



湖南大学
HUNAN UNIVERSITY

硕士学位论文

基于星载InSAR技术的路网变形监测 与风险评估研究

作 者 姓 名	杨晨烨
指 导 教 师	周云教授 谈忠坤教授级高工
培 养 单 位	土木工程学院
专 业 类 别	土木水利
专 业 领 域	结构健康监测

学校代号 10532
学 号 S2301W0003
密 级 公开

湖南大学硕士学位论文

基于星载InSAR技术的路网变形监测 与风险评估研究

湖南省交通运输厅科技进步与创新项目（201912）

国家自然科学基金（52278306）

湖南省重点研发计划（2022SK2096）

湖南省自然科学基金项目（2023JJ70003）

作 者 姓 名： 杨晨烨

指 导 教 师： 周云教授

谈忠坤教授级高工

培 养 单 位： 土木工程学院

专 业 类 别： 土木水利

专 业 领 域： 结构健康监测

论文提交日期： 2026年4月14日

论文答辩日期： 2026年5月21日

答辩委员会主席： 黄远教授

Research on Road Network Deformation Monitoring and Risk
Assessment Based on Spaceborne InSAR Technology

by

Chenye Yang

B.E. (Taiyuan University of Technology) 2023

A thesis 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

Supervisor

Professor Yun Zhou

Senior Engineer Zhongkun Tan

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：杨晨烨

日期：2026年5月20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：杨晨烨

日期：2026年5月20日

导师签名：[Signature]

日期：2026年5月20日

摘 要

随着我国高速公路网络不断向山区、丘陵及地质条件复杂区域延伸，沿线滑坡、地面塌陷及路基沉降等灾害问题日益突出，严重威胁道路基础设施运营安全。湖南省地貌类型复杂，整体呈“七山二水一分田”格局，山地丘陵广布、降雨时空分布不均，且高速公路线路长、跨越地貌单元多、沿线地质环境差异显著，导致高速公路沿线灾害隐患具有空间分散性强、致灾因素复杂和风险识别难度大的特点。传统人工巡检与点式监测方法存在覆盖范围有限、监测效率偏低等不足，难以满足大范围高速公路路网安全监测与风险识别需求。星载合成孔径雷达干涉测量（Interferometric Synthetic Aperture Radar, InSAR）技术具有全天时、全天候、大范围覆盖和毫米级变形监测优势，为高速公路路网变形监测与风险评估提供了新的技术路径。然而，现有研究多集中于地表变形场提取、时序变形分析及局部机理解释，对InSAR动态变形信息如何服务于高速公路灾害风险识别仍缺乏系统研究，主要体现在以下三个方面：一是缺乏面向省域尺度高速公路沿线灾害风险的筛查方法；二是缺乏面向城市尺度高速公路沿线异常变形的精细化识别与分析方法；三是缺乏面向道路工程的动态风险评估框架。基于此，本文以湖南省及长沙地区高速公路路网为研究对象。围绕“省域尺度风险初筛—城市尺度变形精析—道路单元尺度模型改进”，构建了融合SBAS-InSAR时序变形监测与机器学习风险建模的路网变形监测与风险评估方法体系。主要研究内容如下：

（1）构建了面向高速公路路网的SBAS-InSAR变形识别方法，为复杂地表条件下大范围路网缓慢变形连续监测提供了方法支撑。建立了包含Sentinel-1 SAR影像、精密轨道、DEM等在内的数据体系，优化了适用于高速公路路网的SBAS-InSAR处理流程，获取了研究区LOS向变形速率场和变形时间序列结果，并结合现场调查资料对异常区进行了验证，为风险评估提供了动态变形信息。

（2）构建了省域尺度滑坡与地面塌陷灾害风险评估模型，解决了高速公路沿线灾害风险难以精细识别的问题。针对两类灾害形成机制差异，选取高程、坡度、曲率、SPI、TWI、降雨量、NDVI、道路密度和河流密度等影响因子，采用随机森林和XGBoost模型分别开展分灾种建模与对比分析，生成了湖南省滑坡与地面塌陷风险空间分布结果，实现了省域尺度高速公路沿线灾害风险初筛。

（3）提出了融合背景静态风险与InSAR动态变形信息的道路滑坡风险评估方法，解决了传统静态风险评估难以反映局部异常变形的问题。以长沙市

为研究区域，构建约30m×30m的道路单元作为基本评价单元，并提出自适应范围寻点方法，提取道路单元级InSAR动态指标；在此基础上，以静态滑坡风险结果为基础风险值，采用熵权法构建动态风险指数与动态修正系数，实现了道路单元综合风险值的动态增强。以衡南县茶市镇典型道路滑坡坍塌事故为案例进行验证，结果表明耦合模型在事故位置附近形成了更为连续集中的高风险带，与实际灾害位置具有较好对应关系。

本文构建了从省域尺度背景风险识别、城市尺度变形监测到道路单元尺度动态修正的多尺度技术框架，实现了星载InSAR动态变形信息与高速公路灾害风险评估的有效衔接。研究成果可为高速公路沿线灾害隐患筛查、重点路段优先巡检和安全运营管理提供技术支撑，对提升复杂地质环境下高速公路路网风险识别精度和监测预警能力具有重要意义。

关键词：星载 InSAR；小基线集干涉测量；路网变形监测；风险评估；机器学习

Abstract

As China's expressway network continues to expand into mountainous, hilly, and geologically complex regions, hazards such as landslides, ground collapse, and subgrade settlement along expressway corridors have become increasingly prominent, posing serious threats to the safe operation of transportation infrastructure. Due to the characteristics of long linear extent, multiple geomorphic units, and strong geological heterogeneity, traditional field inspection and point-based monitoring methods suffer from limited spatial coverage, low monitoring efficiency, and difficulty in identifying slowly accumulated deformation, and therefore cannot fully meet the needs of large-scale expressway network safety monitoring and risk identification. Interferometric Synthetic Aperture Radar (InSAR), with its advantages of all-weather, all-time, wide-area, and millimeter-level deformation monitoring, provides a new technical approach for expressway network deformation monitoring and risk assessment. However, existing studies have mainly focused on deformation field extraction and evolutionary analysis, while a multi-scale framework for expressway-oriented risk identification and model improvement is still lacking. Therefore, taking the expressway network in Hunan Province and Changsha as the study object, this thesis develops an integrated framework combining SBAS-InSAR time-series deformation monitoring with machine learning-based risk modeling under the overall strategy of "provincial-scale risk screening – city-scale deformation analysis – road-unit-scale model improvement." The main research contents are as follows:

(1) An SBAS-InSAR-based deformation extraction workflow for expressway networks was established to address the problem of continuous large-scale monitoring of slow deformation under complex surface conditions. A multi-source dataset including Sentinel-1 SAR images, precise orbit data, DEM, rainfall data, and historical hazard samples was constructed, and an SBAS-InSAR processing procedure suitable for expressway network monitoring was optimized to obtain LOS deformation velocity fields and deformation time series of the study area. Field investigation data were further used to verify the abnormal deformation zones, providing dynamic deformation information for subsequent risk assessment.

(2) Provincial-scale hazard assessment models for landslides and ground collapse were developed to address the difficulty of identifying the background hazard pattern of expressway-related geological disasters at the regional scale. Considering the differences in the formation mechanisms of the two hazard types, multiple influencing factors,

including elevation, slope, curvature, SPI, TWI, rainfall, NDVI, road density, and river density, were selected. Random Forest and XGBoost models were then applied to conduct separate hazard modeling and comparative analysis, producing spatial risk maps of landslides and ground collapse in Hunan Province and enabling provincial-scale preliminary hazard screening along expressway corridors.

(3) A road-unit landslide risk assessment method integrating InSAR deformation information was proposed to solve the problems that discrete monitoring points cannot be directly used for road management and that conventional static risk assessment cannot effectively reflect localized abnormal activity. Taking Changsha as the representative area, road units of approximately $30\text{ m} \times 30\text{ m}$ were constructed as the basic assessment objects, and an adaptive search-radius method was proposed to extract road-unit-level InSAR dynamic indicators. On this basis, the static landslide risk result was used as the baseline risk value, and an entropy-weight-based dynamic risk index and dynamic correction coefficient were established to enhance the comprehensive road-unit risk value. A typical road landslide-collapse accident at Chashi Town, Hengnan County, was used for validation. The results show that the coupled model generated a more continuous and concentrated high-risk belt around the accident location, showing good agreement with the actual hazard occurrence.

This thesis establishes a multi-scale technical framework spanning provincial-scale background hazard identification, city-scale deformation monitoring, and road-unit-scale dynamic correction, and realizes the effective integration of satellite InSAR-derived dynamic deformation information with expressway hazard risk assessment. The proposed method can provide technical support for hazard screening, priority inspection of critical road sections, and safe operation management of expressways, and is of practical significance for improving risk identification accuracy and monitoring capability in expressway networks under complex geological conditions.

Key Words: Spaceborne InSAR; Small Baseline Subset Interferometry; road network deformation monitoring; risk assessment; machine learning

目 录

摘 要	I
Abstract.....	III
插图索引.....	VIII
附表索引.....	X
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 公路路网变形监测研究现状	3
1.2.2 InSAR技术在公路变形监测中的研究现状	5
1.2.3 风险评估方法研究现状	7
1.2.4 SBAS-InSAR方法的特点与适用性	9
1.3 目前研究工作不足	10
1.4 本文研究内容	11
第2章 星载时序InSAR变形监测理论与方法基础	14
2.1 引言	14
2.2 雷达干涉测量基本原理.....	14
2.2.1 InSAR干涉测量几何	14
2.2.2 干涉相位组成.....	17
2.2.3 干涉相位误差来源与质量影响因素	18
2.3 SBAS-InSAR变形分析方法	20
2.3.1 SBAS-InSAR基本思想与小基线干涉网络构建	20
2.3.2 SBAS-InSAR时序变形求解.....	22
2.3.3 基于相干系数与连通域的参考点选取方法	25
2.4 本章小结	27
第3章 基于SBAS-InSAR的路网变形提取	29
3.1 引言	29
3.2 研究区介绍	29
3.3 数据获取	30
3.3.1 SAR卫星数据	30
3.3.2 精密轨道数据.....	32
3.3.3 DEM数据.....	33
3.4 Sentinel-1影像处理	34

3.4.1	干涉网络构建.....	34
3.4.2	差分干涉图生成与地形相位去除	36
3.4.3	相位解缠与SBAS时序反演处理	38
3.5	InSAR结果验证	43
3.5.1	风险区域一验证.....	43
3.5.2	风险区域二验证.....	45
3.6	本章小结	47
第4章	基于机器学习方法的滑坡与地陷风险评估	49
4.1	引言	49
4.2	数据来源与样本构建	49
4.2.1	灾害样本数据来源与筛选.....	50
4.2.2	多源影响因子数据.....	51
4.3	影响因子相关性及其共线性分析.....	57
4.3.1	相关性分析方法.....	57
4.3.2	共线性分析方法.....	58
4.3.3	相关性分析结果.....	59
4.3.4	共线性分析结果.....	60
4.3.5	因子保留结果.....	61
4.4	湖南省滑坡灾害风险评估.....	61
4.4.1	滑坡风险评估模型构建.....	61
4.4.2	滑坡模型精度评价.....	65
4.4.3	滑坡风险影响因子贡献分析	69
4.4.4	滑坡风险空间分布特征.....	70
4.5	地面塌陷风险评估	72
4.5.1	地面塌陷风险评估模型构建	72
4.5.2	地面塌陷模型精度评价	72
4.5.3	地面塌陷风险影响因子贡献分析	74
4.5.4	地面塌陷风险空间分布特征	75
4.6	本章小结	77
第5章	融合InSAR变形信息的道路单元滑坡风险评估	79
5.1	引言	79
5.2	基于道路单元的InSAR指标提取.....	79
5.2.1	道路单元创建.....	79
5.2.2	InSAR变形因子的构建.....	81
5.2.3	自适应范围寻点方法.....	83

5.3 静态—动态耦合的道路单元综合风险评估	85
5.3.1 动态修正系数构建	85
5.3.2 静态—动态耦合模型	87
5.3.3 风险路段识别结果	89
5.4 方法验证	90
5.4.1 事故前变形特征分析	91
5.4.2 静态与耦合风险结果对比	92
5.4.3 验证结论	93
5.5 本章小结	94
结论与展望	96
参考文献	98
致 谢	110
答辩委员会名单	111

插图索引

图1.1 灾害事故案例	1
图1.2 研究内容图	13
图2.1 杨氏双缝干涉实验示意图	15
图2.2 干涉测量几何示意图	15
图2.3 监测对象回波信号特征示意图	21
图2.4 PS方法与SBAS方法干涉对组合 ^[105]	22
图2.5 SBAS-InSAR处理流程图	23
图2.6 相位解缠示意图	24
图2.7 参考点自动选取流程图	26
图3.1 选取Sentinel-1影像覆盖范围	31
图3.2 湖南省Copernicus DEM	33
图3.3 计算区域划分	34
图3.4 时空基线连接图	35
图3.5 Z5平均相干性图	36
图3.6 Z5分区差分干涉图	38
图3.7 Z1-Z6参考点位置	39
图3.8 Z7-Z11参考点位置	39
图3.9 Z5分区相位解缠图	40
图3.10 Z5区域去线性趋势前后对比图	41
图3.11 Z1-Z6计算区域变形速率	42
图3.12 Z7-Z11计算区域变形速率	42
图3.13 区域一位置及监测点分布	43
图3.14 区域一监测点时序变形曲线	44
图3.15 道路裂缝实景	44
图3.16 路缘石倾斜实景	45
图3.17 区域二位置及监测点分布	45
图3.18 区域二监测点时序变形曲线	46
图3.19 区域二道路裂缝实景	47
图4.1 风险评估总体流程图	49
图4.2 湖南省历史地灾点空间分布	50
图4.3 模型训练选取地灾点	51
图4.4 影响因子1-12空间分布图	56

图4.5 影响因子13-17空间分布图	56
图4.6 连续型影响因子皮尔逊相关系数热力图	59
图4.7 随机森林算法结构图	63
图4.8 XGBoost算法结构图	64
图4.9 滑坡两种模型PR曲线图	67
图4.10 滑坡两种模型ROC曲线图	68
图4.11 滑坡风险评估模型前10位影响因子重要性排序	70
图4.12 湖南省滑坡风险空间分布图	71
图4.13 事故发生路段风险空间分布	72
图4.14 地陷两种模型PR曲线图	73
图4.15 地陷两种模型ROC曲线图	73
图4.16 地面塌陷风险评估模型前10位影响因子重要性排序	75
图4.17 湖南省地陷风险空间分布图	76
图4.18 评估结果与历史发生点对比	77
图5.1 道路单元创建流程图	80
图5.2 总体流程图	81
图5.3 自适应寻点方法示意图	83
图5.4 自适应范围寻点流程图	84
图5.5 长沙市道路滑坡风险空间分布Z1—Z6	88
图5.6 长沙市道路滑坡风险空间分布Z7—Z11	88
图5.7 高风险路段一	89
图5.8 高风险路段二	90
图5.9 事故现场	91
图5.10 灾害区域InSAR分析结果	92
图5.11 InSAR监测点变形时序曲线	92
图5.12 事故路段动态修正前后道路滑坡风险结果对比图	93


附表索引

表1.1 传统公路变形监测技术及优缺点	4
表1.2 主流InSAR方法优缺点对比	10
表3.1 Sentinel-1A卫星基本参数	31
表3.2 区域1影像数据列表	32
表3.3 区域2影像数据列表	32
表3.4 参考点选取结果	38
表4.1 湖南省历史灾害类型统计	51
表4.2 风险因子类别、名称、数据类型及来源	52
表4.3 影响因子 VIF 计算结果	60
表4.4 滑坡模型精度评估结果	68
表4.5 地陷模型精度评估结果	73
表5.1 单元InSAR指标	82

第1章 绪 论

1.1 研究背景及意义

高速公路是国家综合交通运输体系中的骨干基础设施，其安全运行水平直接关系到人员出行安全、区域互联互通效率及国民经济稳定运行。近年来，我国高速公路建设持续推进，国家高速公路网已形成“7射11纵18横”总体布局，规划总规模约13.6万公里^[1]；截至2024年末，全国高速公路里程已达19.07万公里^[2]，国家高速公路主线基本贯通^[3]。随着高速公路不断向山区、丘陵区及复杂地质环境区延伸，沿线滑坡、路基沉降和路面塌陷等灾害问题日益突出，路网安全保障面临更高要求。高速公路灾害具有突发性强、影响范围广和损失后果重等特点。近年来我国发生多起相关事故，例如2023年12月25日，G55二广高速路面出现塌陷事故，造成3人死亡，4人轻伤^[4]；2024年5月1日，广东梅大高速发生路面塌方灾害，造成48人遇难、30人受伤^[5]；同年7月19日，陕西商洛市柞水县境内一高速公路桥梁因山洪暴发发生垮塌，事故造成25辆车辆坠河，62人死亡失踪^[6]；同年12月4日，深圳市宝安区发生地面坍塌事故，造成13人死亡^[7]。相关事故表明，在极端降雨、复杂地形地质条件和工程扰动等因素共同作用下，高速公路沿线灾害风险具有明显的隐蔽性、累积性和突发性。尤其对于切坡路段、填挖交界段及软弱地基路段，降雨入渗、地下水活动、边坡开挖及长期服役劣化等因素均可能诱发地表变形并进一步发展为灾害事故^[8]。



a) 2024年5月广东梅大高速滑坡



b) 2024年7月陕西柞水高速桥梁垮塌



c) 2023年12月G55二广高速路面塌陷



d) 2024年12月深圳施工路面垮塌

图1.1 灾害事故案例

而湖南省地貌类型复杂，整体呈“七山二水一分田”格局，其中山地面积占

全省总面积的51.2%，丘陵及岗地占29.3%^[15]；截至2024年末，全省高速公路通车里程达8197.5公里^[17]。与此同时，湖南也是地质灾害高易发省份之一，截至2023年底，全省共有地质灾害在册隐患点18570处，威胁人员70.87万人，威胁财产319.47亿元^[16]。受山地丘陵广布、降雨集中和工程活动强烈等因素影响，湖南高速公路沿线地质灾害防治形势严峻，尤其滑坡等灾害沿交通干线分布较为突出。因此本文以湖南省为主要对象进行路网变形监测与风险评估研究。

为提高公路基础设施安全水平，加强风险隐患排查与监测预警正逐渐成为交通运输领域的重要共识。2019年，中共中央、国务院印发《交通强国建设纲要》，提出要强化基础设施安全防护能力，提升基础设施灾害防御和应急保障水平^[9]；2021年，中共中央、国务院印发《国家综合立体交通网规划纲要》，明确提出要统筹交通基础设施绿色、安全、智能发展，提升交通网络韧性和本质安全水平^[10]；2022年，国务院印发《“十四五”现代综合交通运输体系发展规划》，强调加强公路基础设施安全监测、风险评估及灾害预警能力建设，推进交通基础设施数字化感知与智能化运维^[11]；同年，交通运输部发布《关于进一步加强公路安全设施和交通秩序管理工作的意见》，提出建立健全高速公路风险隐患动态排查治理机制，强化重点路段灾害风险识别与监测预警^[12]。2024年5月广东梅大高速塌方灾害发生后，国家防灾减灾救灾委员会办公室进一步印发紧急通知，部署各地区全面加强汛期高速公路等基础设施灾害风险隐患排查处置工作^[13]；2026年4月，交通运输部在汛期公路安全风险管控工作部署中再次强调，要推进“人巡+技巡”协同监测体系建设，加强风险隐患闭环整治与监测预警能力提升，持续增强公路基础设施安全韧性水平^[14]。

在《“十四五”现代综合交通运输体系发展规划》《交通强国建设纲要》等政策文件中，均明确提出要提升交通基础设施数字化监测、灾害风险识别与安全预警能力^[11]。鉴于高速公路沿线滑坡、地面塌陷及路基沉降等灾害在失稳破坏前通常存在较明显的缓慢变形征兆，而异常变形往往是道路工程病害演化和灾害发生的重要前兆，因此，提出一种面向公路路网的大范围、低成本、可持续的变形监测与风险识别方法，有利于提升公路灾害隐患筛查和风险评估能力，从而为高速公路安全运营和韧性提升提供技术支撑。

现有高速公路监测仍以人工巡检和局部点式监测为主。水准测量、GNSS、测斜仪和裂缝计等传统方法虽具有较高局部精度，但普遍存在覆盖范围有限、监测成本较高、时空连续性不足以及难以实现大范围常态化监测等问题，难以满足区域尺度高速公路路网风险识别需求。特别是在省域尺度下，仅依赖现场巡查和少量监测点，难以及时发现沿线缓慢累积变形及潜在隐患区。

星载合成孔径雷达干涉测量（InSAR）技术具有全天时、全天候、大范围覆盖及毫米级变形监测优势，为高速公路沿线缓慢变形识别提供了新的技术手段。其

中, SBAS-InSAR能够利用多时相SAR影像获取长期变形速率及时间序列信息, 适用于区域尺度地表缓慢变形监测。与此同时, 高速公路灾害风险不仅受当前变形状态影响, 还与地形地貌、水文气象、植被覆盖和道路工程扰动等多种因素密切相关。因此, 融合InSAR动态变形信息与多源环境因子, 构建面向公路路网的风险评估方法, 对于提升灾害隐患识别能力具有重要意义。

1.2 国内外研究现状

1.2.1 公路路网变形监测研究现状

在公路变形传统监测领域, 现有研究主要围绕点式高精度监测、局部自动化监测以及近景遥感监测三类技术路线展开。(1)点式高精度监测方法以水准测量、GNSS、全站仪、位移计和测斜仪等为代表, 能够较精确地获取路基沉降、边坡位移及桥梁结构变形信息, 常用于重点边坡、桥梁及典型病害路段的长期观测;(2)局部自动化监测方法则在位移、降雨、孔压等传感器基础上, 融合数据采集传输、供电保障和预警分析等模块, 形成可连续运行的自动化监测体系, 适用于局部高风险边坡或特殊环境路段的实时观测;(3)近景遥感监测方法主要包括无人机摄影测量和地面激光扫描等, 可通过多期三维点云重建、配准与差分分析识别边坡表面变形, 在灾后调查和局部精细化监测中具有较高应用价值。

在点式高精度监测方面, Erol等^[18]以土耳其Karasu高架桥为对象, 构建了GPS控制网与精密水准联合监测方案, 分别开展桥梁竖向变形分析与三维变形评估, 验证了GPS与水准联合用于大型交通结构变形监测的可行性。Wang等^[19]针对高速公路高岩质边坡施工期稳定性问题, 通过布设表面监测点、多点位移计和测斜仪, 同步获取坡体表面与坡体内部位移信息, 揭示了边坡开挖与变形响应之间的关系。Yan^[20]等面向青藏高原多年冻土区公路路基病害监测需求, 建立了风光互补供电的GNSS路基监测系统, 实现了严寒环境下的全天候、长期、无人值守观测, 并通过不同工况下的精度评估分析了多年冻土路基的长期沉降特征。Wang等^[21]进一步提出了基于激光基准的高速公路边坡多维变形测量方法, 以提高传统监测在复杂边坡场景下的精度与稳定性。Kane等^[22]则从工程应用角度系统总结了位移计、测斜仪、孔压计等仪器在边坡监测中的布设原则与适用范围, 为点式高精度监测提供了较为成熟的技术框架。

在局部自动化监测方面, Zhang等^[23]针对山区高速公路边坡滑坡灾害管理需求, 构建了集位移计、格栅雨量计、GPRS无线传输和远程预警于一体的监测系统, 实现了边坡位移和降雨信息的实时获取与远程传输。Pei等^[24]提出利用光纤传感技术开展滑坡和泥石流监测与预警, 解决了传统电学传感器在复杂环境下稳定性不足的问题。Ju等^[25]构建了实时监测网络与计算机辅助自动预警系统, 通过多传感

器协同提高了滑坡监测的连续性和预警响应能力。Prakasam等^[26]则从低成本预警角度出发，设计了面向浅层滑坡的实时监测与预警系统，强调了监测设备集成化与成本可控对实际应用的重要性。Khan等^[27]提出基于低成本自动化观测的边坡监测方法，通过时间序列影像分析实现了对活动边坡的连续监测，拓展了自动化监测在交通边坡场景中的应用形式。

表1.1 传统公路变形监测技术及优缺点

监测技术	优点	缺点
水准测量	高程监测精度高，成果直观可靠	外业工作量大，难以实现连续监测
GNSS监测	可连续获取三维位移信息	设备成本较高，空间覆盖有限
全站仪监测	位移监测精度较高，适用性强	受通视条件限制，大范围应用困难
测斜仪	可获取边坡或路基深部位移	安装维护复杂，监测范围较小
裂缝计	对局部裂缝变形响应较敏感	仅适用于已有病害部位监测
孔隙水压力计	可反映地下水对稳定性的影响	属间接监测手段，解释依赖较强
激光扫描	可获取高密度三维地表信息	设备和处理成本高，外业组织复杂
无人机摄影测量	分辨率高，适合快速调查取证	易受天气和遮挡影响，连续性不足
探地雷达	适于识别浅层空洞及结构异常	探测深度有限，结果解释较复杂
钻探与坑探	可直接揭示地下结构与病害特征	破坏性较强，效率低且费用较高

在近景遥感监测方面，Yan等^[28]提出利用无人机近景摄影测量技术识别高速公路边坡变形，通过重建多期三维点云并采用ICP算法进行配准和差分分析，实现了厘米级边坡表面变形识别。Rawabdeh等^[29]利用时序无人机影像构建点云数据集，用于滑坡体变形识别和位移监测，证明了UAV点云在时序变形分析中的应用潜力。Jia等^[30]将地面激光扫描与无人机摄影测量相结合，提出了改进的边坡表面位移评估方法，以提高点云精度和位移识别效果。Ismail等^[31]比较了TLS与UAV在岩质边坡稳定性分析中的适用性，指出二者融合能够更全面地获取坡面结构与几何信息。Zhou等^[32]面向高山峡谷区滑坡监测难题，提出了结合TLS与UAV的滑坡变形监测方法，以解决视线受阻和地面难以到达条件下的高精度监测问题。Sestras等^[33]进一步提出融合UAV摄影测量和LiDAR数据的滑坡变形监测方法，以改善单一传感器在植被覆盖和复杂地形条件下的信息缺失问题。

由表1.1可见，传统监测技术虽在局部点位或重点工程部位具有较高精度和较

强针对性，但普遍存在监测范围有限、布设成本较高、连续性不足以及难以满足大范围高速公路路网常态化监测需求等问题。因此，亟需引入兼具大范围覆盖能力与持续观测能力的遥感监测手段，以实现高速公路沿线变形灾害的高效识别与风险筛查。

1.2.2 InSAR技术在公路变形监测中的研究现状

在线性交通基础设施变形监测方面，已有研究主要围绕高速公路路基沉降、铁路沿线冻融变形、城市高架道路沉降及区域交通网络形变识别等展开。Zhu等^[34]将改进的InSAR变形模型用于佛山软土地地区高速公路沉降监测，反演了路基长期沉降时间序列，并通过水准测量验证了InSAR结果的可靠性；Xing等^[35]进一步针对软黏土路基高速公路沉降监测中SBAS-InSAR变形模型选择问题进行了对比分析，指出考虑季节项的变形模型更适合表达软土地基沉降特征。上述研究表明，针对路基沉降等缓慢、持续性变形过程，InSAR能够提供较传统点式监测更连续的空间观测结果。

除高速公路路基沉降外，InSAR也被广泛用于铁路和区域线性基础设施监测。Zhang等^[36]利用多源SAR数据对青藏铁路拉萨—那曲段开展地表变形监测，指出多年冻土、工程扰动及地质灾害共同影响铁路沿线变形特征，说明InSAR适用于高寒、高海拔地区线性基础设施长期变形识别。Gao等^[37]以巴塞罗那都市区关键基础设施为对象，利用PS-InSAR方法监测铁路、高速公路等目标的沉降、隆起及热胀冷缩变形，证明了InSAR在城市交通基础设施运行状态识别中的应用潜力。

近年来，针对公路不均匀沉降和健康监测需求，研究者开始比较不同InSAR技术在道路场景中的适用性。Zhao等^[46]采用PS-InSAR、SBAS-InSAR和DS-InSAR三种方法对江苏G15沿海高速公路部分路段进行监测，结果表明三种方法在道路沉降识别中具有较好一致性，可为高速公路长期健康监测提供技术支撑。进一步地，有研究围绕交通基础设施目标散射体稀疏、相干点分布不均等问题^[38]，对Sentinel-1 InSAR像元选择方法进行了对比，指出合理的像元筛选策略能够提升交通基础设施位移监测的稳定性和可靠性。这些研究说明，InSAR在线性交通基础设施监测中已从单一路段沉降识别，逐步发展到面向道路、铁路及城市基础设施网络的长期形变监测。

高速公路沿线滑坡、崩塌和高边坡失稳通常具有明显的缓慢变形前兆，因此InSAR在道路边坡和沿线滑坡隐患识别中具有重要应用价值。Bianchini等^[71]较早利用PSI技术开展滑坡活动性制图，将InSAR形变信息用于活动滑坡识别和分级管理，为道路沿线滑坡隐患筛查提供了重要思路。Bekaert等^[39]提出了一种基于InSAR时间序列的慢速滑坡识别方法，通过空间滤波和聚类分析等方法，在尼泊尔山区识别出多个潜在滑坡，表明InSAR可在缺乏地面监测条件的山区实现活动

