

基于多源 GNSS 和地震数据融合的 GeoViT-PFN 地震活动性预测

王雪鉴^{1,2}, 王自法^{1,2*}, 周坤伯^{1,2}, Jianming Wang^{1,2}, 李兆焱^{1,2}

(1. 中国地震局工程力学研究所 地震工程与工程振动重点实验室, 黑龙江 哈尔滨 150080;

2. 地震灾害防治应急管理部重点实验室, 黑龙江 哈尔滨 150080)

摘要: 本文针对地震预测中多源异构数据难以有效融合与标签不对齐的挑战, 提出了一种基于多模态机器学习框架的 GeoViT-PFN 模型, 重点引入 GNSS 形变图像与地震参数协同建模的新方法。该模型将 GNSS 台网位移数据通过距离加权插值转换为图像时序, 同时从地震目录中提取 b 值、a 值作为表格序列; 采用视觉 Transformer (ViT) 对图像进行编码并经 PCA 降维, 与地震特征融合后输入基于 Transformer 的 TabPFN 解码器进行回归预测。实验表明, 所提出的多模态融合方法在测试集上预测地震活动性的误差 (MSE) 降低至 0.7×10^{-4} , 决定系数 (R^2) 为 0.97, 相较于单模态提升约 50%。验证了 GNSS 形变与地震统计参数协同的有效性, 且该框架具备可扩展性, 能够为集成多源地球物理数据提供思路。

关键词: GNSS 地壳形变, 地震目录, 多模态, 深度学习, VIT

中图分类号: P315

收稿日期: 2025-06-06

GeoViT-PFN Seismic Activity Prediction Based on Multi-Source GNSS and Seismic Data

Fusion

Xuejian Wang^{1,2}, Zifa Wang^{1,2*}, Kunbo Zhou^{1,2}, Jianming Wang^{1,2}, Zhaoyan Li^{1,2}

(1. Key Laboratory of Earthquake Engineering and Engineering Vibration, Institute of Engineering Mechanics, China Earthquake Administration, Harbin 150080, China;

2. Key Laboratory of Earthquake Disaster Mitigation, Ministry of Emergency Management, Harbin 150080, China)

Abstract: Addressing the challenges of effective fusion of multi-source heterogeneous data and misaligned labels in earthquake prediction, this paper proposes a multimodal machine learning framework, the GeoViT-PFN model, with a focus on a novel approach that integrates GNSS deformation images and seismic parameters for collaborative modeling. The model converts GNSS station displacement data into image time series through distance-weighted interpolation, while extracting b-values and a-values from earthquake catalogs as tabular sequences. A Vision Transform

基金项目: 国家重点研发计划 (2023YFC3805203), 中国地震局工程力学研究所基本科研业务费专项资助项目 (项目编号: 2023A01), 国家自然科学基金面上项目 (52378544, 52378543)

第一作者: 王雪鉴(2001-), 男, 硕士研究生, 主要从事地震预测研究, **E-mail:** 1415381525@qq.com, ORCID: <https://orcid.org/0009-0001-5240-7414>

通信作者: 王自法(1965-), 男, 研究员, 博士, 主要从事巨灾风险相关研究, **E-mail:** zifa@iem.ac.cn

er (ViT) is employed to encode the images, followed by PCA for dimensionality reduction. The resulting features are fused with seismic characteristics and input into a Transformer-based TabPFN decoder for regression prediction. Experiments demonstrate that the proposed multimodal fusion method reduces the mean squared error (MSE) for predicting seismic activity to 0.7×10^{-4} on the test set, with a coefficient of determination (R^2) of 0.97, representing an improvement of approximately 50% compared to single-modal approaches. This validates the effectiveness of integrating GNSS deformation with seismic statistical parameters, and the framework exhibits scalability, offering a potential solution for incorporating multi-source geophysical data.

Key words: GNSS crustal deformation, seismic catalog, multimodal, deep learning, Vision Transformer (ViT)

引言

地震预测是公认的世界难题，也是作为地球科学研究的关键领域之一。一旦发生大地震，不但会导致重大人员伤亡和基础设施的大规模损毁，而且对社会经济的发展影响深远（**Shi, 2002; Ma, 2008**）。精确预测

地震的三要素（时间、地点、震级）在短期内仍不可能实现，原因在于地球系统的复杂性和观测数据时间和精度局限性等因素。地震活动性预测侧重于分析一定时空范围内地震发生的概率和分布，包括分析 b 值变化等统计特征。目前的地震活动性分析在中长期尺度（数年-数十年）上已经展示出了一定的可行性，长期尺度的预测依赖地震活动性统计规律和地质构造，主要评估未来可能发生的大地震（**陈运泰, 2007; 赵纪东等, 2009**），中期尺度基于地震活动和地壳形变观测数据等识别未来数年可能发生地震的时间和地点（**王锦红等, 2023**）。然而短期预测与临震预报是目前的最大难题，其重要性不言而喻（**陈运泰, 2009**）。

随着观测技术的发展，越来越多的地球物理化学数据为地震前兆提供了新的数据维度，包括记录了更微弱的前震活动、地下水化学和水位变化、GNSS 地表形变观测和地磁地电记录等等（**Wang et al., 2020; Ruan et al., 2023; Pei Huang et al., 2024**）。这些多源的数据提供了关于地震发生更多不同方面的前兆信息，通过联合这些不同信息，其短期的预测可靠性势必高于单一数据源。传统的统计方法无法有效处理这些不同时间尺度和不同格式的数据，例如地震目录记录是离散的时间点数据，GNSS 等监测数据都是连续观测的时间序列，并且还需要考虑不同测站之间的空间信息。

近年来，机器学习方法在地震学领域快速发展，在地震其他领域表现已经非常优秀，例如地震动预测、地震损失预测、地震预警等，其表现已显著优于传统方法（**Mousavi et**

al., 2020; Borate et al., 2023; 胡进军等,2023; 陈建玮等,2023)。然而机器学习方法在地震预测领域还尚处于探索阶段,其主要面临的挑战包括地震领域数据的稀缺性、不同观测数据在时间分辨率和空间分布上的差异、大地震样本的极端不平衡性以及标签的连续性对齐问题。

本文针对地震逐日活动性密度的临近预报(Nowcasting)中的多模态数据融合与标签对齐难题,提出了一种编码器-解码器结构的GeoViT-PFN机器学习模型。本方法的主要创新在于构建了一个统一框架,能够协同处理GNSS形变图像与地震统计参数两类异构数据,实现跨模态特征融合与连续标签预测,为地震风险评估提供新的技术途径。具体而言,首先将选定区域内同一天所有GNSS测站的位移数据,通过基于距离的高斯加权插值方法处理为图像时序。这一处理策略虽未引入复杂应变计算与物理约束,在效率与可实现性方面具有优势,但也可能影响空间细节准确性及边缘区域的可靠性。同时,从地震目录中提取b值与a值时间序列,并引入核密度估计(KDE)方法将离散地震事件转化为以天为单位的连续发生概率密度,以解决样本不平衡和标签对齐问题。随后,采用视觉Transformer(ViT)编码器对GNSS图像进行特征提取与池化压缩,并经PCA降维后与地震参数特征融合,最终输入基于Transformer的TabPFN解码器进行回归预测。该模型在多模态融合机制和特征表示层面具有显著创新性,为融合地球物理多源数据提供了一种可扩展的解决方案,对未来地震活动性短期风险评估研究具有推进意义。

1 多源数据处理

1.1 GNSS 图像数据

GNSS数据已经在多个研究中被证明在大地震之前存在异常变化,是地震发生的重要前兆信号之一(Bletry & Nocquet, 2023; 顾国华, 2023; 刘志军等, 2023)。本文的研究区域覆盖日本地区,经度范围(123° - 148°)和纬度范围(22° - 46°)。日本具有高密度的GNSS测站,平均站距11公里,非常适合形成GNSS地表位移图。GNSS数据来自内华达大地测量实验室(Blewitt et al., 2018),每个台站提供每日位置坐标 $r(t)=(e(t),n(t))$ ($e(t)$ 为东向经度, $n(t)$ 为北向纬度)。将记录日前后两天的测站坐标进行差分,得到东-北平面输入位移 $V(t)=r(t+1)-r(t-1)$ 。本文使用高斯加权插值方法生成每个网格点的位移值使其形成图像,详细如下:

(1)划分网格系统

我们将选定区域划分为 50*50 的网格，每个网格的纬度大小为：

$$\Delta_\phi = \frac{\phi_{\max} - \phi_{\min}}{n_{\text{rows}}} \quad (1)$$

其中， ϕ 代表纬度，单位为度（°）； n_{rows} 代表划分的网格数， Δ_ϕ 代表划分网格的经度。

每个网格的经度大小为：

$$\Delta_\lambda = \frac{\lambda_{\max} - \lambda_{\min}}{n_{\text{cols}}} \quad (2)$$

其中， λ 代表经度，单位为度（°）； n_{cols} 代表划分的网格数， Δ_λ 代表划分网格的经度。网格点的坐标生成为：

$$\phi_g = \phi_{\text{origin}} + i \cdot \Delta_\phi (i \in 0, 1, \dots, n_{\text{rows}} - 1) \quad (3)$$

$$\lambda_g = \lambda_{\text{origin}} + i \cdot \Delta_\lambda (i \in 0, 1, \dots, n_{\text{cols}} - 1) \quad (4)$$

其中， ϕ_{origin} 和 λ_{origin} 代表起始点的经纬度，单位为度（°）， i 表示网格行数和列数的序号。

(2)距离和权重计算

对每个网格点 g 和站点 i 进行球面距离计算，使用哈弗赛因距离计算：

$$d_i = 2R \cdot \arctan2(\sqrt{a_i}, \sqrt{1 - a_i}) \quad (5)$$

$$a_i = \sin^2\left(\frac{\phi_g - \phi_i}{2}\right) + \cos\phi_i \cos\phi_g \sin^2\left(\frac{\lambda_g - \lambda_i}{2}\right) \quad (6)$$

