

# 面向滑坡裂缝计时序数据异常检测的 预警方法研究

曾振威<sup>1,2</sup>, 欧阳淑冰<sup>1,2</sup>, 李代超<sup>1,2</sup>, 刘闽江<sup>3</sup>, 李元<sup>4</sup>

[1. 福州大学 数字中国研究院(福建), 福建 福州 350108;

2. 福州大学 空间数据挖掘与信息共享教育部重点实验室, 福建 福州 350108;

3. 福建省地质测绘院, 福建 福州 350108; 4. 福建省大数据集团, 福建 福州 350108]

**摘要:** [目的] 针对监测预警工作误报漏报问题进行研究, 基于历史预警经验与传感器监测数据构建异常检测模型, 为降低地质灾害预警误报风险提供科学支持。[方法] 以滑坡裂缝计时序数据为例, 提出一种融合不规则时间特征编码和多层感知机混合模块(MLP-Mixer)的异常检测模型, 并通过多任务学习和知识蒸馏机制, 将专家研判标签引导的异常检测任务知识提炼到异常前兆感知任务中, 从而充分利用历史预警经验和不规则时间序列数据隐含的灾害动态信息提升异常识别精度。[结果] 试验结果表明, 该方法在给定数据集上优于基线模型, 在精确率(80.36%)、召回率(95.41%)、 $F_1$ 分数(87.24%)及 ROC 曲线下面积(87.20%)方面取得最优性能。[结论] 模型在召回率和精确率上表现的综合优势有效降低了漏报风险, 可用于自动过滤误报预警信号, 从而提升预警效率和可靠性。

**关键词:** 滑坡预警; 不规则时间序列; 误报预警过滤; 异常检测; 多任务学习; 知识蒸馏

文献标识码: B

文章编号: 1000-288X(2026)01-0228-08

中图分类号: TP183

**文献参数:** 曾振威, 欧阳淑冰, 李代超, 等. 面向滑坡裂缝计时序数据异常检测的预警方法研究[J]. 水土保持通报, 2026, 46(1): 228-235. Zeng Zhenwei, Ouyang Shubing, Li Daichao, et al. Early warning methods for anomaly detection in time-series data of landslide crack meters [J]. Bulletin of Soil and Water Conservation, 2026, 46(1): 228-235.

DOI: 10.13961/j.cnki.stbctb.2026.01.029

CSTR: 32312.14.stbctb.2026.01.029

## Early warning methods for anomaly detection in time-series data of landslide crack meters

Zeng Zhenwei<sup>1,2</sup>, Ouyang Shubing<sup>1,2</sup>, Li Daichao<sup>1,2</sup>, Liu Minjiang<sup>3</sup>, Li Yuan<sup>4</sup>

[1. The Academy of Digital China (Fujian), Fuzhou University, Fuzhou, Fujian 350108,

China; 2. Key Laboratory of Spatial Data Mining & Information Sharing of Ministry of Education,

Fuzhou University, Fuzhou, Fujian 350108, China; 3. Fujian Geological Surveying and Mapping

Institute, Fuzhou, Fujian 350108, China; 4. Fujian Big Data Group Co., Ltd., Fuzhou, Fujian 350108, China]

**Abstract:** [Objective] An anomaly detection model was constructed based on historical warning experience and sensor monitoring data to address the issues of false alarms and omissions in monitoring and early warning operations, in order to provide a scientific support for reducing the risk of false alarms in geological disaster early warnings. [Methods] Using time-series data from landslide crack meters as an example, an anomaly detection model integrating irregular time feature encoding with a multilayer perceptron hybrid module (MLP-Mixer) was proposed. Through multi-task learning and knowledge distillation mechanisms, knowledge from anomaly detection tasks guided by expert judgment labels was distilled into precursor perception tasks, thereby fully utilizing historical early warning experience and the implicit disaster dynamics information in irregular time-series

收稿日期: 2025-09-11

修回日期: 2025-10-24

采用日期: 2025-10-24

资助项目: 国家重点研发计划项目“群智协同时空知识图谱与知识服务”(2022YFB3904205); 国家自然科学基金项目“顾及时空特征的水稻施肥知识图谱构建与应用”(42301523)。

第一作者: 曾振威(2002—), 男(汉族), 江西省赣州市人, 硕士研究生, 研究方向为地理信息系统、地质灾害。Email: 235520003@fzu.edu.cn。

通信作者: 李代超(1989—), 女(汉族), 河南省信阳市人, 博士, 副研究员, 主要从事时空数据挖掘、时空知识图谱、时空数据可视化与可视分析方面的研究。Email: lide@fzu.edu.cn。

data to improve anomaly detection accuracy. [Results] The experimental results showed that the proposed method outperformed baseline models on the given dataset, achieving optimal performance in precision (80.36%), recall (95.41%),  $F_1$  score (87.24%), and area under the ROC curve (87.20%). [Conclusion] The model's comprehensive advantages in recall and precision effectively reduce the risk of missed alarms and can be used to automatically filter false alarm signals, thereby improving the efficiency and reliability of early warning.