滑坡识别。Kang等^[40]利用升轨和降轨InSAR数据监测附近多处缓慢滑坡，结果表明InSAR能够识别复杂地形条件下的滑坡蠕动过程，并揭示降雨与滑坡运动之间的滞后响应关系。

在滑坡监测方面，Handwerger等^[41]基于InSAR分析了滑坡灾害前的长期变形过程，指出在滑坡易发区域中，变形模式变化可为不稳定边坡识别提供依据。Niu等^[42]利用Sentinel-1A数据和SBAS-InSAR技术，对独库公路沿线184处地质灾害区域开展近3年变形特征提取与分析，并结合聚类评价模型识别灾害敏感性，为道路沿线灾害识别提供了参考。Duan等^[43]以贵州毕节地区高速公路边坡为对象，结合C波段Sentinel-1A和L波段ALOS-2数据识别公路沿线变形点，并通过现场验证确认多处公路沿线的地质灾害点，说明多源InSAR能够降低山区公路边坡隐患排查成本并提高识别效率。

国内外针对滑坡和边坡的InSAR研究还表明，不同雷达波段、不同轨道方向以及不同时间序列方法对复杂地形区变形识别能力存在差异。Li等^[44]提出面向库岸不稳定斜坡长期演化监测的InSAR后处理方法和应用策略，强调了水位波动、植被覆盖等条件对InSAR监测结果的影响。Liu等^[45]针对青藏高原高山区活动滑坡，提出了改进InSAR方法用于滑坡灾害制图和分类，说明在高山峡谷等复杂地形条件下，InSAR仍可为滑坡识别和灾害风险管控提供重要信息。

随着Sentinel-1等中低分辨率SAR数据的长期开放，InSAR在区域尺度路网变形筛查中的应用逐渐增多。Felipe等^[55]以意大利罗马路网为对象，利用Sentinel-1 PSI结果获取大范围路网变形总体分布，并结合COSMO-SkyMed高分辨率数据对典型重点路段进行精细分析，提出了“中低分辨率卫星用于区域筛查、高分辨率卫星用于重点诊断”的技术思路。该类方法契合交通基础设施管理中“先普查、后详查”的技术需求，先利用大范围InSAR结果识别疑似异常路段，再对重点区域开展高分辨率监测。在城市交通基础设施场景中，Liao等^[54]利用高分辨率TerraSAR-X影像对上海高架道路开展时序变形分析，并引入归因分析模型识别高架道路变形与区域沉降、交通荷载和建设时间之间的关系，说明高分辨率InSAR不仅能够识别道路结构变形，也可支撑变形成因解释。

从工程应用角度看，InSAR在道路沿线灾害筛查中的业务化应用也逐渐受到重视。我国已有《地质灾害InSAR监测技术指南（试行）》等技术文件^[50]，对InSAR在滑坡、崩塌、泥石流、地面塌陷、地面沉降和地裂缝等地质灾害监测中的适用对象、数据处理和成果表达提出了技术要求。同时，《地质灾害危险性评估规范》、《地质灾害排查规范》等^{[51][52]}文件也将InSAR监测技术指南列为相关技术依据，说明InSAR已逐渐纳入地质灾害监测技术体系。

1.2.3 风险评估方法研究现状

公路灾害风险通常由滑坡、崩塌、泥石流、地面塌陷、洪涝冲毁等多灾种共同构成,其风险评估方法总体与地质灾害风险评估方法一致,但在线性工程对象、沿线空间异质性等方面具有更强的场景约束。现阶段相关研究方法主要可归纳为以下几类。

(1) 经验权重与半定量综合评价方法

经验权重与半定量方法以指标体系和权重构建为核心,能够将地形、地质、降雨、人类活动等因子综合为风险等级或易发性分区,因其实现简便、可解释性强,仍被广泛用于道路灾害快速评价与规划选线阶段,主要包括AHP、模糊综合、灰色关联、信息量法等。

例如, Yoshimatsu等^[59]利用层次分析法对日本滑坡易发区的微观因子进行评分,评价了山体滑坡的易发性。Yalcin^[60]利用AHP结合GIS的方式对滑坡敏感性进行分析,通过构建多因子空间数据库进行综合分析,生成研究区滑坡易发性分区图,为滑坡高风险区识别提供依据。Park等^[61]使用层次分析法生成韩国滑坡易发性指数,用于预测可能发生的滑坡灾害,并与频率比法、逻辑回归法、人工神经网络法对比,指出AHP的总体精度与多种模型方法大致相似。Kanwal^[62]结合地质、地形、水文、人为诱导四类指标组,采用AHP对巴基斯坦北部山区进行滑坡敏感性分析并制作危险度图。Bathrellos等^[63]在希腊河流域分别构建滑坡、洪水、地震危险性评价图,并进一步叠加形成多灾种危险性图,用于支撑城市发展适宜性分析与选址决策。模糊综合评价常用于处理指标阈值不清晰或边界模糊的问题,例如Yang等^[64]基于多类影响因子建立三级模糊综合评价模型,对公路边坡稳定性等级进行分级评价,从而实现对边坡风险的综合判别;灰色关联分析法、信息量法等常用于快速筛查因子贡献与灾害易发区,例如Pasang等^[65]沿亚洲公路AH48采用信息量法生成滑坡易发性分区图,实现道路高风险区识别。

这类方法的突出优势是框架直观、易与工程经验融合;但其局限在于权重依赖主观判断、难刻画强非线性耦合与因子交互,在跨区域迁移时稳定性较弱。

(2) 统计模型与概率推断方法

为降低主观赋权影响并提高可检验性,许多研究引入统计学与概率推断方法,基于历史灾害样本建立“因子组合—灾害发生概率”的映射关系。

例如, Westen等^[66]基于证据权重思想对滑坡易发性进行概率推断,形成了较为成熟的统计框架,并被后续研究广泛借鉴用于不同地区的滑坡危险性制图。Ayalew等^[67]采用逻辑回归模型对滑坡发生概率进行估计,并识别主控因子提升模型解释性与可重复性。在道路场景中,有研究沿交通走廊构建频率比模型,将坡度、地层、距河流距离等因子与滑坡分布频率的关系量化,得到公路沿线滑坡易

发性指数并用于高风险路段筛查。

该类方法的优势在于推断机制相对清晰，可进行显著性检验和误差分析；但当样本不平衡或标签存在偏差时，模型拟合能力与泛化能力可能受限。

（3）机器学习与集成学习方法

随着数据驱动方法发展，机器学习逐渐成为公路灾害风险评估的主流技术路线，尤其适用于多因子耦合、非线性显著且变量交互复杂的情形。

例如，Hong等^[68]以随机森林算法构建滑坡敏感性模型，并指出RF在多源变量下具有较强的泛化能力与较高预测精度。Tien等^[69]对比SVM、RF、神经网络等模型在滑坡易发性制图中的表现，结果表明集成学习在不确定性较大的地质数据环境中更具稳定性。Sun等^[70]引入机器学习算法对滑坡易发性进行建模，通过特征重要性分析识别坡度、地形湿度指数等关键因子，并在测试集上取得较高的预测性能。在道路多灾种场景下，有研究以道路缓冲带为分析区域，结合地形、降雨、地质与人类活动因素训练RF、XGBoost模型输出道路沿线风险概率，并以命中率评价风险评估结果。

（4）多源监测数据融合与动态风险评估

近年来，地质灾害风险评估研究正由基于地形、地质、土地利用等静态背景因子的易发性评价，逐步转向融合地表变形、降雨过程、库水位变化、地下水响应及工程扰动等动态信息的综合风险识别。传统静态易发性评价能够反映灾害发生的空间背景条件，但难以刻画灾害体当前是否处于活动状态，也难以反映降雨、库水位波动和工程扰动等外部因素作用下的时序演化特征。因此，将InSAR变形监测、地面监测数据和多源环境变量纳入风险评估框架，已成为提升灾害现势性识别和动态预警能力的重要方向。

在灾害易发性评价方面，早期研究主要将InSAR结果用于滑坡识别和隐患区筛查。Bianchini等^[71]基于PSI数据开展滑坡活动性制图，利用地表变形速率判别滑坡活动状态，为隐患点分级管理提供了动态依据。随后，相关研究逐渐由活动性判别拓展到InSAR变形信息与机器学习模型耦合的动态易发性评价。Wei等^[72]提出融合机器学习模型与InSAR技术的动态滑坡易发性评价方法，结果表明，引入InSAR变形信息后，模型在区域尺度和局部尺度上的高易发区识别能力均得到提升，并减少了误判和漏判现象。Zhou等^[73]将MT-InSAR提取的地表变形速率引入滑坡危险性制图框架，通过经验评价矩阵生成动态危险性图，证明了InSAR变形信息能够有效增强传统静态危险性评价对活动滑坡的识别能力。

在InSAR与机器学习耦合的风险识别方面，已有研究开始将InSAR变形速率、累计变形量或变形强度作为动态因子，与地形、地质、降雨、土地利用等静态因子共同参与建模。Yao等^[74]以金沙江上游地区为例，比较了多种机器学习模型在考虑InSAR变形信息条件下的滑坡易发性制图效果，指出InSAR变形因子能够增

强模型对活动滑坡区域的识别能力。Vaka等^[75]构建了融合地球观测数据、历史滑坡样本和多时相InSAR结果的滑坡易发性模型，表明InSAR与机器学习结合能够提高区域滑坡识别精度。Zhang等^[76]在龙华县开展动态变形监测与可解释机器学习耦合研究，将SBAS-InSAR毫米级变形信息与多类地质环境因子共同用于滑坡易发性分析，进一步说明InSAR动态指标能够为静态易发性评价提供现实活动状态约束。

在动态风险评价和多源模型融合方面，近年来研究进一步从“是否引入InSAR变形因子”发展为“如何将变形监测、灾害触发因子与模型解释机制相结合”。Li等^[77]构建了融合随机森林模型与InSAR变形信息的动态滑坡易发性评价框架，通过对比基准模型和引入InSAR变形变量后的优化模型，说明动态变形信息能够提升模型对活动风险区的识别能力。Wang等^[78]以白鹤滩库区为例，将SBAS-InSAR获取的地表变形信息与可解释机器学习模型相结合，开展滑坡易发性评价，验证了InSAR动态变形因子在提升滑坡高风险区识别能力方面的有效性。Zhao等^[79]进一步结合可解释机器学习与MT-InSAR技术，针对不同类型滑坡开展精细化易发性评价，强调了变形监测与灾害类型划分、触发机制分析相结合的重要性。

在多源监测数据融合与滑坡位移预测方面，研究重点已由现状识别进一步拓展到趋势预测。Liu等^[85]提出基于多源监测数据融合的滑坡位移预测模型，将位移、环境和其他监测变量进行相关性分析与融合建模，以提高滑坡位移预测精度；Wang等^[81]将InSAR监测、多因子机理分析与深度学习模型相结合，用于滑坡时空演化分析和位移预测，说明InSAR不仅能够用于灾害识别，也能够为灾害演化预测提供关键动态观测量。

随着深度学习和时空建模方法的发展，部分研究开始关注InSAR时间序列、空间邻域关系与气象水文变量的联合建模。Zhang等^[82]提出基于图神经网络的InSAR滑坡位移预测框架，通过耦合空间关系和时间序列特征，提高了滑坡位移预测能力。Strnad等^[83]对多种深度学习方法在滑坡位移预测中的表现进行了比较，指出滑坡预警系统不仅需要降低预测误差，还应关注临近预警阈值时的预测可靠性。Ma等^[84]进一步提出InSAR-YOLOv8方法，从大范围InSAR监测结果中自动识别滑坡目标，表明InSAR与深度学习结合可提升区域滑坡自动识别效率。

多源监测数据融合与动态风险评估研究已由早期将InSAR用于活动性判别和结果解释，逐步发展到将InSAR变形、降雨过程、地面监测和机器学习模型联合用于动态易发性评估、风险分区与位移预测，呈现出明显的综合化发展趋势。

1.2.4 SBAS-InSAR方法的特点与适用性

InSAR变形监测方法并非单一技术路线，而是随着监测对象、散射体类型及应用场景的不同，逐步形成了D-InSAR、PS-InSAR、SBAS-InSAR和DS-InSAR等

多种典型方法。不同方法在监测对象、空间覆盖能力、结果精度以及复杂地表适应性等方面存在明显差异。为清晰说明SBAS-InSAR的技术特点及其在本文研究中的适用性，现对主流InSAR方法的优缺点进行归纳比较，如表1.2所示。

表1.2 主流InSAR方法优缺点对比

方法	主要特点	优点	缺点
D-InSAR ^[112]	基于两景影像获取变形信息	处理流程简单,适合快速获取短时段变形信息	易受大气延迟、时间去相关和DEM误差影响
PS-InSAR ^[106]	基于长期稳定的永久散射体开展时序变形反演	精度高,适合城市建成区及强散射目标监测	对稳定点目标依赖强,在山区、植被覆盖区监测点稀疏
SBAS-InSAR ^[116]	基于小时间基线和小空间基线干涉对开展时序分析	空间覆盖较好,适合大范围、长时序缓慢变形监测	结果受相位解缠质量、大气残差和低相干区影响较大
DS-InSAR ^[111]	基于分布式散射体相位优化提高监测点密度	可提升非城市区域监测点密度,增强自然地表覆盖能力	同质点识别和相位优化过程复杂,计算量大

D-InSAR虽然原理简单、处理效率较高，但其结果高度依赖单对影像质量，难以满足长期缓慢变形监测需求；PS-InSAR在城市建成区和强散射目标密集区域具有较高精度^[114]，但对永久散射体依赖较强，在山区、丘陵及植被覆盖区容易出现监测点不足的问题；DS-InSAR能够有效提高自然地表区域的监测点密度，但算法实现较为复杂，对数据质量、算力条件要求较高^[111]。相比之下，SBAS-InSAR通过构建小时间基线和小空间基线干涉网络，在空间覆盖能力、处理稳健性和区域尺度适用性之间取得了较好平衡，尤其适合大范围、长时序缓慢变形监测。

从方法特性来看，SBAS-InSAR具有三个方面的突出优势。首先，该方法对分布式散射体具有较好的适应性，能够在山地、丘陵、农田及道路沿线等自然地表区域保持较好的空间覆盖能力。其次，SBAS-InSAR利用多景SAR影像构建小基线干涉网络，能够获得研究区平均变形速率和时间序列信息，更适合刻画滑坡蠕变、软土沉降及路基缓慢不均匀变形等长期缓变过程。此外，多景冗余观测和时空滤波策略使其在一定程度上能够减弱大气延迟和随机噪声影响，从而提高结果稳健性。基于此，本文选用SBAS-InSAR作为高速公路路网沿线地表变形提取的主要技术方法。

1.3 目前研究工作不足

综上所述，现有高速公路路网变形监测与灾害风险评估研究已在传统监测技术、InSAR时序变形分析、多源因子风险建模以及动态风险识别等方面取得了较

多成果，为交通基础设施安全监测与灾害防控提供了重要技术支撑。然而，面向高速公路路网这一线性工程对象，现有研究仍存在以下三方面不足：

（1）面向高速公路路网的星载InSAR大范围变形提取与异常区识别研究仍不充分。现有InSAR研究多集中于城市地面沉降、矿区变形、单体滑坡或局部工程结构监测，对高速公路路网沿线这一狭长、连续且跨越多种地貌单元的工程对象关注不足。高速公路沿线地表覆盖类型复杂，既包括城市建成区、硬化路面和桥隧结构，也包括山地丘陵、植被覆盖边坡及农田等非强散射区域，导致相干性条件差异明显，给大范围连续变形提取带来一定困难。因此，如何基于星载SAR影像构建适用于高速公路路网沿线区域的SBAS-InSAR处理流程，获取可靠的变形速率场和时序变形结果，并识别典型异常变形区，是高速公路路网变形监测研究中仍需解决的问题。

（2）省域尺度高速公路沿线地质灾害背景风险识别研究仍需加强。现有道路灾害风险研究多针对局部边坡、单条道路或典型灾害点开展评价，对省域尺度高速公路沿线滑坡、地面塌陷等灾害风险的整体空间格局识别仍相对不足。高速公路沿线灾害发生受地形地貌、水文气象、地表覆盖、地质条件及人类工程活动等多种因素共同影响，不同灾害类型的形成机制和主控因子存在差异。若仅依赖单一灾种、单一因子或经验判断方法，难以全面揭示区域尺度灾害风险分布规律。

（3）InSAR动态变形信息与道路单元风险评估之间的耦合机制尚不完善。现有研究多将InSAR结果用于变形识别、活动性判别或局部灾害解释，而对如何将离散InSAR监测点转化为面向道路工程对象的结构化风险指标研究不足。同时，传统风险评估多基于地形、降雨、植被、道路密度等静态环境因子，能够反映灾害孕育背景，但难以刻画道路边坡、路基及周边地表当前是否已经出现持续变形或局部失稳迹象。对于高速公路路网而言，评价对象应与道路狭长、连续的空间特征相匹配，而不能仅停留在规则栅格或离散监测点层面。

基于上述不足，本文围绕“省域尺度风险初筛—城市尺度变形精析—道路单元尺度模型改进”的总体思路，开展基于SBAS-InSAR时序变形监测与机器学习风险建模的高速公路路网变形监测与风险评估研究。

1.4 本文研究内容

面对复杂地质环境下高速公路沿线灾害隐患识别难度大、传统监测方法难以满足大范围连续监测需求、静态风险评估难以反映道路当前变形活动状态等问题，以及交通基础设施安全韧性提升和灾害风险主动防控的重大需求，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)等课题开展相关研究。本文围绕高速公路路网变形监测与综合风险评估这一核心问题,开展了融合SBAS-InSAR时序变形监测与机器学习风险建模的多尺度研究,研究内容如图1.2所示。

(1) 面向高速公路沿线区域地表变形监测需求,开展SBAS-InSAR时序变形反演与城市尺度精细变形分析。以湖南省及长沙市高速公路路网为研究对象,收集并整理Sentinel-1 SAR影像、精密轨道数据、DEM数据等数据,建立适用于公路路网变形提取的SBAS-InSAR处理流程,获取研究区LOS向变形速率场及变形时间序列结果。进一步以长沙市为典型研究区,对SBAS-InSAR时序反演结果进行精细分析,提取道路沿线异常变形区域,为后续道路单元特征构建与风险评估提供动态变形信息。

(2) 构建面向公路沿线地质灾害风险识别的多源影响因子体系,开展湖南省尺度滑坡与地面塌陷分灾种风险评估。基于湖南省历史滑坡和地面塌陷灾害样本,构建包含高程、坡度、曲率、SPI、TWI、降雨量、NDVI、道路密度和河流密度等在内的多源影响因子体系,分别采用随机森林和XGBoost模型开展分灾种风险识别;通过ROC-AUC、PR-AUC及命中率等指标对模型性能进行评价,并生成湖南省滑坡和地面塌陷风险空间分布图,实现省域尺度路网灾害风险初筛。

(3) 构建道路单元级InSAR指标体系,提出静态—动态耦合的道路单元综合风险评估方法。针对道路工程狭长、连续的空间特征,构建道路单元作为基本评价对象,并提出自适应范围寻点方法,以解决InSAR监测点空间分布不均带来的特征提取问题;在此基础上,构建平均累计变形量、累计变形标准差、平均变形速率等道路单元级动态指标,实现从离散监测点到道路单元的特征转换。进一步筛选动态指标,采用熵权法确定权重,构建动态风险指数和动态修正系数,对道路单元静态风险进行修正,形成融合静态环境背景与动态变形响应的综合风险评估模型,从而提升道路高风险路段识别能力,实现由静态易发性评价向静态—动态综合风险识别的拓展。

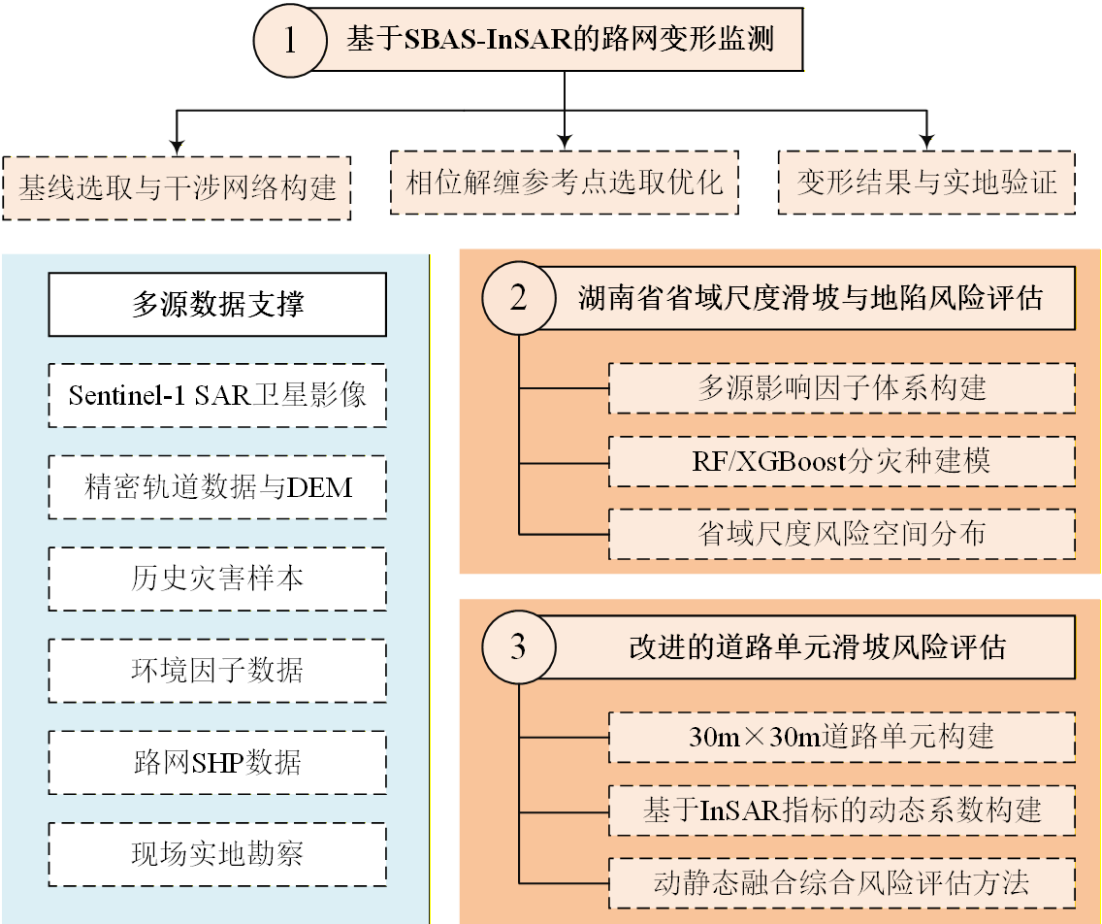


图1.2 研究内容图

第2章 星载时序InSAR变形监测理论与方法基础

2.1 引言

地表缓慢变形是滑坡、地面沉降、路基失稳等多类灾害孕育和演化过程的直接外在表征，也是开展道路灾害识别与风险评估的重要依据。对于高速公路沿线而言，许多灾害在失稳前通常经历较长时间的微小累积变形过程。因此，如何高效、连续地获取地表变形信息，是实现道路灾害监测与风险识别的关键问题。传统水准测量、GNSS和测斜仪等方法虽然在局部点位监测中具有较高精度，但难以满足大范围、长时序、连续化监测需求。星载InSAR技术具有全天时、全天候和大范围覆盖优势，为区域尺度缓慢变形监测提供了重要技术手段。然而，InSAR变形监测并非简单的图像差分过程，其结果获取依赖于雷达干涉测量几何、相位组成机理、时序反演方法以及关键处理参数设置等一系列理论与方法。尤其对于本文所采用的SBAS-InSAR技术而言，干涉网络构建、相位解缠、参考点选取和时序求解等环节均会直接影响最终变形结果的可靠性。基于此，本章首先介绍雷达干涉测量基本原理，阐明干涉相位的构成及其主要影响因素；其次，对PS-InSAR、SBAS-InSAR和DS-InSAR等典型InSAR变形分析方法进行归纳与比较；最后，结合研究需求提出基于相干系数与连通域的参考点选取方法，为后续开展高速公路路网时序变形提取奠定方法基础。

2.2 雷达干涉测量基本原理

2.2.1 InSAR干涉测量几何

InSAR技术的物理基础可以追溯到经典的波动干涉现象。以杨氏双缝干涉实验为例，如图2.1所示，点光源发出的相干光通过两条狭缝后传播至屏幕，由于两束光到达同一点的传播路径不同，因而产生相位差，并在屏幕上形成明暗相间的干涉条纹。其本质在于：两束相干波之间的传播路径差决定了相位差，而相位差进一步决定干涉增强或干涉减弱的结果。对于单色波而言，传播路径差 Δr 与相位差 $\Delta\phi$ 的关系可表示为：

$$\Delta\phi = \frac{2\pi}{\lambda} \Delta r \quad (2.1)$$

式中， $\Delta\phi$ 为相位差，单位为弧度； Δr 为两束波的传播路径差，单位为m； λ 为波长，单位为m。该关系表明，相位差与传播路径差成正比，这也是雷达干涉测量能够利用相位变化反映目标空间位置差异的物理基础。




图2.1 杨氏双缝干涉实验示意图

合成孔径雷达（Synthetic Aperture Radar, SAR）通过向地面目标发射微波电磁信号并接收其后向散射回波，实现对地观测。SAR回波信号通常由幅度和相位两部分组成，其中幅度反映地物后向散射强度，与目标的几何形态、粗糙度及介电特性有关；相位则主要由电磁波传播路径决定，是InSAR获取高程和变形信息的关键观测量。对于单个地面散射体，其回波相位可写为：

$$\varphi = -\frac{4\pi}{\lambda} R + \varphi_s \quad (2.2)$$

式中， φ 为回波相位； R 为雷达到地面目标的斜距，单位为m； λ 为雷达波长，单位为 m； φ_s 为与目标散射特性有关的附加相位项。式中负号表示随着传播距离增大，回波相位呈周期性变化。由于相位对距离变化极为敏感，因此当两次观测几何略有差异时，便可通过相位差探测目标变形^[98]。




图2.2 干涉测量几何示意图

InSAR干涉测量通常由两景SAR影像完成，其中先获取的影像称为主影像，后获取的影像称为辅影像。设卫星在两次成像时分别位于 S_1 和 S_2 ，观测同一地面目标点 P ，则主影像与从影像对应的斜距分别为 R_1 和 R_2 ，两次观测位置之间的空

间距离称为基线，记为 B 。由于两次观测位置不同，雷达波到达目标点的传播路径存在差异，从而产生干涉相位。主、从影像的回波相位分别表示为：

$$\varphi_1 = -\frac{4\pi}{\lambda} R_1 + \varphi_{s1} \quad (2.3)$$

$$\varphi_2 = -\frac{4\pi}{\lambda} R_2 + \varphi_{s2} \quad (2.4)$$

在目标散射特性保持基本稳定的条件下，可认为 φ_{s1} 与 φ_{s2} 的差异较小，则两景影像形成的干涉相位为：

$$\Delta\varphi = \varphi_2 - \varphi_1 = -\frac{4\pi}{\lambda} (R_2 - R_1) \quad (2.5)$$

式中， $\Delta\varphi$ 为干涉相位； $(R_2 - R_1)$ 为两次观测的斜距差。InSAR的核心是通过测量斜距差所引起的相位变化，实现对目标空间位置差异及变形信息的反演。

为了进一步描述干涉测量几何关系，通常将基线 B 分解为沿主视线方向的平行基线分量 $B_{\parallel}$ 和垂直于主视线方向的垂直基线分量 $B_{\perp}$ ，如图2.2所示。其中， $B_{\parallel}$ 主要影响平地相位， $B_{\perp}$ 与地形相位关系最为密切，是影响高程敏感性的关键参数。设目标点 P 的入射角为 θ ，相对于参考椭球面的高程为 h ，则在小基线近似条件下，地形起伏引起的斜距差可近似写为：

$$\delta R_{topo} \approx -\frac{B_{\perp}}{R \sin \theta} h \quad (2.6)$$

对应的地形相位为：

$$\varphi_{topo} = -\frac{4\pi}{\lambda} \delta R_{topo} = \frac{4\pi}{\lambda} \frac{B_{\perp}}{R \sin \theta} h \quad (2.7)$$

式中， φ_{topo} 为地形相位； R 为参考斜距； θ 为入射角； h 为目标高程。由上式可知，垂直基线越大，系统对地形起伏越敏感，但过大的垂直基线又会增加空间去相关风险，降低干涉图质量。因此，在实际处理中需要在高程敏感性和相干性之间进行权衡^[99]。