其中 ϕ_g 、 ϕ_i 、 λ_g 、 λ_i 分别代表网格点和站点的经纬度，单位为度（°）， d_i 为网格点与站点间的大圆距离，单位为米（m）； R 为地球平均半径，取 6371000 m。高斯权重计算为：

$$w_i = \exp\left(-\frac{d_i^2}{2\sigma^2}\right) \quad (7)$$

σ 为高斯衰减参数，一般取 8 倍网格间距对应的地面距离，单位为米（m）； w_i 为第 i 个站点的初始权重。其物理意义可表示为距离越近的站点权重越大，衰减速率由 σ 参数控制。接着进行权重归一化计算：

$$w_i = \frac{w_i}{\sum_{k=1}^N w_k} \quad (8)$$

(3)位移场计算

根据权重进行位移加权：

$$v_g = \begin{bmatrix} v_N \\ v_E \\ v_U \end{bmatrix} = \sum_{i=1}^N w_i \cdot v_i \quad (9)$$

其中的 v_i 表示三个方向的站点观测位移向量值，单位为毫米（mm）。其次我们加权站点平均位置量化 GNSS 站点在空间上的分布，通过加权均值和协方差矩阵。协方差矩阵可表示为：

$$\Sigma = \begin{bmatrix} \sigma_{\phi\phi} & \sigma_{\phi\lambda} \\ \sigma_{\lambda\phi} & \sigma_{\lambda\lambda} \end{bmatrix} \quad (10)$$

加权平均位置可表示为：

$$\mu_\phi = \sum w_i \phi_i \quad (11)$$

$$\mu_\lambda = \sum w_i \lambda_i \quad (12)$$

其中 μ_ϕ 和 μ_λ 分别代表加权平均经纬度，单位为度（°）。

(4) 位移梯度计算

这里我们计算位移-位置协向量，其中北向分量可以表示为：

$$c_N = \begin{bmatrix} cov(\phi, \mu_N) \\ cov(\lambda, \mu_N) \end{bmatrix} = \begin{bmatrix} \sum w_i \phi_i v_{N,i} - \mu_\phi \mu_{vN} \\ \sum w_i \lambda_i v_{N,i} - \mu_\lambda \mu_{vN} \end{bmatrix} \quad (13)$$

其中， c_N 单位为 mm°，其他变量同之前相同。同理可得到东向分量 c_E ，这里不再过多赘述。接着最重要的计算梯度，其物理意义可描述位移场在经纬方向的变化率：

$$\begin{bmatrix} \frac{\partial v_N}{\partial \phi} \\ \frac{\partial v_N}{\partial \lambda} \end{bmatrix} = \Sigma^{-1} c_N \quad (14)$$

$$\begin{bmatrix} \frac{\partial v_E}{\partial \phi} \\ \frac{\partial v_E}{\partial \lambda} \end{bmatrix} = \Sigma^{-1} c_E \quad (15)$$

其中 c_N 和 c_E 表示北向和东向的协向量，单位为 $\text{mm} \cdot {}^\circ$ 。 $\frac{\partial v_N}{\partial \phi}$ 分别为北向位移在纬度和经度方

向的变化率，单位为 $\text{mm}/{}^\circ$ ； $\frac{\partial v_E}{\partial \lambda}$ 分别为东向位移在纬度和经度方向的变化率，单位为 $\text{mm}/{}^\circ$ 。

(5) 位移修正

位移修正通过一阶泰勒展开提高边缘区域精度，修正后的位移场可表示为：

$$v_N = v_N + \frac{\partial v_N}{\partial \phi} (\phi_g - \mu_\phi) + \frac{\partial v_N}{\partial \lambda} (\lambda_g - \mu_\lambda) \quad (16)$$

$$v_E = v_E + \frac{\partial v_E}{\partial \phi} (\phi_g - \mu_\phi) + \frac{\partial v_E}{\partial \lambda} (\lambda_g - \mu_\lambda) \quad (17)$$

最终得到了每个网格点包括北向、东向和垂直向具体位移值，单位 mm ； v_N, v_E 为原始加权位移； ϕ_g, λ_g 为当前网格点经纬度； μ_ϕ, μ_λ 为站点加权平均经纬度。部分 GNSS 图像结果如图 1 所示，可以观察到每个网格点在相应日期出现的地壳形变北、东和垂直向位移值。当前方法采用了一定的简化策略，未引入复杂的应变场计算、误差控制、奇异值处理及地球物理约束（Hsu et al, 2009; Tape et al, 2010; 江在森等, 2010; Shen et al, 2015; Wu et al, 2018），但具有计算效率与高可操作性，可用于快速获取时空连续的特征图像以输入深度学习模型。

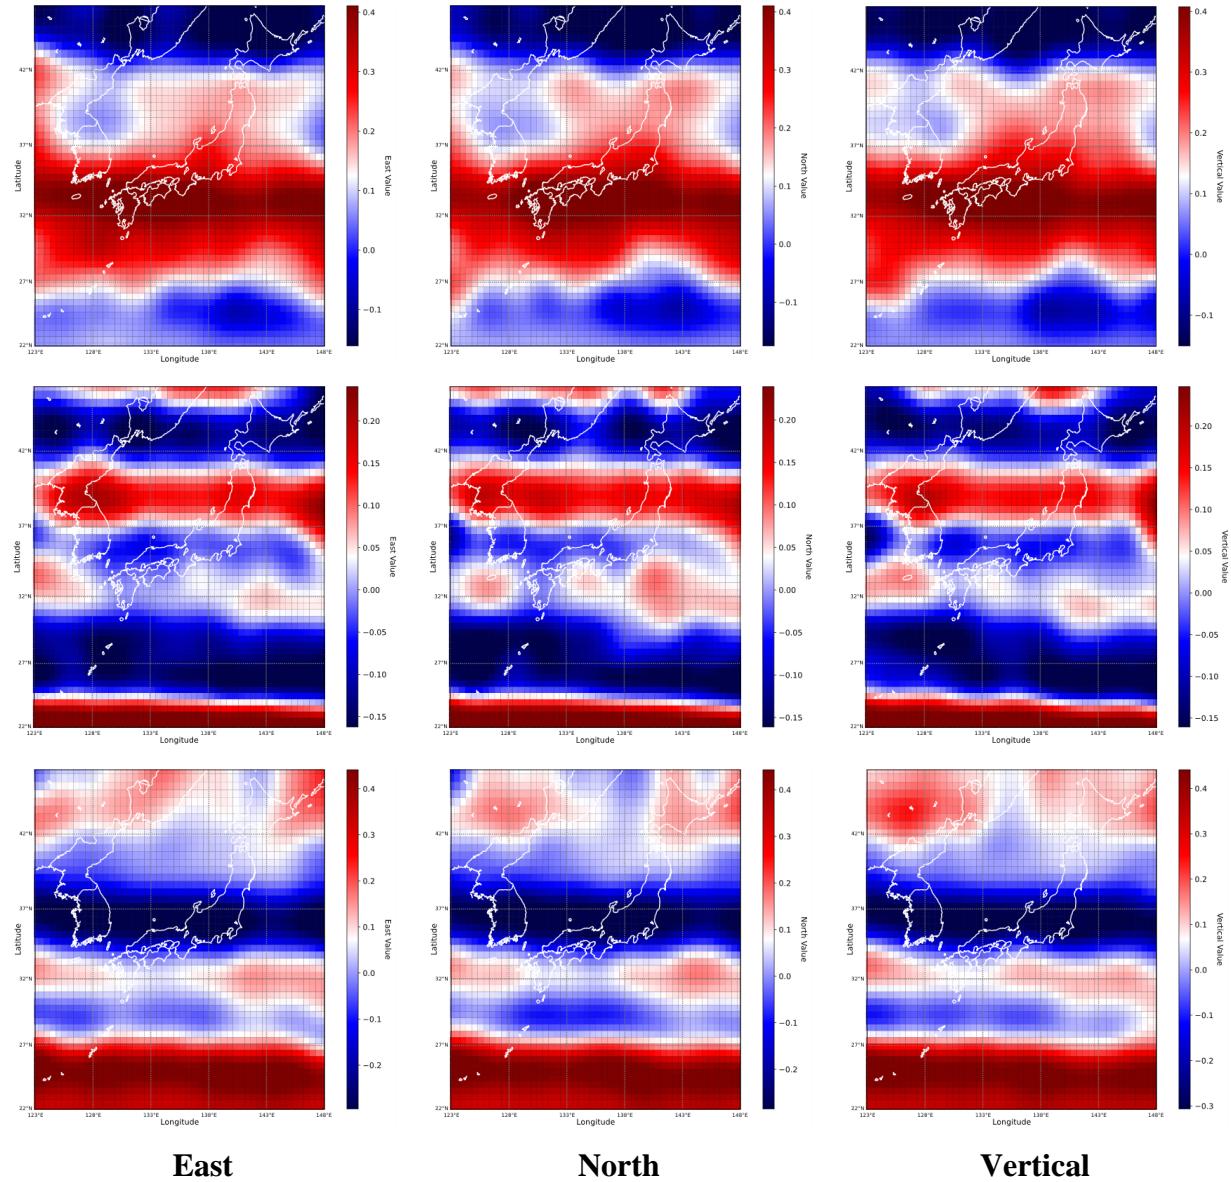


图 1 随机展示部分 GNSS 图像序列, 包括东、北向和垂直

Fig 1 Randomly displaying a portion of GNSS image sequences, including east, north, and vertical directions

1.2 b 值和 a 值

在地震活动性研究中, **b** 值和 **a** 值是描述地震频度-震级关系 (Gutenberg-Richter 关系, 简称 G-R 关系) 的两个关键参数 (Gutenberg and Richter, 1944), 其数学表达式为:

$$\log_{10} N(M) = a - bM \quad (18)$$

其中, $N(M)$ 表示震级大于等于 M 的地震数量, a 值代表研究区域的地震活动水平, b 值则反映大小地震的比例关系。实验与观测研究表明, b 值随应力增加而降低, 在强震前可能出现 b 值下降趋势, 反映区域应力积累。 a 值上升可能反映区域微震活动增强, 而突

