

基于迁移学习-TCN融合在白鹤滩库区时序InSAR形变模式识别

杨梦诗^{1,2}, 尹康^{1,2}, 李赛伟^{1,2}, 李梦华³, 赵志芳^{1,2}, 黄成^{3,4,5}

1. 云南大学 地球科学学院, 昆明 650500;

2. 云南省中老孟缅自然资源遥感监测国际联合实验室, 昆明 650500;

3. 昆明理工大学 国土资源工程学院, 昆明 650093;

4. 云南省高原山区地质灾害预报预警与生态保护修复重点实验室, 昆明 650216;

5. 云南省地质环境研究院, 昆明 650216

摘要: 白鹤滩水电站作为国家重大工程, 其库区地质条件复杂, 蓄水后岸坡稳定性监测至关重要。传统InSAR技术依赖形变速率指标, 难以揭示时序演变规律的问题, 本文融合迁移学习与时间卷积网络(TCN), 构建了一种时序形变模式智能识别模型, 旨在提升库区形变演化特征的认知。研究利用2021年4月至2024年3月的Sentinel-1卫星数据, 采用SBAS-InSAR技术反演获取整个库区的时序形变场, 提出了一种“迁移学习增强的深度学习时序分类架构”: 利用模拟样本数据进行预训练, 再通过真实样本数据进行微调, 研究建立了一个包含平稳、线性、阶跃、分段线性、幂次及未定义类的六维形变分类体系, 并应用于白鹤滩库区的形变模式识别。结果表明: (1) 库区97377个形变点分类统计显示: 平稳型(45.6%)、分段线性型(24.4%)为主导模式, 平稳型与低速率、高相干性显著相关; (2) 石门坎滑坡受库水位滞时调控, 抬升滞后蓄水峰值约2个月, 野猪塘坡体呈现降雨触发的阶跃形变及水位-降水耦合的分段线性响应。本文突破了传统基于速率的单一分析框架, 验证了迁移学习在降低时序标注成本方面的有效性, 并表明多维形变模式解析能够为库区灾害风险的动态评估提供新的方法范式。

关键词: 时序形变分类, TCN, 迁移学习, 白鹤滩库区, SBAS-InSAR, 深度学习, 库岸滑坡, 地质灾害监测
中图分类号: TP2/P2

引用格式: 杨梦诗, 尹康, 李赛伟, 李梦华, 赵志芳, 黄成. 2026. 基于迁移学习-TCN融合在白鹤滩库区时序InSAR形变模式识别. 遥感学报, 30(4): 1130-1149

Yang M S, Yin K, Li S W, Li M H, Zhao Z F and Huang C. 2026. Deformation pattern recognition in the Baihetan reservoir area using transfer learning-temporal convolutional, mengshi multi-temporal InSAR. National Remote Sensing Bulletin, 30(4): 1130-1149 [DOI:10.11834/jrs.20265325]

1 引言

合成孔径雷达干涉测量InSAR (Interferometric Synthetic Aperture Radar) 技术已成为地表形变监测的有力手段, 在水电站库区边坡稳定性研究中得到广泛应用(Li等, 2019; 谢谟文等, 2012)。与传统岩土监测方法相比, InSAR能够实现大范围、连续性的时空形变获取, 对于揭示库岸潜在滑坡及其演化机制具有显著优势(顿佳伟等, 2023; Wang

等, 2022)。水电站蓄水往往导致区域水文地质条件显著改变, 使部分边坡在水位波动或降雨作用下发生失稳, 从而表现出多样化的形变模式(Yang等, 2023; Zhang等, 2013)。已有研究表明, 库区滑坡活动不仅与水位周期性变化存在耦合关系, 还可能受到降雨等外部因素的叠加影响, 呈现出明显的滞后或非线性响应(Shi等, 2021; 王振林等, 2019)。因此, 库区稳定性监测不能仅停留在形变量级的评估, 而应深入关注时序形变的演变模式,

收稿日期: 2025-08-28; 预印本: 2026-01-29

基金项目: 国家自然科学基金(编号: 42474040, 42404036); 云南省基础研究计划(编号: 202301AT070145); 云南省“兴滇英才”青年人才引进项目; 欧洲航天局(ESA) Sentinel-1/2数据(龙计划-6期)(编号: 95473)

第一作者简介: 杨梦诗, 研究方向为时间序列InSAR方法及其在地表形变监测中的应用。E-mail: yangms@ynu.edu.cn

通信作者简介: 李赛伟, 研究方向为深度学习与InSAR数据智能处理。E-mail: lsw_ynu@163.com

以实现潜在地质灾害更精准的识别与动态风险评估,这也是保障水电站长期安全运行的关键。

现有研究中,白鹤滩水电站库区边坡形变监测工作多集中于电站建成前的阶段(谭天宇,2022;吴明堂等,2023;周振凯,2023),而在其投产运行后、特别是蓄水引起库区水位人为抬升以来的形变监测与分析仍较为缺乏。因此,有必要将研究时段聚焦于蓄水后的边坡响应过程,以揭示水位变化对边坡稳定性的影响。Dai等(2023)通过Scoops3D地质力学模型与SBAS-InSAR技术的集成,实现了基于白鹤滩库区库水位急剧变化的滑坡易发性动态评估。Zhang等(2024)通过C/L波段多源SAR数据协同,显著提升了茂密植被覆盖区的探测能力。Dun等(2025)基于多源SAR数据的时序分析,系统揭示了白鹤滩库区蓄水过程中滑坡变形的演化模式。当前InSAR技术多基于形变速率识别潜在不稳定区域,并针对重点区域开展时序分析,然而对InSAR时间序列数据的利用仍处于较浅层次,尚未充分挖掘其在大范围、长时序监测中所蕴含的深层次信息,忽略了长时间序列观测中阶跃变化或变形加速等潜在危险形变信号。InSAR数据具有数据量大、增长快、来源多样的特点,可为数百个观测时间提供数百万个观测点。然而,InSAR时间序列形变模式依赖人工解译,不仅耗时耗力且需专业知识,机器学习和深度学习方法是潜在的解决方案。

目前针对InSAR时序形变模式识别的研究主要基于无监督聚类、假设检验以及深度学习3种方法。聚类算法在没有先验知识的情况下将数据集分成几个子集,无监督的机器学习算法,被广泛应用于InSAR时间序列的形变模式探测。SOM(Li和Ke,2015)、k-means(Gagliardi等,2021)和DBSCAN(Schneider和Soergel,2021)等聚类算法都已经被用于地表InSAR时间序列数据的聚类,从而分析地表形变的时空异质性。然而,这种方法的局限性在于聚类结果以线性趋势为主,表现为线性沉降速率的不同,对结果的解释思路较为单一。随后,有研究通过对视线向InSAR的垂直和水平分量进行聚类,提高了聚类结果的可解释性(Festa等,2022;Schlögl等,2021)。由于聚类的结果往往是未知的,获得可解释的结果需要多次实验来调整最终的聚类数量。在某种程度上,这个问题可以通过在聚类前进行主成分分析(Festa等,

2023;Yang等,2024)或在聚类后对类簇进行假设检验(Zhu等,2023)来解决。有学者使用了一种自监督对比学习InSAR时间序列深度聚类方法(吴晗飞等,2025),并通过实例级对比损失和软聚类分配损失的联合优化,提升了对InSAR时序数据特征的识别与区分能力。与聚类InSAR时间序列相比,具有预定义类别的InSAR时间序列分类更容易解释。最早对InSAR时间序列中潜在模式进行分类的研究旨在检测滑坡的变形模式,该研究采用多重假设检验方法,将区域地表形变分为与时间不相关、线性、二次、双线性、速率变化型阶跃和速率不变型阶跃6种类型(Berti等,2013)。随后,InSAR相位展开误差被归纳为另一个需要假设检验的新的类别(Mirmazloumi等,2022b)。深度学习作为一种机器学习方法,通过构建具有多个隐藏层的神经网络模型来自动学习数据中的特征和模式,从而实现高级任务(Hinton和Salakhutdinov,2006)。深度学习技术与多时序InSAR技术相结合,提升了滑坡识别、形变预测与异常检测的能力,为地质灾害监测与预警提供了新的技术路径。人工神经网络(Mirmazloumi等,2022a)、卷积神经网络(Aguiar等,2021)、长短期记忆网络(Tiwari和Shirzaei,2024)和稀疏自编码器-卷积神经网络(Li等,2023)已被探索用于挖掘大规模InSAR时间序列数据中的潜在模式。Cai等(2023)将时间序列InSAR技术与改进的Faster RCNN模型结合,实现了区域活跃滑坡的高精度自动识别。针对形变时序中的变化点检测,Lattari等(2022)利用长短期记忆网络(LSTM)与时间门控LSTM(TGLSTM)结合真实数据模拟,实现了地表形变趋势异常变化的自动识别。在形变模式识别方面,Yang等(2025)综合运用双向LSTM、时间卷积网络(TCN)及Transformer模型,并引入迁移学习技术,对城市环境中的InSAR形变时序进行分类,迁移学习则显著降低了对真实标注数据的依赖,突破了InSAR数据标注的瓶颈,有助于揭示传统速度分析方法难以捕捉的细微形变特征。此外,Kulshrestha等(2022)采用双向LSTM与多阈值过滤技术,对InSAR时序中的塌陷相关异常,如阶跃与速率变化等进行检测与分类,为地质灾害早期识别提供了分类思路。上述研究体现了深度学习在提升InSAR自动化水平和可解释性方面的进展,推动了地质灾害监测从传统方法向智能化方向发展。

然而, 这些方法仍然存在需要大量人工标记的地面真实形变数据的问题且模型效果移植性较差。

针对真实 InSAR 样本数据稀缺及神经网络模型可移植性不足的问题, 本研究在现有形变模式分类体系基础上进一步拓展, 定义了一套更具通用性的时序形变类别, 包括稳定型、线性型、阶跃型、分段线性型、幂律型及未定义型。基于此, 引入时间卷积网络作为时序分类的基础架构, 并结合迁移学习策略, 有效缓解标注样本不足对模型性能的制约, 该策略提升了模型在真实场景中的适应性、鲁棒性与泛化能力。结果表明, 所提框架在白鹤滩库区 InSAR 时序数据上具有良好识别效果, 不仅验证了方法的有效性, 也突显了迁移学习在解决标记数据匮乏、增强模型跨域迁移能力方面的潜力与价值。

2 研究方法

本文研究方法主要包括3个环节。首先, 利用 SBAS-InSAR 技术 (Berardino 等, 2002) 对研究区时间序列数据进行处理, 以获取高精度的地表形变场, 鉴于该方法已较为成熟, 此处不再赘述。其次, 借鉴 Yang 等 (2025) 提出的形变模式分类框架, 将 InSAR 时间序列划分为若干预定义的模式类型。这些模式在不同区域和数据集均具有可识别性, 并能够结合相关潜在物理过程进行解释。本文共定义5种具有明确数学表征的典型形变模式: 平稳型、线性型、阶跃型、分段线性型和幂次型。此类模式的识别不依赖于特定区域事件, 相似的形变过程往往由相似的物理机制驱动。最后, 本文的核心工作是构建一种基于迁移学习与时间卷积网络 (TCN) 的时序形变模式分类模型, 以提升 InSAR 时序数据的模式识别能力与泛化性能。

2.1 基于迁移学习与 TCN 的 InSAR 时序形变模式识别模型

在进行 InSAR 时间序列分析之前, 需要对原始数据进行滤波, 以削弱随机波动和噪声的影响, 从而更好地突出序列中的趋势成分。本文选用 SG (Savitzky-Golay) (Savitzky 和 Golay, 1964) 滤波器进行滤波, 这种滤波方法的优点是在滤除噪声的同时可以确保信号的形状和宽度不变, 保留了数据中的边缘或过渡。SG 滤波是在数据上滑动窗口, 对窗口内的点拟合一个多项式, 窗口的中心点由

