

基于 ConvNeXt+GRU 的震后次生地质灾害易发性动态评估

游 巧^{1,2} 黄 猛^{1,2} 崔珂玮^{1,2}

YOU Qiao HUANG Meng CUI Kewei

摘 要

为提升雅安地区震后次生地质灾害易发性评估精度,揭示地震、地质与水文条件间的时空动态关联,文章提出一种结合注意力机制的 ConvNeXt+GRU 模型,用于评估地震次生地质灾害易发性。首先将西南地区近 20 年 17 905 个震后次生地质灾害与非灾害样本点划分为训练集、验证集与测试集,基于专家知识、特征重要性与独立性分析,选取地震、地质、水文等 13 类时空特征作为模型输入。随后对空间与时序特征分别处理:在时序特征处理中引入 GRU (gated recurrent unit) 循环神经网络与时间注意力机制以突出关键降雨时段;随后将降雨序列与其他静态空间特征拼接,采用 stem 卷积层扩展特征通道,并利用 SE (squeeze-and-excitation) 模块自适应调整通道权重以提升对关键特征类型的识别。最后通过多尺度特征融合与 Sigmoid 函数计算易发性评估结果。计算结果结合每 5 min 更新 1 次的网格化气象雷达数据进行动态更新。通过 ROC 曲线、易发性等级分布与灾害等级频率比评估模型效果。结果表明:ConvNeXt+GRU 模型准确率达 89.8%,优于 ConvNeXt+LSTM、ConvNeXt、CNN+GRU 和 BPNN 模型。在 2022 年泸定 6.8 级地震、2022 年芦山 6.1 级地震、2017 年九寨沟 7.0 级地震震例进行泛化验证,准确率分别达 89.0%、88.2% 与 86.3%,该模型对提升震后次生地质灾害风险识别与防控能力具有一定作用。

关键词 ConvNeXt; GRU; 注意力机制; 震后次生地质灾害

doi: 10.3969/j.issn.1672-9528.2026.04.039

0 引言

雅安市地处四川盆地与青藏高原的地质过渡带,山高谷深,地质构造复杂。作为西南地区著名的“雨屏”,该市年均降水量达 1 800 mm^[1],区域内雨量充沛,天气多变。同时,雅安位于鲜水河-龙门山地震带交汇处,属于地震活跃区,地震灾害频发。较大的高差、陡峭的地形和丰沛的降雨加剧了地质构造的脆弱性,地震发生后,在强降雨或持续降雨影响下极易引发崩滑泥石流等震后次生地质灾害,从而放大震害风险。2013 年 4 月 20 日 8 时 02 分,雅安市芦山县发生 7.0 级地震,其间伴有小到中雨,截至 4 月 23 日 16 时,共发生崩塌、滑坡 355 处^[2];2022 年 6 月 1 日,芦山县太平镇北部发生 6.1 级地震,此次地震前曾有持续降雨,增加了土壤饱和度,导致滑坡和崩塌 143 处^[3-4]。

开展震后次生地质灾害易发性评估对于地震应急和灾害防治至关重要^[5-6]。准确评估震后次生地质灾害易发性的核心难点,在于如何有效分析特征间复杂的耦合机制。地震作为

主要触发因素,释放的能量会瞬间改变地质体稳定性;地形与地质条件为灾害提供孕育环境;降雨等水文气象因子则进一步诱发地质灾害。而降雨的强度、持续时间,其时空分布又具有高度时变特征,会动态非线性地改变不同区域地质灾害易发性。

近年来,机器学习与深度学习的应用推动了该领域国内外研究进展。例如 Ullah 等^[7-8]采用线性回归、逻辑回归和 SVM 等方法,结合遥感与 GIS 数据对阿伯塔巴德地区滑坡易发性进行评估,结果表明该区域地质灾害易发性受地震与气候因素共同影响,且线性回归模型精度更高。随着深度学习发展,神经网络逐渐应用于地质灾害评估。Chang 等^[9]通过野外调查、航空影像与斜坡圆方差分析地貌特征,并采用 CNN 与 GIS 技术构建了喀斯特地区滑坡风险评估模型,经野外调查进行了验证;张迎宾等^[10-12]利用 ArcGIS 分析九寨沟震后滑坡空间分布及影响因素,然后采用 BP 神经网络进行了滑坡风险评价。尽管现有研究在地震、地形、水文等多源数据融合方面取得了进展,但易发性评估模型多依赖于环境因子的静态快照。常用指标如累计降雨量、降雨持续时间等往往忽略雨强动态变化等内部细节,导致在捕捉“震害-降雨”耦合机制时存在偏差^[13-14],难以充分融合地震冲击、地形脆弱性与震后降雨

1. 防灾科技学院 河北廊坊 065201

2. 河北省高校智能应急应用技术研发中心 河北廊坊 065201

[基金项目] 河北省硕士在读研究生创新能力培养项目 (ZY20250324)

随时间变化的复杂相互作用，从而限制了现有模型对震后地质灾害时空演化规律捕捉的准确性。

在时空数据方面，Wang 等^[15-17]指出当前研究多忽视环境因子，以三峡库区八字门滑坡为例，结合 CNN（convolutional neural networks）与 LSTM（long short-term memory）模型构建了时空风险演化模型。