然下降可能预示能量积累。因此过去一段时间的 a 值和 b 值可能反应了未来的地震活动性。所以我们根据划分时间窗口的方式计算 a 值和 b 值，并设置时间窗口滑动步长形成连续的时间序列用于预测未来的频率情况。 b 值计算采用最大似然估计法，公式为：

$$b = \frac{\log_{10} e}{\bar{M} - M_c} \quad (19)$$

其中， \bar{M} 代表平均震级， M_c 代表完备性震级。在确定 b 值之后， a 值可以通过 G-R 关系直接计算：

$$a = \log_{10} N(M \geq M_c) + bM_c \quad (20)$$

我们选取和 GNSS 数据相同研究区域大小进行 b 值和 a 值的计算，对于时间窗口的大小选取在以往的研究中并未统一（王凯英等，2021；高雅婧等，2022；李蒙亚等，2024），包括有固定时间窗口大小和固定事件数大小两种方式，常见固定事件数大小为 50，这些数值选取往往凭借经验。因此这里我们尝试使用时间序列的平稳性（Stationarity）、可预测性（Predictability）和波动性（volatile）等来给出时间窗口的最佳值（Liu et al. 2024），平稳性是时间序列建模的基础前提，非平稳序列的统计特性（如均值、方差）随时间变化，将导致基于历史规律的外推预测失效；波动性反映序列的离散程度，过高的波动可能掩盖真实的应力变化信号，而过低的波动则可能因过度平滑而丢失突变信息；预测精度（MAE）采用滞后预测法（Naive Forecast）衡量窗口内统计结果的稳健性（Meyer, 2002）。

首先需要符合窗口内地震事件不能过少，即设定为至少不少于 50 个，因为窗口内地震事件过少会导致估计误差增大。平稳性使用 ADF 检验（Augmented Dickey-Fuller test）和 KPSS 检验，波动性使用标准差进行评估。具体结果如表 1 所示，选取了 32, 64, 128, 192, 256 这 5 个窗口进行对比，其中窗口 ≤ 128 时序列平稳（ $ADF_p < 0.05$ 且 $KPSS_p > 0.05$ ），窗口 ≥ 192 时丧失平稳性（ $KPSS_p < 0.05$ ）；而 MAE 随窗口增大显著降低，相对稳定性 CV 随窗口增大而增加，CV 值 < 0.3 为佳， > 0.5 则波动过大；因此综合判断 128 天在保证平稳性的同时，预测误差较低，且相对稳定性较好。

表 1 不同时间窗口下 b 值时间序列的平稳性、可预测性和波动性分析

Table 1 Analysis of stationarity, predictability, and volatility of b -value time series under different time windows

窗口大小	CV	ADF_P	KPSS_P	平稳性	MAE
32	0.22	4.39×10^{-10}	0.1	True	0.006
64	0.25	3.05×10^{-8}	0.1	True	0.007
128	0.29	2.32×10^{-4}	0.051	True	0.003
192	0.31	2.23×10^{-3}	0.023	False	0.001
256	0.33	1.95×10^{-2}	0.017	False	0.0003

设置时间窗口为 128 天, 滑动时间步长为 1 天, 完备性震级为 3 级. 具体结果如何图 2 所示。

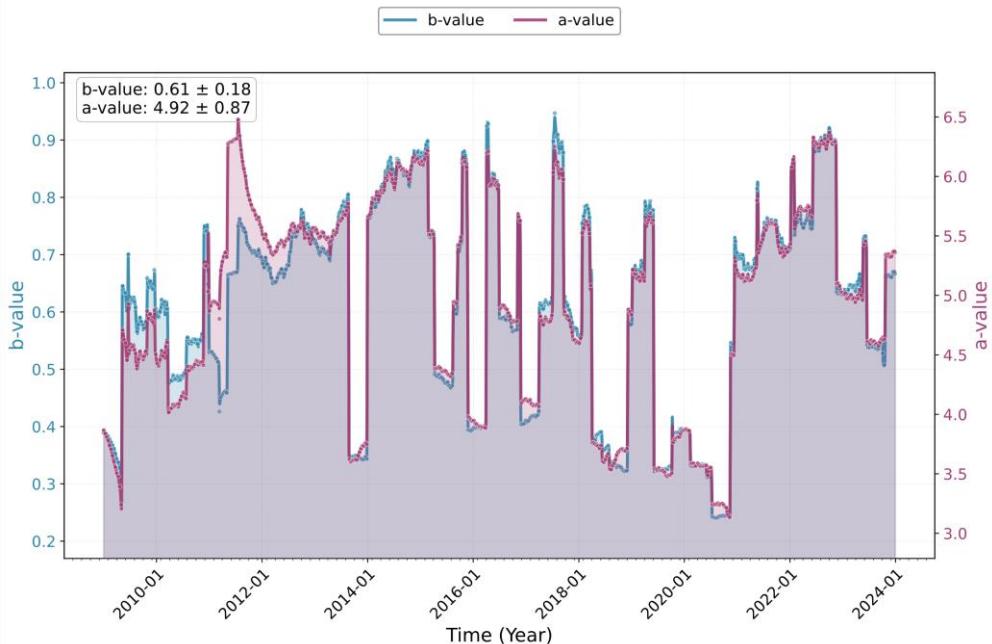


图 2 2009 年-2024 年设置时间窗口 128 天、步长为 1 天的 b 值和 a 值时间序列

Fig 2 Time series of b and a values with a time window of 128 days and a step size of 1 day from 2009 to 2024

1.3 基于 KDE 核密度估计的连续标签引导学习地震活动性

在地震预测研究中, 标签的设置直接决定了模型的泛化能力和预测结果。传统离散地震目录通常以事件发生时间点作为分类标签, 但此类离散标签难以反映地震活动的连续演化特征, 无法有效对齐连续监测的特征数据, 且由于地震震级的极端不平衡性分布, 导致模型预测结果始终偏向多数样本。

为解决上述问题，本研究采用核密度估计（Kernel Density Estimation, KDE）（Chen, 2017）将原始地震目录转换为以天为单位的连续时间序列。KDE 通过概率密度函数反映地震活动的时空聚集性。地震从集（如主余震序列、震群和前震活动）在时间维度上呈现短期高密度爆发特征，而 KDE 通过带宽参数 σ 控制事件影响的时空衰减尺度，与地震从集（clustering）的物理机制一致。KDE 的密度函数可视为地震发生率 $\lambda(t)$ 的非参数估计，与 ETAS（Epidemic-Type Aftershock Sequence）模型中随机点过程的强度函数具有形式等价性。二者的核心差异在于 ETAS 需预设参数化核函数（如修正 Omori 形式），而 KDE 通过数据驱动自适应拟合。

具体步骤为首先是对地震事件时间点应用高斯核函数：

$$K(t, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{t^2}{2\sigma^2}\right) \quad (21)$$

带宽 σ 这里使用的是 Scott 规则，计算方式为：

$$\sigma = n^{-\frac{1}{(d+4)}} \cdot \hat{\sigma}_x \quad (22)$$

其中 n 为样本数量， d 为数据维度（这里 d 为 1，时间序列）， $\hat{\sigma}_x$ 为样本标准差。其次是通过叠加核函数构建连续密度函数：

$$f(t) = \frac{1}{n} \sum_{i=1}^n K(t - t_i; \sigma) \quad (23)$$

其积分值表征单位时间内地震活动的概率强度。最后对 $f(t)$ 按天进行积分，生成以天为单位的连续标签序列：

$$y_d = \int_{d-1}^d f(t) dt \quad (24)$$

其结果如图 3 所示，其中曲线代表 Kde 处理之后的连续标签。

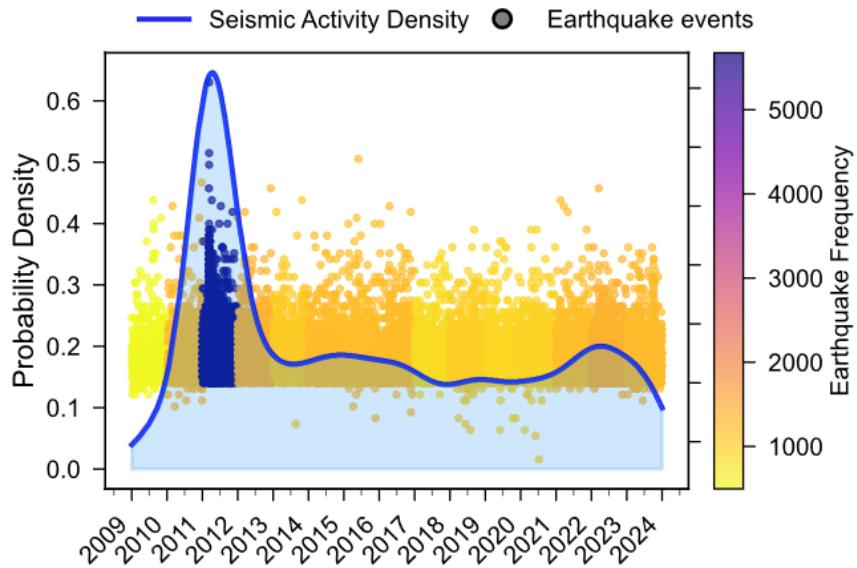


图 3 地震频率概率密度标签曲线变化，高密度值对应了相应的高地震频率

Fig 3 shows the variation of seismic frequency probability density label curve, where high-density values correspond to corresponding high seismic frequencies

与地震频率进行对比，例如在 311 大地震前后时间的地震频率显著升高。曲线的变化代表了对应时间段的地震频率概率密度，能够完全代表地震频率变化。随着地震数量上升，标签曲线随之升高，严格符合地震目录的记录变化。

1.4 数据对齐与回归预测

基于计算得到的 a 、 b 值与 GNSS 图像特征，以及连续标签，如何将其一一对应建立预测关系非常重要。其不但需要符合时间因果关系，而且要保证不出现数据泄露的问题。因此，我们提出一种参考大语言模型的自回归方法，自动回归地预测下一个 Token (Liu et al. 2024)。在这里的任务中则是基于过去时间点特征预测未来的标签。我们将这里的不同特征视作单序列，并已经确保了这些单序列的上下文长度统一。具体如图 4 所示，例如这里用第 1 个窗口 (Token) 的特征序列用于预测第 2 个窗口 (Token) 的标签序列，然后用第 2 个窗口 (Token) 的特征序列用于预测第 3 个窗口 (Token) 的标签序列，以此类推。确保了使用的特征只在过去的时间窗口中，符合时间因果关系和避免数据泄露。