**Keywords:** landslide early warning; irregular time series; false alarm filtering; anomaly detection; multi-task learning; knowledge distillation

近年来,随着物联网、云计算和人工智能等新技术的不断发展,专业监测预警已成为科学防范滑坡等地质灾害的重要技术手段。为提升地质灾害风险防控水平,减轻灾害损失,《全国地质灾害防治“十四五”规划》提出加强普适型地质灾害监测点网络建设,完善专业监测预警体系,扩大监测预警覆盖面,提升动态响应能力<sup>[1]</sup>。然而,实践表明,当前监测预警工作误报率较高。此外,当前滑坡监测预警领域研究通常忽视了传感器监测数据因非等间隔采样而呈现的不规则特性,具体表现为同一传感器监测数据采样间隔不一致,不同传感器采样频率不一致,其往往隐含滑坡动态信息<sup>[2]</sup>。同时未能充分利用历史专家经验且难以预测小型突发性滑坡,限制了滑坡预警的准确性。因此需要建立适应不规则特性并集成专家经验的机制以准确识别预警信号异常模式,从而有效降低误报率。

时间序列异常检测(time-series anomaly detection, TSAD)是识别序列数据中异常模式的重要方法,广泛应用于医疗风险<sup>[3]</sup>、地理信息等<sup>[4]</sup>领域。此外,异常前兆检测旨在检测预示异常事件的前兆模式。例如,在地球物理学领域,异常前兆检测可以检测可能预示地震的异常活动<sup>[5]</sup>。因此,在滑坡监测预警领域,TSAD可以通过异常识别与异常前兆感知为降低误报率提供新思路。

当前时间序列异常检测方法主要包括基于统计学的方法<sup>[6]</sup>、基于传统机器学习的方法<sup>[7]</sup>和基于深度学习的方法<sup>[8]</sup>。基于统计学的方法依赖严格的统计分布假设,难以适应复杂时间序列的动态特征;基于传统机器学习的方法受限于人工特征工程,在高维或非线性数据上的表达能力不足。近年来,深度学习因其非线性建模能力成为研究热点,涌现出一系列基于长短期时间记忆网络(LSTM)、生成模型和Transformer等模型的时间序列异常检测研究,显著提升了复杂时间序列的异常检测性能。例如, Malhotra等<sup>[9]</sup>通过堆叠LSTM网络建模时间序列的正常行为,展现出较强的鲁棒性;Wu Haixu等<sup>[10]</sup>提出具有自相关机制的分解架构Autoformer,通过渐进式分解与子序列依赖关系建模,最初为时间序列预测

设计,同时在异常检测等其他任务中也表现出较好性能。此外,Wu Haixu等<sup>[11]</sup>结合卷积神经网络和快速傅里叶变换,提出通用架构TimesNet,在二维空间映射时间序列数据中的复杂长期依赖关系,在多个基准数据集和任务上达到最优性能。近年来,Hu Rongyao等<sup>[12]</sup>提出基于扩散模型的TimeADDM,首次在多变量时间序列场景中系统化引入扩散式学习,通过在表征空间执行扩散—反演过程以提升异常可分性。Zhong Zhijie等<sup>[13]</sup>提出基于相异性度量的SimAD,通过引入面向长窗口的特征提取,EmbedPatch编码与对比融合模块,强化正常与异常分布差异,在多数数据集上取得了领先结果。

在滑坡监测预警领域,已有研究尝试将时间序列异常检测范式应用于滑坡监测预警,但仍存在通用性制约。例如,张磊等<sup>[14]</sup>提出基于区间预测的时间序列数据实时异常检测方法,利用模型预测值的置信区间为滑坡不同阶段设置异常阈值,然而阈值的建立需要依赖大量历史数据及专家对地质特征的经验判断。郭翊蓁等<sup>[15]</sup>提出一种基于LSTMAD算法与插值法的滑坡监测数据预处理方法,提升了数据缺失场景下的检测准确性,但该方法对特定传感器数据格式依赖性较强,难以推广至不同地质条件的滑坡场景。Wang W等<sup>[16]</sup>将SAR时间序列与深度学习结合以估计滑坡发生时刻,采用“突变检测+LSTM预测”的两阶段策略在区域尺度自动定位失稳时间,但对遥感数据质量与时空覆盖度要求较强。这些方法为滑坡监测异常识别提供了有益探索,但仍存在通用性不足,对专家经验依赖性较强等问题,同时以上方法都忽略了现实场景下时间序列数据的不规则特性。

因此,本研究针对滑坡监测的不规则时间序列数据将问题定义为:①如何从大规模的具有不规则特性的预警信号中识别出有效预警信号,以提升预警效率;②预测当前滑坡监测数据的趋势是否即将发生异常。针对以上问题,本研究以福建省为研究区,基于地质灾害监测预警平台积累的裂缝计监测数据以及历史预警记录,构建异常检测数据集。综合考虑现实场景中传感器监测数据的不规则性与不

同原因引发的预警数据模式,融合不规则时间特征编码方法与多层感知机混合模块(MLP-Mixer),设计一种面向不规则时间序列的异常检测模型,挖掘预警信号中隐含的特征模式。该异常检测框架由两个训练任务组成:①异常检测任务通过分类器识别异常信号;②异常前兆感知任务通过建模历史滑坡监测数据的趋势变化,增强模型对潜在异常的前兆识别能力。它们在统一的多任务学习架构下进行训练,引入知识蒸馏机制并部分共享可训练参数,实现任务间的信息交互与协同优化,从而有效过滤误报预警信号,提升裂缝计传感器预警效率。

