征，但在复杂场景下对非线性关系和多因素耦合效应的刻画能力仍

相对有限。

方法二：基于机器学习的沉降预测方法

随着时序 InSAR 数据和多源环境因子数据的不断积累，沉降预测研究逐渐由机理和统计方法转向数据驱动建模。相关研究表明，人工神经网络能够较处理好处理沉降过程中的非线性关系，并可用于复杂地质条件下的沉降曲线拟合与预测^{[48][49]}。在此基础上，有学者开始将 InSAR 时间序列分析结果与水文地质数据相结合，用于区域级地面沉降评估和预测^[50]。随后，基于地下水位变化、第四系厚度和建成环境指数等多种因素的 XGBoost 沉降预测模型被提出，使多因素驱动下的区域沉降量预测得到进一步发展^[51]。随后，集成 InSAR 与机器学习的地表形变速率建模方法、基于 Sentinel-1 时间序列和随机森林回归或人工神经网络的沉降建模方法相继出现，此时机器学习方法已能够较稳定地服务于区域尺度的沉降模拟与预测^{[52][53]}。此外，基于 GIS 与人工神经网络的沉降建模研究进一步表明，数据驱动方法已经具备直接模拟区域沉降空间分布的能力^[54]。机器学习方法在处理多因素非线性关系方面具有明显优势，推动了沉降预测由单纯机理推演向区域尺度数据驱动建模转变。

方法三：基于深度学习与时空联合建模的沉降预测方法

在机器学习基础上，深度学习方法的引入推动沉降预测由一般回归分析向时空序列建模发展。相关研究开始将 InSAR 获取的沉降时间序列作为核心输入，并进一步结合地下水变化等驱动因子，利用深度学习方法开展区域沉降建模和未来趋势预测^[55]。为了增强模型对空间异质性的刻画能力，基于 PS-InSAR 的地理加权深度学习模型被提出，使不同位置沉降过程对驱动因子的响应差异能够被纳入统一框架中，但其结果本质上属于插值驱动下的时空预测模拟^[56]。在大尺度城市沉降预测中，有学者基于 K-shape 算法对昆明主城区的沉降时间序列进行聚类，并建立多因子 PSO-BP 模型和 LSTM 模型，用于区域沉降速率预测和单点时间序列沉降波动预测^[57]。随着深度学习方法的发展，相关研究开始更加关注时间依赖性与空间相关性的协同表达，并通过引入组合网络结构、时空耦合模型及环境因子辅助输入，提升区域沉降预测对复杂演化过程的刻画能力，推动沉降预测由单纯时间序列外推逐步发展为时空联合建模^{[58][59]}。近年的研究还进一步围绕时空信息增强、模型结构优化和序列分解展开，例如采用 ICA 辅助的 LSTM 模型以提高复杂形变信号背景下的预测稳定性^[60]，以及结合 GTWR、LSTM 与注意力网络以增强模型对局部时空差异的响应能力^[61]。同时，针对非平稳沉降预测，有学者提出将多组分时序分解与门控循环单元相结合的模型，以提升复杂沉降序列的预测能力^[62]。深度学习与时空联合建模方法已成为当前沉降预测研究的重要发展方向，相关研究已经证明，传统时间序列方法和机器学习方法仅适合外部干扰因素较少且预测时段较短的情形，而当地表沉降存在明显非线性和不规则变化时，神经网络模型的性

能具有十分明显的优势^[63]。

1.2.4 城市区域多源异构大数据研究现状

城市地表沉降的形成受地形水文、地表覆盖、工程建设活动、地下介质条件及人类活动强度等多类因素共同影响,仅依赖单一 InSAR 形变观测难以完整解释沉降空间分异的形成背景。随着遥感观测、全球导航定位、城市基础地理信息采集、互联网位置服务和众源地理信息的发展,城市区域研究对象已由单一地表覆盖识别逐步拓展为多源、多尺度、多语义信息共同参与的复杂空间分析问题^{[64][70][71]}。现有研究表明,城市区域多源异构数据通常包括遥感影像、数字高程模型、道路与水系矢量数据、土地利用数据、建筑轮廓、POI、交通轨迹以及专题环境数据等,其核心价值在于从物理形态、空间结构、功能语义和动态活动等多个维度表征城市空间特征^{[65][67][69]}。因此,如何对多源异构数据进行统一组织、融合表达与合理解释,已成为城市复杂地表过程建模的重要基础问题。

方法一:地理空间大数据的组织与处理方法

早期城市区域多源异构数据研究首先关注地理空间大数据的获取、管理和处理问题。Li 等指出,地理空间大数据在数据规模、数据结构、空间分辨率、语义属性和质量控制方面均具有明显复杂性,传统地理信息处理方法在数据存储、索引、并行计算和空间分析效率方面面临新的挑战^[64]。Goodchild 提出的众源地理信息概念进一步扩展了城市空间数据的来源,使普通用户产生的位置、道路、兴趣点和地理标注信息成为城市研究的重要补充^[70]。Batty 则从智慧城市和城市规划角度指出,大规模传感数据、移动通信数据和城市运行数据正在改变城市空间分析方式,使城市研究逐步从静态空间描述转向动态过程识别^[164]。

方法二:遥感影像与地理空间大数据协同表达方法

随着城市遥感研究的发展,单一遥感影像在城市复杂空间识别中的局限逐渐显现。遥感影像能够较好反映地表覆盖、光谱特征和空间纹理,但难以直接表达城市功能结构、人类活动强度和工程扰动背景^{[65][67]}。为弥补这一不足,越来越多研究开始将遥感影像与 POI、路网、建筑轮廓、土地利用和其他地理空间大数据进行联合分析。Yin 等在综述中指出,遥感数据与地理空间大数据融合能够同时利用地表物理特征和社会经济语义信息,是提升城市土地利用识别精度的重要方向^[65]。Yu 和 Fang 进一步指出,城市遥感研究正在由传统的地表覆盖制图,逐步转向融合空间大数据的城市结构、城市功能和城市过程研究^[67]。在具体应用方面,Zhang 等通过融合多源地理空间数据及其交叉相关关系,实现了城市功能用地识别,表明 POI、路网和遥感特征之间存在较强互补性^[69]。Yuan 等则利用人类移动轨迹与 POI 数据识别城市不同功能区域,说明城市功能空间不仅取决于地表形态,也与人类活动模式密切相关^[72]。Du 等对遥感与地理空间大数据支持下的城市功能区制图研究

进行了系统综述,指出该方向已由单一数据源识别逐步发展为多源协同、语义增强和模型驱动的综合识别阶段^[68]。

方法三:多模态遥感数据融合方法

除遥感影像与地理空间大数据融合外,多模态遥感数据融合也是城市区域多源异构数据研究的重要方向。不同传感器获取的信息具有不同物理含义:光学影像能够反映植被覆盖、地表反射率和土地覆盖变化,SAR 数据能够提供全天时、全天候观测能力并反映地物后向散射特征,LiDAR 和 DEM 则能够表征地形起伏、建筑高度和三维结构信息^{[66][67]}。Li 等对多模态遥感数据融合中的深度学习方法进行了系统总结,指出多模态融合已由传统像素级、特征级和决策级融合,逐步发展为深层特征联合表达和端到端融合建模^[66]。这表明,多模态遥感融合的目标已不再局限于提高单一分类任务精度,而是强调不同物理观测信息之间的互补表达。对于城市地表沉降研究而言,多模态遥感数据能够从不同侧面提供沉降形成背景。DEM 及其派生因子可用于表征地形水文条件,光学影像可用于刻画地表覆盖与植被变化,SAR 时序数据可提供形变观测基础,LiDAR 或建筑轮廓数据则有助于补充城市三维建成环境信息^{[65]-[67]}。

1.2.5 图神经网络研究现状

图神经网络(Graph Neural Network, GNN)是一类面向图结构数据的深度学习模型,其基本思想是将研究对象抽象为由节点和边组成的图结构,并通过节点之间的信息传递、邻域聚合和特征更新学习节点、边或整图的表示,其模型典型设计图如图 1.5 所示。




图 1.5 图神经网络模型典型设计图

与传统卷积神经网络主要面向规则欧氏空间数据不同，图神经网络能够直接处理社交网络、知识图谱、分子结构、交通网络、遥感对象关系及空间邻接单元等非规则结构数据，因此逐渐成为结构化关系建模的重要方法^{[76][79]}。从研究发展过程看，图神经网络大体经历了由早期递归图模型、谱域图卷积、空域邻域聚合，再到注意力增强与复杂关系自适应建模的发展过程^{[79][80]}。

方法一：基于图卷积的图结构特征学习方法

早期图神经网络研究主要关注如何将神经网络推广到图结构数据中。Scarselli 等较早提出图神经网络模型，将图中节点的状态表示定义为其自身属性、邻域节点状态以及边属性共同作用下的结果，并通过迭代更新方式实现图结构信息传播^[80]。随后，Bruna 等从谱图理论出发，将卷积操作推广到图拉普拉斯谱域，使卷积神经网络能够处理不规则图结构数据^[81]。在此基础上，Defferrard 等提出基于切比雪夫多项式近似的快速局部谱滤波方法，在降低计算复杂度的同时实现图结构上的局部卷积操作^[82]。Kipf 和 Welling 进一步提出图卷积网络（Graph Convolutional Network, GCN），通过对邻接矩阵进行归一化处理，并在二阶邻域范围内聚合相邻节点特征，使图卷积模型在节点分类任务中得到广泛应用^[83]。图卷积方法的核心贡献在于将节点特征学习与图结构关系结合起来，使模型不仅能够利用节点自身属性，还能够利用邻域节点的上下文信息。与早期递归图模型相比，GCN 及其相关谱域近似方法在模型形式、训练效率和应用推广方面更加简洁，也推动了图神经网络由理论模型向通用深度学习框架发展^{[79][82][83]}。不过，经典图卷积方法通常依赖预先给定的固定图结构，其邻域传播过程容易受到图规模、邻接矩阵存储和多层传播后表征趋同等问题影响；同时，固定传播权重也使其在处理不同邻域贡献差异时存在一定限制。

方法二：基于邻域采样与归纳表示学习的图神经网络方法

随着图结构数据规模不断扩大，传统图卷积方法在大规模图训练和新节点泛化方面的局限逐渐显现。Hamilton 等提出的 GraphSAGE 方法不再为每个节点直接学习固定嵌入，而是通过采样目标节点的局部邻域，并对邻域节点特征进行聚合来生成节点表示，从而实现归纳式图表示学习^[98]。该方法的关键在于将节点表示学习转化为“邻域采样—特征聚合—节点更新”的过程，使模型能够推广到训练阶段未出现的新节点或新图结构。随后，FastGCN 将图卷积解释为概率测度下的积分变换，并通过重要性采样提高大规模图卷积训练效率^[85]；PinSage 则结合随机游走与图卷积思想，将邻域采样机制应用于大规模推荐系统，进一步证明了采样聚合框架在大规模图学习中的适用性^[86]。邻域采样与归纳学习方法的提出，使图神经网络从依赖完整图结构的转导式学习逐渐拓展到可推广的归纳式学习。GraphSAGE 中的均值聚合、LSTM 聚合和池化聚合等方式，使模型能够在不同邻域规模和不同特征分布条件下学习节点表示^[98]。与传统 GCN 相比，这类方法不要求训练时同时访

问全部节点，因而更适用于大规模图、动态图以及节点持续更新的场景。同时，消息传递神经网络（Message Passing Neural Network, MPNN）将多类图神经网络统一到消息传递与读出函数框架下，也从理论层面概括了邻域信息传播类模型的共同机制^[84]。

方法三：基于注意力机制的图神经网络方法

尽管图卷积和邻域采样方法能够实现邻域信息传播，但许多模型在聚合邻域节点时仍采用平均聚合、归一化聚合或固定传播权重，难以区分不同邻域节点对目标节点表示的差异化贡献。注意力机制最初在序列建模中被广泛采用，其核心思想是根据不同输入之间的相关性自适应分配权重，从而突出关键特征或关键关系^[97]。受此启发，Veličković 等提出图注意力网络（Graph Attention Network, GAT），将自注意力机制引入图结构学习，使模型能够根据目标节点与邻域节点之间的特征关系动态计算注意力权重^[99]。在此基础上，GaAN 进一步引入门控机制调节不同注意力头的重要性，以增强多头注意力机制在大规模图和时空图学习中的表达能力^[97]。图注意力方法的重要意义在于，其不再将邻域节点视为等权或固定权重对象，而是根据节点特征及其局部关系自适应确定信息传播强度。GAT 通过 masked self-attention 在节点邻域内计算注意力系数，并利用多头注意力机制从多个特征子空间学习节点间关系，从而提升表示学习的稳定性和表达能力^[97]。与 GCN 等基于固定邻接归一化的传播方式相比，图注意力模型更适合处理邻域关系非均质、节点贡献差异明显和图结构复杂的任务^[99]。Graph Transformer Networks 则进一步将注意力思想扩展到图结构生成和多跳关系学习中，使模型能够在端到端训练过程中学习更有用的组合关系和图结构表达^[88]。

1.2.6 InSAR 离散形变场连续化研究现状

时序 InSAR 技术能够高精度获取地表或建筑物的形变信息，但其监测结果通常以 PS 点、DS 点或网格化像元的形式离散分布^{[89][90]}，难以直接满足建筑变形风险精细化排查的需求。所谓 InSAR 离散形变场连续化，是指在保持离散观测结果空间特征的基础上，通过空间插值、数据融合或数据驱动重建等方法，将离散形变观测结果进一步转换为连续表达的形变场，以实现由遥感观测结果向区域沉降表征或结构变形判读的拓展^[91]。因此，围绕 InSAR 离散形变观测点开展连续化表达与空间重建，逐渐成为形变监测研究中的一个重要发展方向。

方法一：基于地统计插值的离散形变场重建方法

从研究发展过程来看，较早的相关工作主要集中于 InSAR 形变场缺失值填补与局部空间插值。其中，克里金方法属于基于空间自相关结构的地统计插值方法，能够通过变异函数对空间相关性进行建模，因此较早被用于 InSAR 离散形变场的连续化重建。针对地震形变场中由于失相干造成的空洞和缺测问题，研究者曾采用

普通克里金和泛克里金对 InSAR 形变图中的缺失区域进行局部插值, 并通过误差评估证明地统计方法能够较有效地恢复形变场的空间连续性, 其中泛克里金在趋势存在时通常优于普通克里金^[92]。这一阶段的研究表明, InSAR 形变数据的连续化需求最初主要源于形变场完整性恢复和后续反演分析需要, 也奠定了地统计插值在 InSAR 形变场重建中的应用基础。在此基础上, 地统计方法也逐步由单纯缺失值填补拓展到区域尺度沉降场重建。除普通克里金和泛克里金外, 考虑辅助变量的克里金扩展形式被进一步用于沉降场重建。已有研究将 InSAR 形变图作为外部漂移信息, 并联合 GPS 观测和可压缩土层厚度等地质变量进行克里金估计, 从而在保持 InSAR 空间分布特征的同时, 提高了沉降场重建的区域解释能力^[46]。地统计插值方法强调通过变异函数和辅助变量对空间结构进行建模, 在区域尺度地面沉降研究中表现出较强的适用性, 但其结果对变异函数和趋势项设定较为敏感, 在城市建筑群这种沉降机理复杂、局部异质性显著的场景中, 仍存在建模依赖性强和参数确定困难的问题^{[46][92]}。

方法二: 基于确定性插值的连续形变场构建方法

随着 InSAR 由事件性形变监测逐步扩展到长期沉降与基础设施变形监测, 确定性插值方法开始得到更广泛应用。其中, 反距离加权法 (Inverse Distance Weighting, IDW) 是一类基于距离衰减权重的确定性插值方法, 由于原理简单、实现方便、计算效率较高, 在 InSAR 连续变形场构建中应用较早且较为广泛。例如, 在机场长期形变研究中, 已有工作利用空间域 IDW 插值协调不同轨道和不同平台影像获取的形变信息, 并结合时间域三次样条插值恢复连续累计形变过程^[93]; 在建筑物脆弱性评估研究中, 也有工作将 InSAR 形变速率通过 IDW 插值映射到高分辨率鱼网单元, 以支撑建筑风险空间分级^[94]。在此基础上, 面向铁路等线性基础设施监测的研究进一步通过截断窗口的 IDW 插值减少 PS 点地理编码误差对连续变形表达的影响, 说明 IDW 方法已由早期的简单空间填值逐步发展到面向具体工程场景的改进应用^[95]。除 IDW 外, 自然邻域插值和样条插值等方法也逐渐被引入 InSAR 连续形变场构建。自然邻域插值对不规则散点的适应性较好, 且计算效率较高, 近年来被用于多源多波段 InSAR 形变数据的统一格网化表达^[96]; 样条插值则更多用于时间维或时空联合平滑, 在多时相 InSAR 长期形变分析中常与空间域插值配合使用, 以恢复更加连续的累计沉降过程^[93]。这表明确定性插值方法的研究重点, 已由单纯的空间补值逐渐转向服务于多源数据统一表达与长时间序列形变重建。

方法三: 基于多源观测融合连续形变场重建方法

进一步地, 随着 InSAR 与地面观测的协同应用不断深化, 连续形变场构建开始由单纯空间插值发展到多源数据融合。早期研究已尝试将 GPS 观测与 PS-InSAR 紧密结合, 用于垂向地表运动检测, 以增强 InSAR 结果的参考框架稳定性和区域

可靠性^[104]。随后,基于协方差描述的 InSAR 与 GNSS 融合方法被提出,该类方法通过同时考虑两类观测数据的误差谱特征,实现了不同空间频率形变信息的联合保留,从而使融合后的连续变形场兼具 InSAR 的高空间覆盖能力与 GNSS 的高精度优势^[105]。

1.3 已有研究不足

根据国内外研究现状可知,星载 InSAR 技术、多源异构数据融合、图神经网络建模以及离散形变场连续化等研究,已为城市地表沉降监测与建筑群风险筛查提供了重要技术基础。然而,面向城市尺度风险区域快速识别与单栋建筑精细化评估需求,现有研究仍存在以下不足。

(1) 城市复杂建筑环境下 InSAR 离散沉降观测结果的可靠性仍需提高。PS-InSAR 主要依赖长期相位稳定的永久散射体获取形变信息,但在低层建筑密集区、老旧街区及屋面结构简单区域,PS 点常表现出数量不足、分布不均和局部缺失等问题。同时,强散射体旁瓣效应可能导致伪散射体和虚假 PS 点,高层建筑上部结构还可能受温度变化影响,使 PSI 结果中混合结构热变形与地表沉降信息。若直接将此类结果作为后续预测或风险分析基础,容易降低沉降标签的真实性和稳定性。因此,复杂建筑环境下 InSAR 离散沉降观测结果的可靠性仍需进一步提高。

(2) 现有沉降预测研究极少涉及对沉降值缺失区域的空间外推。已有沉降预测研究多围绕已有监测点或 InSAR 时间序列开展趋势外推,常采用机理模型、统计分析、机器学习或深度学习方法建立沉降观测与影响因素之间的映射关系。此类方法能够反映一定的沉降演化规律,但多数仍以已有观测点为核心,对 PS 点缺失区域、低相干区域及观测空白区的沉降空间推断能力不足。城市沉降又受地形水文、地表覆盖、工程扰动和土体物性等多源因素共同影响,并具有空间邻域相关性和局部异质性,因此仍需发展能够融合多源信息并表达空间关系的沉降预测方法。

(3) 建筑尺度下高分辨率连续沉降场构建易受 PS 点非均匀分布影响。由 InSAR 离散观测结果向单栋建筑风险评估拓展时,需要将离散 PS 点形变信息转换为建筑尺度连续沉降场。现有研究多采用 IDW、克里金等传统插值方法,但城市建筑群区域 PS 点分布常具有明显非均匀性,部分建筑上 PS 点高度聚集,而相邻建筑或地面区域可能缺乏有效观测点。传统插值方法主要依据距离或整体空间自相关关系分配权重,难以充分抑制局部 PS 点聚集对估计结果的影响,进而影响建筑沉降曲线、横倾变形和风险指标提取的准确性。因此,建筑尺度连续沉降场构建仍需考虑 PS 点空间分布特征和数据自相关性。

1.4 本文研究内容

基于上述研究不足,本文基于国家自然科学基金项目《基于星载 InSAR 变形测量和信息共享平台数据的大跨度桥梁结构状态评估方法》(52278306)、湖南省重点研发计划项目《基于星载 InSAR 技术的城市桥梁群多灾害条件下状态评估与预警研究》(2022SK2096)、湖南省自然科学基金项目《基于天-空-地一体化的基础设施结构安全监测技术研究》(2023JJ70003)、湖南省水利厅水利科技项目《基于“天-空-地”一体化的渡槽结构损伤检测及状态评估研究》(XSKJ2023059-31)、湖南省应急管理厅科技项目(yjtkjxm_202406)开展相关研究。系统开展了面向城市建筑群安全风险排查的星载 InSAR 离散沉降观测优化、区域尺度沉降预测以及建筑尺度连续沉降场精细化构建与风险评估方法研究。这些研究的目的在于提高低层建筑密集区沉降观测结果的可靠性,增强城市尺度沉降异常区识别与空间判别能力,并为单栋建筑精细化风险评估提供更为准确的连续沉降场支撑。主要内容如图 1.6 所示。

(1) 针对 InSAR 离散沉降观测结果可靠性不足的问题,提出离散沉降监督信息优化方法。具体而言,本文首先针对低层建筑密集区 Sentinel-1 PSI 结果中易出现的伪散射体和虚假 PS 点问题,引入基于旁瓣效应剔除的 PSI 处理流程,并结合 Sentinel-1 与 COSMO-SkyMed 两类卫星影像开展交叉验证,以提高离散沉降观测结果的可靠性。随后,考虑建筑上部结构温度效应对 PSI 形变观测的影响,对显著温度相关形变点进行识别与剔除,并以筛选后的累计观测值作为沉降监督标签。在此基础上,构建多源沉降驱动因子,并通过相关性分析与共线性筛查形成模型有效输入,为后续区域沉降预测提供数据基础。

(2) 针对 PS 点缺失区域沉降值难以获取的问题,提出图神经网络沉降预测模型。具体而言,本文以优化后的 Sentinel-1 PSI 累计沉降观测值作为监督信息,以多源沉降驱动因子作为模型输入,将局部窗口像元组织为图结构,通过节点特征和边连接关系表达空间邻域信息。在模型结构上,构建融合 GraphSAGE 与多头图注意力机制的图神经网络沉降预测模型,利用 GraphSAGE 聚合局部邻域背景信息,并通过图注意力机制增强关键邻域关系表达能力。随后,围绕驱动因子筛查、网络深度和注意力机制开展消融实验与性能评估,并结合 COSMO-SkyMed PSI 结果和现场踏勘情况验证预测结果,实现城市尺度沉降异常区识别。

(3) 针对 PS 点非均匀分布导致的连续沉降场偏差问题,提出建筑尺度连续沉降场构建与风险评估方法。具体而言,本文在模型预测识别出的典型沉降风险区域内,基于高分辨率 COSMO-SkyMed PSI 结果获取建筑周边离散沉降信息,并在剔除显著温度相关形变点后,提出考虑数据自相关性的反距离加权插值方法。该方法在传统距离衰减权重基础上引入样本聚集修正思想,以减弱局部 PS 点聚集对待估位置

沉降估计的不利影响，构建适用于建筑尺度分析的连续沉降场。随后，结合传统 IDW 与普通克里金方法开展对比分析，并进一步提取沉降曲线、横倾变形和沉降增量等指标，建立单栋建筑综合风险评估方法。




图 1.6 研究内容

第2章 星载 InSAR 技术基本原理

2.1 引言

星载 InSAR 技术获取的建筑与地表形变结果，本质上来源于 SAR 影像相位信息在多时相条件下的干涉测量与参数反演过程。在城市建筑群场景下，沉降预测、连续沉降场构建及建筑变形风险评估均以星载 InSAR 结果的合理解释为前提。为此，需要明确 SAR 成像几何、干涉相位组成、LOS 向形变的物理含义，以及建筑场景下 PSI 结果的解析方法。尤其是在 PS 点选取、温度相关变形识别、参考点选取及形变分解等环节，都会直接影响后续沉降值提取与工程判读的可靠性。基于此，本章围绕星载 InSAR 技术的基本原理展开论述，主要介绍 SAR 卫星系统、星载 InSAR 技术基本原理以及城市建筑群场景下的 PSI 变形监测方法，为后续离散沉降信息提取、沉降值解释和建筑风险分析提供方法依据。

2.2 SAR 卫星概述

星载 SAR 平台是获取 SAR 遥感影像并开展 InSAR 观测的主要数据来源，不同星载 SAR 平台在轨道高度、重访周期、工作波段、成像模式和空间分辨率等方面存在差异，这些参数共同决定了雷达影像的观测几何、时空分辨能力以及相干性保持条件，并进一步影响地表形变监测的适用尺度与监测效果。

按照工作波长划分，用于地表沉降监测的星载 SAR 系统主要包括 X 波段、C 波段和 L 波段三类。X 波段典型波长约为 3cm，空间分辨率较高，对建筑边缘、角隅及屋顶构件等局部散射特征更为敏感，适用于建筑物及基础设施的精细形变监测。C 波段典型波长约为 5.6cm，在空间覆盖能力、时间连续性和数据可获取性之间具有较好平衡，因此在区域尺度地表沉降监测中应用最为广泛。L 波段典型波长约为 23cm，对植被和复杂地表覆盖条件具有较强穿透能力，在植被覆盖较高或相干性保持较困难的区域具有一定优势，但在高密度城市建筑场景中的应用相对少于 X 波段和 C 波段。不同波段数据并不存在绝对优劣，其适用性主要取决于研究尺度、监测目标和数据获取条件。

除工作波段外，成像模式也是影响 InSAR 应用效果的重要因素。常见的星载 SAR 成像模式主要包括聚束模式、条带模式和扫描模式，部分卫星还提供面向海洋观测的波模式。不同成像模式在作用机制和适用场景上存在明显差异。如图 2.1 所示，聚束模式通过在目标区域内持续调整天线波束指向，实现对局部区域的持续照射，因此能够获得较高的空间分辨率，但覆盖范围相对较小，更适用于建筑物、

桥梁及局部重点区域的精细化形变监测；条带模式通过天线波束沿轨道方向连续成像，在覆盖范围和空间分辨率之间取得较好平衡，适用于一般区域目标的常规观测；扫描模式则通过多个子波束周期性切换扩大成像幅宽，能够显著提高区域覆盖能力，但空间分辨率相对较低，更适用于大范围地表形变监测与区域连续观测。波模式主要面向海面状态监测，通常不作为城市地表沉降监测的主要数据来源。因此，在 InSAR 实际应用中，往往需要根据研究尺度和监测目标合理选择成像模式。对于城市尺度地表沉降监测与连续预测，更需要兼顾覆盖范围与时间连续性；而对于典型风险区域或单体建筑周边的精细化形变分析，则更强调较高的空间分辨能力。




图 2.1 主要 SAR 成像模式

结合本文研究目标，区域尺度沉降监测与预测主要采用 Sentinel-1 数据，典型风险区域及单栋建筑周边的精细化变形分析主要采用 COSMO-SkyMed 数据。两类星载 SAR 数据的主要平台特征及本文所采用参数如表 2.1 所示，卫星示意图 2.2。




图 2.2 Sentinel-1 与 COSMO-SkyMed 卫星图

表 2.1 两类星载 SAR 数据的主要参数

项目	Sentinel-1	COSMO-SkyMed
研制/运行机构	欧洲航天局 (ESA)	意大利航天局 (ASI) 与意大利国防部 (MoD)

项目	Sentinel-1	COSMO-SkyMed
工作波段	C 波段	X 波段
波长	5.5cm	3.1cm
主要成像模式	Stripmap、EW、IW、Wave	Spotlight、Stripmap、ScanSAR
本文采用极化方式	VV	VV
本文采用成像模式	IW	HIMAGE
空间分辨率	5m×20m	3m×3m
轨道方向	升轨	升轨
入射角	42.03°	23.52°
方位角	-9.36°	-12.25°

2.3 星载 InSAR 对地形变观测技术

2.3.1 星载 InSAR 技术基本原理

星载合成孔径雷达干涉测量（InSAR）是在合成孔径雷达成像基础上发展起来的一种高精度对地观测技术，其核心在于利用不同观测时刻或不同观测轨道获取的复数 SAR 影像之间的相位差，提取目标区域的高程或形变信息^[17]。SAR 属于主动式微波遥感系统，卫星平台在飞行过程中向地表发射微波脉冲，并接收目标后向散射回波，从而获取地物信息^[16]。与光学遥感不同，SAR 不依赖太阳辐射，因而具备全天时、全天候观测能力。由于星载平台沿轨道运动，系统可利用平台飞行过程中连续接收的回波信号，通过距离向脉冲压缩和方位向合成孔径处理，形成具有较高空间分辨率的复数影像^[19]。在该影像中，每个像元同时包含幅度信息和相位信息，其中幅度反映目标后向散射强度，相位则与雷达到目标之间的传播距离密切相关，是 InSAR 开展干涉测量的基础^[18]。

对于某一目标点 P ，其对应回波相位如式（2.1）所示：

$$\varphi = -\frac{4\pi}{\lambda} R + \varphi_0 \quad (2.1)$$

式中， λ 为雷达波长， R 为卫星到目标点的斜距， φ_0 为系统常数项。

由式（2.1）可知，目标回波相位与雷达至目标之间的传播距离直接相关，因此当传播路径发生微小变化时，回波相位也会产生相应变化；这种相位对距离变化

的敏感程度与雷达波长密切相关。正因如此，SAR 相位信息能够为高精度地表高程反演与微小形变探测提供基础。InSAR 的基本原理在于，对同一区域在不同观测时刻或不同轨道位置获取的两景复数 SAR 影像进行干涉处理，利用同一目标点在两景影像中的相位差测量雷达传播路径差，并进一步结合成像几何关系反演目标区域的地形起伏或形变信息。在此过程中，两景影像之间需保持较好的相干性，否则干涉相位将难以稳定获取^[19]。

如图 2.3 所示，图中 S_1 和 S_2 分别表示两次卫星过境的空间位置， P 和 P' 分别表示地表观测点位置变化前后的空间位置。 $B_{\perp}$ 为 SAR 卫星与观测点间的 LOS 向距离，用 SP 表示。 B 为卫星两次过境时轻微轨道差异引起的空间基线，可将其分解为垂直于雷达视线方向的垂直基线 $B_{\perp}$ 和平行于视线方向的平行基线 $B_{\parallel}$ ，计算公式如式 (2.2) 和 (2.3) 所示。 θ 为电磁波的入射角， α 为空间基线与水平方向的夹角。

$$B_{\parallel} = B \sin(\theta - \alpha) \quad (2.2)$$

$$B_{\perp} = B \cos(\theta - \alpha) \quad (2.3)$$

设目标点在两次观测中的相位分别为 φ_1 和 φ_2 ，则干涉相位 $\Delta\varphi$ 的表达式如式 (2.4) 所示：

$$\Delta\varphi = \varphi_1 - \varphi_2 = -\frac{4\pi}{\lambda}(SP - SP') \quad (2.4)$$