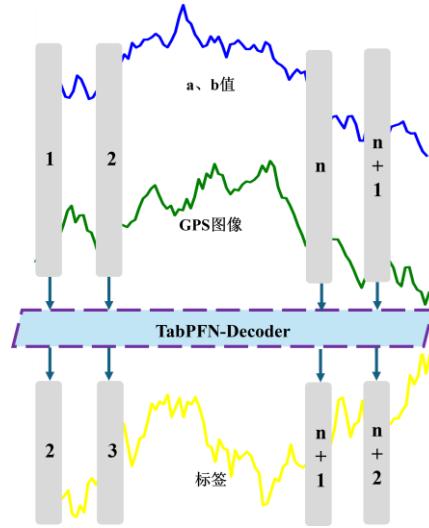


图 4 特征与标签之间的对齐方式及回归预测
 Fig 4 Alignment between features and labels, and regression prediction

2 基于多模态数据融合的 GeoViT-PFN 模型

本研究所提出的 GeoViT-PFN 深度学习如图 4 所示，采用编码器到解码器结构。

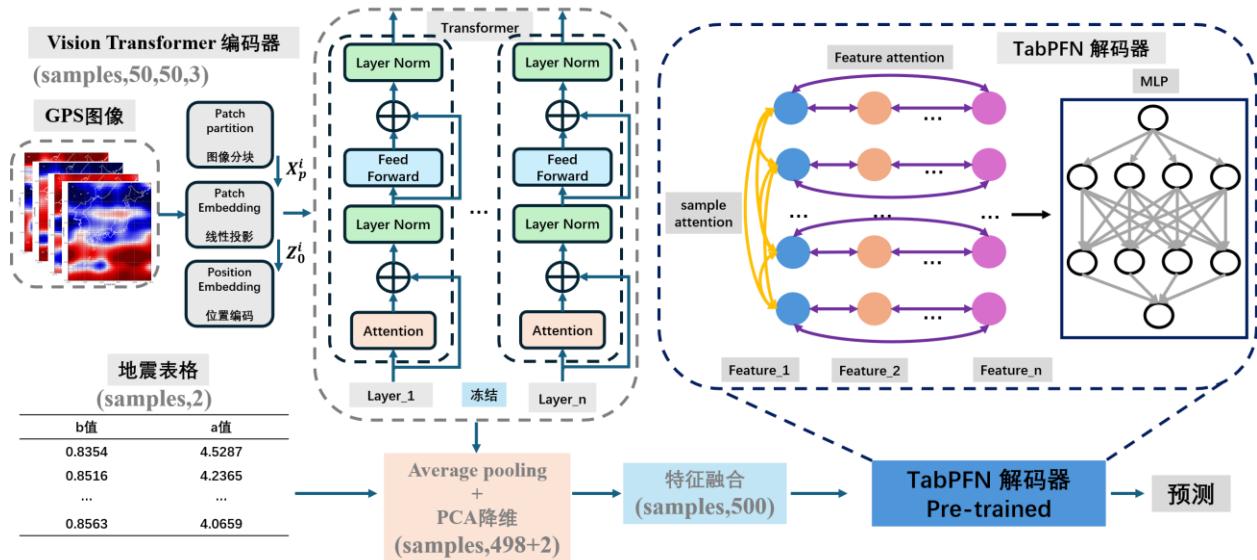


图 5 GeoViT-PFN 深度学习架构，其中编码器为 Vision Transformer (ViT) 处理图像数据，解码器为 TabPFN，处理多模态数据融合信息

Fig 5 GeoViT PFN deep learning architecture, where the encoder is Vision Transformer (ViT) for processing image data, and the decoder is TabPFN for processing multimodal data fusion information

编码器采用 Vision Transformer (ViT)，ViT 将 Transformer 架构应用于图像领域，核心思想是将图像分割为固定大小的图块 (patches)，并将这些图块线性嵌入后作为 Transformer 编码器的输入序列。通过 ViT 编码器，将 GNSS 图像特征提取为适合和二维地

震表格数据进行数据融合的相同格式。GNSS 图像首先被分解为图块后，每个图块通过线性投影转换为向量，通过增加位置编码保留空间信息。其次将处理好的 GNSS 图块放入 Transformer 中通过自注意力机制和多层堆叠进行特征提取。这个过程将图像形状为 (samples,50,50,3) 转换为 (samples,197,768) 的向量形状，再次通过平均池化方法将向量的形状变换为 (samples,768)，这个数据形状符合一般表格数据。这里还考虑到解码器的 TabPFN（下段进行说明）设计，采用了 PCA 主成分分析的技术，将 768 的特征数压缩到 498 个以便于解码器正确处理。这里的 ViT 编码器采用预训练的 Vision Transformer (ViT) 的 vit-base-patch16-224-in21k 版本，由 Google Research 开发并开源（**Dosovitskiy et al, 2021**）。

解码器采用 TabPFN 的 Transformer 架构，TabPFN 是一个专门针对表格数据的预训练模型，在各种任务上都显著超越传统方法（**Hollmann et al, 2025**）。其核心为元学习（Meta-Learning）+ 上下文学习（In-Context Learning, ICL），并且相比于传统方法，其不需要进行参数调整，而是直接根据预训练权重进行使用。该模型采用了双向的注意力机制，通过对表格数据的两个维度分别进行注意力权重的计算。这里我们将生成的 b 值和 a 值表格数据与编码器处理之后的 GNSS 图像数据格式进行拼接，由于 TabPFN 的 Transformer 架构只能处理 500 个特征维度，所以这里我们将 GNSS 的数据形状 (samples,498) 与 b 值和 a 值的数据形状 (samples,2) 进行特征维度上的拼接，即得到总数据形状为 (samples,500) 符合解码器的输入要求。最终通过解码器进行回归预测标签。

3 结果与分析

本文采用决定系数 R^2 (R-Squared) 和均方误差 (Mean Squared Error) 来量化回归预测结果与真实结果之间的差距。其计算公式如下为：

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (24)$$

均方误差 MSE 的计算公式为：

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (25)$$

其中： y_i 为真实值， \hat{y}_i 为预测值， \bar{y}_i 为真实值的均值。

3.1 单模态预测

3.1.1 GNSS 驱动预测

本部分首先尝试单独使用 GNSS 地壳形变图像数据来预测地震活动性变化，我们只输入 GNSS 地壳形变图像数据进入 GeoViT-PFN 模型中进行预测，数据时间长度为 2009 年 1 月 1 日到 2024 年 1 月 1 日。通过 ViT 编码器、平均池化和 PCA 降维的方法，将 GNSS 图像数据编码为形状为(samples, 500)的嵌入，再由解码器 TabPFN 进行预测输出。数据集按照 7: 3 的方式划分训练集和测试集，图 6 展示了 GeoViT-PFN 模型在训练集和测试集上的预测值与真实值分布情况和测试集上的残差分布。分析结果可知，训练集和测试集上的 R^2 分数接近，表明模型没有出现过拟合或欠拟合。残差图中预测值集中在 0.15 到 0.25，这一区域表现良好，但对于样本较少的数据表现较差。说明仅由 GNSS 地壳形变图像数据驱动 GeoViT-PFN 模型无法有效预测地震活动性变化，并且出现了非常明显的系统性偏差。分析原因可能为 GNSS 信号易受非地震灾害和环境变化影响（例如：地下水变化、地下开采、火山活动等），仅凭单一 GNSS 数据源，无法有效学习其中对于地震数据的相关信号特征。

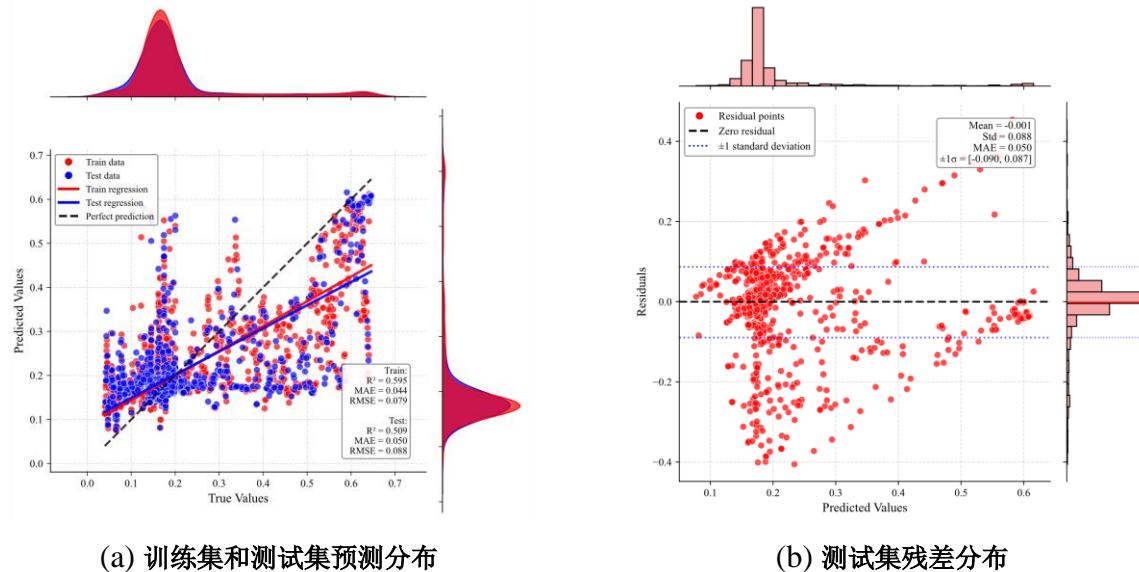


图 6 单模态 GNSS 图像驱动 GeoViT-PFN 模型在训练集和测试集上的表现

Fig 6 Performance of the unimodal GNSS image-driven GeoViT-PFN model on training and test sets