若地面目标在两次成像期间发生了沿雷达视线方向的位移 Δd_{LOS} ，则由变形引起的斜距差可表示为：

$$\delta R_{def} = -\Delta d_{LOS} \quad (2.8)$$

对应的变形相位为：

$$\varphi_{def} = \frac{4\pi}{\lambda} \Delta d_{LOS} \quad (2.9)$$

式中， φ_{def} 为变形相位； Δd_{LOS} 为地面目标沿雷达视线方向的位移分量。当目标朝向卫星运动时，斜距减小；当目标远离卫星运动时，斜距增大。需要指出的是，InSAR直接获取的是目标沿雷达视线方向的一维位移，而非地面目标的真实三维位移，因此在结果解释中应结合观测几何关系进行分析。

2.2.2 干涉相位组成

由前述InSAR干涉测量几何可知，两景SAR影像形成的干涉相位本质上来源于雷达波传播路径差。然而，在实际观测中，干涉相位并非仅由地形高程或地表变形单独决定，而是多种物理过程共同作用的综合结果。换言之，干涉图中每一个像元的相位信息，实际上同时包含了地形起伏、地表运动、大气延迟、轨道误差以及噪声等多种成分。因此，正确理解干涉相位的组成及各组成部分的物理含义，是后续进行地形相位去除、变形反演与误差校正的前提。

一般情况下，两景SAR影像形成的干涉相位可表示为^[100]：

$$\varphi_{\text{int}} = \varphi_{\text{flat}} + \varphi_{\text{topo}} + \varphi_{\text{def}} + \varphi_{\text{atm}} + \varphi_{\text{orb}} + \varphi_{\text{noise}} \quad (2.10)$$

式中， φ_{int} 为干涉相位； φ_{flat} 为平地相位； φ_{topo} 为地形相位； φ_{def} 为变形相位； φ_{atm} 为大气延迟相位； φ_{orb} 为轨道误差相位； φ_{noise} 为噪声相位。各项共同构成实际观测到的相位值，其中只有地形相位和变形相位是研究关注的有效信息，其余部分均属于需要抑制或校正的误差项。

(1) 平地相位 φ_{flat}

平地相位是由于地球曲率及主从影像成像几何差异引起的规则相位分量，即使地面完全平坦、无变形，也会因观测位置不同而产生系统性的相位变化。平地相位本质上与平行基线分量及观测几何关系有关，通常在干涉图中表现为大尺度、规则分布的条纹。由于卫星轨道参数和参考椭球模型已知，因此平地相位通常可以根据成像几何关系预先计算并去除。经过平地相位去除后，干涉图中保留下来的相位变化才更能反映真实地形与变形信息。

(2) 地形相位 φ_{topo}

地形相位是由目标高程相对于参考椭球面的起伏所引起的相位分量，是InSAR获取DEM信息的重要依据。当地面目标高程不同，其到主、从轨道的传播路径差也会发生变化，从而导致相位差异。地形相位与垂直基线分量 $B_{\perp}$ 、斜距 R 、入射角 θ 及目标高程 h 有关，其表达式如式(2.7)所示。

地形相位对垂直基线较为敏感，因此在实际处理中，常利用外部DEM模拟并去除地形相位，以突出地表变形信息。

(3) 变形相位 φ_{def}

变形相位是由于地表目标在两次成像期间发生位移而产生的相位分量，也是InSAR变形监测的核心信息来源。设目标沿雷达视线方向的位移为 Δd_{LOS} ，则变形相位可表示为：

$$\varphi_{\text{def}} = \frac{4\pi}{\lambda} \Delta d_{\text{LOS}} \quad (2.11)$$

其中， Δd_{LOS} 表示目标沿LOS方向的位移分量。当目标朝向卫星运动时，斜距

减小；当目标远离卫星运动时，斜距增大。

（4）大气延迟相位 φ_{atm}

雷达波在穿过大气层传播过程中，会因大气介质折射率变化而产生传播延迟，从而形成附加相位差，这部分相位称为大气延迟相位。大气延迟主要包括对流层延迟和电离层延迟两部分。其中，对流层延迟与温度、气压和水汽分布有关，在C波段InSAR应用中通常是主要影响因素；电离层延迟则与电子密度变化有关，在长波段雷达中影响更为显著。大气相位通常具有较强的空间相关性和一定的时间随机性，是时序InSAR处理中需要重点分离和校正的误差项之一。

若将大气延迟引起的传播路径变化记为 Δr_{atm} ，则其相位贡献可表示为：

$$\varphi_{atm} = \frac{4\pi}{\lambda} \Delta r_{atm} \quad (2.12)$$

大气延迟相位通常表现为大尺度缓变特征，易与低频变形信号混淆，因此需在时序处理中进行估计与削弱。

（5）轨道误差相位 φ_{orb}

轨道误差相位是由于卫星轨道参数存在偏差，使得主从影像的真实基线与理论基线不一致，从而引起的相位误差^[101]。其影响通常表现为大尺度长波趋势项，会对干涉图整体相位场产生系统性偏移。尤其在研究区范围较大时，轨道误差常与大气长波误差共同表现为缓慢变化的相位背景，对局部变形识别造成干扰。因此，在InSAR处理中通常需结合精密轨道数据或后续趋势面拟合方法减弱轨道误差影响。

（6）噪声相位 φ_{noise}

除上述相位项外，干涉相位中还包含由时间去相关、空间去相关、热噪声和处理误差等引起的随机噪声相位。时间去相关主要来源于两次成像间地表散射特性变化，如植被生长、土壤湿度变化等；空间去相关则与基线过大导致两次观测视角差异增大有关；热噪声则来自雷达系统本身的观测误差。噪声相位会降低干涉图相干性，削弱条纹连续性，并直接影响相位解缠与时序反演精度。因此，提高干涉图质量、控制基线参数、增强高相干目标识别，是保证InSAR监测精度的重要环节。

2.2.3 干涉相位误差来源与质量影响因素

虽然InSAR技术能够利用相位差高灵敏度地反映地形起伏和地表变形，但在实际应用中，干涉相位往往会受到多种误差因素影响，进而降低干涉图质量和变形反演精度。由于InSAR变形监测本质上是对微小路径差进行高精度测量，因此任何影响电磁波传播路径、散射特性或成像几何关系的因素，都可能在干涉图中

表现为误差项。特别是在植被覆盖区、地形起伏区及长时序处理场景下，这些误差的叠加效应更为明显。因此，系统分析干涉相位误差来源及质量影响因素，是开展时序InSAR处理和结果解释的重要基础。

（1）时间去相关

时间去相关是影响干涉图质量的主要因素之一，是指同一地面分辨单元在两次成像之间散射特性发生变化，导致相位相关性降低^[102]。其主要原因包括植被生长、土壤湿度变化、地表耕作活动、建筑物状态变化以及降雨、风扰动等外部环境影响。当时间间隔较长时，地物散射中心往往难以保持稳定，干涉相位中随机成分增加，相干性显著下降，从而使干涉条纹模糊甚至完全丢失。

（2）空间去相关

空间去相关是由于主从影像成像位置存在差异，使得两次观测的视角不同，从而导致同一分辨单元内实际响应散射体不完全一致所引起的相干性降低^[89]。空间去相关程度与基线长度密切相关，特别是垂直基线分量越大，空间去相关越明显。当基线超过临界基线时，两景影像之间的相位相关性将迅速降低，干涉图质量明显恶化。因此，在SBAS-InSAR处理中通常通过设置较小的时间基线和空间基线阈值构建干涉网络，以尽量减弱时间去相关和空间去相关的影响。

（3）大气延迟误差

大气延迟误差是InSAR处理中最常见且最难完全消除的误差来源之一^[93]。雷达波在穿过大气层时，会受到对流层和电离层折射率变化的影响，从而产生附加传播延迟^[103]。对于C波段SAR数据而言，对流层延迟通常是主要影响因素，其变化与气压、温度和水汽分布密切相关。大气延迟误差往往在空间上表现为长波、缓变特征，在时间上则具有较强随机性，因此容易与低频变形信号相混淆。若不加以校正，可能导致变形速率场中出现虚假的大范围沉降或隆起趋势。

（4）轨道误差

轨道误差来源于卫星轨道参数的不精确，表现为实际轨道位置与理论轨道位置之间存在偏差^[108]。轨道误差会导致干涉图中出现长波趋势项，通常在大范围研究区中表现更为明显。虽然现代SAR数据处理一般可通过精密轨道产品显著减弱该项误差，但在高精度变形监测场景中，轨道残差仍可能对结果造成影响。因此，在实际处理中通常还需要结合趋势面拟合或空间滤波等方法进一步削弱其影响。

（5）DEM误差

在差分干涉处理中，通常需要利用外部DEM模拟并去除地形相位^[91]。若DEM本身精度不足，或DEM与SAR影像配准存在偏差，则会在差分干涉图中残留部分地形相位，形成DEM误差项。该误差通常与垂直基线相关，并在地形起伏较大区域表现更为明显。DEM误差不仅会影响地形相位去除效果，还可能干扰后续变形相位估计，因此在山区变形监测中需特别关注外部DEM的精度和分辨率。

（6）热噪声与系统噪声

热噪声和系统噪声来源于雷达仪器本身及信号接收过程中的随机误差^[102]。这类误差通常表现为无明显空间结构的随机相位扰动，其影响与目标后向散射强度有关。对于散射较弱、信噪比较低的区域，热噪声会显著降低干涉图质量，增加相位解缠难度^[106]。在多数情况下，热噪声虽不像大气延迟和去相关那样造成大尺度误差，但会直接影响局部像元的相位稳定性，是限制高精度反演的重要因素之一。

（7）地形条件与地物覆盖类型影响

地形条件和地表覆盖类型也是决定干涉图质量的重要影响因素^[94]。在平坦地区，散射中心相对稳定，干涉条纹通常较为连续；而在山地、峡谷及高坡度区域，由于坡面朝向差异、阴影与叠掩效应显著，易造成部分区域失相干甚至无有效观测^[95]。对于不同地物类型而言，城市建筑、裸岩和硬化路面通常具有较高相干性，而林地、耕地和水体区域则相干性较低。

（8）参考点选取与相位解缠误差

在时序InSAR处理中，参考点选取和相位解缠质量也是影响结果可靠性的关键因素^[98]。由于InSAR变形结果本质上属于相对测量结果，若参考点位于低相干区或变形区，可能在整个研究区引入系统偏差。与此同时，若干涉图质量较差、条纹连续性不足或局部存在强噪声，则相位解缠过程中容易出现跳变和错误传播，进而影响后续时序反演结果。

2.3 SBAS-InSAR变形分析方法

2.3.1 SBAS-InSAR基本思想与小基线干涉网络构建

小基线集干涉测量（Small Baseline Subset InSAR, SBAS-InSAR）是时序InSAR变形监测中的经典方法之一^[87]，其核心思想是在多时相SAR影像中优先选取时间基线和空间基线均较小的影像对构建干涉网络，以降低时间去相关和空间去相关对干涉相位质量的影响，并在此基础上联合多景干涉图实现地表变形时间序列反演。与传统D-InSAR仅利用单对影像获取某一时段相对变形信息不同，SBAS-InSAR通过引入多时相冗余观测，在提高结果稳健性的同时，能够在一定程度上削弱大气延迟和随机噪声对反演结果的影响，进而获得研究区平均变形速率和各时刻累计变形量。

从监测对象来看，SBAS-InSAR与PS-InSAR存在明显差异。PS-InSAR主要依赖分辨单元内由单个或少数强散射体主导的稳定点目标^[88]，其基本思想是利用这类目标长期保持稳定散射特性的特点，提取高相干点并开展时序变形分析。而SBAS-InSAR更强调在保证干涉图质量的前提下保留尽可能多的干涉对^[92]，并利

用分布式散射体扩大有效监测点的覆盖范围。对于高速公路沿线场景而言，沿线往往同时包含城市建成区、农田、丘陵、山地和植被覆盖区等多种地表类型，若仅依赖稳定点目标，监测结果容易在非城市区域出现点位稀疏的问题，而SBAS-InSAR在这类复杂地表条件下通常具有更好的适应性。




图2.3 监测对象回波信号特征示意图

如图2.3 (a) 所示，在稳定点目标主导的分辨单元中，回波信号可看作稳定散射体信号与随机噪声的叠加。当目标散射能力较强时，随机噪声对总回波相位的扰动较小，相位稳定性较高；而当目标散射较弱时，在相同噪声条件下相位波动更明显，稳定性相对较差。因此，PS类方法更适用于建筑物、桥梁等强散射目标丰富区域。图2.3 (b) 表明，对于分布式散射体，单个像元中通常不存在绝对占优的强散射点，其回波由多个具有相近统计特性的散射体共同贡献，并叠加随机噪声。通过对同质像元进行相干叠加，可在一定程度上削弱随机噪声影响，增强真实信号，从而提高相位稳定性和监测点密度。这种特性使SBAS-InSAR在山地、丘陵、裸土区和部分植被覆盖区具有较好的空间适用性，也更符合本文公路路网变形监测的场景需求。

SBAS-InSAR的实现基础是由多幅SAR影像构成的小基线干涉网络^[104]。设研究区共获取 $N+1$ 景SAR影像，其成像时刻分别为 $t_0, t_1, \dots, t_N$ 。在满足小基线约束条件下，可从中选取 M 对影像形成干涉对，每个干涉对对应一幅差分干涉图。小基线是指影像对之间的时间间隔和轨道空间分离均应控制在较小范围内，以尽量减弱时间去相关和空间去相关影响。对于任意一组由时刻 t_A 和 t_B 构成的干涉对，其时间基线可表示为：

$$\Delta T = |t_B - t_A| \quad (2.13)$$

式中， ΔT 为时间基线； t_A 和 t_B 分别为两景影像的成像时刻。时间基线越大，地表散射特性在两次观测间发生变化的可能性越大，从而更容易引起时间去相关。

空间基线则是指主影像与辅影像成像时卫星轨道位置之间的空间距离^[119]。设两次观测位置之间的基线长度为 B ，通常可将其分解为沿主视线方向的平行基线分量 $B_{\parallel}$ 和垂直于主视线方向的垂直基线分量 $B_{\perp}$ 。其中， $B_{\perp}$ 与地形相位敏感性和空间去相关程度关系最为密切，是小基线筛选的重要依据。垂直基线越大，系统对地形起伏越敏感，但同时也更容易导致空间去相关增强，降低干涉图质量。因此，在SBAS-InSAR处理中需要设定合理的时间基线阈值和空间基线阈值，仅保留满足条件的影像对参与后续处理。

在上述约束条件下，由多景影像筛选得到的干涉对集合构成SBAS的小基线干涉网络。一个合理的小基线干涉网络应同时满足以下要求：首先，干涉对数量充足，能够为变形时序反演提供足够冗余观测；其二，网络连通性良好，使各成像时刻均能通过干涉对建立联系；其三，时间基线和空间基线分布合理，在保证干涉图质量的同时兼顾时序分辨率。因此，SBAS网络构建实质上是在观测冗余、网络连通性和干涉图质量之间进行平衡。

与PS-InSAR主要依赖单景主影像构建干涉网络不同，SBAS-InSAR采用多主影像、小基线约束的方式构建干涉网络。前者通常以一景质量较高的影像作为统一主影像，其余影像分别与该主影像形成干涉对；后者则在全部影像中优先选取时间基线和空间基线均较小的影像对，构建具有良好连通性的小基线干涉网络，以降低去相关影响并提高时序反演的稳健性。两种方法在干涉对组合方式上的差异如图2.4所示。




图2.4 PS方法与SBAS方法干涉对组合^[105]

PS-InSAR的干涉网络结构相对简单，适用于稳定点目标较丰富的区域；而SBAS-InSAR通过构建多景影像之间的小基线连接网络，能够在保证网络连通性的同时减弱时间去相关和空间去相关影响，更适合长时序、多景影像条件下的区域尺度缓慢变形监测。

2.3.2 SBAS-InSAR时序变形求解

SBAS-InSAR是一种基于多时相SAR影像的小基线时序干涉测量方法，其时

序变形求解流程主要包括差分干涉图生成、外部DEM引入、高质量像元筛选、相位解缠以及时序变形反演等环节。

本研究通过改进后的SBAS-InSAR时序变形分析技术开展长沙市高速公路路网沿线地表变形监测。不同于传统仅面向区域地表变形的一般SBAS-InSAR处理流程，本文结合高速公路路网的线性分布特征、沿线地质环境差异，对SBAS-InSAR的处理过程进行了针对性优化，以提高路网沿线变形提取的有效性与可解释性，处理流程如图2.5所示。




图2.5 SBAS-InSAR处理流程图

在SBAS-InSAR处理中，首先需要对多时相SAR影像进行精确配准。由于干涉相位对像元位置偏差极为敏感，只有主、辅影像中同一地面目标能够被准确对应，后续干涉相位计算才具有物理意义。需从全部影像中选取一景影像作为参考影像，并将其余影像统一配准到该参考影像坐标系中。通过精确配准，可以保证不同时相影像在同一分辨单元内尽可能对应相同地面散射体，为后续干涉图生成提供几何基础。

差分干涉图的生成是SBAS-InSAR处理流程中的关键步骤。对于每一组满足小基线条件的主从影像，通过共轭相乘可得到原始干涉图。由于原始干涉相位中同时包含平地相位、地形相位、变形相位和误差项，因此需首先利用轨道参数去除平地相位，再引入外部DEM模拟并去除地形相位，最终获得以变形信息为主的差分干涉图。设第 k 个干涉对对应的差分干涉相位为 $\phi_{diff}^{(k)}$ ，则其可写为：

$$\varphi_{diff}^{(k)} = \varphi_{def}^{(k)} + \varphi_{topo,res}^{(k)} + \varphi_{atm}^{(k)} + \varphi_{orb}^{(k)} + \varphi_{noise}^{(k)} \quad (2.14)$$

式中, $\varphi_{def}^{(k)}$ 为变形相位; $\varphi_{topo,res}^{(k)}$ 为DEM误差引起的残余地形相位; $\varphi_{atm}^{(k)}$ 为大气延迟相位; $\varphi_{orb}^{(k)}$ 为轨道残差相位; $\varphi_{noise}^{(k)}$ 为噪声项。由此可见, 即使经过差分干涉处理, 干涉图中仍包含非变形相位成分, 因此需依靠后续多时相联合反演进一步分离有效变形信息。

由于差分干涉图中常存在较强随机噪声和局部低相干区域, 在开展时序求解前通常还需进行相位滤波和高质量像元筛选。滤波的目的在于增强干涉条纹连续性、抑制高频噪声, 提高相位解缠成功率; 高质量像元筛选则结合相干系数、振幅稳定性指标进行, 以尽量保留相位稳定的像元参与后续计算。

相位解缠是SBAS-InSAR处理中不可缺少的环节。如图2.6所示, 由于雷达相位观测值本质上被限制在 $(-\pi, \pi]$ 区间内, 直接获得的是缠绕相位, 而不能直接用于变形量计算。通过相位解缠, 可将缠绕相位恢复为连续相位, 从而使其满足时序求解需要。对小基线干涉图而言, 由于基线较小、相干性相对较高, 其条纹连续性通常优于大基线干涉图, 因此更有利于提高解缠质量。解缠后的相位观测值构成了后续时序反演的直接输入。目前相位解缠主流方法主要包括基于路径跟踪的相位解缠算法^[109]、网络流算法^[108]、基于卡尔曼滤波的相位解缠算法^[110]等。




图2.6 相位解缠示意图

在时序反演中, SBAS-InSAR并不是对单幅干涉图分别求解变形量, 而是联合全部小基线干涉图建立时序观测方程。设研究区共形成 M 个小基线干涉对, 则对任意第 k 个干涉对, 其解缠后相位与两时刻累计变形量差之间满足如下关系:

$$\Delta\varphi_k = \frac{4\pi}{\lambda}(d_B - d_A) \quad (2.15)$$

式中, λ 为雷达波长; d_A 和 d_B 分别为时刻 t_A 和 t_B 相对于参考时刻的累计变形量。将全部干涉对联合表示, 可建立矩阵形式的观测方程: 斜体

$$Ad = \Phi \quad (2.16)$$

式中, A 为由干涉对连接关系构成的设计矩阵; d 为各时刻累计变形量向量; Φ 为解缠相位观测向量。进一步将累计变形量转化为相邻时刻之间的变形增量, 并采用最小二乘法或奇异值分解方法求解。

在得到各相邻时刻的变形增量后, 可通过逐步累加恢复研究时段内各时刻的累计变形量, 并进一步求取研究时段内的平均变形速率。设相邻时刻变形增量为 v_i , 则第 i 时刻相对于参考时刻的累计变形量为:

$$d_i = \sum_{j=1}^i v_j \quad (2.17)$$

若研究时段总时长为 T , 则平均变形速率可表示为:

$$\bar{v} = \frac{d_N - d_0}{T} \quad (2.18)$$

式中, $\bar{v}$ 为平均LOS向变形速率。通过上述过程, SBAS-InSAR最终可以输出像元级平均变形速率场、累计变形量分布以及典型点位时间序列曲线, 从而实现地表缓慢变形过程的连续监测。

2.3.3 基于相干系数与连通域的参考点选取方法

在SBAS-InSAR处理中, 参考点选取是影响相位解缠与时序反演结果可靠性的关键环节之一。由于InSAR变形结果本质上属于相对测量结果, 参考点通常被视为变形量为0的基准点, 其稳定性直接关系到结果中变形场的精度与可信度。若参考点位于低相干区、相位噪声较大区域或变形区, 则会在整个研究区引入系统偏差, 进而降低变形结果的准确性。因此, 在相位解缠前有必要优先选取相干性较高、空间连续性较好且尽可能稳定的像元作为参考点。为提高参考点选取的客观性与稳定性, 本文提出一种基于相干系数与连通域分析的参考点自动选取方法, 方法流程如图2.7所示。

该方法以平均相干系数图为基础, 通过“相干阈值筛选—连通域识别—区域评分—最优像元确定”的思路自动选取参考点。其基本原理在于: 高相干区域通常对应散射特性较稳定、相位噪声较小的地物目标, 因而更适合作为参考点候选区; 空间上连续且面积较大的高相干区域, 通常比孤立高相干像元具有更好的稳定性, 也更不易受到局部异常值和随机噪声影响; 在满足高相干和空间连续性的候选区域中, 进一步选取局部相干系数最高的像元作为最终参考点, 可以增强参考点的相位稳定性。

具体而言, 首先读取平均相干系数原始数据, 并根据影像距离向与方位向像元数将其重构为二维矩阵:

$$C = \{c_{ij} | i = 1, \dots, H; j = 1, \dots, W\} \quad (2.19)$$

式中, c_{ij} 表示第*i*行、第*j*列像元的平均相干系数; H 和 W 分别为影像在方位向和距离向上的像元数。为了剔除低相干区域, 对整幅平均相干系数图采用阈值 T_{coh} 进行二值化处理, 构建高相干候选区掩膜:

$$M_{ij} = \begin{cases} 1, & c_{ij} \geq T_{coh} \\ 0, & c_{ij} < T_{coh} \end{cases} \quad (2.20)$$




图2.7 参考点自动选取流程图

式中, T_{coh} 为相干系数阈值。这里是斜体 图2.6中又是正体 结合本研究区干涉图质量和相位稳定性特征, 取 $T_{coh} = 0.4$ 。即认为, 平均相干系数高于0.40的区域在干涉处理中具有较好的相位稳定性, 因此可作为参考点搜索的初始范围。通过该步骤, 原始相干系数图被划分为高相干候选区和低相干非候选区, 为后续连通域分析奠定基础。

在高相干掩膜基础上, 对二值图像进行连通域标记, 将空间上彼此连接的高相干像元划分为若干独立区域, 记为:

$$R_k, k=1, 2, \dots, N \quad (2.21)$$

式中, R_k 表示第*k*个连通域, N 为高相干掩膜中识别出的连通域总数。与单个高相干像元相比, 连通域分析具有两方面优势: 一方面, 可以有效抑制孤立噪声点对参考点选取的干扰; 另一方面, 面积较大的高相干连通区域通常表明该区域内部散射机制更一致、相位质量更高, 更适合作为稳定参考区。

对于每个满足面积要求的连通域, 进一步计算其平均相干系数:

$$\bar{c}_k = \frac{1}{|R_k|} \sum_{(i,j) \in R_k} c_{ij} \quad (2.22)$$

式中, $|R_k|$ 表示区域 R_k 的像元数, $\bar{c}_k$ 表示该连通域的平均相干水平。为了同时兼顾区域的整体相干质量和空间规模, 本文构建如下评分函数对候选区域进行评价:

$$S_k = \bar{c}_k \cdot \ln|R_k| \quad (2.23)$$

式中, S_k 为第 k 个连通域的综合评分。该评分函数中, $\bar{c}_k$ 用于反映区域整体相干水平, $\ln|R_k|$ 用于表征区域规模, 并通过对数形式减弱面积对评分结果的绝对主导作用, 从而避免超大区域仅凭面积优势压制相干质量更高的中小区域。根据评分结果, 可确定综合表现最优的参考区 R^* 。

在确定最优参考区后, 进一步在该区域内部选取相干系数最高的像元作为最终参考点, 其坐标满足:

$$(r^*, a^*) = \arg \max_{(i,j) \in R^*} c_{ij} \quad (2.24)$$

式中, (r^*, a^*) 为最终参考点的像元坐标, r^* 和 a^* 分别表示参考点在距离向和方位向上的位置索引。最终输出结果采用像素坐标形式表示, 为后续相位解缠与时序反演提供统一的参考基准。

在本研究中, 该方法用于对平均相干系数图进行自动分析, 从中识别高相干、空间连续且稳定性较高的候选区域, 并进一步选取最优像元作为参考点。相较于直接人工选点或仅依据单像元最大相干系数进行选取的方式, 基于相干系数与连通域分析的自动选取方法能够更有效地抑制低相干区和孤立异常像元对参考点确定的干扰, 从而提高参考点选择的客观性与稳定性。

2.4 本章小结

本章围绕星载时序 InSAR 变形监测的理论与方法基础, 系统梳理了从雷达干涉测量几何到 SBAS-InSAR 时序反演, 再到参考点自动选取的关键内容, 为后续高速公路路网变形提取与风险评估研究奠定了理论与方法基础。主要结论如下:

(1) 阐明了 InSAR 干涉测量的基本几何关系及干涉相位组成机理。通过分析主从影像观测几何、基线分解方式以及雷达视线方向位移响应关系, 明确了干涉相位由地形相位、变形相位、大气延迟、轨道误差和噪声等多种成分共同构成, 并进一步归纳了时间去相关、空间去相关、大气延迟误差等影响干涉图质量的主要因素, 为后续差分干涉处理和时序变形反演提供了理论依据。

(2) 系统介绍了 SBAS-InSAR 时序变形分析方法及其适用性。围绕 SBAS-InSAR 的基本思想、小基线干涉网络构建、时序变形求解流程及其主要特点, 说明了该方法能够通过控制时间基线和空间基线、联合多景干涉图观测实现大范围缓慢变形的稳健反演。与 D-InSAR、PS-InSAR 和 DS-InSAR 等方法相比, SBAS-

InSAR在空间覆盖能力、地表适应性及区域尺度应用方面具有较好平衡，更适合高速公路这类跨越多种地貌单元和地表覆盖类型的复杂场景。

(3) 提出了基于相干系数与连通域分析的参考点自动选取方法。该方法以平均相干系数图为基础，通过相干阈值筛选、连通域识别、区域综合评分和最优像元确定，实现了参考点的自动化选取。相较于直接人工选点或仅依据单像元最大相干系数进行选取的方式，该方法能够有效降低低相干区和孤立异常像元对参考点选取的干扰，提高参考点选取的客观性与稳定性。

第3章 基于SBAS-InSAR的路网变形提取

3.1 引言

高速公路路网沿线变形是滑坡、路基沉降和局部失稳等灾害孕育与演化的重要外在表现，也是开展道路风险识别与隐患筛查的关键基础信息。对于山区、丘陵及地质条件复杂区域的高速公路而言，灾害往往并非突然发生，而是经历由微小变形逐步累积并最终演化为失稳破坏的过程。因此，从区域尺度获取连续、可靠的地表变形信息，对于识别异常活动区、支撑后续风险评估和提升道路安全监测能力具有重要意义。相比传统点式监测方法，星载InSAR技术具备大范围、长时序和毫米级变形探测优势，能够为高速公路沿线变形识别提供有效技术途径。本章以长沙市高速公路路网沿线区域为研究对象，基于Sentinel-1 SAR影像和SBAS-InSAR技术，开展多时相影像处理、差分干涉图生成、相位解缠及时序变形反演研究，最终获取研究区变形速率场和变形时序结果。围绕上述目标，本章主要开展以下三方面工作：首先，结合研究区高速公路路网分布、地表环境特征及SAR数据覆盖条件，对研究区进行分析并整理影像、轨道、DEM等基础数据；其次，建立适用于高速公路沿线场景的SBAS-InSAR处理流程，完成影像预处理、干涉对构建、差分干涉处理和时序反演；最后，结合典型异常区域和现场调查资料，对InSAR结果进行验证，评估其变形识别的有效性。

3.2 研究区介绍

本研究以长沙市高速公路路网沿线区域为研究区。长沙地处湖南省东部偏北、湘江下游，是湖南省省会和长株潭城市群核心城市，承担着省域综合交通枢纽和区域联通过道的重要功能。全市土地面积约11819km²，2024年末常住人口为1061.65万人^[115]，研究区兼具大城市基础设施密集与城郊山丘区广布的双重特征，具有开展高速公路沿线地表变形监测与风险分析的代表性。