图 2.3 InSAR 观测原理几何示意图

其中，垂直基线 $B_{\perp}$ 决定了干涉相位对地形起伏的敏感程度，是高程反演和形变监测中的重要几何参数^[17]。需要指出的是，实际获取的干涉相位并不是单一物理量，而是多个相位分量叠加的结果。在理想条件下，干涉相位可表示为：

$$\varphi_{int} = \varphi_{flat} + \varphi_{topo} + \varphi_{def} + \varphi_{atm} + \varphi_{orb} + \varphi_{noise} \quad (2.5)$$

式中， φ_{flat} 为平地相位， φ_{topo} 为地形相位， φ_{def} 为形变相位， φ_{atm} 为大气延迟

误差项, φ_{orb} 为轨道误差项, φ_{noise} 为热噪声及失相干等随机误差项。

由式 (2.5) 可以发现, InSAR 处理的关键在于从复合干涉相位中尽可能分离出与形变相关的有效信息。在实际处理过程中, 干涉相位中的非形变分量并不是一次性同时消除, 而是通过不同步骤逐步削弱或分离。平地相位 φ_{flat} 主要由成像几何造成, 可根据卫星精密轨道参数和观测几何关系进行模拟, 并在干涉图生成后直接予以去除。地形相位 φ_{topo} 通常借助外部数字高程模型进行模拟, 再从原始干涉相位中扣除, 从而得到差分干涉相位。对于轨道误差 φ_{orb} , 其空间分布一般表现为长波趋势, 可通过精密定轨数据校正, 或在后续处理中采用多项式拟合等方法加以削弱。大气延迟误差 φ_{atm} 具有较强的空间相关性和时间随机性, 在常规差分干涉中较难完全去除, 通常需要依赖多时相观测, 通过时间域和空间域联合滤波进行分离。至于热噪声、失相干及相位解缠误差等随机误差 φ_{noise} , 则主要通过提高影像配准精度、优化干涉对选择、控制时空基线以及筛选高相干测点等方式减弱其影响。经过上述处理后, 干涉相位中与目标真实形变相关的相位分量才能被较为可靠地提取出来。

在将干涉相位中的形变相位分量分离以后, 可通过式 (2.6) 进一步转化为目标沿雷达视线方向的形变 d_{LOS} :

$$d_{LOS} = -\frac{\lambda}{4\pi} \varphi_{def} \quad (2.6)$$

此外, 由于雷达观测相位以 2π 为周期, 实际获取的干涉相位通常表现为缠绕相位, 其取值范围被限制在 $(-\pi, \pi]$ 内, 真实相位与缠绕相位之间相差整数倍 2π , 即观测相位仅为真实相位对 2π 的模值, 进而导致整数周期信息丢失, 即整周期模糊问题, 因此必须要通过相位解缠方法恢复这些丢失的整数周期数。主要的相位解缠方法有枝切法^[106]、最小二乘法^[107]、最小费用流法^[108]、基于区域生长法^[109], 以及三维时序解缠方法等^[110]。

在长期地表形变监测中, 单对 SAR 影像的差分干涉处理难以充分抑制时空失相干、大气延迟及轨道误差等因素的影响, 因此通常需要采用多时相 InSAR 方法开展时序形变反演。现有多时相 InSAR 方法主要包括 PS-InSAR、SBAS-InSAR 和 DS-InSAR 等类型。其中, PS-InSAR 主要利用长时间序列中后向散射强度稳定、相位一致性较好的永久散射体点进行形变估计, 适用于城市建筑物、道路、桥梁等人工目标较丰富的区域, 能够获得较高精度的离散点状形变结果^[21]。SBAS-InSAR 则通过构建短空间基线和短时间基线干涉图网络, 降低失相干影响, 更适用于缓慢形变区域的面状形变监测, 但其结果通常更强调区域尺度形变场的连续表达^[22]。DS-InSAR 进一步将具有统计同质性的分布式散射体纳入处理框架, 可在非城市区或低相干区域提高有效测点密度, 但其处理过程对同质像元识别、协方差估计和相位优化等步骤要求较高^[24]。相较而言, 本文研究对象为城市建筑群区域, 稳定人工

散射体相对丰富，且后续沉降预测模型需要以可靠离散形变点作为监督信息，因此本文主要采用 PS-InSAR 获取离散沉降观测结果，并在 2.3.2 节进一步说明其检测原理。

2.3.2 PS-InSAR 技术检测原理

永久散射体干涉测量（Persistent Scatterer Interferometric Synthetic Aperture Radar, PS-InSAR）是一种典型的时序 InSAR 方法，其核心思想是在长时间序列 SAR 影像中识别出后向散射特性稳定、相位在时间维上保持较高一致性的永久散射体（Persistent Scatterers, PS），并利用这些稳定散射体的相位信息实现地表微小形变的高精度反演^[21]。相较于传统双景 D-InSAR 方法容易受到时空失相干、大气延迟及轨道误差影响的问题，PS-InSAR 通过多时相影像联合建模与参数估计，能够有效提高形变监测结果的稳定性与精度，其计算流程如图 2.4 所示。




图 2.4 PS-InSAR 计算流程图

PS-InSAR 的处理通常采用单主影像策略构建干涉图网络。设研究区域共获取 N 景 SAR 影像，首先需要从全部影像中选取 1 景作为主影像，其余 $N-1$ 景影像作为辅影像分别与主影像配准，进而形成 $N-1$ 组差分干涉对。主影像的选取直接关系到干涉对质量及后续参数反演的稳定性。一般而言，主影像应同时满足时间基线、空间基线以及多普勒质心频率基线尽可能小的原则^[111]，以提高干涉图整体相干性并减小后续相位解算误差。

在完成主影像选择并构建单主影像干涉网络后，PS-InSAR 的具体处理流程可进一步划分为影像配准、外部 DEM 引入、PS 点综合选取以及 PS 点形变反演四个关键步骤：

（1）影像配准

影像配准的目的是将各景辅影像精确统一到主影像的坐标框架下,从而保证同一地面目标在不同 SAR 影像中的像素位置保持一致,为后续干涉处理和相位分析提供基础。常用的 SAR 影像配准方法包括相干系数法、最大干涉频谱法、相位差影像平均波动函数法以及最小二乘法等^[28]。一般而言,影像配准通常包括同名点搜索、几何映射关系建立、坐标变换与重采样以及配准精度评价等环节。首先,在主影像上均匀选取若干控制点,并在辅影像中以预测同名点位置为中心设置匹配窗口。随后,在窗口移动过程中计算匹配指标,通过最优匹配准则确定最佳同名点位置。为提高同名点检索的稳定性,通常先采用较小窗口完成初始匹配,再逐步扩大匹配窗口重复检索,直至匹配结果趋于稳定。其次,在得到足够数量的同名控制点后,可利用多项式模型建立主辅影像之间的几何映射关系,并通过坐标变换与重采样将辅影像统一到主影像坐标系中。最后,在配准完成后,还需通过相干系数对配准质量进行评价,以确保配准精度达到亚像素水平,从而减小由像元错位引起的附加相位误差。相关研究表明,当配准精度优于 0.1 个像素时,通常能够较为准确地获取干涉相位信息^[112]。因此,高精度影像配准是保证 PS-InSAR 结果可靠性的前提条件之一。

(2) 外部 DEM 引入

在 PS-InSAR 处理中,研究目标主要是提取地表或建筑目标的形变信息,因此必须尽可能剔除由地形起伏引起的地形相位。为此,需要引入外部数字高程模型 (DEM) 对高程相位进行模拟与去除。现有研究一般采用 ShuttleRadarTopographyMissionGlobal1arc-second (SRTMGL1) DEM 数据,其空间分辨率约为 30m。SRTMDEM 由 NASA 与 NGA 联合获取,具有覆盖范围广、分辨率统一和高程精度较稳定等特点,已被广泛应用于地形分析、地表形变监测和星载 InSAR 数据处理中^[113]。在具体处理过程中,需要将外部 DEM 从地理坐标系转换至 SAR 雷达坐标系,并结合主辅影像轨道参数和成像几何关系,将 DEM 高程信息编码为对应的地形相位,随后将模拟得到的地形相位从原始干涉相位中扣除,以获得去除地形效应后的差分干涉相位。

(3) PS 点选取

在完成影像配准和地形相位去除后,需要从全部像元中筛选出时序稳定性高、相位一致性好且受旁瓣效应干扰较小的候选 PS 点。考虑到单一指标难以同时兼顾幅度稳定性、相位稳定性和伪散射体剔除效果,本文采用振幅离差^[21]、相干系数^[114]、平均强度和峰值旁瓣比^[115]四个指标进行综合选点。

振幅离差用于衡量像元在时间维上的幅度稳定性,其值越小表示该像元散射特性越稳定。振幅离差指数常以 0.25 作为候选 PS 点初筛的经验参考值;但仅依赖振幅离差阈值并不能完成全部 PS 点识别,通常还需结合相位稳定性等信息进行进一步筛选。其表达式为:

$$D_{A,i} = \frac{\sigma_{A,i}}{\mu_{A,i}} \quad (2.7)$$

式中, $D_{A,i}$ 为第 i 个像元的振幅离差指数, $\sigma_{A,i}$ 为多时相振幅标准差, $\mu_{A,i}$ 为多时相振幅均值。

相干系数用于描述像元在多干涉对中的相位一致性,其取值通常介于 0 和 1 之间,值越接近 1 表示相位一致性越好、观测质量越高。需要指出的是,相干系数并不存在绝对统一的固定阈值,其选取通常与数据类型、场景特征及处理策略有关。已有研究表明,在 PSI 处理中,固定阈值常取 0.6~0.7 作为经验参考,其中 0.7 是较常见的候选稳定点筛选标准^[116]。其数学表达式为:

$$\gamma = \frac{\left| \sum_{i=1}^m \sum_{j=1}^n M(i,j) \cdot S^*(i,j) \right|}{\sqrt{\sum_{i=1}^m \sum_{j=1}^n |M(i,j)|^2 \cdot \sum_{i=1}^m \sum_{j=1}^n |S^*(i,j)|^2}} \quad (2.8)$$

式中, M 为主影像的复数信息, S 为副影像的复数信息, m 和 n 代表计算窗口的大小, $*$ 表示复数的共轭算子。

平均强度的表达式如式 (2.9) 所示,用于表征像元在时间序列上的总体后向散射能力,其值越高则该像元受主导散射体控制更明显。

$$\bar{I}_i = \frac{1}{N} \sum_{k=1}^N I_i^k \quad (2.9)$$

式中, N 为影像总数, I_i^k 为第 i 个像元在第 k 景影像中的强度值。

PSLR (峰值旁瓣比) 能反映强散射体成像时旁瓣泄漏的严重程度,其绝对值越大,说明旁瓣抑制效果越好,像元受旁瓣污染的可能性越低;反之,则说明该像元更可能受到邻近强散射体能量泄漏的影响,从而形成伪散射体或虚假 PS 点。PSLR 与系统响应特性、加窗方式及成像处理策略密切相关。已有研究表明,未加权条件下理论 PSLR 常约为 -13.26dB^[117]。采用强度形式定义时,PSLR 的表达式如下:

$$PSLR_i = 10 \log_{10} \left(\frac{I_{side,i}^{\max}}{I_{main,i}^{\max}} \right) \quad (2.10)$$

式中, $PSLR_i$ 为第 i 个候选点的峰值旁瓣比, $I_{side,i}^{\max}$ 为该点邻域内最强旁瓣峰值强度, $I_{main,i}^{\max}$ 为对应主瓣峰值强度。

(4) PS 点形变反演

在 2.3.1 节中,干涉相位已表示为平地相位、地形相位、形变相位、大气延迟相位、轨道误差相位和噪声相位等多项分量的叠加。对于 PS-InSAR 处理而言,精密轨道校正和去平地处理可削弱平地相位影响,外部 DEM 可用于模拟并扣除主要

地形相位，轨道误差则可通过精密轨道数据和长波趋势校正进一步减弱。因此，进入 PS 点参数反演阶段的并非原始干涉相位，而是经过预处理后的残余相位。与式（2.5）相比，该残余相位主要由形变相位、DEM 残差相位、大气延迟相位和噪声相位组成，可表示为：

$$\varphi_i^k = \varphi_{\text{def},i}^k + \varphi_{\Delta h,i}^k + \varphi_{\text{atm},i}^k + \varphi_{\text{noise},i}^k \quad (2.11)$$

式中， φ_i^k 为第 i 个 PS 点在第 k 个干涉对中的残余相位； $\varphi_{\text{def},i}^k$ 为形变相位； $\varphi_{\Delta h,i}^k$ 为 DEM 残差相位； $\varphi_{\text{atm},i}^k$ 和 $\varphi_{\text{noise},i}^k$ 分别为大气延迟相位和噪声相位。

根据式（2.6），形变相位与雷达视线方向形变之间满足负比例关系。对于城市建筑场景中的 PS 点，其形变项不仅可能包含长期沉降或稳定形变趋势，还可能叠加由温度变化引起的短周期响应。尤其是附着于建筑物屋顶、立面和金属构件上的永久散射体，容易受到结构热胀冷缩影响，使残余相位中同时包含长期形变分量和温度相关形变分量^{[118][119]}。若将第 i 个 PS 点在第 k 个干涉对对应时刻的 LOS 向形变分解为长期线性形变项和温度驱动的非线性响应项，则可写为：

$$d_i(t_k) = v_i t_k + g_i(T_k) \quad (2.12)$$

式中，第一项反映长期形变趋势，第二项反映温度变化引起的非线性形变响应。相应地，形变相位可表示为：

$$\varphi_{\text{def},i}^k = -\frac{4\pi}{\lambda} [v_i t_k + g_i(T_k)] \quad (2.13)$$

同时，由于外部 DEM 精度有限，地形相位去除后仍可能存在由 DEM 残差引起的剩余地形相位，其表达式可写为：

$$\varphi_{\Delta h,i}^k = \frac{4\pi}{\lambda} \frac{B_{\perp}^k}{R_i^k \sin \theta^k} \Delta h_i \quad (2.14)$$

将形变相位、DEM 残差相位、大气延迟相位和噪声相位代入残余相位表达式，可得到考虑温度项后的第 i 个 PS 点在第 k 景影像中的残余相位模型：

$$\varphi_i^k = -\frac{4\pi}{\lambda} [v_i t_k + g_i(T_k)] + \frac{4\pi}{\lambda} \frac{B_{\perp}^k}{R_i^k \sin \theta^k} \Delta h_i + \varphi_{\text{atm},i}^k + \varphi_{\text{noise},i}^k \quad (2.15)$$

式中， v_i 为第 i 个 PS 点的线性形变速率， t_k 为第 k 景影像相对于参考时刻的时间基线， $g_i(T_k)$ 为温度驱动的非线性响应函数， T_k 为对应时刻的温度观测值， Δh_i 为 DEM 残差， $\varphi_{\text{atm},i}^k$ 为大气延迟相位， $\varphi_{\text{noise},i}^k$ 为噪声相位。

由式（2.15）可知，残余相位中的形变项与 LOS 向形变具有直接对应关系。因此，第 i 个 PS 点的 LOS 向形变时间序列可表示为：

$$d_i(t_k) = v_i t_k + g_i(T_k) \quad (2.16)$$

式中，第一项反映长期形变趋势，第二项反映温度变化引起的非线性形变响应。

当温度观测序列与 PSI 相位时间序列联合使用时, 可通过对 v_i 和 Δh_i 及温度响应参数的联合估计, 更有效地将长期沉降与季节性温度形变区分开来, 从而提高形变反演精度。

在参数估计过程中, 通常先基于多时相 PS 点网络对线性形变速率与 DEM 残差进行初步估计, 再结合时间高通与空间低通等策略分离大气延迟相位, 最后利用温度数据对温度相关相位分量进行建模与估计。为了保证反演结果的稳定性, 需在高可靠度参考点约束下开展网络平差与时序求解。若某些 PS 点的温度响应显著, 则其时序相位中的周期性波动可通过温度项得到合理解释; 而对于温度相关性较弱的地表或低层建筑目标, 其温度项贡献通常较小, 反演结果将更多反映真实形变信息。

2.4 PSI 变形分解原理

2.4.1 PS-InSAR 结果 LOS 向变形组成原理

PSI 技术直接获取的是目标沿雷达视线方向 (Line of Sight, LOS) 的形变分量, 而城市地表沉降监测中更关注的是能够直接表征地表抬升与沉降过程的垂直向形变信息。根据卫星空间观测几何关系, LOS 向形变本质上是监测点在垂直方向、北向和东向形变分量在雷达视线方向上的综合投影。如图 2.5 所示, D_v 、 D_n 和 D_e 分别表示监测点在垂直方向、北向和东向的形变分量 θ 为雷达入射角, α 为卫星航向角, 则 LOS 向形变可表示为:

$$D_{LOS} = D_v \cos \theta + D_n \sin \theta \sin \alpha - D_e \sin \theta \cos \alpha \quad (2.17)$$

由式 (2.17) 可知, 单轨 PSI 观测本质上只提供一个投影量, 因此在无附加条件约束时, 无法直接得到垂直向形变。根据约束来源的不同, LOS 向变形的主流分解方法为基于 GNSS 约束的方法、基于升降轨观测的方法以及忽视水平向形变的传统近似方法。




图 2.5 卫星 LOS 观测几何与形变分解示意图

2.4.2 基于 GNSS 的 LOS 向垂直变形提取

GNSS 能够在东-北-天 (East-North-Up, ENU) 局部坐标系下直接提供监测点的三维形变信息, 其中东向、北向和竖向分别对应 ENU 坐标系的三个正方向; 西向和南向则分别可视为东向和北向的负方向, 因此通常不再单独列为独立分量。相比之下, PSI 具有测点密度高、空间覆盖范围广的优势。将 GNSS 与 PSI 联合使用, 可利用 GNSS 提供的水平形变约束削弱 LOS 向观测中的水平分量混叠影响, 从而提高垂直向形变提取的可靠性^[104]。

基于同名点处已知 GNSS 提供的东向和北向形变, 竖向形变可由式 (2.18) 直接改写为:

$$D_v = \frac{D_{LOS} - D_n^{GNSS} \sin \theta \sin \alpha + D_e^{GNSS} \sin \theta \cos \alpha}{\cos \theta} \quad (2.18)$$

式中, D_n^{GNSS} 和 D_e^{GNSS} 分别为 GNSS 观测提供的北向和东向形变分量。

在实际应用中, GNSS 测点通常相对稀疏, 难以与 PSI 点逐点对应, 因此往往需要先基于 GNSS 构建区域尺度的水平形变场, 再将其插值到 PSI 点位置处, 进而进行垂直向形变求解。换言之, GNSS 与 PSI 结果在联合使用前应统一到同一参考基准和相同时间基准下, 且 GNSS 水平形变的精度将直接影响竖向分解结果。

2.4.3 基于升降轨联合观测的垂直向形变提取

当研究区同时具备升轨和降轨 PSI 观测结果时, 可利用二者在观测几何上的差异, 对 LOS 向形变进行联合分解。由于升轨与降轨卫星在飞行方向、航向角及入射角等方面存在差异, 同一监测点在不同轨道条件下对应的 LOS 向投影关系并不相同, 因此能够为垂直向形变提取提供额外的几何约束^[96]。

由式 (2.18) 可知, 在仅具备一组升轨和一组降轨 LOS 向观测结果时, 观测方程数少于未知形变分量个数, 因此难以在无附加约束条件下稳定恢复东向、北向和垂直向三维形变分量。同时, 由于近极轨侧视成像条件下 LOS 观测对北向形变敏感性相对较弱, 北向分量在升降轨联合分解中的可分性通常较差。在城市地表沉降监测研究中, 研究对象通常以垂直向形变为主, 北向水平形变相对较小; 因此, 当研究区缺乏额外水平形变约束, 且北向运动预期不显著时, 升降轨联合分解通常建立在忽略北向形变分量的近似前提之上, 从而将形变分解问题简化为东向形变与垂直向形变两个分量的联合求解, 如式 (2.19) 所示:

$$\begin{aligned} D_{LOS}^a &= D_v \cos \theta^a - D_e \sin \theta^a \cos \alpha^a \\ D_{LOS}^d &= D_v \cos \theta^d - D_e \sin \theta^d \cos \alpha^d \end{aligned} \quad (2.19)$$

式中, D_{LOS}^a 和 D_{LOS}^d 分别为升轨和降轨影像 PSI 结果的 LOS 向形变; θ^a 和 θ^d 分别为升轨和降轨入射角; α^a 和 α^d 分别为升轨和降轨航向角。

将式 (2.19) 写成矩阵形式为:

$$\begin{bmatrix} D_{LOS}^a \\ D_{LOS}^d \end{bmatrix} = \begin{bmatrix} \cos \theta^a & -\sin \theta^a \cos \alpha^a \\ \cos \theta^d & -\sin \theta^d \cos \alpha^d \end{bmatrix} \begin{bmatrix} D_v \\ D_e \end{bmatrix} \quad (2.20)$$

当系数矩阵可逆时, 可进一步得到:

$$\begin{bmatrix} D_v \\ D_e \end{bmatrix} = \begin{bmatrix} \cos \theta^a & -\sin \theta^a \cos \alpha^a \\ \cos \theta^d & -\sin \theta^d \cos \alpha^d \end{bmatrix}^{-1} \begin{bmatrix} D_{LOS}^a \\ D_{LOS}^d \end{bmatrix} \quad (2.21)$$

需要指出, 基于升降轨融合提取垂直向变形方法存在一定的局限性, 该方法的适用前提在于研究区能够同时获得时段匹配较好的升轨和降轨 PSI 观测结果, 且升降轨形变场在空间配准和参考基准上具有较好一致性。若研究区存在显著北向形变, 或升降轨观测时间差异较大, 则忽略北向形变的近似假设可能不再成立, 从而影响垂直向形变分解结果的精度。

2.4.4 忽视水平向形变的传统近似分解方法

对于仅具备单轨道 PSI 观测结果、且研究区形变以竖向形变为主的情形, 通常可认为水平向形变分量相对于垂直向形变较小, 从而将 LOS 向形变近似换算为垂直向形变。这是城市地表沉降监测中应用最广泛的传统分解方法。

根据式 (2.18), 当东西向形变和北向形变均可忽略时, 垂直向形变的近似表达式为:

$$D_v \approx \frac{D_{LOS}}{\cos \theta} \quad (2.22)$$

忽视水平向形变的传统近似分解方法的优点在于形式简洁、实现方便, 对数据需求低, 尤其适用于以垂直向沉降为主、水平运动较弱的大尺度平原城市区域。在缺乏降轨数据、GNSS 约束或其他辅助观测资料时, 基于单轨 LOS 向形变的余弦换算仍然是获取垂直向沉降结果的最直接方法, 因此在区域尺度城市地表沉降监测中得到了广泛应用^[27]。

2.5 本章小结

本章围绕星载 InSAR 技术的基本原理及其在城市地表沉降监测中的适用基础展开论述, 重点介绍了星载 SAR 数据特征、InSAR 形变观测基本原理、PS-InSAR 技术流程及 LOS 向形变分解方法。围绕 SAR 成像模式、干涉相位组成、PS 点筛选、形变反演和垂直向形变提取等关键内容, 分析了星载 InSAR 由相位观测到沉降信息获取的基本技术路径。上述内容为后续离散沉降观测优化、监督标签构建及建筑尺度变形分析提供了理论基础。主要结论如下:

(1) 梳理了星载 InSAR 观测所依赖的主要数据平台及其基本观测特征。围绕不同工作波段、成像模式、空间分辨率和重访周期等参数差异, 归纳了星载 SAR

数据在城市地表沉降监测中的适用特点，并系统阐述了 InSAR 技术的基本原理，重点说明了干涉测量几何关系、相位组成以及 PSI、SBAS-InSAR 等时序 InSAR 方法的基本流程与技术特征。

(2) 归纳了城市地表沉降监测场景下 PSI 技术解析的关键步骤。围绕影像配准、外部 DEM 引入、PS 点筛选、温度相关形变识别、参考点确定及 PS 点形变反演等内容，明确了时序 InSAR 数据处理中由原始 SAR 影像到稳定形变信息提取的基本技术流程。

(3) 概述了 PSI 结果 LOS 向形变分解与垂直向沉降信息提取的主要思路。重点归纳了基于 GNSS 约束、升降轨联合观测以及忽视水平向位移的传统近似分解三种方法，明确了城市地表沉降监测中由 LOS 向观测结果提取垂直向沉降信息的基本路径及适用条件。

第3章 基于多源异构大数据与图神经网络的沉降预测

模型研究

3.1 引言

城市化进程下,地下空间开发、轨道交通建设以及工程扰动等因素叠加,使城市地表沉降呈现出长期累积、空间差异显著的特征,地表发生不均匀变形,将对既有建筑的安全带来隐患。PS-InSAR 技术能够提供较高精度的形变观测,但在实际应用中需要同时考虑数据可获得性、成本与覆盖效果。Sentinel-1 影像数据公开免费,具备良好的经济性与可推广性,但其空间分辨率相对较低,可提取的 PS 点往往较为稀疏,尤其在低层建筑及老旧低矮街区更易出现 PS 点不足甚至缺失现象,导致形变信息呈离散分布,难以直接支撑城市尺度的连续排查。相比之下,COSMO-SkyMed 等高分辨率商业卫星影像能够提升细部表征能力与 PS 点密度,但数据费用较高,不利于常态化、大范围的风险筛查。上述现象本质上反映了城市尺度低成本常态化监测需求与高密度精细形变观测数据获取能力之间的矛盾。针对这一矛盾,本章具体聚焦于 Sentinel-1 PSI 结果在 PS 点稀疏或缺失区域难以直接获取沉降值的问题,围绕“如何利用有限离散沉降观测结合多源沉降驱动因子实现未观测区域沉降空间外推”开展研究。在离散沉降监督信息构建基础上,构建融合多源沉降驱动因子、局部空间邻域关系与多头图注意力网络的图神经网络沉降预测模型,并建立相应数据集。首先利用哨兵一号卫星影像的 PS-InSAR 离散形变点观测值作为监督约束;其次,采用多源沉降驱动因子表征地形水文背景、地表覆盖变化、土体物性差异及工程与构造边界条件等空间信息;最后,通过局部邻域图结构引入空间上下文,使模型能够在稀疏标签条件下学习驱动因子与沉降响应之间的空间关联,为城市区域连续沉降场预测提供模型基础。

3.2 融合多头图注意力的图神经网络沉降预测模型设计

3.2.1 沉降预测问题的图结构表达

为实现离散沉降观测向区域连续沉降分布的外推预测,本文构建融合多头图注意力的图神经网络沉降预测模型。模型以经温度相关形变剔除后的 Sentinel-1 PSI 累计沉降观测值作为监督约束,以多源沉降驱动因子作为输入,学习驱动因子与沉降响应之间的空间映射关系,从而实现城市尺度连续沉降预测。其中,驱动因子主要用于表征地形水文背景、地表覆盖变化、工程与构造边界条件以及土体物性差异

等对地表沉降空间分异的综合影响,具体的构建过程将在 3.4 小节中进行阐述。城市地表沉降受地形水文条件、地表覆盖变化、工程与构造边界条件以及土体物性差异等多种因素共同影响,并表现出明显的空间相关性与局部异质性。传统回归模型能够利用多源驱动因子建立输入与输出之间的对应关系,但难以同时刻画相邻空间单元之间的拓扑联系。图神经网络能够同时表征节点属性信息与节点间结构关系,因而更适用于具有空间邻域依赖特征的沉降预测问题。基于这一认识,本文将区域沉降预测问题转化为局部图样本回归问题,以实现多源驱动信息与空间上下文关系的联合建模。

图神经网络(Graph Neural Network, GNN)是一类面向图结构数据的深度学习模型,其基本思想最早由 Scarselli 等提出,用于解决传统神经网络难以直接处理非欧氏结构数据的问题^[80]。在图神经网络中,研究对象通常被抽象为由节点和边组成的图结构,节点用于表示研究单元,边用于表示节点之间的连接关系。模型通过节点之间的信息传递、邻域聚合和特征更新,使每个节点的表示不仅包含自身属性,也能够融合其相邻节点的空间或拓扑信息。因此,图神经网络适用于道路网络、社交网络、分子结构、交通系统以及空间邻接单元等具有关系结构的数据建模问题。

对于城市地表沉降预测而言,研究对象并不是彼此孤立的栅格像元,而是具有空间邻域关系的连续地表单元。相邻位置往往具有相近的地形水文背景、地表覆盖条件、工程扰动环境和土体物性特征,其沉降响应也可能存在一定空间相关性。传统回归模型虽然能够利用多源驱动因子建立输入与输出之间的对应关系,但难以同时表达相邻空间单元之间的拓扑联系。基于此,本文将区域沉降预测问题转化为局部图样本回归问题,以参考栅格中的像元作为节点,以相邻像元之间的空间邻接关系作为边,以各像元对应的沉降驱动因子作为节点特征,并以中心节点处的 PSI 累计沉降观测值作为监督标签。通过上述方式,离散 PS 点监督信息、连续分布的多源驱动因子以及局部空间邻域关系可被统一到图结构中进行建模。空间建模中的图结构通常可依据空间单元之间的连接关系进行构建。对于规则栅格数据,可将像元作为节点、将相邻像元作为边,构成基于预定义邻接关系的规则栅格邻接图,其本质属于固定邻接矩阵约束下的图卷积或消息传递建模^{[82][83]};对于离散点、传感器或不规则空间样本,可依据欧氏距离阈值或 K 近邻关系构建空间图,以表达样本之间的局部邻近依赖关系^{[98][175]};对于道路、水系、管网等具有明确实体连通关系的对象,可直接依据真实物理连接关系构建实体网络图,交通网络预测中的时空图卷积模型即属于该类典型应用^[176];当先验图结构不完整或难以准确确定时,也可通过模型训练学习自适应邻接矩阵或动态图结构,以补充固定图结构难以表达的隐含空间依赖关系^[177]。不同图结构并不存在简单的优劣之分,其适用性主要取决于研究对象的数据组织形式和空间关系表达需求。本文所采用的沉降驱动因子均统一至 10m 参考栅格,像元之间具有明确的规则空间邻接关系,因此选用规