多项式拟合估计的值取代, 对于每个窗口, \hat{x}_i 是经过滤波处理后的第 i 个点的值, p 是窗口内多项式的阶数, a_j 是多项式系数, 系数由最小二乘法求得, 因此 p 应该小于窗口长度。

$$\hat{x}_i = \sum_{j=0}^p a_j x_i^j \quad (1)$$

时间序列规范化有助于将不同尺度的特征调整到同一范围, 以避免变尺度数据的干扰, 使模型更关注 InSAR 时序数据内的相对变化特征。在本实验中选用 Z-Score 标准化来进行时间序列规范化:

$$Z - \text{Score} = \frac{x - \mu}{\sigma} \quad (2)$$

通过式 (1) 将原始 InSAR 数据转换为均值为 0, 标准差为 1, 符合标准正态分布的无量纲数据集, 同时也能进一步削弱噪声的影响。

本文采用深度学习方法来识别大规模 InSAR 时间序列中的形变模式, 长度为 T 的一维 InSAR 时间序列可被建模为 $\{x_0, x_1, \dots, x_{T-1}\}$ 用于神经网络的输入。基于卷积架构神经网络构建思想构建时域卷积网络 TCN (Temporal Convolutional Network) 模型对 InSAR 形变模式识别任务进行实验。神经网络总体结构如图 1 (a), 其中核心部分特征提取层由 N 层堆叠而成。神经网络的实现由不同模型的 N 个隐藏层和最终分类层组成, 最终分类层由全连接 FC (fully connected) 网络实现, 通过最后一层隐藏层的时间序列输出表征给出不同类别的预测概率 p_c :

$$p_c = FC(h_i) = \text{softmax}(W_{FC} \cdot h_i + b_{FC}) \quad (3)$$

式中, W_{FC} , b_{FC} 是 FC 层的可学习参数, 输出 $p_c \in [0, 1]$ 是输入样本 X 被识别为不同类别的概率矩阵, 由 softmax 激活函数产生。

TCN 是一种不使用门控机制的时间序列分析网络 (Bai 等, 2018), 能够适用于具有时序性的数据同时可以拥有较大的感受野 (He 和 Zhao, 2019)。对于卷积网络, 每一层使用相同的卷积核且在不同的数据位置上执行的卷积操作是独立的, 因此 TCN 天然具有并行处理的优势可以大大缩短时间。虽然传统的 CNN 架构不具备记忆历史时段信息的能力, 但经过特定设计的 CNN 也能在时间序列分析上取得较好的效果, TCN 即是一种可以用于序列问题建模的特殊 CNN。TCN 的隐藏层是基本模块如图 1 (b), 输入基本模块的为 1 维时间

序列 X ，基本模块主要由两个具有相同膨胀系数的卷积层组成，每个基本模块包括 Conv1d 层，WeightNorm 层，Relu 层和 Dropout 层。Conv1d 是一个一维的膨胀因果卷积 (Van Den Oord 等, 2016)。对序列的元素 x_t 进行卷积运算的 F 定义为

$$F(x_t) = \sum_{i=0}^{k-1} w(i) \cdot x(t - d \cdot i) \quad (4)$$

式中， d 是膨胀因子，卷积核在输入序列上跳跃式移动，每次跳跃 d 个位置。 k 是卷积核大小， i 是卷积核内索引， $w(i)$ 是卷积核中的第 i 个元素， $x(t - d \cdot i)$ 表示从输入 InSAR 序列中选择的点，同时意味着卷积操作不会超过当前时刻 t ，从而确保了因果性。这样一个隐藏层的有效历史信息是 $(k - 1)d$ 。

WeightNorm 层 (Salimans 和 Kingma, 2016) 用于规范化权重参数，加速模型训练。Relu 层为非线性激活函数，用于增强模型的表达能力。Dropout 层用于防止深度学习模型的过拟合问题，输入时间序列 X 经过两层的膨胀因果卷积后输出为 $R(x)$ 。TCN 逐层向上传递，使用更深的网络可以使得神经网络的顶层输出能够表征更大范围的输入，从而有效扩展卷积神经网络的感受野，因此更深和更大的 TCN 的稳定是重要的。残差连接已经被反复证明有利于非常深的网络 (He 等, 2016)，在 TCN 中，使用残差模块连接卷积层，输出当前层的隐藏状态 $H(x)$ ：

$$H(x) = \text{Relu}(x + R(x)) \quad (5)$$

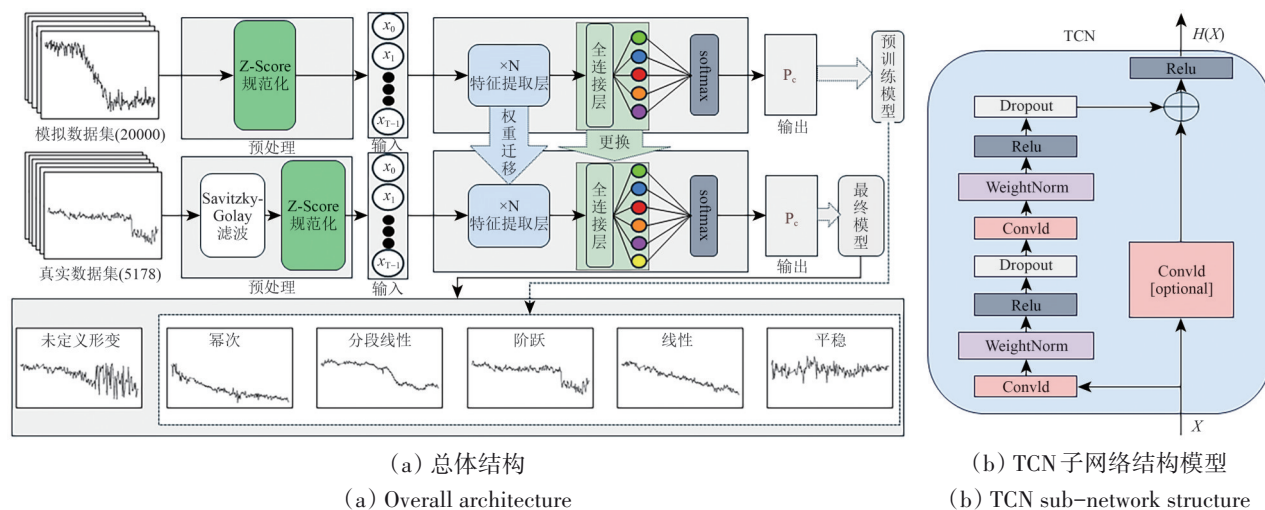


图1 基于迁移学习与TCN的InSAR时序形变模式识别模型

Fig. 1 InSAR time-series deformation pattern recognition model based on transfer learning and TCN

InSAR 时序分析的核心挑战在于，地表形变是一个严格的物理因果过程，同时数据本身还受到大气噪声等多种干扰。TCN 采用了膨胀因果卷积作为其基本运算单元，因果卷积确保了模型在计算任一时刻的输出时，仅依赖于当前及过去的历史观测，从而严格遵守了时序的因果关系。而膨胀卷积则通过指数级增大的膨胀因子，使网络在层数深度增加时，能够以极高的效率扩展其感受野。这意味着顶层的神经元可以关联到数月甚至数年前的历史输入，从而无需巨大参数量即可有效捕捉 InSAR 序列中诸如长期沉降、震后松弛等缓慢发展的趋势信号。

然而，单纯增加网络深度以获取更大感受野会带来梯度消失和训练不稳定的问题。TCN 借鉴了残差网络的思想，在每个基本模块中引入了残

差连接，这一设计缓解了深层网络的梯度消失难题，使构建足以覆盖长时间跨度的模型。在 InSAR 时序数据特征背景下，残差连接允许重要的低频背景形变信号直接穿越网络深层，而每个卷积模块则专注于学习对其的局部修正与细化，例如季节性波动、瞬时形变或噪声抑制。这种机制有效保护了决定形变主体的宏观信息不被层叠的非线性变换所湮没。相较于传统的循环神经网络，TCN 还具备并行计算的天然优势，能大幅提升对海量 InSAR 时序数据的处理效率。

在 TCN (时间卷积网络) 的超参数中，输入通道数设置为 1，这对应单变量时间序列数据，每个时间点仅有一个特征值。输出类别数在实际加载的模型中调整，以适应具体分类任务的类别数量。网络各层的通道配置在实际应用中为了增强

模型表达能力, 修改为九层结构, 每层 100 个通道, 增加模型的深度和复杂度。在残差块内部, 卷积核大小固定为 2; 卷积步长始终保持为 1, 确保不进行下采样; 膨胀系数按照指数规律增长 ($2^0, 2^1, 2^2, \dots$), 使得深层网络能够获得更大的感受野; 填充大小根据卷积核和膨胀系数自动计算, 确保输入输出序列长度保持一致; 丢弃率设置为 0.2, 高于模型整体的丢弃率, 为残差块内部提供更强的正则化效果。所有超参数共同作用, 构建了一个具有 9 层深度、每层 100 个通道、使用 7×7 卷积核的时间卷积网络, 该网络通过指数增长的膨胀系数扩大感受野, 通过残差连接缓解梯度消失, 通过权重归一化提高训练稳定性, 最终在时间序列分类任务中实现类别的准确识别。

在确定 TCN 为主要模型前, 我们做过模型比较实验, 分别采用时间卷积网络 (TCN)、双向长短期记忆网络 (BiLSTM) 和 Transformer 模型, 并在模拟数据集上对其性能进行了评估。如表 1 所示, 3 类模型在模拟数据上的分类准确率均超过 90%, Kappa 系数也普遍处于较高水平, 反映出模型对模拟数据中各类形变模式均具备良好的识别能力。这一结果符合预期, 主要源于模拟数据的构造机制相对简单。进一步比较发现, TCN 取得了最高的分类精度, Transformer 在训练时间上具有优势, 而 BiLSTM 不仅在精度上表现最低, 训练耗时也最长, 表明纯循环神经网络结构在处理本任务中的 InSAR 时间序列分类问题时并非最优选择。

表 1 模拟数据测试结果

Table 1 Simulated data test results

模型	准确率/%	Kappa 系数	训练耗时/s
BiLSTM	95.2	0.940	329.804
TCN	99.7	0.996	318.506
Transformer	98.2	0.977	308.790

注: 加粗字体标识了各项评价指标下的最优结果(准确率与 Kappa 系数取最高值, 训练耗时取最低值)。

基于上述结果, 可以确认 TCN 在模拟数据形变模式识别任务中具有最佳性能。随后, 我们通过迁移学习将模型在真实 InSAR 数据集上进一步训练, 并在独立测试集上评估其泛化能力。如表 2 所示, 与模拟数据相比, 所有模型在真实数据上的性能指标均出现一定程度下降, 这主要源于实际观测数据中更复杂的噪声与形变特征。其中, BiLSTM 性能下降最为显著, 准确率降低约 30 个百分点, Kappa 系数亦明显下降; 而 TCN 与 Transformer 仅下

降约 10 个百分点, Kappa 系数仍保持在 0.6 以上, 显示出二者在跨域迁移中更好的鲁棒性。最终, TCN 在真实数据测试中仍保持 90.1% 的准确率。此外, 因迁移训练阶段样本量有限, 所有模型的训练时间均有所缩短, 此为合理现象。

表 2 真实数据测试结果

Table 2 Real data test results

模型	准确率/%	Kappa 系数	训练耗时/s
BiLSTM	65.3	0.583	112.984
TCN	90.1	0.882	100.128
Transformer	88.7	0.864	73.107

注: 加粗字体标识了各项评价指标下的最优结果(准确率与 Kappa 系数取最高值, 训练耗时取最低值)。

综合模型在模拟与真实数据中的表现, 3 类模型的性能排序为: TCN>Transformer>BiLSTM。结合本研究所涉及的地理区域与分类目标, TCN 在保持高分类精度的同时, 亦具备更简便的调优过程。基于上述优势, 本研究在后续形变模式识别实验中选定 TCN 作为核心特征提取模型。

2.2 InSAR 时序形变模式识别迁移学习

本文提出的基于迁移学习与 TCN 的 InSAR 时序形变模式识别模型中, 将迁移学习用于模型的训练和迁移, 以降低对真实样本的依赖, 并提升模型的准确性。迁移学习是一种机器学习方法, 专注于将从已解决的任务 A 中学到的知识转移到相关的新任务 B, 从而帮助解决任务 B, 当任务 B 的数据有限或难以获得时尤其有用。迁移学习的核心目标是利用源任务积累的经验来提高目标任务的学习效率和表现。本文针对真实 InSAR 时间序列数据标注困难且形变模式复杂的问题, 采用先在大量模拟数据上预训练后小批量人工标记数据迁移微调的方法, 模拟数据上的 InSAR 形变模式识别为源任务, 真实数据上的 InSAR 形变模式识别为目标任务。模拟数据集为 $D_s = \{X^s, Y^s\}$, 真实数据集为 $D_t = \{X^t, Y^t\}$, X^s, X^t 分别为源任务和目标任务的时间序列数据矩阵, Y^s, Y^t 分别为源任务和目标任务的分类标签矩阵, 迁移学习过程可表述为如下:

$$\theta_s = \underset{\theta}{\text{arcmin}} L(Y^s, f(X^s; \theta), g_s(\cdot)) \quad (6)$$

$$Z^t = f(X^t; \theta_s) \quad (7)$$

$$\theta_t = \underset{\theta_s}{\text{arcmin}} L(Y^t, Z^t, g_t(\cdot; W_t, b_t)) \quad (8)$$