从地形地貌条件看，长沙地貌类型多样，整体呈现东北、西北山地环绕，中部和北部相对开阔的空间格局。长沙山地占29.52%，丘陵占17.74%，岗地占23.28%，平原占25.30%，水面占4.16%；地势总体起伏较大，中部由湘江贯穿，南部丘岗起伏，北部趋于平坦开阔。大围山七星岭海拔1607.9m，浏山瓦子寨海拔1070.8m，地形高差显著。该类山地、丘陵及平原并存的地貌格局，使得高速公路沿线既存在切坡段、填挖交界段和高边坡路段，也分布有沿江平原和软弱地基区段，为不同类型变形响应提供了典型地形背景。

从气候水文条件看，长沙属亚热带季风性湿润气候，年均气温约16.8—17.2℃，

年均降雨量约1300 mm，降雨年内分配不均，4—6月为主要雨季，降雨量约占全年的51%。湖南整体年平均降雨量在1200—1700 mm之间，且雨季降雨通常集中于全年降雨量的50%~60%，长沙所在的湘中地区雨季一般从3月底或4月上旬持续至7月初。2024年6月长沙还出现了单小时65.1 mm的极端降雨^[117]，反映出研究区降雨过程具有明显集中性和突发性。水文方面，湘江流经市区约25 km，支流包括浏阳河、浏江、靳江、捞刀河等，区域河网较为发达。上述气候水文条件使得研究区高速公路边坡与路基在雨季更易受到降雨入渗、地下水位波动及坡脚冲刷等因素影响，从而诱发或加剧缓慢变形。

从地质与灾害背景看，长沙总体地质特征表现为地层出露较全、地貌类型复杂、地表水系发育，中部为长衡丘陵盆地向洞庭湖平原过渡地带，东北部和西北部山地较多。该类地质地貌条件决定了研究区高速公路沿线既存在山地丘陵区边坡变形和滑坡隐患，也存在平原及沿江区域地基沉降和不均匀变形风险。湖南省地质灾害类型以滑坡为主，占比约85%—86.6%，且多发生于强降雨过程中，并常见于切坡建房、公路交通沿线等工程扰动区域；宁乡、浏阳等长沙周边地区也被列为地质灾害较为集中的区域。

本研究选择长沙作为研究区，主要基于以下考虑：其一，研究区地貌类型多样，能够覆盖高速公路沿线常见的丘陵、山地、岗地和平原场景；其二，降雨集中、河网发育且工程活动频繁，沿线变形响应具有较强代表性；其三，区域内高速公路路网分布较密，既适合开展城市尺度时序变形精细分析，也有利于支撑后续道路单元尺度InSAR指标提取及综合风险评估。

3.3 数据获取

3.3.1 SAR卫星数据

SAR数据的时序密度、空间覆盖能力以及成像稳定性对结果精度具有重要影响。考虑到研究区范围、数据获取条件及监测周期，本文选取欧空局Sentinel-1卫星获取的C波段SAR影像作为主要数据源，卫星参数如下表所示。

Sentinel-1卫星具备较高的时间分辨率与稳定的重访周期。Sentinel-1采用TOPS (Terrain Observation by Progressive Scans) 成像模式的干涉宽幅 (IW) 模式，具有较大的成像幅宽 (约250km) 和适中的空间分辨率^[118] (约5m×20m)。该特性使其能够在单景影像中覆盖较大区域，适合开展省域或城市尺度的地表变形监测，同时也能够保证高速公路路网等线性基础设施沿线的连续观测；且具有良好的轨道控制精度。此外，Sentinel-1任务具有长期连续观测计划，可为长期地表变形监测提供稳定的数据来源，使研究能够获得较长时间跨度和较高密度的影像数据，满足SBAS-InSAR方法对多时相影像数量的需求。

表3.1 Sentinel-1A卫星基本参数

参数类别	参数名称	参数值 / 描述
卫星基本信息	卫星名称	Sentinel-1A
	发射时间	2014年4月3日
	所属计划	欧盟Copernicus地球观测计划
	运行机构	欧洲航天局
轨道参数	轨道类型	近极地太阳同步轨道
	轨道高度	约693 km
	轨道倾角	98.18°
	重访周期	12 天（单星）
	重访周期（双星）	6天（Sentinel-1A + Sentinel-1B）
雷达系统	雷达类型	C 波段合成孔径雷达
	工作波长	约5.6 cm
	工作频率	5.405 GHz
	极化方式	VV、VH、HH、HV

Sentinel-1 SAR影像在时间分辨率、空间覆盖范围、轨道稳定性以及数据可获得性等方面具有优势，能够为本文开展高速公路沿线地表变形监测及后续风险分析提供可靠的数据基础。本文所选取影像空间覆盖范围如图3.1所示。

覆盖范围1的影像时间跨度为2024年9月7日至2025年8月21日，共24景；覆盖范围2的影像时间跨度为2024年9月2日至2025年8月28日，共31景。每景Sentinel-1影像具体获取时间如表3.2与表3.3所示。




图3.1 选取Sentinel-1影像覆盖范围

表3.2 区域1影像数据列表

序号	获取时间	序号	获取时间
1	20240907	13	20250129
2	20240919	14	20250306
3	20241001	15	20250318
4	20241013	16	20250330
5	20241025	17	20250411
6	20241106	18	20250423
7	20241118	19	20250505
8	20241130	20	20250517
9	20241212	21	20250716
10	20241224	22	20250728
11	20250105	23	20250809
12	20250117	24	20250821

表3.3 区域2影像数据列表

序号	获取时间	序号	获取时间
1	20240902	17	20250313
2	20240914	18	20250325
3	20240926	19	20250406
4	20241008	20	20250418
5	20241020	21	20250430
6	20241101	22	20250512
7	20241113	23	20250524
8	20241125	24	20250605
9	20241207	25	20250617
10	20241219	26	20250629
11	20241231	27	20250711
12	20250112	28	20250723
13	20250124	29	20250804
14	20250205	30	20250816
15	20250217	31	20250828
16	20250301		

3.3.2 精密轨道数据

在InSAR数据处理中，卫星轨道信息对干涉相位计算与影像精确配准具有重要影响。轨道辅助数据记录了卫星在成像过程中的位置和速度信息，是SAR数据处理流程中的重要辅助输入。通过引入高精度轨道数据，可以有效减少轨道误差对干涉相位的影响，提高干涉图生成与变形反演的精度。

Sentinel-1轨道辅助数据由Copernicus Precise Orbit Determination（POD）服务提供，根据生成时效性和精度的不同主要包括三种类型：预测轨道、恢复轨道以

及精密轨道。其中，精密轨道数据基于精确轨道定轨处理获得，是精度最高的轨道产品，通常在数据获取约20天后发布，适用于精度要求高的SAR数据处理与InSAR研究。

3.3.3 DEM数据

当前在星载InSAR研究中，应用较为广泛的全球DEM产品主要包括SRTM DEM、ASTER GDEM、ALOS World 3D以及Copernicus DEM等。SRTM DEM由NASA等机构基于航天飞机雷达测图任务获取，具有近全球覆盖和约30m空间分辨率，长期以来是InSAR处理中最常用的外部DEM之一；ASTER GDEM由NASA与日本METI联合发布，同样具有约30m分辨率，数据获取便捷，但其高程精度和局部伪差问题在复杂地形区相对较为明显^[120]；ALOS World 3D 由JAXA基于ALOS卫星PRISM立体测绘影像生成，AW3D30产品具有约30m空间分辨率，而其高精度原始产品AW3D则可达到更高空间分辨率，在地形表达能力方面具有一定优势；Copernicus DEM则是由欧洲航天局和欧盟Copernicus计划发布的全球数字高程模型，主要基于TanDEM-X任务获取的X波段SAR干涉测量数据生成，具有全球覆盖、一致性较好和产品质量控制较完善等特点。

考虑到本文研究区为长沙市高速公路路网沿线区域，地形条件复杂，对DEM的空间连续性和整体一致性要求较高。且Copernicus DEM GLO-30空间分辨率为30m，与本文后续多源环境因子数据分辨率较为匹配。此外，Copernicus DEM在水体平整、河流连续性和异常地形修正方面进行了专门优化，适合用于InSAR处理中地形相位去除。基于上述原因，本文采用Copernicus DEM GLO-30作为外部DEM数据，经处理最终得到湖南省Copernicus DEM GLO-30数据如图3.2所示。




图3.2 湖南省Copernicus DEM

3.4 Sentinel-1影像处理

3.4.1 干涉网络构建

干涉网络构建是SBAS-InSAR处理流程中的关键环节，其质量直接影响后续差分干涉图生成、相位解缠及时序变形反演的稳定性。对于高速公路沿线地表变形监测而言，研究区通常跨越城市建成区、丘陵区、农田区及植被覆盖区等多种地表环境，不同区域的散射特性和相干性存在明显差异。因此，在构建干涉网络时，需要同时兼顾影像间相干性、网络连通性和时序反演的观测冗余，以保证后续处理结果的可靠性。

由于原始Sentinel-1影像覆盖范围较大，若直接对整景数据进行处理，不仅计算量大，而且会引入大量与研究目标无关的区域噪声。因此，本文沿高速公路路网对计算区域进行分区处理。将路网按空间连续性与哨兵影像覆盖条件划分为11个计算子区，使每个子区满足以下三项：（1）SAR影像数据覆盖完整、干涉网络连通性良好；（2）地形变化与相干性条件相对一致；（3）单个区域计算量可控，降低内存占用与解缠失败风险。并且对相邻计算子区设置一定重叠带，用于结果拼接与边界一致性检验，避免分区处理带来的边界断裂与系统偏差。计算分区结果如图3.3所示。




图3.3 计算区域划分

本文以覆盖长沙市高速公路路网沿线区域的Sentinel-1影像作为基础数据。根据研究区影像获取情况，覆盖范围1的影像时间跨度为20240907—20250821，共24

景；覆盖范围2的影像时间跨度为20240902—20250828，共31景。为保证后续小基线网络构建的稳定性，首先需要从全部影像中选取合适的参考影像。参考影像的选取通常遵循以下原则：一是成像时间尽量位于整个时序中部，以减小与其他影像之间的平均时间基线；二是空间基线总体较小，以减弱几何去相关影响；三是影像本身成像质量较高，覆盖完整且噪声较小。基于上述原则，本文分别选取20250117和20250301作为两个覆盖范围的参考影像。

在参考影像确定后，进一步对全部影像进行时间基线和空间基线统计分析。结合研究区地表覆盖条件、Sentinel-1数据特征以及后续时序反演需求，本文设置时间基线阈值为80d，空间基线阈值为120m。在该约束条件下，仅保留同时满足时间基线与空间基线要求的影像对参与干涉网络构建。

采用上述阈值筛选后，区域1共生成干涉对111组，区域2共生成干涉对130组。由此构建的小基线干涉网络如图3.4所示。从网络结构上看，各时相影像节点之间保持了较好的连通性，多数影像至少与2景相邻时相影像建立了有效连接，能够满足SBAS-InSAR时序反演对网络连通性和观测冗余的要求。同时，干涉对时间基线集中在80 d以内，垂直基线集中在100 m以内，说明网络整体遵循了小基线原则，有利于减弱时间去相关和空间去相关影响，提高干涉图质量。




图3.4 时空基线连接图

在完成干涉网络构建后，进一步基于筛选得到的干涉对生成初始干涉图。初始干涉图反映了主从影像在同一地面目标上的复数相位差，是后续平地相位去除、地形相位模拟和差分干涉处理的基础。在满足小基线约束条件下，研究区多数干涉图能够保持较好的条纹连续性，说明所构建干涉网络在整体上具有较好的相干性基础；同时，部分区域仍存在条纹局部模糊、破碎或纹理不连续现象，这与植被覆盖、地形起伏及局部相干性较低有关，也表明后续差分干涉处理和滤波步骤的必要性。

为进一步定量评价各分区干涉图质量，本文计算了研究区平均相干性图，并

以此分析不同地表类型下的相位稳定性差异，局部结果如图3.6所示。平均相干系数能够综合反映多组干涉对在同一像元处的相位一致性，其值越高，说明该区域散射特性越稳定，干涉相位越可靠。由图3.5可见，城市建成区、道路硬化面及部分裸露地表表现出较高平均相干性，而山地植被覆盖区、水体及局部复杂地形区域则相干性相对较低。对于高速公路沿线变形监测而言，道路本体及部分邻近工程扰动区往往具有较好的相干性条件，而周边边坡和植被覆盖坡面则更容易出现相干性下降现象。这种空间差异特征与研究区实际地表覆盖类型相一致，也为后续参考点选取、高质量像元筛选和时序反演提供了依据。




图3.5 Z5平均相干性图

从时间分布特征来看，所构建的干涉网络能够较连续地覆盖整个监测时段，避免了局部时段观测过于稀疏的问题。从空间基线分布特征来看，大部分干涉对垂直基线集中在100 m范围内，仅少量影像对接近阈值上限。该结果表明，所构建网络在保证观测数量的同时，较好控制了大基线干涉对比例，为相位解缠和时序反演提供了较为稳定的输入条件。

3.4.2 差分干涉图生成与地形相位去除

在完成小基线干涉网络构建并筛选出满足时间基线与空间基线约束的干涉对后，下一步需对各干涉对进行干涉处理，生成差分干涉图，并尽可能去除由地形起伏所引起的相位贡献，以突出研究区真实地表变形信号。该过程是SBAS-InSAR时序反演的关键基础，其处理质量直接关系到后续相位解缠及时序变形求解的稳定性和精度。

对于任意一组通过筛选的小基线主从影像，在完成精确配准后，可通过主影像与从影像复数回波信号的共轭相乘生成原始干涉图。设主影像和从影像的复数回波分别为 S_1 和 S_2 ，则干涉图可表示为：

$$I = S_1 \cdot S_2^* \quad (3.1)$$

式中, I 为干涉图复数值; X^* 表示复共轭。由此得到的干涉相位包含平地相位、地形相位、变形相位以及大气延迟、轨道误差和噪声等多种成分。因此, 原始干涉图并不能直接用于变形分析, 进一步开展差分干涉处理。

本文引入外部DEM数据对地形相位进行模拟, 并从干涉图中扣除, 从而生成差分干涉图。设某一干涉对的原始干涉相位为 φ_{int} , 由外部DEM模拟得到的地形相位为 φ_{topo} , 则差分干涉相位可表示为:

$$\varphi_{\text{diff}} = \varphi_{\text{int}} - \varphi_{\text{topo}} \quad (3.2)$$

式中, φ_{diff} 为差分干涉相位。理论上, 若外部DEM精度足够高且主从影像几何参数准确, 则地形相位可被较好消除, 差分干涉图中将主要保留地表变形信息及残余误差项。实际上, 由于DEM精度有限、轨道参数误差和影像配准误差等因素影响, 地形相位通常不能被完全消除, 差分干涉图中仍可能存在一定的残余地形相位。

本文采用Goldstein滤波方法对差分干涉图进行相位滤波。Goldstein滤波是一种基于频域的自适应滤波方法^[121], 该方法根据局部频谱特征对干涉相位进行平滑, 同时尽量保留真实相位条纹信息, 适用于存在较强斑点噪声和局部低相干现象的场景。

本研究中, Goldstein滤波参数设置如下: 滤波指数 $\alpha = 0.5$; FFT窗口大小为32; 相干值估计窗口大小为5。其中, α 控制滤波强度, α 越大, 滤波越强; FFT窗口用于局部频谱分析; 相干值窗口则用于辅助滤波权重的估计。选择上述参数, 旨在相位平滑与条纹保持之间取得平衡, 即既降低随机噪声, 又尽量保留长沙市高速公路路网沿线沉降和边坡变形等真实相位特征。

为展示差分干涉图处理效果, 本文选取Z5分区部分干涉对的差分干涉图进行展示, 如图3.6所示。由图可见, 在完成平地相位去除、地形相位模拟扣除及相位滤波后, 干涉条纹的空间连续性较原始干涉图有所提高, 局部区域仍存在一定相位紊乱现象, 主要分布于植被覆盖较强或相干性偏低区域。




图3.6 Z5分区差分干涉图

3.4.3 相位解缠与SBAS时序反演处理

相位解缠的目的在于将缠绕于 $(-\pi, \pi]$ 区间内的干涉相位恢复为连续相位值，为后续变形量求解提供可用观测量。由于研究区干涉图质量受地表类型和相干性条件影响较大，若在低相干区直接进行解缠，容易出现相位跳变和误差传播。因此，本文在前述差分干涉图滤波和平均相干系数分析基础上，选取相位质量较高的干涉图参与解缠，并使用前文所述基于相干系数与连通域分析的参考点自动选取方法，为各计算分区确定参考点，以提高相位解缠的稳定性和结果的一致性。参考点选取结果如表3.4及图3.7、图3.8所示。

表3.4 参考点选取结果

区域编号	距离向像元数	方位向像元数	参考点列号	参考点行号
Z1	2307	3421	1120	1279
Z2	1067	861	328	590
Z3	758	3754	2893	4728
Z4	3080	4764	2994	1644
Z5	2187	2022	1297	193
Z6	3128	4554	232	3710
Z7	1913	2743	837	749
Z8	1902	3930	124	2904
Z9	693	3473	72	789
Z10	434	3735	295	3493

Z11	4946	2910	1865	1619
-----	------	------	------	------




图3.7 Z1-Z6参考点位置




图3.8 Z7-Z11参考点位置

基于参考点选取结果，对差分干涉图进行相位解缠处理。部分解缠结果如图3.9所示。由图可见，在高相干区域内，相位条纹经解缠后整体连续性较好，能够较完整地反映研究区地表变形空间分布特征。




图3.9 Z5分区相位解缠图

在获得各干涉对的解缠相位后,进一步开展SBAS时序反演。设研究区共获取 $N+1$ 景SAR影像,其成像时刻分别为 $t_0, t_1, \dots, t_N$, 在小基线约束下形成 M 个干涉对。对于任意由时刻 t_A 和 t_B 构成的干涉对,其解缠后的差分相位可表示为:

$$\Delta\varphi_k = \frac{4\pi}{\lambda}(d_B - d_A) + \varphi_{topo,res}^{(k)} + \varphi_{atm}^{(k)} + \varphi_{orb}^{(k)} + \varphi_{noise}^{(k)} \quad (3.3)$$

式中, $\Delta\varphi_k$ 为第 k 个干涉对的解缠差分相位; λ 为雷达波长; d_A 和 d_B 分别为时刻 t_A 和 t_B 相对于参考时刻的LOS向累计变量; $\varphi_{topo,res}^{(k)}$ 、 $\varphi_{atm}^{(k)}$ 、 $\varphi_{orb}^{(k)}$ 和 $\varphi_{noise}^{(k)}$ 分别表示残余地形相位、大气延迟相位、轨道残差相位和噪声项。对全部干涉对联合建立观测方程,可写为:

$$Ad = \Phi \quad (3.4)$$

式中, A 为由干涉对连接关系构成的设计矩阵; d 为各时刻累计变形量向量; Φ 为解缠相位观测向量。为提高求解稳定性,将累计变形量转化为相邻时刻之间的变形增量,并采用最小二乘法进行求解。通过对全部小基线干涉图的冗余观测进行联合反演,可恢复研究时段内各时刻的累计变形量,并进一步计算平均变形速率。

在本文处理中,通过二维高通滤波增强低频背景误差抑制能力。二维高通滤波主要用于削弱空间上变化平缓的长波分量,如轨道残差和部分大尺度大气延迟,从而保留高速公路沿线带状沉降和局部异常变形特征。同时,设置时序相干系数阈值为0.4。时序相干系数是某像元在整个时序反演过程中相位稳定程度的评价指标,其值越高,说明该像元在时序反演过程中的相位表现越一致,时序反演可信度

越高。

在完成时序反演后,为进一步削弱轨道残差和长波背景误差对变形场的影响,需对反演结果进行趋势项校正。本文采用一次平面趋势拟合方法,对变形速率场中的整体长波趋势进行估计并扣除,以突出高速公路沿线局部异常变形特征。设原始变形结果为 $D(x,y)$, 拟合趋势面为:

$$T(x,y) = a_0 + a_1x + a_2y \quad (3.5)$$

式中, x 和 y 为空间坐标; a_0 、 a_1 和 a_2 为待估参数。则去趋势后的变形结果为:

$$D'(x,y) = D(x,y) - T(x,y) \quad (3.6)$$

通过该步骤,可有效减弱大尺度系统误差对局部异常区识别的干扰,提高变形结果的工程解释能力,以Z5区域为例,去线性趋势前后结果如图3.10所示。




图3.10 Z5区域去线性趋势前后对比图

经上述处理,最终获得了长沙市高速公路沿线研究区各计算分区的LOS向变形速率场和时序变形结果。Z1-Z11的变形速率场如图3.11与图3.12所示,其中Z1-Z7的时间跨度为2024年9月7日—2025年8月21日,Z8-Z11的时间跨度为2024年9月2日—2025年8月28日。研究区大部分区域变形速率接近稳定状态,仅局部路段及邻近边坡区域表现出较为明显的负向变形特征,表明研究区高速公路沿线存在一定程度的局部异常活动区。这些结果为后续异常区识别、InSAR指标提取及道路单元尺度综合风险评估提供了动态数据基础。




图3.11 Z1-Z6计算区域变形速率




图3.12 Z7-Z11计算区域变形速率

3.5 InSAR结果验证

3.5.1 风险区域一验证

为验证本文基于SBAS-InSAR提取的变形结果的可靠性，选取长沙市范围内两个典型异常变形区作为验证区域，结合变形速率场、高分辨率遥感底图、典型监测点时间序列曲线及现场勘查资料，对InSAR监测结果进行验证。

风险区域一位于Z5分区中，在变形速率场中表现为明显的局部异常区，异常点主要集中于红框范围内，整体呈现由中心向外围逐渐减弱的空间分布特征，而周边区域以绿色为主，整体较为稳定，如图3.13（a）所示。将变形结果叠加至高分辨率遥感底图后可以看出，异常监测点在空间上具有较好的连续性和集聚性，说明该区域存在真实的局部变形活动，而非随机噪声所致。

在异常区内部选取3个典型监测点进行时序分析，监测点位置如图3.13（b）所示。结果表明，3个监测点在监测期内整体变化趋势较为一致，前期以小幅波动为主，中后期逐步转为持续负向变化，至监测末期均表现出较明显的负向累计变形，累计沉降量分别达到22.56 mm、23.00 mm及16.73 mm。不同监测点在变形量幅值上存在一定差异，反映出异常区内部具有一定程度的不均匀变形特征。




图3.13 区域一位置及监测点分布





图3.14 区域一监测点时序变形曲线

结合现场勘查资料可见,验证区域1异常变形位置附近存在较为明显的道路病害现象,主要表现为路面裂缝发育和局部路缘石倾斜变形。如图3.15所示,该区域存在沿道路纵向或斜向发育的裂缝,并伴随一定程度的连续扩展特征,说明该区域可能已发生一定程度的不均匀沉降;如图3.16所示,部分路缘石出现明显倾斜和错动现象,反映出道路边部结构受地基变形影响较为显著。上述现场变形迹象与InSAR识别出的异常区在空间位置上具有较好一致性,表明该区域并非随机噪声所致,而是存在真实的变形活动。结合监测点时序曲线持续负向变化特征,可认为该区域已表现出较明显的缓慢沉降与局部不均匀变形响应,现场调查结果进一步验证了InSAR监测结果的可靠性。



a) 裂缝1实景

b) 裂缝2实景

c) 裂缝3实景

图3.15 道路裂缝实景



a) 路缘石倾斜1实景

b) 路缘石倾斜2实景

c) 路缘石倾斜3实景

图3.16 路缘石倾斜实景

3.5.2 风险区域二验证

风险区域二位于Z6分区中，在变形速率场中同样表现出显著异常，异常区主要分布于沿岸附近，整体呈带状集聚特征，如图3.17所示。与验证区一相比，该区异常范围更具方向性，空间上表现出由江岸向内逐渐过渡的特征，表明该区域存在较明显的局部沉降活动。

在该异常区内部选取3个典型监测点进行时间序列分析，如图3.18所示。结果表明，3个监测点在监测初期整体变化较小，随后逐渐转为持续负向变形，并在后期出现较为明显的加速下沉特征，在该时间序列中累计沉降量分别达到30.07 mm、35.49 mm以及23.98 mm。各监测点虽在局部幅值上存在差异，但总体演化趋势一致，表明该区域异常变形具有较强的共同响应特征。




图3.17 区域二位置及监测点分布




图3.18 区域二监测点时序变形曲线

现场勘查结果显示，验证区域二异常变形位置附近已有多处道路裂缝修补痕迹。如图3.19所示，裂缝主要表现为沿路面纵向分布，部分裂缝已呈现连续扩展特征，反映出该区域道路结构可能受到持续变形作用影响。道路裂缝通常是路基不均匀沉降在路面上的直接响应，因此其出现表明该区域并非处于完全稳定状态。

上述现场裂缝分布位置与InSAR识别出的异常变形区具有较好对应关系，说明遥感监测结果能够较真实地反映该区域的地表活动特征。结合监测点时序曲线所表现出的持续负向变化趋势，可以认为验证区域二在监测期内存在缓慢累积变形过程，该处现场裂缝实景进一步验证了InSAR结果的有效性。

两个验证区的分析结果表明，本文基于SBAS-InSAR获取的变形速率场和时间序列结果在空间定位和时序演化两方面均具有较好的可信度。一方面，异常变形区在空间上与高分辨率遥感底图及现场勘查结果具有较好对应关系；另一方面，典型监测点时间序列曲线能够反映区域内持续变形的演化过程。综合来看，本文所建立的SBAS-InSAR处理流程能够较可靠地提取研究区地表变形信息，可为后续道路单元InSAR指标构建及风险评估模型提供数据支撑。



图3.19 区域二道路裂缝实景

3.6 本章小结

本章围绕长沙市高速公路路网沿线区域的时序变形提取，基于SBAS-InSAR技术，完成了Sentinel-1 SAR影像从数据组织、干涉网络构建、差分干涉处理到时序反演及结果验证的全过程研究，为后续道路单元尺度风险评估提供了动态变形数据基础。主要结论如下：

(1) 构建了适用于长沙市高速公路沿线区域的SBAS-InSAR数据处理流程，实现了研究区小基线干涉网络构建。结合研究区SAR影像获取情况、地表覆盖条件及路网空间分布特征，完成了Sentinel-1影像、精密轨道数据和外部DEM等基础数据整理，并通过设置合理的时间基线和空间基线阈值构建了小基线干涉网络。结果表明，所构建网络具有较好的连通性和观测冗余度，能够满足后续差分干涉处理与时序反演要求；同时，干涉图和平均相干性分析结果说明研究区整体具备开展SBAS-InSAR监测的条件。

(2) 完成了差分干涉处理与SBAS时序反演，获取了长沙市高速公路沿线LOS向变形速率场和时间序列结果。通过平地相位去除、外部DEM辅助地形相位扣除、干涉图滤波及相位解缠等步骤，形成了较高质量的差分干涉图序列；进一步基于SBAS时序反演方法，得到了研究区LOS向平均变形速率和累计变形时间序列。结

果表明，研究区整体以稳定区域为主，但部分高速公路沿线边坡及邻近区域表现出较明显的异常负向变形特征。

（3）识别到长沙市高速公路沿线典型异常变形区域，验证了SBAS-InSAR结果用于道路变形监测的可靠性。结合两处典型异常区现场勘查资料，对InSAR监测结果进行了验证，证明了本章变形提取结果的可靠性。验证区域一和区域二的监测点时序曲线均表现出持续负向变化趋势，且异常区附近分别出现道路裂缝、路缘石倾斜等工程病害现象。现场调查结果与InSAR识别出的异常变形区在空间位置和变形特征上具有较好一致性，说明本文建立的SBAS-InSAR处理流程能够较真实地反映长沙市高速公路沿线地表变形状态。

第4章 基于机器学习方法的滑坡与地陷风险评估

4.1 引言

滑坡与地面塌陷是湖南省范围内对交通基础设施安全影响较为显著的两类地质灾害，其发生受地形地貌、水文气象、地表覆盖及人类工程活动等多种因素共同控制，具有明显的空间异质性和复杂非线性特征。为实现省域尺度灾害风险识别，并为后续道路单元尺度模型改进提供基础背景信息，本章以湖南省为研究区，以历史滑坡和地面塌陷灾害样本为依据，构建多源影响因子体系，开展滑坡与地面塌陷分灾种风险评估研究。具体而言，本章首先整理灾害样本数据并构建多源环境因子数据集，在此基础上进行相关性与共线性分析；随后分别采用随机森林和XGBoost模型建立滑坡与地面塌陷风险评估模型，并通过ROC-AUC、PR-AUC及命中率等指标对模型性能进行评价；最后结合最优模型分析两类灾害的主控因子及空间分布特征，以实现湖南省尺度地质灾害风险初筛，并为后续引入InSAR变形信息开展道路综合风险评估奠定基础。