此外在卷积神经网络方面，2022 年提出的 ConvNeXt 模型，通过渐进式通道扩展与深度可分离卷积增强了对复杂数据的建模能力^[18]。在此基础上，Chen 等^[19-20]对比了 ConvNeXt、FCN（fully convolutional networks）等模型在云南地区遥感影像数据上滑坡识别的效果，其中 ConvNeXt 精度最高且泛化能力最优。尽管 ConvNeXt 主要用于图像识别，但其特征提取技术也可迁移至其他领域。何彩虹等^[21-22]优化了 ConvNeXt 卷积层数量和卷积核大小，提升了对含噪飞行数据的评估精度。ConvNeXt 作为改进的 CNN 架构，与轻量化 LSTM 变体 GRU 结合，在震后地质灾害评估中具有应用潜能。

综上所述，现有研究在多源数据融合的灾害识别与评估方面已取得初步进展，但尚未充分捕捉地震、地形与降雨数据间的相互作用，限制了模型的准确性与时空表征能力。因此，本研究拟融合 ConvNeXt 卷积网络、GRU 循环网络与注意力机制，提取多尺度时空特征，并结合实时气象数据动态更新评估结果，实现震后次生地质灾害易发性的有效评估。

1 特征选取

1.1 数据来源

震后次生地质灾害数据是建立震后次生地质灾害动态易发性评价模型的基础。鉴于雅安地区地质灾害点数量有限，因此扩展数据收集范围，纳入地形地貌特征相似的其他西南地区数据用于模型训练。共收集整理 2000—2025 年 3 181 个震后次生地质灾害点。

基于应急管理局地质环境保护与地质灾害防治国家重点实验室学者的研究成果^[23-29]，选取地震三要素、地质条件、降雨条件等核心数据作为主要影响因素。其中，降雨条件由降雨事件的若干相关属性构成。本文将一次降雨事件定义为一段连续的降雨过程，其终止时间即为地质灾害发生时间，其开始时间则根据灾前各降雨时段之间的间隔来确定。若相邻降雨时段的间隔未超过当地汛期平均连续干燥日，则这些时段被视为同一降雨事件^[30]。

不同来源的数据，通过发生时间、地理位置等信息进行相互关联。通过空间网格化方法，将收集后的数据归一化为 30 m × 30 m 的网格单元。震后次生地质灾害相关信息数据来源如表 1 所示。

表 1 震后次生地质灾害相关信息数据来源

数据类型	数据来源	分辨率	数据格式
雅安市地质 灾害编录	四川省雅安市应急管理局	0.000 001°	Excel
地震	中国地震台网	—	Excel
降雨	欧洲中期天气预报中心	0.1°	NetCDF
DEM	地理空间数据云	30 m	grid
土地利用	国家青藏高原科学数据中心	250 m	tiff
断裂带	四川省雅安市应急管理局	—	Geojson
岩性	中国地质资料馆	1:200 000	

根据基础数据与前人研究，选择的特征如表 2 所示。

表 2 震后次生地质灾害易发性特征

基础数据	特征	类型
地震	震级	诱发特征
	震源深度	
	震中距	
降雨	降雨持续时间	诱发特征
	累积降雨量	
	年均降雨量	
DEM	坡度	环境特征
	坡向	
	海拔	
	高差	
土地利用	距水系距离	环境特征
	植被覆盖率	
	土地利用类型	
断裂带	距活动断裂带距离	环境特征
岩性	岩性	环境特征

1.2 非地质灾害点选取

地理学第一定律指出，地理目标变量的属性具有空间相关性，即相互靠近的位置比远离的位置更可能具有相似的属性值^[31]。这一空间聚类现象在次生地质灾害的相关研究中已得到证实^[32-33]。基于该原理，本研究采用逆频比（OFR）抽样法选取非地质灾害点，在高密度灾害区选取较少非灾害点，在低密度灾害区选取较多非灾害点^[34]。以震中距为基础，每 5 km 半径范围划分为独立区域。非灾害样本数量的计算公式为：

$$OFR_i = \frac{1 - N_f(i)/N_f}{S_i/S}$$

(1)

$$N_{nf}(i) = N_f \times \frac{OFR_i}{\sum_{i=1}^n OFR_i}$$

(2)

式中：OFR_{*i*} 为区域 *i* 内非地质灾害点的逆频比；N_{*f*}(*i*) 为区域 *i* 内震后次生地质灾害点数量；N_{*f*} 为震后次生地质灾害点总数；S_{*i*} 为区域 *i* 面积；S 为地震烈度 6 度及以上区域的总面积；N_{*nf*}(*i*) 为区域 *i* 内非灾害点数量。

依据 2000—2025 年中国西南地区的 3 181 个震后次生地质灾害点,共选取 14 724 个非灾害点。

1.3 特征重要性分析

将震后次生地质灾害点与非地质灾害点混合,按 8:1:1 划分训练集、验证集和测试集。为避免数据暴露,仅对训练集数据进行初步特征分析。

特征重要性分析能够找到影响灾害发生的主要因素,剔除相关性较低的特征有助于提升震后次生地质灾害易发性评估的计算效率和准确性。由于逻辑回归、线性分离和随机森林等方法仅能处理线性或非线性单一关系,而特征间具体关联机制尚不明确,因此采用主成分分析法(PCA)进行分析。选取贡献率超过 85% 的主成分,并利用载荷矩阵计算原始特征权重,以分析各特征重要性^[30]。计算过程如式(3)~(7)所示。

$$C = \frac{1}{n-1} X^T X_{\text{centered}} \quad (3)$$

$$C v_i = \lambda_i v_i \quad (4)$$

$$\text{contribution}_i = \frac{\lambda_i}{\sum_{j=1}^p \lambda_j} \quad (5)$$

$$L = C V \quad (6)$$

$$w_i = \frac{\sum_{j=1}^m |l_{ij}|}{\sum_{i=1}^p \sum_{j=1}^m |l_{ij}|} \quad (7)$$