3.1.2 b 值和 a 值驱动预测

本部分尝试单独使用 b 值和 a 值进行预测地震活动性的变化，数据时间长度为 2009 年 1 月 1 日到 2024 年 1 月 1 日。我们只输入 b 值和 a 值的表格数据，所以只使用 TabPFN 的

解码器即可。将形状为(samples, 2)的 b 值和 a 值输入到解码器中进行预测输出。数据集按照 7: 3 的方式划分训练集和测试集, 图 7 展示了 GeoViT-PFN 模型在训练集和测试集上的预测值与真实值分布和测试集上的残差分布。分析结果可知, 训练集和测试集上的 R^2 分数接近, 表明模型没有出现过拟合或欠拟合, 残差图说明预测依然有较大偏差。这说明同样仅凭单一的 b 值和 a 值的地震活动性数据也无法很好预测地震活动性的变化。

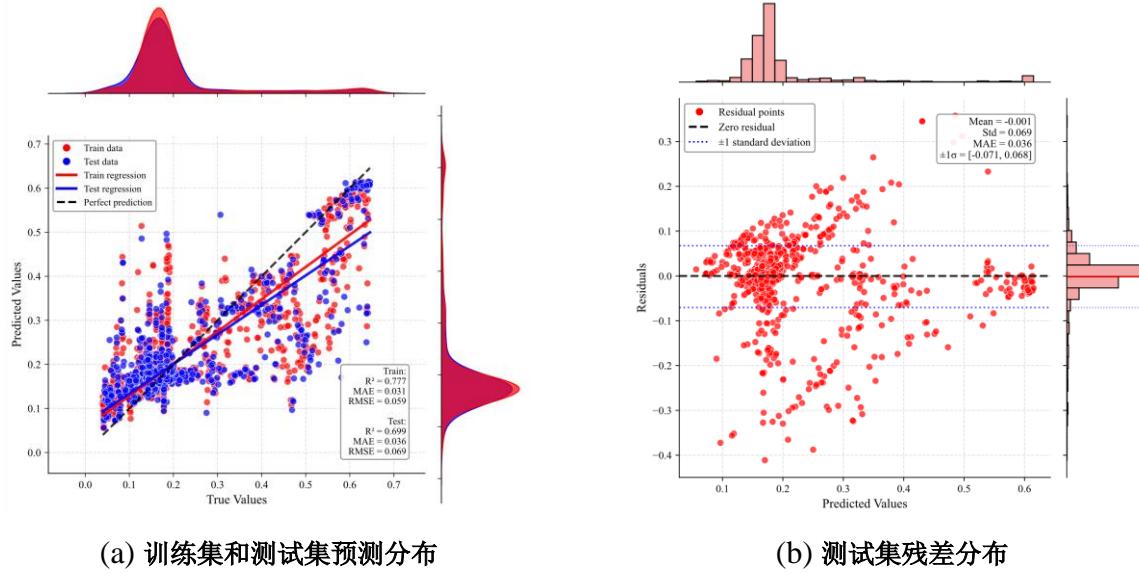
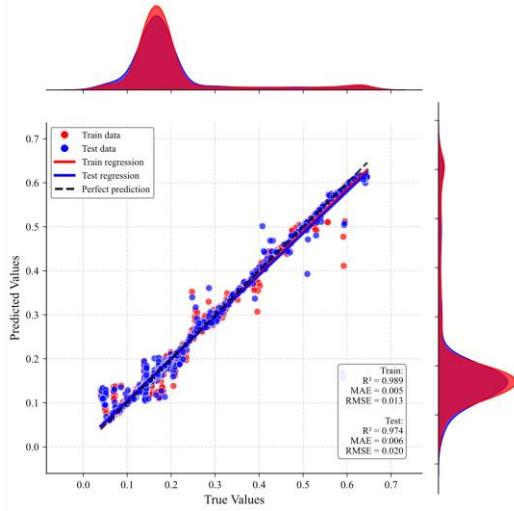


图 7 单模态 b 值 a 值表格数据驱动 GeoViT-PFN 模型在训练集和测试集上的表现

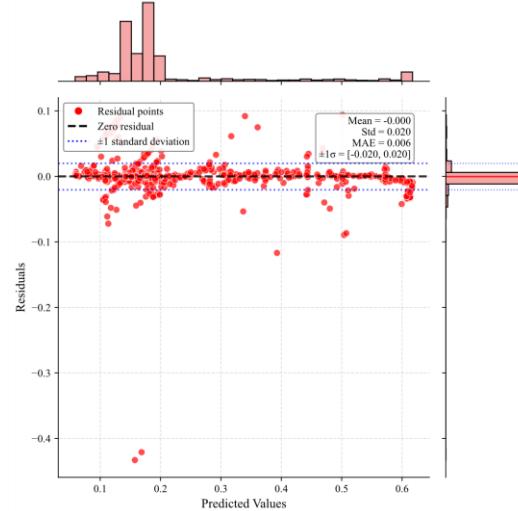
Fig 7 Performance of the unimodal b -value a -value tabular data-driven GeoViT-PFN model on training and test sets 3.2

多模态融合预测

本部分同时使用 GNSS 地壳形变图像数据和 b 值和 a 值的地震活动表格数据输入到 GeoViT-PFN 模型中进行地震活动性的变化预测。数据时间长度为 2009 年 1 月 1 日到 2024 年 1 月 1 日。图 8 展示了 GeoViT-PFN 模型在训练集和测试集上的预测值与真实值分布情况和测试集上的残差分布。可以发现, 将两种不同模态的数据融合之后的预测效果显著增强, 训练集和测试集的拟合 R^2 分别达到了 0.98 和 0.97, 确保模型没有出现过拟合和欠拟合。根据回归直线对比, 说明不存在系统性偏差。由测试集的残差图分析可知, 预测残差呈现出标准的正态分布, 并且样本较少的标签预测性能也有显著提升。说明利用多模态数据并使用 GeoViT-PFN 模型能够准确预测连续的地震频率变化标签, 能够为地震活动分析和地震预报提供一种新指标进行联合判断。



(a) 训练集和测试集预测分布



(b) 测试集残差分布

图 8 多模态 GNSS 图像和 b 值 a 值表格数据驱动 GeoViT-PFN 模型在训练集和测试集上的表现

Fig 8 Performance of the multimodal GNSS image and b-value a-value tabular data-driven GeoViT-PFN model on training and test sets

3.3 解码器模型对比

为了进一步测试 TabPFN 解码器的预测效果，本部分选取在近几年地震活动性预测以及在类似表格任务中表现优秀的模型进行对比（Moghadamnejad et al, 2026），包括随机森林、XGBoost、LightGBM、CatBoost。

3.3.1 单模态预测对比

按照相同方式使用 GNSS 图像数据通过 ViT 进行编码之后输入到随机森林、XGBoost、LightGBM 和 CatBoost 模型解码器中进行预测对比，结果如图 9 所示。分析结果可知，随机森林和 XGBoost 模型在训练集的表现优于 TabPFN，但在测试集上却几乎没有任何预测能力，而 TabPFN 相比之下取得了最好的效果。