4.2 数据来源与样本构建

为系统开展湖南省滑坡与地面塌陷风险评估，本文基于历史灾害样本、多源环境因子及机器学习方法，构建了区域尺度灾害风险评估总体流程。风险评估总体流程如图4.1所示。




图4.1 风险评估总体流程图

4.2.1 灾害样本数据来源与筛选

本文所使用的地质灾害数据来源于中国科学院资源环境科学数据平台的公开数据库^[122]，该数据共统计历史发生的地质灾害8180起，空间分布如图4.2所示。原始灾害数据包含滑坡、不稳定斜坡、崩塌、地面塌陷、泥石流、地裂缝和地面沉降等多种灾害类型。可以看出，灾害点在湖南省范围内广泛分布，在湘西山区、湘中丘陵区以及湘南丘陵山区分布较为密集，这与区域地形起伏、岩性条件及降雨特征密切相关。由于不同灾害类型的形成机理差异较大，为保证模型预测结果的针对性和可靠性，需要对原始灾害数据进行类型筛选和质量控制。




图4.2 湖南省历史地灾点空间分布

首先，对灾害点的空间位置进行统一投影转换，并对明显重复及空间位置异常的数据进行剔除。随后根据研究目标对灾害类型进行分类筛选。本研究重点关注滑坡灾害与地陷灾害两类对道路安全影响较大的地质灾害。

筛选后的灾害类型统计情况如表4.1所示。湖南省地质灾害数据库中滑坡灾害共5336起，地面塌陷灾害755起，纳入模型训练数据。筛选后的模型训练灾害点分布如图4.3所示。对于不稳定斜坡、泥石流、地裂缝和地面沉降等灾害类型，由于其形成机制与研究对象差异较大，未纳入模型训练数据。

表4.1 湖南省历史灾害类型统计

灾害体类型	全省数量	是否纳入模型
滑坡	5336	是
不稳定斜坡	856	否
崩塌	793	否
地面塌陷	755	是
泥石流	354	否
地裂缝	77	否
地面沉降	9	否




图4.3 模型训练选取地灾点

4.2.2 多源影响因子数据

滑坡与地陷的形成通常受地形地貌、岩土条件、水文气象及人类工程活动等多种因素共同控制^[124]。已有研究表明，不同灾种对应的主控因素存在明显差异，因此在省域尺度上开展灾害发生概率预测时，合理选取具有代表性、能够反映灾害孕育环境与触发条件的影响因子，是保证模型精度和结果可靠性的关键^[126]。

结合前人研究成果、湖南省区域环境特征、数据可获取性及后续机器学习建模需求，本文共选取17个影响因子，包括地形地貌因子、生态气候因子、土壤及水文因子和人类活动因子四大类。各因子的名称、变量类型、获取方式及数据来源见表4.2。

表4.2 风险因子类别、名称、数据类型及来源

因子类别	因子名称	数据类型	原始数据来源
地形地貌	高程	连续型	欧空局Copernicus网站
	坡度	连续型	
	坡向	离散型	
	平面曲率	连续型	
	剖面曲率	连续型	
	SPI	连续型	
	TWI	连续型	
	起伏度	连续型	
	粗糙度	连续型	
	地表切割深度	连续型	
生态气候	高程变异系数	连续型	中国科学院资源和环境 科学数据中心 ^[125]
	地貌	离散型	
	NDVI	连续型	
土壤及水文	降雨量	连续型	中国科学院地理科学与 资源研究所 ^[123]
	土壤类型	离散型	国家青藏高原科学数据 中心
人类活动	河流密度	连续型	中国科学院资源和环境 科学数据中心 ^[125]
	道路密度	连续型	OpenStreetMap

注：SPI—水流强度指数，TWI—地形湿度指数，NDVI—归一化植被指数。

根据因子属性及灾害形成机理，本文将所选评价因子划分为四类：（1）地形地貌因子，包括高程、坡度、坡向、平面曲率、剖面曲率、水流强度指数（SPI）、地形湿度指数（TWI）、起伏度、粗糙度、地表切割深度、高程变异系数和地貌，共12个因子；（2）生态气候因子，包括归一化植被指数（NDVI）和降雨量，共2个因子；（3）土壤水文因子，包括土壤类型和河流密度，共2个因子；（4）人类活动因子，包括道路密度，共1个因子。

（1）地形地貌因子

地形地貌因子是控制滑坡发育和地陷空间分布的重要基础背景。本文中，高程及其派生因子均基于Copernicus DEM数据提取获得。高程直接由DEM获取；其余地形因子则主要通过GIS平台中的地表分析、邻域统计和水文分析工具计算得到。

高程（Elevation）：高程直接来源于DEM栅格值，是后续坡度、坡向、曲率等因子计算的基础。高程不仅与降雨、植被覆盖和人类活动强度密切相关，而且不

同高程带通常对应不同的坡面形态、风化条件和水热环境，从而对滑坡和地陷的发生具有间接控制作用。

坡度 (Slope): 坡度反映地表坡面的倾斜程度，通过DEM一阶偏导数计算。其表达式为：

$$S = \arctan \sqrt{\left(\frac{\partial z}{\partial x}\right)^2 + \left(\frac{\partial z}{\partial y}\right)^2} \quad (4.1)$$

式中， z 为高程， $\partial z / \partial x$ 和 $\partial z / \partial y$ 分别为DEM在 x 和 y 方向上的高程梯度。坡度越大，坡体所受重力分量越大，越容易发生失稳，因此是滑坡预测中最常用的核心因子之一。

坡向 (Aspect): 坡向表示坡面最大高程下降方向，通过DEM梯度方向计算。其表达式可写为：

$$A = \arctan\left(\frac{\partial z / \partial y}{-\partial z / \partial x}\right) \quad (4.2)$$

坡向控制坡面的太阳辐射、蒸发强度和水分分布状况，对坡体风化与含水条件具有重要影响。建模时将坡向作为离散型变量处理。

平面曲率 (Plan Curvature): 平面曲率描述等高线方向的弯曲程度，反映坡面水流在平面上的汇聚或发散能力。其计算通常基于二阶偏导数。平面曲率大于0往往表示坡面发散，小于0表示坡面汇聚。汇聚型坡面更有利于径流集中和水分积聚，从而提高滑坡敏感性。

剖面曲率 (Profile Curvature): 剖面曲率表示沿最大坡降方向的曲率变化，反映坡面加速度、侵蚀和沉积趋势。其值影响地表径流速度和物质迁移能力，对坡体失稳具有重要作用。平面曲率和剖面曲率由GIS曲率分析工具从DEM计算得到。

水流强度指数 (SPI): SPI 反映径流侵蚀能力，一般定义为汇流面积与坡度的函数：

$$SPI = A_s \tan S \quad (4.3)$$

式中， A_s 为单位宽度汇流面积， S 为坡度。SPI 越大，表明径流冲刷和侵蚀作用越强，对坡脚削弱和坡体不稳定的影响越明显。

地形湿度指数 (TWI): TWI用于表征地形控制下的潜在土壤湿润程度，其常用表达式为：

$$TWI = \ln\left(\frac{A_s}{\tan S}\right) \quad (4.4)$$

式中， A_s 为单位宽度汇流面积， S 为坡度。TWI值越大，表明该区域越容易发生水分积聚，从而可能通过提高土体含水率和孔隙水压力诱发滑坡，或通过改变地下水补给条件影响地陷发育。

起伏度 (Relief): 起伏度用于衡量一定邻域范围内地形高差大小, 通常定义为窗口内最大高程与最小高程之差:

$$R = Z_{\max} - Z_{\min} \quad (4.5)$$

式中, $Z_{\max}$ 和 $Z_{\min}$ 分别为窗口内最大和最小高程。起伏度越大, 说明地形起伏越强, 地表过程和坡体不稳定性通常也越显著。

粗糙度 (Roughness): 粗糙度反映坡面不规则程度, 一般可由窗口内高程标准差或表面面积比值表示。本文采用邻域高程标准差来表征:

$$R_f = \sigma(z) \quad (4.6)$$

式中, $\sigma(z)$ 为窗口内高程值标准差。粗糙度越大, 地表切割和坡面破碎程度通常越强。

地表切割深度 (Surface Cutting Depth): 地表切割深度描述局部地形被河流或坡面侵蚀切割的程度, 通常通过局部平均高程与最低高程之差表示:

$$D_c = \bar{Z} - Z_{\min} \quad (4.7)$$

式中, $\bar{Z}$ 为窗口内平均高程, $Z_{\min}$ 为窗口内最低高程。该指标越大, 表明局部切割作用越强, 坡体更可能处于不稳定状态。

高程变异系数 (Elevation Coefficient of Variation): 高程变异系数反映局部地形起伏的相对波动程度, 其表达式为:

$$CV_z = \frac{\sigma(z)}{\bar{Z}} \quad (4.8)$$

式中, $\sigma(z)$ 为窗口内高程标准差, $\bar{Z}$ 为窗口内平均高程。该指标同时考虑高程波动与背景地形尺度, 可更稳定地表征复杂地形区的空间异质性。

地貌 (Landform): 地貌因子用于表征区域地表形态类型及其组合特征。不同地貌类型往往对应不同的物质组成条件、水文汇流特征和工程扰动敏感性。山地、丘陵、河谷和平原等地貌单元在坡体稳定性、地表侵蚀强度及地下水活动条件等方面存在明显差异, 从而对滑坡和地陷的形成具有重要控制作用。

(2) 生态气候因子

生态气候条件在灾害形成中主要表现为植被覆盖与降雨输入对地表稳定性的调节作用。

归一化植被指数 (NDVI): NDVI来源于遥感影像波段运算, 常用公式为:

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (4.9)$$

式中, NIR 为近红外波段反射率, Red 为红光波段反射率。 $NDVI$ 反映植被覆盖程度和生物量。适度植被覆盖有利于固土和减缓侵蚀, 但其与灾害关系往往受坡度、土地利用和人类活动共同影响。

降雨量 (Rainfall): 降雨量数据来源于多年气象栅格数据。本文采用多年平均

降雨量作为输入变量，通过对年尺度降水数据进行时间平均获得：

$$P = \frac{1}{n} \sum_{i=1}^n P_i \quad (4.10)$$

式中， P_i 为第*i*年的降雨量， n 为统计时段长度。降雨是滑坡最重要的触发因子之一，也会通过入渗和地下水补给影响地陷活动。

（3）土壤及水文因子

土壤类型 (Soil Type)：土壤类型属于离散型变量，通过赋予不同土壤类别编码参与建模。不同土壤在颗粒组成、孔隙结构、渗透性能及抗剪强度等方面存在差异，这些性质会直接影响降雨入渗、地表径流分配及坡体抗扰动能力。

河流密度 (River Density)：河流密度反映单位面积内河流总长度，通常通过线密度分析得到：

$$D_r = \frac{L_r}{A} \quad (4.11)$$

式中， L_r 为某统计单元内河流总长度， A 为统计单元面积。河流密度越大，表明区域水系越发育，侵蚀和地下水活动往往越强。

（4）人类活动因子

道路密度 (Road Density)：道路密度反映单位面积内道路总长度，一般通过线密度分析获得：

$$D_{road} = \frac{L_{road}}{A} \quad (4.12)$$

式中， L_{road} 为某统计单元内道路总长度， A 为统计单元面积。道路密度越大，通常意味着工程活动越频繁，对坡体结构和地下环境的扰动越显著。

（5）因子数据获取与统一处理

本研究中，各类因子来源于不同数据源。地形地貌因子中的高程直接来源于Copernicus DEM数据，其余地形因子通过DEM后处理获得。坡度、坡向、曲率类因子由地表分析工具直接计算；SPI和TWI在Arcgis平台通过水文分析与栅格运算获得；起伏度、粗糙度、地表切割深度和高程变异系数则通过邻域统计与窗口分析计算。

本文在建模前对所有因子进行了统一投影转换、重采样和栅格化处理，并统一到相同空间分辨率下表达，以保证后续样本提取和机器学习建模的一致性，最终结果如图4.4与图4.5所示。




图4.4 影响因子1-12空间分布图




图4.5 影响因子13-17空间分布图

4.3 影响因子相关性及共线性分析

在机器学习建模过程中,若影响因子之间存在较强相关性或多重共线性关系,可能导致变量信息重复、模型训练效率下降以及结果解释偏差等问题。尤其是在地形因子体系中,许多变量由同一DEM数据派生而来,其空间分布和数学含义存在一定相似性,因此有必要在正式建模前对各影响因子之间的关系进行系统分析。基于此,本文采用相关性分析与共线性诊断相结合的方法,对所选多源影响因子进行检验,以评估因子间冗余程度,并为后续输入变量的筛选提供依据。

4.3.1 相关性分析方法

在构建灾害风险评估模型之前,有必要先分析各影响因子之间的相关关系^[128]。本文所选取的高程、坡度、曲率、起伏度、粗糙度、地表切割深度和高程变异系数等多项因子均由DEM派生得到,它们在地学意义上虽各有侧重,但在空间分布上往往存在一定相似性。若多个因子之间具有较强相关性,则说明这些因子可能在一定程度上重复表达了相近的环境信息。虽然随机森林和XGBoost等集成学习模型对变量相关性的敏感性低于传统线性模型,但在建模前开展相关性检验,仍有助于识别因子之间的线性联系,为后续共线性分析、因子筛选和结果解释提供依据。

本文采用皮尔逊相关系数(Pearson correlation coefficient)对连续型影响因子之间的两两线性相关关系进行分析。皮尔逊相关系数用于衡量两个连续变量随彼此变化的线性一致程度,其表达式为^[127]:

$$r_{XY} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4.13)$$

式中, x_i 和 y_i 分别表示变量 X 与变量 Y 在第 i 个样本处的取值; $\bar{x}$ 和 $\bar{y}$ 分别表示两个变量的样本均值; n 为样本数量; r_{XY} 为变量 X 与变量 Y 的皮尔逊相关系数。

皮尔逊相关系数的取值范围为 $[-1,1]$ 。当 $r_{XY} > 0$ 时,表示两个变量呈正相关,即一个变量增大时另一个变量总体上倾向于增大;当 $r_{XY} < 0$ 时,表示两个变量呈负相关,即一个变量增大时另一个变量总体上倾向于减小;当 $|r_{XY}|$ 越接近1时,说明变量之间的线性相关程度越强;当 $|r_{XY}|$ 越接近0时,则说明二者线性相关程度越弱。一般认为, $|r| < 0.3$ 为弱相关, $0.3 \leq |r| < 0.5$ 为低度相关, $0.5 \leq |r| < 0.8$ 为中等相关, $|r| \geq 0.8$ 为强相关。

皮尔逊相关系数反映的是两个变量之间的两两线性关系^[129],主要回答某两个影响因子之间是否具有较强线性相关性这一问题。例如,高程与起伏度、坡度与粗糙度之间若具有较高相关系数,说明这些因子在空间上可能表达了相近的地形特征。

在具体处理上，本文仅对连续型影响因子进行皮尔逊相关分析。对于高程、坡度、平面曲率、剖面曲率、SPI、TWI、降雨量、起伏度、粗糙度、地表切割深度、高程变异系数、NDVI、河流密度和道路密度等连续型因子，采用皮尔逊相关系数构建相关矩阵并绘制热力图，以直观展示各因子之间的相关结构。对于坡向、地貌和土壤类型等离散型或类别型变量，则不直接纳入传统皮尔逊相关分析。其中，坡向因子具有角度变量的周期性特征，为避免其数值首尾相接带来的统计偏差，先进行正弦和余弦变换，构建 $aspect_sin$ 和 $aspect_cos$ 两个连续变量后再参与相关性分析。

为保证分析结果具有代表性并兼顾计算效率，本文从所有完成空间对齐和无效值剔除后的栅格数据中，随机抽取5000个有效像元作为样本，对各连续型因子进行皮尔逊相关系数计算。通过相关性分析，可以从两两变量关系层面识别因子之间可能存在的信息重复现象，为后续共线性诊断和因子保留提供基础。

4.3.2 共线性分析方法

在完成影响因子两两相关性分析后，还需进一步判断各因子之间是否存在明显的多重共线性问题。相关性分析主要反映两个变量之间的线性相关程度，而在多因子建模中，某一因子还可能同时与多个因子存在组合线性关系，即该因子能够被其他若干因子共同解释。若输入因子之间存在较强共线性，则可能导致变量信息重复，增加模型解释难度，并影响后续主控因子分析结果的清晰性。因此，在正式建模前，有必要对影响因子进行共线性诊断。

本文采用方差膨胀因子（Variance Inflation Factor, VIF）对连续型影响因子进行多重共线性分析。VIF的基本思想是：依次将每一个因子作为因变量，其余因子作为自变量建立辅助回归模型，并考察该因子能够在多大程度上被其他因子共同线性解释。对于第 j 个影响因子，其VIF定义为^[130]：

$$VIF_j = \frac{1}{1 - R_j^2} \quad (4.14)$$

式中， R_j^2 为以第 j 个因子作为因变量、其余因子作为自变量进行线性回归时得到的决定系数。 R_j^2 越大，说明该因子越容易被其他因子解释，其所包含的独立信息越少，对应的VIF值也越大。

从统计意义上看，VIF是一个无量纲诊断指标，用于表征某一变量回归系数方差因共线性而被放大的程度^[131]。VIF值越大，说明该变量与其他变量之间的信息重叠越严重，冗余程度越高。通常可按如下标准判断共线性水平：当 $VIF < 5$ 时，认为该变量与其余变量之间不存在明显共线性；当 $5 \leq VIF < 10$ 时，认为存在一定程度共线性；当 $VIF \geq 10$ 时，通常认为存在较强共线性，需要结合变量的

地学意义和建模需求进一步分析其保留必要性。

本文对连续型因子进行 *VIF* 计算。对于坡向因子，考虑其角度变量的周期性特征，先进行正弦和余弦变换，构建 *aspect_sin* 和 *aspect_cos* 两个连续变量后再参与共线性分析；地貌、土壤类型等离散型因子则不纳入 *VIF* 计算。

在具体实现上，本文基于前述随机抽取的5000个有效像元样本，对各连续型影响因子逐一建立辅助回归模型，并计算对应的 *VIF* 值，以诊断因子体系中的多重共线性程度。通过 *VIF* 分析，可从整体层面识别与其他因子高度冗余的变量，为后续因子筛选和模型解释提供依据。

4.3.3 相关性分析结果

连续型影响因子的皮尔逊相关系数矩阵热力图结果如图4.6所示。从整体上看，多数影响因子之间存在不同程度的相关关系，其中由DEM派生得到的地形因子之间相关性较为明显，而河流密度、道路密度以及坡向正余弦变量与其他因子的线性相关程度相对较弱。




图4.6 连续型影响因子皮尔逊相关系数热力图

地形起伏度、地形粗糙度、坡度、地表切割深度和高程变异系数等因子均用于描述区域地表起伏及形态复杂程度，因此它们之间出现较强相关关系是合理的。

高程与起伏度、地表切割深度等变量也表现出一定相关性，这些指标在一定程度上共同反映了区域地貌背景及地形破碎程度。

相关性热力图表明本文所选影响因子之间并非完全独立，尤其是多种DEM派生因子之间具有较强联系。这一结果说明影响因子体系存在一定程度的信息冗余现象。

4.3.4 共线性分析结果

VIF 计算结果如表4.3所示。结果表明，不同影响因子的共线性水平存在明显差异。其中，地形粗糙度、地形起伏度、坡度、地表切割深度、*NDVI* 和 *TWI* 的 *VIF* 值分别为200.790、128.661、82.062、62.586、28.901和19.209，均大于10，表现出较强的多重共线性；高程、平面曲率、高程变异系数和 *SPI* 的 *VIF* 值分别为8.280、7.068、6.227和6.122，处于5~10区间，表现为中等程度共线性；剖面曲率、道路密度、河流密度以及坡向正余弦变量的 *VIF* 值均小于5，不存在明显共线性问题。

表4.3 影响因子 *VIF* 计算结果

因子中文名称	因子英文名称	<i>VIF</i>
地形粗糙度	rough	200.790
地形起伏度	relief	128.661
坡度	slope	82.062
地表切割深度	cut_depth	62.586
归一化植被指数	ndvi	28.901
地形湿度指数	twi	19.209
高程	elev	8.280
降雨量	rain	7.236
平面曲率	plan_curv	7.068
高程变异系数	elev_cv	6.227
河流功率指数	spi	6.122
剖面曲率	prof_curv	3.552
道路密度	road_density	1.493
河流密度	river_density	1.382
坡向_cos	aspect_cos	1.129
坡向_sin	aspect_sin	1.006

从结果看，*VIF* 值较高的变量主要集中在地形起伏、坡面形态和地表环境表征因子上，尤其是粗糙度、起伏度、坡度和地表切割深度等指标。这些变量均与区域地表形态变化和坡面复杂程度密切相关，因此在统计上呈现出较强共线性具

有明显的地学合理性。 $NDVI$ 的 VIF 值也相对较高,说明其与其他环境变量之间同样存在较强的空间耦合关系。

高程、平面曲率、高程变异系数和 SPI 的 VIF 值处于中等水平,这些变量虽然存在一定冗余,但尚未达到必须剔除的程度。道路密度、河流密度及坡向正余弦变量 VIF 值较低,表明它们与其他变量之间相对独立,在后续模型训练中能够提供较为独立的信息。

4.3.5 因子保留结果

从统计结果来看,本文所选影响因子体系中确实存在较为明显的多重共线性现象,尤其在DEM派生地形因子之间表现突出。部分高 VIF 变量可以考虑剔除,以降低输入变量之间的信息冗余。但对于地质灾害风险评估而言,影响因子不仅承担模型输入的作用,同时也是解释灾害形成机理的重要依据。

具体而言,高程主要反映区域整体地貌背景;坡度描述坡面倾斜程度;地形起伏度强调一定邻域尺度内的高差变化;地形粗糙度表征地表起伏不平程度;地表切割深度反映流水侵蚀和地貌切割强度;高程变异系数则从统计角度刻画局部高程波动幅度。尽管有些变量在统计上存在较强相关关系,但它们分别从不同层面反映了地貌环境特征,在地质灾害形成机制分析中具有不同的解释意义。若简单删除其中某些变量,可能导致模型对复杂地表环境的刻画能力下降。

TWI 和 SPI 虽均属于水文相关因子,但前者偏重于地表汇水,后者偏重于径流侵蚀动力,二者在灾害致灾机理中具有不同作用。 $NDVI$ 从植被覆盖角度反映研究区环境背景,虽然其 VIF 值较高,但直接删除可能削弱模型对外部环境条件的综合表达能力。

本文在相关性分析与共线性分析基础上,剔除了地形粗糙度和地形起伏度两个冗余程度最高的因子,最终形成由15个影响因子构成的风险评估因子体系。

4.4 湖南省滑坡灾害风险评估

在完成影响因子构建及相关性分析的基础上,本文进一步开展湖南省滑坡灾害风险评估。滑坡属于典型的地形地貌控制型地质灾害,其发生发展过程通常受坡面形态、地形起伏、水文条件、植被覆盖及降雨等多种因素共同影响。为较准确刻画滑坡发生概率与环境因子之间的复杂非线性关系,本文采用随机森林(Random Forest, RF)和极端梯度提升(Extreme Gradient Boosting, XGBoost)两种学习模型开展对比建模,并基于空间交叉验证结果对模型性能进行评价。

4.4.1 滑坡风险评估模型构建

在完成滑坡灾害样本构建和影响因子筛选后,本文进一步开展湖南省尺度滑

坡风险评估模型构建。以历史滑坡样本与非滑坡样本为训练对象，以多源环境因子作为输入特征，建立环境条件与滑坡发生之间的映射关系，输出各空间单元的滑坡发生概率。其技术路线可概括为“样本构建—因子输入—模型训练—概率输出”。模型以多源环境因子为输入，以滑坡/非滑坡标签为输出，最终生成空间单元的滑坡发生概率。

设第 i 个样本的特征向量为：

$$X_i = (x_{i1}, x_{i2}, \dots, x_{im}) \quad (4.15)$$

式中， m 为输入因子数量， x_{ij} 表示第 i 个样本在第 j 个影响因子上的取值。对应的类别标签记为：

$$y_i \in \{0, 1\} \quad (4.16)$$

其中， $y_i = 1$ 表示滑坡样本， $y_i = 0$ 表示非滑坡样本。模型训练的目标是学习一个非线性映射函数：

$$f(x_i) \rightarrow P(y_i = 1 | x_i) \quad (4.17)$$

考虑到滑坡灾害的形成机理具有显著的非线性和多因子耦合特征，传统线性模型难以充分刻画环境因子之间复杂的交互作用。因此，本文选取随机森林^[132]（Random Forest, RF）和极端梯度提升^[135]（Extreme Gradient Boosting, XGBoost）两种集成学习模型开展对比建模。两类模型均属于树模型集成方法，能够较好地处理高维、多源、非线性的输入特征，但其集成机制存在明显差异：随机森林采用并行Bagging思想，通过构建多棵相互独立的决策树并进行投票集成完成分类^[133]；XGBoost采用串行Boosting思想，通过逐轮构建新树拟合前一轮模型残差，不断修正预测误差^[139]。

（1）随机森林模型原理

随机森林是一种基于Bootstrap重采样和随机特征选择的集成学习算法^[136]，其基本思想是从原始训练样本中有放回抽样构建多个子样本集，并在每个子样本集上训练一棵决策树；在树节点划分过程中，不是从全部特征中选择最优分裂变量，而是从随机抽取的部分特征中选择最优划分特征，以增强树之间的差异性；最终通过对多棵树的分类结果进行投票，输出样本的预测结果。其算法结构如图4.7所示。




图4.7 随机森林算法结构图

设随机森林中共包含 K 棵决策树，第 k 棵树对样本 x 的分类结果记为 $h_k(x)$ ，则最终分类结果可表示为：

$$H(x) = \arg \max_{c \in \{0,1\}} \sum_{k=1}^K I(h_k(x) = c) \quad (4.18)$$

式中， $I(\cdot)$ 为示性函数，当条件成立时取1，否则取0； c 为类别标签。若以“属于滑坡类”的投票比例作为输出，则样本的滑坡发生概率可表示为：

$$P(y=1|x) = \frac{1}{K} \sum_{k=1}^K p_k(x) \quad (4.19)$$

式中， $p_k(x)$ 为第 k 棵树对样本属于滑坡类别的概率估计值。

随机森林的优势主要体现在三个方面：其一，通过Bootstrap抽样和随机特征选择，有效降低了单棵决策树过拟合风险，提高了模型泛化能力；其二，能够较好地处理因子之间复杂的非线性关系和变量交互作用；其三，模型训练完成后可输出特征重要性，为后续主控因子识别提供依据。因此，随机森林特别适用于滑坡风险评估这类多源因子耦合、分类边界复杂的地质灾害识别问题。

（2）XGBoost模型原理

XGBoost是一种基于梯度提升决策树发展而来的集成学习算法^[137]，其基本思想并非并行训练多棵独立树，而是采用串行迭代方式逐轮构建新的决策树，使新树专门拟合前一轮模型尚未解释的误差或残差，从而不断提升整体模型预测能力。其算法机制如图4.8所示。与随机森林的并行投票不同，XGBoost属于逐轮提升结构，各棵树之间存在前后依赖关系，最终输出为所有树预测结果的加权累加^[141]。




图4.8 XGBoost算法结构图

设模型由 T 棵树组成，则第 i 个样本的预测值可表示为：

$$y_i = \sum_{t=1}^T f_t(x_i), f_t \in \Gamma \quad (4.20)$$

式中， f_t 表示第 t 棵回归树， Γ 为回归树函数空间。对于二分类问题，XGBoost通常先输出一个预测得分，再通过Sigmoid函数将其转换为样本属于滑坡类别的概率：

$$P(y_i = 1|x_i) = \frac{1}{1 + \exp(-y_i)} \quad (4.21)$$

因此，XGBoost模型同样可以输出空间单元的滑坡发生概率，并以此作为滑坡风险概率。

XGBoost的目标函数由损失函数和正则化项共同构成^[138]，即：

$$Obj = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{t=1}^T \Omega(f_t) \quad (4.22)$$

式中， $l(y_i, \hat{y}_i)$ 为损失函数，用于衡量模型预测值与真实值之间的差异； $\Omega(f_t)$ 为正则化项，用于约束树模型复杂度。对单棵树而言，正则化项通常写为：

$$\Omega(f_t) = \gamma N_t + \frac{1}{2} \lambda \sum_{j=1}^{N_t} w_j^2 \quad (4.23)$$

式中， N_t 为第 t 棵树的叶节点数， w_j 为第 j 个叶节点的权重， γ 和 λ 分别为控制模型复杂度的正则化系数。通过在目标函数中引入正则化项，XGBoost在提升拟合能力的同时，能够有效抑制过拟合问题。

XGBoost具有如下特点：一是采用一阶梯度和二阶梯度共同优化目标函数，

提高了模型求解效率和精度；二是通过正则化项控制树结构复杂度，增强模型稳健性；三是支持列采样、行采样等随机化机制，有助于提高模型泛化能力。

（3）模型训练与验证策略

以滑坡风险模型为例，在滑坡风险模型训练中，本文以筛选后的15个影响因素作为输入变量，以滑坡/非滑坡标签作为输出类别，分别建立随机森林和XGBoost模型。地质灾害样本通常具有显著的空间集聚性，若采用普通随机划分方式划分训练集和测试集，容易因训练样本与测试样本在空间上过于接近而高估模型精度。因此，本文采用空间分块交叉验证策略进行模型训练与验证。

