滑坡易发性相关致灾环境因子研究的综述与展望

黄发明[1,2]，陈杰[1]，杨阳[1]，陈茜[1]，周创兵[1]，江炳辰[1]，郭飞[2*]

1. 南昌大学工程建设学院，南昌 330031；
2. 三峡大学三峡库区地质灾害教育部重点实验室，湖北 宜昌 443002

第一作者，E-mail：faminghuang@ncu.edu.cn

* 通信作者，E-mail：ybbnui.2008@163.com

2024-12-16 收稿；2025-03-03 修回；2025-03-11 接受

基金项目：国家自然科学基金项目(42377164)；江西省自然科学基金项目(20242BAB23052；20232BAB204077)；防灾减灾湖北省重点实验室开放基金项目(2024XCZX05)

中图分类号：P642.22　　文章编号：2096-8523(2025)02-0014-24　　doi：10.19509/j.cnki.dzkq.tb20240766

摘　要：致灾环境因子是滑坡易发性预测建模的输入变量，是指影响滑坡发生、发展和分布的各种边坡自然属性因子。类型齐全且意义明确的致灾环境因子，对提高滑坡易发性结果的准确性和可靠性至关重要。为了进一步明确致灾环境因子的研究现状和未来展望，本研究在 Web of Science 的核心合集数据库中进行了文献检索，标题中包含“landslide susceptibility”，出版日期范围从 20130101−20231231，收集了 767 篇滑坡易发性英文论文构成文献数据库。首先统计每篇文献中致灾环境因子数量、获取方法、来源、重要性和认可度等信息，然后详述了致灾环境因子的定义和物理意义；之后对致灾环境因子的优化选取/组合方法、因子联接方法、因子误差及其适宜性等特征进行了讨论，为后续预测滑坡易发性时选取致灾环境因子的不确定性研究提供参考。综述结果表明：①文献数据库中共统计出 82 种致灾环境因子，使用频率较高的因子有 40 余种，其中坡度、坡向、高程、岩性是使用频率最高的 4 个因子，坡度、高程、公路密度、岩性、降雨等因子在滑坡易发性预测中的重要性依次增高；②发现采用类型齐全且物理意义明确的致灾环境因子、基于环境因子联接方法来构建模型输入变量、消除环境因子中的随机误差、提升环境因子的适宜性和内在可解释性等研究有利于大幅提升机器学习方法预测滑坡易发性的性能，在未来研究中需要重点关注这些关键问题。

关键词：滑坡易发性；致灾环境因子；机器学习；不确定性讨论；地形地貌因子；水文环境因子；地表覆被因子；地层岩性因子

滑坡易发性是指在研究区域内，多种致灾环境因素的非线性相互作用下，某一特定斜坡演变为滑坡的空间概率分布[1]。精确预测滑坡易发性对于防灾减灾工作非常重要，它不仅为政府相关部门的土地利用规划与灾害防控决策提供了科学依据，还提高了滑坡灾害应急响应措施的有效性[2]。近 20 a 来，通过应用各类机器学习算法构建的滑坡易发性预测模型，已成功绘制出准确的滑坡易发性分区图[3]。此类模型通过对滑坡与非滑坡区域环境变量的深入分析，捕捉并模拟了复杂的非线性关系，从而实现对研究区内滑坡风险的全面评估。这些模型包括支持向量机[4]、人工神经网络[5]、随机森林等决策树类模型[6]、极度随机树[7] 和梯度提升模型[8] 等。研究表明，在所有模型中，决策树系列机器学习方法因其较高的稳定性和泛化能力而表现出显著优势。

基于机器学习模型的滑坡易发性预测是一个基于大数据源的复杂预测过程，包括对研究区内滑坡的成因机制进行深入分析，对滑坡编录及其相关致

著录信息：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.
HUANG Faming，CHEN Jie，YANG Yang，et al. A review and prospect of disaster-causing environmental factors related to landslide susceptibility prediction［J］. Bulletin of Geological Science and Technology，2025，44(2)：14-37.

