

基于多源数据融合的 CNN-LSTM 滑坡位移预测模型

王枰峻, 郭洋洋, 郝琦, 高煜桂, 邱屹
天津铁道职业技术学院, 天津 300240
DOI: 10.61369/TACS.2026060032

摘 要 : 针对目前滑坡位移预测模型存在数据单一、鲁棒性不高不足的问题, 提出一种基于多源数据和 CNN-LSTM 滑坡位移预测方法。首先以华北地区某铁路沿线滑坡作为研究区, 并获取 2018—2023 年 1 月 Sentinel-1 InSAR(月度)、GNSS 位移(1h)、降雨(1h)和孔压(1h)数据进行监测, 采用线性插值的方式将其统一到 1h 时间步上, 进一步进行 Z-score 标准化对齐得到具有全部特征的协同输入序列。其次建立 CNN-LSTM 时空耦合模型: 利用 1D-CNN 层从多源监测数据中学习空间信息, 用 LSTM 学习滑坡演化的时序相关性, 上述两部分特征在输出层融合来预测下一时刻的位移, 并且利用 Huber 损失 ($\delta = 1.0$) 来代替 MSE 进行训练, 从而增加对于离群点或者突变值的鲁棒性。使用其中 70% 的数据作为训练集, 即大约 7000 个样本; 将剩下的 30% 用作测试集, 即大约 3000 个样本, 分别比较 SVR 和单独 LSTM 的结果。最终发现本文方法得到的 MAE 只有 1.87 mm, RMSE = 2.34 mm, $R^2 = 0.968$, 均高于 SVR 和 LSTM 模型(差异达显著性水平, $p < 0.05$)。本文方法结构简单、易实现, 可用于滑坡预警可靠的预测模型。

关 键 词 : 滑坡预测; CNN-LSTM; 多源数据融合; Huber 损失; 时间序列

A CNN-LSTM Landslide Displacement Prediction Model Based on Multi-Source Data Fusion

Wang Pingjun, Guo Yangyang, Hao Qi, Gao Yugui, Qiu Yi
Tianjin Railway Technical and Vocational College, Tianjin 300240

Abstract : To address the limitations of existing landslide displacement prediction models, such as limited data sources and insufficient robustness, this paper proposes a novel approach based on multi-source data fusion and a CNN-LSTM architecture. First, a landslide along a railway in North China was selected as the study area. Monitoring data from January 2018 to January 2023 were acquired, including Sentinel-1 InSAR (monthly), GNSS displacement (hourly), rainfall (hourly), and pore-water pressure (hourly). These datasets were resampled to an hourly temporal resolution via linear interpolation and subsequently aligned using Z-score standardization to generate a unified input sequence containing all features. Second, a spatiotemporal coupled CNN-LSTM model was constructed. A 1D-CNN layer was employed to extract spatial features from the multi-source monitoring data, while an LSTM network captured the temporal evolution patterns of the landslide. The features derived from these two components were fused at the output layer to predict displacement for the next time step. Furthermore, the Huber loss function ($\delta = 1.0$) was adopted in place of Mean Squared Error (MSE) during training to enhance the model's robustness against outliers and abrupt changes. The dataset was partitioned into a training set (70%, approximately 7,000 samples) and a test set (30%, approximately 3,000 samples). The performance of the proposed method was compared with that of Support Vector Regression (SVR) and a standalone LSTM model. Results indicate that the proposed method achieved a Mean Absolute Error (MAE) of only 1.87 mm, a Root Mean Square Error (RMSE) of 2.34 mm, and an R^2 of 0.968. These metrics significantly outperformed those of the SVR and LSTM models ($p < 0.05$). The proposed method is structurally simple, easy to implement, and provides a reliable predictive tool for landslide early warning systems.

Keywords : landslide prediction; CNN-LSTM; multi-source data fusion; Huber loss; time series

引言

滑坡位移预测作为滑坡灾害预警的重要部分, 近年来基于数据的研究较多。但是这些工作大都存在着数据来源单一、没有很好地挖掘出数据中的时空特性以及容易受到一些离群值干扰等问题。本文针对上述问题有以下几点改进:

通讯作者: 郭洋洋 (1992.02—), 女, 天津津南, 硕士, 天津铁道职业技术学院助教。

多源异构数据融合：本文综合 Sentinel-1 InSAR (月)、GNSS 位移 (1h) 和雨量 (1h) 及孔压 (1h)，利用时间插值方式将上述数据转化为 1h 序列进行输入；相对于单数据研究而言，多源数据能够获得更为完整的滑坡演化信息。

CNN-LSTM 时空耦合模型：本文建立“空间特征提取 - 时间序列建模 - 特征融合”的分阶段模型：1D-CNN 层用来提取多源监测数据的局部空间特征，LSTM 层用来学习滑坡位移随时间的动态规律，并在最后一层进行特征级融合输出预测结果；相比于单纯的 LSTM 或者简单的串起来的方法，该模型可以更好地描述滑坡的非线性演变规律。