式中, $f(\cdot)$ 和 $g(\cdot)$ 分别是深度学习模型的特征提取器和分类器, L 为损失函数, 训练的目标是得到使损失函数最小化的模型参数, θ_0 , θ_s , θ_t 分别是源任务特征提取器的默认初始化参数, 调优后的参数, 目标任务调优后的参数, Z' 是目标任务上的初始特征表示, 由于源任务为模拟数据上的5分类任务, 目标任务为真实数据集上的6分类任务, 所以分类器由 $g_s(\cdot)$ 替换为 $g_t(\cdot)$, W_t , b_t 为最终目标任务的分类器参数。

3 基于迁移学习与TCN的InSAR时序形变模式识别模型训练

3.1 模型训练数据集

本研究构建了一套基于数学定义与物理机制的InSAR时间序列形变模式分类体系, 旨在实现对各类形变过程的自动识别与物理解释。该方法将形变模式归纳为以下6类基本类型, 如图2所示, 每一类均具备明确的数学特征, 并对应特定的地质或人为过程: (1) 平稳形变: 数学上表现为形变量随时间在稳定值附近随机波动, 与时间无显著相关性。物理上通常反映监测期间内无明显位移的稳定地表或人工构筑物 (Berti等, 2013)。

(2) 线性形变: 数学上呈形变随时间以恒定速率递增或递减的线性关系。物理上多与持续作用的变形机制相关, 如滑坡蠕变、地面沉降或构造活动的稳态运动。(3) 阶跃形变: 数学上体现为某一时刻形变发生跳跃式变化, 阶跃前后形变速率可保持一致或发生改变 (Berti等, 2013)。物理上通常由地震、断层错动、采矿塌陷等瞬态事件引起。(4) 分段线性形变: 数学上由多个具有不同斜率的线性段组成, 各段通过分段点连接。物理上常见于与流体抽取或回注相关的地表响应, 如油气开采过程中不同生产阶段导致的多段线性形变 (Ketelaar, 2009); 亦可见于地震前后运动状态的改变 (Mirmazloumi等, 2022a)、滑坡多阶段演化 (Mirmazloumi等, 2022b) 及火山活动不同时期的形变组合 (Lanari等, 2010)。(5) 幂次形变: 数学上表现为形变速率随时间连续变化, 呈加速或减速趋势。物理上通常与震后松弛 (Savage等, 2003)、滑坡演化 (Montgomery等, 1998)、土壤压实或矿区渐进变形 (Wang等, 2020) 等过程相关。若序列末期形变速率趋于零, 则指示减速过程; 反之为加速过程。(6) 未定义形变: 包括因数据处理误差导致的低质量序列、多种基本模式的混合形态, 以及其他无法归类为上述基本模式的复杂形变过程。




图2 6种可解释的形变类别

Fig. 2 Six interpretable deformation categories

由于真实 InSAR 时间序列标注数据的匮乏，难以标注大量样本进行训练，所以首先合成 5 种基本形变模式的模拟数据。为了能够充分模拟真实数据的特征，增加深度学习模型的鲁棒性，模拟数据需要添加高斯白噪声 $n(t)$ ，本研究中高斯白噪声服从均值为 0，方差为 0.83^2 的标准正态分布。根据 3σ 原则在进行数据模拟时要保证噪声项分布大多数在 3σ 范围内，设置 $3\sigma \approx 2.5$ 表明白噪声主要在 $-2.5—2.5$ mm 范围内波动，故 $\sigma^2 = 0.83^2$ 。由此 InSAR 形变模拟主要根据以下公式：

$$D_i = f(t) + n(t), n(t) \sim N(0, 0.83^2) \quad (9)$$

式中， $f(t)$ 根据算法 1 生成 5 种基本形变模式， k ， k_1 ， k_2 ， k_3 为模拟数据时不同线性域的数值意义的斜率，即使模拟数据要经过数据标准化再输入神经网络，但模拟数据时依旧合理设置斜率值和缩放因子 α 使数据近似真实 InSAR 数据的相对变化情

况，具体模拟时间序列时模拟时间序列的极差不超过 InSAR 监测真实数据的最大极差 326 mm，这也更符合实际研究区域的地表变化情况。总共模拟 20000 条形变数据，训练集，验证集和测试集的比例为 7 : 1 : 2。本文模拟数据中增加的白噪声，指时序 InSAR 数据经过去噪处理后，残存于形变序列中的随机成分，该类噪声具有幅值小、无空间关联性及无时间相关性的特征。

最终模拟的部分形变数据图 3 所示，分别为平稳形变模式、线性形变模式、阶跃形变模式、分段线性形变模式、幂次形变模式。阶跃形变模式可能上下阶跃，阶跃前后速率变化或不变，分段线性形变模式主要模拟了两段和三段两种常见线性情况，幂次形变模式模拟存在形变速率的递增或递减情况。

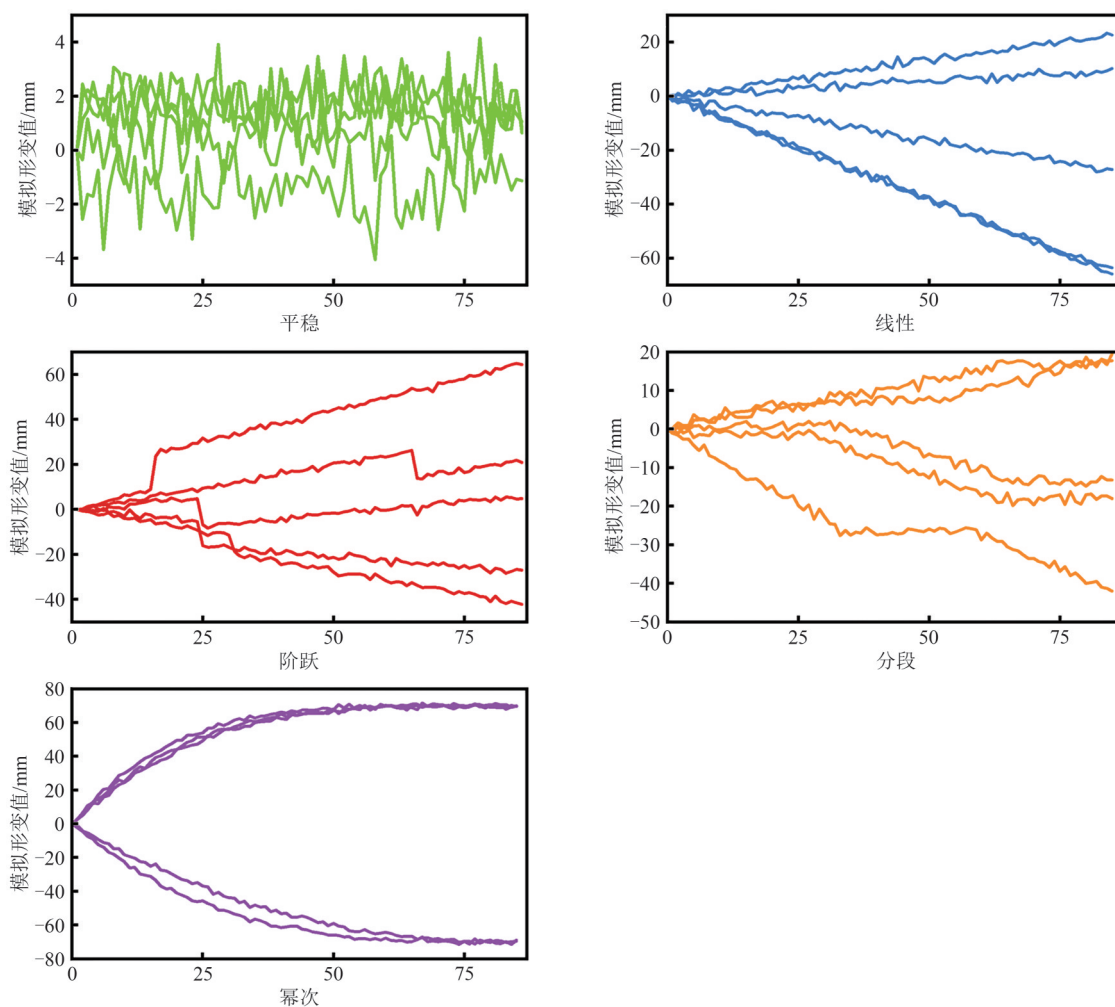


图 3 模拟的 5 种基本形变类别(部分示意)

Fig. 3 Simulated five basic deformation categories (Partial illustration)

实验区内总共获取 97377 个相干点, 由于在本文提出的 InSAR 形变模式识别方法中, 对真实数据进行迁移训练仅需要少量标签数据, 因此通过目视解译在真实数据中标注了 5178 个相干点, 其中训练集: 验证集: 测试集的比例为 7 : 1 : 2, 保留了充足的训练集和测试集用于训练和测试, 同时又有一定的验证集辅助进行超参数的调优, 标注了 1034 个相干点作为测试集, 不同类别的样本标注情况如表 3。

表 3 真实样本标注数量

Table 3 Number of labeled real samples

形变模式	训练集	验证集	测试集	行总计
平稳	609	87	174	870
线性	608	86	173	867
阶跃	602	86	172	860
分段线性	607	86	173	866
幂次	603	86	172	861
未分类	599	85	170	854
列总计	3628	516	1034	5178

3.2 模型训练流程

在模型预处理阶段, SG 滤波的关键参数是窗长 w_l 和多项式阶数 p_o , w_l 越大每个窗口内估值时允许考虑的点就越多, 从而产生更平滑的输出, 但同时伴随着滤波过度失去精细细节的风险。 p_o 越大, 窗口内更高阶的多项式可以捕获更复杂的趋势变化, 但也可能引入不必要的振荡噪声。因为神经网络经过训练可以对含噪声的数据具有一定鲁棒性, 所以滤波预处理中应重点关注形变细节的保留, 在研究中设置 $w_l = 5$, $p_o = 3$ 来进行滤波, 以便在不损失 InSAR 形变阶跃点, 分段线性变化点等细节的同时尽可能去除噪声。

InSAR 形变模式识别任务本质为多分类问题, 所以训练过程中的损失函数采用交叉熵损失函数, 用于计算模型预测类别和真实类别的损失, 其计算公式如下所示:

$$L = -\frac{1}{N \times M} \sum_{i=1}^N \sum_{c=1}^M s_{ic} \log(p_{ic}) \quad (10)$$

式中, N 为样本总数, M 为类别总数, i 和 c 分别为样本索引和类别索引, s_{ic} 是一个符号函数, 若样本 i 的真实类别等于 c 则取 1, 否则取 0。 p_{ic} 为观测样本 i 属于类别 c 的预测概率。

模型训练分为模拟数据训练和真实数据迁移微调两个阶段。在训练期间, 输入的 InSAR 数据通过网络前向传播以生成预测输出, 然后通过交叉熵损失函数计算预测和目标输出之间的误差。通过反向传播过程, 模型计算网络每层的梯度, 然后指导优化算法更新网络中的参数。前向传播和后向传播协同工作, 迭代过程持续不断, 逐渐接近能够使损失函数最小化的最优解, 以使得网络预测更接近真实标签。模型训练的硬件平台 GPU 为 Nvidia GeForce RTX 3090, CPU 为 12th Gen Intel (R) Core (TM) i9-12900k。模型训练的软件平台 Python 版本为 3.9.0, Torch 版本为 2.0.0, CUDA 版本为 11.7。