本文的主要贡献在于:①提出不规则嵌入模块,用于模型学习滑坡裂缝计时序数据的不规则模式,提取滑坡隐含动态信息。②引入适用多层感知器混合网络的编码器设计,模型可以充分捕捉数据的不规则性、时间依赖性和维度相关性。③设计多任务学习框架,并引入知识蒸馏机制。将专家研判标签引导的异常检测任务知识蒸馏到异常前兆感知任务中,显著提升了模型整体性能。

## 1 研究区概况与数据来源

### 1.1 研究区概况

研究区福建省位于中国东南沿海,地质环境条件脆弱,极易发生滑坡等地质灾害,通常表现出隐蔽性、突发性强,发生频率高,单次灾情规模较小但群发性显著等特点<sup>[17]</sup>,严重威胁当地人民生命财产安全和基础设施稳定。

### 1.2 数据来源

本研究使用的数据来源于福建省地质灾害监测预警平台。考虑设备数量、覆盖范围及历史预警案例的积累情况,选取裂缝计历史预警信号作为研究对象,以其时间序列数据作为分析对象。数据集共采集3586个样本。样本取自福建省地质灾害监测预警平台2021年5月1日至2025年3月1日积累的所有裂缝计预警记录,其监测预警范围覆盖整个福建省区域。异常样本标记为负类(标签为“0”),而经专业人员分析监测数据特征与现场核实情况后研判为有效预警的样本则标记为正类(标签为“1”)。其中,负类样本是来自平台中经现场调查后确定误报原因的误报预警样本,主要由阈值模型准确度不高,泛化能力不足引起,表现出显著差异于正样本的数据模式<sup>[18-19]</sup>。

## 2 研究方法

本研究提出的异常检测框架采用通用的多任务学习架构,融合不规则时间特征编码与多层感知机

模块(MLP-Mixer)的神经网络结构,并经过了多任务训练和知识蒸馏机制进行优化。模型整体架构如图1所示。该框架工作流程为:①采用滑动窗口方法预处理裂缝计原始监测数据的粗差;②通过不规则时间特征编码提取时间序列的非等间隔不规则特性,并利用MLP-Mixer模块学习数据的深层特征表示;③异常检测任务层接收时间步*i*之前的监测数据 $X_i$ 与时间步*i*之后的监测数据 $X_{i+1}$ 得到输出 $y^a_i$ 和 $y^a_{i+1}$ ,异常前兆感知任务层基于输入 $X_i$ 生成预测输出 $y^p_{i+1}$ ;④通过知识蒸馏机制,协同优化模型训练过程,最终输出异常分数,并结合训练过程学习得到的最佳异常得分阈值判别预警信号的有效性。

### 2.1 问题描述

滑坡预警信号的判别不仅依赖于单一时间点的观测值,更需结合其前后序列变化特征进行整体分析,因此样本构建必须充分考虑时间序列的上下文信息。根据已有研究结果,福建省地质灾害主要由降雨诱发,降雨影响期为72 h内<sup>[20]</sup>。据此,本研究将每个样本的时间跨度设定为72 h,使用时间长度固定的窗口剪取预警时刻前的72 h长度连续监测数据,用以捕捉序列演化模式。

为增强样本的表达能力,在本研究预处理后的裂缝位移监测数据基础上,计算其变形速率以扩展原始特征的表达维度。此外,保留时间信息作为模型输入。为显式表示时间信息与采样结构,并进行数据预处理阶段的异常值剔除操作,在保留原始观测时间点的基础上,进行重采样获得扩充的未观测时间点,并引入掩码机制:原始时间点的掩码值为1,未观测时间点的掩码值为0。最终得到输入序列表示为

$$X = (x_1, x_2, \dots, x_t) \quad (x_t \in \mathbb{R}^{L \times C})$$

式中: $L$ 表示序列长度; $C$ 为特征维度;每个时间观测点元组表示为 $x_t = [\text{value}(\text{取值}), \text{time}(\text{时间}), \text{mask}(\text{掩码})]$ 。

### 2.2 数据预处理

裂缝计实时监测滑坡变形过程中不可避免会出现一些明显的异常值,这些异常值会干扰滑坡变形模式的识别和后续模型分析的准确性。因此,本研究使用拉依达准则来识别和剔除这些异常值。

拉依达准则首先计算样本序列的均值( $\mu$ )和标准差( $\sigma$ ):

$$\mu = \frac{1}{n} \sum_{i=1}^n \text{dist}_i \quad (1)$$

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (\text{dist}_i - \mu)^2} \quad (2)$$