式中: C 为协方差矩阵; n 为灾害点总量 2 544; X 为数据矩阵,每一行表示一个灾害点,每一列表示一个特征; X_{centered} 为中心化后的数据矩阵,即每个特征值减去对应特征均值的结果; V 为特征向量矩阵; v_i 为第 i 个特征向量; λ_i 为 v_i 对应的特征值; contribution_i 为第 i 个主成分特征的贡献率; L 为 $p \times m$ 大小的载荷矩阵; p 为原始特征数量,值为 16; m 为选取的主成分数量; w_i 为第 i 个原始特征的权重; l_{ij} 为第 i 个原始特征在第 j 个主成分上的载荷系数。

结果表明,年平均降雨量权重值为 0.017 7,低于 0.03,其重要性较低,因此剔除该特征^[35]。特征权重计算结果如图 1 所示。



图 1 基于主成分分析的震后次生地质灾害易发性评估特征权重

1.4 特征共线分析

为确保特征间的独立性,采用皮尔逊相关系数法计算特征间的相关性,用公式表示为:

$$r_{ij} = \frac{\sum_{k=1}^n (X_{ik} - \bar{X}_i)(X_{jk} - \bar{X}_j)}{\sqrt{\sum_{k=1}^n (X_{ik} - \bar{X}_i)^2 \sum_{k=1}^n (X_{jk} - \bar{X}_j)^2}} \quad (8)$$

式中: X_{ik} 和 X_{jk} 表示第 k 个灾害点的第 i 和第 j 个特征值; $\bar{X}_i$ 和 $\bar{X}_j$ 表示第 i 和第 j 个特征的平均值; n 表示灾害点数量,值为 2 544。计算结果如图 2 所示。




图 2 15 个选定地质灾害因子的 Pearson 相关矩阵

根据统计学标准,当相关系数绝对值小于 0.7 时^[9],可判定变量间存在多重共线性。计算结果中,海拔与高差之间存在共线性关系,基于特征重要性分析结果,剔除高程特征。最终共保留震级、震源深度、震中距、累计降雨量、连续降雨时长、坡度、坡向、高差、距水系距离、植被覆盖率、土地利用类型、距活动断裂带距离以及岩性 13 个关键特征。

2 基于时空注意力机制的 ConvNeXt+GRU 模型构建

2.1 模型概述

训练集共包含 2 544 个震后次生地质灾害点与 11 779 个非灾害点,总计 14 323 条数据。为缓解样本量有限导致的过拟合风险,在模型训练中采用 Dropout 和早停技术。其中 Dropout 率设为 0.2,通过随机丢弃部分神经元防止神经元间形成复杂关系,提升模型泛化能力;当验证损失连续 5 个 epoch 未下降时终止训练。

模型以 ConvNeXt 网络架构为基础,针对多源地质灾害数据的时空特征进行优化。模型输入特征指标包括如地震三要素、地质灾害和水文流域等空间,以及降雨时序特征。统一卷积核难以适配空间-时序特征的不同尺度特性,进而导致特征提取不充分,降低模型对时空特征的学习能力。此外,由于降雨具有空间和时间特征,首先提取空间特征可能会稀释降雨数据中的重要信息。因此将降雨与其他特征分别处理。对于具有时间特征的降雨数据,首先使用 GRU 网络和时序注意力机制进行特征提取,然后将其与标准化后的地震及地

质特征拼接；经通道扩展后，通过通道注意力机制自动调整权重分配；最后通过多层 block 卷积、全连接层和 sigmoid 激活函数提取多尺度特征，计算震后次生地质灾害易发性。整体模型结构如图 3 所示。

2.2 降雨时序特征提取

GRU 相比 LSTM (long short-term memory) 和 RNN (recurrent neural networks) 具有更少的参数和更快的训练速度，能够高效地捕捉输入序列中的长期依赖关系。因此采用 GRU 门控循环单元进行降雨时序特征建模。为有效表征降雨动态的复杂时序模式，模型须具备足够的隐藏状态维度，从而实现对长周期降雨特征的鲁棒性表达。为平衡特征提取程度与模型计算效率，将隐藏层维度设定为 64。GRU 网络由多个级联单元结构构成，通过门控机制实现状态传递与迭代。每个单元接收前一时间步降雨数据隐藏状态和当前时刻观测降雨强度。计算过程如式 (9) ~ (12) 所示。

$$\mathbf{z}_t = \sigma(\mathbf{W}_z \cdot [\mathbf{h}_{t-1}, \mathbf{r}_t] + \mathbf{b}_z) \quad (9)$$

$$\mathbf{r}_t = \sigma(\mathbf{W}_r \cdot [\mathbf{h}_{t-1}, \mathbf{r}_t] + \mathbf{b}_r) \quad (10)$$

$$\tilde{\mathbf{h}}_t = \tanh(\mathbf{W}_h \cdot [\mathbf{r}_t \times \mathbf{h}_{t-1}, \mathbf{r}_t] + \mathbf{b}_h) \quad (11)$$

$$\mathbf{h}_t = (1 - \mathbf{z}_t) \times \mathbf{h}_{t-1} + \mathbf{z}_t \times \tilde{\mathbf{h}}_t \quad (12)$$