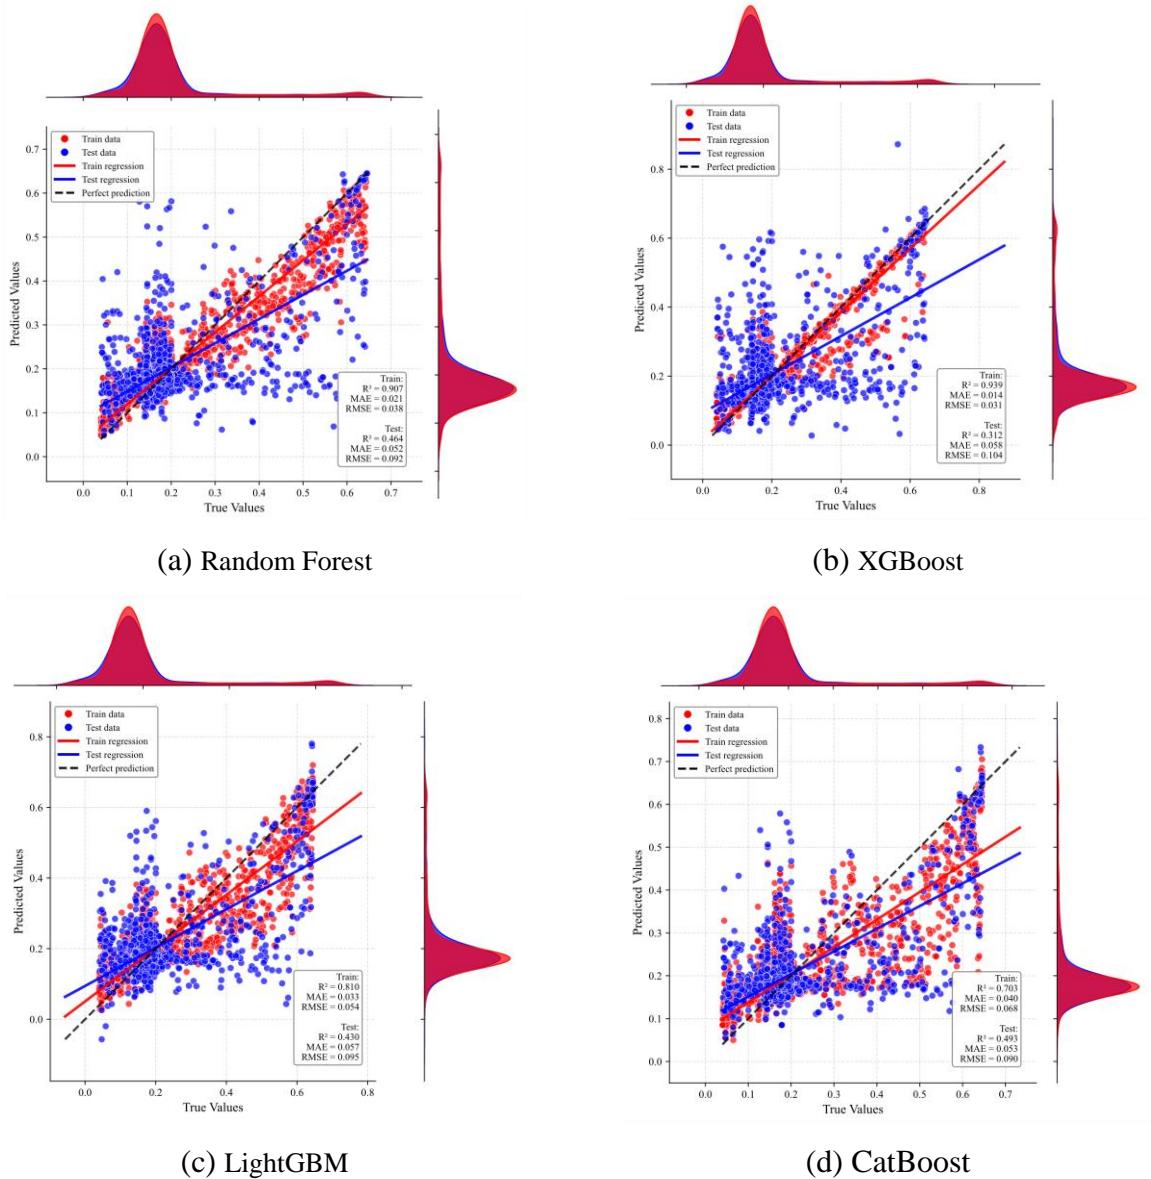


图 9 单模态 GNSS 数据在不同解码器表现

Fig 9 Performance of single-modal GNSS data in different decoders

接着我们将使用 a 值和 b 值的表格数据输入到随机森林、XGBoost、LightGBM 和 CatBoost 模型解码器中进行预测对比，结果如图 10 所示。TabPFN 相比之下也取得了最好的效果。

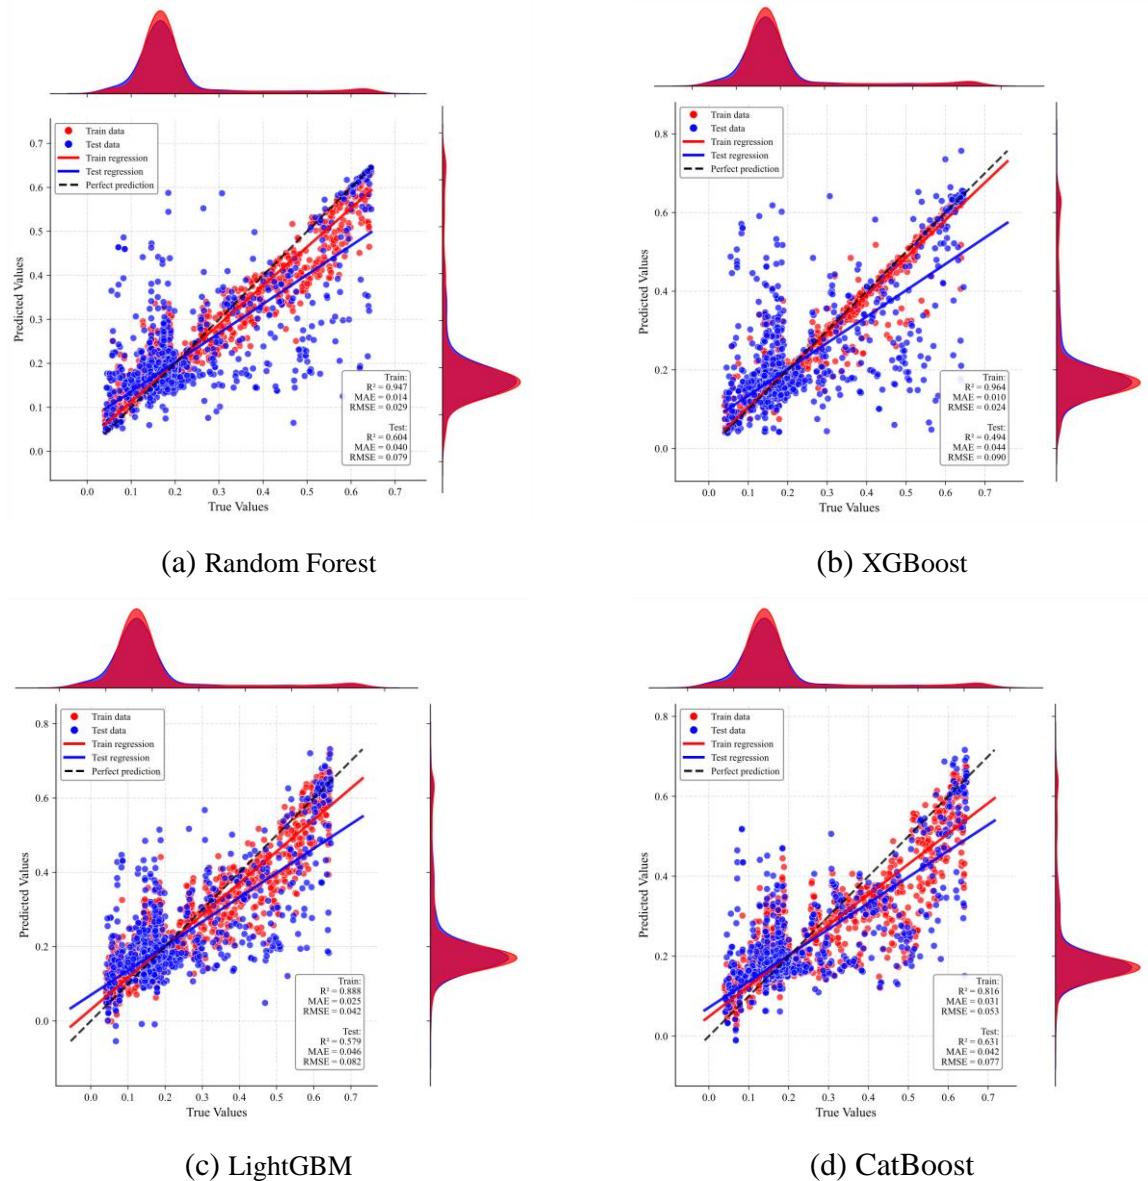


图 10 单模态 a 值 b 值数据在不同解码器表现

Fig 10 Single-modal a-value and b-value data are performed on different decoders

3.3.2 多模态预测对比

依然按照相同的方式使用 GNSS 图像数据通过 ViT 进行编码之后与 a 值 b 值表格数据进行数据融合之后输入到随机森林、XGBoost、LightGBM 和 CatBoost 模型解码器中进行预测对比，结果如图 11 所示。分析结果，TabPFN 取得了最好的效果。

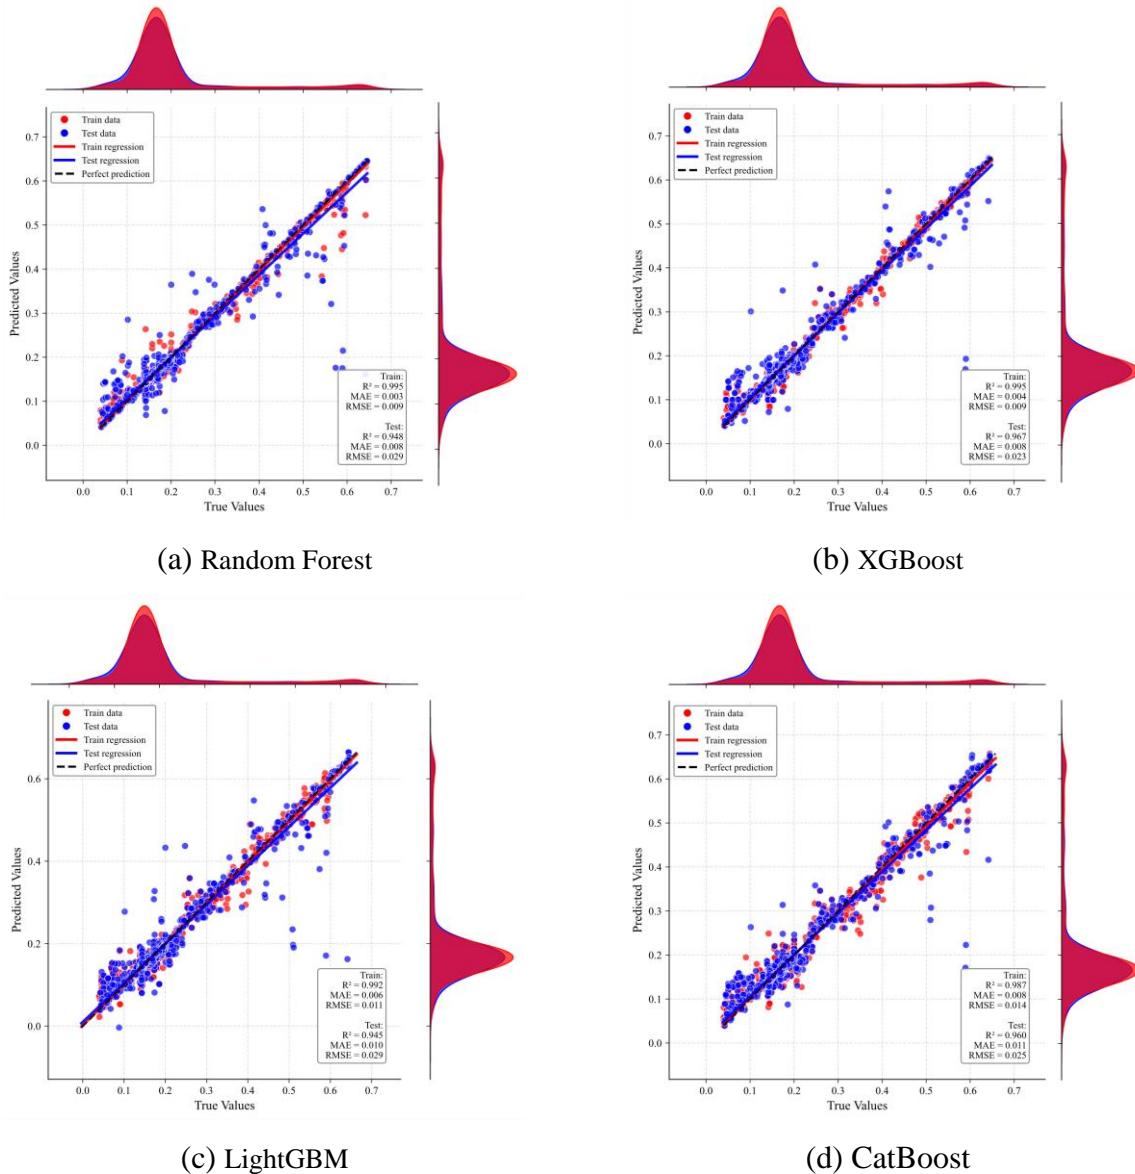


图 11 多模态数据融合在不同解码器表现

Fig 11 Performance of multimodal data fusion in different decoders

3.4 大地震之前的前震现象

前震的定义条件各有不同，包括与主震相关的空间范围定义和发生前多少天的时间范围定义等。主震破裂方式和构造环境的不同也会影响是否有前震（周少辉&蒋海昆，2016；蒋海昆&周少辉，2020）。具有直接前震的地震事件仍占少数，所以本部分无法针对前震作严格的分析。我们仅从地震活动性方面来尝试分析大地震之前的异常表现。