则栅格局部邻接图作为基本图结构。图 3.1 进一步说明了本文沉降预测问题与图神经网络建模之间的对应关系。




图 3.1 城市地表沉降预测问题的图结构表达模式示意图

3.2.2 基于图神经网络的沉降预测模型总体架构

在样本组织方式上，本文将研究区域内用于统一全部驱动因子空间范围、坐标系、空间分辨率及像元位置关系的基准格网作为参考栅格，并以参考栅格上的局部窗口为基本样本单元，将窗口内各像元抽象为图节点，并依据空间邻接关系建立节点连边，从而将规则栅格结构转化为局部图结构。在此基础上，以节点位置处的多源沉降驱动因子作为节点属性，以中心节点对应位置的累计沉降观测值作为监督标签，构建由输入层、特征提取模块和决策层组成的沉降预测模型。




图 3.2 Patch 图样本的 SAGEGAT 特征提取与中心节点回归结构示意图

其中，输入层负责完成节点特征表达；特征提取模块负责开展邻域信息传播与空间关联建模；决策层则根据中心节点的高维表征输出对应位置的沉降预测值。特

征提取模块采用 GraphSAGE 与多头图注意力网络相结合的混合结构，前者用于稳定聚合局部邻域背景信息，后者用于增强模型对关键邻域关系的自适应表征能力。模型整体架构如图 3.2 所示。

3.2.3 输入层设计

输入层设计的作用在于将研究区域内多源沉降驱动因子组织为图神经网络可处理的节点特征，并建立局部窗口样本中节点之间的空间对应关系。由于后续各类驱动因子来源不同、空间分辨率不一，若不首先建立统一空间基准，则难以保证不同数据在像元层面的准确对应。为此，本文引入参考栅格作为统一的空间基准。参考栅格是指用于统一全部驱动因子空间范围、坐标系统、空间分辨率及像元位置关系的基准格网。后续各类驱动因子均经裁剪、重采样与空间对齐后统一映射到该格网之上，局部窗口裁剪、节点构建以及全区域预测结果输出也均以该格网为基础。本文模型中的基本空间单元为参考栅格上的单个像元。在本研究中，各驱动因子统一对齐至 10m 空间分辨率参考栅格，局部窗口中的每个节点对应地表上的一个 10m × 10m 栅格单元。

在完成空间基准统一后，需进一步将区域沉降预测问题组织为适于图网络处理的局部图样本。若直接在全域范围内构建图结构，不仅会显著增加模型存储开销与训练复杂度，而且不利于突出待预测位置周边的局部空间上下文信息。为在保留局部空间拓扑特征的同时控制图结构规模，本文采用局部窗口构图方式。具体而言，对于任一待预测位置，以该位置为中心裁剪固定尺度的邻域窗口，并将窗口内各像元抽象为图节点；节点之间依据规则栅格邻接关系建立连边，其边连接关系由式 (3.1) 定义，示意如图 3.3 所示。




图 3.3 边连接关系示意图

通过上述处理，区域沉降预测问题可转化为局部窗口图样本学习问题，从而为后续空间特征提取与中心节点沉降回归提供基础。

$$E = \{(v_i, v_j) \mid \|s_i - s_j\|_\infty = 1\} \quad (3.1)$$

其中, E 为边集合; v_i 和 v_j 为局部窗口中的两个节点; $\mathbf{s}_i=(r_i, c_i)$ 表示节点 v_i 在窗口内的行列坐标, $\|\cdot\|_\infty$ 为无穷范数。

城市地表沉降并非由单一因素决定, 而是地形水文条件、地表覆盖变化、工程与构造边界条件以及土体物性差异共同作用下的空间响应结果。因此, 本文输入层所采用的节点属性由多类沉降驱动因子共同构成, 主要包括地形水文因子、地表覆盖因子、工程与构造边界因子以及土壤物性因子四类, 各类驱动因子的来源与构建方法将在 3.4 节中进行详细阐述。

对于局部窗口图样本中的任一节点, 其特征由该位置处全部驱动因子的取值及节点位置编码共同组成, 节点原始属性向量如式 (3.2) 所示:

$$\mathbf{x}_i = [\tilde{d}_{i,1}, \tilde{d}_{i,2}, \dots, \tilde{d}_{i,F}, \mathbf{p}_i] \in \mathbb{R}^D \quad (3.2)$$

其中, $\mathbf{x}_i$ 为节点 v_i 的输入特征向量; $\tilde{d}_{i,f}$ 为第 f 个驱动因子在节点 v_i 处的归一化值; F 为驱动因子总数; $\mathbf{p}_i$ 为位置编码向量; D 为总输入维度。

考虑到不同驱动因子的量纲、数值范围及统计分布存在明显差异, 若直接输入模型, 容易导致大尺度变量在训练过程中占据主导, 从而削弱不同因子之间的相对表征能力。为此, 本文对各驱动因子采用最小—最大归一化处理, 其表达式如式 (3.3) 所示。经过归一化后, 不同驱动因子能够在相对一致的尺度下参与模型训练, 从而提高参数更新过程的稳定性, 并减弱量纲差异对模型学习结果的不利影响。

$$\tilde{d}_{i,f} = \frac{d_{i,f} - d_f^{\min}}{d_f^{\max} - d_f^{\min}} \quad (3.3)$$

其中, $d_{i,f}$ 为原始驱动因子值, $d_f^{\min}$ 与 $d_f^{\max}$ 分别为第 f 个驱动因子在训练样本域内的最小值与最大值。

仅利用驱动因子取值难以显式表征节点在局部窗口中的相对空间位置, 而沉降过程往往同时受到邻域结构与空间方位差异的影响。为增强模型对空间位置关系的感知能力, 本文在节点特征中引入二维位置编码, 其表达式为:

$$\mathbf{p}_i = \left[x_i, y_i, \{\sin(2\pi\omega_m x_i), \cos(2\pi\omega_m x_i), \sin(2\pi\omega_m y_i), \cos(2\pi\omega_m y_i)\}_{m=1}^M \right] \quad (3.4)$$

其中, (x_i, y_i) 为节点在全局参考栅格坐标归一化后的结果, ω_m 为第 m 个频率, M 频率个数。

综合归一化驱动因子与位置编码后, 输入层最终形成局部窗口图样本的节点特征矩阵, 其表达式为:

$$\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]^T \in \mathbb{R}^{N \times D} \quad (3.5)$$

式中, $\mathbf{X}$ 为局部窗口图样本的节点特征矩阵; $\mathbf{x}_i$ 为节点 v_i 的输入特征向量;

整合更大空间范围内的背景信息。然而，地表沉降形成过程中，不同邻域节点对中心位置沉降响应的贡献并不相同。为进一步增强模型对关键邻域关系的辨识能力，本文在 GraphSAGE 背景聚合的基础上引入多头图注意力网络（Graph Attention Network, GAT）。对于节点 v_i 及其邻域节点 v_j ，第 k 个注意力头下的未归一化注意力系数定义为式（3.7）：

$$e_{ij}^{(l,k)} = \text{LeakyReLU}\left(\mathbf{a}^{(l,k)\text{T}} \left[\mathbf{W}_g^{(l,k)} \mathbf{h}_i^{(l)} \parallel \mathbf{W}_g^{(l,k)} \mathbf{h}_j^{(l)} \right]\right) \quad (3.7)$$

式中， $e_{ij}^{(l,k)}$ 表示第 l 层第 k 个注意力头下节点 v_j 对节点 v_i 的未归一化注意力系数； $\text{LeakyReLU}(\cdot)$ 表示带泄露项的线性整流激活函数； $\mathbf{a}^{(l,k)}$ 表示第 l 层第 k 个注意力的注意力权重向量； $\mathbf{W}_g^{(l,k)}$ 表示对应的线性变换矩阵。

在此基础上，归一化注意力权重及多头聚合结果可表示为式（3.8）与式（3.9）：

$$\alpha_{ij}^{(l,k)} = \frac{\exp(e_{ij}^{(l,k)})}{\sum_{t \in \mathcal{N}(i)} \exp(e_{it}^{(l,k)})} \quad (3.8)$$

$$\mathbf{h}_i^{(l)} = \parallel \sigma \left(\sum_{k=1}^K \alpha_{ij}^{(l,k)} \mathbf{W}_g^{(l,k)} \mathbf{h}_j^{(l)} \right) \quad (3.9)$$

式中 $\alpha_{ij}^{(l,k)}$ 表示归一化后的注意力权重； $\mathbf{h}_i^{(l)}$ 表示节点 v_i 在的最终输出特征； K 表示注意力头数。

通过多头机制，模型能够从多个表示子空间并行学习邻域关系，从而增强对局部异常与复杂空间异质性的表征能力。为提高深层图网络训练的稳定性，并缓解多层堆叠过程中可能出现的表征退化问题，本文进一步在各层输出中引入残差连接与层归一化操作，其表达式为：

$$\mathbf{h}_i^{(l)} = \text{LayerNorm}\left(\mathbf{h}_i^{(l)} + \mathbf{W}_r^{(l)} \mathbf{h}_i^{(l-1)}\right) \quad (3.10)$$

式中， $\mathbf{h}_i^{(l)}$ 表示节点 v_i 在第 l 层最终输出特征； $\text{LayerNorm}(\cdot)$ 表示层归一化算子； $\mathbf{W}_r^{(l)}$ 表示残差映射矩阵。

经过多层 GraphSAGE 与多头图注意力编码后，局部窗口内各节点均获得包含邻域上下文信息的高维表征，从而为后续中心节点沉降回归提供判别特征。

3.2.5 决策层与优化目标设计

本文将局部窗口图样本的沉降预测任务定义为监督学习问题。对于每一个局部窗口图样本，仅中心节点对应一个监督标签，该标签来自经旁瓣效应剔除、交叉验证及温度相关形变剔除后的 Sentinel-1 PSI 累计沉降观测值；窗口中的其他邻域节点虽然不直接对应监督标签，但能够通过图结构中的信息传播为中心节点提供局部背景约束。因此，本研究的监督学习并不是对窗口内全部节点同时进行逐点回

归，而是以局部窗口为样本单位，仅对中心节点开展沉降值预测。

在完成特征提取后，仅提取局部窗口中心节点的最终表示，并通过多层感知机实现沉降值回归，其表达式为：

$$\hat{y}_n = \text{MLP}(\mathbf{h}_{n,c}^{(L)}) \quad (3.11)$$

式中， $\hat{y}_n$ 为第 n 个局部窗口图样本中心节点的预测沉降值； $\mathbf{h}_{n,c}^{(L)}$ 为该样本中心节点经第 L 层特征提取后的最终表示； c 表示中心节点索引； $\text{MLP}(\cdot)$ 为由全连接层构成的回归映射函数。

考虑到沉降观测值可能受异常样本、局部噪声及残余误差影响，若直接采用均方误差作为损失函数，模型训练容易受到少量大残差样本的过强干扰。为兼顾收敛效率与鲁棒性，本文采用加权 Huber 损失作为监督项，其表达式如式 (3.12) 所示 [102]。

$$\mathcal{L}_{\text{sup}} = \sum_{n=1}^B \omega_n \begin{cases} \frac{r_n^2}{2\delta}, & |r_n| < \delta, \\ |r_n| - \frac{\delta}{2}, & |r_n| \geq \delta, \end{cases} \quad r_n = \hat{y}_n - y_n, \quad \mathcal{L}(y_n, \hat{y}_n) \quad (3.12)$$

式中， $\mathcal{L}_{\text{sup}}$ 表示监督损失项； B 表示一个批次内的图样本数； ω_n 表示第 n 个样本对应的损失权重； r_n 表示第 n 个样本预测值与真实值之间的残差； $\hat{y}_n$ 表示第 n 个样本的预测沉降值； y_n 表示第 n 个样本的真实沉降值； δ 表示 Huber 损失的分段阈值，当残差较小时，损失函数保持二次惩罚形式，以保证参数更新的平滑性；当残差较大时，损失函数转为线性惩罚，从而降低异常样本对整体训练过程的不利影响。考虑到不同沉降样本对区域连续场构建的重要程度可能存在差异，引入样本权重后，还可进一步提升模型对关键观测点的拟合能力。

除监督项外，局部窗口图中仍包含大量无标签节点，考虑到沉降场在局部尺度上通常具有一定连续性，此若相邻节点预测值出现过强振荡，则不利于后续连续沉降场构建与物理解释。基于此，本文借鉴图拉普拉斯平滑思想 [103]，引入弱平滑正则项，对无标签节点相关边上的预测结果施加适度的空间连续性约束，并将其与监督损失共同构成总体优化目标。

首先，定义节点标签指示变量 m_i ，当节点 v_i 为有标签中心节点时， $m_i = 1$ ；否则 $m_i = 0$ 。参与平滑约束的边集合定义为：

$$E' = \{(i, j) \in E \mid m_i m_j = 0\} \quad (3.13)$$

其中， E' 表示参与平滑约束的边集合； E 表示局部窗口图的原始边集合。

该定义表示仅对至少一端为无标签节点的边施加平滑约束，从而避免将平滑项简单退化为仅针对中心监督节点的拟合补充。在此基础上，弱平滑损失可表示为：

$$\mathcal{L}_{\text{sm}} = \frac{1}{|E'|} \sum_{(i,j) \in E'} (\hat{y}_i - \hat{y}_j)^2 \quad (3.14)$$

其中, $\mathcal{L}_{\text{sm}}$ 表示弱平滑正则项; $|E'|$ 表示参与平滑约束的边数; $\hat{y}_i$ 与 $\hat{y}_j$ 分别表示相邻节点 v_i 和 v_j 的预测值。

最终, 本文将监督损失与弱平滑正则共同构成模型的总体优化目标:

$$\mathcal{L} = \mathcal{L}_{\text{sup}} + \lambda \mathcal{L}_{\text{sm}} \quad (3.15)$$

其中, λ 为平滑正则权重, 用于平衡监督拟合与空间连续性约束。

3.3 研究区域与数据集预处理

3.3.1 长沙市区域概况

作为中国湖南省的省会, 长沙市是湖南省最大的城市之一, 其地理位置处于湖南省中部偏北地区, 坐落于湘江沿岸。行政区域大致位于北纬 $27^{\circ}51'$ — $28^{\circ}40'$ 、东经 $111^{\circ}53'$ — $114^{\circ}15'$ 之间, 辖域面积约 11816km^2 。从地形条件看, 长沙整体地势相对平缓, 地貌类型以低山丘陵与平原为主。建成区主要分布在湘浏盆地内, 外围多丘陵与山地环绕, 形成较为明显的盆地—丘陵过渡格局。水系方面, 湘江与浏阳河贯穿市域并构成主要径流体系, 其中湘江为湖南省重要河流之一, 也是长沙最具代表性的河流; 浏阳河则主要流经市域西部, 并在城区与湘江汇合。综合而言, 长沙自然地理条件较为优越, 水资源条件良好, 气候适宜且植被类型多样, 为城市建设、生态维持及居民生产生活提供了较坚实的环境基础。

3.3.2 数据集来源

为支撑区域尺度沉降预测模型构建与后续典型区域精细验证, 本文所采用的数据主要包括两类: 一类为 SAR 影像数据, 用于 PSI 处理、离散沉降观测提取及结果验证; 另一类为沉降驱动因子源数据, 用于表征研究区地形水文背景、地表覆盖变化、工程与构造边界条件以及土体物性差异。

本文采用的 SAR 影像包括 Sentinel-1 和 COSMO-SkyMed 两类。其中, Sentinel-1 数据主要用于研究区域尺度 PSI 处理、离散沉降观测提取以及监督标签构建, 是第三章沉降预测模型训练与预测的基础数据; COSMO-SkyMed 数据主要用于典型区域的高分辨率 PSI 处理, 并作为后续 Sentinel-1 结果交叉验证及模型预测结果精细验证的数据支撑。

Sentinel-1 数据选取 VV 极化方式与宽幅干涉成像模式, 数据覆盖时间为 2022 年 9 月 30 日至 2024 年 9 月 19 日, 共 23 景, 主要用于长沙市区域尺度 PSI 处理及后续沉降预测模型监督信息构建。COSMO-SkyMed 数据选取 VV 极化方式与 HIMAGE 成像模式, 数据覆盖时间为 2022 年 9 月 27 日至 2024 年 9 月 24 日, 共

24 景。两类 SAR 数据在本文中承担的任务并不相同。Sentinel-1 数据服务于区域尺度沉降预测模型的监督标签构建与连续沉降预测，COSMO-SkyMed 数据则主要用于高分辨率精细验证。图 3.5 为本文所采用的 COSMO-SkyMed 影像覆盖范围，面积约 1806 平方公里。相较于 COSMO-SkyMed 数据，Sentinel-1 影像覆盖范围更大，且包含图 3.5 所示典型区域。




图 3.5 COSMO-SkyMed SAR 影像覆盖范围示意图

为表征地表沉降形成的多源控制因素，本文进一步收集了构建沉降驱动因子所需的多类源数据，其总体情况如表 3.1 所示。

表 3.1 沉降驱动因子源数据概况


序号	类别	名称	来源
1	光学遥感影像	Sentinel-2	阿拉斯加卫星设施
2	数字高程模型	World DEM TM Neo	德国宇航中心
3	土壤特性栅格数据	第二版 CSDLv2	国家青藏高原数据中心 ^[149]
4	河流水系矢量数据	长沙市水系矢量数据	OpenStreetMap
5	断层分布矢量数据	长沙市断层分布	中国活动断层数据库
6	城市轨道交通线网	长沙市地铁线路数据	8684 地铁查询网；高德开放平台

数据选取主要围绕自然地理背景、浅层介质条件及城市工程扰动三类因素展开，以保证后续驱动因子能够从地表覆盖、地形起伏、土体物性、水文边界、构造边界和轨道交通扰动等方面表征沉降空间分异特征。具体而言，Sentinel-2 光学遥感影像用于提取地表覆盖与植被变化信息，WorldDEMTM Neo 用于派生地形水文因子，CSDLv2 土壤特性栅格数据用于表征浅层土体物性差异，河流水系、断层分布


和城市轨道交通线网数据则分别用于刻画水文环境、构造背景及工程活动对地表沉降的潜在影响。按照数据类型划分,本文所采用的源数据主要包括光学遥感影像、数字高程模型、土壤特性栅格数据、河流水系矢量数据、断层分布矢量数据以及城市轨道交通线网数据。

3.3.3 基于旁瓣效应剔除的 PS-InSAR 技术流程

如图 3.6 所示,在城市建筑群区域,屋顶边缘、金属构件以及建筑角隅等会形成强散射体,其有限带宽成像的点扩散函数会把能量通过旁瓣“泄漏”到邻近像元,使得主瓣与旁瓣周围的冗余像元在幅度稳定性等指标上同样呈现出“像 PS”的特征,进而在强散射体周边产生簇状的伪 PS 点并污染 PS 点云空间分布,破坏 PSI 对“单像元点状主导散射、相位可建模”的基本前提^[21]。



(a) Sentinel-1 影像旁瓣效应



(b) COSMO-SkyMed 影像旁瓣效应

图 3.6 SAR 影像旁瓣效应

同时多时相 InSAR 研究也明确指出,旁瓣往往表现出相干回波行为,若不在 PS 候选筛选前进行识别与掩膜,就可能被误选为 PS 点并把旁瓣相关的相位噪声带入形变反演,导致沿建筑轮廓及其他线状结构出现错误的形变异常和残差增大^[1]。在高分辨率城市场景中,这类旁瓣伪影还会与建筑间多次反射产生的幽灵 PS 点现象共同抬升误判风险^[46],如图 3.7 所示。



图 3.7 伪散射体产生的虚假 PS 点

因此，本文提出基于旁瓣效应剔除的 PS-InSAR 技术流程，通过旁瓣效应阈值抑制和人工二次剔除方法，将所有由于旁瓣效应产生的伪散射体进行剔除，提升城市区 PS-InSAR 形变结果可信度，流程图如 3.8 所示。




图 3.8 基于旁瓣效应剔除的 PSI 流程图

3.3.4 PS-InSAR 结果交叉验证

通过如图 3.5 所示范围的 Sentinel-1 影像数据与 COSMO-SkyMed 影像数据，采用基于旁瓣效应剔除的 PSI 方法获取了河西区域中 COSMO-SkyMed 影像所覆盖的全部区域的变形场结果。该交叉验证分析区域面积约为 825.425km²，在相同

区域范围内, Sentinel-1 数据共提取 PS 点 56568 个, COSMO-SkyMed 数据共提取 PS 点 305338 个, 对应的 PS 点密度分别约为 68.53 个/km^2 和 369.92 个/km^2 。由此可见, COSMO-SkyMed 数据在该区域内提取的 PS 点数量约为 Sentinel-1 数据的 5.40 倍, 能够提供更高密度的离散形变观测信息。随后, 通过式 (2.18) 进行 LOS 向变形三维分解后, 得到的 PSI 垂直向变形场结果如图 3.9 所示。




图 3.9 长沙市河西地区 PSI 结果示意图

为验证 Sentinel-1 数据与 COSMO-SkyMed 数据在 PSI 处理结果中的准确性, 本文采用交叉验证方法对两套数据的 PSI 形变结果开展相互对比分析, 在图 3.5 中的区域 A 和区域 B 内分别选取空间位置接近的两种数据的 PS 点时序结果进行相互验证, 如图 3.10 所示, 验证结果如图 3.11 所示。






图 3.10 PSI 结果交叉验证区域

两套时间序列在个别时段存在轻微错位, 主要表现为峰谷出现时刻并非完全重合, 这种差异是源于 Sentinel-1 与 COSMO-SkyMed 的成像获取时间并不完全一致, 两者观测时刻存在数天的时间差, 从而使得在对齐到同一时间轴时出现局部时序偏移。尽管存在上述时间差异, 但两条曲线在总体趋势与变化幅度上仍保持一致, 说明两类数据的 PSI 结果具有良好的相互印证关系, Sentinel-1 与 COSMO-SkyMed 影像数据反演得到的 PSI 形变时间序列结果是可靠的。



a) 区域 A 交叉验证结果




b) 区域 B 交叉验证结果

图 3.11 Sentinel-1 与 COSMO-SkyMed 数据 PSI 交叉验证结果

3.3.5 PSI 结果温度变形剔除与监督信号构建

城市建成区中, PSI 可稳定识别的永久散射体多依附于建筑物、构筑物及其附属设施, 尤其在高密度建筑群环境下, PS 点通常集中分布于屋顶边缘、建筑立面、金属构件及墙角等强散射部位。因此, 部分研究在工程应用中常将建筑物上的 PS 点形变直接等效为地表沉降信息, 以此表征地基或地表的变形状态^{[121][122]}。但对于城市地表沉降预测而言, 直接采用上述处理方式存在一定局限性。高层建筑立面往往沿高度方向分布连续的 PS 点序列, 而此类建筑多采用嵌岩深基础或稳定性较高的深基础形式, 其基底变形相对有限, 上部结构则容易受气温变化影响产生热胀冷缩响应。由此产生的温度形变会叠加于 InSAR 观测结果之中, 一定程度上掩盖真实的地表沉降分量。



a) PS 点变形速率

b) PS 点热变形

图 3.12 高层建筑下 PS 点变形速率与热变形分布图^[174]

如图 3.12 所示, 若不加区分地将建筑物 PS 点形变直接视为地表沉降, 则所得结果实质上混合了结构温度响应与地基沉降信息, 难以准确反映真实地表变形特

征。基于此,本文在将 PSI 结果引入监督样本构建之前,对受温度形变影响显著的 PS 点进行识别与剔除。具体而言,本文将建筑高度 24m 作为识别高层建筑上部结构温度响应影响的工程参考阈值。该阈值主要依据民用建筑高度分类中常用的高层建筑界限,用于区分更易受到立面、屋顶构件及附属设施热胀冷缩影响的 PS 点。需要说明的是,该处理并非否定高层建筑区域可能存在地基沉降,而是为了避免建筑上部结构温度形变被误作为地表沉降信息引入模型训练标签。基于此,本文对高度超过 24m 且可能受温度相关形变影响较大的 PS 点进行剔除,仅保留更能反映地表沉降响应的剩余 PS 点,并将其累计沉降观测值定义为模型训练标签 y 。

在完成温度形变显著 PS 点的识别与剔除后,剩余 PS 点的累计沉降值能够更稳定地反映研究时段内的地表沉降响应。本文将这些 PS 点对应的累计沉降值作为图神经网络沉降预测模型的监督标签,并依据其空间位置提取对应局部窗口内的多源沉降驱动因子及空间邻接关系,构建用于模型训练、验证与测试的样本数据集。由此,PSI 离散沉降观测结果由单纯的形变监测结果进一步转化为沉降预测模型可利用的标签数据。




图 3.13 监督信号数据集划分

考虑到城市地表沉降具有显著空间自相关性,空间上相邻的 PS 点在沉降量级及变化趋势上通常具有较强相似性,若直接采用随机抽样方式划分训练集、验证集和测试集,则容易使空间邻近的样本同时分布于不同数据子集之中,从而导致训练样本与测试样本之间存在较强空间信息重叠,最终使模型精度被高估,难以真实反

映模型对未知区域的泛化能力。基于此，本文采用空间分块策略对监督样本进行划分，即首先按照研究区空间位置将有效 PS 点划分为若干相互独立的空间块，再以空间块为基本单元进行数据集分配，最终按点数比例形成训练集、验证集和测试集，其中训练集占 80%，验证集占 10%，测试集占 10%，如图 3.13 所示。

空间分块策略划遵循的基本原则是同一空间块内的样本尽量归属于同一数据子集，不同数据子集之间尽可能保持空间分离，以增强训练集、验证集和测试集之间的空间独立性。通过空间分块策略划分训练集、验证集和测试集，能显著增强不同数据子集之间的空间独立性，使验证集和测试集能够更接近真实预测任务中“利用已有区域样本推断未观测区域沉降分布”的应用情形。与随机划分相比，空间分块方法能够有效避免空间自相关带来的信息泄漏问题，使模型评估结果更加严格，也更能反映模型对空间外推任务的适应能力。同时，空间分块划分保留了局部沉降斑块与邻域背景之间的完整空间结构，有利于在训练阶段稳定学习驱动因子与沉降响应之间的空间映射关系，在验证与测试阶段则能够检验模型在空间分异条件变化下的鲁棒性。

3.4 沉降驱动因子分析与构建

本节在 3.3.2 所述数据基础上开展沉降驱动因子构建工作。以 World DEMTM Neo 数字高程模型与中国土壤特性栅格数据集第二版 CSDLv2 两类主要栅格源数据为基础，并结合河流水系、断层分布与城市轨道交通线网等基础矢量数据，构建得到 21 种与地表沉降过程具有较强相关性的驱动因子，用于表征地形水文背景、地表覆盖变化、土体物性差异及工程与构造边界条件等对沉降空间分异的综合约束，其源数据对应关系如表 3.2 所示。

表 3.2 沉降驱动因子与源数据对应关系

驱动因子	分辨率 (m)	源数据
地形湿度指数	5	World DEM TM Neo
流动功率指数	5	
地形崎岖度指数	5	
坡度	5	
坡向	5	
海拔	5	
平面曲率	5	
年均 NDVI 变化量	10	Sentinel-2
距离断层的距离	10	长沙市断层分布

驱动因子	分辨率 (m)	源数据
距离河流的距离	10	长沙市水系矢量数据
距地铁线路的距离	10	长沙市地铁线路数据
0-30cm 土壤容重	90	CSDLv2
30-200cm 土壤容重	90	
0-30cm 土壤粘粒含量	90	
30-200cm 土壤粘粒含量	90	
0-30cm 土壤砾石含量	90	
30-200cm 土壤砾石含量	90	
0-30cm 土壤孔隙度	90	
30-200cm 土壤孔隙度	90	
0-30cm 固结可压缩敏感性指数	90	
30-200cm 固结可压缩敏感性指数	90	

3.4.1 基于 DEM 构建的沉降驱动因子

DEM 不仅提供地表高程信息,还能够通过地形几何关系进一步反映坡面形态、水流组织方式及局部起伏特征。对于城市地表沉降而言,地形背景虽然并非直接致沉因素,但会通过影响地表径流汇聚、浅层土体含水条件以及工程建设场地整治方式,对沉降空间分异形成基础约束。相较于单一高程指标,基于 DEM 派生的多种地形因子能够从不同角度刻画地形对沉降形成环境的综合调制作用。因而,在沉降预测模型中引入 DEM 派生因子,有助于增强对区域沉降空间异质性的表征能力。本小节所选取的 7 种沉降驱动因子均采用 ArcMap 10.8.1 对 DEM 数据进行后处理制作而成,如图 3.14 所示。

(1) 地形湿度指数

地形湿度指数 (Topographic Wetness Index, TWI) 用于表征局部地形对水分汇聚与滞留的控制作用,是地形水文分析中常用的空间指标。该指数具有明确的物理意义,可用于刻画水流汇聚与径流路径的形成过程,在水文学、农业与工程地质等研究与应用中被广泛采用。在降雨径流建模中, TWI 能够辅助推断特定区域径流发生的规模及其响应时序;而在土壤水分建模中,它可以用来预测土壤水分的空间分布。总体而言, TWI 是理解和预测水在景观中移动的有用工具^[123]。此外, TWI 还可以识别可能受到降雨事件引发洪水影响的区域^[124]。TWI 的计算公式如式 (3.16) [125]:

$$TWI = \ln(\alpha/\tan\beta) \quad (3.16)$$

其中， α 代表上坡汇流面积， β 代表坡度。

地形控制下的汇水与滞水格局可影响浅层土体含水状态与周期性干湿变化，并改变软弱土体在长期荷载作用下的压密条件与变形累积过程。基于该物理含义，TWI 可用于约束沉降在地形低洼与汇水通道附近的空间聚集特征，表征近地表湿润背景的空间差异，并为后续模型学习沉降与地形水文背景之间的关联提供连续型输入变量。




图 3.14 基于 DEM 派生的沉降驱动因子

(2) 流动功率指数

流动功率指数 (Stream Power Index, SPI) 用于表征坡面汇流在重力作用下的潜在能量水平，反映坡面径流的侵蚀与搬运能力。SPI 的计算公式如式 (3.17) 所示^[126]:

$$SPI = \alpha * \tan \beta \quad (3.17)$$

其中， α 代表流积累， β 代表坡度

SPI 的引入侧重于刻画地表水动力过程对地表形态与浅层地基环境的约束作

用。坡面汇流能量较高的区域更可能出现冲刷与沉积重分配，并在工程建设以及地表覆盖改变条件下表现出更强的沟谷发育和地表形态调整趋势，该类过程会改变浅层土体结构连续性与局部地基条件。