式中： $\mathbf{z}_t$ 为更新门，表示 t 时刻历史降雨特征与当前降雨量的混合比例； $\mathbf{r}_t$ 为重置门，由 64 维向量表示，当某一维接近 0 时表示对应历史降雨特征被舍弃，接近 1 时表示完整保留该历史特征； $\mathbf{h}_{t-1}$ 为 64 维向量，表示 $t-1$ 时刻隐藏状态，编码了历史降雨累积效； $[\]$ 表示两个向量链接； $\cdot$ 表示两个矩阵相乘； $\times$ 表示两个矩阵中的对应元素相乘； σ 和 $\tanh$ 分别表示 sigmoid 和 tanh 激活函数； $\mathbf{W}$ 和 $\mathbf{b}$ 分别表示可训练权重和

偏置项。

关键时段降雨数据对地质灾害演化趋势预测准确度具有显著影响。例如累计降雨量均为 120 mm，一种情况为地震后 24 h 内，3 h 降雨量达 100 mm，其余 21 h 降雨速率约为 1 mm/h；另一种情况为 20 h 内均匀降雨，每小时 6 mm。前者可能因短时强降雨的侵蚀作用更具危险性。因此，在 GRU 网络后引入时序注意力机制，可对每个时间步的输出序列动态分配权重，使模型聚焦于关键时段以获得更精准的预测结果。

针对可变长度序列，采用 Padding 填充，批长度由所有降雨持续时间的众数 t_M 决定。短于此长度的序列在起始处补零，超过此长度的序列截断后分批处理。时序注意力机制的输入为 GRU 的输出序列，其维度为 $(t_d, 64)$ ，其中 t_d 表示连续降雨历时。输出 RAIN，为基于注意力权重的各时间步特征的加权和。计算过程如式 (13) ~ (15) 所示。

$$\mathbf{e}_t = \mathbf{W} \cdot \mathbf{h}_t \quad (13)$$

$$\alpha_t = \frac{\exp(\mathbf{e}_t)}{\sum_{i=1}^T \exp(\mathbf{e}_i)} \quad (14)$$

$$\text{RAIN} = \sum_{t=1}^T \alpha_t \odot \mathbf{h}_t \quad (15)$$

式中： $\mathbf{e}_t$ 为每个时间步的注意力分数； α_t 为通过 Softmax 函数将 $\mathbf{e}_t$ 转化的概率分布，表示每个时间步的重要性权重，进行归一化后所有 α_t 之和为 1； $\odot$ 为两个矩阵逐元素相乘。

2.3 时空特征融合与通道扩展

为确保不同来源的特征向量能够在统一的维度空间中进行有效的运算，对坡度、海拔等空间特征值进行编码。为避免特征之间量纲差异，首先进行特征标准化处理。然后将标




图 3 基于时空注意力机制的 ConvNeXt+GRU 模型

准化后的数据进行单一值扩展, 转换成 64 维的向量, 并与时序注意力机制加权后的降雨特征进行维度对齐拼接。拼接后的特征矩阵维度为 13×64 , 即每个地质灾害点包含 13 个特征, 每个特征表示为 64 维向量。

为避免直接使用二维卷积核带来的无效感知, 对 ConvNeXt 的 Stem 卷积模块进行改进。采用两层一维卷积, 通过渐进式特征融合逐步扩展通道。第一层卷积使用 16 个 7×1 大小卷积核, 步幅为 4。结合 ReLU 激活函数, 初步建立特征间非线性交互, 捕获局部模式特征。通道数从 13 扩展至 16, 输出特征向量长度为 16。第二层卷积使用 32 个 3×1 大小卷积核, 步幅为 2, 深度聚合跨通道信息以增强全局表征能力。通道数从 16 扩展至 32, 特征向量长度变化为 8。

2.4 基于通道注意力机制自适应特征加权

在复杂地质灾害场景中, 不同特征的重要性并不固定。例如, 2008 年汶川 8.0 级地震中, 震级、震中距、活动断裂带距离等地质特征发挥决定性作用; 而 2013 年芦山 7.0 级地震中, 降雨、地形坡度等特征增加了震后地质灾害发生的可能性。

为实现对关键特征重要性的自适应学习, 引入 SE (squeeze-and-excitation) 通道注意力机制进行特征加权。SE 通道注意力机制分为压缩、激励和缩放 3 个阶段。压缩阶段通过全局平均池化操作, 将 32 个特征通道的每个 8 维特征向量, 通过平均值压缩为一个单一数值, 作为该通道的全局特征, 生成 32 维通道特征 $\mathbf{y}_{\text{gap}} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_{32}]$ 。激励阶段首先将压缩后的 32 个通道特征输入到一个降维全连接层中, 概括为 2 个核心组合^[36]; 然后通过 ReLU 函数非线性变化, 将负特征归零, 剔除无关或矛盾的特征; 最后通过一个升维全连接层将低维特征重新映射回原始的 32 维, 恢复原始通道维度, 并利用 sigmoid 激活函数将每个通道的注意力权重限制在 $[0, 1]$ 范围内。缩放阶段将每个通道的特征与相应的通道权重相乘。输出特征维度为 $(1, 32, 8)$ 。