分析标签预测与大地震之间的前兆关系，我们通过 2021 年-2024 年日本三个 Mw7 以上的地震进行分析，如图 12 所示。可以发生随着地震频率概率密度的提升，相应时间段

的地震频率上升，并且随之发生了 Mw7.1、Mw7.0 和 Mw7.3 地震，频率密度在 M7.3 地震发生前后达到最高，之后地震频率概率密度逐渐下降。分析这种情况，在地震发生前的频率上升，可能代表了前震活动频繁，我们随即可视化了从 2020 年到 2022 年震前日本区域的地震事件密度如图 13 和 14 所示，可以发现，大多数地震都集中在三个 7 级以上地震附近，该区域的地震密度显著高于附近，说明出现了显著的区域地震活动性频繁，这在时间上也与相应的预测结果一致。

然而在所选研究时间段中，并非所有的地震事件发生前都有明显地震活动性上升的情况，这也与前震研究的情况符合。

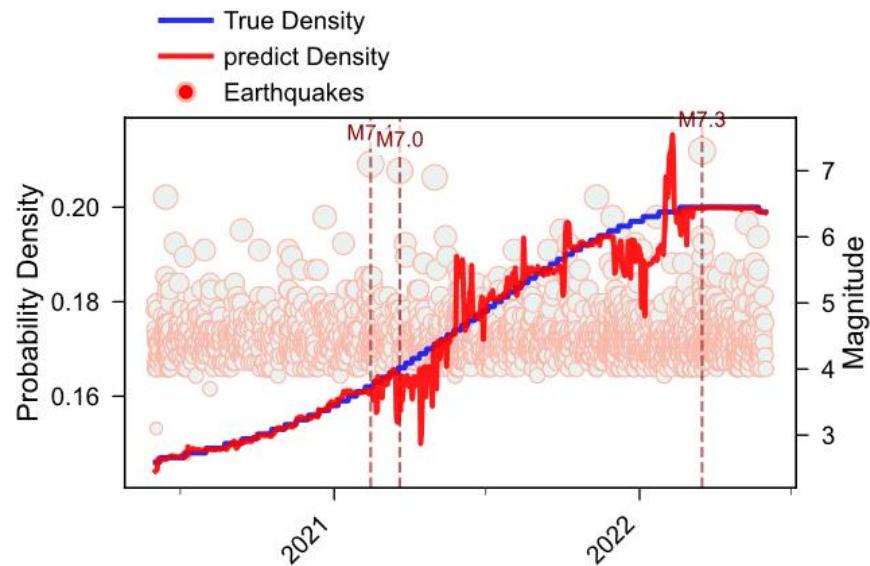


图 12 大地震之前相应时间段地震频率密度提升

Fig 12 Increase in seismic frequency density during the corresponding time period before a major earthquake

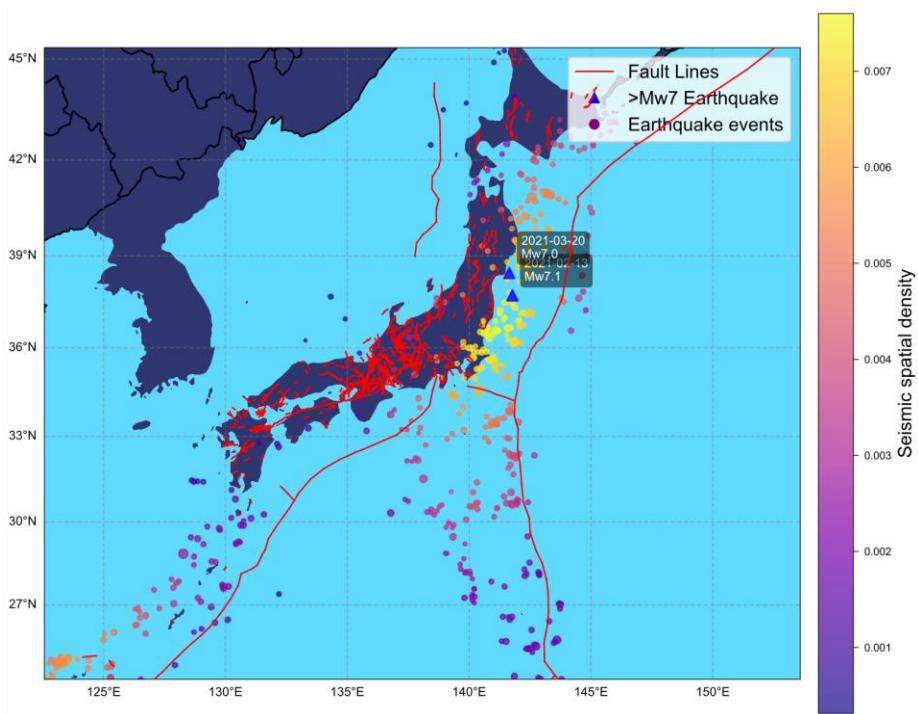


图 13 2020 年 6 月-2021 年 6 月地震事件集中区域

Fig 13 Seismic event concentration area from June 2020 to June 2021

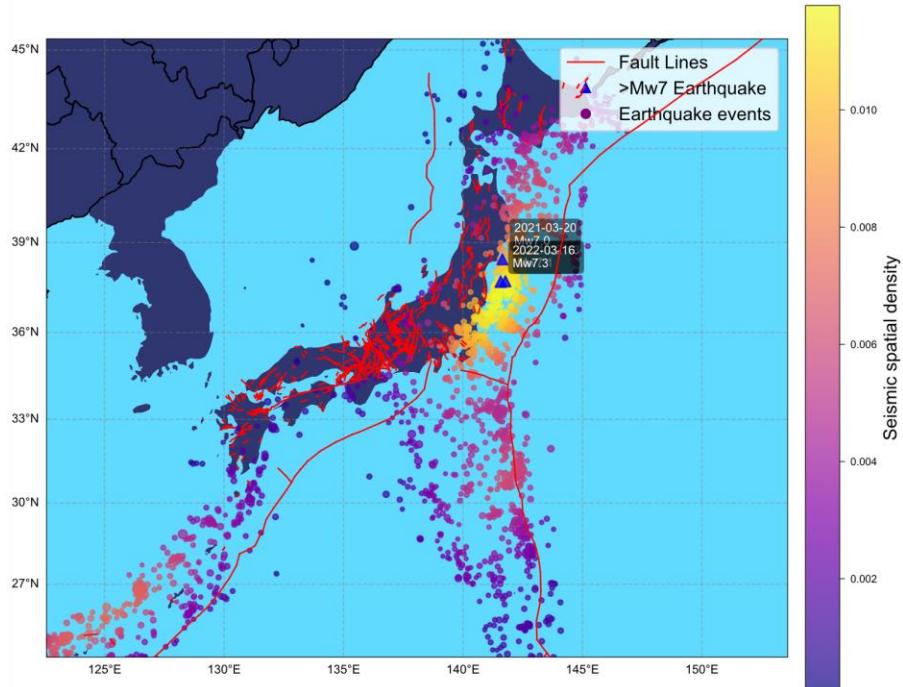


图 14 2020 年 6 月-2022 年 6 月地震事件集中区域

Fig 14 Seismic event concentration area from June 2020 to June 2022

4 结论

本研究针对地震预测中多源数据融合困难及离散地震标签难以对齐的问题，提出了一种基于多模态数据融合的 GeoViT-PFN 机器学习框架。该框架的创新性主要体现在将 GNSS 地表形变数据转换为图像时序，并与地震目录统计特征（如 b 值、 a 值）进行高效融合，从而实现了多模态、跨结构数据的协同学习与联合表征。

实验结果表明，多模态融合策略能够有效整合 GNSS 形变图像与地震参数，在逐日地震活动性密度临近预报（Nowcasting）任务中展现出潜力和协同增强效应。通过对 2021–2024 年日本三次 $M_w \geq 7.0$ 地震的分析，发现地震频率概率密度的上升与主震发生具有时间相关性。然而，并非所有大地震前均出现明显活动性上升，这与已知前震现象的随研究一致，前震并非普适性前兆。

尽管当前模型在 GNSS 数据处理方面存在简化，其结果可靠性仍存在提升空间，但本文所提出的架构已具备良好的可扩展性，未来可直接嵌入 InSAR 形变、地磁、地电等时序或图像模态，通过适配不同编码器实现视频、音频等多格式数据的集成，为构建更全面、物理可解释的多模态地震预测模型提供基础。