（3）地形崎岖度指数

地形崎岖度指数（Terrain Ruggedness Index, TRI）用于表征局部地形起伏与粗糙程度，是衡量地表形态复杂性的定量指标之一。TRI 通常由数字高程模型在一定邻域范围内计算得到，其基本思想是利用目标像元与其邻域像元之间的高程差异来度量地形起伏幅度。该指标已被用于地形分区、地貌形态刻画及与地表过程相关的空间分析中^[127]，其计算公式如式（3.18）所示：

$$TRI = \sqrt{\sum_{i=1}^n (z_i - z_0)^2} \quad (3.18)$$

其中， z_0 为目标像元的高程值， z_i 为邻域内第 i 个像元的高程值， n 为邻域像元数量，通常取 $n=8$ ，对应 3×3 邻域的八邻域像元。TRI 值越大表示邻域内高程差异越明显，地形起伏程度越高；TRI 值较小则指示地形相对平缓、起伏较弱的区域。

通常地形起伏较强的区域局部高差变化更显著，地表形态也更为复杂，工程建设活动中更可能出现填挖方与地形整治，同时会形成不同的人工地基条件，在该类地形背景下可对沉降的空间非均质性提供解释框架，因此 TRI 被作为补充地形因子引入模型输入以增强对沉降空间差异的刻画能力。

（4）坡度与坡向

坡度（Slope）和坡向（Aspect）是描述地表形态与地形起伏的基本地理参数，坡度表示单位水平距离内的垂直变化量，坡向表示坡面在水平面内的朝向，两者可由 DEM 的局部高程梯度计算获得。坡度与坡向的计算公式分别如式（3.19）与式（3.20）所示：

$$\text{Slope} = \arctan\left(\frac{\Delta Z}{\Delta D}\right) \quad (3.19)$$

$$\text{Aspect} = \arctan\left(\frac{dZ/dy}{dZ/dx}\right) \quad (3.20)$$

其中， ΔZ 为相邻像元之间的高程差， ΔD 为像元间的水平距离。 dZ/dx 和 dZ/dy 分别表示在水平面上的高程梯度沿 X 轴和 Y 轴的变化。以正北方向为 0° ，顺时针方向增加。

坡度与坡向被纳入沉降驱动因子体系，主要用于表征坡面几何条件对地表过程与工程扰动敏感性的约束。坡度较大时，坡面重力分量增大并对应更强的地表侵蚀与堆积差异，同时在工程活动中更易伴随边坡开挖与支护等措施，从而使地基环

境与变形响应的空间差异增强。坡向则通过影响太阳辐射分配与微气候条件,可形成不同的地表干湿差异与覆盖差异,并为沉降空间差异提供地形朝向维度的背景信息。在沉降敏感性建模研究中,坡度与坡向常作为基础地形变量参与多因子建模^{[128][129]},因此本研究将其作为图神经网络输入变量之一。

(5) 海拔

海拔在城市尺度沉降研究中的作用主要体现在其对宏观地貌格局与沉积环境的指示意义。低海拔平原与河流冲积区往往对应松散沉积物堆积与细粒沉积占比增加,软弱土层厚度与可压缩介质体积可能更大,从而在外部荷载与地下水位变化背景下更易形成持续性沉降。全球尺度沉降威胁评估结果表明,沉降风险在城市与灌溉平原等区域更为集中,且与地形与沉积地貌背景存在空间耦合关系^[128]。

此外,海拔作为 DEM 的基础变量,也是水文指数与地貌参数的重要数据基础,其在地形分析中的基础地位已在数字地形建模综述中进行系统总结^[125]。因此,本研究将海拔作为连续型地形因子输入模型,用于引入宏观地形格局与沉积地貌背景信息,以约束沉降空间分布的整体趋势。

(6) 平面曲率

平面曲率 (Plan Curvature) 用于表征等高线方向上地表形态的弯曲程度,是数字高程模型构建的重要地形参数之一。与海拔和坡度主要描述地表高程水平及坡面陡缓程度不同,平面曲率更强调坡面在横向上的收敛与发散特征,可用于刻画地表水流在坡面上的侧向汇聚能力及微地形控制下的空间差异^[158]。相关研究指出,平面曲率本质上反映了坡面横向的汇流与分流过程,是描述地形收敛—发散格局的重要指标。平面曲率可表示为沿等高线方向的二阶地形变化率,其常用表达式如式 (3.21) 所示^[159]:

$$k_p = -\frac{z_{xx}z_y^2 - 2z_{xy}z_xz_y + z_{yy}z_x^2}{(z_x^2 + z_y^2)^{3/2}} \quad (3.21)$$

其中, z_x 与 z_y 分别表示高程在 x 与 y 方向上的一阶偏导数 z_{xx} 、 z_{yy} 与 z_{xy} 分别表示对应的二阶偏导数。

相较于地形湿度指数和流动功率指数分别侧重于汇水背景与坡面水动力过程,平面曲率能够进一步补充局部微地形横向形态差异的信息。因此,本文将平面曲率作为连续型地形因子纳入沉降驱动因子体系,用于增强模型对局部微地形控制下沉降空间差异的表达能力。

3.4.2 年均归一化植被指数变化量

归一化植被指数 (Normalized Difference Vegetation Index, NDVI) 是基于植被在红光波段强吸收、在近红外波段强反射的光谱差异构建的植被活力与覆盖状况表征指标,用于表征植被覆盖与光合活性状态。NDVI 的经典定义如式 (3.22)^[131]:

$$\text{NDVI} = \frac{\rho_{\text{NIR}} - \rho_{\text{RED}}}{\rho_{\text{NIR}} + \rho_{\text{RED}}} \quad (3.22)$$

式中, ρ_{NIR} 与 ρ_{RED} 分别表示近红外与红光波段的反射率。

为刻画研究期内地表覆盖的阶段变化, 本研究构建年均 NDVI 变化量作为驱动因子之一。年均 NDVI 通过同一年内多期 NDVI 观测进行时间聚合获得, 若某一年对应 m_y 期有效 NDVI 影像, 则年均 NDVI 可表示为式 (3.23) :

$$\overline{\text{NDVI}}_y = \frac{1}{m_y} \sum_{t=1}^{m_y} \text{NDVI}_{y,t} \quad (3.23)$$

在此基础上, 年均 NDVI 变化量定义为式 (3.24) :

$$\Delta \overline{\text{NDVI}} = \overline{\text{NDVI}}_{2024} - \overline{\text{NDVI}}_{2022} \quad (3.24)$$

式中, $\overline{\text{NDVI}}_{2024}$ 与 $\overline{\text{NDVI}}_{2022}$ 分别表示 2024 年与 2022 年的年均 NDVI 栅格。

本研究构建的 $\Delta \overline{\text{NDVI}}$ 如图 3.15 所示, 用于表征地表覆盖变化与生态水文过程调整的空间差异, 植被覆盖变化可改变蒸散发强度与地表水量平衡过程, 从而间接影响浅层土体含水环境与地表能量交换背景, 植被指数在蒸散发估算与水量平衡分析中的应用已在综述研究中得到总结^[130]。同时, 在沉降易发性制图的多因子实践中, 植被或地表覆盖相关变量常被作为辅助因子用于提升模型对沉降空间差异的区分能力^[129]。




图 3.15 年均 NDVI 变化量

3.4.3 基于欧氏距离创建的沉降驱动因子

除地形水文、地表覆盖及土体物性因子外, 城市地表沉降的空间分布差异还常受到断层、水系及轨道交通等线性边界条件的影响。此类边界要素虽然不能直接以单一栅格属性表示其作用强度, 但其影响通常具有明显的空间衰减特征, 即距相关要素越近, 其对局部地下水条件、工程扰动或介质非均质性的约束作用往往越强。基于此, 本文以长沙市断层分布、水系以及地铁线路三类矢量数据为基础, 采用 ArcMap10.8.1 软件的 Euclidean Distance 工具构建距离断层的距离、距离河流的距离以及距地铁线路的距离三种欧氏距离栅格, 并将其作为沉降驱动因子引入模型, 如图 3.16 所示。为保证不同驱动因子在像元层面的空间对应关系, 上述距离栅格

均在统一投影坐标系下计算，并按照 10m 空间分辨率输出。

对于任一线性边界要素类型 k ，其欧氏距离因子定义为任意像元中心位置 x 到该类要素集合 y 的最小平面距离，即：

$$D_k(x) = \min_{y \in \Omega_k} \|x - y\|_2 \quad (3.25)$$

式中， $D_k(x)$ 表示像元中心位置 x 到第 k 类边界要素的欧氏距离； Ω_k 表示该类边界要素的空间集合； y 表示集合 Ω_k 中任一点的位置坐标； $\|\cdot\|_2$ 表示二维欧氏范数。




图 3.16 基于欧氏距离创建的沉降驱动因子

(1) 距离断层的距离

距离断层的距离用于表征构造边界对沉降空间分异的约束作用，其定义为任意像元中心至最近断层要素的最小平面距离。断层带通常由断层核与损伤带等结构单元构成，不同单元的破碎程度与渗透性结构可形成明显差异，并控制流体运移路径与局部水力联系^[135]。断层水文地质综述进一步指出，断层在不同地质条件下可表现为导水通道或隔水边界，并改变含水层连通性与水力梯度^[136]。

在沉降过程机理中，构造边界对地下水流场与介质结构非均质性的调制可导致压密响应的空间差异，相关研究在全球沉降问题综述中已被归纳^[137]。同时，基于遥感形变观测的案例研究显示，断层与软土厚度等因素可共同影响沉降空间格局^[138]。因此，本文将距离断层的距离作为构造控制条件的空间代理变量输入模型，以增强对沉降空间非均质性的解释能力。

(2) 距离河流的距离

距离河流的距离用于刻画河流边界对地下水系统与沉降空间分布的约束作用，其定义为任意像元中心至最近河道要素的最小平面距离。河流与含水层之间可通过河床渗漏与河岸入渗等机制发生交换过程，地下水与地表水相互作用的系统性综述对该类机制进行了归纳^[139]。在定量研究中，河岸入渗对地下水位波动的影响呈现明显的距离衰减与时间滞后特征^[140]，说明河流作为水力边界对地下水系统影响具有空间尺度效应。

距离河流的距离在沉降驱动因子体系中的作用主要体现为对近河水力边界影响强度的空间表达。近河区域的水位涨落与补排条件变化更易传递至浅层含水系统，并改变局部孔隙水压力背景与压密条件，从而使沉降在空间上表现出与河流邻近性相关的差异。沉降易发性建模研究中常将距离河流作为输入变量用于提升空间区分能力^[141]，因此本研究同样将该距离因子纳入模型输入。

（3）距离地铁线路的距离

距离地铁线路的距离用于表征轨道交通走廊相关工程扰动对地表沉降空间分异的约束作用，其定义为任意像元中心至最近地铁线路的最小平面距离。地铁盾构施工与车站基坑开挖会引起土体扰动与应力重分布，施工参数与地层条件差异可导致沉降槽形成并呈现随距离增加而衰减的空间规律^[142]。

盾构施工沉降控制与数值分析研究表明，地层损失与注浆等施工因素与沉降幅值密切相关^[143]。基坑降水与开挖过程可引起地下水位下降与围护结构变形并导致地表沉降，其过程机理在数值研究中已有讨论^[144]。在既有建筑邻近条件下的案例研究同样指出，线路邻近性对沉降影响显著^[145]。因此，本研究将距离地铁线路的距离作为施工扰动强度的空间代理变量输入模型，用于引入轨道交通建设活动对沉降空间差异的约束信息。

3.4.4 基于土壤分布构建的沉降驱动因子

本文所采用的土壤属性数据来源于 CSDLv2 数据集，该数据集采用 Global Soil Map 的标准土层体系，按 0-5、5-15、15-30、30-60、60-100 和 100-200cm 六个标准深度层提供土壤属性值^[146]。考虑到 0-30cm 在土壤学与数字土壤数据库中通常对应表层土范围，而 30cm 以下则更能表征浅部次表层至浅部地基土主体层特征^[147]，本文将原始六个层位分别聚合为 0-30cm 和 30-200cm 两个深度段，以兼顾数据源标准层位与工程沉降分析需求，并保持不同深度土层信息的可解释性。其中，0-30cm 更接近近地表扰动带与覆土层，易受地表荷载变化与浅层含水状态变化影响，30-200cm 更接近浅部地基土主体层，可用于表征浅层介质在有效应力长期调整条件下的固结压密潜势。地下水开采导致的沉降通常与可压缩含水层系统的压密过程相关，并在细粒夹层中表现出更显著的压密贡献^[148]。城市地表沉降亦可能受到建筑荷载等城市化过程的影响，荷载引起的应力增量会向浅部介质传递并触发压密变形，相关机制在城市地球物理研究中已被讨论^[150]。同时，多城市尺度的观测研究指出，以浅层介质物性刻画沉降空间分异具有必要性^[151]。

两类深度段指标均采用厚度加权平均进行聚合，对任一土壤属性 X ，0 至 30cm 与 30 至 200cm 的聚合计算分别如式（3.26）与式（3.27）所示。

$$X_{0\sim30} = \frac{5X_{0\sim5} + 10X_{5\sim15} + 15X_{15\sim30}}{30} \quad (3.26)$$

$$X_{30\sim200} = \frac{30X_{30\sim60} + 40X_{60\sim100} + 100X_{100\sim200}}{170} \quad (3.27)$$

其中 $X_{i\sim j}$ 表示第 i 到第 j cm 对应的土壤属性值。

本研究基于两类深度段的土壤属性共构建 10 个沉降相关土壤指标，如图 3.17 所示，分别为粘粒含量、容重、孔隙度、砾石含量与固结可压缩敏感性指数在两个

深度段的表征。




图 3.17 土壤相关因子

(1) 土壤粘粒含量 Clay

粘粒含量用于表征细粒组分占比，可反映细粒介质的压缩性与固结特征差异。沉降机理研究普遍指出，地下水开采导致的压密沉降常与细粒夹层或黏性土层的压密过程相关，细粒介质在孔隙水压力降低背景下更易贡献沉降量^[148]。天然黏土压缩性研究表明，黏土结构性与颗粒组成共同控制其压缩响应与孔隙比演化^[152]。

粘粒含量按式 (3.26) 与式 (3.27) 分别得到 $Clay_{0-30}$ 与 $Clay_{30-200}$ ，并作为沉降

驱动因子输入用于刻画浅表层与浅部地基细粒背景差异。

(2) 土壤容重 BD

容重 BD 用于表征单位体积土体的干质量，可作为土体紧实程度与结构状态的宏观指标。表层压实敏感性研究指出，土体压缩响应可与含水状态及容重建立统计关联，容重可为压密敏感性提供可用约束^[153]。

容重按式 (3.26) 与式 (3.27) 分别得到 BD_{0-30} 与 BD_{30-200} ，并用于表征浅表层与浅部地基土结构紧实程度差异。

(3) 土壤孔隙度 Prosimy

孔隙度用于表征孔隙体积占比，是固结压密过程的重要状态量。固结参数统计研究表明，压缩指数等参数可由初始孔隙比等状态量进行近似估计，提示孔隙结构状态对压密变形具有控制作用^[154]。孔隙度按式 (3.26) 与式 (3.27) 分别得到 $Prosimy_{0-30}$ 与 $Prosimy_{30-200}$ ，并用于刻画潜在可压缩空间的深度分异。

(4) 土壤砾石含量 Gravel

砾石含量用于表征粗颗粒骨架组分占比，可用于刻画粗细颗粒组合差异对介质压缩性与排水条件的约束。沉降综述指出，细粒介质通常为压密沉降的主要贡献者，而粗颗粒骨架增加会降低等效可压缩体比例并改变压密贡献结构^[148]。沉降综述研究亦指出沉积物粒度组成是影响压密敏感性的关键因素之一^[155]。砾石含量按式 (3.26) 与式 (3.27) 分别得到 $Gravel_{0-30}$ 与 $Gravel_{30-200}$ ，并用于表征浅表层与浅部地基土粗骨架差异。

(5) 固结可压缩敏感性指数 CSI

为综合表达孔隙结构状态与细颗粒比例对压密潜势的共同影响，本研究构建固结可压缩敏感性指数 CSI。细粒土压缩性研究指出，孔隙结构与细粒性质的组合可更直接反映压密敏感性差异^[152]。相关统计研究与经验关系研究也表明，压缩指数可由孔隙结构状态量及细粒性质近似表征^{[154][156]}。CSI 的计算如式 (3.28) 至式 (3.30) 所示：

$$FF = \frac{\text{Silt} + \text{Clay}}{100} \quad (3.28)$$

$$e = \frac{\text{Prosimy}}{1 - \text{Prosimy}} \quad (3.29)$$

$$CSI = e \cdot FF \quad (3.30)$$

其中，Prosimy、Clay 与 Silt 在 0 至 30cm 与 30 至 200cm 两个深度段分别按式 (3.26) 与式 (3.27) 进行厚度加权聚合，得到 CSI_{0-30} 与 CSI_{30-200} 。CSI 作为综合指标用于在不引入额外试验参数条件下提供对压密潜势差异的空间约束，因此被纳入沉降驱动因子体系。

本文构建的 21 个沉降驱动因子来源于多种栅格与矢量数据，其源数据原始空间分辨率并不一致。为保证不同驱动因子在像元层面的空间对应关系，本文在驱动因子构建完成后，统一将全部驱动因子重采样至 10m 的空间分辨率栅格。

3.5 模型训练示例

前文已分别从地形水文、地表覆盖变化、工程与构造边界条件以及土体物性等方面构建了沉降驱动因子。由于各类因子来源、空间分辨率、坐标系统和数据格式存在差异，仅完成单类因子构建仍不能直接作为图神经网络输入。为进一步说明多源异构数据如何组织为图神经网络训练样本，本文在前述模型输入层设计基础上，以单个 Sentinel-1 PSI 沉降观测点为例，对输入数据、输出标签、空间配准、标准化预处理及特征融合过程进行说明，单个训练样本的输入—标签构成示例具体如表 3.3 所示。

表 3.3 图神经网络单个训练样本的输入与标签构成示例

项目	示例说明	在模型中的作用
样本中心	某一经筛选后的 Sentinel-1 PSI 沉降观测点 P_i	确定局部图样本的中心位置
局部窗口	以 P_i 所在 10m 栅格像元为中心裁剪固定尺度窗口	构建局部图样本
节点	局部窗口内每一个 10m×10m 栅格像元	表示地表空间单元
边	相邻像元之间的规则栅格邻接关系	表达局部空间拓扑关系
输入数据	各节点处归一化后的多源沉降驱动因子与位置编码	作为图神经网络输入特征
监督标签	中心节点处筛选后的 PSI 累计沉降值 y_i	仅在训练阶段作为真实标签
模型输出	中心节点沉降预测值 $\hat{y}_i$	与 y_i 计算损失并更新模型参数
配准方式	各类驱动因子统一至 10m 参考栅格	保证不同来源数据在像元层面对应
标准化方式	对各驱动因子进行最小—最大归一化	减弱量纲差异对模型训练的影响
特征融合方式	节点特征拼接后输入 GraphSAGE 与多头 GAT	实现多源属性信息与空间邻接关系联合建模

(1) 输入数据

以研究区内某一经筛选后的 Sentinel-1 PSI 沉降观测点为例，首先将该点映射至统一的 10m 参考栅格中，并以其所在像元作为局部图样本的中心节点。以该中心节点为中心裁剪固定尺度的局部窗口，窗口内每一个 10m×10m 栅格像元均作为

图结构中的一个节点，相邻像元之间按照式（3.1）所示的规则栅格邻接关系建立边连接。由此，单个 PSI 点被组织为一个包含局部空间邻域关系的图样本，该图样本的模型输入为局部窗口内各节点对应位置处的多源沉降驱动因子及位置编码。其中，多源沉降驱动因子包括 DEM 派生的地形水文因子、Sentinel-2 影像构建的年均 NDVI 变化量、基于断层、水系和地铁线路矢量数据生成的欧氏距离因子，以及不同深度段的土壤物性因子。对于窗口内任一节点 v_j ，其节点特征由该位置处各类驱动因子的取值及位置编码共同组成，具体表达形式已由式（3.2）给出

（2）输出标签，

图样本仅中心节点具有监督标签。该标签为 p_i 处经旁瓣效应剔除、Sentinel-1 与 COSMO-SkyMed 交叉验证以及温度相关形变剔除后的 PSI 累计沉降值，记为 y_i 。需要说明的是， y_i 仅在模型训练阶段作为真实沉降标签，用于与模型输出的中心节点沉降预测值 $\hat{y}_i$ 计算损失函数；在模型预测阶段，PS 沉降值不作为输入数据参与特征提取，模型仅依据多源沉降驱动因子、位置编码和空间邻接关系输出待预测位置的沉降值。

（3）多源异构数据配准

本文以 10m 参考栅格作为统一空间基准，对不同来源的沉降驱动因子进行空间预处理。具体而言，DEM 派生因子、NDVI 变化量、欧氏距离因子和土壤物性因子均被统一裁剪至研究区范围，并通过投影转换、重采样和空间对齐，使不同数据在坐标系统、空间分辨率、像元大小、行列号和空间范围上保持一致。经过配准后，同一 10m 栅格像元可同时对应一组地形水文、地表覆盖变化、工程与构造边界及土体物性属性值，从而保证节点特征在空间位置上的一致性。

（4）标准化预处理

同沉降驱动因子的量纲和取值范围差异较大。例如，距离类因子通常以米为单位，坡度和坡向反映地形几何特征，NDVI 变化量为无量纲指标，土壤物性因子则具有不同的物理含义。若直接将原始数值输入模型，容易使数值范围较大的变量在训练过程中占据主导。为减弱量纲差异对模型训练的影响，本文按照式（3.3）对各类驱动因子进行最小—最大归一化处理，使不同类型因子能够在相对一致的数值尺度下参与模型训练。

（5）特征融合

本文采用“节点特征拼接—图结构邻域融合”的方式实现多源异构数据融合。首先，在输入层将同一节点位置处归一化后的多源沉降驱动因子与位置编码进行拼接，形成节点特征向量；随后，局部窗口内全部节点特征共同组成式（3.5）所示的节点特征矩阵，并与节点间边连接关系共同输入图神经网络。模型通过 GraphSAGE 聚合局部邻域背景信息，并利用多头图注意力机制对不同邻域节点的贡献进行自适应加权，最终提取中心节点的高维特征并输出沉降预测值。通过上述过程，多源

属性信息、空间邻接关系和 PSI 沉降监督标签被统一到局部图样本回归框架中,实现了由离散 PSI 观测点向区域连续沉降预测的建模转换。

综上,单个训练样本可概括为:以某一经筛选后的 PSI 沉降观测点为中心构建局部图样本,窗口内各 10m 栅格像元作为节点,相邻像元之间的空间邻接关系作为边;各节点处归一化后的多源沉降驱动因子与位置编码共同构成模型输入;中心节点处筛选后的 PSI 累计沉降值作为监督标签;模型输出为中心节点沉降预测值。

3.6 本章小结

本章提出了基于多源沉降驱动因子与图神经网络的城市地表沉降预测方法,解决了 Sentinel-1 PSI 结果在 PS 点稀疏或缺失区域难以直接获取沉降值的问题。该方法以温度相关形变剔除后的 PSI 累计沉降值作为沉降监督标签,结合多源沉降驱动因子与局部空间邻域关系,将区域沉降预测转化为局部图样本回归问题。通过图神经网络学习驱动因子、空间邻域关系与沉降响应之间的映射关系,实现对未观测区域沉降值的空间外推。

(1) 构建了融合 GraphSAGE 与多头图注意力机制的沉降预测模型框架。基于 Sentinel-1 数据的 PSI 结果,以局部窗口为样本单位建立邻域关系表达方式,将稀疏标签条件下的区域沉降预测转化为局部图样本回归任务,并引入弱平滑正则策略以降低预测结果在空间上的高频振荡。

(2) 构建了用于模型训练的可靠沉降监督标签。本文提出基于旁瓣效应剔除的 PSI 计算方法,并利用 Sentinel-1 与 COSMO-SkyMed 两类 SAR 影像的 PSI 结果开展交叉验证。在此基础上,将 Sentinel-1 影像的 PSI 结果中具有显著温度变形的 PS 点进行剔除,以筛选后的累计观测值作为沉降预测模型的监督标签。

(3) 构建了面向沉降预测的多源驱动因子体系。基于六种多源异构数据,本文构建了涵盖地形水文、地表覆盖变化、工程扰动与土体物性等方面的 21 种沉降驱动因子。针对不同来源数据完成裁剪、重采样、空间对齐与深度段聚合处理,为后续沉降预测模型的输入组织与空间规律表达提供了基础。

第4章 基于图神经网络的沉降预测模型验证与分析

4.1 引言

面向区域尺度地表沉降预测，沉降驱动因子的构建通常涉及地形水文、地表覆盖变化、工程扰动及土体物性等多个方面，具有明显的多源异构特征。尽管经过裁剪、重采样、空间配准与深度段聚合等处理后，各类驱动信息能够被统一组织到同一建模框架中，但不同因子之间仍可能存在较强相关性、信息冗余及尺度响应交叠等问题。此外，区域沉降预测效果不仅取决于输入因子体系是否合理，还与网络结构对局部空间依赖关系和复杂非线性响应的表征能力密切相关。因此，在模型应用于区域沉降异常识别与风险区域筛查之前，仍有必要围绕输入合理性、结构有效性及结果可靠性开展系统检验。因此，本章将围绕所构建沉降预测模型的输入合理性、网络结构有效性及预测结果可靠性开展系统分析。首先，对沉降驱动因子之间的相关性与共线性关系进行检验，在识别冗余信息的基础上形成更为合理的输入因子组合。其次，围绕不同输入方案及网络结构设置开展对比分析，重点考察驱动因子筛查、GraphSAGE 网络深度及图注意力网络引入对模型预测效果的影响，并结合统一评价指标对模型性能进行综合评估，同时与 IDW 和 Kriging 等传统空间插值方法进行对比。最后，基于最优模型获取研究区连续沉降预测结果，对其空间分布特征及沉降异常区域进行识别与分析，并结合典型区域验证进一步评估模型在区域尺度沉降异常识别中的适用性与可靠性。

4.2 驱动因子相关性分析

在多源沉降驱动因子共同参与建模时，不同因子之间可能存在信息冗余与线性依赖关系，使高相关性因子所表征的控制信息在一定程度上发生重复。当高相关性因子同时进入模型时，虽然不一定直接导致预测结果失真，但容易造成输入信息冗余，增加参数学习过程中的不稳定性，并进一步影响后续因子贡献分析与机理解释的可靠性。因此，在模型训练之前，有必要对各沉降驱动因子之间的相关性与共线性关系进行筛查，以识别可能存在的冗余输入，并形成更为合理的因子组合。

本节采用皮尔逊相关分析对驱动因子之间的线性相关程度进行定量表征。皮尔逊相关系数可用于衡量两个变量之间线性关系的强弱，取值范围为 $r_{xy} \in [-1, 1]$ 。设在同一空间位置采样得到的两个驱动因子序列分别为 $\{x_i\}_{i=1}^n$ 与 $\{y_i\}_{i=1}^n$ ，则由式(4.1)可得到皮尔逊相关系数^[157]：

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4.1)$$

其中， $\bar{x}$ 与 $\bar{y}$ 分别表示样本均值， n 为样本数。当 $|r_{xy}|$ 趋近于 1 时，说明两因子具有较强的线性相关性，存在较高的共线性风险。

本研究以研究区范围内的有效像元为采样对象，对 21 个驱动因子进行两两相关性计算。为保证各因子在空间上的可比性，采样前将各栅格因子对齐到统一参考网格，并采用双线性方式进行重采样处理。在统计上，为降低局部区域样本偏置的影响，从有效像元中抽取 100000 个样本点用于相关系数估计，并设置 $|r| \geq 0.9$ 作为强相关阈值，用于识别需要进一步处理的高共线性因子对。本研究所选取的 21 个沉降驱动因子的皮尔逊相关系数如图 4.1 所示。




图 4.1 沉降驱动因子的皮尔逊相关系数热力图

筛查结果表明，在所分析的 21 个驱动因子中仅有两组因子相关系数超过强相关阈值 $|r| \geq 0.9$ 。第一组为坡度（Slope）与地形崎岖度指数（TRI），其相关系数 $|r| = 0.9929$ ；第二组为深层固结可压缩敏感性指数（CSI₃₀₋₂₀₀）与深层粘粒含量（Clay₃₀₋₂₀₀），其相关系数 $|r| = 0.9121$ 。两组强相关因子对应的散点图如图 4.2 所示。

对于第一组强相关因子，二者均由数字高程模型派生，均可表征地形起伏特征，其中坡度在地形水文与地貌分析中具有更直接的几何意义与更广泛的应用基础，

因此在该组中保留坡度并剔除地形崎岖度指数；对于第二组强相关因子，深层固结可压缩敏感性指数是由深层粘粒含量进行二次计算获得，为降低复合指标与基础物性指标的冗余输入，本研究在该组中保留深层粘粒含量并剔除深层固结可压缩敏感性指数。




图 4.2 强相关驱动因子散点图

经相关性筛查后，最终保留的沉降驱动因子为 19 个，分别为 Aspect、海拔、坡度、平面曲率、流动功率指数、地形湿度指数、年均 NDVI 变化量、距离断层的距离、距离河流的距离、距地铁线路的距离，以及 0-30cm 与 30-200cm 两个深度段的土壤容重、土壤粘粒含量、土壤砾石含量、土壤孔隙度与浅层固结可压缩敏感性指数

4.3 实验设计与结果分析

为验证所提出模型结构的有效性以及驱动因子共线性分析的必要性，本节采用消融实验对关键设计进行对比检验，通过对比分析改进前后模型在决定系数、均方根误差、均方误差、平均绝对误差四个方面的精度，从不同角度验证模型的性能。

4.3.1 实验环境与参数设置

本文实验在一台运行 Linux 系统的 Dell Precision 5820 Tower 工作站上完成。实验平台的中央处理器（CPU）为 Intel Xeon W-2255 @ 3.70 GHz，图形处理单元（GPU）为 NVIDIA RTX A6000，显存容量为 48 GB。GPU 驱动版本为 470.256.02，安装了 CUDA 11.4 用于支持深度学习相关计算。编程语言选择了 Python 3.8，模型训练基于 PyTorch 与 PyTorch Geometric 框架实现。在训练参数方面，模型最大训练轮数设置为 300，批量大小设置为 256，初始学习率设置为 0.001，权重衰减系数设置为 0.0001。采用 AdamW 优化器，并结合 Reduce LR On Plateau 学习率调度策略，当验证集损失在连续若干轮内无明显下降时，学习率按 0.5 的比例衰减，最小

学习率设置为 1×10^{-6} 。同时，早停轮数设置为 60，以防止模型在后期训练中出现过拟合。这样的实验设计充分考虑了硬件配置和深度学习框架的要求，并在网络训练参数上进行了合理设置，以确保模型在训练过程中能够充分学习特征，并通过合适的学习率调整和权重衰减措施，提高模型的收敛速度和泛化能力。