2.5 模型损失函数与权重调整

由于训练数据评估结果仅包含发生与不发生两种情景, 模型采用损失熵价差公式计算预测值与真实结果之间的误差, 若误差过大则调整权重并重新训练。二元交叉熵损失函数的计算公式为:

$$\text{Loss} = \frac{1}{N} \sum_{i=1}^N (-[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})]) \quad (16)$$

式中: N 为训练集的数量 14 323; y 为数据集输出结果 1 或 0, 表示次生地质灾害发生或不发生; $\hat{y}$ 为 $[0, 1]$ 区间内模型预测的概率值, 表示灾害易发性大小。

本模型采用 Lion 优化器^[20]进行参数梯度调整, 该优化器通过引入动量机制减少训练过程中的振荡, 能够在梯度较小区域实现稳定更新, 从而帮助模型更快收敛至最优解。

Lion 优化器计算过程如式 (17) ~ (19) 所示。

$$\mathbf{m}_t = \beta_1 \mathbf{m}_{t-1} + (1 - \beta_1) \mathbf{g}_t \quad (17)$$

$$\mathbf{u}_t = \text{sign}(\beta_1 \mathbf{m}_{t-1} + (1 - \beta_1) \mathbf{g}_t) \quad (18)$$

$$\theta_t = \theta_{t-1} - \eta(\mathbf{u}_t + \lambda \theta_{t-1}) \quad (19)$$

式中: $\mathbf{m}_t$ 表示在第 t 次迭代时的梯度历史平均, 帮助优化器在更新参数时考虑历史梯度信息; β_1 表示用于控制一阶矩中历史梯度信息的影响程度; $\mathbf{g}_t$ 表示在第 t 次迭代时的梯度向量; $\mathbf{u}_t$ 表示第 t 次迭代时的符号动量, 通过取梯度的符号简化更新过程; θ_t 表示在第 t 次迭代时的模型参数; η 表示学习率, 决定每次迭代参数更新的步长; λ 表示权重衰减系数, 用于防止模型过拟合。

2.6 震后次生地质灾害易发性等级划分

模型通过多层块卷积提取多尺度特征后, 采用 Sigmoid 分类器和全连接层将地质灾害易发性评估结果映射至 $[0, 1]$ 区间。为使计算结果更具直观指导意义, 采用自然断点法将震后次生地质灾害易发性结果划分为五个等级: 极低易发区 $[0, 0.2]$ 、低易发区 $[0.2, 0.4]$ 、中易发区 $[0.4, 0.6]$ 、高易发区 $[0.6, 0.8]$ 和极高易发区 $[0.8, 1]$ ^[37]。

3 实验与结果分析

3.1 实验环境

本研究使用 TensorFlow 2 构建试验模型, 并在一台配备 NVIDIA GeForce RTX 3080 GPU、第 12 代 Intel(R) Core(TM) i7-12700H 2.30 GHz CPU、16 GB 内存和 512 GB 固态硬盘的计算机上进行实验。

3.2 评价指标

本研究采用 ROC 曲线及其对应的 AUC 值, 以易发性等级分布及频率比作为模型性能的主要评价指标。ROC 曲线通过绘制真正例率 (TPR) 与假正例率 (FPR) 之间的关系, 评估模型在不同阈值设置下识别震后次生地质灾害发生概率能力。ROC 曲线下面积为 AUC, AUC 在 0.7~0.9 之间, 模型具有较高的准确性, 当 $\text{AUC} > 0.9$ 时, 模型具有极高的准确性^[38]。计算过程如式 (20) ~ (22) 所示。

$$\text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (20)$$

$$\text{FPR} = \frac{\text{FP}}{\text{FP} + \text{TN}} \quad (21)$$

$$\text{AUC} \approx \sum_{i=1}^{n-1} \frac{(\text{TPR}_i + \text{TPR}_{i+1}) \times (\text{FPR}_{i+1} - \text{FPR}_i)}{2} \quad (22)$$

式中: TPR 表示在所有实际发生地质灾害的样本中, 模型正确识别出的比例; TP 表示模型正确评估为发生地质灾害的样本数量; FN 表示错误评估为不发生地质灾害的样本数量; FPR 表示在所有实际未发生地质灾害的样本中, 模型错误识

别未发生的比例；FP 表示模型错误评估为发生地质灾害的样本数量；TN 表示模型正确评估为不发生地质灾害的样本数量； TPR_i 和 FPR_i 表示第 i 个阈值下的 TPR 和 FPR 值。

3.3 模型训练结果分析

为验证模型可靠性，采用不同随机种子进行 5 次独立重复实验。模型评估准确率最高达 93.2%，最低为 86.7%，均大于 85%，平均准确率为 90%，极差为 6.5%。实验结果表现稳定，未见明显异常值。具体分布如图 4~5 所示。



