引文格式:瞿伟,边子策,李久元,等.融合Transformer与CNN的正样本缓冲滑坡易发性评价模型:以宝鸡市为例[J].武汉大学学报(信息科学版),2026,51(4):726-740.DOI:10.13203/j.whugis20250295

Citation: QU Wei, BIAN Zice, LI Jiuyuan, et al. Landslide Susceptibility Assessment Model Based on Positive Sample Buffering with Transformer-CNN Integration: A Case Study of Baoji City[J]. Geomatics and Information Science of Wuhan University, 2026, 51(4):726-740.DOI:10.13203/j.whugis20250295

融合Transformer与CNN的正样本缓冲滑坡易发性评价模型:以宝鸡市为例

瞿 伟[1] 边子策[1] 李久元[1] 唐兴友[1] 陈沛男[1]

1 长安大学地质工程与测绘学院,陕西 西安,710054

摘 要:宝鸡市滑坡灾害频发,但当前该区域滑坡编录数据样本较少,同时若仅采用滑坡点样本训练模型会导致模型的空间代表性不足,从而制约对该区域滑坡易发性评价的精度。针对此,结合卷积神经网络模型(convolutional neural network, CNN)的局部特征提取优势和注意力机制Transformer的全局建模能力,提出一种融合Transformer与CNN的正样本缓冲滑坡易发性评价模型。依据滑坡规模设置90~130 m动态缓冲区扩展正样本,并综合考虑地形地貌、地质条件、水文气象和人类工程等选取13类滑坡影响因子,通过多重共线性分析后构建了滑坡评价体系。研究结果显示,采用缓冲区将随机森林、CNN、Transformer、Transformer-CNN模型四者的ROC曲线下的面积(area under the curve, AUC)从0.834、0.852、0.847、0.875分别提升至0.883、0.913、0.926、0.959。此外,Transformer-CNN相较CNN、Transformer,未缓冲时AUC分别从0.852、0.847提升至0.875,进行缓冲时分别从0.913、0.926提升至0.959;基于夏普利加性解释算法可解释性分析进一步揭示出岩性、年降雨、坡向三类因子对滑坡易发性预测贡献度最大,贡献度分别达0.55、0.47、0.43,且三者交互效应显著,为锁定区域滑坡高易发区提供了可量化的依据。

关键词:滑坡;易发性评价;正样本缓冲;CNN;Transformer;SHAP

中图分类号:P237 **文献标识码**:A **收稿日期**:2025-10-14

DOI:10.13203/j.whugis20250295 **文章编号**:1671-8860(2026)04-0726-15

Landslide Susceptibility Assessment Model Based on Positive Sample Buffering with Transformer-CNN Integration: A Case Study of Baoji City

QU Wei[1] *BIAN Zice*[1] *LI Jiuyuan*[1] *TANG Xingyou*[1] *CHEN Peinan*[1]

1 College of Geology Engineering and Geomatics, Chang'an University, Xi'an 710054, China

Abstract: **Objectives**: Landslide susceptibility mapping (LSM) serves as a fundamental tool for geohazard prevention and regional planning. However, the accuracy of LSM in complex geological environments, such as Baoji City, is often constrained by two primary challenges: The scarcity of historical landslide samples leading to poor spatial representation, and the limitation of traditional convolutional neural networks (CNN) in capturing long-range spatial dependencies. To address these issues, we propose a novel framework that integrates a positive sample buffering strategy with a hybrid Transformer-CNN model. The primary objective is to enhance the spatial representation of landslide samples and effectively fuse local and global features to improve the predictive performance and interpretability of LSM. **Methods**: First, to overcome the limitations of point-based sampling which fails to reflect the actual spatial extent of landslides, a dynamic buffering strategy was implemented. Based on the scale of historical landslides, variable buffer radii ranging from 90 m to 130 m were applied to expand positive samples from isolated points into spatial polygons. Second, a total of 13 conditioning factors were selected, including topography (elevation, slope,

基金项目:国家重点研发计划(2024YFC3012604);国家自然科学基金(42174006,42090055);陕西省杰出青年科学基金(2022JC-18);长安大学中央高校基本科研业务费专项资金(300102263201)。

第一作者:瞿伟,博士,教授,主要从事地质灾害高精度监测及成因机理研究。quwei@chd.edu.cn

aspect, plan curvature, profile curvature), geology (lithology, distance to faults), hydrology (distance to rivers, topographic wetness index, rainfall), ecological environment (normalized difference vegetation index) and human activities (land use, distance to roads). Multicollinearity analysis, utilizing both Pearson correlation coefficients and variance inflation factor (VIF), was conducted to ensure the statistical independence of these factors. Third, a Transformer-CNN coupled model was constructed. The architecture utilizes a CNN backbone with a 15×15 input window to extract high-dimensional local features, which are then serialized and fed into a Transformer encoder. The Transformer employs a multi-head self-attention mechanism to dynamically weigh the importance of different spatial positions, thereby capturing global non-linear interactions among factors. To rigorously evaluate the proposed framework, a total of eight experimental scenarios were designed, comparing the performance of random forest, standalone CNN, standalone Transformer, and the coupled Transformer-CNN model under both buffered and unbuffered sample conditions. Furthermore, the Shapley additive explanations (SHAP) algorithm was integrated to interpret the "“black-box” decision process of the optimal Transformer-CNN model, quantifying the contribution of each factor to landslide susceptibility. **Results**: Experimental validation demonstrate significant improvements in both model robustness and prediction accuracy. (1) Effectiveness of buffering strategy: The application of the buffering strategy universally enhanced the performance of all tested models. Specifically, the area under the curve values for RF, CNN, Transformer, and Transformer-CNN increased from 0.834, 0.852, 0.847, and 0.875 (unbuffered) to 0.883, 0.913, 0.926, and 0.959 (buffered), respectively. (2) Superiority of the hybrid model: The proposed Transformer-CNN model consistently outperformed single-structure models in both experimental settings. In the unbuffered scenario, it improved the AUC from 0.852 (CNN) and 0.847 (Transformer) to 0.875; in the buffered scenario, it further elevated the AUC from 0.913 (CNN) and 0.926 (Transformer) to 0.959. (3) Interpretability analysis: Based on SHAP interpretability analysis, it was further revealed that lithology, annual precipitation, and slope aspect contributed most significantly to predicting landslide susceptibility in Baoji City, with contributions of 0.55, 0.47, and 0.43, respectively. The interaction effects among these three factors were significant. **Conclusions**: The positive sample buffering strategy effectively mitigates the issue of insufficient spatial representation in historical inventories. The Transformer-CNN coupled architecture successfully overcomes the intrinsic limitations of single-structure models, offering a state-of-the-art solution for complex non-linear geological modeling. This study establishes a robust framework for landslide susceptibility assessment in data-scarce regions. These findings provide actionable scientific insights for local disaster mitigation and land-use planning.

Key words: landslide; susceptibility assessment; positive sample buffering; CNN; Transformer; SHAP

开展滑坡易发性评价研究,可以为准确识别滑坡高风险区域、滑坡灾害预警、工程防治和应急避险等提供重要的科学依据[1]。滑坡易发性评价方法经历了从定性到定量、从经验驱动到数据驱动、从统计模型到智能算法的发展历程。早期研究主要依赖专家知识与野外调查,通过层次分析法、模糊综合评判等方法进行定性或半定量评价。此类方法虽然能够融合专家经验,但存在主观性强、可重复性差,难以适应大尺度、高精度评价需求的问题。20世纪90年代至21世纪初,随着地理信息系统与遥感技术的发展,基于数理统计的定量评价方法逐渐成为主流。例如,信息量模型通过计算各影响因子与滑坡发生的统计关联,量化因子贡献度。证据权重法基于贝叶斯概率理论,可为每个因子赋予正负权重。频率比模型则可以通过滑坡点在不同因子分级中的分布频率评估因子的易发性指示作用。这类方法能够量化各影响因子与滑坡发生的统计关联,但在处理高维非线性关系和因子间复杂交互方面存在一定的局限性。近十年来,机器学习与深度学习模型凭借强大的非线性拟合能力和数据挖掘优势,被广泛应用于滑坡易发性评价[2-6]。例如,支持向量机通过核函数映射可以实现高维空间的非线性分类。随机森林(random forest,RF)基于集成学习思想,可以通过多棵决策树的投票机制提升模型鲁棒性,从而取得了较高的精确率。人工神经网络及其变体(如反向传播神经网络)能够自适应学习输入、输出间的复杂映射关系。特别地,卷积神经网络(convolutional neural network,CNN)因其

对空间特征的自动提取能力,在滑坡易发性评价研究中表现出色[7]。CNN通过多层卷积与池化操作,能够从高维栅格数据中自动学习局部空间模式,有效捕捉到滑坡与周边地质地貌环境的关联特征。而深度学习的最新进展体现在Transformer架构的引入。Transformer基于自注意力机制,能够无视空间距离直接建模任意位置间的依赖关系,在计算机视觉、自然语言处理等领域已展现出优异的全局特征提取能力。近年来,相关学者尝试将Transformer应用于地质灾害预测。例如,采用基于Transformer的边坡变形预测模型,并在高陡边坡位移预测中取得了优于长短期记忆网络的预测精度[8]。然而,Transformer在滑坡易发性评价中的应用尚处于探索阶段,其与CNN的融合机制、参数设置依据以及可解释性分析等方面仍有待进一步的系统性研究。