4.3.2 实验评价指标

在深度学习的预测模型的评价中，通常采用均方误差（MSE）、均方根误差（RMSE）、平均绝对误差（MAE）和决定系数（ R^2 ）作为模型性能评价指标^[161]。

MSE 表示预测误差平方的平均值，其数值越小，说明模型整体误差越小，通过采用平方的形式使得该指标对大误差样本具有更强的惩罚作用；RMSE 则为 MSE 的平方根，直接反映模型预测结果与真实值之间的偏离程度，在保持对大误差敏感的同时，更便于从实际物理量尺度上解释模型误差；MAE 表征的是模型在整体样本上的平均预测偏差； R^2 用于描述模型对真实值总体变异的解释程度，其值越接近 1，表示模型拟合效果越好。四类评价指标的定义式如式（4.2）至（4.5）所示：

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.2)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.3)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4.5)$$

式中， n 表示测试样本数， y_i 表示第 i 个样本的真实沉降值， $\hat{y}_i$ 表示第 i 个样本的预测值， $\bar{y}$ 则为全部真实值的均值。


4.3.3 沉降驱动因子消融实验

为验证沉降驱动因子共线性筛查对模型预测性能与训练稳定性的影响，本节在保持模型结构、样本划分方式和训练参数一致的前提下，对共线性分析前后的两组驱动因子输入进行对比实验。为避免网络结构差异对结论造成干扰，统一采用 SAGE-多头 GAT-SAGE 的三层混合图神经网络结构。本节共设置两组对照实验，具体如表 4.1 所示。

表 4.1 共线性分析前后驱动因子输入的消融实验设计

组别	模型结构	模型输入
C1	SAGE-多头 GAT-SAGE	初始驱动因子集合
C2	SAGE-多头 GAT-SAGE	共线性筛查后的驱动因子集合

消融实验的评估结果与损失函数曲线分别如图 4.3 和表 4.2 所示，可以看出，无论是在训练集、测试集还是验证集上，在进行沉降驱动因子共线性分析之后，C2 组的各项评价指标均要优于 C1 组，这表明共线性筛查并未削弱模型对沉降空间分异规律的表达能力，反而通过减少高相关变量带来的重复输入，使模型能够更加集中地提取有效控制信息，从而提高了整体泛化表现。



a) C1 组损失函数曲线

b) C2 组损失函数曲线

图 4.3 C1 与 C2 组预测模型的损失函数曲线图

表 4.2 共线性分析前后驱动因子输入的模型评价指标

组别	C1	C2
训练集 MSE	2.401	2.248
测试集 MSE	2.675	2.576
验证集 MSE	2.778	2.700
训练集 RMSE	1.550	1.499
测试集 RMSE	1.636	1.605
验证集 RMSE	1.667	1.643
训练集 MAE	0.962	0.930
测试集 MAE	1.024	1.001
验证集 MAE	1.038	1.017
训练集 R^2	0.561	0.589
测试集 R^2	0.518	0.536
验证集 R^2	0.507	0.521

此外，从两组损失函数曲线可以发现，训练过程中 C2 组的验证集损失波动更小、收敛过程更平稳，这进一步表明，共线性分析能够降低强相关因子对参数优化带来的干扰。

4.3.4 网络结构消融实验

为进一步验证本文沉降预测模型的最优网络结构,本节在统一输入因子、样本划分方式和训练参数设置的前提下,对网络深度与模块组合进行消融实验。所有实验均采用第三章共线性筛查后的 19 种驱动因子作为输入,以避免输入冗余对网络结构比较结果造成干扰。

(1) GraphSAGE 层数消融实验

为验证地表沉降预测模型的最优 GraphSAGE 网络深度,分别设置 1 层、2 层、4 层、6 层和 8 层、10 层和 12 层 GraphSAGE 的预测模型开展消融实验,不同层数下各预测模型的损失函数曲线图 4.4 所示,从图中可以观察到,不同 GraphSAGE 层数下的预测模型,其训练集与验证集损失函数曲线均表现为前期快速下降、后期逐步收敛的典型特征,说明各组模型均能够完成对局部窗口图样本的有效学习,但不同层数模型的收敛水平存在显著差异。G1 和 G2 的训练损失与验证损失始终处于较高水平,表明浅层 GraphSAGE 的信息传播范围有限,只能完成低阶邻域特征聚合,难以充分表征中心节点与更大空间范围内驱动因子之间的耦合关系。随着网络层数由 1 层增加至 9 层,损失曲线整体持续下移,说明增加 GraphSAGE 层数后,模型的有效感受野同步扩大,中心节点能够整合更多高阶邻域信息,从而更充分地学习局部沉降背景的空间依赖结构。

表 4.3 不同 GraphSAGE 层数下预测模型的评价指标

组别	G1	G2	G4	G6	G8	G9	G10	G12
训练集 MSE	2.928	2.451	2.033	1.834	1.805	1.680	1.836	1.996
验证集 MSE	3.075	2.710	2.446	2.328	2.320	2.251	2.332	2.395
测试集 MSE	3.128	2.818	2.554	2.443	2.447	2.376	2.451	2.497
训练集 RMSE	1.711	1.566	1.426	1.354	1.344	1.296	1.355	1.413
验证集 RMSE	1.754	1.646	1.564	1.526	1.523	1.500	1.527	1.548
测试集 RMSE	1.769	1.679	1.598	1.563	1.564	1.541	1.566	1.580
训练集 MAE	1.072	0.972	0.882	0.837	0.831	0.803	0.840	0.880
验证集 MAE	1.105	1.031	0.972	0.952	0.946	0.930	0.947	0.970
测试集 MAE	1.111	1.044	0.987	0.964	0.958	0.946	0.963	0.982
训练集 R^2	0.465	0.552	0.628	0.665	0.670	0.693	0.664	0.635
验证集 R^2	0.446	0.512	0.560	0.581	0.582	0.595	0.580	0.569
测试集 R^2	0.445	0.500	0.547	0.567	0.566	0.579	0.565	0.557

表 4.3 对不同层数 GraphSAGE 模型在训练集、测试集和验证集上的预测结果

进行了定量比较，结合图 4.4 可以发现，在本文局部窗口图建模条件下，基于 9 层 GraphSAGE 的预测模型在高阶信息整合能力与节点表征可分性之间取得了最佳平衡，是纯 GraphSAGE 结构在本文任务中的最优深度设置。




图 4.4 不同 GraphSAGE 层数预测模型损失函数曲线

GraphSAGE 的均值聚合本质上是一种局部低通滤波过程，适度增加层数能够增强模型对中心节点的周围邻接节点特征及其空间关系的综合表征能力，但当层数超过任务所需的有效传播深度后，连续的邻域平均会使节点表示逐步同质化，节点间可分性下降，进而削弱对空间异质性的刻画能力，G10 和 G12 的各项性能均低于 G9，正是过深图卷积导致过平滑的直接体现。

(2) 注意力网络消融实验

GraphSAGE 层数消融实验结果表明，单纯增加 GraphSAGE 网络深度能够提升模型对高阶邻域信息的聚合能力，但纯均值聚合方式仍难以体现不同邻居节点的重要性差异。基于此，本文在已确定较优 GraphSAGE 深度的基础上，进一步引入图注意力网络，通过设置不同注意力头数、不同 GraphSAGE 深度及不同图注意力网络层数的对照实验，以比较不同组合结构在地表沉降预测中的性能差异，并分析注意力网络对模型空间异质性表征能力的影响。

表 4.4 注意力网络消融实验设置

组别	GraphSAGE 网络深度（层数）	GAT 注意力头数	GAT 层数
A1	9	0	0
A2	8	2	1
A3	8	4	1
A4	8	8	1
A5	9	4	1
A6	8	4	2

实验具体设置如表 4.4 所示，A1 为 9 层纯 GraphSAGE 基线模型，A2 至 A4 用于比较不同注意力头数设置，A5 用于检验在引入注意力后继续增加 GraphSAGE

深度的效果，A6 用于检验增加 GAT 层数后的结构表现。本组设计可将注意力网络的影响分解为注意力是否引入、注意力头数是否合理以及注意力层数是否适度三个方面，对混合结构的有效性进行系统验证。

由图 4.5 可见，A3 组的训练集与验证集损失曲线下降最快，收敛后稳定处于最低水平，说明其在参数优化过程中能够更有效地提取局部窗口图中的关键空间信息；A2 和 A4 的损失曲线整体高于 A3，表明无论注意力头数偏少还是偏多，都会削弱模型的特征提取能力；A5 和 A6 虽然同样引入了图注意力网络，但收敛水平仍明显劣于 A3，说明在已建立注意力加权机制后，继续增加 GraphSAGE 深度或叠加 GAT 层数均未带来额外收益，反而降低了训练稳定性。




图 4.5 A1 至 A6 组损失函数曲线

表 4.5 对上述现象给出了定量验证。A3 组在训练集、验证集和测试集上的 MSE、RMSE、MAE 均为所有组别中最小， R^2 均为最大，说明其在整体预测性能上达到最优。尤其是在验证集和测试集上，A3 相较于纯 GraphSAGE 基线模型 A1 的优势更为明显，表明该结构的提升并非仅体现在训练样本拟合能力上，而是更直接体现在未参与训练样本的预测效果上。这表明在最优深度的 GraphSAGE 基础上引入图注意力网络后，模型对局部空间异质性的刻画能力得到显著增强，邻域信息的加权聚合更加符合真实沉降响应的空间传播特征，从而有效提升了模型的泛化性能。

从 A2、A3、A4 之间的评价指标可以发现，注意力头数并非越多越好，而是存在与当前任务匹配的最优设置。多头注意力的作用是将邻域关系映射到多个表示子空间中进行并行建模，头数过少时，邻域关系表达维度不足，难以完整刻画沉降预测中不同方向、不同类型驱动因子之间的异质性；头数过多时，在固定隐藏维度条件下单头特征容量被压缩，注意力分配趋于碎片化，导致有效信息密度下降。A3 与 A5、A6 的指标对比进一步表明，在当前局部窗口图任务中，单层 GAT 已经充分承担了邻域差异加权的函数，继续增加 GraphSAGE 深度或 GAT 层数不会增强模型的有效表达，反而会破坏注意力层已经形成的特征区分结构。

表 4.5 A1 至 A6 组的评价指标

组别	A1	A2	A3	A4	A5	A6
训练集 MSE	1.680	1.853	1.620	1.854	1.823	1.766
验证集 MSE	2.251	2.368	1.957	2.358	2.332	2.313
测试集 MSE	2.376	2.462	2.025	2.441	2.428	2.434
训练集 RMSE	1.296	1.361	1.273	1.362	1.350	1.329
验证集 RMSE	1.500	1.539	1.399	1.535	1.527	1.521
测试集 RMSE	1.541	1.569	1.423	1.562	1.558	1.560
训练集 MAE	0.803	0.843	0.788	0.842	0.838	0.824
验证集 MAE	0.930	0.953	0.902	0.954	0.948	0.946
测试集 MAE	0.946	0.963	0.883	0.962	0.959	0.959
训练集 R^2	0.693	0.661	0.704	0.661	0.667	0.677
验证集 R^2	0.595	0.574	0.636	0.576	0.580	0.584
测试集 R^2	0.579	0.563	0.618	0.567	0.569	0.568

从 A2、A3、A4 之间的评价指标可以发现，注意力头数并非越多越好，而是存在与当前任务匹配的最优设置。多头注意力的作用是将邻域关系映射到多个表示子空间中进行并行建模，头数过少时，邻域关系表达维度不足，难以完整刻画沉降预测中不同方向、不同类型驱动因子之间的异质性；头数过多时，在固定隐藏维度条件下单头特征容量被压缩，注意力分配趋于碎片化，导致有效信息密度下降。A3 与 A5、A6 的指标对比进一步表明，在当前局部窗口图任务中，单层 GAT 已经充分承担了邻域差异加权的功能，继续增加 GraphSAGE 深度或 GAT 层数不会增强模型的有效表达，反而会破坏注意力层已经形成的特征区分结构。

本实验验证了图注意力网络在地表沉降预测中具有显著增益，本研究设计的基于图神经网络的沉降预测模型已经在局部背景信息整合、空间异质性刻画和模型复杂度控制之间达到了最佳平衡，在本文后面小节的模型性能评估与预测结果验证都将基于第三章中所设计的基于“4 层 GraphSAGE-4 头 GAT-4 层 GraphSAGE”图神经网络模型。

4.4 模型性能评估与驱动因子重要性排序

4.4.1 模型性能评估

为进一步验证本研究所设计的预测模型的预测结果并非来源于简单的空间邻近延拓, 本文将其与 IDW 和 Ordinary Kriging 两类传统插值方法进行对比, 两种方法的基本原理及相关数学表达式已在第 5 章 5.2.1 和 5.2.2 中进行了系统阐述。需要说明的是, 本节中两类插值方法均采用训练集中的 PS 点作为参与插值样本, 并以测试集中的 PS 点作为独立验证点进行精度评估, 即利用训练区已知点对测试区样本点沉降值进行估算, 再与测试集上的真实值进行比较, 评价指标采用 4.2.2 节所定义的四类精度评价方法。

由表 4.6 可见, 传统插值方法在测试集上的误差水平远高于本文模型。以测试集结果为例, IDW 的 MSE、RMSE 和 MAE 分别约为本文模型的 4.62 倍、2.15 倍和 2.30 倍, Ordinary Kriging 的 MSE、RMSE 和 MAE 分别约为本文模型的 4.19 倍、2.05 倍和 2.22 倍; 在决定系数方面, 本文模型的 R^2 分别约为 IDW 的 8.47 倍和 Ordinary Kriging 的 3.89 倍。

表 4.6 传统插值方法在测试集上的评价指标

插值方法	MSE	RMSE	MAE	R^2
IDW	9.357	3.059	2.033	0.073
普通 Kriging	8.480	2.912	1.958	0.159

IDW 与 Kriging 的建模基础均建立在已知样本点的空间邻近性或空间自相关结构之上, 其本质仍是利用观测值之间的距离关系或变异函数关系, 对未知位置进行局部估计。因此, 这类方法的预测精度高度依赖于样本点在空间上的连续分布与邻域支撑条件。当观测点分布较为离散、空间分块明显, 尤其是在训练样本与测试样本存在空间分离的情况下, 传统插值方法对未知区域的外推能力会迅速减弱, 预测结果也随之显著劣化。相比之下, 本文所构建的沉降预测模型并不以邻近观测值的直接传递为核心, 而是通过图结构学习驱动因子与沉降响应之间的空间映射关系, 使地形、水文、地表覆盖、工程扰动及土体属性等物理信息共同参与预测。因此, 模型输出不仅受已知沉降样本约束, 更受到沉降形成机制的综合控制, 在空间分离条件下仍保持了较好的稳定性与泛化能力。

本节设置 IDW 与 Ordinary Kriging 对照, 并非单纯比较不同方法在常规局部插值条件下的优劣, 而是检验不同方法在空间外推场景下的适用性差异。从这一角度看, 传统插值方法在测试集上的失效并不是偶然现象, 而是由其方法本身对邻域样本连续性的高度依赖所决定的。这也进一步说明, 针对城市地表沉降预测任务, 仅依靠样本点间的空间插值难以获得可靠结果, 必须引入能够表征沉降形成过程

的物理属性驱动因子，并通过面向空间关联学习的预测模型实现对未知区域沉降分布的有效推断。

4.4.2 沉降驱动因子重要性排序

为明确各驱动因子在沉降预测中的相对贡献，本文在最优模型训练完成后，对输入变量开展重要性排序分析。考虑到仅依据网络参数大小难以准确反映驱动因子对预测结果的实际作用，本文将输入层权重范数分析与验证集置乱检验进行结合，以综合刻画各驱动因子的相对重要性。前者用于衡量驱动因子在输入映射阶段的响应强度，后者则通过比较因子空间对应关系被破坏前后模型误差的变化，直接衡量该因子对预测精度的实际贡献。

(1) 输入层权重范数分析

设输入映射层权重矩阵为 $W \in \mathbb{R}^{d_h \times d_{in}}$ ，其中 d_h 为隐藏层维度， d_{in} 为输入特征维度，第 j 个驱动因子对应的权重列向量记为 $\mathbf{w}_j = [w_{1j}, w_{2j}, \dots, w_{d_h j}]^T$ ，则 L_1 范数定义为^[168]：

$$\|\mathbf{w}_j\|_1 = \sum_{k=1}^{d_h} |w_{kj}| \quad (4.6)$$

其 L_2 范数定义为^[169]：

$$\|\mathbf{w}_j\|_2 = \left(\sum_{k=1}^{d_h} w_{kj}^2 \right)^{1/2} \quad (4.7)$$

其中， L_1 范数用于刻画某一驱动因子在输入映射中的总体作用强度，表示参数绝对幅度； L_2 范数用于反映该因子权重的整体能量水平，表示参数集中程度。

(2) 验证集置乱检验

置乱的重要思想最早用于随机森林变量重要性分析^[170]，随后被推广为适用于一般预测模型的模型无关特征重要性方法。其核心在于，在保持模型参数、图结构以及其余驱动因子不变的条件下，仅将某一驱动因子在验证样本中的取值顺序随机重排。经过这一处理后，该因子的取值范围、均值和方差保持不变，但其与原始空间位置之间的对应关系被切断，因此可以直接检验该因子所承载的空间信息对预测结果的贡献程度。

设模型在验证集上的基准误差为 $\text{RMSE}_{\text{base}}$ ，将第 j 个驱动因子置乱后的验证误差记为 $\text{RMSE}_{\text{perm},j}$ ，则该因子的置乱重要性定义为：

$$I_j = \text{RMSE}_{\text{perm},j} - \text{RMSE}_{\text{base}} \quad (4.8)$$

其中， I_j 越大，说明当该因子的空间对应关系被破坏后，模型精度下降越明显，其对预测结果的贡献越高。为便于比较不同因子的相对作用强弱，进一步将全部因子的置乱重要性归一化为：

$$W_j = \frac{I_j}{\sum_{j=1}^m I_j} \quad (4.9)$$

其中， W_j 为第 j 个驱动因子的归一化重要性权重， m 为参与排序的驱动因子总数。

表 4.7 模型输入层权重范数与验证集置乱检验结果

驱动因子	L_1 范数	L_2 范数	RMSE _{base}	RMSE _{perm, i}	I_j
坡向	38.360	5.535	1.459	1.762	0.304
地形湿度指数	49.722	6.436	1.459	1.713	0.255
年均归一化植被指数变化量	35.988	4.778	1.459	1.651	0.192
土壤孔隙度 30-200cm	37.554	5.265	1.459	1.625	0.166
距离河流的距离	28.057	3.772	1.459	1.578	0.119
坡度	62.489	8.414	1.459	1.563	0.104
土壤孔隙度 0-30cm	37.088	4.882	1.459	1.554	0.095
土壤砾石含量 30-200cm	37.918	4.982	1.459	1.553	0.094
流动功率指数	37.384	4.938	1.459	1.552	0.093
土壤容重 0-30cm	22.296	2.981	1.459	1.520	0.061
土壤容重 30-200cm	21.532	2.835	1.459	1.509	0.050
固结可压缩敏感性指数 0-30cm	21.455	2.628	1.459	1.502	0.044
土壤粘粒含量 30-200cm	18.930	2.429	1.459	1.500	0.042
土壤砾石含量 0-30cm	26.814	3.490	1.459	1.496	0.038
土壤粘粒含量 0-30cm	22.608	2.868	1.459	1.493	0.035
距离断层的距离	10.550	1.521	1.459	1.485	0.026
海拔	49.984	7.195	1.459	1.472	0.013
距地铁线路的距离	11.789	1.510	1.459	1.460	0.002
平面曲率	8.424	1.044	1.459	1.459	0.000

基于上述原理，本研究所提出的沉降预测模型输入层权重范数与验证集置乱检验结果如表 4.7 所示，利用式(4.9)对 19 个驱动因子进行重要性权重归一化后，得到的重要性排序结果如图 4.6 所示。

排序结果表明，长沙市地表沉降的空间分异主要受地形水文条件、地表覆盖变化以及浅部地基土物性共同控制。换言之，模型所识别出的主导信息并未集中于单一类型变量，而是体现为河谷地貌背景、城市建设活动与浅部地基条件的综合作用，这与长沙实际地表环境和城市发展格局是相一致的。




图 4.6 沉降驱动因子重要性排序

可以发现，长沙市地表沉降的空间分异主要受地形水文条件、地表覆盖变化以及浅部地基土物性共同控制。换言之，模型所识别出的主导信息并未集中于单一类型变量，而是体现为河谷地貌背景、城市建设活动与浅部地基条件的综合作用，这与长沙实际地表环境和城市发展格局是相一致的，具体结论如下：

（1）坡向是影响长沙地表沉降空间分异的最重要因子。长沙主城区沿湘江两岸展开，城区与周缘岗地之间高程起伏连续过渡，坡向差异直接对应坡面排水方向、受光条件以及近地表干湿环境差异。在河谷平原与低丘岗地交错分布的地貌背景下，坡向能够较好地区分不同地形单元对应的浅层环境条件，因此当该信息被打乱后，模型预测精度下降最为明显。

（2）地形湿度指数是表征长沙沉降格局的重要控制因子。研究区地表沉降对汇水与滞水条件具有较强响应。长沙地区以湘江、浏阳河、捞刀河及其附属水系构成主要水文骨架，滨水冲洪积平原、河漫滩及低洼汇水区广泛发育，局部汇水条件会直接影响浅层土体的含水环境与压密条件，从而对沉降分布产生显著约束。

（3）距河流的距离能够有效表征长沙沉降分布对滨水地貌背景的依赖性。河流两侧不仅补给与排泄条件差异明显，而且沉积环境及地基类型也显著区别于周缘岗地区域，因此距河流的距离在本研究区内不仅具有水文边界意义，同时也可视作地基条件空间差异的重要代理变量。与此同时，坡度与流动功率指数在重要性排序中同样处于中上位次，进一步说明长沙地表沉降更受综合地形水文背景制约，而并非由单一几何起伏条件主导。

（4）年均归一化植被指数变化量反映了城市建设活动及地表环境演化对沉降格局的影响。其所承载的信息并不局限于植被状态本身，而是综合表征了地表硬化、植被退化、建设用地转换及工程扰动等过程。近年来，长沙城市扩展持续加快，湘江两岸新城开发、产业园区扩张、交通廊道建设及旧城更新活动较为集中，年均NDVI变化量因而能够较好表征城市建设活动背景下地表环境调整对沉降空间分

异的影响。

(5) 浅部孔隙度类因子是控制研究区沉降差异的重要土体物性指标。长沙沿湘江及其支流两侧广泛发育第四系冲洪积沉积层，浅部土体整体压缩性较强。在荷载作用及含水条件变化影响下，孔隙体积占比越高的土体越容易发生压密变形，因此孔隙度类因子在模型中表现出较高的重要性。

(6) 平面曲率与海拔对本研究沉降预测的独立贡献相对有限。所反映的微地形信息，在较大程度上已经被地形湿度指数、流动功率指数及坡度等更具过程指向性的指标所吸收和替代，因此在多因子共同参与建模的条件下，其边际贡献相对较弱。

(7) 距地铁线路的距离不是 2022—2024 年长沙地表沉降空间分异的主导控制因子。这一结果与长沙地铁建设时序及本文所采用的形变观测时段具有较好一致性。本文使用的 SAR 数据覆盖时间为 2022—2024 年，而长沙市大部分地铁线路已在 2022 年之前建成通车，其由开挖、降水、盾构推进及工后固结等过程引起的显著沉降主要集中发生于施工阶段及建成后的早期稳定阶段。因此，在本文对应的观测时段内，地铁工程对区域地表沉降的直接影响已明显减弱。该因子权重较低并不意味着地铁建设不会引起沉降，而是表明模型识别出的主导控制信息与 2022—2024 年期间实际持续作用的沉降过程具有较好一致性，从侧面说明了模型识别结果具有较强的时效性与合理性。

4.5 模型预测结果与验证

基于前文确定的最优沉降预测模型，本文进一步开展长沙市研究区连续沉降场预测。模型训练阶段以统一参考网格下的多源沉降驱动因子为输入，将每个待训练位置周边的 10m 栅格像元组织为局部 Patch 图样本；模型输出为该 Patch 中心节点的累计沉降预测值，并以经旁瓣效应剔除、温度相关形变剔除及交叉验证后的 Sentinel-1 PS-InSAR 累计沉降结果作为沉降监督标签，通过预测值与标签值之间的损失计算完成参数优化。在此基础上，预测阶段则将研究区范围内具有完整驱动因子覆盖的 10m 栅格像元作为待估位置，逐像元构建局部 Patch 图样本并输入训练完成的图神经网络模型，从而将“多源沉降驱动因子—局部空间邻域—累计沉降响应”之间的映射关系推广至无 PS 点覆盖区域，获得长沙市研究区连续沉降预测结果，如图 4.7 所示。

为检验预测结果的可靠性，本文进一步选取 COSMO-SkyMed 高分辨率影像 PSI 结果和现场踏勘结果作为独立验证依据。其中，COSMO-SkyMed 影像 PSI 结果主要用于对 A1、A2 和 A3 等典型区域的沉降异常位置、数值量级及空间分布形态进行对比验证，以判断基于 Sentinel-1 监督标签训练得到的模型是否能够在更高

分辨率观测结果中得到印证；现场踏勘结果则用于补充识别预测异常区内道路、硬化地坪及建筑周边是否存在裂缝、变形等实际病害迹象。通过多源驱动因子建模预测、COSMO-SkyMed 高分辨率 PSI 对比和现场调查相互印证，可进一步评价模型预测结果在区域尺度沉降异常识别中的可靠性。




图 4.7 长沙市沉降预测结果

为进一步验证模型预测结果的可靠性，本文在河西与河东地区分别选取了 3 处和 2 处预测表现出较明显沉降响应的典型区域开展实地核查，分别记为 A1、A2、A3 和 B1、B2，其空间位置如图 4.7 所示。所选区域均为连续沉降场中相对突出的局部异常斑块，具有一定代表性，能够较好反映模型对沉降异常区域的识别效果。

(1) A1 区域结果验证

图 4.8 展示了区域 A1 的沉降预测结果与 COSMO-SkyMed 影像 PSI 结果的对比情况。其中，预测结果显示该区域最大沉降值为 64.34mm，CSK 影像 PSI 结果对应的最大沉降值为 72.26mm，二者在数值量级上总体接近。就空间分布而言，两种结果表现出较强的一致性。模型预测结果表明，沉降异常主要集中于研究区中西部住宅建筑较为密集的区域，并呈现连续分布特征；在对应的 PSI 结果中，该区域同样分布有较为集中的大沉降值 PS 点，而周边厂房及道路区域整体以相对稳定为主。虽然二者在表达形式上分别表现为连续面状结果与离散点状观测，但在异常区位置、分布范围及空间变化趋势上总体吻合，这证明了所构建模型能够较好地反映

该区域的实际沉降特征。




图 4.8 区域 A1 的模型预测结果与 CSK 影像 PSI 结果



图 4.9 区域 A1 现场勘探结果

图 4.9 给出了区域 A1 的现场踏勘照片。由现场情况可见，该区域建筑周边已出现较为明显的变形病害，入户门前混凝土地坪可见贯通性裂缝，裂缝由门口台阶附近向外延伸；室内构件或饰面板表面出现斜向开裂；建筑外侧台基及勒脚部位可见较长的水平裂缝，部分裂缝沿建筑外缘连续分布。该区域建筑及其附属地坪已表

现出一定的不均匀变形特征，与模型预测结果及 CSK 影像 PSI 结果所反映的沉降异常位置具有较好的一致性。

值得注意的是，A1 区域在连续沉降场中对应的沉降漏斗规模最大，且沉降幅值最为显著，是本次区域预测中识别出的重点异常区。结合现场踏勘情况可见，该漏斗影响范围内已有多处房屋出现地坪开裂、墙体裂缝及台基开裂等变形病害，区域内建筑受沉降影响较为集中。鉴于 A1 区域沉降响应强、影响范围广，且已出现较为明确的建筑受损迹象，本文在本章完成现场核查后，将于第五章进一步针对该区域开展建筑变形风险评估。

(2) A2 和 A3 区域验证

图 4.10 和 4.11 给出了区域 A2 和 A3 的模型预测结果与 CSK 影像 PSI 结果对比。总体来看，两个区域中连续沉降场与 PSI 离散观测结果在空间分布上具有较好的一致性，模型识别出的沉降异常位置与 PSI 结果中大沉降值 PS 点的集中分布区域基本对应，预测结果能够较好反映局部沉降异常的空间格局。





图 4.10 区域 A2 的模型预测结果与 CSK 影像 PSI 结果


需要指出的是，在局部区域内，连续沉降预测结果与 COSMO-SkyMed 影像 PSI 点状观测结果并非完全一致，存在预测结果显示一定沉降响应，而对应位置附近 PS 点未表现出明显沉降的情况。对于此类区域，需要结合现场踏勘、周边地物条件及后续多时相观测进一步核查的潜在沉降线索。造成上述差异的原因可能与两类结果的数据表达形式和观测尺度有关。COSMO-SkyMedPSI 结果反映的是稳定散射体点位处的离散形变响应，其空间分布受散射体可识别性、点位密度和局部观测条件影响；连续沉降预测结果则是在多源沉降驱动因子和局部空间邻域关系约束下形成的面状估计结果，反映的是区域沉降响应的空间趋势。因此，在结果判读中，本文主要关注预测异常区与 COSMO-SkyMedPSI 结果在异常位置、沉降量级和空间形态上的整体对应关系；对于局部不一致区域，则保持谨慎解释，并结合现场调查结果进行辅助判断。



a) A3 区域模型预测结果

b) A3 区域 CSK 影像 PSI 结果

图 4.11 区域 A3 的模型预测结果与 CSK 影像 PSI 结果



a) 区域 A2-1

b) 区域 A2-2

c) 区域 A2-3

d) 区域 A3-1

e) 区域 A3-2

f) 区域 A3-3

图 4.12 区域 A2 与 A3 的现场勘探结果

如图 4.12 所示, A2 与 A3 区域的现场踏勘结果进一步验证了模型预测结果的可靠性。A2 区域中, A2-1 与 A2-2 可见道路路面及建筑周边硬化地坪存在明显裂缝, A2-3 则反映出建筑外墙下部存在局部异常痕迹, 说明该区域已出现较为明显的地表变形现象, 且异常主要集中于建筑周边与道路交接部位。

结合图 4.10 中模型预测结果与 CSK 影像 PSI 结果可以看出, A2 区域现场裂缝出现位置与预测沉降异常区具有较好的空间对应关系, 表明该区域局部沉降响应并非孤立现象, 而是与连续沉降场所揭示的异常分布相互印证。A3 区域中, A3-1 与 A3-2 可见较清晰的道路裂缝, A3-3 中局部立面构筑物表面亦可见裂缝迹象, 表明该区域除地表开裂外, 周边附属构筑物也已受到一定影响, 局部沉降响应已由