研究区空间块尺度设定为5000 m，即以5000m×5000m空间块作为分组单元。随后采用5折分组交叉验证方式，将同一空间块内样本划入同一折中，从而保证训练集与测试集在空间上相对独立。设交叉验证折数为5，每一轮均以4个子集为训练集、1个子集为测试集，分别对RF和XGBoost进行训练与预测。该方法能够更真实地评估模型的泛化能力，也更符合区域尺度滑坡风险评估的实际应用需求。

在分类阈值设置上，本文采用 $threshold = 0.5$ 将模型输出概率转换为二分类标签，即当样本滑坡发生概率大于或等于0.5时判为滑坡，否则判为非滑坡。同时，为评价模型在高风险区优先识别方面的能力，精度评价中设置了TOP1%、TOP5%和TOP10%三个高风险区命中率指标。

4.4.2 滑坡模型精度评价

为全面评价滑坡风险模型的分类性能，本文采用ROC-AUC、PR-AUC、Precision、Recall、F1值以及高风险区命中率等指标对随机森林和XGBoost模型进行比较分析。这些指标分别从总体区分能力、少数类识别能力、分类平衡性以及高风险区提取效果等不同角度反映模型性能，能够较全面地衡量模型在滑坡风险评估中的适用性。

（1）Precision、Recall与F1值

在二分类问题中，设真正例数为TP，假正例数为FP，假负例数为FN，真负例数为TN。其中，TP表示实际为滑坡且被模型正确识别为滑坡的样本数，FP表示实际非滑坡但被误判为滑坡的样本数，FN表示实际为滑坡但被误判为非滑坡的样本数，TN表示实际非滑坡且被正确判定为非滑坡的样本数^[140]。

精确率（*Precision*）表示模型预测为正类的样本中，真正为正类的比例，其计算公式为^[140]：

$$Precision = \frac{TP}{TP + FP} \quad (4.24)$$

Precision 越高，说明模型识别出的高风险样本越可靠，误报越少。

召回率（*Recall*）表示所有真实正类样本中，被模型成功识别出来的比例，

其计算公式为^[143]:

$$Recall = \frac{TP}{TP + FN} \quad (4.25)$$

Recall 越高, 说明模型能够识别出更多真实滑坡样本, 漏报越少。在滑坡风险评估中, 召回率通常具有更高的重要性。

F1 值是 *Precision* 和 *Recall* 的调和平均, 用于综合衡量模型在精确率和召回率之间的平衡能力, 其计算公式为:

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4.26)$$

F1 值越高, 说明模型在减少误报和减少漏报之间取得了更好的平衡。

(2) ROC曲线与ROC-AUC

ROC (Receiver Operating Characteristic) 曲线是以假正率 (False Positive Rate, FPR) 为横轴、真正率 (True Positive Rate, TPR) 为纵轴绘制得到的性能曲线^[144], 其计算公式分别为:

$$TPR = \frac{TP}{TP + FN} \quad (4.27)$$

$$FPR = \frac{FP}{FP + TN} \quad (4.28)$$

其中, *TPR* 实际上即为召回率, 反映模型对正类样本的识别能力; *FPR* 表示所有负类样本中被错误识别为正类的比例。

ROC-AUC是ROC曲线下面积 (Area Under the Curve), 其取值范围为 0~1。AUC值越接近1, 表明模型对正负样本的区分能力越强; 当AUC接近 0.5 时, 说明模型接近随机分类水平^[144]。在滑坡风险评估中, ROC-AUC可以反映模型总体判别能力, 是常用的综合评价指标。

(3) PR曲线与PR-AUC

由于滑坡样本通常远少于非滑坡样本, 数据集往往存在明显类别不平衡, 因此仅依赖ROC-AUC可能不足以全面反映模型对少数类样本的识别能力。为此, 本文进一步采用 PR (Precision-Recall) 曲线进行评价。PR曲线以*Recall*为横轴、*Precision*为纵轴, 反映模型在不同分类阈值下对正类样本的识别质量。

PR-AUC表示PR曲线下面积, 其值越大, 说明模型在少数类识别方面表现越好。与ROC-AUC相比, PR-AUC对类别不平衡问题更加敏感, 更适合用于滑坡风险评估这类正负样本分布不均衡的场景。

(4) 高风险区命中率HitRate

除传统分类指标外, 本文还引入高风险区命中率指标, 用于衡量模型在高风险区域优先筛查方面的实际应用能力。基本思想是: 将测试集中所有样本按模型预测概率从高到低进行排序, 选取预测概率最高的前 *k%* 样本作为高风险区, 再

统计其中命中的真实滑坡样本数量占全部真实滑坡样本的比例。其计算公式为：

$$HitRate@Topk\% = \frac{TP_{Topk\%}}{P} \quad (4.29)$$

式中， $TP_{Topk\%}$ 表示预测概率排名前 $k\%$ 的样本中，真实为滑坡的样本数； P 表示测试集中全部真实滑坡样本数。

$HitRate@Top1\%$ 、 $HitRate@Top5\%$ 和 $HitRate@Top10\%$ 分别表示模型在风险概率最高的前1%、前5%和前10%区域中命中的真实滑坡样本比例。该指标越高，说明模型越能够在较小的重点区域内覆盖更多历史滑坡点，因而在风险区优先识别和防控资源优化配置方面具有更高应用价值。

（5）滑坡模型精度结果分析

基于空间交叉验证结果，RF和XGBoost两种模型均表现出较好的滑坡风险识别能力，但整体精度存在一定差异。从综合指标看，XGBoost模型整体优于随机森林模型。具体而言，XGBoost模型的平均ROC-AUC为0.7472，高于随机森林模型的0.7429；平均PR-AUC为0.5417，也高于随机森林模型的0.5309，说明在空间分块验证条件下，XGBoost对滑坡正负样本的总体区分能力和对少数类滑坡样本的识别能力均略优于随机森林模型。图4.9和图4.10分别展示了两类模型的PR曲线和ROC曲线，表4.4则汇总了滑坡风险评估模型的空间交叉验证精度指标。




图4.9 滑坡两种模型PR曲线图




图4.10 滑坡两种模型ROC曲线图

表4.4 滑坡模型精度评估结果

精度指标	RF	XGBoost
ROC-AUC	0.743	0.747
PR-AUC	0.531	0.542
Precision	0.623	0.481
Recall	0.227	0.647
F1	0.332	0.552
HitRate@Top1%	0.026	0.027
HitRate@Top5%	0.115	0.120
HitRate@Top10%	0.214	0.220

从分类精度指标看，XGBoost模型的平均Precision为0.4813，低于随机森林模型的0.6229；但其平均 Recall 达到0.6467，显著高于随机森林模型的0.2269，表明XGBoost能够识别出更多真实滑坡样本。由于滑坡风险评估更强调潜在危险区域的充分识别，因此较高的召回率具有更重要的实际意义。在Precision与Recall的综合作用下，XGBoost模型的平均F1值达到0.5518，显著高于随机森林模型的0.3324，说明其在滑坡风险识别中具有更优的整体平衡能力。

从高风险区命中能力看，XGBoost模型在不同风险阈值下均略优于随机森林模型，其HitRate@Top1%、HitRate@Top5%和HitRate@Top10%分别为0.0272、0.1197和0.2198，均高于随机森林模型对应的0.0262、0.1154和0.2142。这表明在相同高风险面积占比条件下，XGBoost能够覆盖更多历史滑坡点，因此在滑坡重点防控区提取方面具有更高应用价值。

综合ROC-AUC、PR-AUC、Recall、F1值以及高风险区命中率等指标可以认为，XGBoost模型在湖南省滑坡风险评估中的总体表现优于随机森林模型。因此，本文选取XGBoost作为滑坡风险制图的最终模型。

4.4.3 滑坡风险影响因子贡献分析

在完成滑坡风险模型构建与精度评价后,为进一步识别影响湖南省滑坡发生的主控因素,本文基于滑坡最优模型XGBoost开展影响因子贡献分析。其目的在于从模型内部解释各环境因子在滑坡风险识别过程中的相对作用大小,从而揭示滑坡形成的主要控制条件,并为后续风险分区结果分析提供依据。

本文的影响因子贡献分析,并非直接计算某一因子对滑坡发生的实际物理作用强度,而是基于机器学习模型训练结果,对各输入因子在模型分类过程中的相对重要性进行统计。具体而言,模型输入为前文筛选保留的15个影响因子,输出为样本单元属于滑坡类别的概率值。在此基础上,XGBoost通过多轮提升树迭代不断优化分类结果,各因子在树节点分裂过程中对目标函数下降的贡献可用于衡量其重要程度。

本文采用Gain作为特征重要性指标。Gain表示某一特征在所有树模型分裂过程中带来的平均增益,即该特征被用于节点划分后,对模型目标函数优化程度的平均贡献。其值越大,说明该因子在提升模型分类能力方面发挥的作用越明显。gain本质上是一个无量纲统计指标,不具有实际物理单位,也不能直接等同于因子对滑坡发生的真实物理控制强度;其主要反映的是该因子在当前样本集和当前模型结构下,对滑坡与非滑坡样本区分能力的相对贡献。因此,本节所讨论的贡献高低为模型识别层面的相对重要性。

滑坡最优模型前10位影响因子的重要性排序如图4.11所示。结果表明,降雨量、高程、NDVI、坡度、高程变异系数、剖面曲率、道路密度、平面曲率、SPI和坡向余弦值是对湖南省滑坡风险识别贡献较高的因子,说明湖南省滑坡灾害的形成并非由单一因素控制,而是降雨触发、地形地貌背景、地表覆盖条件和人类工程活动共同作用的结果。

其中,降雨量的重要性最高,表明降雨是影响湖南省滑坡发生的首要外部触发因素。湖南省降雨时空分布不均,强降雨过程频繁,在坡面入渗、孔隙水压力上升和抗剪强度降低等作用下,往往会显著提高边坡失稳概率。模型结果中降雨量居于首位,说明其对滑坡样本与非滑坡样本的区分能力最强,也与滑坡灾害“降雨触发型”特征相一致。

高程和坡度的重要性同样较高,说明区域地貌背景和坡面几何形态对滑坡空间分布具有显著控制作用。高程不仅反映地貌分区和坡面发育条件,也在一定程度上指示了气候、水文和人类活动强度的空间差异;坡度则直接影响坡体重力量 and 稳定状态,是滑坡形成中最基本的地形控制因子。较高高程和较大坡度区域通常具有更强的地表起伏和更复杂的坡体结构,因此更容易形成不稳定斜坡。




图4.11 滑坡风险评估模型前10位影响因子重要性排序

NDVI的重要性位居前列,说明植被覆盖状况对滑坡风险识别具有较强指示作用。植被条件一方面影响坡面侵蚀、土体保持和水分调节,另一方面也间接反映不同区域土地利用方式和地表扰动程度。湖南省山地丘陵区植被分布与地形、降雨及人类活动密切相关,因此NDVI在模型中具有较高贡献是合理的。

道路密度进入前10位,说明人类工程活动对滑坡风险具有不可忽视的影响。道路建设通常伴随边坡开挖、荷载扰动和排水条件改变,容易破坏原有坡体稳定状态,尤其在山区和丘陵区,沿交通干线两侧更容易形成人工切坡和填方边坡,从而提高滑坡发生概率。道路密度的重要性较高,表明模型能够识别工程活动对滑坡发育的扰动效应。

湖南省滑坡风险影响因子贡献结果表明,滑坡灾害形成具有显著的多因子耦合特征,其中降雨量和地形地貌因子起主导作用,植被覆盖与工程扰动因素起重要调节作用。该结果与滑坡灾害的一般形成机理基本一致,也说明本文构建的影响因子体系能够较好反映湖南省滑坡灾害的主要孕育环境和触发条件。

4.4.4 滑坡风险空间分布特征

基于XGBoost最优模型输出的滑坡发生概率,本文生成湖南省滑坡风险空间分布图,并划分为五个等级,如图4.12所示。从总体空间格局看,滑坡风险在湖南省范围内表现出明显的空间异质性,高风险和极高风险区主要分布于地形起伏较大、坡度较陡、地貌条件复杂且降雨条件较为有利的区域。

结合前述特征重要性分析结果可以推断，滑坡高风险区主要受地形起伏、坡面形态和降雨条件共同控制。高程较大、坡度较陡、剖面曲率变化明显及地貌单元复杂的区域，更容易形成不稳定斜坡；在降雨作用下，土体含水量和孔隙水压力增加，进而降低边坡稳定性，导致滑坡更易发生。

滑坡风险分布结果与历史滑坡点空间位置具有较好一致性，多数历史滑坡灾害点落入中高风险以上区域，表明模型输出结果在空间上具有较好的可信度。该结果不仅可为湖南省区域尺度滑坡重点防控区识别提供依据，也可国土空间规划、山区基础设施布局和地质灾害监测预警提供技术支撑。




图4.12 湖南省滑坡风险空间分布图

为进一步验证本文滑坡风险评估结果在高速公路路网场景中的适用性，本文选取2024年6月湖南一处路面塌方事故作为典型案例进行补充分析。



图4.13 事故发生路段风险空间分布

图4.13展示了事故现场图、光学卫星影像及本文滑坡风险评估结果的空间对应关系。由图可见，事故路段位于山区高速公路沿线，周边地形起伏明显，道路多沿山体开挖布设，具备发生路基失稳和边坡塌滑的环境条件。结合风险空间分布可知，事故发生路段及其邻近区域在模型结果中表现为相对较高风险分布，说明本文构建的滑坡风险评估模型能够在一定程度上识别高速公路沿线潜在不稳定区。

4.5 地面塌陷风险评估

与滑坡灾害相比，地面塌陷的形成机制往往具有更强的地下环境与地表条件耦合特征，同时也受到地形、水文、植被覆盖及人类活动环境等多种因素综合影响。为识别湖南省地面塌陷高风险区域，本文在多源影响因子体系基础上，采用随机森林和XGBoost两种机器学习模型构建地面塌陷风险评估模型，并基于空间交叉验证结果对模型性能进行比较分析。

4.5.1 地面塌陷风险评估模型构建


本文以历史地面塌陷灾害点作为正样本，以研究区内未发生塌陷的空间单元作为负样本，构建地面塌陷风险评估样本集。模型输入变量包括高程、坡度、坡向、平面曲率、剖面曲率、SPI、TWI、年均降雨量、地形起伏度、地形粗糙度、地表切割深度、高程变异系数、NDVI、河流密度、道路密度以及地貌类型、土壤类型等多源影响因子。

考虑到地面塌陷样本具有明显空间异质性，且不同环境因子之间存在复杂非线性关系，本文同样选取随机森林与XGBoost两种模型开展对比分析，并采用空间交叉验证评估模型泛化能力。

4.5.2 地面塌陷模型精度评价

空间交叉验证结果表明，两种模型均具有一定的地面塌陷风险识别能力，但随机森林模型整体优于XGBoost模型。从总体区分能力看，随机森林模型的平均ROC-AUC为 0.7663，高于 XGBoost 模型的0.7609；平均PR-AUC为0.0798，也高


于 XGBoost 模型的0.0626。这表明在地面塌陷样本极不平衡的条件下,随机森林在整体分类性能和少数类识别质量方面均表现更优。图4.14和图4.15分别展示了两类模型的ROC曲线和PR曲线,表4.5汇总了两类模型的空间交叉验证精度结果。



a) RF模型PR曲线

b) XGBoost模型PR曲线

图4.14 地陷两种模型PR曲线图



a) RF模型ROC曲线

b) XGBoost模型ROC曲线

图4.15 地陷两种模型ROC曲线图

表4.5 地陷模型精度评估结果

精度指标	RF	XGBoost
ROC-AUC	0.766	0.761
PR-AUC	0.080	0.063
Precision	0.490	0.056
Recall	0.005	0.448
F1	0.009	0.099
HitRate@Top1%	0.081	0.063
HitRate@Top5%	0.238	0.205
HitRate@Top10%	0.365	0.336

从分类指标看,随机森林模型的平均Precision为0.4899,显著高于XGBoost模型的0.0557,说明随机森林在识别出的高风险样本中具有更高的准确性。虽然XGBoost模型的平均Recall达到0.4475,明显高于随机森林模型的0.0047,但其Precision极低,说明模型虽然捕获了更多正样本,却同时引入了大量误报。在区域地面塌陷风险评估中,若模型将过多低风险区域错误划为高风险,将削弱结果的实际可用性。因此,需要综合Precision、PR-AUC与高风险区命中率等指标进行判断。

从F1值看,XGBoost模型的平均F1为0.0991,高于随机森林模型的0.0093,主要原因在于其较高的召回率提升了调和均值结果。但结合PR-AUC和高风险区命中率分析,随机森林模型在风险区识别的可靠性和空间筛查效率方面仍更具优势。RF模型 HitRate@Top1%、HitRate@Top5%和HitRate@Top10%分别为0.0814、0.2381和0.3651,均高于XGBoost模型对应的0.0631、0.2045和0.3357,说明在相同高风险面积占比条件下,随机森林能够覆盖更多历史地面塌陷点。

尽管XGBoost模型具有更高的召回率,但其Precision和PR-AUC明显偏低,表明误报较多。相较之下,RF模型在高风险区识别可靠性和空间筛查效率方面表现更稳定,因此被选为最终模型。

4.5.3 地面塌陷风险影响因子贡献分析

为揭示湖南省地面塌陷风险形成的主控因素,本文对随机森林模型的特征重要性进行了分析,结果如图4.16所示。从结果看,降雨量、高程、道路密度、NDVI、坡度、高程变异系数、河流密度、平面曲率、坡向正弦值和TWI是贡献度排名前十的影响因子,说明湖南省地面塌陷风险受气象条件、地形背景、水文环境、地表覆盖及人类活动等多种因素共同作用。其中,降雨量的重要性最高,表明降雨是影响地面塌陷风险的首要因素。降雨入渗会改变土体含水状态和地下水活动条件,并可能加剧潜蚀作用和地下空隙发育,从而提高地面塌陷发生的可能性。

高程的重要性仅次于降雨量,说明区域地貌背景对地面塌陷空间分布具有明显控制作用。不同高程条件下,地表起伏、水文过程及人类活动分布均存在差异,因此会影响塌陷风险的形成格局。道路密度的重要性位居第三,表明人类工程活动对地面塌陷风险具有显著影响。道路建设通常伴随地表扰动、荷载变化及排水条件改变,这些因素可能破坏原有地表—地下系统平衡,从而提高局部塌陷风险。NDVI的重要性较高,说明植被覆盖状况能够在一定程度上反映地表环境稳定性及水土保持条件,植被覆盖较差区域更容易出现侵蚀增强和地表结构松散等问题。坡度和高程变异系数的重要性也较为突出,表明局部地形起伏对地面塌陷发育具有一定影响。

此外,河流密度、平面曲率、坡向正弦值和TWI进入前十,说明地表水系条

件、坡面形态及湿润环境同样对地面塌陷风险具有一定影响。其中，河流密度反映了地表水文活动强度，较高的河流密度往往对应较强的地下水交换和潜蚀作用；TWI反映地表汇水与湿润程度，其重要性表明水分条件在地面塌陷形成过程中发挥了重要作用。

总体来看，地面塌陷风险形成表现出明显的水文条件主导、地形背景控制、地表环境与人类活动共同调节特征。上述结果与地面塌陷灾害的形成机理相符，也表明本文构建的影响因子体系能够较好反映地面塌陷风险的主控环境特征。




图4.16 地面塌陷风险评估模型前10位影响因子重要性排序

4.5.4 地面塌陷风险空间分布特征

基于随机森林最优模型输出的地面塌陷发生概率，本文生成湖南省地面塌陷风险分布图，并划分为五个等级，如图4.17所示。从整体空间格局看，地面塌陷风险呈现明显的不均匀分布特征，高风险和极高风险区主要集中于地表环境变化较强、水文活动较活跃以及道路等人类活动条件较复杂的区域。

结合前述特征重要性分析结果可以推断，地面塌陷高风险区主要受降雨、高程背景、地表水文过程及交通环境共同控制。年均降雨量较大、NDVI变化明显、道路密度较高或河流密度较大的区域，更可能存在地表环境扰动增强、潜蚀作用发育或地下空间不稳定的问题，从而提高地面塌陷发生概率。相比之下，环境条件相对稳定、人类活动干扰较弱且水文过程不显著的区域，其地面塌陷风险整体

较低。

如图4.18所示，风险分布结果与历史地面塌陷点空间位置具有较好的一致性，多数灾害点分布于中高风险及以上区域，说明模型输出结果在空间上具有较好的可信度。该结果可为湖南省区域尺度地面塌陷重点防控区识别、基础设施风险排查和地质灾害动态监测提供科学依据。




图4.17 湖南省地陷风险空间分布图




图4.18 评估结果与历史发生点对比

4.6 本章小结

本章基于湖南省多源环境因子数据，系统开展了滑坡与地面塌陷风险评估研究，构建了区域尺度地质灾害风险识别与空间分布分析框架。研究表明，基于多源影响因子与机器学习算法的风险评估方法能够较好揭示两类地质灾害的空间分布规律，并提高高风险区域识别的科学性与可靠性。主要结论如下：

(1) 构建了适用于湖南省区域尺度地质灾害风险评估的多源影响因子体系，并通过相关性分析与共线性分析通过什么方法验证了其合理性。本文综合选取地形地貌、水文条件、气象环境、植被覆盖及人类活动等相关因子，形成了较为完整的评价指标体系。相关性与共线性分析结果表明，部分DEM派生地形因子之间存在一定相关性，但各因子在地学意义上分别反映了地貌背景、坡面形态、水文过程和地表环境等不同属性，整体上能够满足后续模型训练需求。

(2) 构建并对比了滑坡与地面塌陷风险评估模型，建立了适用于不同灾害类型的区域尺度风险识别方法。空间交叉验证结果表明，滑坡风险评估中XGBoost模型整体优于RF模型，在ROC-AUC、PR-AUC、Recall、F1值及高风险区命中率等指标上表现更优，因此被选为滑坡风险制图的最终模型；地面塌陷风险评估中RF模型整体优于XGBoost模型，在ROC-AUC、PR-AUC、Precision及高风险区命中率等方面表现更好，因此被选为地面塌陷风险制图的最终模型。该结果说明，不同类型地质灾害的风险评估应结合灾害特征与模型性能进行针对性建模。

(3) 揭示了滑坡与地面塌陷风险的主控因素及空间分布特征，验证了基于多

源影响因子与机器学习方法开展区域尺度地质灾害风险评估的适用性。滑坡风险主要受坡度、高程、年均降雨量、NDVI、剖面曲率、地貌类型和道路密度等因素控制，体现出地形主控、降雨触发的基本特征；地面塌陷风险主要受年均降雨量、高程、道路密度、NDVI、坡度、高程变异系数和河流密度等因素影响，表现出较明显的“水文条件—地表环境—人类活动”耦合特征。基于最优模型得到的风险空间分布结果与历史灾害点具有较好一致性，可为湖南省地质灾害重点防控区识别及后续精细化风险评估提供依据。

第5章 融合InSAR变形信息的道路单元滑坡风险评估

5.1 引言

前文基于湖南省历史滑坡灾害样本及多源环境因子，构建了区域尺度滑坡风险评估模型，实现了对滑坡易发性的空间识别，为道路沿线灾害风险初筛提供了基础。然而，区域尺度模型所反映的主要是地形地貌、水文气象、地表覆盖和人类活动等背景条件下的灾害发生概率，属于相对静态的风险表征方式。对于道路这一线性工程对象而言，其风险不仅受区域环境脆弱性控制，还与局部边坡、路基及周边地表的实时变形状态密切相关。仅依赖静态环境因子，虽能够揭示道路沿线灾害孕育背景，但对已出现缓慢变形、局部失稳征兆的路段，识别能力仍然有限。对于高速公路这一线性工程对象而言，滑坡风险还与道路边坡、路基及周边地表的实际变形状态密切相关。若某一道路单元同时具有较高静态滑坡风险和明显的持续变形特征，则其发生灾害的可能性应高于仅具有高静态风险但尚未出现明显变形的路段。因此，本章并非将InSAR变形作为风险评估的输出结果，而是将其作为反映道路单元当前活动状态的动态信息，引入到前文静态滑坡风险评估结果中，对道路单元风险进行动态修正。基于此，本章以长沙地区高速公路路网为研究对象，在静态滑坡风险评估结果的基础上，引入InSAR动态变形信息，构建“静态风险概率—动态变形指标—综合风险修正”的道路单元滑坡风险评估方法。首先，根据道路工程对象的线性分布特征构建约 $30\text{ m} \times 30\text{ m}$ 道路单元，作为风险评估的基本空间单元；其次，针对InSAR监测点空间分布离散和不均匀的问题，提出自适应范围寻点方法，提取道路单元级动态变形指标；随后，采用熵权法确定不同变形指标权重，构建动态风险指数与动态修正系数，并对静态滑坡风险评估结果进行修正，形成融合静态环境背景与动态变形响应的道路单元综合风险值；最后，结合典型道路滑坡灾害案例，对静态风险结果与静态—动态耦合风险结果进行对比分析，以验证引入InSAR动态变形信息后对高风险路段识别能力的提升效果。

5.2 基于道路单元的InSAR指标提取

5.2.1 道路单元创建

为将时序InSAR变形信息有效融入道路变形风险识别模型，需要解决两个关键问题：一是如何建立适用于道路工程对象表达的空间分析单元，二是如何将离散分布的InSAR监测点数据转化为可用于机器学习建模的单元级统计特征。由于InSAR监测成果通常以离散点形式存在，而道路本身属于狭长型线性工程对象，

若直接采用单个监测点或普通栅格像元作为评价对象，难以与道路具体区段建立对应关系，也不利于与地形环境因子在统一尺度下进行融合。因此，本文以道路单元为基础，将离散的InSAR变形信息转换为道路单元尺度的统计指标，从而实现动态变形信息与静态环境因子的结合。

道路单元是本文开展InSAR指标提取和风险建模的基本空间载体。与区域滑坡评价中常用的规则网格不同，基于道路中心线构建的道路单元更符合道路工程的方向性和连续性特征，也更有利于将模型结果直接对应到具体道路区段。道路单元的创建流程如图5.1所示。




图5.1 道路单元创建流程图

本文道路单元的创建总体遵循沿道路方向分段、沿道路横向分块的原则。首先，以道路中心线为基础，对道路骨架进行整理和连续化处理，以保证道路几何表达的完整性；然后，沿道路延伸方向按30 m长度进行切分，使道路被划分为一系列长度相同的基础线段；在此基础上，再根据道路中心线的方向，在垂直于道路延伸方向的横向上按30 m宽度逐级展开，构建规则化的面状单元。通过这一过程，原本线状的道路对象被转换为规则面单元，既保留了道路空间分布的方向特征，又具备了作为统计分析单元的几何条件。

本文采用约30 m×30 m的道路单元作为基础分析单元。这一尺度的设定主要基于两方面考虑：一方面，研究中所使用的高程、坡度、曲率、地形起伏度、粗糙度、地表切割深度和降雨量等环境因子大多以30m分辨率栅格形式存在，因此道路单元与环境因子分辨率保持一致；另一方面，30m级单元能够较好反映道路沿线局部边坡和路基的空间差异，使风险识别结果更符合道路工程监测需求。道路单元不仅是一个空间划分结果，也是贯穿本章分析全过程的基础单元。本章总体流程如图5.2所示。




图5.2 总体流程图

5.2.2 InSAR变形因子的构建

第四章模型构建所采用的因子体系主要反映区域灾害孕育环境和长期背景条件，能够较好表达灾害的空间易发性，但难以直接反映当前是否已经发生缓慢变形。对于公路沿线滑坡和地陷而言，实际风险往往与正在发生的位移过程密切相关。例如，某一边坡虽然在地形和岩性条件上具有高易发性，但当前并未发生明显变形，则其短期风险可能相对有限；反之，某些背景易发性中等的路段，若已表现出持续沉降或缓慢位移，则其风险应受到更高重视。

SBAS-InSAR时序变形结果能够提供道路沿线地表缓慢变形的动态观测信息，因此，本章并非重新构建机器学习风险模型，而是在第四章静态滑坡风险结果的基础上，进一步引入InSAR动态变形信息，对道路单元风险进行动态修正。具体而言，首先利用SBAS-InSAR监测结果提取道路单元尺度的平均累计变形量、累计变形标准差、平均变形速率等动态指标，用于表征道路单元当前的变形活动状态；随后，基于这些动态指标构建动态风险指数与动态修正系数，并与第四章得到的静态滑坡风险概率进行耦合，从而形成融合“静态环境背景”与“动态变形响应”

的道路单元综合风险结果。

在完成道路单元创建后，本文进一步以道路单元为基本对象提取InSAR变形指标。考虑到道路灾害往往既表现为整体缓慢变形，也表现为局部差异沉降和不均匀位移，因此本文并未仅采用单一变形量，而是分别从累计变形和变形速率两个方面进行统计描述。根据现有处理流程，研究中读取了InSAR点数据中的累计变形量和变形速率两个基础字段，并分别计算其统计量，最终形成道路单元尺度的InSAR特征集。