Huber loss 提高鲁棒性：考虑到滑坡监测数据中存在较多突变异常（例如因暴雨突增引起的位移跳跃），在训练损失函数中加入 Huber 损失 ($\delta=1.0$)。Huber Loss 结合 L2 和 L1 的优点，对异常值不敏感，在一定程度上能提升模型对于极端情况下的稳健预测性能。

一、方法

（一）数据来源与预处理

本文数据来自华北地区某铁路沿线滑坡监测项目，时间为 2018 年 1 月至 2023 年 12 月。数据包含 Sentinel-1 InSAR 形变序列（采样间隔为 30d，6 年的数据共有 72 张卫星图像）、地面 GNSS 连续位移（5 个监测点，间隔为 1h），以及现场雨量计和孔压计数据（分辨率为 1h）。总样点数约 10000 个。

预处理流程如下：首先，对 InSAR、GNSS、降雨、孔压等不同频率的数据进行线性插值时间对齐，统一到 1h 一时刻的时间序列（插值得到约 10000 个时刻点）。然后，对缺失数据（如 InSAR 数据丢帧或 GNSS 短期缺失）采用局部线性插值和邻近值填充。接着，对每种数据特征进行 Z-score 标准化，消除量纲差异并加快模型收敛。最后，使用滑动窗口技术构建样本：设定窗口长度 $T=72h$ 、步长 $S=1h$ ，则每个训练样本包含过去 72h 的多源特征序列，标签为窗口末端的位移值。数据集中按时间顺序将前 70%（约 7000 个样本）用作训练集，后 30%（约 3000 个样本）用作测试集，以避免未来信息泄露。

（二）模型结构及 Huber 损失

本文设计了 CNN-LSTM 复合预测模型（见图 1）。首先，1D-CNN 层对输入的多通道时序数据进行卷积运算，以提取滑坡的局部特征，使用 32 个卷积核（尺寸为 3），卷积后接 ReLU 激活和池化层。随后，将 CNN 提取的特征序列输入双层 LSTM（隐藏单元数 128 和 64），用于学习滑坡位移变化的长短期依赖^[5]。最后，LSTM 输出通过全连接层映射为下一时刻的位移预测值。该模型结构既保留了足够的建模能力，又避免了过度复杂度。




图 1 CNN-LSTM 模型结构示意图

损失函数方面，使用 Huber 损失增强鲁棒性^[7]。Huber 损失

定义为当误差时采用二次损失，当时采用线性损失^[8]，以减小异常点的影响。本文取 $\delta=1.0$ 。模型训练使用 Adam 优化器（学习率 1×10^{-3} ），批量大小为 32，迭代 100 轮。示例超参数配置为：学习率=0.001、batch=32、epochs=100、Huber 阈值 $\delta=1.0$ 。

二、实验

（一）数据集描述

本文选取华北地区某铁路沿线滑坡监测数据作为案例进行分析。滑坡监测时间为 2018—2023 年 12 月，时间跨度 6 年；InSAR 数据为 Sentinel-1 卫星水平 / 垂直极化干涉测量数据 (1 幅 / 月)，共 72 幅；GNSS 监测点 5 个，1h 采样；现场雨量计和孔压计数据采样频率均为 1h，总计约 10000 个时间点。将所有原始数据处理成相同的 1h 时间序列，作为模型的输入。

表 1 数据处理步骤

步骤	说明
时间对齐	将 InSAR（月）、GNSS（1h）、降雨（1h）、孔压（1h）数据通过线性插值得到 1h 时间序列，共计约 10000 个时刻点。
缺失值处理	对于插值之后依然为空的数值采用线性插值或者最近邻平均填补，实现数据不缺失。
特征标准化	对所有输入特征（位移、降雨、孔压等）进行 Z-score 标准化，消除量纲差异 ^[9] 。
时序窗口生成	以 $T=72h$ 为一个输入窗口（步长 $S=1h$ ），构建训练 / 测试样本。
数据集划分	按时间顺序划分：前 70%（约 7000 个样本）为训练集，后 30%（约 3000 个样本）为测试集。

（二）对比实验设置

为验证模型性能，设置以下对比试验^[10]：
支持向量回归（SVR）：采用径向基核（RBF）SVR，使用相同训练数据拟合滑坡位移。

SVM：径向基核（RBF）支持向量机 SVM，利用相同的训练样本对滑坡位移进行拟合。

Single Layer LSTM：结构同本文模型，但去掉 CNN 特征提取，只用双层 LSTM (128 / 64 单元) 直接对齐序列输入预测。

本文模型（CNN-LSTM）：包含 1D-CNN 提取和 LSTM 时序建模。

所有模型均使用相同训练 / 测试划分和输入特征进行训练，评价指标包括 MAE、RMSE 和。

(三) 消融实验设置

为评估各模块效果，设计以下消融方案：

- 1. 无 CNN 模块：直接将归一化后原始时序数据输入 LSTM（使用 Huber 损失）。
- 2. 无 Huber 损失：模型完整（含 CNN），但损失函数使用 MSE。
- 3. 完整模型：同时使用 CNN 和 Huber 损失。