地表延伸至地上附属结构。结合图 4.11 可知, A3 区域预测沉降异常位置与 CSK 影像 PSI 结果中的较大沉降值 PS 点分布具有一定一致性, 现场裂缝现象进一步增强了该区域预测结果的现实依据。总体来看, A2 和 A3 区域现场均观测到较明显的裂缝及异常变形迹象, 且其分布位置与连续沉降场识别出的异常区总体一致, 进一步验证了模型预测结果能够较准确地反映研究区局部沉降异常的实际空间分布特征。

(3) B1 和 B2 区域验证

B1 和 B2 区域的连续沉降场结果见图 4.13, 与 A1 至 A3 区域不同, 位于河东的 B1 和 B2 区域不在 COSMO-SkyMed 影像覆盖范围内, 因此无法采用高分辨率 PSI 结果对模型预测结果进行直接对比验证。鉴于此, 本文主要结合连续沉降场所识别出的异常位置, 进一步开展现场踏勘。




图 4.13 B1 与 B2 区域的模型预测结果

如图 4.14, 踏勘结果显示, B1 和 B2 区域均可观察到较为明显的沉降相关病害, 说明模型在该区域识别出的局部沉降异常具有较好的现实对应性。此外, 公开报道中亦有关于该 B2 区域相关小区楼栋墙体沉降开裂问题的反映, 该问题在业主交付入住后的前期阶段即已受到持续关注, 具有一定延续性。结合连续沉降场结果、现场踏勘情况及公开信息可知, B2 区域所识别出的沉降异常具有较好的现实依据。

此外, 为进一步展示模型在长沙市主要城市建成区范围内的区域化预测效果, 本文结合连续沉降场整体分布特征, 选取了 12 个具有代表性的主要城市区域进行统一展示, 其空间位置及编号如图 4.15 所示。所选区域总体覆盖了研究区中部核心建成区、西部延伸区及东部主要发展片区, 能够较全面反映模型在不同城市功能背景和不同空间位置条件下的沉降预测表现。考虑到第四章重点在于对模型预测结果的整体可靠性及典型异常区识别效果进行验证, 因此各区域的连续沉降场具体分布结果不再于正文中逐一展开, 其详细展示见附录 A。




图 4.14 区域 B1 与 B2 的现场勘探结果




图 4.15 长沙市主要城市区域沉降预测结果位置分布图

4.6 本章小结

本章围绕图神经网络沉降预测模型，提出区域尺度模型验证与结果分析方法，解决输入因子、网络结构及预测可靠性需系统检验的问题。通过构建统一的对比实

验体系，分别从沉降驱动因子筛选、网络结构消融、模型性能评估、驱动因子重要性分析和典型区域验证等方面展开研究，以综合判断所建模型在城市尺度沉降预测与异常区识别中的适用性。

（1）基于皮尔逊相关性分析对驱动因子进行相关性筛查，提高了模型输入的有效性。结果表明，经共线性筛查后保留的 19 个驱动因子能够在减少冗余信息干扰的同时，较好保留沉降控制因素的有效信息，模型在训练集、验证集和测试集上的综合预测效果均有所改善。

（2）通过消融实验，验证了 GraphSAGE 与多头 GAT 的耦合结构能有效提升沉降预测模型的局部空间关系表达能力。结果表明，本文所采用的混合网络结构能够更充分地提取局部邻域内的复杂空间关联信息，在整体精度和泛化能力方面均优于对照模型。

（3）基于多源对比结果，验证了所提沉降预测模型对沉降异常区的识别能力。通将与传统插值方法、高分辨率 PSI 观测结果及现场踏勘情况进行综合对比，验证了该模型能够识别区域尺度上的主要沉降异常区，且在典型局部区域中与 COSMO-SkyMed PSI 结果及现场病害迹象具有一定对应关系。

第5章 区域沉降场精细化构建与变形风险评估研究

5.1 引言

前述研究主要实现了城市级区域尺度地表沉降的识别与预测，为沉降风险的宏观判识提供了基础，但对于单体建筑或建筑群的精细化评估而言，现有结果仍存在一定局限。受当前数据获取条件和技术分辨率限制，已有驱动因子的最高空间分辨率仅为 10 m，难以充分表征单栋建筑物及其邻近建筑之间的局部变形差异，无法满足单独建筑物的精细化变形风险评估。部分研究者通过 IDW 插值方法，基于高分辨率 SAR 影像的 PS-InSAR 结果，构建了高分辨率的连续沉降场对建筑物进行综合风险评估。连续变形场的精度直接决定了建筑风险评估的结果，由于 PS 点在空间上的分布通常表现出显著的不均匀性与聚集性，传统的连续变形场构建方法在面对数据聚集现象时常常难以产生理想的结果。为此，本章旨在探讨基于 PS 点数据分布特性的最佳连续变形场构建方法，提出一种能够充分挖掘有限且离散点位信息的建筑群区域精细化连续沉降场构建方法，并基于该沉降场对建筑进行精细化变形风险评估。

5.2 传统插值方法原理与局限性

在基于 MT-InSAR 离散 PS 点形变结果构建连续沉降场时，常用插值方法可按未知位置变形值的求取依据概括为两种基本思路。一种方法主要依据待估点周边观测点的空间邻近关系进行加权估算，即利用距离远近、邻域范围等几何信息直接推求未知点的沉降值，反距离加权法即属于此类。另一种方法则将离散沉降值视为空间相关变量，先利用样点之间的空间相关结构建立统计模型，再据此估算未知点的沉降值，普通克里金法是最具代表性的形式。前者形式简明、实现便捷，但对样点空间分布较为敏感；当 PS 点受建筑散射条件影响而呈现局部聚集、分布不均甚至局部空缺时，插值结果容易受到样点配置方式的影响。后者能够在一定程度上刻画空间自相关特征，并可对估计误差进行量化，但其结果对变异函数模型及参数拟合较为敏感，在局部异质性显著的建筑群区域同样存在适用边界。鉴于本文研究对象为建筑周边高分辨率离散沉降点，且其空间分布具有明显的不均匀性，因此有必要先对反距离加权法与普通克里金法的基本原理及局限性进行说明，并以此作为后续改进插值方法构建与对比分析的基础。

5.2.1 反距离加权法原理与局限性

反距离加权法（Inverse Distance Weighting, IDW）是确定性插值方法中一种广

泛应用的技术。该方法的基本原理是通过已知数据点的加权平均来估算未知点的变形值，权重与已知点到插值点之间的距离成反比^[162]。具体而言，IDW 假设距离插值点较近的已知点对插值结果的影响较大，而距离较远的已知点对插值结果的影响较小，其数学表达式如(5.1)所示。式中 D_u 表示待求点的变形， $S_i (i=1,2,\dots,n)$ 表示已知变形点与待求点之间的距离， $D_i (i=1,2,\dots,n)$ 表示的是已知点的变形。

$$D_u = \frac{1}{\frac{1}{S_1} + \frac{1}{S_2} + \dots + \frac{1}{S_n}} D_1 + \frac{1}{\frac{1}{S_1} + \frac{1}{S_2} + \dots + \frac{1}{S_n}} D_2 + \dots + \frac{1}{\frac{1}{S_1} + \frac{1}{S_2} + \dots + \frac{1}{S_n}} D_n \quad (5.1)$$




图 5.1 反距离权重插值原理

IDW 插值方法计算效率较高、对计算资源需求较低，通常适用于采样点空间分布相对均匀的场景。然而，PS-InSAR 技术所获取的永久散射体（PS）点具有稳定的后向散射特性，其空间分布在实际应用中往往受建筑物结构差异的显著影响，呈现出明显的不均匀性。尤其在城市环境中，不同建筑物由于材料、结构及朝向等因素的不同，其表面可形成的稳定后向散射体数量差异较大。一方面，部分建筑物上可能分布有大量稳定的 PS 点；另一方面，一些建筑物上仅存在少量 PS 点，甚至完全缺乏稳定散射体。由此导致基于 PS-InSAR 解算得到的 PS 点在空间上普遍呈现高度不均匀的分布特征，这种不均匀特征会使得 IDW 插值结果在空间上出现严重偏倚，进而影响在连续沉降下的建筑变形风险评估结果。

图 5.2 示意了在 PS 点空间分布不均匀条件下，传统 IDW 方法产生的插值偏倚。图中 A 建筑周边分布有大量密集的 PS 点，而 B、C 及周边其他建筑附近的 PS 点数量明显较少，局部区域甚至接近缺失，反映出城市建筑环境中 PS 点受建筑材料、结构形式及观测几何条件影响所形成的显著空间不均匀性。由于传统 IDW 方法仅依据已知点与待估点之间的距离进行加权，而未考虑样点之间的聚集程度及采样冗余性，因此 A 建筑周边高密度 PS 点在插值过程中会对周边区域产生更强的控制作用，导致所构建的连续沉降场在 A 附近形成范围较大的高值区，并向邻近区域扩散。相比之下，B、C 等 PS 点较为稀疏的建筑区域，其插值结果更多受到邻近高密度样点簇的间接影响，难以真实反映各建筑自身的沉降特征。因此当 PS

点呈现局部聚集而整体分布不均时，传统 IDW 方法构建的连续沉降场在样点分布显著不均的条件下，往往更易受 PS 点空间密度格局的主导，难以准确表征真实沉降的空间变化特征，进而导致建筑尺度沉降场估计出现偏差。




图 5.2 不均匀 PS 点分布情况下 IDW 产生的错误估计

5.2.2 克里金插值原理

克里金插值 (Kriging) 是一种基于地统计学的插值方法^[163]，它通过对数据的空间相关性进行建模，利用变异函数或协方差函数来描述数据点之间的空间依赖性，从而对未知点的变形值进行估算。与确定性插值方法不同，Kriging 不仅考虑数据点之间的几何距离，还综合考虑了数据点之间的统计相关性，因此在处理空间分布不均或存在局部变异的数据时能够提供更为精确的插值结果。Kriging 基本原理是通过建立变异函数模型来刻画已知点之间的空间变化趋势，并利用该模型对未知点进行加权估算，其数学表达式如 (5.2) 所示。

$$D^*(x_0) = \sum_{i=1}^n \lambda_i D(x_i) \quad (5.2)$$

式中， $D^*(x_0)$ 为待求点的变形值， $D(x_i)$ 为已知点的变形值， λ_i 为对应已知点 x_i 的权重系数，由变异函数模型和已知点之间的空间关系确定。变异函数描述了在不同空间距离下数据点之间的变异程度，它是克里金插值的核心组成部分，其常见形式包括球状模型、指数模型和高斯模型等^[164]。

球状模型 (Spherical Model) 的数学表达式如式 (5.3) 所示，是描述空间数据中短距离内具有强相关性、长距离内相关性逐渐减弱的情形时常用的变异函数模型。

$$\lambda(h) = \begin{cases} C_0 + C_1 \left[1.5 \frac{h}{a} - 0.5 \left(\frac{h}{a} \right)^3 \right], & \text{if } 0 \leq h \leq a \\ C_0 + C_1, & \text{if } h > a \end{cases} \quad (5.3)$$

指数模型 (Exponential Model) 的数学表达式如式 (5.4) 所示, 用于描述数据点之间的空间相关性逐渐衰减的情况, 特别是在空间数据的变异性随着距离增加而迅速减弱时。

$$\lambda(h) = C_0 + C_1 \left[1 - \exp \left(-\frac{h}{a} \right) \right] \quad (5.4)$$

高斯模型的数学表达式如式 (5.5) 所示, 用于描述数据点之间空间相关性衰减速率较缓的情况, 尤其是在数据点之间的变异性随着距离增加而呈现平滑下降趋势时。

$$\lambda(h) = C_0 + C_1 \left[1 - \exp \left(-\left(\frac{h}{a} \right)^2 \right) \right] \quad (5.5)$$

在式 (5.3) 至 (5.5) 中, $\lambda(h)$ 表示变异函数, h 为两个数据点之间的距离, C_0 为块金值 (nugget), 反映测量误差和微尺度随机变异引起的非连续性, C_1 为结构方差, a 为变异范围。

Kriging 插值并非仅依据样点之间的距离关系进行加权估计, 而是首先在区域化变量理论框架下, 假定研究对象满足一定的空间平稳性条件, 并结合样本数据的空间分布特征, 对其空间相关结构进行分析; 在此基础上, 通过构建实验变异函数, 并选取合适的理论变异函数模型进行拟合, 确定块金值、基台值和变程等关键参数, 最后求解 Kriging 方程组以获得各已知点对待估点的最优无偏权重, 从而实现待插值点数值的估计。

尽管引入了空间自相关性建模, Kriging 方法能一定程度上反映局部变异特征, 在片区尺度中构建的连续沉降场效果要优于 IDW, 但其对异常值敏感且计算复杂度高, 且 Kriging 的性能往往取决于变异函数模型的选取, 因此要具有大量的先验知识, 由于变形源复杂且多样, 难以获取充分的先验数据, 同时由于城市变形机制的不明确性, 会导致变异函数无法准确反映数据的空间结构, 严重影响城市区域内连续变形场构建的准确性。

5.3 考虑数据自相关性的反距离加权法

5.3.1 考虑数据自相关性的反距离加权法原理

为减弱 PS 点局部聚集分布对传统 IDW 插值结果的主导作用, 本文在 IDW 权重计算框架中, 除考虑已知点 D_i 与待估点 D_u 之间的距离衰减关系外, 进一步引入

已知点 D_i 与其他已知点之间的相对距离，用以刻画已知观测点在局部邻域中的聚集程度。当某一已知点周围存在较多距离较近的已知观测点时，说明该点所表征的空间信息与邻近已知观测点之间具有较强重复性，其权重应适当降低；反之，当某一观测点与周围其他已知观测点距离较大时，表明其所代表区域已知观测点相对稀疏，该点所携带的信息具有更强的补充作用，其权重可相应提高。基于这一思路，改进后的方法能够在保留距离衰减特征的同时，削弱局部密集样点的过度影响，增强稀疏区域样点对插值结果的有效贡献，从而使所构建的连续沉降场更接近真实空间分布格局。本文提出的考虑数据自相关性的反距离加权法的数学表达式如式 (5.6) 所示：

$$D(u) = \sum_{i=1}^m \omega_i(u) D_i \quad (5.6)$$

式中， D_u 表示未知点 u 的估计变形值， D_i 表示第 i 个 PS 点的变形值， ω_i 表示第 i 个 PS 点在未知点 u 上的变形值贡献权重，其数学表达式如式 (5.7) 所示：

$$\omega_i(u) = \frac{S(u,i)^{-p_1} \cdot \sum_{j=1}^m S(i,j)^{p_2}}{\sum_{k=1}^m \left[S(u,k)^{-p_1} \cdot \sum_{j=1}^m S(k,j)^{p_2} \right]} \quad (5.7)$$

式中， $S(u,i)$ 表示第 i 个 PS 点到未知点 u 上的距离， $S(i,j)$ 表示第 i 个 PS 点到第 j 个 PS 点的距离， p_1 为距离衰减强度指数， p_2 为聚集修正强度指数。 $S(u,i)^{-p_1}$ 反映已知观测点对待估点的直接距离影响，即已知观测点越接近待估点，其对插值结果的作用越强； $\sum_{j=1}^m S(i,j)^{p_2}$ 则用于反映该已知观测点在局部邻域中的空间聚集状态。




图 5.3 考虑数据自相关性的反距离加权法机制图

图 5.3 对上述权重调节机制进行了示意说明。图左侧为抽象样点分布情形，其

中上部黄色点簇表示局部高度聚集的样点集合，下部蓝色点表示相对离散分布的样点集合。在改进权重机制下，聚集样点由于彼此距离较近、信息重复性较强，其综合权重将受到聚集抑制；而离散样点由于周边缺少相邻观测、空间代表性相对更强，其综合权重将获得稀疏补偿。图右侧则将这一机制对应到建筑场景中，建筑 A 周边分布有大量密集 PS 点，而建筑 B、C 及周边建筑上的 PS 点数量相对较少。在引入已知观测点间距离修正后，建筑 A 周边密集样点的冗余影响得到抑制，而 B、C 等区域有限样点的局部表征作用得到增强，因此可获得更稳定、更加符合实际空间分异特征的连续沉降场。

5.3.2 全局常数与局部变化指数的确定方法

由式 (5.7) 可知，距离衰减强度指数 p_1 用于控制已知观测点对待估点的距离衰减强度，聚集修正强度指数 p_2 用于控制局部聚集已知观测点的权重抑制程度，二者的取值将直接影响连续沉降场的构建结果，因此有必要进一步讨论其确定方式。基于此，本节分别从全局常数与局部变化指数两个层面，对 p_1 与 p_2 的确定方法进行分析。

(1) 全局常数指数的选取方法

采用全局常数策略时，所有待插值位置均采用统一的参数组合进行权重计算。本文采用基于留一交叉验证 (Leave-One-Out Cross-Validation, LOOCV) 的遍历搜索方法^[165]，在预设范围内寻找最优距离衰减强度指数 p_1 或聚集修正强度指数 p_2 ，具体流程如图 5.4 所示。该方法以参与插值的 PS 点为验证对象，通过逐点模拟“该点未知、其余点已知”的插值场景，考察不同全局常数取值下模型对已知样本的重建能力，从而评价参数组合对区域整体连续沉降场构建的适用性。相较于仅依赖单次训练—验证划分的方式，留一交叉验证能够充分利用全部样本信息，并减少验证结果对样本划分偶然性的依赖，使所得最优参数更具稳定性和代表性。

首先，在预设的候选参数范围内，依次选取不同的 p_1 或 p_2 ，对参与插值的 PS 点开展逐点留一检验，每次从样本集中剔除一个 PS 点，将其视为待估点，其余 PS 点作为已知样本，依据式 (5.6) 和式 (5.7) 对该点的形变值进行反演预测。其次，将预测结果与其真实观测值进行比较，通过式 (4.2) 与式 (4.3) 计算在该点 RMSE 与 MAE，并记录在当前候选指数下的单点预测偏差。完成一个样本点的检验后，再继续剔除下一个 PS 点，重复上述过程，直至所有参与插值的 PS 点均完成一次循环。由此，可在同一候选参数条件下获得覆盖全部样本点的整体误差结果。最终，在候选参数空间内选取整体误差最小的 p_1 或 p_2 作为最优全局常数，并基于该常数进行连续沉降场的构建。




图 5.4 全局常数指数的选取流程图

(2) 局部变化指数的选取方法

与全局常数情形不同，局部变化指数的选取不再追求适用于全区域的统一最优参数，而是针对每一个待估位置，在其局部邻域范围内确定更符合该处点位分布特征和形变空间结构的指数取值，由此得到的 $p_1(x_0)$ 或 $p_2(x_0)$ 是随空间位置变化的参数场，具体流程如图 5.5 所示。

局部变化指数的确定仍采用基于留一交叉验证的误差最小化思想，但其评价尺度由全区域转变为待估位置 x_0 的局部邻域 $N(x_0)$ 。具体而言，对于任一待估位置，首先依据统一的邻域搜索规则提取其邻域样点；随后在预设候选范围内对参数组合进行逐一检验，并在该邻域内部开展留一交叉验证，即依次剔除一个邻域样点，剩余样点按照式 (5.6) 与式 (5.7) 进行插值估计，最后利用 RMSE 和 MAE 选取局部交叉验证误差最小的参数作为该待估位置的最优变化指数。本选取方法的实质是将参数选取过程由全区域统一寻优转化为局部邻域独立寻优，从而使指数参数能够随 PS 点局部聚集程度、空间分布结构及形变非平稳特征的变化而自适应调整，使插值结果更符合真实的沉降场。




图 5.5 局部变化指数的选取流程图

5.3.3 基于考虑数据自相关性 IDW 的四种插值模型

由全局常数指数与局部变化指数的确定方法可知,采用单一局部变化指数进行插值所花费的计算时间,根据 PS 点量级的不同,所花费的时间是全局常数指数的几十倍至几百倍。基于此本文根据不同的指数选取方法,构建了四种插值模型,研究基于全局常数指数与局部变化指数构建的不同连续沉降场之间的精度差异,四种插值模型的设计如表 5.1 所示。

表 5.1 基于考虑数据自相关性 IDW 的四种插值模型设计

插值模型	距离衰减强度指数 p_1	聚集修正强度指数 p_2
模型 1	全局常数指数	全局常数指数
模型 2	全局常数指数	局部变化指数
模型 3	局部变化指数	全局常数指数
模型 4	局部变化指数	局部变化指数

5.4 研究区域与实验设计

5.4.1 研究区域及数据

在第四章模型预测结果验证中, 区域 A1 在连续沉降场中表现为本研究识别出的沉降响应最强、影响范围最广的重点异常区。将该区域的模型预测结果与 3m 分辨率 COSMO-SkyMed 影像获取的 PSI 结果进行对比可见, 两者在沉降异常位置、分布范围及空间变化趋势上总体一致; 同时, 现场踏勘结果表明, 区内建筑周边地坪、台基及墙体等部位已出现不同程度的开裂与变形病害, 其空间分布与沉降异常区具有较好的对应关系。基于上述结果, 说明该区域不仅具有较为显著的沉降异常特征, 而且已表现出一定的建筑受损迹象, 因而具有进一步开展建筑尺度精细化分析的代表性。




图 5.6 研究区域 PS 点分布情况

为此, 本文选取该小区作为本章研究区域, 基于 COSMO-SkyMed 影像 PSI 结

果构建研究区高分辨率的连续沉降场，并基于连续沉降场进行单栋建筑的精细化变形风险评估。在连续沉降场构建前，本文继续采用 3.3.5 节所述的温度变形剔除方法，对研究区内具有显著温度相关变形特征的 PS 点进行剔除，以尽可能减弱建筑上部结构温度响应对沉降信息提取的干扰。处理后，研究区内共保留 1249 个有效 PS 点。为对后续插值结果开展独立精度验证，并尽量降低样本空间分布不均对验证结果的影响，本文采用均匀随机抽样方式，从中选取 100 个 PS 点作为验证样本，并将其 PSI 观测沉降值作为精度评价的参考值；其余 1149 个 PS 点则用于连续沉降场构建。参与插值的 PS 点与验证样本的空间分布如图 5.6 所示。

5.4.2 实验设计

为验证本文所提出的四种插值模型对连续沉降场精度的提升效果，引入传统 IDW 与普通克里金 (Ordinary Kriging, OK) 作为外部基准方法，所有距离项 $S(u, i)$ 、 $S(i, j)$ 均在投影坐标系下采用欧氏距离计算。


四种插值模型的 p_1 与 p_2 指数范围设置从 0.0 到 20.0，步长为 0.1。对于局部变化指数的邻域搜索算法采用结合固定半径邻域与最小点数保护的策略，固定半径取 $r = 25\text{m}$ ，当某一邻域内的 PS 点数量少于 20 时，通过逐级扩大半径的方式确保邻域内至少有 20 个 PS 点进行局部参与权重归一化。在利用参与插值的 PS 点完成 1m 分辨率连续沉降场栅格构建后，通过 100 个验证 PS 点进行精度评估，采用式 (4.1) 至 (4.4) 的四种经典误差测量方法对四种插值模型和两种外部基准插值方法进行精度评估。

5.4.3 实验结果

(1) 全局常数指数的最佳指数分析

图 5.7 给出了插值模型 1 在 (p_1, p_2) 参数空间内不同评价指标的等值线分布。整体上，误差指标的低值区集中出现在 $p_2 \in (3, 4)$ 的区域；当 p_2 取值偏小时，MAE、MSE 与 RMSE 均明显增大，表现出对聚集区 PS 点权重失衡的敏感性。与此同时， p_1 在较小取值范围内对误差下降贡献更为显著，随后进入相对平缓的低误差平台区。

从最优参数结果来看，MAE 指标的最优点为 $p_1 = 8.8$ 、 $p_2 = 3.9$ ，对应的 MAE 为 4.940； R^2 、MSE 以及 RMSE 指标的最优点一致，均为 $p_1 = 3.4$ 、 $p_2 = 3.2$ ，对应的 R^2 、MSE 和 RMSE 分别为 0.8564、76.597 和 8.752。考虑到有三相评估指标的最优质均在 $p_1 = 3.4$ 、 $p_2 = 3.2$ 时取得，且此时 MAE 的值可以接受，最终将 $p_1 = 3.4$ 、 $p_2 = 3.2$ 作为最优全局常数指数参数用于插值模型 1 的后续连续变形场构建以及作为后续模型 2 和模型 3 的全局参数基准。


 图 5.7 插值模型 1 的 p_1 与 p_2 等值线图

(2) 全局常数指数交叉验证

为进一步验证 5.4.3.1 中所确定的全局常数指数 $p_1 = 3.4$ 、 $p_2 = 3.2$ 的合理性，本节分别在插值模型 2 和插值模型 3 中，对不同全局常数指数下的相关解释精度进行分析。

图 5.8 给出了插值模型 2 在不同全局 p_1 取值下的精度变化结果，随着全局 p_1 的增大，插值模型 2 的各项评价指标总体呈现先优化后劣化的变化特征。当 p_1 由 0 增大到 2~4 时，MAE、MSE 与 RMSE 明显下降，而 R^2 快速升高，表明适度增强距离衰减作用后，插值结果能够更有效地反映近邻 PS 点对待估点的控制作用，从而提高模型精度。当 p_1 继续增大至 4 以上时，各误差指标逐渐回升， R^2 相应下降，说明距离衰减作用过强后，权重过度集中于极近邻 PS 点，使模型对邻域整体样点信息的利用不足，反而会降低模型对整体空间信息的综合表征能力。从图中整体趋势看，插值模型 2 的较优取值区间主要集中在 $p_1 = 3$ 附近，且该区间附近曲线变化较为平缓，说明该参数范围内模型精度具有较好的稳定性，这表明插值模型 1 中所确定的最优全局 $p_1 = 3.4$ 在插值模型 2 中同样具有较好的适用性。




图 5.8 不同 p_1 指数下插值模型 2 估算值的相关解释精度 a) MAE; b) MSE; c)RMSE; d) R^2




图 5.9 不同 p_2 指数下插值模型 3 估算值的相关解释精度 a) MAE; b) MSE; c)RMSE; d) R^2

图 5.9 给出了插值模型 3 在不同全局 p_2 取值下的精度变化结果，其与插值模型 2 表现出相似规律。 p_2 最优区间位于 3~4 之间，可以验证插值模型 1 中所确定的最优全局 $p_2 = 3.2$ 在插值模型 3 中同样具有较好的适用性。通过插值模型 1 与插值模型 2 和 3 之间的交叉验证结果可以发现，当一个指数由全局常数转为局部变化指数后，另一个指数的较优取值区间并未发生明显偏移，表明距离衰减强度指数 p_1 与聚集修正强度指数 p_2 在同一研究区域内具有较强的参数稳定性和较弱的耦合性，二者的合理取值基本不受另一指数取值方式变化的显著影响。换言之，插值模型 1 获取的某区域最优全局指数反映了该区域沉降的空间分布规律，其结果在同一研究区域内可以直接用于插值模型 2 和 3 中进行更高精度的连续沉降场构建。

（3）最佳局部变化指数分析

局部变化指数策略以未知点 x_0 的邻域 $N(x_0)$ 为单位，采用局部 LOOCV 误差最小原则分别确定距离衰减强度指数与聚集修正强度指数的最优取值，进而形成随空间位置变化的参数场 $p_1^*(x_0)$ 和 $p_2^*(x_0)$ ，本研究区域的两类最佳指数空间分布特征分别如图 5.10 和图 5.11 所示。




图 5.10 最佳距离衰减强度指数 $p_1^*(x_0)$ 的空间分布特征

从图 5.10 中可以发现， $p_1^*(x_0)$ 整体表现为低值占主导、局部高值突增的分布格局。研究区大部分区域以低值为主，表明在这些位置的局部最优权重分配并不需要过强的距离衰减，即允许一定范围内的已知 PS 点共同参与估计更有利于降低局部交叉验证误差。这类区域通常对应沉降空间变化相对连续、梯度较缓以及 PS 点较为均衡的情形，此时权重不会过度集中于极近邻点，可缓解由于单个近邻异常或噪声导致的估计波动，提升局部泛化能力。而图中部分线状和斑块状区域出现显著高值带，表明这些位置需要更强的距离衰减来突出近邻样点的主导作用。

如图 5.11 所示, 最佳聚集修正强度指数 $p_2^*(x_0)$ 的空间分布特征呈现明显的碎片化斑块结构, 表现出更频繁的高低值交替。从机理上看, 存在明显聚集效应的 PS 点时, 若仅依赖距离衰减, 聚集区样点会因数量优势与空间接近性获得过高综合权重, 导致估计结果对聚集区信息过拟合, 并向外产生偏倚传播。此时局部寻优倾向于给出较大的 p_2 , 以增强对聚集点权重的抑制来改善权重失衡问题。相反, 在点位分布较均匀或聚集性不显著的区域, 过大的 p_2 会不必要地削弱有效观测信息, 甚至造成估计更多受稀疏点控制而精度下降, 因此这些区域多对应较低的 p_2 。




图 5.11 最佳聚集修正强度指数 $p_2^*(x_0)$ 的空间分布特征

(4) 插值模型性能对比

图 5.12 展示了四种插值模型和两种传统插值方法在 100 个独立验证 PS 点处的估计值与真实值的散点图, 六种插值方法的精度与计算时间如表 5.2 所示。

表 5.2 六种插值方法的精度与计算时间

插值方法	MAE	MSE	RMSE	R^2	计算时间
插值模型 1	5.172	76.597	8.752	0.857	17min4s
插值模型 2	4.389	59.274	7.699	0.876	5h29min6s
插值模型 3	4.321	58.629	7.657	0.885	5h29min43s
插值模型 4	3.561	45.279	6.729	0.911	6d21h33min28s
IDW	5.519	98.129	9.906	0.808	8min18s
Kriging	5.150	82.319	9.073	0.839	11min19s

由表 5.2 可知, 不同插值方法的估算精度存在明显差异。总体上, 四种考虑数据自相关性的改进模型均优于传统 IDW 和 Kriging, 其中插值模型 4 的综合精度最高, 其 MAE、MSE 和 RMSE 分别为 3.561、45.279 和 6.729, R^2 为 0.911; 插值