如表5.1表明，本文提取的InSAR指标主要包括累计变形和变形速率两类统计特征。其中，均值用于表征道路单元整体变形水平，标准差和极差用于刻画单元内部差异变形特征，最小值和最大值用于反映变形分布范围。该指标体系能够较为全面地描述道路周边地表的动态活动状态，为后续道路灾害风险识别模型提供重要输入。

表5.1 单元InSAR指标

指标类别	指标名称	计算公式
累计变形指标	平均累计变形量	$\bar{d} = \frac{1}{n} \sum_{i=1}^n d_i$
	累计变形标准差	$\sigma_d = \sqrt{\frac{1}{n} \sum_{i=1}^n (d_i - \bar{d})^2}$
	最小累计变形量	$d_{min} = \min(d_1, d_2, \dots, d_n)$
	最大累计变形量	$d_{max} = \max(d_1, d_2, \dots, d_n)$
	累计变形极差	$R_d = d_{max} - d_{min}$
变形速率指标	平均变形速率	$\bar{v} = \frac{1}{n} \sum_{i=1}^n v_i$
	变形速率标准差	$\sigma_v = \sqrt{\frac{1}{n} \sum_{i=1}^n (v_i - \bar{v})^2}$
	最小变形速率	$v_{min} = \min(v_1, v_2, \dots, v_n)$
	最大变形速率	$v_{max} = \max(v_1, v_2, \dots, v_n)$
	变形速率极差	$R_v = v_{max} - v_{min}$

注： d_i 表示第*i*个InSAR监测点的累计变形量， v_i 表示第*i*个InSAR监测点的变形速率， n 表示参与统计的有效监测点数量。

5.2.3 自适应范围寻点方法

在基于道路单元提取InSAR变形指标的过程中，若仅限定使用道路单元内部的监测点进行统计，会面临一个突出问题，即大量道路单元内部有效InSAR点数量不足，甚至不存在可用点位。这主要与InSAR点位的空间分布特征有关。受地表覆盖、相干性条件、观测几何关系及地物散射特性影响，InSAR监测点通常呈现非均匀分布状态^[142]，而本文构建的道路单元尺度较小，难以保证每个单元内部都包含足够数量的有效监测点。因此，若直接在单元内部进行统计，不仅会造成大量道路单元缺失变形特征，还会使部分点数过少的单元统计结果波动较大，难以真实反映道路周边地表的的活动状态。

为解决上述问题，本文提出自适应范围寻点方法。该方法的基本思想是：以道路单元为中心建立邻域搜索范围，在保证最小有效点数要求的前提下，逐级扩大搜索范围，以获取足够数量的InSAR监测点用于统计分析。与简单采用固定搜索范围的方法相比，自适应范围寻点方法遵循局部优先、逐步扩展的原则，优先在较小范围内搜索道路单元附近的InSAR点，以保证统计结果尽可能反映该道路单元的局部变形特征；仅在点位不足时才逐步扩大搜索范围，以提高特征提取的完整性和稳定性。




图5.3 自适应寻点方法示意图

若搜索半径过小，虽然提取结果更接近道路单元自身的局部变形状态，但会导致大量道路单元因点数不足而无法获得InSAR特征；若直接采用较大的固定搜索范围，虽然能够提高点位覆盖率，但可能会引入过多远离道路单元中心的监测点，削弱道路单元变形指标的局部代表性。因此，自适应范围方法通过逐级扩展邻域，在保证最小监测点数门槛的基础上，选择能够满足统计要求的最小搜索范围，兼顾局部性与稳定性。

本方法具体流程图如图5.4所示。首先为每个道路单元设定最小有效监测点数量门槛，并预设若干级递增的邻域搜索范围。对于每一个道路单元，优先在最小搜索范围内提取邻域中的InSAR监测点；若该范围内监测点数量达到要求，则直接利用这些点计算道路单元的变形统计指标，包括均值、标准差、最小值、最大值和极差等；若点数不足，则继续扩大搜索范围，并重复上述过程，直至满足最小点数要求或达到预设的最大搜索范围。若在最大搜索范围内仍不能获得足够数量的有效点，则认为该道路单元变形信息不足，其相关特征记为无效值。




图5.4 自适应范围寻点流程图

采用这一方法后，每个道路单元都对应一个实际使用的搜索范围和实际参与统计的监测点数量。其中，实际使用的搜索范围可反映该道路单元周边InSAR点分布的稠密程度：若在较小范围内即可获得足够监测点，说明该单元附近点位较密集，其统计结果局部代表性较强；若需在较大范围内才能满足要求，则说明该区域InSAR点较为稀疏，其结果虽然仍可作为建模输入，但局部性相对较弱。实际参与统计的监测点数量则可作为结果可靠性的重要参考，点数越多，说明统计

基础越充分，指标稳定性越高。

5.3 静态—动态耦合的道路单元综合风险评估

5.3.1 动态修正系数构建

第四章所得到的滑坡风险概率主要反映道路沿线区域在地形地貌、水文气象、岩性及人类活动等背景条件作用下的滑坡易发程度，其本质属于静态风险结果。然而，对于高速公路沿线滑坡灾害而言，区域环境背景仅决定灾害发生的潜在条件，而道路边坡、路基及周边地表当前是否已经出现持续变形，则更能够反映灾害的现实活动状态。因此，为提高道路高风险区段识别能力，有必要进一步引入InSAR动态变形信息，对静态滑坡风险结果进行动态修正。

本研究认为，道路单元风险应同时包含“环境易发性”与“变形活动性”两部分信息。其中，第四章模型输出的滑坡风险概率用于表征道路单元的静态环境风险；而SBAS-InSAR监测结果所提取的道路单元变形指标，则用于表征道路单元当前的动态活动状态。若某一道路单元同时具有较高静态风险和明显变形特征，则说明其发生滑坡灾害的可能性相对更高，其综合风险应相应增强。因此有必要引入InSAR动态变形信息，对当前风险值进行进一步修正。

本文从已提取的道路单元InSAR统计指标中，结合道路边坡失稳机理筛选出3个具有代表性的动态指标，分别为平均变形速率、平均累计变形量和变形速率标准差。其中，平均变形速率用于表征道路单元当前持续变形活动强度，平均累计变形量用于反映一定监测周期内的累积沉降程度，变形速率标准差则用于描述单元内部变形的不均匀性和局部波动特征。三者分别对应三个层面的动态信息，能够较全面地表征道路单元当前状态。

结合研究区道路灾害类型及指标物理意义，本文认为负向变形代表下滑，为危险方向。因此，为保证各指标方向一致，本文对平均变形速率和平均累计变形量进行危险方向提取，保留负值部分并取绝对值，构造危险强度指标：

$$X_{1,i} = |\min(0, V_i)| \quad (5.1)$$

$$X_{2,i} = |\min(0, D_i)| \quad (5.2)$$

$$X_{3,i} = S_i \quad (5.3)$$

式中， $X_{1,i}$ 表示第*i*个道路单元的平均变形速率危险强度， V_i 为其平均变形速率； $X_{2,i}$ 表示平均累计变形量危险强度， D_i 为平均累计变形量； $X_{3,i}$ 为变形速率标准差， S_i 为单元内变形速率的离散程度。由于标准差本身不具有方向性，其值越大说明单元内部变形越不均匀，因此可直接作为风险正向指标参与后续计算。

为减少主观赋权带来的不确定性，本文采用熵权法对3个动态指标进行客观赋权。熵权法认为，某一指标在样本间离散程度越大，其携带的信息量越多，对综

合评价结果的贡献也越大。首先，对各指标进行极差标准化处理：

$$Z_{ij} = \frac{X_{ij} - \min(X_j)}{\max(X_j) - \min(X_j)} \quad (5.4)$$

式中， Z_{ij} 为第 i 个道路单元在第 j 个指标上的标准化值， X_{ij} 为原始指标值。然后计算第 j 个指标中第 i 个样本所占比重：

$$p_{ij} = \frac{Z_{ij}}{\sum_{i=1}^n Z_{ij}} \quad (5.5)$$

进一步计算信息熵：

$$e_j = -k \sum_{i=1}^n p_{ij} \ln p_{ij}, k = \frac{1}{\ln(n)} \quad (5.6)$$

并计算差异系数与权重：

$$d_j = 1 - e_j \quad (5.7)$$

$$w_j = \frac{d_j}{\sum_{j=1}^m d_j} \quad (5.8)$$

式中， e_j 为第 j 个指标的信息熵， d_j 为差异系数， w_j 为其权重。

计算结果表明，平均变形速率危险强度、平均累计变形量危险强度和变形速率标准差的权重分别为0.275916、0.465572 和0.258512。平均累计变形量在动态风险表征中占主导地位，说明累积沉降效应对道路单元当前不稳定性的指示作用最为显著；平均变形速率次之，体现了持续活动强度对风险识别的重要意义；变形速率标准差虽权重相对较低，但能有效补充道路单元内部变形不均匀性的表征。

在完成动态指标筛选与权重确定后，本文进一步构建道路单元动态风险指数，以表征各道路单元在监测期内的动态变形活跃程度。动态风险指数定义为3个标准化指标的加权线性组合：

$$D_i = w_1 Z_{i1} + w_2 Z_{i2} + w_3 Z_{i3} \quad (5.9)$$

式中， D_i 为第 i 个道路单元的动态风险指数； w_1 、 w_2 、 w_3 分别为平均变形速率危险强度、平均累计变形量危险强度和变形速率标准差的熵权； Z_{i1} 、 Z_{i2} 、 Z_{i3} 为对应指标的标准化值。 D_i 越大，表示该道路单元在当前时段内沉降活动越明显、累积变形越大、局部变形越不均匀，从而具有更高的动态风险。

动态风险指数本身仅表示相对强弱关系，尚不能直接用于对静态风险结果进行定量修正。为此，本文进一步将动态风险指数映射为动态修正系数。考虑到动态信息的作用应当体现为对静态基础风险的增强或保持，而不宜过度放大导致静态背景失去约束作用，本文设置修正强度参数 α ，并采用如下形式构建动态修正

系数:

$$C_i = \begin{cases} 1 + \alpha D_i, & insar_{valid} = 1 \\ 1, & insar_{valid} = 0 \end{cases} \quad (5.10)$$

式中, C_i 为第 i 个道路单元的动态修正系数; $insar_{valid}$ 为道路单元 InSAR 指标的有效性标记。当道路单元在自适应搜索半径内提取到足够数量的有效 InSAR 点时, $insar_{valid} = 1$, 其静态风险将根据动态指数进行增强; 当道路单元未获取到有效 InSAR 监测信息时, $insar_{valid} = 0$, 则令修正系数取 1, 即保持静态风险不变。本文取 $\alpha = 0.3$, 保证动态因子能够起到修正作用。

5.3.2 静态—动态耦合模型

基于前文得到的静态基础风险值和动态修正系数, 本文建立静态—动态耦合的道路单元综合风险模型。设第 i 个道路单元的静态基础风险值为 $R_{s,i}$, 动态修正系数为 C_i , 则其原始综合风险值表示为:

$$R_i^* = R_{s,i} \times C_i \quad (5.11)$$

式中, R_i^* 为静态—动态耦合后的原始风险值。

为保证不同道路单元之间的可比性, 并便于后续风险分级, 本文对原始综合风险值进行极差归一化处理:

$$R_i = \frac{R_i^* - R_{\min}}{R_{\max} - R_{\min}} \quad (5.12)$$

式中, R_i 为第 i 个道路单元的最终综合风险指数; $R_{\min}$ 和 $R_{\max}$ 分别为研究区内原始综合风险值的最小值和最大值。经归一化后, 最终综合风险指数统一映射 0-1 区间。

在风险结果表达上, 本文根据归一化综合风险指数进一步将道路单元划分为低、较低、中等、较高和高风险 5 个等级, 以便于从整体上分析研究区道路单元综合风险的空间分异特征。最终得到的综合风险结果既保留了静态风险图对基础孕灾背景的表达能力, 又通过动态修正强化了对当前变形活跃单元的识别, 从而实现了道路风险由静态易发性评价向“静态—动态”综合识别的拓展。

基于静态滑坡风险结果, 并结合 2024 年 9 月—2025 年 9 月湖南省长沙地区 SBAS-InSAR 监测结果, 本文对长沙市道路单元风险进行动态修正, 最终得到长沙地区道路滑坡综合风险分布图, 由于单元尺寸为 30m, 比例缩小后展示效果不佳, 因此结果按照长沙 SBAS-InSAR 分析时相同的计算分区进行结果的制图, 如图 5.5 与图 5.6 所示。与仅依赖静态环境因子的风险评估结果相比, 动态修正后的结果不仅保留了地形地貌、降雨和下垫面条件对道路灾害孕育环境的约束作用, 同时进一步引入了当前时段地表变形活动信息, 使最终结果能够更敏感地响应道路沿线

潜在失稳路段的动态特征。




图5.5 长沙市道路滑坡风险空间分布Z1—Z6




图5.6 长沙市道路滑坡风险空间分布Z7—Z11

从区域整体分布结果看，长沙地区大多数道路单元以低风险和较低风险等级为主，空间上表现为大范围连续分布的蓝色和青色路段；中等风险路段主要零散分布于丘陵过渡区和局部起伏较大的道路沿线；较高风险和高风险路段数量相对较少，但在空间上具有较强的集聚性，呈现为短距离连续分布的黄色和红色路段。这表明，动态修正后的综合风险并非在全区均匀抬升，而是主要增强了少数具有明显沉降活动、累计变形较大或变形空间差异显著的道路单元，使风险空间格局由静态背景控制进一步演化为静态背景控制下的动态分布特征。

5.3.3 风险路段识别结果

通过对滑坡风险分布结果的分析，识别到两处高风险路段。第一处位于S71华常高速洩水河大桥南侧，地理坐标 28.13651°N ， $112.17007^{\circ}\text{E}$ 附近，如图5.7所示。该路段整体以中高风险等级为主，其中局部道路单元出现连续分布的高风险路段，表现为明显的红色和黄色集聚带，滑坡综合风险值明显高于其他路段。从光学卫星底图上看，该高风险路段紧邻山体边坡，道路一侧为较陡坡地，另一侧靠近沟谷，地形条件较复杂。此类道路易受到边坡切坡、坡脚扰动及汇水侵蚀的共同影响，存在发展为浅层滑塌或局部失稳的隐患。




图5.7 高风险路段一

综合判断，该路段高风险的形成可能与以下因素有关：其一，静态风险层面上，该区本身位于滑坡易发环境条件较高的边坡地段；其二，InSAR监测揭示道

路沿线存在持续的负向变形活动，表明坡体或路基在监测期内处于活动或缓慢变形状态。由此可见，该路段并非仅具有潜在易发性，而是已经表现出一定程度的动态失稳迹象，因此被识别为高风险路段具有较强合理性。

第二处位于S19浏洪高速长蛟冲隧道1与长蛟冲隧道2中间的隧道出入口上方，地理坐标 $28.146993^{\circ}\text{N}$, $113.572682^{\circ}\text{E}$ 附近。其综合风险结果表现为更为连续且集中分布的高风险带。由图5.8可见，该路段在坡面过渡位置形成了大段连续红色路段，两端则过渡为黄色和绿色，说明风险值沿道路具有明显的梯度变化特征。这种分布形态表明，高风险并非随机出现，而是与道路走向、坡体空间形态及局部变形集中区具有较强对应关系。




图5.8 高风险路段二

与典型路段一相比，典型路段二的高风险识别结果更加连续，该路段的基础地质环境较不利，而且在监测时段内表现出更明显的地表活动响应，因此最终综合风险值被显著提升。该结果表明，动态修正方法能够有效突出那些在静态易发背景下又具有当前活动迹象的道路路段，从而实现对高风险路段的优先识别。

5.4 方法验证

为验证本文所构建的静态—动态耦合道路滑坡风险评估方法在实际灾害识别中的适用性，选取2025年4月衡南县茶市镇一处已发生滑坡并造成路面坍塌的典

型事故路段作为验证案例。该路段具有较为清晰的灾害边界和明显的道路破坏特征，且事故发生前一年具有可用的Sentinel-1时序影像数据。基于事故发生前一年的22景Sentinel-1影像，利用SBAS-InSAR方法反演该路段周边的地表变形信息，并结合静态风险结果与动态修正结果进行对比分析，以验证本文方法对潜在高风险路段的识别能力。

5.4.1 事故前变形特征分析

从灾害现场影像可见，该事故路段位于道路一侧边坡部位，灾害发生后形成了明显的坍塌带，路肩及部分路面结构遭到破坏，大量土体滑塌至道路一侧，表现出典型的道路边坡滑塌特征，如图5.9所示。灾害范围整体沿道路展布，表明该路段在事故发生前可能已经存在一定程度的缓慢变形与稳定性降低现象。

本文基于事故发生前一年的26景Sentinel-1影像，对该路段周边区域进行了SBAS-InSAR反演。如图5.10与图5.11所示，从结果中的InSAR监测点的LOS向变形时序曲线可见，3个监测点在监测期内总体均呈现持续负向变化趋势。监测初期，各点位变形幅度较小，整体处于相对稳定状态；随着时间推移，逐渐进入持续下沉阶段，并在后续监测过程中不断累积负向变形。至监测末期，监测点1、监测点2和监测点3的累计负向变形量均已达到较明显水平，其中监测点2的变形幅度最大，达到30.60 mm，监测点1和监测点3次之，分别达到25.86 mm与23.23 mm。尽管三者局部时段存在一定波动，但总体变化趋势较一致，说明事故路段在灾害发生前并非处于完全稳定状态，而是存在持续性的缓慢变形过程。



图5.9 事故现场

这一结果表明，事故路段附近在灾害发生前已出现可监测的地表活动迹象。虽然其变形速率并不表现为突发式快速失稳，但持续的负向累积变形反映出坡体及道路结构处于渐进劣化过程之中。对于此类道路边坡灾害，仅依靠静态环境因

子只能识别其基础易发性，而InSAR时序变形则能够进一步揭示其事故发生前的动态特征，从而为后续风险修正提供更加直接的监测依据。




图5.10 灾害区域InSAR分析结果




图5.11 InSAR监测点变形时序曲线

5.4.2 静态与耦合风险结果对比

为了比较动态修正前后风险识别结果的差异，本文分别绘制了事故路段在静态滑坡风险模型下和静态—动态耦合风险模型下的道路单元风险分布结果，如图5.12所示。对比图显示，在仅使用静态环境因子的条件下，事故路段周边虽然表现出一定的滑坡易发性，但道路单元风险等级整体以中低风险为主，未在事故位置形成明显集中、连续的高风险带，对具体事故位置的突出表达不足。




图5.12 事故路段动态修正前后道路滑坡风险结果对比图

与此相比，在引入InSAR动态修正系数后，事故路段附近道路单元的综合风险值明显抬升。原本在静态结果中表现为中等风险或较高风险的若干单元，在动态修正后进一步提升为高风险单元，并在事故发生位置附近形成较连续的高风险分布带。尤其是在最终坍塌带对应的道路单元位置，动态修正后的结果表现出更强的空间集聚性和针对性，表明InSAR监测得到的变形信息有效增强了对潜在失稳路段的识别能力。

动态修正前道路沿线虽已有一定风险分异，但事故路段与周边路段之间的差异并不十分显著；动态修正后，事故路段对应的道路单元被明显强化，高风险单元在空间上与实际灾害位置具有较好的对应关系。这说明动态修正并不是对所有道路单元进行放大，而是重点增强既有一定静态易发背景、又在监测期内表现出明显沉降活动的道路单元，从而实现了对重点风险路段的突出表达。

这种差异进一步说明，静态风险与动态变形信息在道路滑坡风险识别中具有互补性。静态风险主要反映道路单元在长期地质环境、地形地貌和水文条件共同控制下的基础易发性，而动态InSAR信息则反映道路边坡当前时期的活动程度和变形响应。对于事故路段而言，其静态背景本身已具备一定不利条件，而事故发生前持续的缓慢沉降又进一步表明坡体处于活化状态，因此在静态—动态耦合模型中，该路段风险被进一步增强并最终表现为高风险区段。由此可见，本文提出的耦合方法能够在静态风险基础上引入时间维度上的活动信息，从而提高对潜在灾害位置的识别精度。

5.4.3 验证结论

事故发生前一年的InSAR时序结果表明，事故路段附近3个监测点均存在持续的负向变形趋势，说明该路段在灾害发生前已具备一定的缓慢变形活动特征，

InSAR数据能够有效揭示事故前坡体及路基的动态响应状态。且静态风险结果虽然能够识别该路段具有一定滑坡易发性,但对最终灾害位置的突出表达仍然有限;而在引入动态修正后,事故路段处道路单元的综合风险显著增强,并形成与实际坍塌位置较一致的高风险带,表现出更好的空间针对性和识别能力。通过该事故路段的验证分析可以看出,本文所构建的静态—动态耦合道路滑坡风险评估方法在实际道路灾害识别中具有较好的有效性。

本文提出的“静态—动态”耦合方法能够一定程度弥补传统静态风险评估对当前活动性表达不足的缺陷,适用于识别那些在静态背景下已经具有一定失稳敏感性、并在事故发生前呈现缓慢变形活动的道路边坡单元。该案例表明,将InSAR变形信息以动态修正系数的形式引入道路滑坡风险评估中,能够提升高风险路段识别的可靠性。对于道路灾害监测与巡查管理而言,该方法有助于实现从基础易发性识别向兼顾当前活动状态的综合风险识别转变,为潜在危险路段的优先筛查和防控提供更具针对性的技术支撑。

5.5 本章小结

本章以长沙地区为研究对象,在静态滑坡风险评估结果基础上,引入SBAS-InSAR变形监测信息,构建了道路单元尺度的静态—动态耦合滑坡风险评估方法,并通过一处典型滑坡坍塌事故进行了验证。可归纳为以下三点:

(1) 构建了道路单元尺度的静态—动态耦合滑坡风险评估框架,实现了静态环境背景风险与动态变形活动信息的融合表达。以 $30\text{m}\times 30\text{m}$ 道路单元为基本评价对象,将静态滑坡风险结果作为基础风险值,结合InSAR变形信息构建动态修正系数,实现了静态环境背景因子与当前地表变形活动信息的融合。该方法能够在保留基础易发性表达能力的同时,进一步增强对道路当前活动状态的刻画。

(2) 提出了基于机理筛选与熵权法相结合的动态修正方法,实现了离散InSAR监测信息向道路单元综合风险指标的转换。根据道路边坡失稳机理,从InSAR指标中筛选平均变形速率、平均累计变形量和变形速率标准差3个指标,分别表征持续变形活动强度、累积沉降程度和单元不均匀变形特征;利用熵权法确定动态指标权重,进而构建道路单元风险动态修正系数,最终通过乘性修正得到综合风险结果。

(3) 验证了静态—动态耦合滑坡风险评估方法在高速公路路网风险识别中的有效性,识别了具有持续变形特征的道路高风险区段。长沙地区高速公路路网滑坡风险结果及茶市镇典型案例验证表明,本文方法具有较好的有效性与工程应用价值。动态修正后的道路滑坡风险结果能够更加突出局部高风险路段,使高风险单元在空间上表现出更强的集中性和针对性;在衡南县茶市镇滑坡坍塌事故验证

中，事故发生前一年的InSAR监测结果显示事故路段附近3个监测点均呈现持续负向变形趋势，而静态—动态耦合风险结果在空间上与实际坍塌位置具有较好的对应关系，说明本文所提方法能够有效提升道路滑坡高风险路段识别能力。

结论与展望

本文依托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)和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)等课题,面向复杂地质环境下高速公路路网安全监测与灾害风险识别需求,开展了基于星载InSAR技术的路网变形监测与风险评估研究。

针对传统监测方法难以满足大范围、长时序、连续化监测需求,以及静态风险评估难以反映道路当前变形活动状态等问题,本文以湖南省及长沙地区高速公路路网为研究对象,构建了融合SBAS-InSAR时序变形监测、机器学习风险建模和道路单元动态修正的多尺度技术框架,实现了由省域尺度灾害风险初筛、城市尺度变形精细识别到道路单元尺度综合风险评估的递进分析。主要结论如下:

(1) 构建了面向高速公路路网的SBAS-InSAR变形提取流程,实现了复杂地表条件下路网沿线缓慢变形的连续监测。结合长沙市高速公路沿线区域的Sentinel-1数据,完成了小基线干涉网络构建、差分干涉处理、相位解缠及时序反演,获取了研究区LOS向变形速率场及时间序列结果。结合典型异常区现场调查可知,InSAR识别结果与道路裂缝、路缘石倾斜等病害现象具有较好一致性,说明本文建立的技术流程能够较可靠地反映高速公路沿线变形特征。

(2) 构建了湖南省尺度滑坡与地面塌陷分灾种风险评估模型,实现了高速公路沿线灾害背景风险的区域识别。基于历史灾害样本和多源环境因子,分别采用随机森林和XGBoost模型开展建模与对比分析。结果表明,XGBoost模型在滑坡风险评估中表现更优,随机森林模型在地面塌陷风险评估中表现更优;两类灾害风险分布结果与历史灾害点总体对应较好。降雨量、高程、坡度、NDVI、道路密度及河流密度等因子对两类灾害风险识别具有重要作用,说明灾害发生受地形地貌、水文条件、地表环境及人类活动共同控制。

(3) 提出了融合InSAR变形信息的道路单元滑坡风险评估方法,实现了由静态易发性评价向静态—动态综合风险识别的拓展。针对道路工程狭长、连续的空间特征,本文构建了约30m×30m的道路单元,并提出自适应范围寻点方法提取道路单元级InSAR动态指标。在此基础上,采用熵权法构建动态风险指数与动态修正系数,建立静态—动态耦合模型。以一处道路滑坡坍塌事故为例进行验证,结果表明,耦合模型在事故位置附近形成了更为连续集中的高风险带,对实际灾害位置的对应性更好,说明引入InSAR动态变形信息能够有效提升道路高风险路段

识别能力。

尽管本文围绕高速公路路网变形监测与风险评估开展了较为系统的研究，并初步实现了星载InSAR动态变形信息与道路灾害风险识别模型的融合，但受数据条件、样本规模及验证条件等限制，仍有以下几个方面值得进一步深入研究：

（1）深化道路沿线复杂地表条件下的SAR影像信息利用，进一步提升路网变形监测的精细化与可靠性。本文主要基于Sentinel-1数据开展区域尺度路网沿线变形提取，能够较好识别缓慢变形总体分布，但在植被覆盖较强的山地边坡、低相干路段中，仍存在监测点稀疏、局部结果连续性不足等问题。后续可结合更高分辨率SAR数据，提升道路本体、边坡坡肩及局部异常区的变形识别能力；同时针对道路场景中的大气延迟、低相干噪声和相位解缠误差开展针对性优化，以增强复杂场景下异常变形识别的准确性。

（2）完善道路单元尺度动态特征表达，进一步提高道路灾害风险评估模型对现势风险的刻画能力。本文已构建道路单元级InSAR动态指标，并通过静态—动态耦合方式实现了对基础风险结果的增强识别，但当前动态指标仍以统计特征为主，对道路灾害演化过程的表征仍不够充分。后续可围绕累计变形、变形梯度、不均匀变形及阶段性变化特征，构建更加完整的道路单元动态指标体系，并结合道路结构形式、边坡类型、排水条件等特征，增强结果的可解释性；同时将降雨过程、地下水变化及交通荷载等时变因素纳入统一框架，建立面向道路防灾的动态更新模型，提高对高风险路段和潜在失稳区的识别能力。

（3）加强样本支撑与验证，进一步推动路网风险识别成果向实际应用转化。本文已通过典型异常区调查和事故案例验证了方法的有效性，但现有验证仍以有限案例为主，样本代表性仍需增强。后续应进一步收集高速公路沿线滑坡、塌陷、沉降等多类型灾害案例，建立更加完善的道路灾害样本数据库，并结合巡检记录、现场监测资料及多时相遥感结果，对模型输出开展多尺度对比验证；在此基础上，进一步探索“遥感监测—风险识别—隐患筛查—现场复核”的应用流程，为高速公路灾害隐患排查、重点路段优先巡检和安全运营管理提供更直接的技术支撑。

参考文献

- [1] 国家发展和改革委员会, 交通运输部. 国家公路网规划 [EB/OL]. <https://www.ndrc.gov.cn/xxgk/zcfb/ghwb/202207/P020220712348051707026.pdf>, 2022-07-12.
- [2] 交通运输部. 2024 年交通运输行业发展统计公报 [EB/OL]. https://xxgk.mot.gov.cn/jigou/zhghs/202506/t20250610_4170228.html, 2025-06-10.
- [3] 国务院新闻办公室. 2024 年我国交通运输经济运行有关情况 [EB/OL]. https://www.scio.gov.cn/live/2024/35242/xgbd/202412/t20241225_878895.html, 2024-12-24.
- [4] 央视网. 二广高速内蒙古段路面塌陷事故救援结束 [EB/OL]. <https://news.cctv.com/2023/12/26/ARTIbDticeIKAwNWBMqLnnb3231226.shtml>, 2023-12-26.
- [5] 新华社. 广东梅大高速茶阳路段塌方灾害已致 48 人死亡 [EB/OL]. <https://www.news.cn/20240502/d38b1a7675794535a811b0e9a3c31686/c.html>, 2024-05-02.
- [6] 中华人民共和国应急管理部. “7·19”高速公路桥梁垮塌调查报告 [EB/OL]. <https://www.mem.gov.cn/gk/zfxxgkpt/fdzdgknr/202503/W020250507619450709564.pdf>, 2025-03-27.
- [7] 新华网. 深江铁路致 13 死重大坍塌事故调查报告公布 [EB/OL]. <https://www.news.cn/20251124/1d0a53c9a8654bcc80adc1d8ba6005d1/c.html>, 2025-11-24.
- [8] Mamat R C, Ghani A N A, Hasan M M, et al. A review of road embankment stability on soft ground[J]. IIUM Engineering Journal, 2019.
- [9] 中共中央, 国务院. 交通强国建设纲要 [EB/OL]. <https://www.12371.cn/2019/09/19/ARTI1568891211041883.shtml>, 2019-09-19.
- [10] 中共中央, 国务院. 国家综合立体交通网规划纲要 [EB/OL]. https://xxgk.mot.gov.cn/jigou/zhghs/202102/t20210225_3527909.html, 2021-02-25.
- [11] 国务院安委会办公室. “十四五”全国道路交通安全规划 [EB/OL]. https://www.mem.gov.cn/gk/zfxxgkpt/fdzdgknr/202207/t20220728_419231.shtml, 2022-07-28.
- [12] 交通运输部办公厅. 公路安全设施管理精细化提升行动方案 [EB/OL].