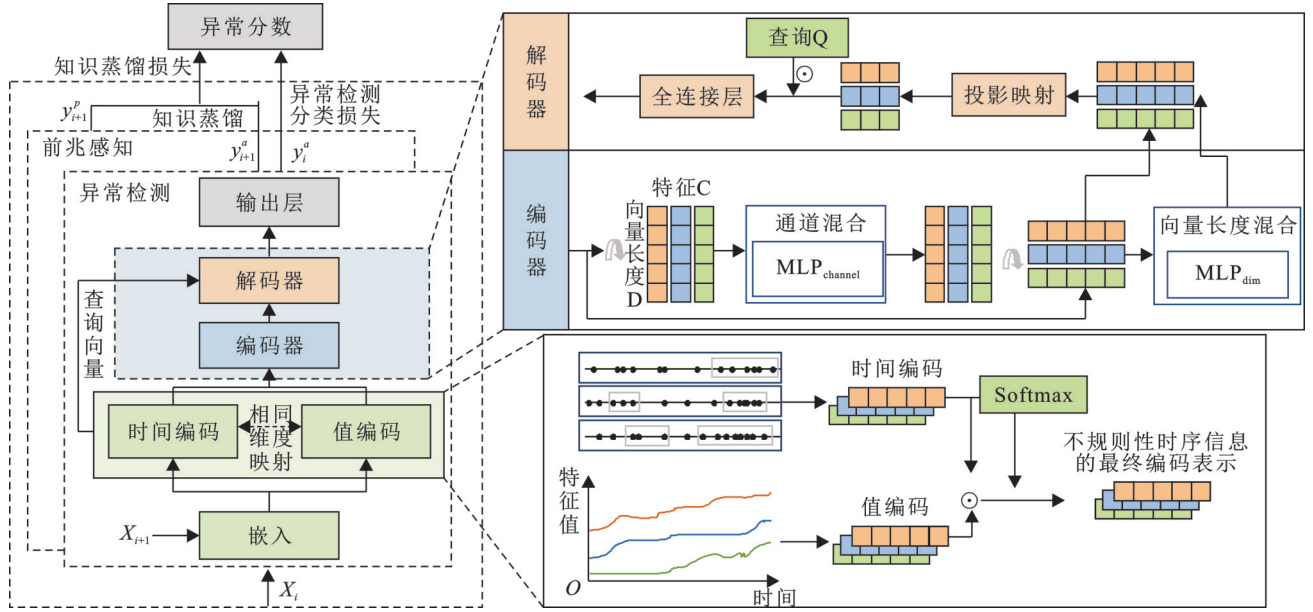


图 1 模型整体架构示意图

Fig.1 Diagram for overall architecture of model

将确定后的平均值和标准差代入公式(3)进行判别:

$$\mu - 3\sigma \leq \text{dist}_t \leq \mu + 3\sigma \quad (3)$$

式中:  $\text{dist}_t(\text{mm})$  为  $t$  时刻的位移观测值。如果该观测值位于  $[\mu - 3\sigma, \mu + 3\sigma]$  范围内, 则不予剔除; 反之若处于该区间范围外, 则表示该观测值是异常值予以剔除处理。

### 2.3 不规则时间特征编码方法

为包含裂缝计数据采集时间的信息, 本研究通过将时间嵌入到高维向量空间中获取有意义的时间表示, 然后将观测值与时间信息聚合并施加权重, 得到最终编码结果。

首先, 通过映射将包含时间信息的观测元组  $x_i = (\text{value}, \text{time}, \text{mask})$  嵌入到一致的高维空间中, 得到在相同维度的向量表示  $h_i \in R^D$ 。由于观测值和时间可能具有不同的初始维度, 因此, 通过公式(4)~(5)分别将观测值  $v_i$  和时间  $t_i$  编码到隐藏维度  $D$ 。

$$v_i^{\text{enc}} = W_1 v_i + b_1 \quad (4)$$

$$t_i^{\text{enc}} = W_2 [\text{relu}(W_1 t_i + b_1)] + b_2 \quad (5)$$

其次, 将以上结果进行双分支处理: 为获得包含时间信息的编码表示, 对  $v_i^{\text{enc}}$  和  $t_i^{\text{enc}}$  进行逐元素相乘 [公式(6)]。此外, 基于  $v_i^{\text{enc}}$  和  $t_i^{\text{enc}}$  得到权重  $\alpha_i$  [公式(7)] 用于后续聚合操作。

$$H_i = v_i^{\text{enc}} \odot t_i^{\text{enc}} \quad (6)$$

$$\alpha_i = \text{softmax} \{ W_2 [\text{relu}(W_1 t_i + b_1)] + b_2 \} \quad (7)$$


最后, 通过加权聚合的方式使最终的嵌入表示可以包含不同特征维度在时间维度上的重要性程度表示, 获得最佳嵌入表示  $z_c$  [公式(8)]。

$$z_c = \sum_{i=1}^C (\alpha_c)_i \odot H_i + b_c \quad (8)$$

式中:  $(\alpha_c)_i$  表示第  $i$  个特征通道在时间维度上的权重;  $W_N, b_N$  表示可学习的权重和偏差项;  $\text{relu}$  为激活函数;  $\odot$  表示逐元素相乘。

### 2.4 多层感知机混合器

考虑到 MLP 混合架构在时间序列分析领域的表现<sup>[21]</sup>, 使用 MLP-Mixer 对裂缝计监测数据进行深度特征提取, MLP-Mixer 模块如图 2 所示。



注:  $C$  为通道维度;  $D$  为隐藏维度;  $W_N, b_N$  分别表示可学习的权重和偏差项;  $\text{relu}$  为激活函数;  $Z_i$  代表第  $i$  个 MLP-Mixer 模块的输出结果;  $Z'_i$  代表 MLP-Mixer 模块的中间输出。

图 2 多层感知机混合器示意图

Fig.2 Diagram for MLP-Mixer

本研究中所采用的 MLP-Mixer 模块由两个全连接层构成,分别沿输入的通道维度  $C$  和隐藏维度  $D$  进行顺序映射,用于捕捉跨通道与跨隐藏维度的特征依赖关系。为学习非线性关系,在每层中添加 Relu 作为激活函数,同时引入残差连接以缓解深层网络的梯度消失问题并提升训练稳定性。此外,为提升模型收敛性与泛化性能,在每个全连接层之前引入归一化操作。