本研究通过模拟数据验证了方法在含噪数据中的基本鲁棒性, 但当前的模拟数据构建策略存在一定局限性。对真实 InSAR 时序数据进行了 Savitzky-Golay 滤波以抑制高频噪声, 但模拟数据并未进行相同的预处理, 这导致了模拟数据与真实数据处理流程的不一致, 可能使得模型在模拟实验中的去噪与趋势提取表现与处理实际已滤波数据时的表现存在评估间隙。在模拟数据中添加的噪声主要为高斯白噪声, 其目的在于表征 InSAR 系统中普遍存在的、量级相对较小的随机测量误差, 而在实际的时序 InSAR 观测中, 尤其是于山区、河谷等复杂地形区域, 由大气时空变化引起的相位延迟误差往往具有显著的空间相关性, 且其量级可能远超本文所设的毫米级随机噪声。尽管在时序 InSAR 处理中, 大气误差通常会通过时空滤波、外部数据融合等方法进行估计与剔除, 但残余的大气信号或改正不完善引入的误差仍然是实际形变结果中不容忽视的不确定性来源。本研究没有在模拟数据中显式构建此类更复杂、量级可能更大的误差成分, 当前实验对于抵抗强空间相关噪声或系统性偏差的能力仍需在未来利用更逼真的模拟数据或包含典型大气误差场景的真实数据进行进一步验证。

构建更贴近真实的模拟数据集需综合考量 InSAR 误差的多元构成, 特别是引入具有合理空间结构与幅度的模拟大气相位, 以及考虑地形相关相位等。发展能够协同抑制随机噪声与空间相关误差的增强型滤波或校正算法也是提升本方法实用性与稳健性的关键, 后续工作将致力于在此方

面进行深化,以期使方法能更好地应对复杂现实场景下的挑战。

4 白鹤滩库区 InSAR 时序形变模式分类结果分析

4.1 实验区概况

白鹤滩水电站是金沙江下游4个梯级水电站的第二梯级,坝址位于四川省宁南县和云南省巧家县境内,上游距巧家县城约41 km,距乌东德坝址约182 km;下游距离溪洛渡水电站约195 km,距离宜宾市河道里程约380 km。坝址控制流域面积43.03万 km^2 ,占金沙江以上流域面积的91%。区域海拔在550—4224 m。实验区位于药山镇到拖布卡镇之间沿江两侧约10 km的库岸边坡,如图4所示。

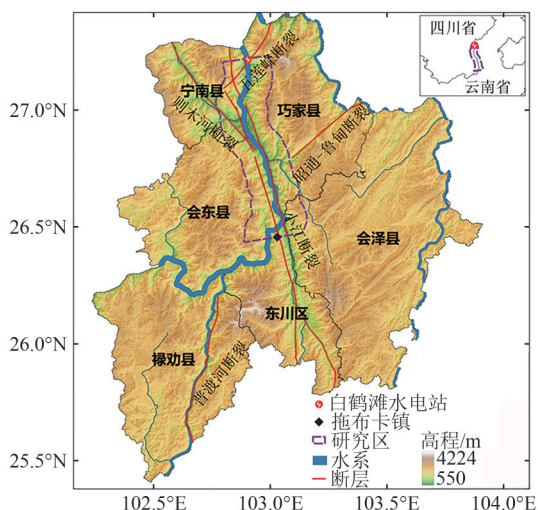


图4 白鹤滩水电站库岸边坡实验区位图

Fig. 4 Location map of the experimental area for reservoir bank slopes at the Baihetan hydropower station

实验区域涵盖水库库区的中上游段,其中中游地带人口聚居较为密集。该区域人类工程活动类型多样,包括水利水电工程建设、道路交通与城镇开发、矿产资源开采,以及农业垦殖引发的植被破坏等类型。当前沿江公路边坡因工程开挖引发多处崩塌、滑坡现象,形成不少地质灾害隐患点;坡地因过度垦殖引发严重的水土流失问题,区域内冲沟发育及泥石流现象普遍,原生地质环境受到显著扰动(顿佳伟等,2023)。

白鹤滩水电工程设计正常蓄水位825 m,防洪限制水位785 m,死水位765 m,年内水位波动约

60 m。从白鹤滩水电站正式下闸蓄水开始,选择从2021年4月—2024年4月的影像数据进行边坡形变监测。

4.2 实验区 InSAR 时序形变结果

本文实验采用Sentinel-1卫星降轨干涉宽幅模式(IW)数据,研究时段为2021年4月9日—2024年3月24日,共获取85景影像。利用SBAS-InSAR技术生成干涉图并反演形变速率,同时结合GACOS数据进行大气延迟改正,最终获得整个库区的地表形变场。

本研究采用水准测量数据对SBAS-InSAR监测结果的精度进行评定。SBAS-InSAR数据覆盖时段为2021年—2024年,而水准监测分别于2022年7月24日、2023年5月13日及2024年1月26日获取了两个水准点的高程数据。为实现在时间节点上的对齐,对InSAR时间序列进行了插值处理,以获取与水准观测同期对应的形变值,在空间匹配方面,选取各水准点周边30 m范围内的InSAR监测点作为对比样本。结果如图5显示,两个样本点的InSAR形变序列与水准观测结果整体吻合良好,平均误差为0.095 mm,均方根误差为0.35 mm,表明SBAS-InSAR监测数据具有较高的可靠性。

图6(a)显示了2021年4月—2024年3月的视线向(LOS)降轨形变监测结果。降轨数据中在实验区内得到97377个相干点,监测结果表明,实验区大部分区域保持了相对稳定的趋势,形变速率范围为 $[-108, 57]$ mm/a,对形变速率分布进行统计如图6(b),速率服从正态分布,有接近99%的点形变速率在 $[-25, 25]$ mm/a以内,其中816个相干点速率小于 -25 mm/a,占比0.83%,形变速率大于25 mm/a的点有319个,占比0.38%。InSAR监测结果分布在库中段和小部分库首段。在库首段,距坝址10—30 km范围内零星分布有少量抬升区,在金沙江支流分流处存在明显抬升;在库中段,受人类活动影响较多,尤其是巧家县城附近有明显的沉降形变,沉降区集中在距坝址60—85 km范围内,且该段河道两侧形变密集,应该重点关注。从监测结果可以得出,InSAR结果在整体形变稳定,白鹤滩水电站自建成蓄水后运行的3年时间里,对周围地质环境的影响不大,大部分地区形变速率较小。

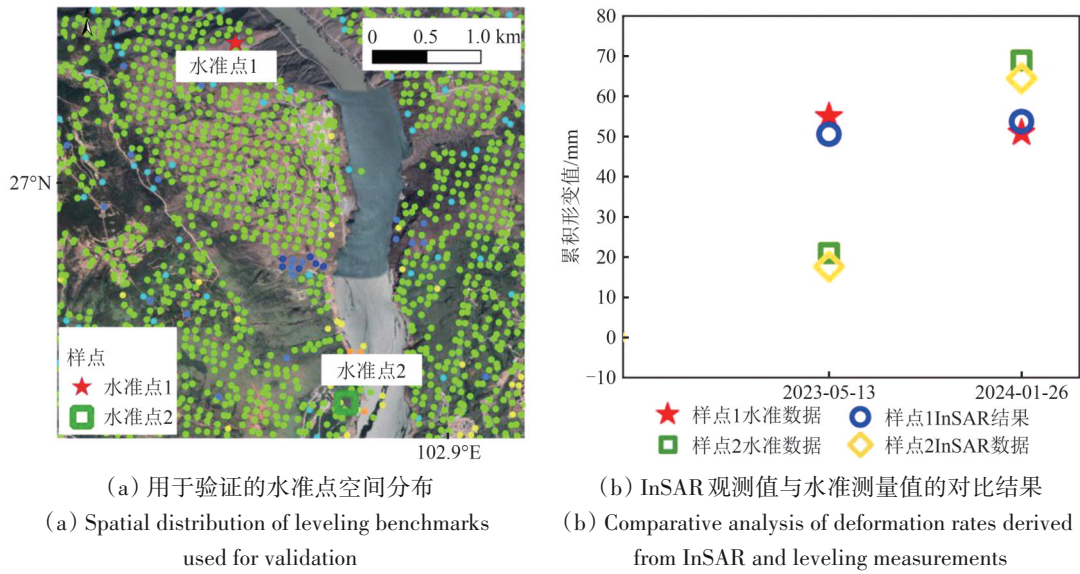


图5 InSAR形变监测结果的精度验证

Fig. 5 Accuracy validation of the InSAR deformation monitoring results

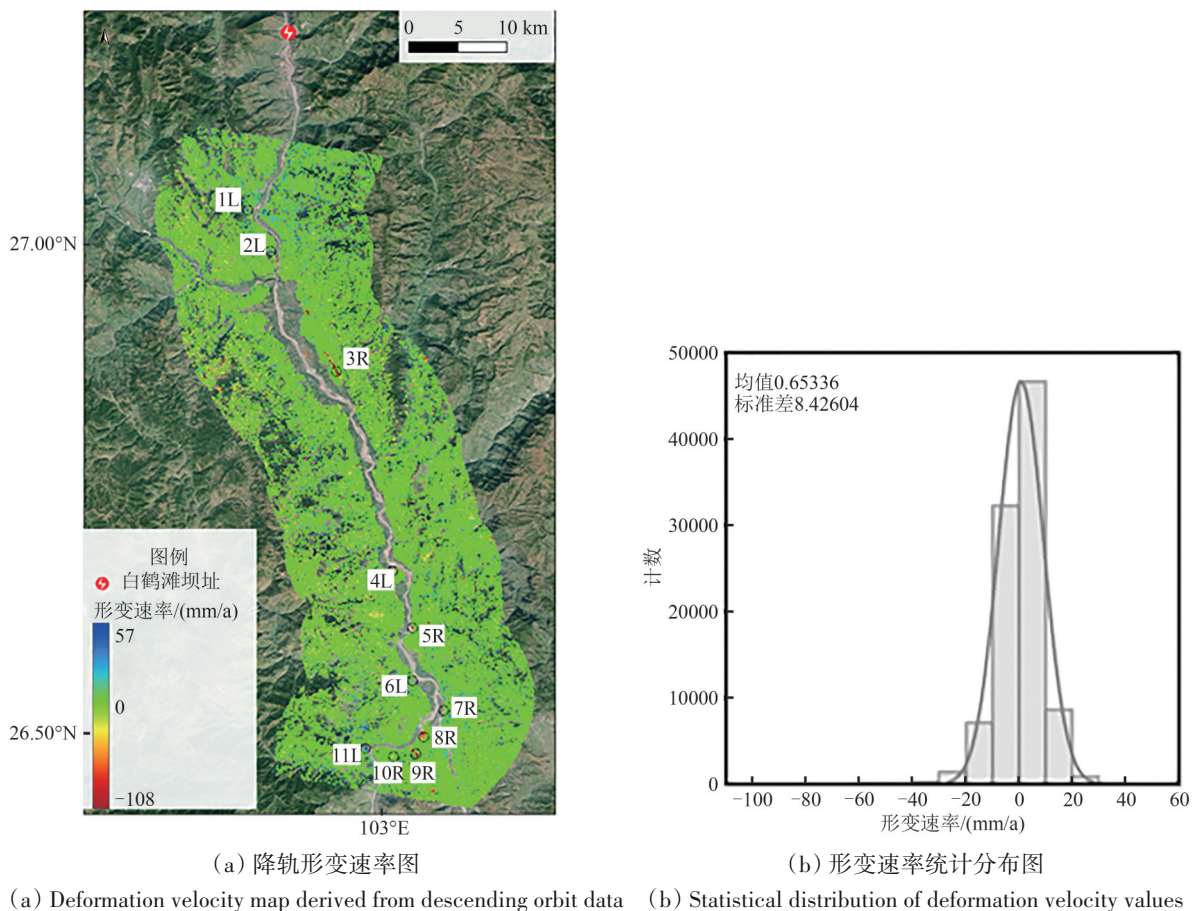


图6 研究区地表形变速率监测结果

Fig. 6 Monitoring results of surface deformation velocity in the study area

4.3 白鹤滩库区 InSAR 时序形变模式识别结果

将经过迁移训练的 TCN 模型应用于整个白鹤滩库区降轨数据进行分类, 得到白鹤滩库区的

InSAR 时序形变模式分类结果。从图 7 (a) 可以看出, 绿色代表的平稳形变分布范围最广, 表明实验区多数区域地表形变相对稳定, 但是与形变速

率图对比分析可以发现, 实验区域内平稳形变的实际占比, 较速率阈值法判定的平稳比例存在差异, 并未达到后者所呈现的规模; 与此同时, 白鹤滩库区地表形变类别呈现较为显著空间分异特征, 这一结果也与实际地表复杂多变的演化特征高度吻合。图7 (b) 呈现各类形变比例, 平稳形变占比45.6%, 为主要形变类型, 反映实验区整体稳定性较高; 其次是分段线性 (24.4%) 和阶跃