- https://jtt.hunan.gov.cn/jtt/jjzdgz/aqsc/zcfg_2/zcfgjtgcjs/202203/t20220310_22500215.html, 2022-01-25.
- [13] 国家防灾减灾救灾委员会办公室. 印发紧急通知部署全面做好汛期高速公路等基础设施灾害风险隐患排查处置工作 [EB/OL]. https://www.mem.gov.cn/xw/yjglbgzdt/202405/t20240503_486824.shtml, 2024-05-03.
- [14] 交通运输部. 2026年汛期公路安全风险管控工作视频部署会 [EB/OL]. https://www.mot.gov.cn/xinwen/jiaotongyaowen/202604/t20260410_4203378.html, 2026-04-10.
- [15] 中华人民共和国湖南省人民政府. 省情介绍 [EB/OL]. https://www.hunan.gov.cn/hnszf/jxxx/hngk/sqjs/201904/t20190422_4976917.html, 2019-04-22.
- [16] 湖南省自然资源厅. 《湖南省2024年度地质灾害防治方案》 [EB/OL]. https://zrzyt.hunan.gov.cn/zrzyt/hdjl/zxts/ftsl/202405/t20240520_33309396.html, 2024-05-20.
- [17] 湖南省高速公路网规划（2024-2035年） [EB/OL]. <https://www.miluo.gov.cn/uploadfiles/202510/2025101416400848330.pdf>, 2025-10-14.
- [18] Erol S, Erol B, Ayan T. A general review of the deformation monitoring techniques and a case study: analysing deformations using GPS/levelling[C]//XXth ISPRS congress. 2004, 7(5): 12.
- [19] Wang Y Q, Zhang S B, Chen L L, et al. Field monitoring on deformation of high rock slope during highway construction: A case study in Wenzhou, China[J]. International Journal of Distributed Sensor Networks, 2019, 15(12): 1550147719895953.
- [20] Yan Y, Peng S, Chang D, et al. Research on the application of the GNSS monitoring system in subgrade deformation monitoring in permafrost regions[J]. Measurement, 2025: 119513.
- [21] Wang H, Cheng H, Jiao Y, et al. A slope deformation measurement method based on laser datum and complex target motion model[J]. Measurement, 2022, 199: 111526.
- [22] Kane W F, Beck T J. Instrumentation practice for slope monitoring[J]. Engineering geology practice in Northern California. Association of engineering geologists Sacramento and San Francisco sections, 2000.
- [23] Zhang Y, Li H, Sheng Q, et al. Real time remote monitoring and pre-warning

- p>system for Highway landslide in mountain area[J]. Journal of Environmental Sciences, 2011, 23: S100-S105.
- [24] Pei H, Cui P, Yin J, et al. Monitoring and warning of landslides and debris flows using an optical fiber sensor technology[J]. Journal of Mountain Science, 2011, 8(5): 728-738.
 - [25] Ju N, Huang J, Huang R, et al. A real-time monitoring and early warning system for landslides[J]. Journal of Mountain Science, 2015, 12(5): 1219-1228.
 - [26] Prakasam C, Aravinth R, Kanwar V S, et al. Design and development of real-time landslide early warning system through low cost soil and rainfall sensors[J]. Materials Today: Proceedings, 2021, 45: 5649-5654.
 - [27] Khan M W, Dunning S, Bainbridge R, et al. Low-cost automatic slope monitoring using vector tracking analyses on live-streamed time-lapse imagery[J]. Remote Sensing, 2021, 13(5): 893.
 - [28] Yan X, Yu Y, Zhan W, et al. Research on the Application of UAV Photogrammetry Technology in Highway Slope Deformation Identification[M]//Advances in Frontier Research on Engineering Structures II. Singapore: Springer Nature Singapore, 2024: 523-531.
 - [29] Al-Rawabdeh A, Moussa A, Foroutan M, et al. Time series UAV image-based point clouds for landslide progression evaluation applications[J]. Sensors, 2017, 17(10): 2378.
 - [30] Jia H, Zhu G, Guo L, et al. An improved point clouds model for displacement assessment of slope surface by combining TLS and UAV photogrammetry[J]. Applied Sciences, 2022, 12(9): 4320.
 - [31] Ismail A, Safuan A R A, Sa'ari R, et al. Application of combined terrestrial laser scanning and unmanned aerial vehicle digital photogrammetry method in high rock slope stability analysis: A case study[J]. Measurement, 2022, 195: 111161.
 - [32] Zhou J, Jiang N, Li C, et al. A landslide monitoring method using data from unmanned aerial vehicle and terrestrial laser scanning with insufficient and inaccurate ground control points[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2024, 16(10): 4125-4140.
 - [33] Sestras P, Badea G, Badea A C, et al. A novel method for landslide deformation monitoring by fusing UAV photogrammetry and LiDAR data based on each sensor's mapping advantage in regards to terrain feature[J]. Engineering Geology, 2025, 346: 107890.
 - [34] Zhu L, Xing X, Zhu Y, et al. An advanced time-series InSAR approach based on

- Poisson curve for soft clay highway deformation monitoring[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 9206-9219.
- [35] Xing X, Zhu L, Fu H, et al. Radar interferometry time series to investigate deformation of soft clay subgrade settlement: A case study of Lungui Highway, China[J]. *Remote Sensing*, 2019, 11(4): 429.
- [36] Zhang Q, Li Y, Zhang J, et al. InSAR technique applied to the monitoring of the Qinghai–Tibet Railway[J]. *Natural Hazards and Earth System Sciences*, 2019, 19(10): 2229-2240.
- [37] Gao Q, Crosetto M, Monserrat O, et al. Infrastructure monitoring using the interferometric synthetic aperture radar (InSAR) technique[J]. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2022, 43: 271-276.
- [38] Piter A, Haghshenas Haghighi M, Motagh M. Challenges and opportunities of Sentinel-1 InSAR for transport infrastructure monitoring[J]. *PFG–Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 2024, 92(5): 609-627.
- [39] Bekaert D P S, Handwerger A L, Agram P, et al. InSAR-based detection method for mapping and monitoring slow-moving landslides in remote regions with steep and mountainous terrain: An application to Nepal[J]. *Remote Sensing of Environment*, 2020, 249: 111983.
- [40] Kang Y, Lu Z, Zhao C, et al. InSAR monitoring of creeping landslides in mountainous regions: A case study in Eldorado National Forest, California[J]. *Remote Sensing of Environment*, 2021, 258: 112400.
- [41] Handwerger A L, Huang M H, Fielding E J, et al. A shift from drought to extreme rainfall drives a stable landslide to catastrophic failure[J]. *Scientific reports*, 2019, 9(1): 1569.
- [42] Niu Y, Xu Y, Guo C, et al. Research on geological hazard characteristics and susceptibility of the Duku Highway based on SBAS-InSAR and improved spatiotemporal clustering[J]. *Scientific Reports*, 2024, 14(1): 29323.
- [43] Duan L, Lim H S, Sharoni S M H M, et al. Assessing highway slope stability risks using InSAR: a case study in Bijie, China[J]. *Geocarto International*, 2025, 40(1): 2521661.
- [44] Li L, Wen B, Yao X, et al. InSAR-based method for monitoring the long-time evolutions and spatial-temporal distributions of unstable slopes with the impact

- p>of water-level fluctuation: A case study in the Xiluodu reservoir[J].
- Remote Sensing of Environment*
- , 2023, 295: 113686.
- [45] Liu X, Zhao C, Yin Y, et al. Refined InSAR method for mapping and classification of active landslides in a high mountain region: Deqin County, southern Tibet Plateau, China[J]. *Remote Sensing of Environment*, 2024, 304: 114030.
- [46] Zhao D, Yao H, Gu X. Highway deformation monitoring by multiple InSAR technology[J]. *Sensors*, 2024, 24(10): 2988.
- [47] Moretto S, Bozzano F, Mazzanti P. The role of satellite InSAR for landslide forecasting: Limitations and openings[J]. *Remote sensing*, 2021, 13(18): 3735.
- [48] 李晓恩, 周亮, 苏奋振, 等. InSAR 技术在滑坡灾害中的应用研究进展[J]. *遥感学报*, 2021, 25(2): 614-629.
- [49] Liang J, Liu Z, Meng F, et al. InSAR and machine learning-based red beds highway slope hazard assessment in Southern China[J]. *Environmental Earth Sciences*, 2025, 84(16): 472.
- [50] 地质灾害InSAR监测技术指南（试行）: T/CAGHP 013—2018. 武汉: 中国地质大学出版社, 2018.
- [51] 地质灾害危险性评估规范: GB/T 40112—2021. 北京: 中国标准出版社, 2021.
- [52] 地质灾害排查规范: DZ/T 0284—2015. 武汉: 中国地质大学出版社, 2015.
- [53] Lorenz R, Petryna Y, Lubitz C, et al. Thermal deformation monitoring of a highway bridge: combined analysis of geodetic and satellite-based InSAR measurements with structural simulations[J]. *Journal of Civil Structural Health Monitoring*, 2024, 14(5): 1237-1255.
- [54] Wang R, Yang T, Yang M, et al. A safety analysis of elevated highways in Shanghai linked to dynamic load using long-term time-series of InSAR stacks[J]. *Remote Sensing Letters*, 2019, 10(12): 1133-1142.
- [55] Orellana F, Di Napoli M, et al. DInSAR for road infrastructure monitoring: Case study highway network of Rome metropolitan (Italy)[J]. *Remote Sensing*, 2020, 12(22): 3697.
- [56] Zhang R, et al. High-precision monitoring method for airport deformation based on time-series InSAR[J]. *Engineering Structures*, 2023, 290: 116406.
- [57] Zhao D, et al. Highway deformation monitoring by multiple InSAR technology[J]. *Sensors*, 2024, 24(10): 2988.
- [58] Xing X, Ge L, et al. Highway deformation monitoring based on an integrated CRInSAR algorithm[J]. *International Journal of Pattern Recognition and Artificial Intelligence*, 2018, 32(14): 1850036.

- [59] Yoshimatsu H, Abe S. A review of landslide hazards in Japan and assessment of their susceptibility using an analytical hierarchic process (AHP) method[J]. *Landslides*, 2006, 3(2): 149-158.
- [60] Yalcin A, Bulut F. Landslide susceptibility mapping using GIS and digital photogrammetric techniques: A case study from Ardesen (NE-Turkey)[J]. *Natural Hazards*, 2007, 41(1): 201-226.
- [61] Park S, Choi C, Kim B, et al. Landslide susceptibility mapping using frequency ratio, analytic hierarchy process, logistic regression, and artificial neural network methods at the Inje area, Korea[J]. *Environmental Earth Sciences*, 2013, 68(5): 1443-1464.
- [62] Kanwal S, Atif S, Shafiq M. GIS based landslide susceptibility mapping of northern areas of Pakistan, a case study of Shigar and Shyok Basins[J]. *Geomatics, Natural Hazards and Risk*, 2017, 8(1): 348-366.
- [63] Bathrellos G D, Skilodimou H D, Chousianitis K G, et al. Suitability estimation for urban development using multi-hazard assessment map[J]. *Science of the Total Environment*, 2017, 575: 119-134.
- [64] Yang M, Wang Y, Li X, et al. Stability analysis of highway expansive soil slope based on three-level fuzzy comprehensive evaluation model[J]. *Iranian Journal of Earth Sciences*, 2023, 15(2): 83-94.
- [65] Pasang S, Kubicek P. Landslide susceptibility mapping using statistical methods along the Asian Highway, Bhutan[J]. *Geosciences*, 2020, 10(11): 430.
- [66] Van Westen C J, Rengers N, Terlien M T J, et al. Prediction of the occurrence of slope instability phenomena through GIS-based hazard zonation[J]. *Geologische Rundschau*, 1997, 86(2): 404-414.
- [67] Ayalew L, Yamagishi H. The application of GIS-based logistic regression for landslide susceptibility mapping in the Kakuda-Yahiko Mountains, Central Japan[J]. *Geomorphology*, 2005, 65(1-2): 15-31.
- [68] Hong H, Pradhan B, Xu C, et al. Spatial prediction of landslide hazard at the Yihuang area (China) using two-class kernel logistic regression, alternating decision tree and random forest models[J]. *CATENA*, 2015, 133: 266-281.
- [69] Tien Bui D, Tsangaratos P, Nguyen V T, et al. Comparing the prediction performance of a Deep Learning Neural Network model with conventional machine learning models in landslide susceptibility assessment[J]. *CATENA*, 2020, 188: 104426.
- [70] Sun D, Xu C, Wen H, et al. A random forest model of landslide susceptibility

- p mapping based on hyperparameter optimization using Bayesian optimization algorithm[J].
- Geomorphology*
- , 2020, 362: 107201.
- [71] Bianchini S, Cigna F, Raspini F, et al. Landslide activity maps generation by means of persistent scatterer interferometry[J]. *Remote Sensing*, 2013, 5(12): 6198-6222.
 - [72] Wei Y, Zhang L, Li T, et al. Refined and dynamic susceptibility assessment of landslides by integrating machine learning models and InSAR technology[J]. *Geoscience Frontiers*, 2024, 15(6): 101890.
 - [73] Zhou C, Cao Y, Hu X, et al. Enhanced dynamic landslide hazard mapping using MT-InSAR method in the Three Gorges Reservoir Area[J]. *Landslides*, 2022, 19(7): 1585-1597.
 - [74] Yao J, Yao X, Zhao Z, et al. Performance comparison of landslide susceptibility mapping under multiple machine-learning based models considering InSAR deformation: a case study of the upper Jinsha River[J]. *Geomatics, Natural Hazards and Risk*, 2023, 14(1): 2212833.
 - [75] Vaka D S, Yaragunda V R, Perdikou S, et al. InSAR integrated machine learning approach for landslide susceptibility mapping in California[J]. *Remote Sensing*, 2024, 16(19): 3574.
 - [76] Zhang K, Xiao W, Ning S, et al. Assessing landslide susceptibility with dynamic deformation monitoring and explainable machine learning: a case study in Longhua County, China[J]. *Geomatics, Natural Hazards and Risk*, 2026, 17(1): 2616638.
 - [77] Li Z, Xiang J, Zhuo G, et al. Dynamic Landslide Susceptibility Assessment in the Yalong River Alpine Gorge Region Integrating InSAR-Derived Deformation Velocity[J]. *Remote Sensing*, 2025, 17(18): 3210.
 - [78] Wang H, Deng C, Zhang Z, et al. Dynamic Landslide Susceptibility Assessment Integrating SBAS-InSAR and Interpretable Machine Learning: A Case Study of the Baihetan Reservoir Area, Southwest China[J]. *Remote Sensing*, 2026, 18(4): 578.
 - [79] Zhao F, Miao F, Wu Y, et al. Integration of interpretable machine learning and MT-InSAR for dynamic enhancement of landslide susceptibility in the Three Gorges Reservoir Area[J]. *Journal of Rock Mechanics and Geotechnical Engineering*, 2025.
 - [80] Zhou C, Cao Y, Gan L, et al. A novel framework for landslide displacement prediction using MT-InSAR and machine learning techniques[J]. *Engineering*

- Geology, 2024, 334: 107497.
- [81] Wang C, Lin N, Li B, et al. InSAR-Supported Spatiotemporal Evolution and Prediction of Reservoir Bank Landslide Deformation[J]. Applied Sciences, 2025, 15(22): 12092.
 - [82] Zhang Y, He Y, Gao F, et al. A spatiotemporal displacement prediction method for InSAR-detected landslides using a graph neural network coupling spatial and temporal features[J]. Geomatics, Natural Hazards and Risk, 2025, 16(1): 2596362.
 - [83] Strnad D, Mongus D, Horvat Š, et al. A multi-task deep learning approach for landslide displacement prediction with applications in early warning systems[J]. Scientific reports, 2025.
 - [84] Ma R, Yu H, Liu X, et al. InSAR-YOLOv8 for wide-area landslide detection in InSAR measurements[J]. Scientific Reports, 2025, 15(1): 1595.
 - [85] Liu H, Bai M, Li Y, et al. Landslide displacement prediction model based on multisource monitoring data fusion[J]. Measurement, 2024, 236: 115055.
 - [86] Liu Y, Xu Q, et al. Landslide displacement prediction based on multi-source data fusion and sensitivity states[J]. Engineering Geology, 2020, 271: 105608.
 - [87] Yao J, Yao X, Liu X. Landslide detection and mapping based on SBAS-InSAR and PS-InSAR: A case study in Gongjue County, Tibet, China[J]. Remote Sensing, 2022, 14(19): 4728.
 - [88] Ferretti A, Prati C, Rocca F. Permanent scatterers in SAR interferometry[J]. IEEE Transactions on Geoscience and Remote Sensing, 2001, 39(1): 8-20.
 - [89] Sousa J J, Bastos L, Ruiz A M, et al. Persistent Scatterer InSAR: A comparison of methodologies based on a case study[J]. Remote Sensing of Environment, 2011, 115(12): 3302-3316.
 - [90] Pangen K, Dhakal K, K C D, et al. Landslide monitoring using PS-InSAR: A cost-effective approach for the Himalayas[J]. Discover Applied Sciences, 2025, 7: 161.
 - [91] Rana D, Dadkhah H, Ghaderpour E, et al. Monitoring slow-moving landslides through PS-InSAR and antecedent precipitation index: A case study of Petacciato, Italy[J]. International Journal of Remote Sensing, 2026, 47(4): 1-24.
 - [92] 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, 2002, 40(11): 2375-2383.
 - [93] Lanari R, Casu F, Manzo M, et al. An overview of the Small Baseline Subset algorithm: A DInSAR technique for surface deformation analysis[J]. Proceedings

- p>of the IEEE, 2007, 95(1): 7-24.
- [94] Chen Y, Ding C, Huang P, et al. Research on time series monitoring of surface deformation in Tongliao urban area based on SBAS-PS-DS-InSAR[J]. Sensors, 2024, 24(4): 1169.
 - [95] Poggi F, Caleca F, Nardini O, et al. Sentinel-1 imagery for wide-scale quantitative landslide vulnerability assessment of buildings[J]. Remote Sensing of Environment, 2026, 334: 115199.
 - [96] Even M, Schulz K. InSAR deformation analysis with distributed scatterers: A review complemented by new advances[J]. Remote Sensing, 2018, 10(5): 744.
 - [97] Dutta R, Maurer J. Mapping deformation processes using InSAR PS+DS timeseries estimation in Northern California, U.S.[J]. Remote Sensing of Environment, 2025, 329: 114922.
 - [98] Bamler R, Hartl P. Synthetic aperture radar interferometry[J]. Inverse Problems, 1998, 14(4): R1-R54.
 - [99] 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.
 - [100] Rosen P A, Hensley S, Joughin I R, et al. Synthetic aperture radar interferometry[J]. Proceedings of the IEEE, 2000, 88(3): 333-382.
 - [101] Hanssen R F. Radar interferometry: Data interpretation and error analysis[M]. Dordrecht: Kluwer Academic Publishers, 2001.
 - [102] Zebker H A, Villasenor J. Decorrelation in interferometric radar echoes[J]. IEEE Transactions on Geoscience and Remote Sensing, 1992, 30(5): 950-959.
 - [103] Ding X, Li Z, Zhu J, et al. Atmospheric effects on InSAR measurements and their mitigation[J]. Sensors, 2008, 8(9): 5426-5448.
 - [104] Lanari R, Mora O, Manunta M, et al. A small-baseline approach for investigating deformations on full-resolution differential SAR interferograms[J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(7): 1377-1386.
 - [105] Li S, Xu W, Li Z. Review of the SBAS InSAR time-series algorithms, applications, and challenges[J]. Geodesy and Geodynamics, 2022, 13(2): 114-126.
 - [106] 李德仁, 廖明生, 王艳. 永久散射体雷达干涉测量技术. 武汉大学学报(信息科学版), 2004, (8): 664-668.
 - [107] Goldstein R M, Werner C L. Radar interferogram filtering for geophysical applications[J]. Geophysical Research Letters, 1998, 25(21): 4035-4038.
 - [108] 廖明生, 林琿. 雷达干涉测量—原理与信号处理基础. 北京: 测绘出版社, 2003

- [109] Goldstein R M, Zebker H A, Werner C L. Satellite Radar Interferometry Two-dimensional Phase Unwrapping. *Radio Science*, 1988, 23(4): 713-720.
- [110] Loffeld O, Nies H, Knedlik S, et al. Phase Unwrapping for SAR Interferometry: A Data Fusion Approach by Kalman Filtering. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, 46(1): 47-58.
- [111] 周云, 陈建炜, 邹少豪, 等. 基于星载 InSAR 技术的城市建筑群变形监测与安全风险评估研究综述[J]. *土木工程学报*, 2025, 59(4): 47-70.
- [112] Liu Y, Li L, Yang J, et al. Estimating snow depth using multi-source data fusion based on the D-InSAR method and 3DVAR fusion algorithm[J]. *Remote Sensing*, 2017, 9(11): 1195.
- [113] 周云, 郝官旺, 危俊杰等. 基于PS-InSAR技术的大跨度桥梁结构变形监测综述. *工程力学*, 2024: 1-4.
- [114] 秦晓琼, 杨梦诗, 王寒梅, 等. 高分辨率PS-InSAR在轨道交通形变特征探测中的应用. *测绘学报*, 2016, 45(6): 713-721.
- [115] 长沙市统计局. 长沙市2024年国民经济和社会发展统计公报[EB/OL]. https://tjj.hunan.gov.cn/tjfx/tjgb/szgb/zss_1/202505/t20250516_33673433.html, 2025-04-09.
- [116] Ma C, Lu B L. Prediction of the Deformation of Heritage Building Communities under the Integration of Attention Mechanisms and SBAS Technology. *Electronics*, 2023, 12(23): 4724.
- [117] 湖南省人民政府. 湖南降雨较历年同期偏多近五成[EB/OL]. https://hunan.gov.cn/topic/fx2024/xqbb24/202406/t20240625_33336111.html, 2024-06-25.
- [118] Torres R, Snoeij P, Geudtner D, et al. GMES Sentinel-1 mission[J]. *Remote sensing of environment*, 2012, 120: 9-24.
- [119] 秦晓琼. 时间序列D-InSAR城市基础设施精细形变测量研究: [武汉大学博士学位论文]. 武汉: 武汉大学, 2019: 15-17.
- [120] Meyer D J, Gesch D B, Oimoen M J, et al. Summary of the validation of the second version of the ASTER Global Digital Elevation Model (ASTER GDEM2)[J]. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2012, I-4: 291-293.
- [121] Goldstein R M, Werner C L. Radar interferogram filtering for geophysical applications[J]. *Geophysical Research Letters*, 1998, 25(21): 4035-4038.
- [122] 中国科学院资源环境科学数据平台. 地质灾害点空间分布数据[EB/OL]. <https://www.resdc.cn/data>.

- [123] Yang J, Dong J, Xiao X, et al. Divergent shifts in peak photosynthesis timing of temperate and alpine grasslands in China[J]. *Remote Sensing of Environment*, 2019, 233: 111395.
- [124] Yang Y, Li Z, Zhang X, et al. Multi-scale analysis of the susceptibility of different geological hazards and their controlling factors[J]. *Environmental Impact Assessment Review*, 2024, 110: 107687.
- [125] 徐新良, 刘纪远, 张树文, 等. 中国多时期土地利用土地覆被遥感监测数据集 (CNLUCC) [DS/OL]. 中国科学院资源环境科学数据中心数据注册与出版系统, 2018. DOI:10.12078/2018070201.
- [126] Park J H, Kim J H, Lee S, et al. Machine-learning-based ground sink susceptibility assessment using urban geotechnical and infrastructure factors[J]. *Scientific Reports*, 2022, 12: 21876.
- [127] Pearson K. Mathematical contributions to the theory of evolution. III. Regression, heredity, and panmixia[J]. *Philosophical Transactions of the Royal Society of London. Series A*, 1896, 187: 253-318.
- [128] Gu T, Li K, Zhang H, et al. Study on landslide susceptibility mapping with different factor screening methods and random forest models[J]. *PLoS One*, 2023, 18(10): e0292897.
- [129] de Winter J C F, Gosling S D, Potter J. Comparing the Pearson and Spearman correlation coefficients across distributions and sample sizes: A tutorial using simulations and empirical data[J]. *Psychological Methods*, 2024, 29(6): 1390-1410.
- [130] O'Brien R M. A caution regarding rules of thumb for variance inflation factors[J]. *Quality & Quantity*, 2007, 41(5): 673-690.
- [131] Zhou X, Wen H, Zhang Y, et al. Landslide susceptibility mapping using hybrid random forest with GeoDetector and RFE for factor optimization[J]. *Geoscience Frontiers*, 2021, 12(5): 101211.
- [132] Breiman L. Random forests[J]. *Machine Learning*, 2001, 45(1): 5-32.
- [133] Hong H, Pourghasemi H R, Pourtaghi Z S. Landslide susceptibility assessment in Lianhua County (China): A comparison between a random forest data mining technique and bivariate and multivariate statistical models[J]. *Geomorphology*, 2016, 259: 105-118.
- [134] Sun D, Xu J, Wen H, et al. An optimized random forest model and its generalization ability in landslide susceptibility mapping: Application in two areas of Three Gorges Reservoir, China[J]. *Journal of Earth Science*, 2020, 31(6):

1068-1086.

- [135] Chen T, Guestrin C. XGBoost: A scalable tree boosting system[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2016: 785-794.
- [136] Zhang W, Tang H, Ma J, et al. Landslide susceptibility mapping using random forest and extreme gradient boosting classifier models: A case study of the upper Jinsha River, China[J]. Geological Journal, 2023, 58(6): 2372-2395.
- [137] Yao J, Pradhan B, Chen W, et al. Landslide susceptibility assessment using random forest and XGBoost models: A case study of the upper Jinsha River[J]. Geomatics, Natural Hazards and Risk, 2023, 14(1): 2212833.
- [138] Achu A L, Thomas J, Reghunath R, et al. Machine-learning based landslide susceptibility modelling and comparative analysis of model uncertainty using spatially explicit region-based cross-validation[J]. Geoscience Frontiers, 2023, 14(6): 101670.
- [139] Wang S, Sun D, Xu J, et al. Application of Bayesian hyperparameter optimized random forest and XGBoost model for landslide susceptibility mapping[J]. Frontiers in Earth Science, 2021, 9: 712240.
- [140] Fawcett T. An introduction to ROC analysis[J]. Pattern Recognition Letters, 2006, 27(8): 861-874.
- [141] Pradhan A M S, Kim Y T. Extreme gradient boosting with Shapley additive explanations for landslide susceptibility assessment[J]. Geoscience Frontiers, 2025, 16(4): 102154.
- [142] Piter A, Haghighi M H, Reale C, et al. Challenges and Opportunities of Sentinel-1 InSAR for Transport Infrastructure Monitoring[J]. European Journal of Remote Sensing, 2024, 57(1): 2414539.
- [143] Sokolova M, Lapalme G. A systematic analysis of performance measures for classification tasks[J]. Information Processing & Management, 2009, 45(4): 427-437.
- [144] Rainio O, Teuho J, Klén R. Evaluation metrics and statistical tests for machine learning[J]. Scientific Reports, 2024, 14: 6080.

致 谢

感谢我的导师周云教授。从论文选题的确立，到研究框架的搭建；从技术路线的反复推敲，到章节内容的字句斟酌，周老师始终以严谨的治学态度和深厚的学术素养，为我指引方向。感谢我的家人的一路支持，感谢父母的养育之恩，感谢我最爱的人赵玉如的陪伴与包容，感谢她带给我的快乐与幸福。

感谢同门魏子青、邹少豪、张阳、陈祎林、刘迎澳的帮助。感谢周门每个人。

感谢各位专家、教授、老师能够在百忙之中参与本论文的评审和答辩。

杨晨烨

2026年5月于湖南大学

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