模型 2 和插值模型 3 次之，且二者均优于插值模型 1；传统 IDW 误差最大、 R^2 最低。




图 5.12 六种插值方法在 100 个验证 PS 点处的估算值与实际值的散点图

结合图 5.12 的散点分布特征可以看出，随着模型由全局常数形式逐步过渡到局部变化形式，估算值与真实值整体上不断向 1:1 参考线收敛，说明局部自适应策略能够更有效地表征研究区 PS 点分布不均匀及沉降空间异质性特征。其中插值模型 3 略优于插值模型 2，表明在本研究区内对距离衰减强度进行局部调整所带来的精度提升略高于对聚集修正强度进行局部调整；插值模型 4 进一步同时对两个指数进行局部寻优后取得最优结果，说明距离效应与聚集效应的联合局部表征更有利于提高连续沉降场的构建精度。

同时，表 5.2 表明插值精度的提升伴随着计算代价的显著增加。传统 IDW、Kriging 和插值模型 1 的计算时间均处于分钟级，插值模型 2 和插值模型 3 增至小时级，而插值模型 4 达到天级。由此可见，不同方法在精度与效率之间存在明显权衡关系。若以连续沉降场构建精度为首要目标，插值模型 4 可作为本研究区的最优方案；若综合考虑精度提升与计算效率，插值模型 3 则表现出更好的应用适宜性。

(5) 基于 IDW 与插值模型 4 的连续沉降场构建结果

为进一步说明最优插值模型在连续沉降场构建中的实际表现，本文在展示插值模型 4 结果的同时，引入传统 IDW 所得连续沉降场作为对照。如图 5.13 所示，传统 IDW 结果整体较为平滑，研究区西侧及北部形成了范围较大的连续高值过渡区，局部沉降异常存在一定程度的扩散现象，部分建筑周边的沉降响应边界不够清晰。相比之下，插值模型 4 所构建的连续沉降场中，沉降高值区的局部集中性更强，异常区域之间的分离度更高，建筑周边沉降梯度变化也更加明确，更有利于反映研究区建筑尺度下的差异沉降特征。




图 5.13 基于不同插值方法的连续沉降场构建结果

从定量结果看，插值模型 4 在 100 个验证 PS 点上的 MAE、MSE、RMSE 和 R^2 分别为 3.561、45.279、6.729 和 0.911，而传统 IDW 分别为 5.519、98.129、9.906

和 0.808。相较于传统 IDW, 插值模型 4 的 MAE 降低约 35.5%, MSE 降低约 53.9%, RMSE 降低约 32.1%, R^2 提高 0.103, 表明二者差异并非仅体现在连续沉降场的图面形态上, 而是对应着验证精度的实质改善。表 5.2 同时表明, 插值模型 4 在六种方法中具有最高的综合精度, 因此其连续沉降场结果能够更可靠地作为后续建筑变形风险评估的基础输入。

综合连续沉降场空间分布与验证结果可知, 传统 IDW 虽能够反映研究区沉降场的总体变化趋势, 但在局部异常范围控制和建筑周边空间分异表达方面仍存在不足; 插值模型 4 则能够在保持整体沉降格局的同时, 更清晰地刻画局部沉降异常的集中范围及其边界特征。考虑到后续单栋建筑风险评估对连续沉降场局部细节表达能力具有较高要求, 本文最终选取插值模型 4 所构建的连续沉降场作为后续分析的基础数据。

5.5 基于连续沉降场的建筑变形风险评估

5.5.1 基于连续沉降场的建筑变形风险评估方法

基于研究区内的最优连续沉降场结果, 本文进一步开展面向单栋建筑的变形风险评估。参考周云等^[166]提出的建筑级风险评估思路, 从结构损伤风险与整体变形风险两个层面进行建筑变形风险综合评价。其中, 结构损伤风险是指建筑因差异沉降或横向扭转而产生不利附加应力的风险, 该类风险直接影响建筑结构安全; 整体变形风险则主要反映建筑因整体下沉、整体倾斜及持续变形而影响正常使用功能的的风险。基于此, 本文选取沉降曲线挠度比、横倾曲线挠度比、最大沉降量、纵向倾角、最大横倾角和近期沉降量 6 项指标构建建筑综合风险评估体系。需要说明的是, 不同结构类型对差异沉降和倾斜变形的敏感性并不相同。本文研究区域内重点关注的建筑以砌体结构为主, 此类建筑整体性和变形协调能力相对有限, 墙体开裂、门窗变形及局部沉降裂缝往往对差异沉降较为敏感。

本文以研究区建筑白膜矢量、累计连续沉降场和近半年沉降增量场为基础进行建筑级指标提取。首先, 根据建筑多边形最小外接矩形的长边方向确定建筑主轴方向, 将其作为建筑纵向方向。随后, 沿建筑主轴方向等距布设纵向分析位置, 并在每个位置上构建一条横向剖面, 从累计连续沉降场中提取剖面两端的沉降值。最后, 利用各横向剖面的平均沉降构建建筑纵向沉降曲线, 并基于剖面两端沉降差构建横倾角曲线。

在获得风险区域变形场基础上, 可提取建筑沉降值绘制沿纵向的沉降曲线。依据沉降曲线的形态, 将建筑沉降变形分为图 5.14 所示的 4 种模式。

设建筑沿纵向共提取 m 个有效分析位置, 第 i 个位置的纵向坐标为 x_i , 对应横向剖面两端的累计沉降值分别为 D_i^L 和 D_i^R , 则该位置的代表性纵向沉降量 d_i 的计

算公式如式 (5.8) 所示:

$$d_i = \frac{D_i^L + D_i^R}{2} \quad (5.8)$$




图 5.14 建筑沉降示意图^[166]

建筑的纵向倾角 η 用于刻画建筑沿主轴方向的整体倾斜程度, 其计算公式如式 (5.9) 所示:

$$\eta = \left| \frac{d_m - d_1}{x_m - x_1} \right| \quad (5.9)$$

式中, d_1 和 d_m 分别为建筑纵向沉降曲线起点和终点的沉降值; x_1 和 x_m 分别为对应位置的纵向坐标。

如图 5.14 中的沉降模式 I 和沉降模式 II 所示, 当严重纵向不均匀沉降导致建筑发生弯曲变形时, 建筑可能产生不利于结构安全的附加弯曲应力, 此时通过简化 Finno 等^[167]提出的方法计算沉降曲线挠度比衡量建筑产生不利附加应力的风险程度。如式 (5.10) 所示, 首先以建筑纵向沉降曲线首尾两点构造弦线 $\hat{d}_i$:

$$\hat{d}_i = d_1 + \frac{d_m - d_1}{x_m - x_1} (x_i - x_1) \quad (5.10)$$

则沉降曲线挠度比 ω_d 的计算式如式 (5.11) 所示:

$$\omega_d = \frac{\max_{1 \leq i \leq m} |d_i - \hat{d}_i|}{x_m - x_1} \quad (5.11)$$

式中, $\hat{d}_i$ 为第 i 个纵向位置在首尾连线上的理论沉降值, $|d_i - \hat{d}_i|$ 为第 i 个纵向位置相对于弦线的挠度偏差。

为表征建筑横向扭转或横向倾斜效应，在每个纵向位置上利用横向剖面两端沉降差定义局部横倾角，如式（5.12）所示：

$$\theta_i = \frac{D_i^R - D_i^L}{B_i} \quad (5.12)$$

式中， θ_i 为第 i 个纵向位置的局部横倾角， B_i 为该横向剖面的有效宽度。当建筑平面形态较规则时， B_i 近似等于建筑宽度 B 。

与纵向弯曲变形类似，当房屋沿横向发生严重不均匀沉降时会具有扭转变形风险，故采用横倾曲线挠度比 ω_θ 衡量其产生扭转附加应力的风险程度，其计算方法与沉降挠度曲线基本一致，唯一的区别在于采用局部横倾角 θ_i 代替沉降值 d_i 。

最大沉降量 $d_{\max}$ 和最大横倾角 $|\theta_{\max}|$ 可以直接通过沉降曲线和横倾角曲线进行提取，近期沉降量 Δ_d 取建筑近半年各点沉降增量的平均值。在完成上述 6 项指标提取后，本文采用相对综合风险值进行建筑风险量化，计算方法如式（5.13）所示：

$$R_j(\%) = \sum_{i=1}^n \left(\frac{I_{ij}}{I_{i,\max}} P_i \right) \quad (5.13)$$

式中， R_j 为第 j 栋建筑的综合风险值， I_{ij} 为第 j 栋建筑在第 i 项指标上的取值， $I_{i,\max}$ 为研究区内全部建筑在第 i 项指标的最大值， P_i 为第 i 项指标的权重，具体如表 5.3 所示。

表 5.3 风险评估指标占比^[166]

风险类别	评估指标 I_i	占比 $P_i/\%$	累计占比/%
结构损伤	沉降曲线挠度比 ω_d	40	50
	横倾曲线挠度比 ω_θ	10	
	最大沉降量 $d_{\max}$	10	
整体变形	纵向倾角 η	10	50
	最大横倾角 $ \theta_{\max} $	10	
	近期沉降量 Δ_d	20	

5.5.2 建筑风险评估结果与空间分布特征

（1）数据准备

①建筑白膜矢量：本研究采用具有高度信息的城市建筑白膜数据限定单栋建筑的空间范围。建筑白膜数据通常由建筑物二维轮廓面及高度或楼层属性构成，可用于生成简化三维建筑体块模型。本文研究区域建筑白膜来源于水经微图平台获取的高德地图建筑物矢量数据，经坐标统一、属性检查与高度字段筛选后，为建筑主方向识别及剖面构建提供几何基础，研究区域的建筑白膜分布情况如图 5.15 所示。

②近半年沉降增量场：基于 2022 年 9 月 27 日至 2024 年 9 月 24 日的 COSMO-

SkyMed 数据 PSI 时序结果，本文提取了本章研究内 2024 年 3 月至 9 月的累计沉降值，通过插值模型 4 构建了该区域近半年的沉降增量场，结果如图 5.16 所示。



图 5.15 研究区域建筑白膜矢量示意图




图 5.16 基于插值模型 4 的研究区域近半年沉降增量场

(2) 建筑风险评估结果

基于研究区域的最优连续沉降场与近半年沉降增量场，结合具有高度信息的城市建筑白膜矢量，本文完成了研究区单栋建筑的变形风险评估，建筑风险分级结果如图 5.17 所示，统计结果见表 5.4。

结合图 5.17 与图 5.13 可以发现，低风险和较低风险建筑主要分布于沉降幅值相对较小、沉降场变化较为平缓的区域；中风险及较高风险建筑则更多出现在沉降梯度变化较明显的过渡区域；风险等级为高风险的建筑总体上与连续沉降场高值区及局部差异变形较强区域相对应。这表明，单栋建筑风险不仅受到累计沉降量大

小的影响，同时也与建筑范围内沉降空间变化的剧烈程度密切相关。当建筑处于局部沉降集中发育区或沉降梯度突变区时，即使其整体沉降量并非研究区最大，也可能因纵向差异沉降或横向不均匀倾斜而表现出更高的综合风险。




图 5.17 建筑沉降变形风险评估图

表 5.4 研究区域内相对综合风险值的百分位分级结果

风险等级	综合风险百分位 (%)	建筑数量 (栋)
高风险	80 以上	14
较高风险	60~80	13
中风险	40~60	13
较低风险	20~40	13
低风险	0~20	13

5.5.3 典型建筑风险特征分析

从图 5.13b) 中分别提取了这四栋建筑的纵向沉降曲线，结果如图 5.18 所示。可以发现，这四栋建筑均具有明显的沉降，其中 B1 栋的沉降曲线表现为典型的沉降模式 II，其弯曲变形的中性轴位于结构底部，结构横断面上存在全截面受拉的附加应力，这意味着其发生开裂损伤概率将大大增加；B2 栋的变形模式属于沉降模式 III，会导致建筑发生一定的倾斜，但由于最大差异沉降不足 10mm，因此其倾斜情况不会很明显；B3 栋的变形模式属于沉降模式 I，但沉降差异从产生附加应力角度考虑，可以认为 B3 产生了上部受压、下部受拉的不利附加应力产生，同样由于最大差异沉降不足 5mm，建筑开裂损伤的概率较低；B4 栋趋向于沉降模式 IV，属于整体沉降，建筑受到的影响很小。

四栋建筑的横倾角曲线如图 5.19 所示，B1 至 B4 的局部横倾角均未超过 1/1000，

意味着建筑几乎不存在横向倾斜，这从侧面验证了基于单一指标进行建筑风险评估的局限性。




图 5.18 建筑沉降曲线




图 5.19 建筑局部横倾角

图 5.20 展示了四栋典型建筑的相对综合风险值评估结果，可以发现，四栋建筑的最大沉降和近期沉降对风险评估的影响几乎一致，但在考虑了结构损伤之后，

B1 与 B2 栋的建筑风险远高于 B3 和 B4。因此，建筑风险等级的提高并不简单对应最大沉降量的单调增大，而更取决于差异沉降特征及其持续发展程度。相比之下，横倾曲线挠度比在 4 栋建筑中的贡献均较小，表明在本研究区内横向扭转并非主导风险来源。




图 5.20 典型建筑风险评估结果

此外，由风险评估结果可以看出，建筑风险评估中结构损伤风险的识别，实质上高度依赖于纵向沉降曲线和横倾角曲线的准确提取。由于沉降曲线挠度比和横倾曲线挠度比分别用于表征建筑纵向弯曲风险和横向扭转风险，因此连续沉降场构建结果的精度将直接影响建筑结构损伤评估的准确性。本研究所提出的考虑数据自相关性的 IDW 插值方法，正是为了在 PS 点空间分布不均匀条件下更加准确地恢复建筑范围内沉降场的局部变化特征，从而为建筑风险评估提供更加可靠的连续空间信息基础。

表 5.5 典型建筑相对风险百分位评估结果

建筑编号	相对综合风险值	风险百分位/%	风险等级
B1	62.21	98.48	高风险
B2	55.03	90.90	高风险
B3	29.07	53.03	中风险
B4	23.72	37.87	较低风险

表 5.5 给出了 4 栋典型建筑的风险百分位等级。与相对综合风险值相比，风险百分位更能反映建筑在研究区内部的相对风险排序，因此适用于指导沉降漏斗区域内建筑人工风险巡查的先后顺序。风险百分位的计算式为 (5.14)：

$$P_m = \frac{1}{N} \sum_{k=1}^N I(R_k \leq R_m) \times 100\% \quad (5.14)$$

式中， P_m 为第 m 栋建筑的风险百分位； R_m 为第 m 栋建筑的相对综合风险值； R_k

为研究区内第 k 栋建筑的相对综合风险值； N 为参与风险评估的建筑总数； $I(\cdot)$ 为指示函数，当括号内条件成立时取 1，否则取 0。风险百分位越高，表示该建筑的相对综合风险值在研究区全部建筑中排序越靠前。

由表 5.5 可知，B1 和 B2 的风险百分位分别为 98.48% 和 90.90%，均属于高风险建筑，应作为优先核查对象；B3 的风险百分位为 53.03%，属于中风险建筑，可作为后续重点关注对象；B4 的风险百分位为 37.87%，属于较低风险建筑，但考虑到其仍位于沉降影响区域内，仍需结合具体变形特征进一步分析。

图 5.21 展示了 B1 至 B4 建筑的现场实景，4 栋典型建筑的表现损伤现象与表 5.5 所示风险排序结果总体上具有较好一致性。B1 的相对综合风险值和风险百分位最高，现场可见大面积开裂，表明其结构损伤风险已经具有较明显的外在表现；B2 虽由于后期修补已难以直接观察到裂缝，但其墙体表面存在明显的二次粉刷痕迹，这在一定程度上表明该建筑此前已出现过较为显著的损伤现象，与其高风险判定结果相吻合；B3 的风险百分位处于中等水平，现场仅发现少量裂缝且裂缝宽度较小，表明其虽已受到沉降变形影响，但整体损伤程度仍相对有限；B4 的风险百分位最低，现场基本完好无损，说明其在沉降影响区域内仍保持较好的结构工作状态。




图 5.21 典型建筑现场实景

由上述结果可以发现，典型建筑的现场表现损伤程度与本文风险评估结果总体一致，表明基于连续沉降场和结构损伤指标构建的综合风险评估方法能够较准确地识别不同建筑的实际风险水平，从而验证了该方法的准确性。

5.6 本章小结

本章提出面向单栋建筑的连续沉降场精细化构建与变形风险评估方法，解决区域尺度沉降结果难以直接用于单栋建筑精细化风险评估的问题。围绕 PS 点非均匀分布条件下的连续沉降场构建、插值模型精度对比及建筑变形风险指标提取开展分析，主要结论如下：

（1）提出考虑数据自相关性的反距离加权插值方法，解决了建筑群区域 PS 点分布不均导致局部沉降差异恢复不足的问题。通过在传统距离衰减权重基础上引入聚集修正指数，增强插值结果对建筑周边局部沉降梯度和空间差异特征的表达能力，为建筑尺度连续沉降场的精细化构建提供了新的技术途径。

（2）提出全局常数与局部变化相结合的四种插值模型，解决了连续沉降场构建中精度与效率难以兼顾的问题。结果表明，不同模型在计算成本和连续场表达能力上具有明显差异，可适用于不同时间需求下的沉降场构建任务。为提高后续建筑风险评估的可靠性，最终选取精度最高的插值结果作为连续沉降场输入。

（3）提出面向单栋建筑的综合变形风险评估方法，解决单一沉降量指标难以表征建筑变形风险的问题。基于最优连续沉降场提取建筑沉降曲线、横倾角及近期沉降等指标，计算相对综合风险值与风险百分位。结果表明，该方法能够区分沉降量相近建筑之间的风险差异，评估结果与现场踏勘现象总体一致，可为建筑尺度风险识别与分级提供依据。

结论与展望

地面沉降作为城市化进程中最具隐蔽性、累积性和持续性的地质环境问题之一，其风险并不只体现在地表高程整体降低，更重要的是不均匀沉降在建筑单体及建筑群尺度上的集中释放。面向城市建筑群安全风险排查需求，本文以国家自然科学基金项目《基于星载 InSAR 变形测量和信息共享平台数据的大跨度桥梁结构状态评估方法》（52278306）、湖南省重点研发计划项目《基于星载 InSAR 技术的城市桥梁群多灾害条件下状态评估与预警研究》（2022SK2096）、湖南省自然科学基金项目《基于天-空-地一体化的基础设施结构安全监测技术研究》（2023JJ70003）、湖南省水利厅水利科技项目《基于“天-空-地”一体化的渡槽结构损伤检测及状态评估研究》（XSKJ2023059-31）、湖南省应急管理厅科技项目（yjtkjxm_202406）为支撑，以长沙市为研究对象，围绕星载 InSAR 离散沉降观测、区域尺度沉降预测、建筑尺度连续沉降场构建以及单栋建筑变形风险分析等内容开展了系统研究，具体研究内容和成果如下：

（1）改进了 PS-InSAR 技术流程并构建多源异构沉降驱动因子体系，解决复杂建筑区 PS 点可靠性不足与多源因子难以统一表达的问题。通过在 Sentinel-1 PSI 处理中引入旁瓣效应剔除，减少强散射体旁瓣导致的伪散射体与虚假 PS 点；进一步结合温度序列识别并剔除显著温度相关形变点，使保留 PS 点更能反映地表沉降而非建筑上部结构热变形。采用 COSMO-SkyMed 高分辨率 PSI 结果作为独立对照依据，用于检验 Sentinel-1 沉降观测结果的空间对应性与可靠性。在此基础上，构建涵盖地形水文、地表覆盖、工程扰动和土体物性的多源异构沉降驱动因子，并统一至 10 m 参考网格，经相关分析与共线性筛查保留 19 个有效因子，为区域沉降预测提供可靠观测基础与统一模型输入。

（2）构建了基于图神经网络的区域沉降预测模型，并引入多头 GAT 注意力机制，解决星载 InSAR 观测盲区沉降信息缺失的问题。采用 GraphSAGE 邻域聚合方法，解决单一像元特征难以表达周边空间背景的问题；引入多头 GAT 注意力机制，解决不同邻域节点对中心节点沉降响应贡献差异难以区分的问题。在此基础上，以优化后的 Sentinel-1 PSI 累计沉降值作为模型训练标签，以多源异构沉降驱动因子作为节点特征，学习“沉降驱动因子—空间邻域关系—沉降响应”之间的映射关系。结果表明，该模型能够将有 PS 点区域学习到的沉降响应规律推广至无 PS 点覆盖区域，实现由离散 InSAR 观测向城市尺度连续沉降预测的拓展。

（3）提出建筑尺度连续沉降场精细化构建与综合风险评估方法，解决区域沉降预测结果难以支撑单栋建筑风险判别的问题。以沉降预测模型识别出的典型沉

降异常区为对象,采用 COSMO-SkyMed 高分辨率 PSI 结果获取建筑周边离散沉降信息,弥补 10 m 区域预测结果难以刻画建筑尺度局部差异沉降的不足;提出考虑数据自相关性的反距离加权插值方法,通过距离衰减与聚集修正共同约束插值权重,降低 PS 点分布不均和局部聚集对连续沉降场估计的影响,在此基础上,进一步结合建筑白膜提取沉降曲线、横倾角和近期沉降增量等指标,形成单栋建筑综合风险评估结果。结果表明,所提方法够刻画建筑周边差异沉降特征,并为典型异常区内建筑风险分级提供依据。

尽管本文围绕星载 InSAR 技术在城市建筑群安全风险排查中的应用开展了较为系统的研究,并在区域沉降预测、连续沉降场精细化构建及建筑风险分析等方面取得了一定成果,但受数据条件、研究区域范围以及方法适用边界等因素影响,仍有若干问题值得进一步深入研究。主要体现在以下几个方面:

(1) 区域尺度沉降预测结果的空间分辨率和跨区域适用性仍有进一步提升空间。本文构建的图神经网络沉降预测模型能够较好识别城市尺度沉降异常区,但其输出结果本质上仍服务于风险区域筛查,尚难直接满足单栋建筑精细化分析对更高空间分辨率的要求。后续可结合更高分辨率 SAR 影像、更精细的光学遥感数据以及更加完备的城市建筑与地下空间信息,进一步提升沉降预测结果对局部沉降梯度和微小空间差异的表达能力;同时,可在不同城市、不同地质环境和不同建成区类型下开展扩展验证,以提高模型的跨区域迁移能力和普适性。

(2) 沉降预测模型与沉降形成机理之间的耦合关系仍需加强。本文所构建的方法总体属于多源驱动因子约束下的数据驱动建模框架,能够较好识别区域沉降异常的空间分异格局,但对地下水变化、工程施工扰动、地层压缩特性及土体动力响应等机理过程的显式表达仍然不足。后续可进一步引入地下水位时序、工程建设活动信息、地基处理资料及更长时间尺度的形变观测结果,在数据驱动模型中融入更多机理约束,以增强模型对沉降演化过程的解释能力和长期预测能力。

(3) 面向单栋建筑的风险分析体系仍需结合更丰富的结构信息进一步完善。本文在建筑尺度上主要依托高分辨率 PSI 结果与连续沉降场开展风险分析,并参考已有兼顾结构损伤风险与整体变形风险的评估思路完成典型建筑分析,但建筑结构形式、基础类型及材料特征等,都可能对风险分析结果产生影响。后续可进一步结合建筑结构设计资料、基础形式信息对风险分析指标的取值依据、权重设置及工程判据进行更深入研究,并在更多典型建筑 and 不同风险等级场景中开展验证,以提高相关方法在不同建筑类型和应用场景下的精细化水平与工程适用性。

参考文献

- [1] Herrera-García G, Ezquerro P, Tomás R, et al. Mapping the global threat of land subsidence[J]. Science, 2021, 371(6524): 34-36.
- [2] Ao Z, Hu X, Tao S, et al. A national-scale assessment of land subsidence in China's major cities[J]. Science, 2024, 384(6693): 301-306.
- [3] Serhal J, Deck O, Al Heib M, et al. Damage of masonry structures relative to their properties: Development of ground movement fragility curves[J]. Engineering Structures, 2016, 113: 206-219.
- [4] Lin L, Hanna A, Sinha A, et al. High-rise building subjected to excessive settlement of its foundation: a case study[J]. International Journal of Structural Integrity, 2017, 8(2): 210-221.
- [5] Locorotondo P, Guerriero A, Chiaradia M T, et al. Preliminary assessment of side-lobe mitigation techniques for proper coherent targets selection in MTInSAR applications (Conference Presentation)[C]//Active and Passive Microwave Remote Sensing for Environmental Monitoring II. SPIE, 2018, 10788: 1078804.
- [6] 湖南长沙“4·29”特别重大居民自建房倒塌事故调查报告[EB/OL]. 中华人民共和国应急管理部.
- [7] 住房和城乡建设部关于开展房屋市政工程安全生产治理行动的通知[EB/OL]. 中华人民共和国住房和城乡建设部.
- [8] 吕国屏, 廖承锐, 高媛赟, 等. 激光雷达技术在矿山生态环境监测中的应用[J]. 生态与农村环境学报, 2017,33(07):577-585.
- [9] 何庆成, 叶晓滨, 李志明, 等. 我国地面沉降现状及防治战略设想[J]. 高校地质学报, 2006(02):161-168.
- [10] 王辉, 曾琪明, 焦健, 等. 结合序贯平差方法监测地表形变的 InSAR 时序分析技术[J]. 北京大学学报(自然科学版), 2021,57(02):241-24
- [11] Lucieer A, Jong S M, Turner D. Mapping landslide displacements using Structure from Motion (SfM) and image correlation of multi-temporal UAV photography[J]. Progress in physical geography, 2014, 38(1): 97-116.
- [12] Zhong W, Chu T, Tissot P, et al. Integrated coastal subsidence analysis using InSAR, LiDAR, and land cover data[J]. Remote Sensing of Environment, 2022, 282: 113297.
- [13] 刘国祥, 陈强, 罗小军, 等. InSAR 原理与应用. 北京: 科学出版社, 2019.

- [14] Cigna F, Osmanoglu B, Cabral-Cano E, et al. Monitoring land subsidence and its induced geological hazard with Synthetic Aperture Radar Interferometry: A case study in Morelia, Mexico[J]. *Remote Sensing of Environment*, 2012, 117: 146-161.
- [15] Zhou Y, Chen J, Hao G, et al. Deformation Monitoring of High-Rise Building Clusters: Acquiring Deformation Coefficients by Combining Satellite Imagery and Persistent Scatterer Interferometry[J]. *Structural Control and Health Monitoring*, 2024, 2024(1): 2326106.
- [16] Graham L C. Synthetic interferometer radar for topographic mapping[J]. *Proceedings of the IEEE*, 1974, 62(6): 763-768.
- [17] Zebker H A, Goldstein R M. Topographic mapping from interferometric synthetic aperture radar observations[J]. *Journal of Geophysical Research: Solid Earth*, 1986, 91(B5): 4993-4999.
- [18] Gabriel A K, Goldstein R M, Zebker H A. Mapping small elevation changes over large areas: Differential radar interferometry[J]. *Journal of Geophysical Research: Solid Earth*, 1989, 94(B7): 9183-9191.
- [19] Bamler R, Hartl P. Synthetic aperture radar interferometry[J]. *Inverse problems*, 1998, 14(4): R1-R54.
- [20] Massonnet D, Feigl K L. Radar interferometry and its application to changes in the Earth's surface[J]. *Reviews of geophysics*, 1998, 36(4): 441-500.
- [21] Ferretti A, Prati C, Rocca F. Permanent scatterers in SAR interferometry[J]. *IEEE Transactions on geoscience and remote sensing*, 2001, 39(1): 8-20.
- [22] Berardino P, Fornaro G, Lanari R, et al. A new algorithm for surface deformation monitoring based on small baseline differential SAR interferograms[J]. *IEEE Transactions on geoscience and remote sensing*, 2003, 40(11): 2375-2383.
- [23] Hooper A. A multi - temporal InSAR method incorporating both persistent scatterer and small baseline approaches[J]. *Geophysical research letters*, 2008, 35(16).
- [24] Ferretti A, Fumagalli A, Novali F, et al. A new algorithm for processing interferometric data-stacks: SqueeSAR[J]. *IEEE transactions on geoscience and remote sensing*, 2011, 49(9): 3460-3470.
- [25] Goel K, Adam N. An advanced algorithm for deformation estimation in non-urban areas[J]. *ISPRS journal of photogrammetry and remote sensing*, 2012, 73: 100-110.
- [26] Crosetto M, Monserrat O, Cuevas-González M, et al. Persistent scatterer interferometry: A review[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2016, 115: 78-89.
- [27] Pepe A, Calò F. A review of interferometric synthetic aperture RADAR (InSAR)

- multi-track approaches for the retrieval of Earth's surface displacements[J]. *Applied Sciences*, 2017, 7(12): 1264.
- [28] 朱建军, 李志伟, 胡俊. InSAR 变形监测方法与研究进展[J]. 2017.
- [29] Gernhardt S, Auer S, Eder K. Persistent scatterers at building facades—evaluation of appearance and localization accuracy[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015, 100: 92-105.
- [30] Yang M, López-Dekker P, Dheenathayalan P, et al. Linking persistent scatterers to the built environment using ray tracing on urban models[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(8): 5764-5776.
- [31] Gernhardt S, Adam N, Eineder M, et al. Potential of very high resolution SAR for persistent scatterer interferometry in urban areas[J]. *Annals of GIS*, 2010, 16(2): 103-111.
- [32] Gernhardt S, Bamler R. Deformation monitoring of single buildings using meter-resolution SAR data in PSI[J]. *ISPRS journal of photogrammetry and remote sensing*, 2012, 73: 68-79.
- [33] Reale D, Fornaro G, Pauciullo A, et al. Tomographic imaging and monitoring of buildings with very high resolution SAR data[J]. *IEEE Geoscience and remote sensing letters*, 2011, 8(4): 661-665.
- [34] Montazeri S, Zhu X X, Eineder M, et al. Three-dimensional deformation monitoring of urban infrastructure by tomographic SAR using multitrack TerraSAR-X data stacks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(12): 6868-6878.
- [35] Wang Y, Zhu X X, Bamler R. Retrieval of phase history parameters from distributed scatterers in urban areas using very high resolution SAR data[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2012, 73: 89-99.
- [36] Lv X, Yazıcı B, Zeghal M, et al. Joint-scatterer processing for time-series InSAR[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(11): 7205-7221.
- [37] Jiang M, Ding X, Hanssen R F, et al. Fast statistically homogeneous pixel selection for covariance matrix estimation for multitemporal InSAR[J]. *IEEE transactions on geoscience and remote sensing*, 2014, 53(3): 1213-1224.
- [38] Even M, Schulz K. InSAR deformation analysis with distributed scatterers: A review complemented by new advances[J]. *Remote Sensing*, 2018, 10(5): 744.
- [39] Shamshiri R, Nahavandchi H, Motagh M, et al. Efficient ground surface displacement monitoring using Sentinel-1 data: Integrating distributed scatterers (DS) identified using two-sample t-test with persistent scatterers (PS)[J]. *Remote*