(15.4%), 表明部分区域存在阶段性形变或突发性形变特征, 而未定义类别占比1.8%, 表明本文的分类方法对多数区域适用性较强。线性形变所占的比例并不高 (5.9%), 这也说明了在进行时序InSAR处理时主流的线性模型形变反演并不完善。幂次形变多与滑坡的变化相关, 占比7%也说明了该区域存在一定量的滑坡。

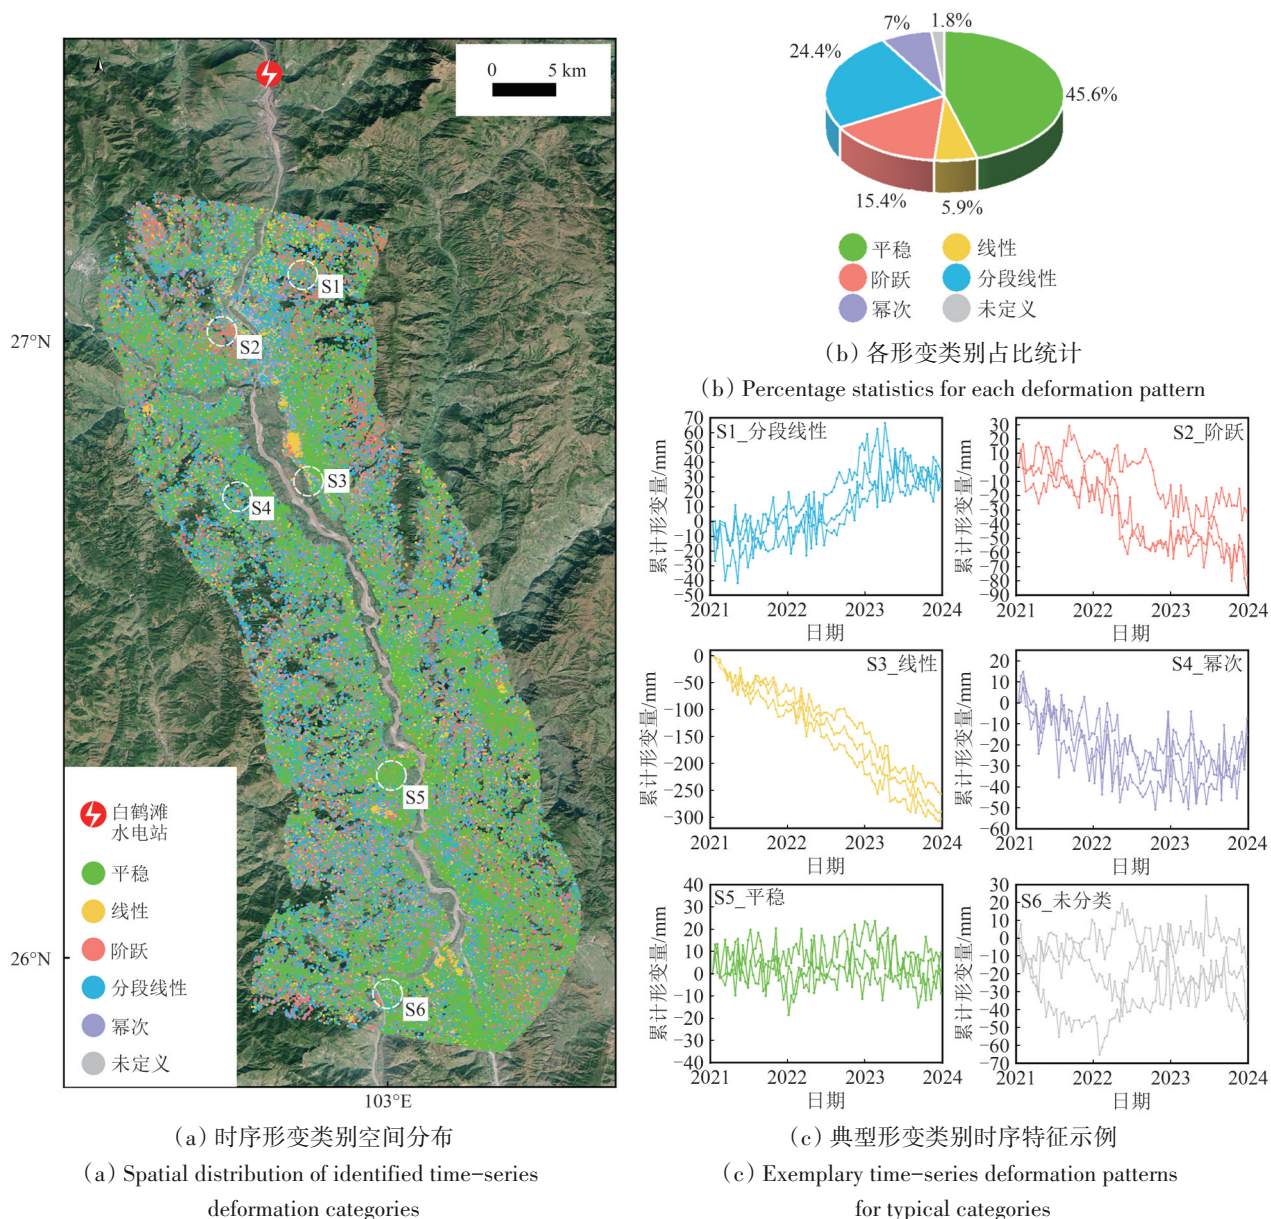


图7 研究区时序InSAR形变分类结果

Fig. 7 Classification results of time-series InSAR deformation in the study area

由于整个白鹤滩库区面积大, 不同区域InSAR地表形变幅度差异性大, 而本文的方法重点捕捉形变内在时序变化的形状特征, 所以此处选择S1—S6区域内的显著形变类别点绘制其时间序列

来观察形变识别的效果 (图7 (c)), S1—S6分别代表分段线性形变模式、阶跃形变模式、线性形变模式、幂次形变模式、平稳模式、未定义分类模式 (图8)。可以观察到S1—S6形变类别差异明

显，表明本文的方法在真实数据的形变分类上也具有较好的识别效果。

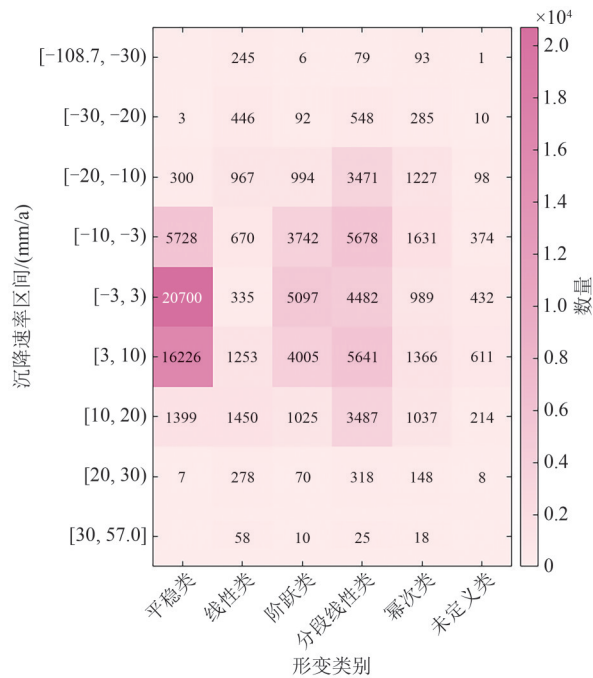


图8 不同形变类别的形变速率区间分布

Fig. 8 Distribution of deformation rate ranges for different deformation patterns

进一步分析不同形变模式与形变速率的关系可以发现，不同形变类别在速率区间上呈现出明显的分布规律。平稳类形变高度集中于[-3, 3) mm/a的低速区间，反映出地表基本稳定的状态。线性类形变则在中低速率沉降区间（如[-20, -10) mm/a）与抬升区间（如[10, 20) mm/a）呈现双峰分布，表现为持续、匀速的单向形变特征。分段线性、阶跃、幂次等复杂形变类别共同主导中低速率的区间，尤其在[-10, -3)及[3, 10) mm/a范围内分布最为集中，说明该速率段是形变发生转折、突变或非线性变化的主要区域，可能对应着地质活动、人为工程影响或水文作用等多种机制。

从各类形变模式内部的速率分布来看，其形变特征进一步凸显：平稳类在低速区间占比极高，随着速率绝对值增大比例迅速下降；线性类在中等速率区间表现突出，在极高速与极低速区间占比较低，符合其线性形变的模式；复杂形变类别广泛覆盖中低速率段，在高速区间占比极低，说明强形变下复杂时序特征相对较少；未定义类在多个区间均有一定分布，进一步反映了其信号解

释与分类上的不确定性。这一分布规律也与白鹤滩库区的实际分类结果相对应：平稳形变虽占比最高（45.6%），但并未覆盖所有低速区域，说明仅凭速率阈值难以完全识别形变模式；线性形变比例较低（5.9%），暗示单纯线性模型在反演复杂时序形变时的局限；而分段线性、阶跃与幂次等类别在中低速率区广泛存在，印证了该区域形变机制的多样性与时序行为的非线性特征（图9）。



图9 不同形变类别内形变速率区间的相对占比

Fig. 9 Relative proportion of deformation rate ranges within each deformation pattern

4.4 白鹤滩库区InSAR时序形变模式相关性分析

通过对形变类别，速度和相干性进行分析，图10表明大多数形变类别的速率集中在-5—5（mm/a）之间，与整体的速率分布保持一致，非平稳形变类别在Q2（中位数）和Q3（第三四分位数）的速率分布密度比Q1（第一四分位数）和Q2之间的速率分布密度更高。平稳形变的点集呈现单峰分布，速度范围为-5—5 mm/a，峰值在0 mm/a附近。线性、分段线性和幂次形变类别呈现双峰分布，在正、负速率段均有峰值。线性和分段线性形变类别的速率中位数大于0 mm/a，而幂次形变的中位速率接近0 mm/a。阶跃和未定义形变类别也呈现双峰分布，速率中位数接近0 mm/a，且这两种类别在速率为0 mm/a附近也相对于其他非平稳类别数据点更密集。




图 10 不同形变类别关于速率的分布图

Fig. 10 Distribution of different deformation types with respect to rate

在图 11 中，各种形变类别的相干性值集中在 0.6—1 之间，相干性中位数在 0.6—0.8 之间。平稳形变类别的数据点密度在 0.6—0.8 之间最高。线性、分段线性和幂次形变表现出相似的相干性分布，在 0.8—1 之间的密度最高。阶跃和未定义类别也表现出相似的相干性分布。




图 11 不同形变类别关于相干性的分布图

Fig. 11 Distribution of different deformation types with respect to coherence

上述结果表明，不同的时序形变类别在速率分布和相干性分布方面表现出独特的特征。平稳形变通常表现为低的速率和较高的相干性，而其

他形变类别，比如线性、分段线性和幂次，可能具有更广的速率变化范围和不同的相干水平。阶跃和未定义形变在速率分布上表现出更高的可变性，但往往具有相似的相干水平。这些发现为实验区域的变形特征和潜在机制提供了有价值的见解，有助于更好地理解驱动这些形变的物理过程。

地表形变的发育和分布与地形因子具有密切的关系。将实验区的地形坡度按照每 10° 一个等级进行划分，如图 12 分为 7 个等级。结果表明，随着坡度的增加，6 种形变类别的数量存在先增大后减小的趋势，与不同等级坡度占比变化趋势保持一致，坡度在 10°—40° 占比较多，相应的各个类别的数量也在这个范围内占比较大。不同坡度的形变类别也占比也与饼图一致。其中平稳形变和阶跃形变在 20°—30° 之间达到峰值，其他 4 种非平稳形变均在坡度为 30°—40° 之间时达到峰值。




图 12 不同形变类别关于坡度的分布图

Fig. 12 Distribution of different deformation types with respect to slope gradient