图 4 五折交叉验证 ROC 曲线和 AUC 值



图 5 五折交叉验证 AUC 值

在易发性评估中，非地质灾害样本数量明显超过地质灾害样本数量，其分布遵循地质灾害点与非地质灾害区的实际比值规律。易发性等级分布和频率比如图 6 所示。




图 6 易发性等级分布和频率比

3.4 消融实验

依次移除关键模块构建简化模型，通过消融实验分析各模块对提升模型效果是否有效。每个简化模型在相同初始化条件及训练流程下进行，采用独立随机种子分别进行五次测试，取性能指标平均值为评估结果。完整模型准确率达到 89.2%，而移除各模块均造成不同程度的性能下降：当时序

注意力模块被移除时，准确率降至 85.1%；当通道注意力模块被移除时，准确率下降至 86.9%。结果表明两种注意力模块对捕获震后次生地质灾害特征关联均具有一定作用。消融实验结果对模型性能的对比结果如表 3 所示。

表 3 消融实验结果对比

实验条件	AUC/%	准确率下降幅度 /%
完整模型	89.2	—
移除时序注意力	86.9	2.3
移除通道注意力	85.1	4.1

3.5 模型对比

采用网格搜索与随机搜索相结合的方法进行超参数优化，并在相同训练集和统一硬件环境下进行实验，对 ConvNeXt+GRU、ConvNeXt+LSTM、ConvNeXt、CNN+GRU 和 BPNN 在地质易发性评估中的表现进行比较。结果表明 ConvNeXt+GRU 能有效捕捉静态空间特征与降雨动态变化，其 ROC 曲线在大部分区域优于其他模型。ConvNeXt 及 ConvNeXt+LSTM 模型具备有效卷积结构，虽精度略低于 ConvNeXt+GRU，但仍能有效完成震后次生地质灾害易发性评估。BPNN 因模型结构简单、特征捕捉能力有限，准确率相对较低。对比结果如图 7 所示。




图 7 五种评估模型的 ROC 曲线与 AUC 评价结果对比

在易发性等级分布中，高易发性和极高易发性区域合计约占全部区域的 25%，与训练数据集中地质灾害点与非灾害点的比例相符。极低易发性区域中，BPNN 占比约 30%，比其他模型低约 20%。BPNN 的极高易发性区域占比最小，而其他模型中该等级占比均为第二高。采用卷积或循环神经网络的模型在敏感性评价结果中呈现双峰特征，能有效区分地质灾害点与非灾害点。五类模型易发性等级分布如图 8 所示。

在易发性等级频率比方面，地质灾害点的频率比从极低到极高等级依次递增，模型评价结果与实际观测相符。其中 BPNN、ConvNeXt 和 ConvNeXt+GRU 模型有超过 50% 的地质灾害点分布在高易发性和极易发性区域，对地质灾害点与非灾害点具有较好区分能力。五类模型敏感性等级频率比如图 9 所示。



图8 五类模型易发性等级分布




图9 五类模型易发性等级频率比

综合 ROC 曲线 AUC 值、易发性等级分布及频率比结果分析, ConvNeXt+GRU 模型表现最优。

3.6 模型泛化验证

为推进模型应用,需通过模拟真实地震,评估 VI 度及以上区域的震后次生地质灾害易发性,以验证模型在未训练数据与完整案例中的泛化性能。以雅安为主要研究区,选取近五年内发生的两次独立地震事件,2022 年 6 月 1 日芦山 6.1 级地震和 2022 年 9 月 5 日泸定 6.8 级地震为评估模型在雅安地区的预测能力,引入 2017 年 8 月 8 日九寨沟 7.0 级地震,验证更远空间范围上的模型泛化能力。考虑降雨累积效应,以震后 72 h 内的评估结果作为最终对比依据^[39]。模型在三次地震中的预测准确率分别为 88.2%、89.0% 和 86.3%,表现稳定。相应事件的 ORC 曲线与 AUC 评估结果如图 10 所示。

以 2022 年影响雅安区域的泸定地震为例,评估结果中的高易发性区域与次生地质灾害点位置基本吻合。高易发性和极高易发性区域内的灾害点沿河床分布较为密集,这可能与河床周边岩土结构、土壤饱和度的地质条件,降雨、水流等水文因素易加剧滑坡、泥石流等次生地质灾害发生的可能性。泸定 6.8 级地震的震后次生地质灾害易发性可视化热力图如图 11 所示。




图10 三次地震事件 ROC 曲线与 AUC 评估结果对比



图11 泸定 6.8 级地震次生地质灾害易发性热力图

4 易发性动态评估

地震发生后,根据各地理网格的特征指标值与训练好的模型计算地质灾害易发性。模型输入中的降雨数据通过 socket 通信连接雅安气象雷达与水文站数据进行实时更新。其中历史降雨数据来自水文站,未来降雨数据源自气象雷达,数据格式为 1 km×1 km 网格。历史降雨数据每 5 min 更新,未来降雨更新频率为 2 h 内每 5 min 更新,2~12 h 每 10 min 更新,12~24 h 每小时更新。模型在震后 72 h 内持续更新地质灾害易发性计算结果,更新频率与气象数据更新同步。