尽管滑坡易发性评价方法取得了显著进展,但在模型全局建模能力、样本代表性和样本不均衡处理等方面仍有改进的空间。传统CNN会受限于固定感受野和局部连接机制,在建模远距离空间依赖关系方面的能力尚有待提高,难以全面表达滑坡发生过程中多个影响因子间复杂的全局交互关系,这在一定程度上限制了模型在面对大尺度、多样性强的地貌环境时的适应性和预测能力。而基于自注意力机制的Transformer能够在无需引入额外卷积结构的情况下捕捉到任意位置间的长距离依赖关系,其核心优势在于:通过查询(query,Q)、键(key,K)、值(value,V)三元组动态计算位置间的关联权重,实现一步到位的全局建模,可以有效弥补CNN在建模全局特征方面的不足。

此外,滑坡样本采集会受到地形复杂性、历史资料完整性等因素制约,许多区域的历史滑坡记录稀少。为应对样本稀缺的问题,相关学者采用了考虑合成孔径雷达干涉测量(interferometric synthetic aperture radar,InSAR)地表形变的滑坡易发性评价[9],结合欠采样与过采样的方式开展滑坡易发性评价研究[10-11],采用合成少数类过采样法和自适应合成采样法开展滑坡易发性评价[12],以及基于信息量法的机器学习模型开展滑坡易发性评价[13]。虽然上述方法能够降低对滑坡易发性评价的不确定性,增加正样本量,然而欠采样方法在低易发区采样可能会丢失一些重要信息,导致负样本不具有多样性与代表性;在过采样阶段,即使采用了线性与非线性方法增加了正样本数量,但采用的数学模型有时过于线性单一,则可能会偏离真实样本的分布规律,或是采用的数学模型较为复杂,又会导致正样本分布复杂,增加冗余信息,从而偏离真实情况,降低模型精度。CNN模型对训练样本量也较为敏感,当前研究多直接利用滑坡点坐标作为正样本开展计算,未充分考虑到样本点周围的地质地貌环境,从而忽视了空间相关性,导致正样本代表性不足,进而影响滑坡易发性评价结果的可靠性。从CNN卷积运算的本质来看,其核心就是对图像进行卷积处理。而滑坡在现实空间中并非孤立的点,而是具有一定范围的面状地质灾害体。将滑坡简化为点坐标输入模型,会忽视滑坡影响范围内地质结构的连续性与空间关联性。因此,基于滑坡实际规模设置缓冲区,将点样本扩展为面样本,使得滑坡正样本不再是一个点,而是一片区域,既符合滑坡空间分布的客观规律,同时也满足地理学第一定律(地理事物或属性在空间分布上相互关联,邻近事物间的相关性高于距离较远的事物)和地理学第三定律(地理环境越相似,地理特征越相近)[14],从而可以有效地顾及到滑坡的空间相关性。由于正样本已经过缓冲区分析进行扩展,即可在进行正样本扩展以外的区域(非滑坡区域)也进行负样本的随机选取,选取得到的负样本同样具有多样性与代表性。

基于此,为了解决现有模型在滑坡易发性评价中对多尺度空间特征建模能力不足的问题,本文提出了Transformer-CNN耦合模型。该耦合模型借助Transformer对长距离依赖关系的建模优势,弥补了CNN在长距离空间关联捕捉、全局空间结构信息挖掘的不足,从而增强了其对多尺度空间特征的表达与建模能力。选取陕西省宝鸡市滑坡域为研究对象,首先选取地形地貌、地质条件、水文气象和人类工程等13类滑坡影响因子构建评价体系,通过共线性诊断剔除冗余变量,以确保输入因子的独立性与科学性。进一步针对滑坡样本稀缺及空间分布合理性问题,综合考虑滑坡规模与地理空间相似性,采用基于滑坡缓冲区的正样本扩展策略,依据滑坡大小设置差异化缓冲半径,并考虑滑坡滑动范围,以增强正样本数量与空间分布的合理性[15]。在此基础上,通过设置8种实验方案测试了本文提出的缓冲区分析方法的有效性,并验证了Transformer-CNN模型在滑坡易发性评价精度上的优势。最后,引入夏普利加性解释(Shapley additive explanations,SHAP)算法量化了各影响因子对预测结果的贡献度,识别出区域滑坡的主控因子,还进一步提升了模型的可解释性。研究成果可为滑坡样本稀缺场景下开展有效的滑坡易发性评价提

供解决路径。

1　研究算法

1.1　RF 算法

RF 是一种基于 Bagging 策略的集成学习算法[16-17],其核心是通过自助采样构建多棵互不关联的分类回归树(classification and regression tree,CART)决策树,并利用投票机制输出最终分类结果。相比单棵决策树,RF 引入了样本扰动和特征随机性,具有极强的抗过拟合能力和鲁棒性。此外,RF 利用袋外数据(out-of-bag,OOB)进行无偏估计,能够有效评估模型的泛化误差,其效果近似于交叉验证,常被用作滑坡易发性评价的基准模型。本文引入 RF 作为基准模型,一是因为它是滑坡易发性评价领域公认的高性能模型,将其作为基准可以客观地评估深度学习模型的改进效果。二是用于验证缓冲区策略的普适性,通过对比 RF 在正样本未缓冲与缓冲两种情景下的性能提升,旨在验证正样本缓冲策略是否能够通用于不同的评价模型,而非仅对特定深度学习模型有效。

1.2　CNN 模型

根据地理学第一定律,地物相距越近,其相关性越大。滑坡的发生并非孤立事件,而是与其局部的孕灾环境密切相关。CNN 通过滑动窗口机制,能够将滑坡点周边的孕灾环境因子(如地形地貌、水文地质等)作为局部图像块输入,利用卷积运算自动提取环境因子在空间上的组合结构特征,从而挖掘出滑坡与孕灾环境之间复杂的非线性关联,可以得到较为准确的滑坡易发性分区图。

CNN 因其在图像处理中的优异表现,已被广泛应用于地质灾害领域。基础 CNN 模型主要由卷积层、池化层、激活层和全连接层组成[18-19]。其中,卷积层能够有效识别各类特征之间的关联性,通过提取输入图像中的特征来提升性能。卷积层的输出经过激活层处理,不同的激活函数有不同的功能侧重面,激活函数能显著改善神经网络的非线性表达能力。池化层通过对激活层后的特征进行下采样,帮助避免模型过拟合。最终,池化后的数据在全连接层被整合为输出结果。

1.3　Transformer 注意力机制

注意力机制是一种在深度学习中模拟人类注意力的机制,允许模型在处理信息时选择性地关注输入数据中的关键部分,从而提高处理效率和准确性[20]。它不同于传统模型通过全局权重给出整个滑坡区域特征的重要性,注意力机制可以在给定的滑坡局部空间窗口内动态重标定特征权重,其核心在于通过计算滑坡影响因子的重要性权重,对其进行加权融合,使得每个滑坡窗口都能适应空间异质,从而提升模型对关键特征的敏感性。

注意力机制的核心运算基于查询向量 $\boldsymbol{Q}$、键向量 $\boldsymbol{K}$ 和值向量 $\boldsymbol{V}$ 3 个要素。其本质是通过计算 $\boldsymbol{Q}$ 与 $\boldsymbol{K}$ 的相似度得出注意力分数,经 Softmax 归一化后作为权重对 $\boldsymbol{V}$ 进行加权求和。该机制能够根据输入特征的内在相关性,动态地为关键信息分配更大的权重,从而实现对重要特征的精准聚焦与提取。

1.4　Transformer-CNN

传统 CNN 虽然能够高效地提取局部空间特征,但受限于卷积核固定感受野,难以捕捉到滑坡影响因子间的远距离空间依赖。Transformer 基于自注意力机制,能够动态计算任意位置间的关联权重以实现全局建模。本文设计的 Transformer-CNN 融合架构可以充分发挥出两者的优势,CNN 负责底层局部特征提取,Transformer 负责高层全局关系建模。Transformer-CNN 网络模型结构主要包括 4 部分,如图 1 所示。

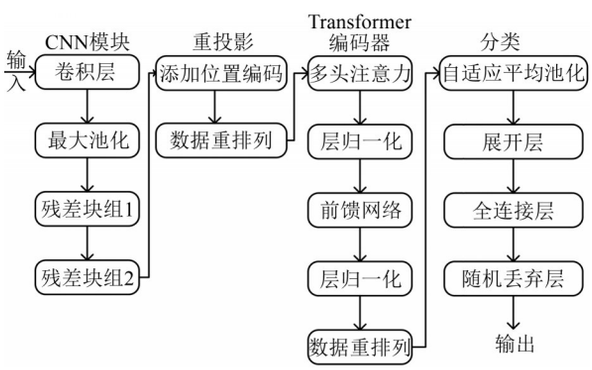


图 1　Transformer-CNN 模型结构

Fig. 1　Transformer-CNN Model Structure

结构一:输入数据为 15×15×13 的三维张量(15×15 空间窗口,13 个滑坡影响因子)。首先经过卷积层(卷积核 3×3,步长 1,填充 1)提取初步空间特征,再通过最大池化层(2×2)降维并增强特征鲁棒性。进一步引入两组残差块(每组包含 2 个卷积层+批归一化+修正线性单元(rectified linear unit,ReLU)激活),通过残差连接以缓解深层网络梯度消失问题,提取更抽象的高层特征。此阶段输出特征图尺寸为 4×4×128(空间分辨率 4×4,特征通道 128)。

结构二:CNN 输出的 4×4×128 特征图需转换为 Transformer 可处理的序列格式。具体操作为:将空间维度展平(4×4=16 个空间位置),每个位置保留 128 维特征向量,形成长度为 16 的序列。由于