应用多个 MLP-Mixer 模块作为模型编码器,将其输出定义为:

$$Z'_i = Z_{i-1} + \text{relu}(W_1(\text{Norm}(Z_{i-1})) + b_1) \quad (9)$$

$$Z_i = Z_{i-1} + Z'_i + \text{relu}(W_2(\text{Norm}(Z'_i)) + b_2) \quad (10)$$

式中:  $W_N, b_N$  表示可学习的权重和偏差项; relu 为激活函数;  $Z_i$  代表第  $i$  个 MLP-Mixer 模块的输出结果;  $Z'_i$  代表 MLP-Mixer 模块的中间输出。

## 2.5 解码器

一般而言,为获得最终预测输出,需将每一通道的隐藏状态映射至查询空间,并进一步解码为通道与查询之间的标量响应值。Klöttergens C 等<sup>[22]</sup>提出通过将时间信息与隐藏状态进行连接,生成表示整个通道的固定维度向量,并据此对连续查询点进行预测,最终通过神经网络实现输出。在本研究使用的方法中,将查询时间作为标量输入一个包含  $D_{out}$  个输出神经元的双层网络中。随后,将查询时间向量与对应通道的编码结果进行逐元素乘法运算,融合查询与通道间的交互信息。最终,通过线性变换层将融合后的矢量映射为标量输出,得到最终输出结果。

$$q_i = W_2 \text{relu}(W_1 q'_i + b_1) + b_2 \quad (11)$$

$$y_{out} = W_3 (q_i \odot Z_i) + b_3 \quad (12)$$

式中:  $W_N, b_N$  表示可学习的权重和偏差项; relu 为激活函数;  $Z_i$  代表编码器输出结果;  $q'_i$  代表裂缝计采样的原始时间查询;  $q_i$  代表映射为与目标输出形状一致的查询向量;  $\odot$  代表逐元素相乘;  $y_{out}$  为模型输出结果。

## 2.6 目标函数

知识蒸馏(knowledge distillation, KD)<sup>[23]</sup>是一种将复杂模型的知识迁移至简单模型的技术,可将复杂模型的特征提取能力转移到更高效的简单模型上。其过程首先利用大规模时间序列数据集训练复杂模型,生成高精度预测结果;随后,这些预测结果用于指导简单模型的训练。在本研究中,知识蒸馏应用于前兆感知任务,通过优化简单模型,使其预测输出尽可能接近异常检测任务的预测结果,学习时间序列数据的动态模式和内在关系<sup>[24]</sup>。具体来说,

在训练过程中,异常检测任务基于“硬标签”(即真实标签)进行分类学习,以确保直接且准确的分类结果;随后,将未来序列输入异常检测任务,作为“老师模型”生成软标签,这些软标签提供了比硬标签更为丰富的概率分布信息,有效降低了模型对噪声标签的敏感性,并隐含了模型对历史数据的深层理解。学生模型(即异常前兆感知任务)以历史序列为输入,通过学习老师模型的概率分布输出,将其知识提炼至学生模型中,从而减少噪声数据的影响,提升预测精度与泛化能力。本研究使用交叉熵损失来训练模型。 $L_{KD}$  和  $L_a$  分别表示知识蒸馏和异常检测的交叉熵损失:

$$L_{KD} = \text{CE}(y_{i+1}^a, y_{i+1}^b) \quad (13)$$

式中:  $y_{i+1}^a$  表示异常检测任务的输出;  $y_{i+1}^b$  表示异常前兆感知任务的输出。

$$L_a = \text{CE}(y_i^a, y_i) \quad (14)$$

式中:  $y_i$  表示第  $i$  个时间窗口的真实标签。如公式(14)所示,利用交叉熵损失,将异常检测的知识提炼到异常前兆感知中。

## 3 结果与分析

### 3.1 模型评估

#### 3.1.1 评价指标与基线模型

为全面评估本文模型性能,采用精确率  $P$  (precision)、召回率  $R$  (recall)、 $F_1$  分数和 ROC 曲线下面积(AUC)作为主要评价指标。其中,精确率  $P$  衡量模型识别为异常的样本中真正异常的比例;召回率  $R$  反映模型检测所有真实异常的能力; $F_1$  分数作为精确率与召回率的调和平均数,能够综合评估模型的性能;AUC 表示 ROC 曲线下的面积,衡量模型在不同分类阈值下的综合分类能力,其值越接近 1,表明模型区分正常与异常样本的能力越强,用于评估模型的鲁棒性和对阈值变化的适应性。令 FP, FN, TN, TP 分别表示假正类、假负类、真负类、真正类,对应指标的计算公式为

$$P = \frac{TP}{TP + FP}, R = \frac{TP}{TP + FN}, F_1 = 2 \times \frac{P \times R}{P + R} \quad (15)$$

AUC 评价指标表示假阳性率 FPR (false positive rate) 与真阳性率(召回率  $R$ ) 之间的关系。其中 FPR 计算公式为

$$\text{FPR} = \frac{FP}{FP + TN} \quad (16)$$

为了验证本研究使用的异常检测方法的性能,本文选取具有代表性的时间序列异常检测模型进行对比试验,比较方法包括 Isolation Forest<sup>[25]</sup>,