以 2022 年 6 月 1 日芦山 MS6.1 地震为例,震后 1 h 准确率为 82.91%,而震后 72 h 准确率提升至 88.2%。这主要是因为 6 月 1 日 7 时前芦山地区降雨量较小,降雨停止后模型通过注意力机制自适应增强了对其他地质条件的关注度,评估结果随之动态调整。实际灾害点信息,通过 2022 年 6 月 1 日吉林一号卫星拍摄的芦山 MS6.1 地震灾后遥感影像,结合应急管理部地质灾害研究中心许冲研究员团队记录的灾情数据^[40],进行目视解译得出。可视化结果表明,评估结果中的高易发性区域主要分布在震中上方,与实际震后次生地质灾害点分布总体吻合。震后 1 h 和 72 h 的次生地质灾害易发性

评估结果如图 12~13 所示。




图 12 2022 年芦山 6.1 级地震震后 1 h 次生地质灾害易发性热力图



图 13 2022 年芦山 6.1 级地震震后 72 h 次生地质灾害易发性热力图

5 结论和展望

本研究基于地理空间分析方法和 ConvNeXt 网络架构，引入了 CRU 循环网络、时间注意机制与通道注意机制，从而能够有效捕捉降雨的时变特征，并较好地处理地震条件、地质条件与水文条件之间的动态关联。与同类研究相比，该模型在应对降雨时变特征方面表现良好，其评估结果与历史地震灾害点的分布基本吻合，准确性较高。此外，基于实时气象数据，该模型可实现地质灾害易发性评估结果的持续更新，验证了其有效性与应用潜力^[41]。

然而，目前该模型基于公里网格的栅格单元构建，尚未从整体性视角进行分析，导致各易发性等级覆盖范围较广。在后续研究中，可结合雅安市在册隐患点、人口密度等多元信息，进一步实现对影响区域的精细化评估。另一方面，由于训练数据引入了雅安市外其他相似地区的数据以扩充样本量，当前模型更具普适性特征，而非最优的区域专用模型。因此，如何进一步提升其在雅安地区的准确率，是未来需要重点考虑的问题。

参考文献：

[1] 马豪宇,陈冠陶,王宇,等.氮添加对亚热带常绿阔叶林

土壤溶液化学特性的影响[J].生态学报,2021,41(23):9354-9363.

[2] 四川省人民政府.芦山“4·20”7.0级强烈地震灾害情况通报[Z].成都:四川省人民政府,2013.

[3] 雅安市应急管理局,雅安市减灾委员会.雅安市“6·1”芦山地震灾害损失评估报告[R].雅安:雅安市应急管理局,2022.

[4] 第十一届全国人大常委会.中华人民共和国防震减灾法[Z].北京:法律出版社,2009.

[5] 应急管理部,中国地震局.地震灾后次生灾害防范与处置工作指南[R].北京:应急管理部,2013.

[6] 中华人民共和国国务院.地质灾害防治条例[Z].北京:中国法制出版社,2003.

[7] ULLAH I, ASLAM B, SHAH S H I A, et al. An integrated approach of machine learning, remote sensing, and GIS data for the landslide susceptibility mapping[J]. Land, 2022, 11(8): 1265.

[8] ABAY A, MULUGETA A, MEBRAHTU G. GIS-based landslide susceptibility mapping using frequency ratio method: a case study from adigrat-mugulat mountain chains, northern ethiopia[J]. Scientific african, 2025, 28: e02661.

[9] CHANG M, DOU X Y, ZHU X S, et al. Integrated risk assessment of landslide in karst terrains: advancing landslides management in Beiliu City, China[J]. International journal of applied earth observation and geoinformation, 2024, 132: 104046.

[10] 张迎宾,徐佩依,林剑锋,等.基于BP神经网络的九寨沟地区地震滑坡危险性预测研究[J].工程地质学报,2024,32(1):133-145.

[11] 唐学武,刘耕,邵磊,等.基于CF-BPNN耦合模型的益湛铁路沿线滑坡危险性评价[J].地质科学,2024,59(5):1470-1486.

[12] 景斐媛,陈婕,杨泽强,等.基于I-PSO-BP模型的黄河南岸康店镇黄土地质灾害易发性评价[J].水利水电技术(中英文),2025,56(S2):643-655.

[13] 黄发明,陈杰,杨阳,等.滑坡易发性相关致灾环境因子研究的综述与展望[J].地质科技通报,2025,44(2):14-37.

[14] GUO Z Z, FERRER J V, HÜRLIMANN M, et al. Shallow landslide susceptibility assessment under future climate and land cover changes: a case study from southwest China[J]. Geoscience frontiers, 2023, 14 (4): 101542.

[15] WANG L, YANG K J, WU C Z, et al. Novel approach to quantitative risk assessment of reservoir landslides using a hybrid CNN-LSTM model[J]. Landslides, 2025, 22: 943-956.