Transformer自身不具备位置感知能力,需要添加位置编码以保留空间位置信息。本文采用可学习的位置嵌入向量,为每个序列位置分配独立的128维向量,与特征向量相加后输入Transformer。这一转换过程实现了从空间表征到序列表征的映射,原本在二维空间中相邻的像素,在序列中仍保持邻接关系,但Transformer的自注意力机制能够打破这种局部约束,计算任意位置间的关联。

结构三:Transformer编码器包含多头自注意力层、前馈网络和层归一化模块。对于序列中的每个位置,计算其与所有位置的注意力权重,多头机制进一步增强了模型的表达能力,将128维特征分割为8个头(每头16维),并行计算8组注意力,捕捉不同子空间的依赖关系。前馈网络由两层全连接层组成(激活函数为高斯误差线性单元),对注意力输出进行非线性变换,进一步增强了特征表达能力。层归一化应用于每个子模块后,稳定训练过程并加速收敛。

结构四:Transformer输出的特征进入分类模块,依次经过自适应平均池化、展开层、全连接层与随机丢弃层。自适应平均池化将特征图调整为固定尺寸,适配全连接层的输入要求,同时保留全局特征统计信息;展开层将二维特征图展平为一维向量,为全连接层做准备;全连接层将特征映射到类别概率空间。随机丢弃层在训练时随机丢弃部分神经元,防止过拟合,提升模型泛化能力。经过分类模块处理后,最终输出分类结果。

CNN的局部感受野与Transformer的全局视野形成了优势互补。从CNN的低层空间特征,到Transformer的高层语义关系,模型构建了从局部到全局的层次化表征空间。Transformer的自注意力机制能够根据输入样本动态调整不同空间位置的重要性,而非CNN的固定卷积权重,因此可以使模型能够适应于不同区域的空间异质性,提升模型的泛化能力。

1.5 SHAP算法

SHAP算法借鉴了博弈论中的Shapley值理论,通过精确量化每个滑坡影响因子对模型预测结果的贡献,为深度学习模型在滑坡易发性评价中的解释性提供了一种直观、可量化的方法,该算法能够有效揭示“黑箱”模型的内部决策逻辑,帮助研究者理解模型为何将某一区域判定为高滑坡风险[21-22]。SHAP算法的核心优势在于它能够提供模型解释的两个层面:全局解释和局部解释。全局解释揭示了整个数据集中影响因子的重要性分布,从而指导地质灾害防控策略的制定;而局部解释则深入到单个观测值,分析各个影响因子对特定预测结果的具体影响。对于特征集合S中的特征i,Shapley值计算公式如下:

$$g(z')=\phi_0+\sum_{i=1}^{D}\phi_i z_i'\approx f(z) \tag{1}$$

$$\phi_i=\sum_{S\subseteq N\setminus\{i\}}\frac{|S|!(|N|-|S|-1)!}{|N|!}\left(f\left(S\cup\{i\}\right)-f(S)\right) \tag{2}$$

式中,g为解释模型;z'为简化输入,与原始输入z为映射关系,为特征存在与否的二元标识;ϕ_0为模型在整个数据集上的预测均值;ϕ_i为第i个影响因子的贡献值(即Shapley值);z_i'为对第i个滑坡影响因子进行特征变换后得到的分量;f代表滑坡易发性预测所采用的深度学习模型;N为影响因子全集;$f\left(S\cup\{i\}\right)$和$f(S)$表示包含影响因子i的影响因子子集和不包含影响因子i的影响因子子集所对应的模型预测值。

2 研究区概况与数据源

2.1 研究区概况

宝鸡市位于陕北黄土高原的西南部,地处陕西、甘肃、四川三省交汇之地,总面积为18 131 km^2,地势呈三面高、中间低的箕状断陷盆地。地貌类型复杂,涵盖山地、丘陵和平原,其中山地面积占比达56%。南部为秦岭基岩山区,北部为黄土台塬,中部为渭河阶地,岩土分布具有明显的分带性:北部黄土层厚、湿陷性强,南部基岩裸露、风化破碎。宝鸡属暖温带大陆性季风气候,降水集中于夏秋季,暴雨频发,8月尤为显著。其特殊的地形地质结构及频繁的强降水,为滑坡、崩塌、泥石流等地质灾害的发生提供了有利条件。

宝鸡市滑坡灾害在空间上多沿活动断裂、塬边、河岸及人类工程扰动区呈带状、片状分布,周期长、破坏性强[23-26]。本文使用的宝鸡市历史滑坡编录数据包含703个滑坡点,来源于中国科学院资源环境科学数据中心(https://www.resdc.cn/)所统计的地质灾害点空间分布数据,滑坡点位置见图2。宝鸡市滑坡灾害每年均造成不同程度的人员伤亡与财产损失,急需构建科学的滑坡易发性评价体系,以提升风险识别与防控能力。

2.2 数据源

本文采用的地形数据为30 m分辨率的数字高程模型,源自地理空间数据云,经数据处理软件提

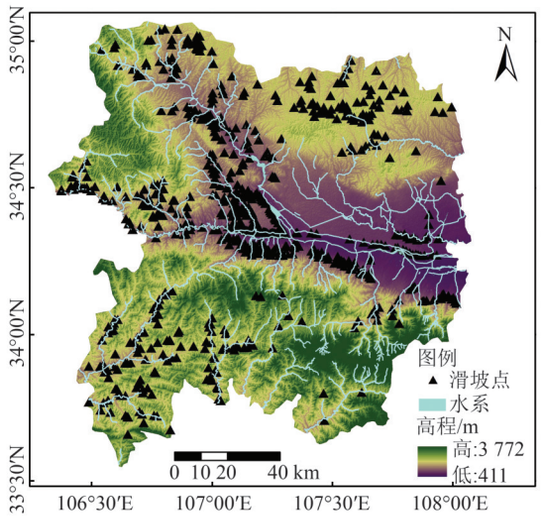


图 2　研究区概况图

Fig. 2　Overview Map of the Study Area

取高程、坡向、坡度等地形因子。水系数据、道路数据源自 OpenStreetMap,断层数据源自地震地质;地层岩性由宝鸡市地质图提取,详细标注了岩层类型;气象水文数据由国家青藏高原科学数据中心提供,包括近 100 年逐年降水量分布图,空间分辨率为 1 km;归一化植被指数(normalized difference vegetation index,NDVI)源自美国宇航局地球数据;土地利用类型源自中国年度土地数据集。所有数据经空间配准统一至 WGS_1984_UTM_Zone_48N 坐标系,利用重采样技术将它们转换成 30 m 分辨率,以此来保证相同的空间信息细致程度。数据类型与数据来源如表 1 所示。

表 1　数据类型和数据来源

Table 1　Data Types and Data Sources

数据类型	影响因子	数据格式	数据来源	时间
地形	高程 坡向 坡度 平面曲率 剖面曲率 TWI	栅格数据(30 m)	地理空间数据云	2019 年
地质	距水系距离	矢量数据	OpenStreetMap	2023 年
	距断层距离		1:400 万中国活动构造空间数据库	2019 年
	地层岩性		宝鸡市地质图	2017 年
生态	NDVI	栅格数据(30 m)	美国宇航局地球数据	2023 年
气象	年平均降水量	栅格数据(30 m)	国家青藏高原科学数据中心	2023 年
人类工程活动	距道路距离	矢量数据	OpenStreetMap	2023 年
	土地利用类型	栅格数据(30 m)	中国年度土地数据集	2023 年

注:TWI(topographic wetness index):地形湿度指数。

3　滑坡影响因子选取与预处理

3.1　滑坡影响因子选取

遵循科学性、独立性与可操作性原则,针对宝鸡市滑坡灾害现状,结合其独特的地质构造、地理位置及自然环境特征,选取高程、坡向、坡度、TWI、平面曲率、剖面曲率、NDVI、年平均降雨量、地层岩性、距道路距离、距断层距离、距水系距离、土地利用类型 13 个滑坡影响因子[27-28](图 3)。

13 个滑坡影响因子的物理含义与对滑坡易发性的关联机制如下:(1)高程:地表相对海拔高度,控制重力势能与风化程度,高程越高,构造应力与冻融作用越强。(2)坡向:坡面朝向(0°～360°),影响光照、蒸发与地下水富集,阴坡(N、NE)含水量高,易滑。(3)坡度:地表倾斜角度,直接决定下滑力,坡度 15°～35°为滑坡高发区,>45°以崩塌为主。(4)TWI:表征地表水分累积趋势,TWI 高值区易积水,孔隙水压力升高,降低土体抗剪强度。(5)平面曲率:坡面水平方向弯曲度,凹坡汇水、凸坡散水;凹坡易饱和,增加滑动风险。(6)剖面曲率:坡面垂直方向弯曲度,凹形坡加速水流,冲刷坡脚;凸形坡减速沉积,影响稳定。(7)NDVI:植被覆盖度,植被根系固土,降低侵蚀,高 NDVI 区滑坡发生率降低 40%～60%。(8)年平均降雨量:多年平均降水量,降雨是滑坡主要触发因素,饱和土体重度增加,基质吸力丧失。(9)地层岩性:岩石/土体类型与强度,黄土、软弱泥岩遇水软化,抗剪强度骤降,坚硬岩石稳定性高。(10)距道路距离:至公路/铁路的距离,道路开挖破坏坡体结构,改变地表排水,距道路距离<100 m 滑坡风险增加 2～3 倍。(11)距断层距离:至最近活动断层的距离,断层破碎带岩体完整性差,应力集中,距断层小于 500 m 滑坡密度高 3～5 倍。(12)距水系距离:至河流/溪流的距离,河流侵蚀坡脚,降低支撑力,地下水位抬升,增加静水压力。(13)土地利用类型:地表覆盖/利用方式,耕地灌溉增加入渗,建设用地增加荷载,滑坡率高,林地根系加固,滑坡率低。