比较各配置下的 MAE、RMSE 结果，以验证 CNN 和 Huber 损失的贡献。

为了综合评估模型效果，本文选用平均绝对误差（MAE）、均方根误差（RMSE）和决定系数（ R^2 ）作为评价指标。其中 MAE 和 RMSE 表示预测误差大小，表示模型拟合优度。

三、结果

对比实验的结果如表2所示。相比于 SVR 和 LSTM 基准模型来说，本文算法在 MAE 和 RMSE 上都有了显著的下降，在 R^2 上有了明显的提升：

表2 模型预测性能对比

方法	MAE (mm)	RMSE (mm)	R^2
SVR	3.12	4.05	0.850
LSTM	2.75	3.32	0.900
本文方法	1.87	2.34	0.968

同时，将 SVR、LSTM 和本文的方法结果做成对样本 t 检验（显著性水平 $\alpha = 0.05$ ），发现本文的方法相对于基线模型而言，其降低误差的效果是显著的，这说明多源数据的引入以及 CNN-LSTM 的结构对于提高滑坡位移预测精度是有益处的。

四、讨论

本文方法从工程角度来看是可行的：由于 CNN-LSTM 模型结构简单（只有少量卷积和 LSTM 层），整体参数不多，在一般硬件条件下可以较快地进行训练并在线运行；采用 Huber 损失使得网络对异常值的预测更加稳定。当然也有一定的不足之处：本文使用单个滑坡样本进行训练，模型尚未经过严格的区域泛化检验；基于数据的模型难以对滑坡产生做出物理解释。后续可通过增加监测点数量并考虑地质资料，或者使用注意力网络提高模型的泛化性和可解释性。

五、结论

本文建立一种基于多源数据融合的 CNN-LSTM 滑坡位移预测模型并引入 Huber 损失提高其鲁棒性。以华北地区某铁路沿线一滑坡为案例进行试验分析发现：本文方法 MAE 只有1.87mm，RMSE 为2.34mm， R^2 达到0.968，均优于传统的 SVR 和单 LSTM 方法。本文建立的模型结构简单，在实际工程中容易实现，并可以用于滑坡预警系统的可靠预测。下一步将考虑扩展至其他地区并引入物理模型来提高模型的预测能力和解释力。

参考文献

[1] 刘航源, 陈伟涛, 李远耀, 等. 基于 EEMD-CNN-LSTM 的新型综合模型在滑坡位移预测中的应用 [J]. 地质力学学报, 2024, 30(4): 633 - 646.

[2] Meng S Q, Shi Z M, Peng M, et al. Landslide displacement prediction with step-like curve based on CNN-BiGRU-Attention hybrid model[J]. Engineering Applications of Artificial Intelligence, 2024, 108078.

[3] Nan X C, Liu J F, Zhang Y X, et al. Dynamic prediction of landslide displacement based on multi-source time series[J]. Pearl River, 2023, 44(4): 54 - 62.

[4] 田斌, 葛友诚, 梁冰, 等. 基于 CNN-LSTM 混合模型的工频磁扰动信号预测 [J]. 自动化与仪表, 2021(011):036.

[5] 胡佳超. 基于 CNN-LSTM-Attention 的滑坡深部位移预测研究 [D]. 东华理工大学, 2025.DOI: 10.27145/d.cnki.ghddc.2025.000235.

[6] 陈攀. 基于 CNN-LSTM 神经网络的软土地质条件下的路基沉降预测研究 [J]. 交通世界, 2025, (10): 81-83+87.DOI: 10.16248/j.cnki.11-3723/u.2025.10.047.

[7] 李梅, 宁德军, 郭佳程. 基于注意力机制的 CNN-LSTM 模型及其应用 [J]. 计算机工程与应用, 2019, 55(13): 20-27.

[8] 王朝阳, 李丽敏, 温宗周, 等. 基于时间序列和 CNN-LSTM 的滑坡位移动态预测 [J]. 国外电子测量技术, 2022, 41(03): 1-8.DOI: 10.19652/j.cnki.femt.2103321.

[9] Hossein H, Asghar A A, Mahdi P, et al. Landslide susceptibility mapping using deep learning models in Ardabil province, Iran[J]. Stochastic Environmental Research and Risk Assessment, 2022, 36(12): 4287-4310.DOI: 10.1007/S00477-022-02263-6.

[10] 王晶晶. 基于深度学习的泸定县滑坡隐患识别与易发性评估方法研究 [D]. 中国地质大学, 2023.DOI: 10.27492/d.cnki.gzdz.2023.000233.