LSTMAD, Autoformer, TimesNet, TimeADDM 和 SimAD。部分基线模型的超参数设置参考 Time-Series-Library<sup>[26]</sup>中提供的配置,以确保试验比较的公平性与可重复性。

### 3.1.2 试验设置

本文模型中,不规则时间特征编码模块对输入序列以及查询时间进行编码嵌入,MLP-Mixer 模块执行嵌入维度和通道维度的特征聚合。具体设置如下,嵌入及通道聚合维度为 64,MLP-Mixer 模块最终输出维度为 32,模块数量为 3,嵌入模块中非线性网络的隐藏层维度设置为 64。模型训练采用 Adam 优化器,初始学习率设为 0.001,权重衰减为 0.000 1。并引入早停机制(验证集损失不再下降时停止),耐心值设置为 10。训练过程中,批次大小设置为 32,总训练轮次为 100。在异常检测阶段,首先计算所有训练样本的异常分数,使用真实异常样本的最小异常分数作为最佳异常分数阈值  $\tau$ 。然后计算测试集中样本的异常分数,并将分数大于阈值  $\tau$  的样本标识为异常<sup>[27]</sup>。

## 3.2 试验结果

### 3.2.1 对比试验

表 1 与图 3 分别为不同时间序列异常检测模型在给定数据集上的指标表现。试验结果表明,本文模型在高召回(95.41%)的同时取得最高的精确率(80.36%)与  $F_1$  分数(87.24%)。就综合指标而言,本文模型在  $F_1$  分数较次优方法 TimesNet(69.04%)提升 18.20 个百分点,相较 Autoformer(68.31%)提升 18.93 个百分点;相对两类高敏感方法 TimeADDM 与 SimAD(召回率均为 100%), $F_1$  分别高出 26.81 与 26.16 个百分点,而召回率相对来说仅小幅降低 4.59 个百分点。由此可见,本文模型以极小的召回代价显著降低了误报,带来最优综合性能。

从不同模型的结果分布上看,基于重构/预测误差的 LSTMAD 与基于稀有点假设的 Isolation Forest 在本数据上精确率分别为 41.32% 与 40.09%,尽管召回率分别达到 88.50% 与 80.53%,但高误报使得  $F_1$  分数仅为 56.34% 与 53.53%,表明在存在上下文相关与形态多样的异常时,这两类基线更易产生假阳性。面向长序列的 Autoformer 与 TimesNet 在相近的召回率(均为 85.84%)下显著提升精确率(分别为 56.73% 与 57.74%), $F_1$  分数达到 68.31% 与 69.04%,显示长依赖与多尺度模式的建模有助于抑制误报,获得更均衡的表现。TimeADDM 与 SimAD 的召回率为 100%,但精确率分别仅 43.30% 与 43.97%, $F_1$  分数为 60.43% 与 61.08%,呈现“高召回,低精确率”的特征

组合,会带来较重的报警负担。与上述各类方法相比,本文模型的优势主要体现在其稳健性:在不牺牲高召回的前提下显著提高了精确率,具有最好的模型分类性能(AUC 为 87.20%),从而在不同类型异常并存的情形下实现更低的误报率与更高的综合指标。

表 1 不同模型在异常检测任务的性能表现  
Table 1 Performance of different models in anomaly detection tasks

方法	精确率/%	召回率/%	$F_1$ 分数/%
Isolation Forest	40.09	80.53	53.53
LSTMAD	41.32	88.50	56.34
Autoformer	56.73	85.84	68.31
TimesNet	57.74	85.84	69.04
TimeADDM	43.30	100	60.43
SimAD	43.97	100	61.08
Ours	80.36	95.41	87.24

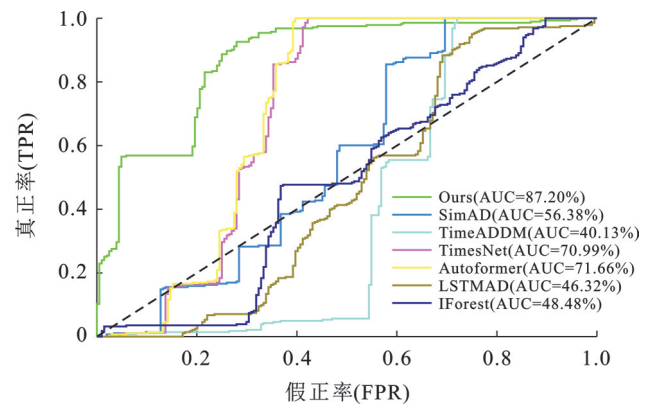


图 3 不同模型 ROC 曲线下面积 (AUC)

Fig.3 Area under ROC curve (AUC) for different models

### 3.2.2 消融试验

表 2 与图 4 的消融试验结果反映了各组件对总体性能的贡献。移除时间嵌入(ours-without-time)以更大范围的召回率下降换取模型精确率上升。这说明时间维的可学习表示通过对不规则时间信息的显式建模强化了模型对异常样本的覆盖度和敏感性,从而在低误报漏报要求的监测预警场景下具有必要性。将通道交互由 MLP-Mixer 替换为通道级 Transformer(ours-transformer),两者指标表现相近,但前者(MLP-Mixer)召回率与 AUC 更加稳定,后者(transformer)精确率略高。这与两者的结构先验一致:MLP-Mixer 的参数收缩与可分离映射在小样本场景下更加稳定,而注意力机制的冗余表达导致其覆盖不足,表现为召回劣化、分类性能下降;去除知识蒸馏(ours-without-KD)在精确率和 AUC 上表现相差不大,但召回率和  $F_1$  分数小幅上升。这表明蒸