首先对滑坡易发性影响因子进行多重共线性分析。为了评价两个变量之间是否存在线性关系,采用皮尔逊相关系数进行分析。当皮尔逊相关系数绝对值大于 0.5 时,一般认为变量间存在共线性[29]。图 4 为皮尔逊相关系数图,红色代表正相关,

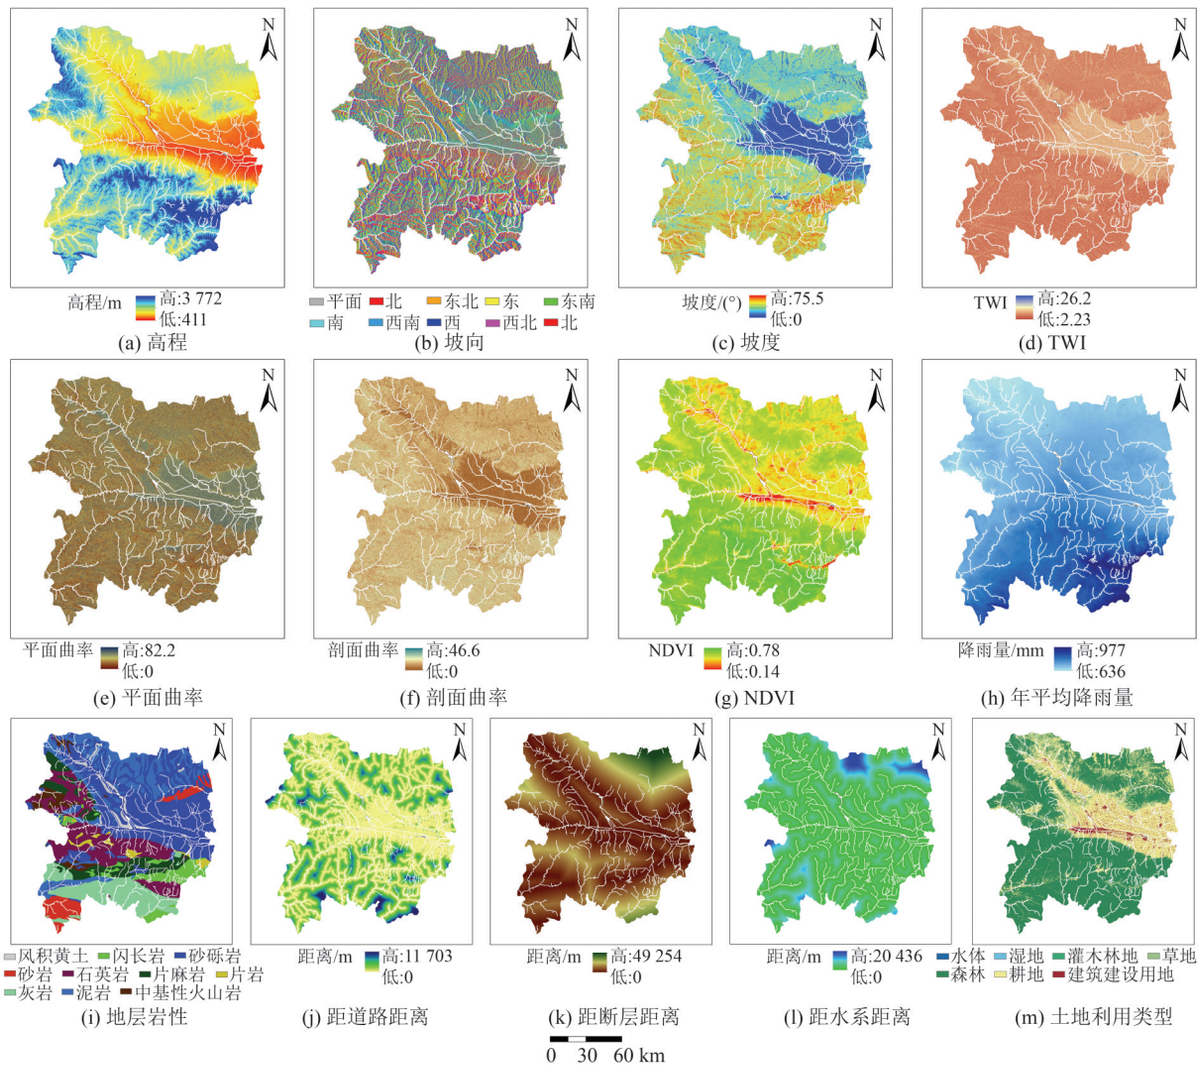


图3 滑坡影响因子

Fig. 3 Landslide Influencing Factors

蓝色代表负相关,颜色越深表示相关性越强,颜色越浅表示相关性越弱。从图4中可以看出,在选取的13个滑坡影响因子中,除高程与NDVI的相关系数为0.52外,其余各因子两两之间的相关系数绝对值均低于0.5,表明各因子间共线性微弱,独立性良好。统计学中通常认为皮尔逊相关系数大于0.7,才表明存在严重共线性[30]。相关系数为0.52虽然显示出一定相关性,但未达到严重共线性的阈值,表明两个因子仍然能够提供较独立的信息。此外,高程因素主要控制着滑坡体的重力势能与风化环境,决定了滑坡发生的能量基础,NDVI也表征了植被根系固土与水文截留效应,是抑制滑坡发生的关键阻力。因此,高程和NDVI这两个因子在滑坡发育过程中扮演着驱动与抵抗的对立角色,具有不可替代的物理意义。因此,在本文中考虑保留这两个因子。

为了更加精准地量化多重共线性程度,进一步采用方差膨胀因子(variance inflation factor, VIF)评估影响因子之间的多重共线性程度(表2)。VIF值越大,表明共线性越严重,这会导致输入特征包含大量冗余信息,降低易发性评价模型的鲁棒性。通常,如果VIF值大于10,表明自变量之间存在显著的多重共线性[11,18]

表2是计算得到特征的VIF值,可以看出,所有影响因子的VIF值都小于10,最高仅2.685,表明各因子相关性弱,也证明不需排除DEM与NDVI两个滑坡影响因子。因此,所选因子可直接用于后续滑坡易发性评价,无需进行因子剔除处理。

3.2 数据预处理

针对宝鸡市整个区域703个滑坡点样本的不足,本文提出一种滑坡点缓冲区方法,即根据滑坡的大小选取不同的缓冲区进行分析,同时增加了4个未进行缓冲区分析的对比实验。CNN通过滑动窗口提取局部空间特征,窗口尺寸会影响

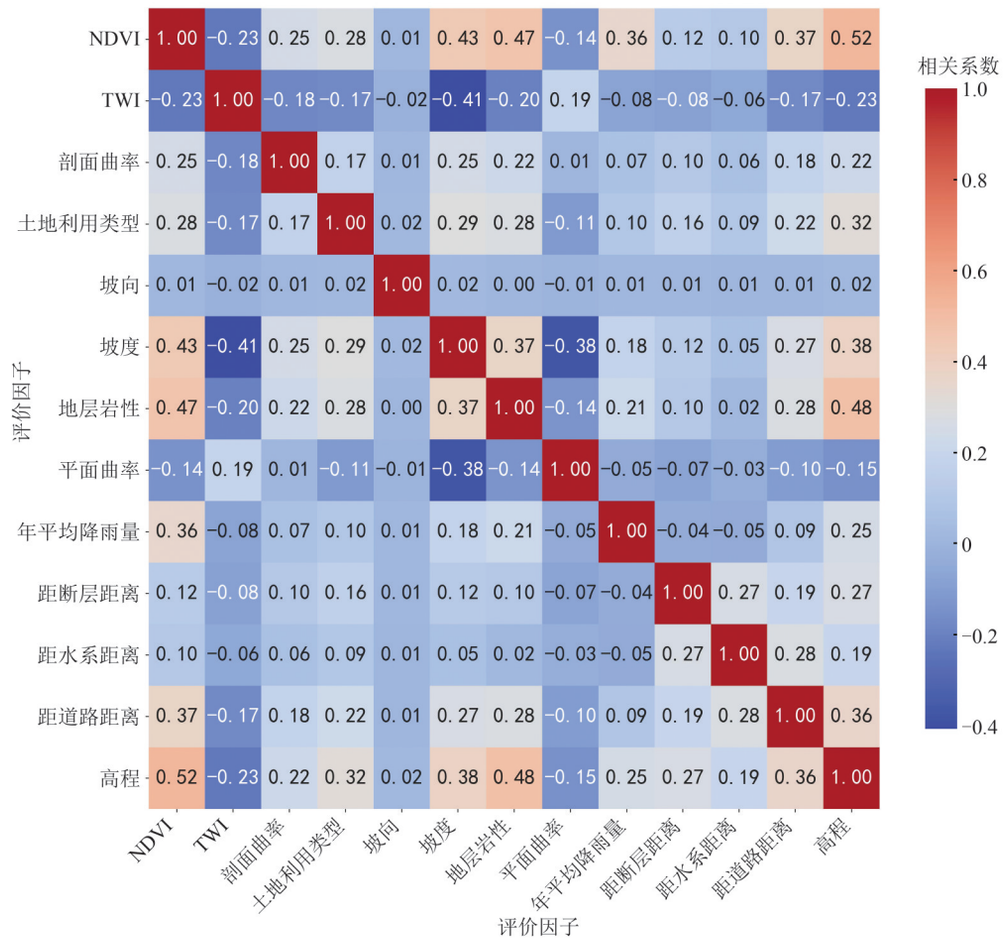


图 4　皮尔逊相关系数

Fig. 4　Pearson Correlation Coefficient

表 2　影响因子 VIF 值

Table 2　Value of Impact Factor VIF

影响因子	VIF 值
高程	2.685
坡向	1.004
坡度	2.556
TWI	1.368
平面曲率	1.502
剖面曲率	1.214
NDVI	2.507
年平均降雨量	1.604
地层岩性	1.971
距道路距离	1.389
距断层距离	1.469
距水系距离	1.468
土地利用类型	1.061