太阳辐射和降水会受到坡向分布的影响，进一步影响地表植被生长。对于地震诱发的斜坡，坡向也会影响地震动力的传播方向（戴福初和邓建辉，2020）。分别统计实验区 6 大形变类别在 N、NE、E、SE、S、SW、W 和 NW 等 8 个不同坡向下的占比情况，生成分析雷达图（图 13）。结果表明，实验区阳坡（SE、S、SW）较多，每种类别大部分 InSAR 点集中在此，但总体各个方向所占比例差异不大，因为实验区选择了沿河岸 10 km 做缓冲区，所以除了沿南北走向河谷的 W 和 E 方向斜坡外，S 方向的斜坡也有很多。每种形变类别均在 S 方向上占比较大，在 NW 方向上占比较少，这也是由于降轨雷达侧视成像的特点导致的，雷达散射对及雷达波束对地面倾斜照射时，在山脉、高大目标的背

面因接收不到雷达信号，会产生雷达阴影，导致相干点较少，这也说明NW向雷达阴影较多。

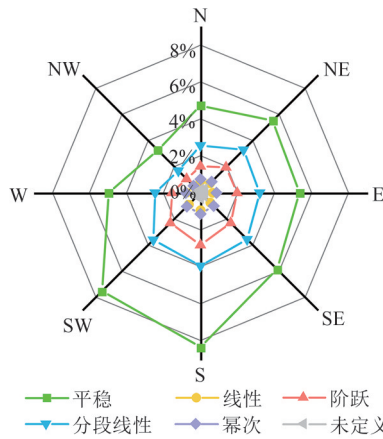


图 13 不同形变类别关于坡向的分布图

Fig. 13 Distribution of different deformation types with respect to slope aspect

4.5 石门坎和野猪塘形变区时空特征分析

选取降轨速率图和降轨形变模式图都能共同观测到的象鼻岭重点沉降区进行分析，该区域位于象鼻岭和金沙江之间，有两个较为明显的沉降区。DD’为石门坎形变区，该区域在边坡上呈现扇形分布。LL’为野猪塘形变区，该区域狭长沿斜坡呈现长条带状分布。这个区域的岩性以变质细碎屑岩、碳酸盐岩夹火山岩、火山碎屑岩为主，区域结构稳定性差，岩性容易进水，受水压力改变地层应力，抗风化侵蚀能力弱。

首先对石门坎斜坡进行沉降漏斗分析，基于图 14 所示的 DD’ 剖线，对沿线的 InSAR 时间序列形变数据进行提取。通过选取 6 个具有代表性的 InSAR 时间节点，对沉降漏斗区域的形变演化过程进行分析，具体结果如图 15 所示。

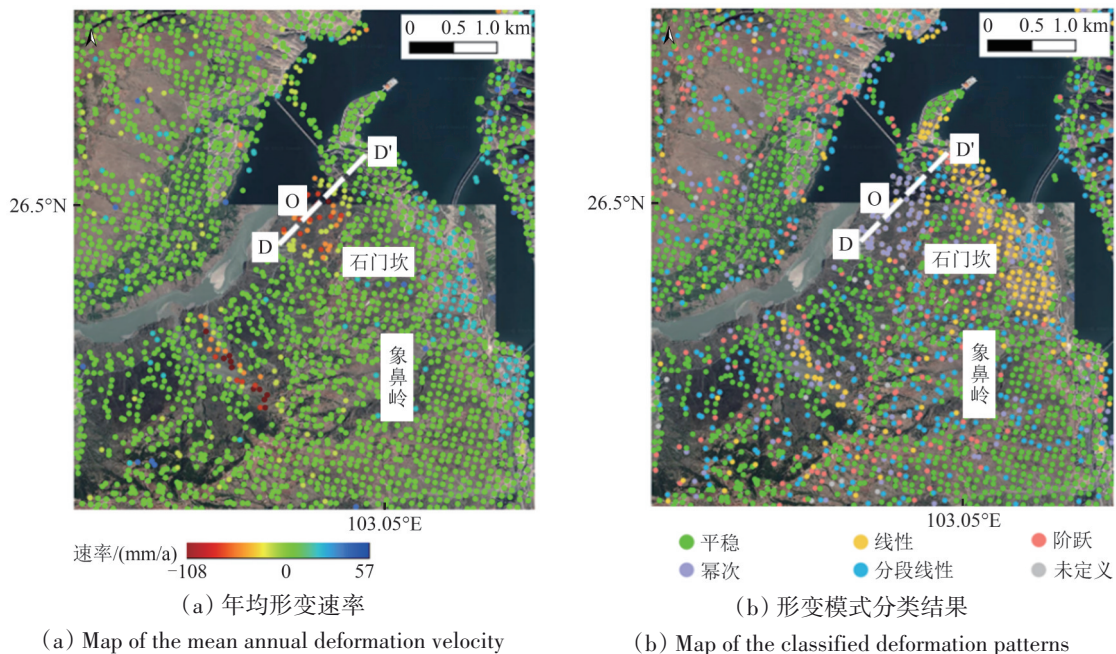


图 14 石门坎地区地表形变监测结果

Fig. 14 Monitoring results of surface deformation in the Shimenkan area

图 15 中，“2211”指的是在 2022 年 11 月的 InSAR 累积形变量值。从图 15 可以清晰地理解不同时间点的沉降变化情况。沉降中心区域在距 D 点 100—300 m 范围内，该区域在多个时间点出现明显的下沉趋势，下沉量最大可达 130 mm。随着离漏斗中心越远，地表形变量越小，显示出相对稳定的地表状态。2021 年 5 月时，整个形变区出现轻微沉降，2021 年 7 月到 2022 年 3 月的第一个蓄水周期漏斗中

心沉降了 55 mm。2022 年 6 月—2023 年 4 月的第二个蓄水周期内漏斗中心累计最高沉降 103 mm，其中 2023 年 01 月到 2023 年 04 月出现轻微的抬升与水位上升的滞后作用有关，累计抬升约 15 mm。2023 年 06 月到 2024 年 01 月，漏斗中心最大沉降 141 mm。

将石门坎区域的时间序列进行逐条绘制以进行具体分析，并联合降水、水位综合分析如图 16。图 16 中点线的颜色代表该点的形变类别。该区域

大部分相干点总体以幂次形变为主，仅有一条线性形变序列和一条分段线性形变序列。幂次形变速率变化较大的点即为上述的五个时间点。该区域的InSAR观测结果总体呈现下降趋势，2021年6—8月降水量丰富，此时形变受降雨影响沉降速度较快，此后一段时间形变受水位和第一次蓄水的耦合作用，虽有沉降，但是沉降较慢，第二次和第三次蓄水后，2023年1月—2023年4月，2023年11月—2024年3月都存在形变的抬升，相比于当年的最高蓄水位月份，有两个月的时滞。该结果与沉降漏斗的结果也具有较高的一致性。

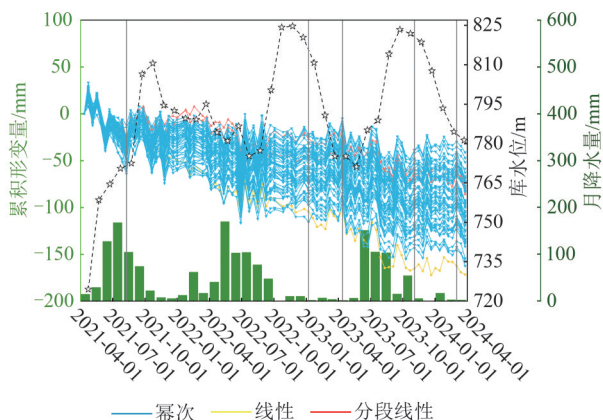


图 16 石门坎边坡形变、降水、库水位变化关系
Fig. 16 Relationship between deformation, precipitation, and reservoir water level changes at the Shimenkan slope



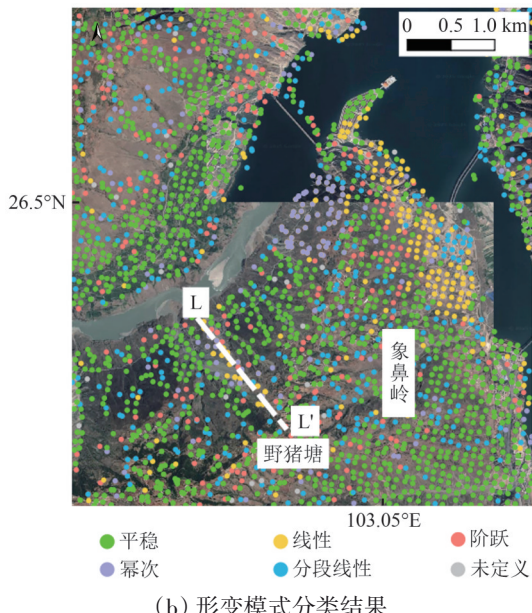


图 15 石门坎边坡沉降漏斗
Fig. 15 Subsidence funnel at the Shimenkan slope

按图 17 中的 LL' 剖面提取野猪塘边坡沉降漏斗的 InSAR 时间序列形变结果进行分析，图 17 中可公开获取的高精度底图数据本身存在部分缺失，但不影响关键区域结果对比分析。图 18 反映了距离金沙江岸从近到远的各个高程尺度上的形变速率和形变模式变化。可以观察到在距岸 0—200 m 时以幂次形变为主，因为边坡底部有上方滑动物的堆积，形变速率可能随时间变化；在距岸 200—1300 m 时以线性形变为主，表明该段可能是滑动的主要部分；在距岸 1300—1600 m 以分段线性形变为主，这可能是滑坡的发育部分。



(a) Map of the mean annual deformation velocity



(b) Map of the classified deformation patterns

图 17 野猪塘地区地表形变检测结果

Fig. 17 Monitoring results of surface deformation in the Yezhutang area

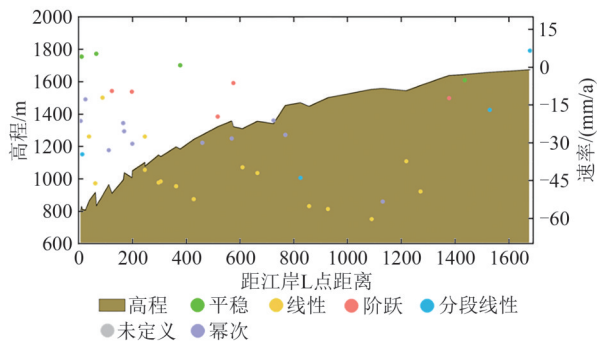



图 18 野猪塘斜坡形变类别、速率随坡面变化关系
Fig. 18 Variation of deformation type and rate with slope surface at the Yezhutang incline

将形变时间序列与降水、水位关联分析如图 19 所示。该区域包含 5 种基本形变的累计沉降量分层明显，线性形变模式的累计沉降量最大可达 190 mm，幂次形变次之，其他 3 种形变沉降量较小。这也正印证了图 18 中近岸的滑坡前缘由于滑物堆积产生幂次变化，形变不如滑坡体的线性形变变化大。在图 19 中平稳类形变曲线波动幅度小，表明其受降雨及库水位综合变化影响较弱；阶跃形变在 2023 年 8 月出现向下的约 20 mm 阶跃，此时正值库水位升高期，初步推测为 2023 年 6 月—8 月的集中降雨触发；分段线性类形变呈现阶段性变化趋势，与降水量、库水位的阶段性波动存在潜在对应关系，2022 年 8 月前一直处于速率较大的沉降中，2022 年 8 月—2023 年 5 月形变速率接近平缓，此阶段降水较少，初步推测第一段线性是由于降水导致的；幂次、线性类形变则通过趋势变化，反映出地表形变对降雨、库水位长期累积效应的响应模式。从整体来看，5 类形变通过不同曲线形态，展现了地表形变在月降水量、库水位综合影响下的差异化演化特征。