馏主要作用于判别边界的校准与置信度分布的整形:在不显著牺牲精度的前提下提升对正例的覆盖,从而提高综合指标。此外,将两任务完全独立训练(anomaly detection/precursor of anomaly)发现,多任务学习在保持高召回的同时显著提高精确率,在  $F_1$  分数上小幅上升,而 AUC 与最佳单任务接近,说明共享表征与蒸馏传递在两个任务中取得综合表现,能更加稳定地实现“高召回,较高精确率”的组合目标。综上所述,3项组件和多任务框架对模型性能的贡献具有显著的互补性和必要性。

表 2 不同模块的消融试验表现  
Table 2 Performance of different modules in ablation experiments

方法	精确率/%	召回率/%	$F_1$ 分数/%
Ours-without-time	90.62	81.98	86.36
Ours-transformer	82.04	93.64	87.46
Ours-without-KD	80.95	90.11	85.28
Anomaly Detection	76.94	97.88	86.16
Precursor of Anomaly	75.34	97.17	84.88
Ours	80.36	95.41	87.24

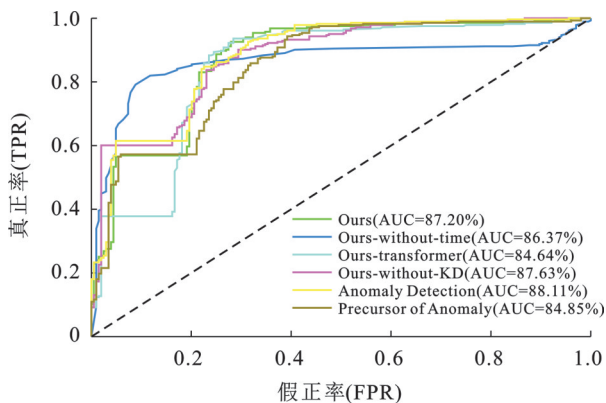


图 4 消融试验下 ROC 曲线下面积 (AUC)

Fig.4 Area under ROC curve (AUC) in ablation experiments

## 4 讨论

本研究提出的模型在处理滑坡裂缝计时序数据时,取得了在高召回率下的均衡性能,这主要得益于不规则时间特征的显式编码和专家经验的知识蒸馏整合。通过将观测值和时间信息嵌入高维空间并加权聚合,有效捕捉传感器监测数据中隐含的动态模式,克服了传统模型对非等间隔采样的忽略,从而提升了异常识别精度。引入的 MLP-Mixer 模块以更少的参数实现通道与特征的非线性交互,使模型在有限样本条件下仍具有稳定高效的特征表达能力。同

时,多任务学习框架下的知识蒸馏机制允许异常检测任务的专家知识迁移到前兆感知任务中,促进任务间信息互补与共享,从而进一步增强模型的鲁棒性与泛化性。相较之下,基于统计假设的 Isolation Forest 和基于预测误差的 LSTMAD 因其在处理上下文相关和形态多样的异常上的能力有限,容易产生假阳性。而 Autoformer 和 TimesNet 虽具有更强的建模能力,但模型参数量较大,对样本规模依赖性强,难以在当前数据场景下保持稳定表现。此外,TimeADDM 通过扩散式学习增强了异常可分性,但也带来了较高的假阳性比例;而 SimAD 虽基于相异性度量强化了正常与异常分布的差异,但在噪声环境下牺牲了精确度。消融试验进一步验证了各组件的贡献:不规则时间嵌入模块提供了时间维的可学习表示,对构建稳定的时间加权和跨步聚合至关重要,使模型能够充分利用不规则时间序列数据中的时序关联和隐含关系;MLP-Mixer 在当前地质监测数据场景下更加稳健,能够避免注意力机制带来的表达冗余;知识蒸馏机制则在判别边界校准和置信度分布整形方面发挥了突出作用,显著提升了模型对正例的覆盖与分类置信度。这些组件的互补性确保了模型在不规则时序数据上的鲁棒性与泛化能力。综上所述,所提方法可有效过滤海量误报预警信号,为地质灾害监测预警的工程应用提供更为可靠的技术方法支撑。然而,该方法仍存在一定的局限性。

本研究采用的数据源于福建省监测预警工作的数据积累,受限于其体系建设时间相对较短,样本数量相对较少,限制了模型的应用场景。同时,模型对云南、重庆等典型滑坡区域的应用价值还需进一步验证。此外,降雨作为福建省滑坡灾害的重要诱发因素,本文因数据获取难度以及研究条件所限,并未纳入雨量数据进行分析,这可能影响模型的预测精度。

## 5 结论

(1) 相比传统机器学习方法和基于深度学习的基线模型,本研究提出的模型在高召回率下显著降低了误报率,展现了较强的鲁棒性和泛化能力,有助于降低地质灾害监测预警中的误报风险,为预警系统的优化提供新思路。

(2) 传感器监测数据的不规则时间信息能够提升异常识别精度,其隐含的动态信息具有重要价值。本研究通过显式编码这些时间信息,挖掘滑坡演化潜在模式,增强了模型性能,为地质灾害预警提供理论支持。