模型的感受野范围与特征表达能力,窗口过小会导致空间上下文信息不足,无法捕捉到滑坡与周边环境的关联,窗口过大则会引入冗余信息,增加计算负担。因此,为了科学地确定模型的输入特征图尺寸,本文在借鉴前人研究的基础上,根据滑坡空间尺度特征、CNN 感受野理论和计算效率,对多种不同尺度的输入窗口进行了对比实验。通过反复调参和效果评估,最终采用 15×15 的输入窗口能够在模型预测精度与训练效率之间实现最优平衡,故选取该尺寸作为模型输入大小,栅格分辨率为 30 m[10,28],窗口覆盖范围为 450 m×450 m(图 5)。

进行缓冲区分析选取缓冲半径需要同时考虑滑坡实际的规模和 CNN 卷积窗口的尺寸,对于滑坡缓冲区最大半径可以根据下式计算:

$$r_{\max}=\frac{a\left(2-\sqrt{2}\right)}{2} \tag{3}$$

式中,$r_{\max}$ 为缓冲区最大半径;a 为卷积窗口尺寸,即 450 m,计算得到最大半径约为 130 m。确认最大缓冲半径可以确保卷积窗口能够覆盖整个扩展的滑坡范围,当滑坡中心距窗口中心距离小于 130 m 时,缓冲后的滑坡范围必然覆盖窗口中心,从而可以使该点被正确标记为滑坡样本。

窗口与滑坡范围的关系见图 5,其中图 5(a)的中心标签值为 1(滑坡),图 5(b)的中心标签值为 0(非滑坡)。可见,只有当滑坡范围覆盖到窗

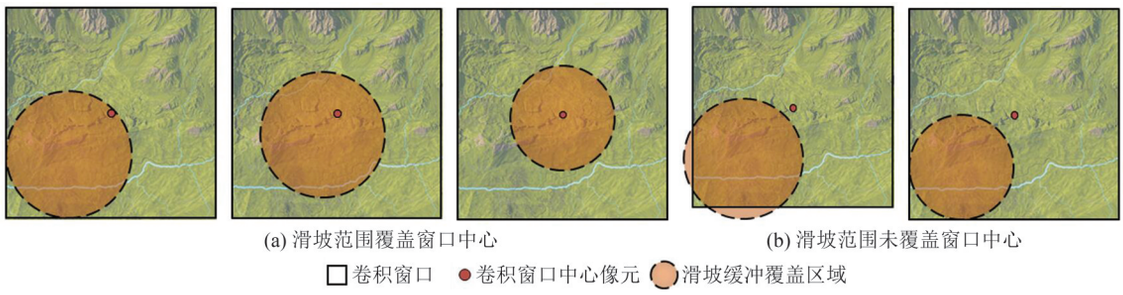


图5 窗口与滑坡范围关系

Fig. 5 Relationship Between Window and Landslide Area

口中心时,该点才能够被识别为滑坡,当滑坡范围在窗口中心之外,即使整个滑坡窗口中包含了完整的滑坡范围,但因为滑坡类型为小型或中型滑坡,距离中心过远,也不会被识别为滑坡。考虑理论与实际,本文中的缓冲区分析考虑了神经网络的卷积运算与滑坡范围。

根据《滑坡防治工程勘查规范》(DZ/T 0218—2006)对滑坡规模的划分标准,按照滑坡体积与面积大小分为小型滑坡、中型滑坡、大型滑坡、特大型滑坡,结合宝鸡市703个历史滑坡的统计特征与CNN窗口尺寸对应的最大半径,本文制定了差异化缓冲方案,小型滑坡、中型滑坡、大型滑坡和特大型滑坡分别采用半径为90 m、110 m、120 m和130 m作为缓冲距离。缓冲完毕后进行面转栅格,可以得到与滑坡因子相同的栅格分辨率与行列数。

4 滑坡易发性结果与分析

4.1 模型训练与精度分析

本文选取8组对比实验,其中实验1是未进行缓冲区分析的RF模型训练,实验2是未进行缓冲区分析的CNN模型训练,实验3是未进行缓冲区分析的Transformer模型训练,实验4是未进行缓冲区分析的Transformer-CNN模型训练,实验5是进行缓冲区分析的RF模型训练,实验6是进行缓冲区分析的CNN模型训练,实验7是进行缓冲区分析的Transformer模型训练,实验8是进行缓冲区分析的Transformer-CNN模型训练。滑坡影响因子数据不进行因子分级,在输入模型前进行归一化处理,方便保留数据完整性与可靠性,正样本与负样本比例为1∶2,训练集随机选取70%滑坡和非滑坡数据构建数据集,其余的30%作为测试集[13,15,30]。

RF模型采用5折交叉验证选取最优参数:决策树数量为800棵,最大深度约束为15层,最小叶子样本数为5个。Transformer-CNN模型去除Transformer模块,其余结构不做调整,则构成CNN模型。为了在模型训练中避免模型过拟合,采用多重正则化与轻量化设计策略。在CNN卷积层与全连接层引入$L2$权重衰减(为0.000 1),惩罚过大的模型参数,抑制模型复杂度。在全连接层前应用Dropout(丢弃率0.5),训练时随机关闭50%的神经元,使得模型学习鲁棒的特征表示而非依赖特定神经元;Transformer-CNN模型采用适度的网络深度(2组残差块+1层Transformer编码器),可以有效避免过度参数化。同时,残差连接与层归一化也可以保证梯度的稳定传播,使模型能够充分得到训练而不会陷入局部最优,从而提升了模型的泛化能力。

学习率基于网格搜索确定、注意力头数与Transformer嵌入维度采用贝叶斯超参数优化,以保证模型的收敛速度与稳定性,避免陷入局部最优。选择优化器AdamW,相较于Adam,AdamW引入了权重衰减,更适合处理包含Transformer结构的深度网络,有效防止过拟合。卷积模型各项参数如表3所示。

表3 参数设置表

Table 3 Parameters Setting

模型	卷积核大小	最大池化	激活函数	优化器	残差模块中的激活函数	学习率	训练次数	注意力头数	Transformer嵌入维度
CNN模型	3×3	2×2	ReLU	AdamW	Sigmoid	0.000 3	500	无	无
Transformer模型	无	无	ReLU	AdamW	无	0.000 3	500	8	128
Transformer-CNN模型	3×3	2×2	ReLU	AdamW	Sigmoid	0.000 3	500	8	128

将训练集导入模型进行训练,用训练好的模型分别对验证集和测试集进行运算,目前滑坡风险性评价模型的预测性能普遍采用受试者工作特征(receiver operating characteristic,ROC)曲线进行评估。ROC 曲线以假阳性率(非滑坡点被误判为滑坡点的比例)为横坐标,以真阳性率(滑坡点被正确识别的比例)为纵坐标[17-18]。曲线越靠近左上角,表明模型泛化能力越强,对滑坡点的识别越准确。曲线下面积(area under curve,AUC)是对 ROC 曲线的量化指标,取值为 0.5～1。AUC＜0.7 表示模型预测能力较弱;AUC≥0.7 且越接近 1,表示模型性能越优,区分滑坡与非滑坡点的能力越强。

基于宝鸡市滑坡样本的测试结果,8 类模型的 ROC 曲线如图 6 所示。可以看出,进行缓冲区分析的 RF 模型、CNN 模型、Transformer 模型和 Transformer-CNN 模型相较未进行缓冲区分析的模型,其 AUC 值分别由 0.834、0.852、0.847、0.875 提升至 0.883、0.913、0.926、0.959,分别提升 5.9%、7.2%、9.3%、9.6%。未进行缓冲区分析的 Transformer-CNN 模型相较于 CNN 模型、Transformer 模型,其 AUC 值分别由 0.852、0.847 提升至 0.875,分别提升 2.7%、3.3%,进行缓冲区分析的 Transformer-CNN 模型相较于 CNN 模型、Transformer 模型,其 AUC 值分别由 0.913、0.926 提升至 0.959,分别提升 5%、3.6%。ROC 曲线与 AUC 值共同表明,进行缓冲区分析的 Transformer-CNN 模型的性能表现更好。