针对野猪塘的阶跃形变特征，在降雨与库水位耦合作用分析的基础上，其发生机制还需置于

水文地质背景中理解。该区域的岩层界面、节理裂隙或潜在的软弱夹层，为降水与库水的入渗、运移及地下水波动提供了优势通道和存储空间，同时可能构成了潜在的滑移边界。地下水波动在这一过程中扮演了关键角色，集中降雨与周期性库水位抬升共同导致了坡体内地下水位的显著上升，这种上升并非均匀静态的，而是会产生动态的孔隙水压力场；地下水位的抬升降低了滑带物质的有效应力，从而削弱其抗剪强度。地下水在复杂渗流路径中可能产生指向临空面的渗透压力，进一步推动坡体变形。2023 年 8 月观测到的显著阶跃，很可能是坡体内某关键区域的地下水位在持续补给后达到了一个临界高度，导致孔隙水压力激增，使得沿特定软弱面的抗滑力瞬间低于下滑力，从而触发了一次突发性滑移。此外，地下水位的波动与形变响应之间可能存在时间滞后效应，这取决于岩土体的渗透性与储水能力。

野猪塘的阶跃形变可解释为外部触发因素与内部控制因素在特定时空条件下耦合作用的结果，而这一机制推断也可通过相关研究进一步印证。例如，有学者 (Dun 等, 2025) 对白鹤滩库区蓄水前后滑坡分布进行调查，发现位于库区南部的野猪塘斜坡在蓄水前已出现变形迹象；水库蓄水后，由于水位波动影响，其变形进一步加剧，地表裂缝发育，并伴有岩块下落现象。另 Dai 等 (2023) 对库区大蓄水期间滑坡动态敏感性进行评价，指出当库水位大幅上升 150 m 时，野猪塘所在的库区南部高敏感性滑坡区域显著扩展，动态风险等级较高。这些实际监测与评估结果，均从不同侧面印证了野猪塘的阶跃式变形是在库水位变动、降雨等外部因素与坡体内部水文地质结构共同控制下，于特定时空条件下耦合触发的结果。



(a) 平稳形变类别与降水、库水位关系
(a) Relationship for the stable deformation pattern



(b) 阶跃形变类别与降水、库水位关系
(b) Relationship for the stepped deformation pattern

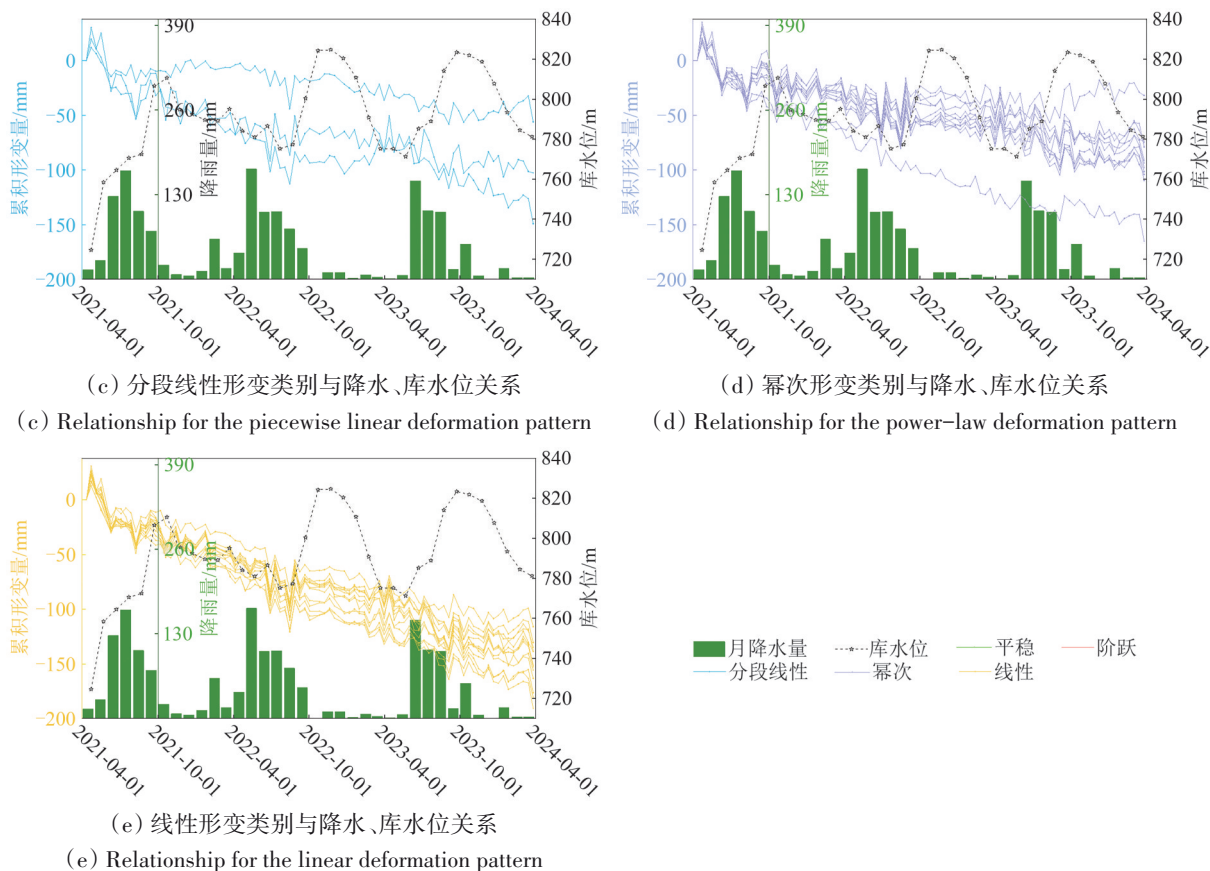


图 19 野猪塘斜坡形变、降水、库水位变化关系

Fig. 19 Relationships between slope deformation, precipitation, and reservoir water level at the Yezhutang slope

5 结论

本文利用SBAS-InSAR技术对白鹤滩库区近3年地表形变进行了系统监测，并提出了一种融合迁移学习与时间卷积网络(TCN)的时序形变模式分类方法，构建了包含平稳、线性、阶跃、分段线性、幂次及未定义6类的分类体系。通过模拟数据预训练与真实数据微调相结合的迁移学习策略，对库区9万余个形变点开展模式识别。结果表明：平稳类(45.6%)和分段线性类(24.4%)为主导模式，平稳类普遍表现出低速率和高相干性，不同坡向的类别分布总体一致。

典型滑坡区分析进一步揭示了水文与气候因子的驱动机制。石门坎滑坡呈现降雨与库水位共同作用下的幂次型演化特征，其抬升过程滞后于蓄水峰值约两个月，体现了库水调蓄的时滞效应；野猪塘坡体则表现出显著空间分异，2023年8月约20 mm的阶跃形变与库水位上升及集中降雨过程密切相关，分段线性形变速率在2022年8月前后发生明显转折，可能受降水波动影响，而幂次

与线性模式则反映出长期累积效应下的渐进响应。

综上，本研究突破了传统基于速率的单一监测框架，验证了迁移学习在提升InSAR时序分类精度与降低标注成本方面的有效性，提出的多维形变模式解析为库区地质灾害的动态风险评估与早期识别提供了一种新范式。

参考文献(References)

- Aguiar P, Cunha A, Bakon M, Ruiz-Armenteros A M and Sousa J J. 2021. Multivariate outlier detection in postprocessing of multi-temporal PS-InSAR results using deep learning. *Procedia Computer Science*, 181: 1146-1153 [DOI: 10.1016/j.procs.2021.01.326]
- Bai S J, Kolter J Z and Koltun V. 2018. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. *arXiv preprint arXiv: 1803.01271* [DOI: 10.48550/arXiv.1803.01271]
- Berardino P, Fornaro G, Lanari R and Sansosti E. 2002. A new algorithm for surface deformation monitoring based on small baseline differential SAR interferograms. *IEEE Transactions on Geoscience and Remote Sensing*, 40(11): 2375-2383 [DOI: 10.1109/TGRS.2002.803792]
- Berti M, Corsini A, Franceschini S and Iannacone J P. 2013. Automat-

- ed classification of Persistent Scatterers Interferometry time series. *Natural Hazards and Earth System Sciences*, 13(8): 1945-1958 [DOI: 10.5194/nhess-13-1945-2013]
- Cai J H, Zhang L, Dong J, Guo J C, Wang Y A and Liao M S. 2023. Automatic identification of active landslides over wide areas from time-series InSAR measurements using Faster RCNN. *International Journal of Applied Earth Observation and Geoinformation*, 124: 103516 [DOI: 10.1016/j.jag.2023.103516]
- Dai F C and Deng J H. 2020. Development characteristics of landslide hazards in Three-Rivers Basin of southeast Tibetan Plateau. *Advanced Engineering Sciences*, 52(5): 3-15 (戴福初, 邓建辉. 2020. 青藏高原东南三江流域滑坡灾害发育特征. *工程科学与技术*, 52(5): 3-15) [DOI: 10.15961/j.jsuese.202000651]
- Dai K R, Chen C, Shi X L, Wu M T, Feng W K, Xu Q, Liang R B, Zhuo G C and Li Z H. 2023. Dynamic landslides susceptibility evaluation in Baihetan Dam area during extensive impoundment by integrating geological model and InSAR observations. *International Journal of Applied Earth Observation and Geoinformation*, 116: 103157 [DOI: 10.1016/j.jag.2022.103157]
- Dun J, Feng W K, Yi X Y, Ding Z W, Zhuo G C, Dai K R and Wu M T. 2025. Detection and updation of landslide inventory before and during impoundment in the Baihetan reservoir area using multi-temporal InSAR datasets. *Scientific Reports*, 15(1): 9889 [DOI: 10.1038/s41598-025-94520-1]
- Dun J W, Feng W K, Yi X Y, Zhang G Q and Wu M T. 2023. Early InSAR identification of active landslide before impoundment in baihetan reservoir area—A case study of Hulukou town xiangbiling section. *Journal of Engineering Geology*, 31(2): 479-492 (顿佳伟, 冯文凯, 易小宇, 张国强, 吴明堂. 2023. 白鹤滩库区蓄水前活动性滑坡InSAR早期识别研究——以葫芦口镇至象鼻岭段为例. *工程地质学报*, 31(2): 479-492) [DOI: 10.13544/j.cnki.jeg.2022-0016]
- Festa D, Bonano M, Casagli N, Confuorto P, De Luca C, Del Soldato M, Lanari R, Lu P, Manunta M, Manzo M, Onorato G, Raspini F, Zinno I and Casu F. 2022. Nation-wide mapping and classification of ground deformation phenomena through the spatial clustering of P-SBAS InSAR measurements: Italy case study. *ISPRS Journal of Photogrammetry and Remote Sensing*, 189: 1-22 [DOI: 10.1016/j.isprsjprs.2022.04.022]
- Festa D, Novellino A, Hussain E, Bateson L, Casagli N, Confuorto P, Del Soldato M and Raspini F. 2023. Unsupervised detection of InSAR time series patterns based on PCA and K-means clustering. *International Journal of Applied Earth Observation and Geoinformation*, 118: 103276 [DOI: 10.1016/j.jag.2023.103276]
- Gagliardi V, Tosti F, Ciampoli L B, D'Amico F, Alani A M, Battagliere M L and Benedetto A. 2021. Monitoring of bridges by MT-InSAR and unsupervised machine learning clustering techniques//*Proceedings Volume 11863, Earth Resources and Environmental Remote Sensing/GIS Applications XII*. Online: SPIE: 132-140 [DOI: 10.1117/12.2597509]
- He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition//*Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE: 770-778 [DOI: 10.1109/CVPR.2016.90]
- He Y D and Zhao J B. 2019. Temporal convolutional networks for anomaly detection in time series. *Journal of Physics: Conference Series*, 1213(4): 042050 [DOI: 10.1088/1742-6596/1213/4/042050]
- Hinton G E and Salakhutdinov R R. 2006. Reducing the dimensionality of data with neural networks. *Science*, 313(5786): 504-507 [DOI: 10.1126/science.1127647]
- Ketelaar V B H. 2009. *Satellite Radar Interferometry: Subsidence Monitoring Techniques*. Dordrecht: Springer [DOI: 10.1007/978-1-4020-9428-6]
- Kulshrestha A, Chang L and Stein A. 2022. Use of LSTM for sinkhole-related anomaly detection and classification of InSAR deformation time series. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15: 4559-4570 [DOI: 10.1109/JSTARS.2022.3180994]
- Lanari R, Berardino P, Bonano M, Casu F, Manconi A, Manunta M, Manzo M, Pepe A, Pepe S, Sansosti E, Solaro G, Tizzani P and Zeni G. 2010. Surface displacements associated with the L'Aquila 2009 Mw 6.3 earthquake (central Italy): new evidence from SBAS-DInSAR time series analysis. *Geophysical Research Letters*, 37(20): L20309 [DOI: 10.1029/2010GL044780]
- Lattari F, Rucci A and Matteucci M. 2022. A deep learning approach for change points detection in InSAR time series. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5223916 [DOI: 10.1109/tgrs.2022.3155969]
- Li M H, Wu H F, Yang M S, Huang C and Tang B H. 2023. Trend classification of InSAR displacement time series using SAE - CNN. *Remote Sensing*, 16(1): 54 [DOI: 10.3390/rs16010054]
- Li M H, Zhang L, Shi X G, Liao M S and Yang M S. 2019. Monitoring active motion of the Guobu landslide near the Laxiwa Hydropower Station in China by time-series point-like targets offset tracking. *Remote Sensing of Environment*, 221: 80-93 [DOI: 10.1016/j.rse.2018.11.006]
- Li Y C and Ke Y H. 2015. Spatial-temporal heterogeneity of land subsidence evolution in Beijing based on InSAR and cluster analysis//*IET International Radar Conference 2015*. Hangzhou: IET: 1-5 [DOI: 10.1049/cp.2015.1423]
- Mirmazloumi S M, Gambin A F, Palamà R, Crosetto M, Wassie Y, Navarro J A, Barra A and Monserrat O. 2022a. Supervised machine learning algorithms for ground motion time series classification from InSAR data. *Remote Sensing*, 14(15): 3821 [DOI: 10.3390/rs14153821]
- Mirmazloumi S M, Wassie Y, Navarro J A, Palamà R, Krishnakumar V, Barra A, Cuevas-González M, Crosetto M and Monserrat O. 2022b. Classification of ground deformation using Sentinel-1 persistent scatterer interferometry time series. *GIScience and Remote Sensing*, 59(1): 374-392 [DOI: 10.1080/15481603.2022.2030535]
- Montgomery D R, Sullivan K and Greenberg H M. 1998. Regional test of a model for shallow landsliding. *Hydrological Processes*, 12(6): 943-955 [DOI: 10.1002/(SICI)1099-1085(199805)12:6<943::AID-HYP664>3.0.CO;2-Z]