(3) 未来研究可进一步扩展数据集,结合降雨等滑坡诱发因素优化模型性能;同时,探索更先进的深度学习架构,以提升对复杂地质环境的自适应性。

(4) 当前模型在福建省数据集上表现优异。将来可在云南省、重庆市等典型滑坡区域开展试验,验证其在其他地质环境下的适用性。

### 参考文献 (References)

- [1] 自然资源部. 全国地质灾害防治“十四五”规划[R]. 北京: 自然资源部, 2022.  
Ministry of Natural Resources. The 14 th Five-Year Plan for National Geological Disaster Prevention and Control [R]. Beijing: Ministry of Natural Resources, 2022.
- [2] Cook A A, Mısırlı G, Fan Zhong. Anomaly detection for IoT time-series data: A survey [J]. IEEE Internet of Things Journal, 2020, 7(7): 6481-6494.
- [3] Yang Xue, Qi Xuejun, Zhou Xiaobo. Deep learning technologies for time series anomaly detection in healthcare: A review [J]. IEEE Access, 2023, 11: 117788-117799.
- [4] 刘刚, 叶立新, 陈麒玉, 等. 基于多传感器信息融合的城市边坡监测数据异常事件检测[J]. 地质科技通报, 2022, 41(2): 13-25.  
Liu Gang, Ye Lixin, Chen Qiyu, et al. Abnormal event detection of city slope monitoring data based on multi-sensor information fusion [J]. Bulletin of Geological Science and Technology, 2022, 41(2): 13-25.
- [5] 张聪聪, 王秀英. 前兆观测异常数据检测方法研究[J]. 震灾防御技术, 2014, 9(S1): 615-621.  
Zhang Congcong, Wang Xiuying. Research on detection method of abnormal data of precursory observation [J]. Technology for Earthquake Disaster Prevention, 2014, 9(S1): 615-621.
- [6] Barnett V, Lewis T. Outliers in Statistical Data [M]. 3rd ed. Chichester, England; New York; Wiley, 1994.
- [7] 李莽每, 成丽波. 基于小波分析的时间序列ARIMA模型预测方法[J]. 沈阳师范大学学报(自然科学版), 2021, 39(1): 49-53.  
Li Qiaomei, Cheng Libo. Prediction method of time series ARIMA model based on wavelet analysis [J]. Journal of Shenyang Normal University (Natural Science Edition), 2021, 39(1): 49-53.
- [8] 谢丽霞, 王嘉敏, 杨宏宇, 等. 时间序列异常检测方法研究综述[J]. 中国民航大学学报, 2024, 42(3): 1-12.  
Xie Lixia, Wang Jiamin, Yang Hongyu, et al. Review of anomaly detection methods for time series [J]. Journal of Civil Aviation University of China, 2024, 42(3): 1-12.
- [9] Malhotra P, Vig L, Shroff G M, et al. Long short term memory networks for anomaly detection in time series [C]// Proceeding of the European Symposium on Artificial Neural Networks, Piscataway N J: IEEE, 2015
- [10] Wu Haixu, Xu Jiehui, Wang Jianmin, et al. Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting [J]. Advances in Neural Information Processing Systems, 2021, 34: 22419-22430.
- [11] Wu Haixu, Hu Tengge, Liu Yong, et al. TimesNet: Temporal 2D-variation modeling for general time series analysis [C]// The Eleventh International Conference on Learning Representations (ICLR) 2023.
- [12] Hu Rongyao, Yuan Xinyu, Qiao Yan, et al. Unsupervised anomaly detection for multivariate time series using diffusion model [C]// Seoul Korea: IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2024.
- [13] Zhong Zhijie, Yu Zhiwen, Xi Xing, et al. SimAD: a simple dissimilarity-based approach for time-series anomaly detection [J]. IEEE Transactions on Neural Networks and Learning Systems, 2025, 36(11): 19669-19680.
- [14] 张磊, 巨能攀, 何朝阳, 等. 滑坡裂缝计时序数据实时异常检测分析[J]. 岩石力学与工程学报, 2024, 43(1): 206-215.  
Zhang Lei, Ju Nengpan, He Chaoyang, et al. Real-time anomaly detection and analysis of time series data for crack gauge in landslides [J]. Chinese Journal of Rock Mechanics and Engineering, 2024, 43(1): 206-215.
- [15] 郭翊蓁, 颜晨昕, 杜苗增, 等. 基于LSTMAD算法和Hermite插值法的滑坡监测数据预处理方法: CN114970688A [P]. 2022-08-30.  
Guo Yizhen, Yan Chenxin, Du Miaozeng, et al. A Pre-processing Method for Landslide monitoring data based on LSTMAD algorithm and hermite interpolation: CN114970688A [P]. 2022-08-30.
- [16] Wang W, Motagh M, Plank S, et al. Application of sar time-series and deep learning for estimating landslide occurrence time [J]. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2022, XLIII-B3-2022: 1181-1187.
- [17] 林经纬. 福建省滑坡灾害特征及驱动因素分析[J]. 莆田学院学报, 2015, 22(5): 83-88.  
Lin Jingwei. Characteristics and driving factors of landslide hazard in Fujian Province [J]. Journal of Putian University, 2015, 22(5): 83-88.
- [18] Zhang Weihua. Geological disaster monitoring and early warning system based on big data analysis [J]. Arabian Journal of Geosciences, 2020, 13(18): 946.