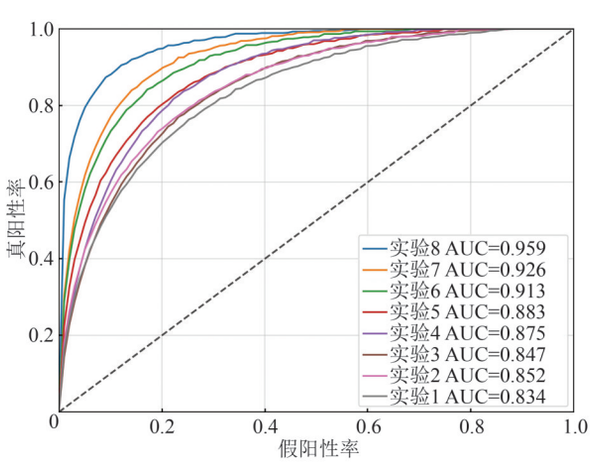


图 6　ROC 曲线和曲线下面积

Fig. 6　ROC Curves and Area Under Curve

针对模型构建过程中使用的测试数据集,选取准确率、精确率、*F*1 分数和 Kappa 系数作为评价指标,用于衡量模型训练的性能。准确率指分类正确的样本数占总样本数的比例,通常情况下,准确率越高,说明分类器性能越好。精确率指模型预测为正类的样本中真正为正类的比例,精确率越高,说明分类器性能越好。*F*1 分数是统计学中常用来评价二分类模型性能的指标,它兼顾了模型的精准率与召回率,数值越大,意味着模型对少数类和多数类的分类能力越均衡。Kappa 系数也可用来衡量滑坡易发性预测模型的性能,其大小反映模型区分滑坡单元与非滑坡单元的能力。8 个模型的 4 个统计参数值如表 4 所示,可以看到,未进行缓冲区分析的 Transformer-CNN 模型相较 CNN 模型、Transformer 模型,测试集准确率、精确率、*F*1 分数、Kappa 系数分别提升 2.7%、2.7%、5.9%、9% 与 3.2%、3.5%、6.9%、10.8%;进行缓冲区分析的 Transformer-CNN 模型相较 CNN 模型、Transformer 模型,测试集准确率、精确率、*F*1 分数、Kappa 系数分别提升 4.8%、4.9%、8.3%、13% 与 3.5%、3.8%、5.8%、9%。进行缓冲区分析的 RF 模型、CNN 模型、Transformer 模型、Transformer-CNN 模型相较未进行缓冲区分析前,测试集准确率、精确率、*F*1 分数和 Kappa 系数分别提升 5.3%、5.4%、11.7%、18.3%,7.2%、7.3%、14.9%、23.4%,9.1%、9.2%、18.6%、29.9% 和 9.4%、9.6%、17.4%、27.9%。此外,进行缓冲区分析的 Transformer-CNN 4 个参数值都是最高的,可见其在宝鸡区域滑坡易发性评价中具有最高的准确性和可靠性。

表 4　8 种模型的评价指标

Table 4　Evaluation Metrics of the Eight Models

模型	准确率	精确率	*F*1 分数	Kappa 系数
未进行缓冲区分析的 RF 模型	0.835	0.830	0.720	0.606
未进行缓冲区分析的 CNN 模型	0.849	0.845	0.747	0.642
未进行缓冲区分析的 Transformer 模型	0.845	0.839	0.740	0.632
未进行缓冲区分析的 Transformer-CNN 模型	0.872	0.868	0.791	0.700
进行缓冲区分析的 RF 模型	0.879	0.875	0.804	0.717
进行缓冲区分析的 CNN 模型	0.910	0.907	0.858	0.792
进行缓冲区分析的 Transformer 模型	0.922	0.916	0.878	0.821
进行缓冲区分析的 Transformer-CNN	0.954	0.951	0.929	0.895

4.2　影响因子贡献度分析

为进一步分析不同影响因子对滑坡的作用程度,采用 SHAP 算法量化各滑坡影响因子在 Transformer-CNN 模型中的贡献度。图 7 是 Transformer-CNN 模型计算得到的 SHAP 值,可以看到

地层岩性对滑坡的影响最大,宝鸡市位于黄土高原西南缘,黄土与软弱粘土层构成了滑坡发生的内在物质基础。市域中北部为厚层风成黄土与粉质粘土,下部普遍分布透水性弱的亚粘土、三门组粘土层等软弱夹层,遇水后强度急剧软化,易形成贯通的滑动面,宝鸡市黄土滑坡占据主要滑坡,符合实际情况;宝鸡市属暖温带半湿润季风气候,年平均降水量为600~1 000 mm,70%集中于7月—9月,暴雨与连阴雨是滑坡的主要触发因子;SHAP值计算结果显示,坡向对Transformer-CNN模型的贡献度排名第3,坡向通过太阳辐射、蒸散发及地下水富集程度的差异,影响黄土坡体的含水状态和风化深度。综合区内地层岩性控制滑面发育、降雨触发强度劣化、坡向调节水文-风化过程的耦合机制,可明确岩性-降雨-坡向是宝鸡市滑坡灾害的核心主控因子,与模型输出结果完全一致。

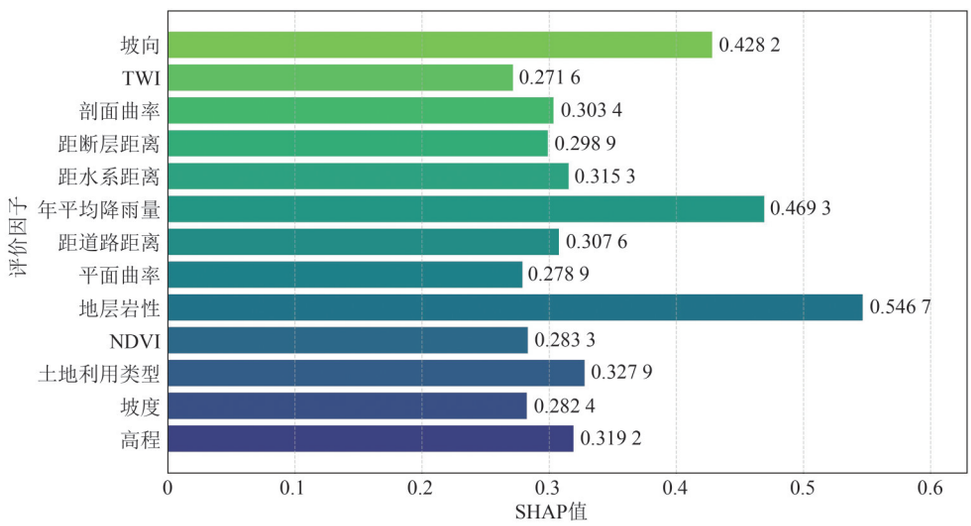


图7 SHAP值

Fig. 7 Values of SHAP

4.3 滑坡易发性评价结果

将训练好的模型应用到整个研究区域的滑坡易发性评价研究中,得到研究区的滑坡发生概率[31-33],根据自然断点法将0~1的滑坡发生概率分为5个等级:极高易发区、较高易发区、中等易发区、较低易发区、极低易发区。8个实验模型获得的宝鸡市滑坡易发性评价结果如图8所示,其中黑色小点为历史滑坡点。

从图8(a)可以看出,虽然大部分历史滑坡点都处于高易发与极高易发区,但是计算得到的高易发以及极高易发区过多,不符合实际情况。图8(b)、8(c)、8(d)是未进行缓冲区分析的CNN模型、Transformer模型与Transformer-CNN模型计算得到的滑坡易发性分区图,可以看出计算得到的高易发区以及极高易发区仍很高,同图8(a)一样,是由于样本点过少导致模型产生过拟合,发生误判,将低易发区判定为高易发区。图8(e)是进行缓冲区分析的RF模型得到的滑坡易发性分区图,与图8(a)相比,极高与高易发区减少,但由于其计算方式为逐栅格点计算,未考虑周围地理环境,仍出现较多极高与高易发区。图8(h)是进行缓冲区分析的Transformer-CNN模型得到的滑坡易发性分区图,与进行缓冲区分析的CNN模型(图8(f))、Transformer模型(图8(g))相比,极高易发区少量增多,高易发区少量减少,且极低易发区增加,历史滑坡绝大部分也都位于极高易发区与高易发区。

表5统计了各易发区的栅格单元数量,并计算出极低易发区、低易发区、中易发区、高易发区和极高易发区的面积及其占研究区总面积的比例,以及各易发区内历史滑坡点的数量及其占总滑坡数量的比例。基于历史滑坡点的分布特征,较优的滑坡易发性模型需同时满足3项指标[16]:(1)绝大多数的历史滑坡点应落在极高易发区;(2)未落入极高易发区的点应主要分布于高易发区;(3)落入极高易发区与高易发区的历史滑坡点占比应尽可能大。

从表5可以看出,对于第(1)项指标,在极高易发区,进行缓冲区分析的Transformer-CNN模型历史滑坡点分布数目最多(达607个),多于未进行缓冲区分析的RF模型(577个)、CNN模型(580个)、Transformer模型(578个)、Transformer-CNN模型(587个),以及进行缓冲区分析的RF模型(585个)、CNN模型(592个)、Transformer模型(594个);对于