- Sensing, 2018, 10(5): 794.
- [40] Azadnejad S, Maghsoudi Y, Perissin D. Evaluation of polarimetric capabilities of dual polarized Sentinel-1 and TerraSAR-X data to improve the PSInSAR algorithm using amplitude dispersion index optimization[J]. International Journal of Applied Earth Observation and Geoinformation, 2020, 84: 101950.
- [41] Chen B, Yang J, Li Z, et al. A new sequential homogeneous pixel selection algorithm for distributed scatterer InSAR[J]. GIScience & Remote Sensing, 2023, 60(1): 2218261.
- [42] Budillon A, Crosetto M, Johnsy A C, et al. Comparison of persistent scatterer interferometry and SAR tomography using Sentinel-1 in urban environment[J]. Remote Sensing, 2018, 10(12): 1986.
- [43] Zhang P, Qian X, Guo S, et al. A new method for continuous track monitoring in regions of differential land subsidence rate using the integration of PS-InSAR and SBAS-InSAR[J]. Remote Sensing, 2023, 15(13): 3298.
- [44] Larson K J, Başağaoğlu H, Marino M A. Prediction of optimal safe ground water yield and land subsidence in the Los Banos-Kettleman City area, California, using a calibrated numerical simulation model[J]. Journal of hydrology, 2001, 242(1-2): 79-102.
- [45] Zhao Y, Wang C, Yang J, et al. Coupling model of groundwater and land subsidence and simulation of emergency water supply in Ningbo urban Area, China[J]. Journal of hydrology, 2021, 594: 125956.
- [46] Béjar-Pizarro M, Guardiola-Albert C, García-Cárdenas R P, et al. Interpolation of GPS and geological data using InSAR deformation maps: Method and application to land subsidence in the alto guadalentín aquifer (SE Spain)[J]. Remote Sensing, 2016, 8(11): 965.
- [47] Deng Z, Ke Y, Gong H, et al. Land subsidence prediction in Beijing based on PS-InSAR technique and improved Grey-Markov model[J]. GIScience & remote sensing, 2017, 54(6): 797-818.
- [48] Ambrožič T, Turk G. Prediction of subsidence due to underground mining by artificial neural networks[J]. Computers & Geosciences, 2003, 29(5): 627-637.
- [49] Yang W, Xia X. Prediction of mining subsidence under thin bedrocks and thick unconsolidated layers based on field measurement and artificial neural networks[J]. Computers & Geosciences, 2013, 52: 199-203.
- [50] Bagheri M, Dehghani M, Esmaily A, et al. Assessment of land subsidence using interferometric synthetic aperture radar time series analysis and artificial neural

- p>network in a geospatial information system: case study of Rafsanjan Plain[J]. Journal of Applied Remote Sensing, 2019, 13(4): 044530-044530.
- [51] Shi L, Gong H, Chen B, et al. Land subsidence prediction induced by multiple factors using machine learning method[J]. Remote Sensing, 2020, 12(24): 4044.
 - [52] Naghibi S A, Khodaei B, Hashemi H. An integrated InSAR-machine learning approach for ground deformation rate modeling in arid areas[J]. Journal of hydrology, 2022, 608: 127627.
 - [53] Azarakhsh Z, Azadbakht M, Matkan A. Estimation, modeling, and prediction of land subsidence using Sentinel-1 time series in Tehran-Shahriar plain: A machine learning-based investigation[J]. Remote sensing applications: Society and Environment, 2022, 25: 100691.
 - [54] Ku C Y, Liu C Y. Modeling of land subsidence using GIS-based artificial neural network in Yunlin County, Taiwan[J]. Scientific Reports, 2023, 13(1): 4090.
 - [55] Radman A, Akhoondzadeh M, Hosseiny B. Integrating InSAR and deep-learning for modeling and predicting subsidence over the adjacent area of Lake Urmia, Iran[J]. GIScience & Remote Sensing, 2021, 58(8): 1413-1433.
 - [56] Li H, Zhu L, Dai Z, et al. Spatiotemporal modeling of land subsidence using a geographically weighted deep learning method based on PS-InSAR[J]. Science of the Total Environment, 2021, 799: 149244.
 - [57] Zhou D, Zuo X, Zhao Z. Constructing a large-scale urban land subsidence prediction method based on neural network algorithm from the perspective of multiple factors[J]. Remote Sensing, 2022, 14(8): 1803.
 - [58] Guo H, Yuan Y, Wang J, et al. Large-scale land subsidence monitoring and prediction based on SBAS-InSAR technology with time-series sentinel-1A satellite data[J]. Remote Sensing, 2023, 15(11): 2843.
 - [59] Leng J, Gao M, Gong H, et al. Spatio-temporal prediction of regional land subsidence via ConvLSTM[J]. Journal of Geographical Sciences, 2023, 33(10): 2131-2156.
 - [60] Peng M, Motagh M, Lu Z, et al. Characterization and prediction of InSAR-derived ground motion with ICA-assisted LSTM model[J]. Remote Sensing of Environment, 2024, 301: 113923.
 - [61] Yuan Y, Zhang D, Cui J, et al. Land subsidence prediction in Zhengzhou's main urban area using the GTWR and LSTM models combined with the Attention Mechanism[J]. Science of The Total Environment, 2024, 907: 167482.
 - [62] Chen T, Ning D, Liu Y. Land Subsidence Predictions Based on a Multi-Component

- Temporal Convolutional Gated Recurrent Unit Model in Kunming City[J]. *Applied Sciences*, 2024, 14(21): 10021.
- [63] Zheng L, Wang Q, Cao C, et al. Development and comparison of InSAR-Based land subsidence prediction models[J]. *Remote Sensing*, 2024, 16(17): 3345.
- [64] Li S, Dragicevic S, Castro F A, et al. Geospatial big data handling theory and methods: A review and research challenges[J]. *ISPRS journal of Photogrammetry and Remote Sensing*, 2016, 115: 119-133.
- [65] Yin J, Dong J, Hamm N A S, et al. Integrating remote sensing and geospatial big data for urban land use mapping: A review[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2021, 103: 102514.
- [66] Li J, Hong D, Gao L, et al. Deep learning in multimodal remote sensing data fusion: A comprehensive review[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2022, 112: 102926.
- [67] Yu D, Fang C. Urban remote sensing with spatial big data: A review and renewed perspective of urban studies in recent decades[J]. *Remote Sensing*, 2023, 15(5): 1307.
- [68] Du S, Zhang X, Lei Y, et al. Mapping urban functional zones with remote sensing and geospatial big data: A systematic review[J]. *GIScience & Remote Sensing*, 2024, 61(1): 2404900.
- [69] Zhang Y, Li Q, Tu W, et al. Functional urban land use recognition integrating multi-source geospatial data and cross-correlations[J]. *Computers, Environment and Urban Systems*, 2019, 78: 101374.
- [70] Goodchild M F. Citizens as sensors: the world of volunteered geography[J]. *GeoJournal*, 2007, 69(4): 211-221.
- [71] Batty M. Big data, smart cities and city planning[J]. *Dialogues in human geography*, 2013, 3(3): 274-279.
- [72] Yuan J, Zheng Y, Xie X. Discovering regions of different functions in a city using human mobility and POIs[C]//*Proceedings of the 18th ACM SIGKDD international conference on Knowledge discovery and data mining*. 2012: 186-194.
- [73] Casali Y, Aydin N Y, Comes T. Machine learning for spatial analyses in urban areas: a scoping review[J]. *Sustainable cities and society*, 2022, 85: 104050.
- [74] Ma L, Liu Y, Zhang X, et al. Deep learning in remote sensing applications: A meta-analysis and review[J]. *ISPRS journal of photogrammetry and remote sensing*, 2019, 152: 166-177.
- [75] Liu P, Biljecki F. A review of spatially-explicit GeoAI applications in Urban

- Geography[J]. International Journal of Applied Earth Observation and Geoinformation, 2022, 112: 102936.
- [76] Khelifi M K, Boulila W, Farah I R. Graph-based deep learning techniques for remote sensing applications: Techniques, taxonomy, and applications—A comprehensive review[J]. Computer Science Review, 2023, 50: 100596.
- [77] Xu Y, Zhou B, Jin S, et al. A framework for urban land use classification by integrating the spatial context of points of interest and graph convolutional neural network method[J]. Computers, Environment and Urban Systems, 2022, 95: 101807.
- [78] Bai T, Tahmasebi P. Graph neural network for groundwater level forecasting[J]. Journal of Hydrology, 2023, 616: 128792.
- [79] Zhou J, Cui G, Hu S, et al. Graph neural networks: A review of methods and applications[J]. AI open, 2020, 1: 57-81.
- [80] Scarselli F, Gori M, Tsoi A C, et al. The graph neural network model[J]. IEEE transactions on neural networks, 2008, 20(1): 61-80.
- [81] Bruna J, Zaremba W, Szlam A, et al. Spectral networks and locally connected networks on graphs[J]. arXiv preprint arXiv:1312.6203, 2013.
- [82] Defferrard M, Bresson X, Vandergheynst P. Convolutional neural networks on graphs with fast localized spectral filtering[J]. Advances in neural information processing systems, 2016, 29.
- [83] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks[J]. arXiv preprint arXiv:1609.02907, 2016.
- [84] Gilmer J, Schoenholz S S, Riley P F, et al. Neural message passing for quantum chemistry[C]//International conference on machine learning. Pmlr, 2017: 1263-1272.
- [85] Chen J, Ma T, Xiao C. Fastgcn: fast learning with graph convolutional networks via importance sampling[J]. arXiv preprint arXiv:1801.10247, 2018.
- [86] Ying R, He R, Chen K, et al. Graph convolutional neural networks for web-scale recommender systems[C]//Proceedings of the 24th ACM SIGKDD international conference on knowledge discovery & data mining. 2018: 974-983.
- [87] Zhang J, Shi X, Xie J, et al. GaAN: Gated attention networks for learning on large and spatiotemporal graphs[J]. arXiv preprint arXiv:1803.07294, 2018.
- [88] Yun S, Jeong M, Kim R, et al. Graph transformer networks[J]. Advances in neural information processing systems, 2019, 32.
- [89] Ma P, Lin H, Wang W, et al. Toward fine surveillance: A review of multitemporal

- interferometric synthetic aperture radar for infrastructure health monitoring[J]. IEEE Geoscience and Remote Sensing Magazine, 2021, 10(1): 207-230.
- [90] Sansosti E, Berardino P, Bonano M, et al. How second generation SAR systems are impacting the analysis of ground deformation[J]. International Journal of Applied Earth Observation and Geoinformation, 2014, 28: 1-11.
- [91] Bianchini S, Pratesi F, Nolesini T, et al. Building deformation assessment by means of persistent scatterer interferometry analysis on a landslide-affected area: the Volterra (Italy) case study[J]. Remote sensing, 2015, 7(4): 4678-4701.
- [92] Yaseen M, Hamm N A S, Woldai T, et al. Local interpolation of coseismic displacements measured by InSAR[J]. International journal of applied earth observation and geoinformation, 2013, 23: 1-17.
- [93] Gao M, Gong H, Chen B, et al. InSAR time-series investigation of long-term ground displacement at Beijing Capital International Airport, China[J]. Tectonophysics, 2016, 691: 271-281.
- [94] Ezquerro P, Del Soldato M, Solari L, et al. Vulnerability assessment of buildings due to land subsidence using InSAR data in the ancient historical city of Pistoia (Italy)[J]. Sensors, 2020, 20(10): 2749.
- [95] Tao R, Lau A, Mossefin M E, et al. Monitoring of ground displacement-induced railway anomalies using PS-InSAR techniques[J]. Measurement, 2025, 248: 116863.
- [96] Johnston P J, Filmer M S, Fuhrmann T, et al. Multiband 2D InSAR deformation models with error estimates from natural neighbour interpolation: Case study in the Latrobe Valley, Australia[J]. Advances in Space Research, 2023, 72(6): 2137-2155.
- [97] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[J]. Advances in neural information processing systems, 2017, 30.
- [98] Hamilton W, Ying Z, Leskovec J. Inductive representation learning on large graphs[J]. Advances in neural information processing systems, 2017, 30.
- [99] Veličković P, Cucurull G, Casanova A, et al. Graph attention networks[J]. arXiv preprint arXiv:1710.10903, 2017.
- [100] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 770-778.
- [101] Ba J L, Kiros J R, Hinton G E. Layer normalization[J]. arXiv preprint arXiv:1607.06450, 2016.
- [102] Huber P J. Robust estimation of a location parameter[M]//Breakthroughs in

- statistics: Methodology and distribution. New York, NY: Springer New York, 1992: 492-518.
- [103] Cao Y, Chen D R. Generalization errors of Laplacian regularized least squares regression[J]. Science China Mathematics, 2012, 55(9): 1859-1868.
- [104] Chen Q, Liu G, Ding X, et al. Tight integration of GPS observations and persistent scatterer InSAR for detecting vertical ground motion in Hong Kong[J]. International Journal of Applied Earth Observation and Geoinformation, 2010, 12(6): 477-486.
- [105] Parizzi A, Rodriguez Gonzalez F, Brcic R. A covariance-based approach to merging InSAR and GNSS displacement rate measurements[J]. Remote sensing, 2020, 12(2): 300.
- [106] Goldstein R M, Zebker H A, Werner C L. Satellite radar interferometry: Two-dimensional phase unwrapping[J]. Radio science, 1988, 23(4): 713-720.
- [107] Ghiglia D C, Romero L A. Robust two-dimensional weighted and unweighted phase unwrapping that uses fast transforms and iterative methods[J]. Journal of the Optical Society of America A, 1994, 11(1): 107-117.
- [108] Costantini M. A novel phase unwrapping method based on network programming[J]. IEEE Transactions on geoscience and remote sensing, 2002, 36(3): 813-821.
- [109] Xu W, Cumming I. A region-growing algorithm for InSAR phase unwrapping[J]. IEEE transactions on geoscience and remote sensing, 1999, 37(1): 124-134.
- [110] Hooper A, Zebker H A. Phase unwrapping in three dimensions with application to InSAR time series[J]. Journal of the Optical Society of America A, 2007, 24(9): 2737-2747.
- [111] 陶秋香, 刘国林. PS InSAR 公共主影像优化选取的一种新方法[J]. 武汉大学学报: 信息科学版, 2011, 36(12): 1456-1460.
- [112] Werner C, Strozzi T, Wegmuller U, et al. SAR geocoding and multi-sensor image registration[C]//IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2002, 2: 902-904.
- [113] Farr T G, Rosen P A, Caro E, et al. The shuttle radar topography mission[J]. Reviews of geophysics, 2007, 45(2).
- [114] Touzi R, Lopes A, Bruniquel J, et al. Coherence estimation for SAR imagery[J]. IEEE transactions on geoscience and remote sensing, 2002, 37(1): 135-149.
- [115] Lu X, Sun H. Parameter assessment for SAR image quality evaluation system[C]//2007 1st Asian and Pacific Conference on Synthetic Aperture Radar.

- IEEE, 2007: 58-60.
- [116] Yang B, Xu H, Liu W, et al. An improved Stanford method for persistent scatterers applied to 3D building reconstruction and monitoring[J]. Remote Sensing, 2019, 11(15): 1807.
- [117] Kim K, Kang J, Kim J H. Phase calibration for ideal wideband chirp in satellite-based synthetic aperture radar[J]. ICT Express, 2022, 8(4): 490-493.
- [118] Monserrat O, Crosetto M, Cuevas M, et al. The thermal expansion component of persistent scatterer interferometry observations[J]. IEEE Geoscience and Remote Sensing Letters, 2011, 8(5): 864-868.
- [119] Reale D, Fornaro G, Pauciuolo A. Extension of 4-D SAR imaging to the monitoring of thermally dilating scatterers[J]. IEEE transactions on geoscience and remote sensing, 2013, 51(12): 5296-5306.
- [120] Auer S, Gernhardt S, Bamler R. Ghost persistent scatterers related to multiple signal reflections[J]. IEEE Geoscience and Remote Sensing Letters, 2011, 8(5): 919-923.
- [121] Yang K, Yan L, Huang G M, et al. Monitoring Building Deformation with InSAR: Experiments and Validation. Sensors, 2016, 16(12): 2182.
- [122] Bianchini S, Pratesi F, Nolesini T, et al. Building deformation assessment by means of persistent scatterer interferometry analysis on a landslide- affected area: the Volterra (Italy) case study. Remote Sensing, 2015, 7(4): 4678-4701.
- [123] Qin C Z, Zhu A X, Pei T, et al. An approach to computing topographic wetness index based on maximum downslope gradient[J]. Precision agriculture, 2011, 12(1): 32-43.
- [124] Ballerine C. Topographic wetness index urban flooding awareness act action support, Will & DuPage Counties, Illinois[J]. ISWS Contract Report CR-2017-02, 2017.
- [125] Moore I D, Grayson R B, Ladson A R. Digital terrain modelling: a review of hydrological, geomorphological, and biological applications[J]. Hydrological processes, 1991, 5(1): 3-30.
- [126] Pradhan B, Abokharima M H, Jebur M N, et al. Land subsidence susceptibility mapping at Kinta Valley (Malaysia) using the evidential belief function model in GIS[J]. Natural hazards, 2014, 73(2): 1019-1042.
- [127] Riley S J, Degloria S D. A Terrain Ruggedness Index That Quantifies Topographic Heterogeneity.(1999)[EB/OL].
- [128] Herrera-García G, Ezquerro P, Tomás R, et al. Mapping the global threat of land subsidence[J]. Science, 2021, 371(6524): 34-36.

- [129] Ranjgar B, Razavi-Termeh S V, Foroughnia F, et al. Land subsidence susceptibility mapping using persistent scatterer SAR interferometry technique and optimized hybrid machine learning algorithms[J]. Remote Sensing, 2021, 13(7): 1326.
- [130] Glenn E P, Nagler P L, Huete A R. Vegetation index methods for estimating evapotranspiration by remote sensing[J]. Surveys in Geophysics, 2010, 31(6): 531-555.
- [131] Tucker C J. Red and photographic infrared linear combinations for monitoring vegetation[J]. Remote sensing of Environment, 1979, 8(2): 127-150.
- [132] Vivekananda K S, Nagaraj H B. Prediction of the Coefficient of Volume Compressibility of Fine-Grained Soils Using a Modified Shrinkage Factor and SPT Data[J]. Geotechnical and Geological Engineering, 2025, 43(8): 403.
- [133] Ranjgar B, Razavi-Termeh S V, Foroughnia F, et al. Land subsidence susceptibility mapping using persistent scatterer SAR interferometry technique and optimized hybrid machine learning algorithms[J]. Remote Sensing, 2021, 13(7): 1326.
- [134] Moore I D, Grayson R B, Ladson A R. Digital terrain modelling: a review of hydrological, geomorphological, and biological applications[J]. Hydrological processes, 1991, 5(1): 3-30.
- [135] Caine J S, Evans J P, Forster C B. Fault zone architecture and permeability structure[J]. Geology, 1996, 24(11): 1025-1028.
- [136] Bense V F, Gleeson T, Loveless S E, et al. Fault zone hydrogeology[J]. Earth-Science Reviews, 2013, 127: 171-192.
- [137] Bagheri-Gavkosh M, Hosseini S M, Ataie-Ashtiani B, et al. Land subsidence: A global challenge[J]. Science of The Total Environment, 2021, 778: 146193.
- [138] Navarro-Hernández M I, Tomás R, Valdes-Abellan J, et al. Monitoring land subsidence induced by tectonic activity and groundwater extraction in the eastern Gediz River Basin (Türkiye) using Sentinel-1 observations[J]. Engineering Geology, 2023, 327: 107343.
- [139] Sophocleous M. Interactions between groundwater and surface water: the state of the science[J]. Hydrogeology journal, 2002, 10(1): 52-67.
- [140] Zhang Q, Liu H, Zhu P, et al. Evaluation of the influence of river bank infiltration on groundwater in an inland alluvial fan using spectral analysis and environmental tracers[J]. Hydrogeology Journal, 2021, 29(3): 1117-1128.
- [141] Abdollahi S, Pourghasemi H R, Ghanbarian G A, et al. Prioritization of effective factors in the occurrence of land subsidence and its susceptibility mapping using an SVM model and their different kernel functions[J]. Bulletin of Engineering

- Geology and the Environment, 2019, 78(6): 4017-4034.
- [142] Loganathan N, Poulos H G. Analytical prediction for tunneling-induced ground movements in clays[J]. Journal of Geotechnical and geoenvironmental engineering, 1998, 124(9): 846-856.
- [143] Guo H, Zhang G, Wu Z, et al. The Control of Shield Tunnel Construction-Induced Ground Settlement Based on an Optimized Gap Parameter Theory and Three-Dimensional Finite Element Analysis[J]. Buildings, 2025, 15(9): 1578.
- [144] Yang K, Jiang M, Chi M, et al. Numerical analysis of diaphragm wall deformation and surface settlement caused by dewatering and excavation at center and end positions in a subway foundation pit[J]. Buildings, 2025, 15(15): 2796.
- [145] Wang R, Zhang B, Wang Y. Analysis of settlement induced by shield construction of the metro passing under existing buildings based on the finite difference method[J]. Geofluids, 2022, 2022(1): 1206867.
- [146] Shi G, Sun W, Shangguan W, et al. A China dataset of soil properties for land surface modeling (version 2)[J]. Earth System Science Data Discussions, 2024, 2024: 1-35.
- [147] FAO/IIASA/ISRIC/ISSCAS/JRC. Harmonized World Soil Database (version 1.2)[DB/OL]. 2012.
- [148] Galloway D L, Burbey T J. Review: regional land subsidence accompanying groundwater extraction. Hydrogeology 19: 1459–1486[EB/OL].(2011)
- [149] Shi, G., Sun, W., Shangguan, W., Wei, Z., Yuan, H., Li, L., Sun, X., Zhang, Y., Liang, H., Li, D., Huang, F., Li, Q., and Dai, Y.: A China dataset of soil properties for land surface modelling (version 2, CSDLv2), Earth Syst. Sci. Data, 17, 517–543, <https://doi.org/10.5194/essd-17-517-2025>, 2025.
- [150] Parsons T. The weight of cities: Urbanization effects on Earth's subsurface[J]. AGU Advances, 2021, 2(1): e2020AV000277.
- [151] Ohenhen L O, Zhai G, Lucy J, et al. Land subsidence risk to infrastructure in US metropolises[J]. Nature Cities, 2025, 2(6): 543-554.
- [152] Burland J B. On the compressibility and shear strength of natural clays[J]. Géotechnique, 1990, 40(3): 329-378.
- [153] Saffih-Hdadi K, Défossez P, Richard G, et al. A method for predicting soil susceptibility to the compaction of surface layers as a function of water content and bulk density[J]. Soil and Tillage Research, 2009, 105(1): 96-103.
- [154] Azzouz A S, Krizek R J, Corotis R B. Regression analysis of soil compressibility[J]. Soils and Foundations, 1976, 16(2): 19-29.
- [155] Figueroa-Miranda S, Tuxpan-Vargas J, Ramos-Leal J A, et al. Land subsidence by

- groundwater over-exploitation from aquifers in tectonic valleys of Central Mexico: A review[J]. *Engineering Geology*, 2018, 246: 91-106.
- [156] Tiwari B, Ajmera B. New correlation equations for compression index of remolded clays[J]. *Journal of Geotechnical and Geoenvironmental Engineering*, 2012, 138(6): 757-762.
- [157] Lee Rodgers J, Nicewander W A. Thirteen ways to look at the correlation coefficient[J]. *The American Statistician*, 1988, 42(1): 59-66.
- [158] Zevenbergen L W, Thorne C R. Quantitative analysis of land surface topography[J]. *Earth surface processes and landforms*, 1987, 12(1): 47-56.
- [159] Moore I D, Grayson R B, Ladson A R. Digital terrain modelling: a review of hydrological, geomorphological, and biological applications[J]. *Hydrological processes*, 1991, 5(1): 3-30.
- [160] Wu X, Xu X, Yu G, et al. The China active faults database (CAFD) and its web system[J]. *Earth System Science Data*, 2024, 16(7): 3391-3417.
- [161] Chicco D, Warrens M J, Jurman G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation[J]. *Peerj computer science*, 2021, 7: e623.
- [162] Shepard D. A two-dimensional interpolation function for irregularly-spaced data[C]//*Proceedings of the 1968 23rd ACM national conference*. 1968: 517-524.
- [163] MATHERON G. Principles of geostatistics[J]. *Economic Geology*, 1963, 58(8): 1246-1266.
- [164] Webster R, Oliver M A. *Geostatistics for environmental scientists*[M]. John Wiley & Sons, 2007.
- [165] Stone M. Cross - validatory choice and assessment of statistical predictions[J]. *Journal of the royal statistical society: Series B (Methodological)*, 1974, 36(2): 111-133.
- [166] 周云, 陈建炜, 郝官旺, 等. 融合 InSAR 技术与大数据的城市建筑群结构变形风险评估的一项案例研究[J]. *土木工程学报*, 59(3): 15-31.
- [167] Finno R J, Voss Jr F T, Rossow E, et al. Evaluating damage potential in buildings affected by excavations[J]. *Journal of geotechnical and geoenvironmental engineering*, 2005, 131(10): 1199-1210.
- [168] Tibshirani R. Regression shrinkage and selection via the lasso[J]. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 1996, 58(1): 267-288.
- [169] Krogh A, Hertz J. A simple weight decay can improve generalization[J]. *Advances in neural information processing systems*, 1991, 4.

- [170] Breiman L. Random forests[J]. Machine learning, 2001, 45(1): 5-32.
- [171] Ouyang L, Zhao Z, Zhou D, et al. Study on the relationship between groundwater and land subsidence in Bangladesh combining GRACE and InSAR[J]. Remote Sensing, 2024, 16(19): 3715.
- [172] Dong J, Guo S, Wang N, et al. Tri-decadal evolution of land subsidence in the Beijing Plain revealed by multi-epoch satellite InSAR observations[J]. Remote Sensing of Environment, 2023, 286: 113446.
- [173] Navarro-Hernández M I, Valdes-Abellan J, Tomás R, et al. Analysing the impact of land subsidence on the flooding risk: evaluation through InSAR and modelling[J]. Water Resources Management, 2023, 37(11): 4363-4383.
- [174] Crosetto M, Monserrat O, Cuevas-González M, et al. Measuring thermal expansion using X-band persistent scatterer interferometry[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 100: 84-91.
- [175] Wang Y, Sun Y, Liu Z, et al. Dynamic graph cnn for learning on point clouds[J]. ACM Transactions on Graphics (tog), 2019, 38(5): 1-12.
- [176] Yu B, Yin H, Zhu Z. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting[J]. arXiv preprint arXiv:1709.04875, 2017.
- [177] Wu Z, Pan S, Long G, et al. Graph wavenet for deep spatial-temporal graph modeling[J]. arXiv preprint arXiv:1906.00121, 2019.

附录 A（长沙市主要城市区域沉降预测结果展示图）




图 A.1 区域 1 沉降预测结果




图 A.2 区域 2 沉降预测结果




图 A. 3 区域 3 沉降预测结果




图 A. 4 区域 4 沉降预测结果




图 A. 5 区域 5 沉降预测结果




图 A. 6 区域 6 沉降预测结果




图 A. 7 区域 7 沉降预测结果




图 A. 8 区域 8 沉降预测结果




图 A. 9 区域 9 沉降预测结果




图 A. 10 区域 10 沉降预测结果




图 A. 11 区域 11 沉降预测结果




图 A. 12 区域 12 沉降预测结果

致 谢

二十一载漫漫求学路，至此将近尾声。回望来时，感慨系之，仓卒之间，竟不知所言。读书可以改变命运，这句话在我的身上有了具体而真切的印证。年少时因贪玩荒废学业，2017 年高考未达三本分数线；在家中体验两个月销售员生活后，方知社会谋生之艰辛，遂赴长沙复读，并有幸以超过一本分数线四十余分的成绩考入湖南科技大学。此后，为进入更高平台，我于 2021 年开始备考研究生，参加 2022 年湖南大学研究生招生考试，却因发挥不佳以 358 分遗憾落榜。复盘不足后，我选择考研二战，并以 425 分、专业第一的成绩考入湖南大学土木工程学院。两次重新开始的经历，给了我直面困难的勇气，也在心中留下阴影。研二下学期，因就业形势与个人规划，我开始准备国家电网考试。面对跨专业学习电工类课程的压力，我曾担心自己是否又要经历“第二次”才能成功。为摆脱这层枷锁，我每日早八晚十守在图书馆，最终一次通过国家电网第一批招聘考试，也顺利留在了长沙这座心仪的城市。一路走来，我曾几次站在人生十字路口：18 岁时在读大专与复读之间抉择，22 岁时在考研二战与进入土木国企做施工员之间抉择。万幸的是，每一次我都选择了那条虽艰苦却受益终生的路。

尊师教诲，亲友相助，终获硕士学位，谓之“恩似海”。乌鸦反哺，羊羔跪乳，首先感谢我的父母，是你们一路将我从小供养至硕士，给予我物质条件和精神支持，使我能够心无旁骛完成学业；感谢奶奶、叔叔婶婶在童年给予我的陪伴与关怀；也感谢所有家人多年来的鼓励与帮助。师道既尊，学风自善。衷心感谢我的导师周云教授。周老师是我学术上的导师，亦是生活中的向导，在论文写作中给予悉心修改，在能力历练中给予宝贵机会，在生活中给予诸多关心，在我犯错时给予包容与教诲，点点滴滴，终生不忘。感谢师爷易伟建教授在研究方向选择、研究方法改进和论文审阅修改等方面的指导与付出。感谢郝官旺博士、陈建伟师兄在科研过程中给予的耐心解答与指导，感谢罗先明博士、周晓枫博士、朱师琪博士、肖寒博士、颜博超博士的多方协助；感谢魏子青、邹少豪、杨晨烨、张阳、陈祎林、叶鹏师兄、张文杰师兄、周易师兄、赵贺俊师兄、张鑫师兄、张璐瑶师姐、徐晓婉师姐、李婷师姐、汪柏煊师兄、冷建波、刘森森、曹爽、徐骢荣、雷霆、刘程、黄一钊、李子卿等同门在各项工作中的团结协作，特别感谢好兄弟李智仁在备考国家电网期间给予的鼓励与帮助。谨以此文，向所有曾经关心、帮助、支持和鼓励我的人致以最诚挚的谢意，求学多年，少有陪伴，养育之恩，无以为报，唯愿日后不负所望。

刘迎澳

2026 年 5 月于岳麓山下

答辩委员会名单

答辩委员会	姓名	职称	工作单位
主席	黄远	教授	湖南大学
委员	易伟建	教授	湖南大学
委员	李鹏	高工	湖南省建筑设计院
秘书	刘艳芝	副教授	湖南大学