- Salimans T and Kingma D P. 2016. Weight normalization: a simple re-parameterization to accelerate training of deep neural networks// Proceedings of the 30th International Conference on Neural Information Processing Systems. Barcelona: Curran Associates Inc.: 901-909
- Savage J C, Svarc J L and Prescott W H. 2003. Near-field postseismic deformation associated with the 1992 Landers and 1999 Hector Mine, California, earthquakes. *Journal of Geophysical Research: Solid Earth*, 108(B9): 2432 [DOI: 10.1029/2002jb002330]
- Savitzky A and Golay M J E. 1964. Smoothing and differentiation of data by simplified least squares procedures. *Analytical Chemistry*, 36(8): 1627-1639 [DOI: 10.1021/ac60214a047]
- Schlögl M, Widhalm B and Avian M. 2021. Comprehensive time-series analysis of bridge deformation using differential satellite radar interferometry based on Sentinel-1. *ISPRS Journal of Photogrammetry and Remote Sensing*, 172: 132-146 [DOI: 10.1016/j.isprsjprs.2020.12.001]
- Schneider P J and Soergel U. 2021. Clustering persistent scatterer points based on a hybrid distance metric//43rd DAGM German Conference on Pattern Recognition. Bonn: Springer: 621-632 [DOI: 10.1007/978-3-030-92659-5_40]
- Shi X G, Hu X, Sitar N, Kayen R, Qi S W, Jiang H J, Wang X D and Zhang L. 2021. Hydrological control shift from river level to rainfall in the reactivated Guobu slope besides the Laxiwa hydropower station in China. *Remote Sensing of Environment*, 265: 112664 [DOI: 10.1016/j.rse.2021.112664]
- Tan T Y. 2022. Early Identification and Monitoring of Reservoir Landslides based on InSAR Technology-Taking Baihe Tan Reservoir Area as an Example. Qinhuaungdao: Yanshan University (谭天宇. 2022. 基于InSAR技术的库区滑坡早期识别与监测——以白鹤滩库区为例. 秦皇岛: 燕山大学) [DOI: 10.27440/d.cnki.gysdu.2022.001980]
- Tiwari A and Shirzaei M. 2024. A novel machine learning and deep learning semi-supervised approach for automatic detection of InSAR-based deformation hotspots. *International Journal of Applied Earth Observation and Geoinformation*, 126: 103611 [DOI: 10.1016/j.jag.2023.103611]
- Van Den Oord A, Dieleman S, Zen H, Simonyan K, Vinyals O, Graves A, Kalchbrenner N, Senior A and Kavukcuoglu K. 2016. WaveNet: a generative model for raw audio. arXiv preprint arXiv: 1609.03499 [DOI: 10.48550/arXiv.1609.03499]
- Wang L Y, Deng K Z and Zheng M N. 2020. Research on ground deformation monitoring method in mining areas using the probability integral model fusion D-InSAR, sub-band InSAR and offset-tracking. *International Journal of Applied Earth Observation and Geoinformation*, 85: 101981 [DOI: 10.1016/j.jag.2019.101981]
- Wang Z L, Liao M S, Zhang L, Luo H and Dong J. 2019. Detecting and characterizing deformations of the left bank slope near the Jinping hydropower station with time series Sentinel-1 data. *Remote Sensing for Land and Resources*, 31(2): 204-209 (王振林, 廖明生, 张路, 罗恒, 董杰. 2019. 基于时序 Sentinel-1 数据的锦屏水电站左岸边坡形变探测与特征分析. *国土资源遥感*, 31(2): 204-209) [DOI: 10.6046/gtzyyg.2019.02.28]
- Wang Z Y, Xu J H, Shi X G, Wang J N, Zhang W and Zhang B. 2022. Landslide inventory in the downstream of the Niulanjiang River with ALOS PALSAR and Sentinel-1 datasets. *Remote Sensing*, 14(12): 2873 [DOI: 10.3390/rs14122873]
- Wu H F, Feng B, Li M H, Yang M S, Zhang Z and Tang B H. 2025. Self-supervised contrastive learning clustering method for InSAR time series deformation data. *Journal of Remote Sensing (in Chinese)*, 29(7): 2442-2456 (吴晗飞, 俸彬, 李梦华, 杨梦诗, 张震, 唐伯惠. 2025. InSAR 时序形变数据的自监督对比学习聚类方法. *遥感学报*, 29(7): 2442-2456) [DOI: 10.11834/jrs.20254393]
- Wu M T, Fang Y F, Zhuo G C, Yi X Y, Dai K R, Chen J Q and Feng W K. 2023. Comprehensive remote sensing identification of potential geohazards in Sanjiacun Reservoir Bank of Baihetan. *Journal of Kunming University of Science and Technology (Natural Science)*, 48(3): 53-61 (吴明堂, 房云峰, 卓冠晨, 易小宇, 戴可人, 陈建强, 冯文凯. 2023. 白鹤滩库区三家村库岸地质灾害隐患综合遥感识别. *昆明理工大学学报(自然科学版)*, 48(3): 53-61) [DOI: 10.16112/j.cnki.53-1223/n.2023.03.122]
- Xie M W, Huang J H, Wang Z F and Liu X Y. 2012. Study on monitoring of rock and soil change in a large area. *Science of Soil and Water Conservation*, 10(1): 59-64 (谢谟文, 黄洁慧, 王增幅, 刘翔宇. 2012. 广域岩土体变化监测研究. *中国水土保持科学*, 10(1): 59-64) [DOI: 10.3969/j.issn.1672-3007.2012.01.010]
- Yang M S, Li M H, Huang C, Zhang R S and Liu R. 2024. Exploring the InSAR deformation series using unsupervised learning in a built environment. *Remote Sensing*, 16(8): 1375 [DOI: 10.3390/rs16081375]
- Yang M S, Li S W and Yu H. 2025. A transfer learning approach for deformation pattern recognition in InSAR time series. *IEEE Transactions on Geoscience and Remote Sensing*, 63: 5205616 [DOI: 10.1109/TGRS.2025.3543580]
- Yang Z R, Xi W F, Yang Z Q, Shi Z T, Huang G C, Guo J Q and Yang D Q. 2023. Time-Lag response of landslide to reservoir water level fluctuations during the storage period: a case study of Baihetan reservoir. *Water*, 15(15): 2732 [DOI: 10.3390/w15152732]
- Zhang D X, Wang G H, Yang T J, Zhang M C, Chen S H and Zhang F Y. 2013. Satellite remote sensing-based detection of the deformation of a reservoir bank slope in Laxiwa Hydropower Station, China. *Landslides*, 10(2): 231-238 [DOI: 10.1007/s10346-012-0378-9]
- Zhang R, Zhao X, Dong X J, Dai K R, Deng J, Zhuo G C, Yu B, Wu T T and Xiang J M. 2024. Potential landslide identification in baihetan reservoir area based on C-/L-band synthetic aperture radar data and applicability analysis. *Remote Sensing*, 16(9): 1591 [DOI: 10.3390/rs16091591]
- Zhou Z K. 2023. Study on the Deformation Failure Law, Development Mechanism and Stability of Bank Slope at the Initial Stage of Impoundment of Baihetan Reservoir in Jinsha River. Beijing: China University of Geosciences (Beijing) (周振凯. 2023. 金沙江白鹤滩水库蓄水初期岸坡变形破坏规律、机制与稳定性研究. 北京: 中国地质大学(北京)) [DOI: 10.27493/d.cnki.gzdz.2023.000066]

Deformation pattern recognition in the Baihetan reservoir area using transfer learning–temporal convolutional networks and multi–temporal InSAR

YANG Mengshi^{1,2}, YIN Kang^{1,2}, LI Saiwei^{1,2}, LI Menghua³, ZHAO Zhifang^{1,2}, HUANG Cheng^{3,4,5}

1. School of Earth Sciences, Yunnan University, Kunming 650500, China;

2. Yunnan International Joint Laboratory of China-Laos-Bangladesh-Myanmar Natural Resources Remote Sensing Monitoring, Kunming 650500, China;

3. Faculty of Land Resources Engineering, Kunming University of Science and Technology, Kunming 650093, China;

4. Yunnan Key Laboratory of Geohazard Forecast and Geological Restoration in Plateau Mountainous Area, Kunming 650216, China;

5. Yunnan Institute of Geological Environment Monitoring, Kunming 650216, China

Abstract: The Baihetan Hydropower Station, as a national mega-project, is located in a geologically complex reservoir area where slope stability monitoring after impoundment is crucial. Traditional InSAR techniques mainly rely on deformation rate indicators and thus face limitations in capturing the full temporal evolution of slope deformation. This study aims to overcome these limitations by developing an intelligent framework for time-series deformation pattern recognition to improve hazard identification and risk assessment in the reservoir area.

Sentinel-1 SAR data spanning April 2021 to March 2024 were processed using the SBAS-InSAR technique to retrieve the reservoir-wide deformation field. A transfer learning-enhanced deep learning architecture was proposed, in which synthetic samples were used for pretraining and real samples for fine-tuning. Based on this framework, a six-class taxonomy of deformation patterns—stable, linear, step-like, piecewise linear, power-law, and undefined—was established. A Temporal Convolutional Network (TCN) was then applied to classify deformation modes across the Baihetan reservoir.

(1) Among 97377 deformation points, the dominant patterns were stable (45.6%) and piecewise linear (24.4%), with stable deformation strongly associated with low velocity and high coherence. (2) The Shimenkan landslide exhibited a delayed uplift response regulated by reservoir water level, lagging peak impoundment by about two months. (3) The Yezhutang slope showed rainfall-triggered step-like deformation and a piecewise linear response under coupled water level-precipitation forcing.

The findings demonstrate that transfer learning effectively reduces labeling costs, while multidimensional deformation pattern analysis provides a new paradigm for dynamic risk assessment of reservoir-induced geohazards.

Key words: time-series deformation classification, TCN, transfer learning, Baihetan reservoir area, SBAS-InSAR, deep learning, reservoir bank landslide, geohazard monitoring

Supported by National Natural Science Foundation of China (No. 42474040, 42404036); The Yunnan Provincial Basic Research Program (No. 202301AT070145); Yunnan Province Xingdian Talent Program. Data Source: the Sentinel-1/2 Dataset under the Sino-EU Dragon Project (No. 95473)