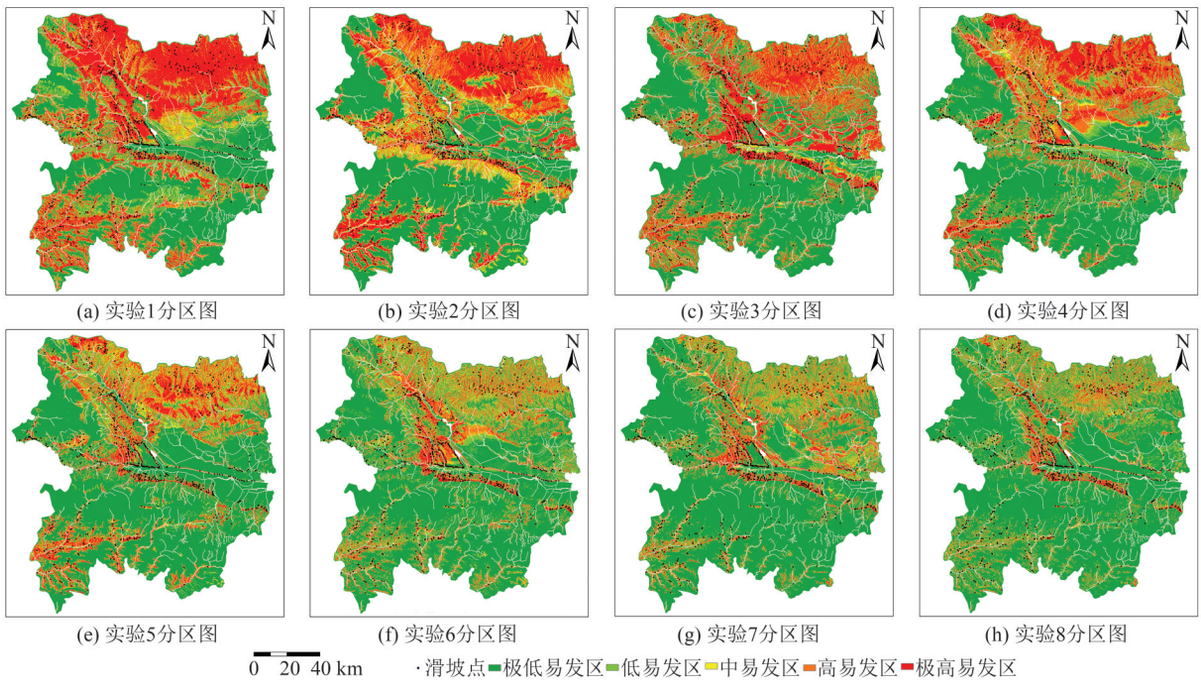


图 8　滑坡易发性分区图

Fig. 8　Landslide Susceptibility Zoning Maps

第(2)项指标,在高易发区,虽然进行缓冲区分析的 Transformer-CNN 的滑坡点数目(68 个)不是最高的,这是由于未进行缓冲区分析的 Transformer-CNN 模型中的样本数目少(75 个)导致模型过拟合,使计算的极高易发区与高易发区面积占比很大,导致部分样本点落在高易发区,进行缓冲区分析的 Transformer-CNN 模型比 RF 模型(60 个)、CNN 模型(60 个)、Transformer 模型(63 个)高,仍然符合第(2)项指标;对于第(3)项指标,落入极高易发区与高易发区的历史滑坡点比重最大的仍是进行缓冲区分析的 Transformer-CNN 模型(96.0%),高于未进行缓冲区分析的 Transformer-CNN 模型(94.2%)、进行缓冲区分析的 Transformer 模型(93.5%)、CNN 模型(92.7%)、RF 模型(91.7%),以及未进行缓冲区分析的 CNN 模型(91.2%)、Transformer 模型(90.7%)、RF 模型(90.4%)。上述 3 项指标均表明,进行缓冲区分析的 Transformer-CNN 滑坡易发性评价模型结果优于其他 7 个模型。

5　结　语

本文针对宝鸡市黄土滑坡易发性评价中样本不足,并考虑滑坡周围地理环境相似性,提出融合正样本缓冲区分析与 Transformer-CNN 深度学习模型的创新方法,结合 SHAP 算法实现因子贡献度解析。主要结论如下:

1)依据滑坡规模动态设置缓冲区半径(小型 90 m、中型 110 m、大型 120 m、特大型 130 m),有效扩充正样本代表性。实验表明,进行缓冲区分析的 Transformer-CNN 模型的测试集 AUC 值最高,证实该方法可缓解样本不足导致的过拟合问题。

2)引入注意力机制的 Transformer-CNN 模型在测试集的表现显著优于传统的 CNN、Transformer 与 RF 模型,证明其能有效捕捉滑坡与环境因子的复杂空间非线性关联,减少高易发区误判。

3)SHAP 全局解释量化了主导贡献因子,地层岩性-年平均降雨量-坡向的组合机制与宝鸡市典型黄土滑坡触发过程一致,为精准防治提供了理论依据。本文研究成果可为宝鸡市地质灾害风险管控、国土空间规划及应急响应提供科学支撑,可为其他区域滑坡灾害的易发性评价研究提供参考。

本文研究结果表明,正样本缓冲策略可以有效解决样本不足的问题,为样本稀缺地区的滑坡易发性评价提供了一种有效的解决途径。在未来的研究中,将进一步致力于通过综合遥感地质解译与 InSAR 技术提取高精度的滑坡矢量边界,构建基于真实多边形-Transformer-CNN 的耦合评价模型,以期实现更精细化的滑坡易发性评价。

表5 易发区面积及滑坡数量

Table 5 Area of Susceptible Zones and Landslide Count

模型	易发性等级	区域面积/km²	面积占比/%	滑坡数量/处	数量占比/%
未进行缓冲区分析的RF模型	极低	7 089.2	39.1	16	2.3
	低	1 795.0	9.9	16	2.3
	中	1 504.9	8.3	36	5.1
	高	2 066.9	11.4	58	8.3
	极高	5 675.0	31.3	577	82.1
未进行缓冲区分析的CNN模型	极低	8 086.4	44.6	12	1.7
	低	1 504.9	8.3	20	2.8
	中	1 486.7	8.2	30	4.3
	高	3 245.4	17.9	61	8.7
	极高	3 807.5	21.0	580	82.5
未进行缓冲区分析的Transformer模型	极低	9 029.2	49.8	14	2.0
	低	1 450.5	8.0	20	2.8
	中	1 323.6	7.3	31	4.4
	高	1 940.0	10.7	60	8.5
	极高	4 387.7	24.2	578	82.2
未进行缓冲区分析的Transformer-CNN模型	极低	9 337.5	51.5	8	1.1
	低	1 776.8	9.8	9	1.3
	中	1 251.0	6.9	24	3.4
	高	2 592.7	14.3	75	10.7
	极高	3 172.9	17.5	587	83.5
进行缓冲区分析的RF模型	极低	10 624.8	58.6	11	1.6
	低	1 577.4	8.7	12	1.7
	中	1 649.9	9.1	35	5.0
	高	2 085.1	11.5	60	8.5
	极高	2 193.9	12.1	585	83.2
进行缓冲区分析的CNN模型	极低	10 570.4	58.3	9	1.3
	低	2 991.6	16.5	16	2.3
	中	1 504.9	8.3	26	3.7
	高	1 432.3	7.9	60	8.5
	极高	1 631.8	9.0	592	84.2
进行缓冲区分析的Transformer模型	极低	11 767.0	64.9	8	1.1
	低	1 958.1	10.8	13	1.8
	中	1 359.8	7.5	25	3.6
	高	1 468.6	8.1	63	9.0
	极高	1 577.4	8.7	594	84.5
进行缓冲区分析的Transformer-CNN模型	极低	12 292.8	67.8	5	0.7
	低	1 432.3	7.9	8	1.1
	中	1 323.6	7.3	15	2.1
	高	1 414.2	7.8	68	9.7
	极高	1 668.1	9.2	607	86.3

参 考 文 献

[1] MERGHADI A, YUNUS A P, DOU J, et al. Machine Learning Methods for Landslide Susceptibility Studies: A Comparative Overview of Algorithm Performance[J]. *Earth-Science Reviews*, 2020, 207: 103225.

[2] ADO M, AMITAB K, MAJI A K, et al. Landslide Susceptibility Mapping Using Machine Learning: A Literature Survey[J]. *Remote Sensing*, 2022, 14(13): 3029.

[3] JIANG Z Y, WANG M, LIU K. Comparisons of Convolutional Neural Network and Other Machine Learning Methods in Landslide Susceptibility Assessment: A Case Study in Pingwu[J]. *Remote Sensing*, 2023, 15(3): 798.

[4] 郭飞, 赖鹏, 黄发明, 等. 基于知识图谱的滑坡易发性评价文献综述及研究进展[J]. 地球科学, 2024, 49(5): 1584-1606.
GUO Fei, LAI Peng, HUANG Faming, et al. Literature Review and Research Progress of Landslide Susceptibility Mapping Based on Knowledge Graph[J]. *Earth Science*, 2024, 49(5): 1584-1606.

[5] 赵占骜, 王继周, 毛曦, 等. 多维CNN耦合的滑坡易发性评价方法[J]. 武汉大学学报(信息科学版), 2024, 49(8): 1466-1481.
ZHAO Zhan'ao, WANG Jizhou, MAO Xi, et al. A Multi-dimensional CNN Coupled Landslide Susceptibility Assessment Method[J]. *Geomatics and Information Science of Wuhan University*, 2024, 49(8): 1466-1481.

[6] ZHANG Q, WANG T. Deep Learning for Exploring Landslides with Remote Sensing and Geo-Environmental Data: Frameworks, Progress, Challenges, and Opportunities[J]. *Remote Sensing*, 2024, 16(8): 1344.

[7] 王守华, 王睿菘, 孙希延, 等. 基于CF-CNN-LSTM模型的滑坡易发性评价[J]. 自然灾害学报, 2024, 33(5): 84-95.
WANG Shouhua, WANG Ruisong, SUN Xiyan, et al. Landslide Susceptibility Evaluation Based on CF-CNN-LSTM Model[J]. *Journal of Natural Disasters*, 2024, 33(5): 84-95.