[16] 石庆研,赵婉彤,韩萍.基于时空特征提取的GTA-

- Seq2Seq 多步 4D 航迹预测模型[J/OL]. 北京航空航天大学学报, 1-16[2026-04-03]. <https://doi.org/10.13700/j.bh.1001-5965.2024.0679>.
- [17] 曾志伟, 杨华, 宁启蒙, 等. 洞庭湖区土地利用强度演变及其对生态系统服务的影响[J]. 经济地理, 2022, 42(9): 176-185.
- [18] LIU Z, MAO H Z, WU C Y, et al. A ConvNet for the 2020s[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Piscataway: IEEE, 2022: 11976-11986.
- [19] CHEN J, ZENG X, ZHU J R, et al. The diverse mountainous landslide dataset (DMLD): a high-resolution remote sensing landslide dataset in diverse mountainous regions[J]. Remote sensing, 2024, 16(11): 1886.
- [20] 王婷婷, 蒋静怡, 赵万春, 等. 改进 ConvNeXt V2 的岩石薄片岩性识别方法[J]. 石油地球物理勘探, 2025, 60(2): 292-301.
- [21] 何彩虹, 王辉, 张智铭, 等. 改进 ConvNeXt 网络的航班延误预测模型优化研究[J]. 航空计算技术, 2023, 53(4): 19-23.
- [22] 任紫文, 刘怀广, 孙伟. 基于时序预测的激光光斑聚焦状态判别算法研究[J]. 激光与光电子学进展, 2025, 62(6): 287-295.
- [23] MA J X, GAO H R, XU C, et al. Characterization and formation mechanism of the catastrophic flash flood-debris flow hazard triggered by the July 2023 extreme rainstorm in Hantai Gully of Beijing, China[J]. Landslides, 2025, 22: 877-893.
- [24] 范宣梅, 方成勇, 戴岚欣, 等. 地震诱发滑坡空间分布概率近实时预测研究: 以 2022 年 6 月 1 日四川芦山地震为例[J]. 工程地质学报, 2022, 30(3): 729-739.
- [25] GONZALEZ F C G, CAVACANTI M C R, RIBEIRO W N, et al. A systematic review on rainfall thresholds for landslides occurrence[J]. Heliyon, 2024, 10(1): e23247.
- [26] 中国地质环境监测院. 中国崩塌滑坡泥石流易发程度图(1:5000000)说明书[Z]. 北京: 地质出版社, 2010.
- [27] SAMIA J, TEMME A, BREGT A, et al. Do landslides follow landslides? insights in path dependency from a multi-temporal landslide inventory[J]. Landslides, 2017, 14: 547-558.
- [28] ZHOU S H, LI J F, ZHANG J C, et al. Exploring bayesian network model with noise filtering for rainfall-induced landslide susceptibility assessment in Fujian, China[J/OL]. Frontiers in earth science, 2024[2026-04-02]. <https://doi.org/10.3389/feart.2024.1444882>.
- [29] 伍剑波, 丁明涛, 孙东, 等. 基于不同组合模型的川西滑坡易发性评价不确定性分析[J]. 灾害学, 2025, 40(4): 51-61.
- [30] 张书豪. 基于 GIS 与人工智能的区域泥石流、地震滑坡易发危险性评价方法研究[D]. 成都: 西南交通大学, 2022.
- [31] LU M, YU Z H, HUA J, et al. Spatial dependence of floods shaped by extreme rainfall under the influence of urbanization[J]. The science of the total environment, 2022, 857(1): 159134.
- [32] 孙俊, 潘玉君, 和瑞芳, 等. 地理学第一定律之争及其对地理学理论建设的启示[J]. 地理研究, 2012, 31(10): 1749-1763.
- [33] WANG J Z, ZHANG Z P, WANG Y K, et al. How to solve small sample size problems in time-series soil organic carbon mapping: new insights from the third law of geography[J]. Geoderma, 2025, 460: 117402.
- [34] 孙加慧, 刘庚元, 赵薛强. 基于逆频率比采样方法的洪水易发性评价[J]. 人民黄河, 2025, 47(8): 96-101.
- [35] 温娅惠, 霍文博, 刘龙庆. 基于主成分分析的 K-Means 聚类算法在实时洪水预报中的应用[J]. 水文, 2025, 45(5): 36-43.
- [36] ULLAH S, PIRAHANDEH M, KIM D H. Self-attention deep ConvLSTM with sparse-learned channel dependencies for wearable sensor-based human activity recognition[J]. Neurocomputing, 2024, 571: 127157.
- [37] 陈航, 刘惠军, 王韬, 等. 基于频率比-深度神经网络耦合模型的滑坡易发性评价: 以盐源县为例[J]. 水文地质工程地质, 2024, 51(5): 161-171.
- [38] 马思远, 许冲, 陈晓利. 地震崩塌滑坡危险性应急评估模型效果对比: 以 2022 年 6 月 1 日 M_w 5.8 芦山地震为例[J]. 地震地质, 2023, 45(4): 896-913.
- [39] 赵国蓉, 李万志, 刘冰, 等. 青海东部降雨型滑坡灾害特征及其致灾雨量分析[J]. 干旱区地理, 2025, 48(4): 632-639.
- [40] SHAO X Y, XU C, MA S Y. Preliminary analysis of coseismic landslides induced by the 1 June 2022 M_s 6.1 Lushan earthquake, China[J]. Sustainability, 2022, 14(24): 16554.
- [41] LUO Q, DAI F, LIU Y, et al. Seismic performance assessment of velocity pulse-like ground motions under near-field earthquakes[J]. Rock mechanics and rock engineering, 2021, 54(8): 3799-3816.

【作者简介】

游巧(2002—), 女, 四川内江人, 硕士研究生, 研究方向: 灾害信息处理技术。

黄猛(1976—), 男, 河南新乡人, 硕士, 教授, 研究方向: GIS、软件工程、人工智能、大数据分析、灾害信息处理。

崔珂玮(2000—), 男, 山东临沂人, 硕士研究生, 研究方向: 灾害信息处理技术、目标检测。

(收稿日期: 2025-09-08 修回日期: 2026-04-09)