参考文献：

- Borate, P., Rivière, J., Marone, C., Mali, A., Kifer, D., & Shokouhi, P. (2023). Using a physics-informed neural network and fault zone acoustic monitoring to predict lab earthquakes. *Nat. Commun.*, 14, 3693. <https://doi.org/10.1038/s41467-023-39377-6>
- Bletery, Q., & Nocquet, J.-M. (2023). The precursory phase of large earthquakes. *Science*, 381(655), 297–301. <https://doi.org/10.1126/science.adg2565>
- Blewitt, G., Hammond, W., & Kreemer, C. (2018). Harnessing the GNSS data explosion for interdisciplinary science. *Eos*, 99(2), e2020943118. <https://doi.org/10.1029/2018eo104623>
- Chen, Y. T. (2007). Earthquake prediction—Progress, difficulties, and prospects. *Seismological and Geomagnetic Observation and Research*, (2), 1-24. (in Chinese with English abstract)
- Chen, Y. C. (2017). A tutorial on kernel density estimation and recent advances. *Biostatistics & Epidemiology*, 1(1), 161-187. <https://doi.org/10.1080/24709360.2017.1396742>

- Chen, Y. T. (2009). Earthquake prediction: Retrospect and prospect. *Science in China Series D: Earth Sciences*, 39(12), 1633-1658. (in Chinese with English abstract)
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghanian, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Houlsby, N. (2021). An image is worth 16x16 words: Transformers for image recognition at scale. *International Conference on Learning Representations (ICLR)*. <https://arxiv.org/pdf/2010.11929/1000.pdf>
- Gu, G. H. (2023). Precursory horizontal deformation before large earthquakes measured by GNS. *S. Earthquake Research in China*, 39(4), 721-731. (in Chinese with English abstract)
- Gao, Y. J., Sun, Y. Q., & Luo, G. (2022). Spatio-temporal evolution of b-values and stress field in the Taiwan region before and after the 1999 Chi-Chi earthquake. *Chinese Journal of Geophysics*, *65*(6), 2137–2152. (in Chinese with English abstract)
- Hollmann, N., Müller, S., Purucker, L., Krishnakumar, A., Körfer, M., Hoo, S. B., ... & Hutter, F. (2025). Accurate predictions on small data with a tabular foundation model. *Nature*, 637(8045), 319-326. <https://doi.org/10.1038/s41586-024-08328-6>
- Huang, P., Lv, W., Huang, R., Luo, Q., & Yang, Y. (2024). Earthquake precursors: A review of key factors influencing radon concentration. *J. Environ. Radioact.*, 271, 107310. <https://doi.org/10.1016/j.jenvrad.2023.107310>
- Hsu, Y. J., Yu, S. B., Simons, M., Kuo, L. C., & Chen, H. Y. (2009). Interseismic crustal deformation in the Taiwan plate boundary zone revealed by GNSS observations, seismicity, and earthquake focal mechanisms. *Tectonophysics*, 479(1-2), 4-18. <https://doi:10.1016/j.tect.2008.11.016>

- Jiang, H. K., & Zhou, S. H. (2020). Foreshocks: Predictive significance and identification methods. *Seismological and Geomagnetic Observation and Research*, 41(5), 222-225. (in Chinese with English abstract)
- Jiang, Z. S., & Liu, J. N. (2010). A method for establishing crustal movement velocity and strain fields using least-squares collocation. *Chinese Journal of Geophysics*, 53(5), 1109, 1116–1117. (in Chinese with English abstract)
- Liu, Z. J., Liu, J., & Shao, Z. G. (2023). Reliable precursory signals of large earthquakes detected by high-frequency GNSS observations? *Chinese Science Bulletin*, 68(33), 4442-4444. (in Chinese with English abstract)
- Li, M. Y., Zeng, X. W., Yao, H. J., et al. (2024). Variation of b-values before and after the September 5, 2022, Luding M6.8 earthquake and its aftershocks in Sichuan, China. *China Earthquake Engineering Journal*, 46(5), 1214–1222. (in Chinese with English abstract)
- Liu, Y., Zhang, H., Li, C., Huang, X., Wang, J., & Long, M. (2024). Timer: Generative pre-trained transformers are large time series models. *arXiv preprint arXiv:2402.02368*.
- Lu, J. Q., Wang, Y. J., Li, S. Y., et al. (2025). An on-site PGV prediction model based on XGBoost. *Earth Science*, 50(5), 1861–1874. (in Chinese with English abstract)
- Mousavi, S. M., Ellsworth, W. L., Zhu, W., Chuang, L. Y., & Beroza, G. C. (2020). Earthquake transformer—an attentive deep-learning model for simultaneous earthquake detection and phase picking. *Nat. Commun.*, 11(1), 3952. <https://doi.org/10.1038/s41467-020-17591-w>
- Ma, Z., 2008. China's natural disasters and mitigation measures(six). *J. of Institute of Disaster-Prevention Science and Technology* 10 (1), 1–4. (in Chinese with English abstract)
- Meyer, D. (2002). Naive time series forecasting methods. *R news*, 2(2), 7-10. <https://journal.r-project.org/articles/RN-2002-008/>

- Moghadamnejad, A., Moghaddasi, M. A., Hamidia, M., Mohammadi, R. K., & Zare, M. (2026). Ranking earthquake prediction algorithms: A comprehensive review of machine learning and deep learning methods. *Soil Dynamics and Earthquake Engineering*, 200(Part A), 109740. <https://doi.org/10.1016/j.soildyn.2025.109740>
- Ruan, Q., Yuan, X., Liu, H., et al. (2023). Study on co-seismic ionospheric disturbance of Alaska earthquake on July 29, 2021 based on GNSS TEC. *Sci. Rep.*, 13, 10679. <https://doi.org/10.1038/s41598-023-37374-9>
- Shi, P., 2002. Theory on disaster science and disaster dynamics. *J. Nat. Disasters* 11 (3), 1–9. (in Chinese with English abstract)
- Shen, Z. K., Wang, M., Zeng, Y., & Wang, F. (2015). Optimal interpolation of spatially discretized geodetic data. *Bulletin of the Seismological Society of America*, 105(4), 2117-2127. <https://doi.org/10.1785/0120140247>
- Tape, C., Liu, Q., Maggi, A., & Tromp, J. (2010). Seismic tomography of the southern California crust based on spectral-element and adjoint methods. *Geophysical Journal International*, 180(1), 433-462. <https://doi:10.1111/j.1365-246X.2009.04429.x>
- Wang, J. H., & Jiang, H. K. (2023). A review of machine learning-based earthquake prediction research based on seismic observation data. *Journal of Seismological Research*, 46(2), 173-187. <https://doi.org/10.20015/j.cnki.issn1000-0666.2023.0022>(in Chinese with English abstract)
- Wang, Q., Xu, X., Jiang, Z., et al. (2020). A possible precursor prior to the Lushan earthquake from GNSS observations in the southern Longmenshan. *Sci. Rep.*, 10, 20833. <https://doi.org/10.1038/s41598-020-77634-6>

Wang, K. Y., Jin, M. P., Huang, Y., et al. (2021). Spatio-temporal evolution of the May 21, 2021, Yangbi MS6.4 earthquake sequence in Yunnan, China. *Seismology and Geology*, *43*(4), 1030–1039. (in Chinese with English abstract)

Wu, Z., Xu, T., Liang, C., Wu, C., & Liu, Z. (2018). Crustal shear wave velocity structure in the northeastern Tibet based on the Neighbourhood algorithm inversion of receiver functions. *Geophysical Journal International*, 212(3), 1920-1931. <https://doi.org/10.1093/gji/ggx521>

Zhao, J. D., & Zhang, Z. Q. (2009). Development, application, and implications of earthquake early warning systems. *Geological Bulletin of China*, 28(4), 456-462. (in Chinese with English abstract)

Zhou, S. H., & Jiang, H. K. (2016). A review of research progress on foreshocks. *Earthquake*, 36(3), 1-13. (in Chinese with English abstract)

Zhu, J. B., Li, S. Y., & Song, J. D. (2025). A multi-modal deep learning-based prediction model for instrumental seismic intensity in China. *Earth Science*, 1–20. [Online first]. Retrieved August 13, 2025. (in Chinese with English abstract)

中文参考文献：

陈运泰.地震预测——进展、困难与前景[J].地震地磁观测与研究,2007,(02):1-24.

赵纪东,张志强.地震预警系统的发展、应用及启示[J].地质通报,2009,28(04):456-462.

王锦红,蒋海昆.基于地震观测数据的机器学习地震预测研究综述[J].地震研究,2023,46(02):173-187.DOI:10.20015/j.cnki.issn1000-0666.2023.0022.

陈运泰.地震预测:回顾与展望[J].中国科学(D辑:地球科学),2009,39(12):1633-1658.

顾国华.GNSS 测得的大地震前兆水平形变[J].中国地震,2023,39(04):721-731.

刘志军,刘静,邵志刚.高频 GNSS 观测发现可靠的大地震前兆信号[J].科学通报,2023,68(33):

4442-4444.

蒋海昆,周少辉.前震:预测意义及识别方法[J].地震地磁观测与研究,2020,41(05):222-225.

周少辉,蒋海昆.前震研究进展综述[J].地震,2016,36(03):1-13.

李蒙亚,曾宪伟,姚华建,等.2022年9月5日四川泸定6.8级地震及其余震前后b值变化[J].地

震工程学报,2024,46(05):1214-1222.

王凯英,金明培,黄雅,等.2021年5月21日云南漾濞MS6.4地震序列的时空演化[J].地震地

质,2021,43(04):1030-1039.

高雅婧,孙云强,罗纲.1999年集集地震前后台湾地区地震b值及应力场时空演化特征[J].地球

物理学报,2022,65(06):2137-2152.

江在森,刘经南.应用最小二乘配置建立地壳运动速度场与应变场的方法[J].地球物理学

报,2010,53(05):1109+1116-1117.

陈建玮,陈国雄,王德涛,等.基于 BiX-NAS 的地震层序智能识别——以荷兰近海地区 F3 数据

为例[J].地球科学,2023,48(08):3162-3178.

胡进军,丁祎天,张辉,等.基于长短期记忆神经网络的实时地震烈度预测模型[J].地球科

学,2023,48(05):1853-1864.