[8] 伊廷婧汶, 黄才生, 覃勇, 等. 基于北斗监测数据的高陡边坡变形Transformer-CNN预测模型[J]. 重庆大学学报, 2025, 48(10): 81-94.
YI Tingjingwen, HUANG Caisheng, QIN Yong, et al. Transformer-CNN Prediction Model of High and Steep Slope Deformation Based on Beidou Detection Data[J]. *Journal of Chongqing University (Natural Science Edition)*, 2025, 48(10): 81-94.

[9] 秦佳松, 李为乐, 周胜森, 等. 考虑InSAR地表形变的滑坡易发性评价负样本选取与结果优化[J]. 武汉大学学报(信息科学版), 2025, DOI: 10.13203/j.whugis20240494.
QIN Jiasong, LI Weile, ZHOU Shengsen, et al.

Optimizing Negative Sample Selection and Results for Landslide Susceptibility Assessment Using In-SAR Surface Deformation[J]. *Geomatics and Information Science of Wuhan University*,2025,DOI:10.13203/j.whugis20240494.

[10] 杨仲康,张世殊,邓建辉,等. 斜坡单元尺寸和滑坡取样方式对区域滑坡易发性评价的影响[J]. 岩石力学与工程学报,2025,44(3):602-617.
YANG Zhongkang, ZHANG Shishu, DENG Jianhui, et al. The Impact of Slope Unit Scale and Landslide Sampling Methods on Regional Landslide Susceptibility Assessment[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2025, 44(3): 602-617.

[11] 刘纪平,梁恩婕,徐胜华,等. 顾及样本优化选择的多核支持向量机滑坡灾害易发性分析评价[J]. 测绘学报,2022,51(10):2034-2045.
LIU Jiping, LIANG Enjie, XU Shenghua, et al. Multi-Kernel Support Vector Machine Considering Sample Optimization Selection for Analysis and Evaluation of Landslide Disaster Susceptibility[J]. *Acta Geodaetica et Cartographica Sinica*, 2022, 51(10): 2034-2045.

[12] 武雪玲,杨经宇,牛瑞卿. 一种结合SMOTE和卷积神经网络的滑坡易发性评价方法[J]. 武汉大学学报(信息科学版),2020,45(8):1223-1232.
WU Xueling, YANG Jingyu, NIU Ruiqing. A Landslide Susceptibility Assessment Method Using SMOTE and Convolutional Neural Network[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(8): 1223-1232.

[13] 孔嘉旭,庄建琦,彭建兵,等. 基于信息量和卷积神经网络的黄土高原滑坡易发性评价[J]. 地球科学,2023,48(5):1711-1729.
KONG Jiaxu, ZHUANG Jianqi, PENG Jianbing, et al. Evaluation of Landslide Susceptibility in Chinese Loess Plateau Based on IV-RF and IV-CNN Coupling Models[J]. *Earth Science*, 2023, 48(5): 1711-1729.

[14] 朱阿兴,闾国年,周成虎,等. 地理相似性:地理学的第三定律?[J]. 地球信息科学学报,2020,22(4):673-679.
ZHU Axing, LÜ Guonian, ZHOU Chenghu, et al. Geographic Similarity: Third Law of Geography?[J]. *Journal of Geo-Information Science*, 2020, 22(4): 673-679.

[15] HE Y, ZHAO Z A, YANG W, et al. A Unified Network of Information Considering Superimposed Landslide Factors Sequence and Pixel Spatial Neighbourhood for Landslide Susceptibility Mapping[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2021, 104: 102508.

[16] 刘坚,李树林,陈涛. 基于优化随机森林模型的滑坡易发性评价[J]. 武汉大学学报(信息科学版),2018,43(7):1085-1091.
LIU Jian, LI Shulin, CHEN Tao. Landslide Susceptibility Assesment Based on Optimized Random Forest Model[J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(7): 1085-1091.

[17] 瞿伟,李昕,李久元,等. 一种改进自适应步长人工蜂群优化随机森林的滑坡风险性评价方法[J]. 大地测量与地球动力学,2024,44(12):1211-1219.
QU Wei, LI Xin, LI Jiuyuan, et al. A Landslide Risk Assessment Method with Improved Adaptive Step Size Artificial Bee Colony Optimization Random Forest[J]. *Journal of Geodesy and Geodynamics*, 2024, 44(12): 1211-1219.

[18] 郑德凤,高敏,闫成林,等. 基于卷积神经网络的滑坡易发性评价:以辽南仙人洞国家级自然保护区为例[J]. 地球科学,2024,49(5):1654-1664.
ZHENG Defeng, GAO Min, YAN Chenglin, et al. Susceptibility Assessment of Landslides Based on Convolutional Neural Network Model: A Case Study from Xianrendong National Nature Reserve in Southern Liaoning Province[J]. *Earth Science*, 2024, 49(5): 1654-1664.

[19] ZHAO Z, CHEN J H. A Robust Discretization Method of Factor Screening for Landslide Susceptibility Mapping Using Convolution Neural Network, Random Forest, and Logistic Regression Models[J]. *International Journal of Digital Earth*, 2023, 16(1): 408-429.

[20] LI Y, ZENG J B, SHAN S G, et al. Occlusion Aware Facial Expression Recognition Using CNN with Attention Mechanism[J]. *IEEE Transactions on Image Processing*, 2019, 28(5): 2439-2450.

[21] 丁明涛,江辉,李振洪,等. 融合卷积模糊神经网络与SHAP特征优化的地震诱发滑坡易发性评价[J]. 武汉大学学报(信息科学版),2025,DOI:10.13203/J.whugis20250017.
DING Mingtao, JIANG Hui, LI Zhenhong, et al. Earthquake-Induced Landslide Susceptibility Assessment by Fusing Convolutional Fuzzy Neural Network and SHAP Feature Optimization Strategy[J]. *Geomatics and Information Science of Wuhan University*, 2025,DOI:10.13203/J.whugis20250017.

[22] 李文权,邓安鑫,郑炎,等. 基于机器学习的中型城市居民出行方式选择行为研究[J]. 交通运输系统工程与信息,2024,24(2):13-23.

LI Wenquan, DENG Anxin, ZHENG Yan, et al. Analysis of Residents' Travel Mode Choice in Medium-Sized City Based on Machine Learning[J]. *Journal of Transportation Systems Engineering and Information Technology*, 2024, 24(2): 13-23.

[23] 李磊. 宝鸡市滑坡发育特征与易发性评价研究[D]. 北京: 中国地质大学(北京), 2023.
LI Lei. Study on Development Characteristics and Vulnerability Evaluation of Landslide in Baoji City[D]. Beijing: China University of Geosciences(Beijing), 2023.

[24] 石玲, 王涛, 辛鹏. 陕西省宝鸡市地质灾害发育特征[J]. 地质力学学报, 2013, 19(4): 351-363.
SHI Ling, WANG Tao, XIN Peng. Development Characteristics of the Geo-Harzards in Baoji City, Shaanxi Province[J]. *Journal of Geomechanics*, 2013, 19(4): 351-363.

[25] LI L, XU C, YANG Z Q, et al. An Inventory of Large-Scale Landslides in Baoji City, Shaanxi Province, China[J]. *Data*, 2022, 7(8):114.

[26] ZHUANG J Q, PENG J B, WANG G H, et al. Distribution and Characteristics of Landslide in Loess Plateau: A Case Study in Shaanxi Province[J]. *Engineering Geology*, 2018, 236: 89-96.

[27] 唐晓娜. 基于卷积神经网络和综合指数模型的吕梁市滑坡灾害易发性评价[D]. 太原: 太原理工大学, 2019.
TANG Xiaona. Evaluation of Landslide Susceptibility in Lüliang City Based on Convolutional Neural Network and Comprehensive Index Model[D]. Taiyuan: Taiyuan University of Technology, 2019.

[28] YANG S, LI D Y, SUN Y Q, et al. Effect of Landslide Spatial Representation and Raster Resolution on the Landslide Susceptibility Assessment[J]. *Environmental Earth Sciences*, 2024, 83(4): 132.

[29] 王世宝, 庄建琦, 郑佳, 等. 基于深度学习的CZ铁路康定-理塘段滑坡易发性评价[J]. 工程地质学报, 2022, 30(3): 908-919.
WANG Shibao, ZHUANG Jianqi, ZHENG Jia, et al. Landslide Susceptibility Evaluation Based on Deep Learning Along Kangding-Litang Section of CZ Railway[J]. *Journal of Engineering Geology*, 2022, 30(3): 908-919.

[30] DORMANN C F, ELITH J, BACHER S, et al. Collinearity: A Review of Methods to Deal with It and a Simulation Study Evaluating Their Performance[J]. *Ecography*, 2013, 36(1): 27-46.

[31] 陈飞, 蔡超, 李小双, 等. 基于信息量与神经网络模型的滑坡易发性评价[J]. 岩石力学与工程学报, 2020, 39(S1): 2859-2870.
CHEN Fei, CAI Chao, LI Xiaoshuang, et al. Evaluation of Landslide Susceptibility Based on Information Quantity and Neural Network Model[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2020, 39(S1): 2859-2870.

[32] LU J G, HE Y, ZHANG L F, et al. A Synergistic CNN-DF Method for Landslide Susceptibility Assessment[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2025, 18: 6584-6599.

[33] LIU S L, WANG L Q, ZHANG W G, et al. A Comprehensive Review of Machine Learning-Based Methods in Landslide Susceptibility Mapping[J]. *Geological Journal*, 2023, 58(6): 2283-2301.