© Editorial Office of Bulletin of Geological Science and Technology. This is an open access article under the CC BY-NC-ND license.　https://dzkjqb.cug.edu.cn

灾环境因子的数据采集与整理，将这些数据进一步作为机器学习模型的输出与输入变量，通过建立滑坡易发性预测模型可以对潜在滑坡的空间概率进行预测并得到滑坡易发性指数[9-10]。致灾环境因子选择、滑坡/非滑坡样本选择、评价单元类型、评估模型选取和模型参数优化都是影响最终滑坡易发性预测准确性的不确定性问题。其中，致灾环境因子是滑坡易发性预测面临的首要问题，环境因子中的各类不确定性特征会逐步传导至易发性预测的各个环节，甚至会呈现出放大效应[11]。可见致灾环境因子作为滑坡易发性预测模型数据输入的起点发挥着重要的作用[12]。

随着滑坡编录和致灾环境因子等空间数据获取技术的快速发展，空间数据集的质量得到了显著提升，为近 10 a 来滑坡易发性预测的快速发展奠定了数据和技术基础[13]。一般而言，具体研究区内的致灾环境因子类型可通过相关文献综述和研究区的自然地质条件来确定[14]。基于机器学习模型的滑坡易发性预测取决于现有滑坡编录和致灾环境因子的类型、丰富程度、质量，然而研究人员主要使用了他们所能获取的致灾环境因子，这些因子并不一定是特定区域建立滑坡易发性模型所需的最佳且更相关因子[10]。并且虽然现有研究使用了广泛的致灾环境因子，但是由于缺乏详细的描述和分类致灾环境因子的方法而存在不确定性。这是一个需深入探讨的问题，因为基于机器学习的滑坡易发性预测的质量受构建该模型的致灾环境因子的质量和相关性的影响非常大[10]。

综上所述，本研究拟通过滑坡致灾环境因子相关文献来开展环境因子的综述性研究，在此基础上系统性地探讨致灾环境因子定义和物理意义、因子选取、因子联接方法、环境因子误差、环境因子的适宜性和内在可解释性等问题，旨在为准确可靠的滑坡易发性预测研究奠定空间数据集基础。

1　研究方法及文献统计结果

1.1　文献研究方法

本研究系统地检索了 2013−2023 年之间的 767 篇代表性的滑坡易发性预测相关英文文献，文献获取流程如下：

①在 Web of Science（简称 WOS）的核心合集数据库（science citation index expanded）中进行了专项检索，检索内容为“标题=（landslide susceptibility）”。同时限定文献的出版日期范围，从 2013/1/1−2023/12/31。②对检索到的文献进行期刊精炼，重点关注了《Remote Sensing》，《Natural Hazards》，《Environmental Earth Sciences》，《Geocarto International》，《Bulletin of Engineering Geology and the Environment》，《Catena》，《Landslides》，《Geomatics Natural Hazards Risk》，《Sustainability》，《Applied Sciences Basel》，《Science of the Total Environment》，《Water》，《Geomorphology》，《Isprs International Journal of Geoinformation》，《Journal of Mountain Science》和《Geoscience Frontiers》等滑坡易发性文献发表数量多的期刊。经过这一步骤，共检索到了 1 087 篇相关文献。③将所有检索到的文献下载下来并逐一查阅。特别关注每篇文献中提及的滑坡致灾环境因子，记录了每类致灾环境因子出现的频数，以此作为文献综述分析的基础，由于部分文献无法下载或文献中并未提及致灾环境因子的原因，本研究最终成功统计到有致灾环境因子信息的文献共计 767 篇。

对于文献数据库中的 767 篇文献，统计每篇文献中致灾环境因子类型数量、获取来源、因子重要性和认可程度等。全面搜集文献中出现的各类致灾环境因子并进行详细描述，以此尽可能丰富致灾环境因子类型。在完成因子收集后，进一步深入分析这些因子在滑坡演化阶段的具体作用以及影响方式，从而清晰阐述其对滑坡演化过程的影响。

1.2　文献综述结果的统计分析

根据对 WOS 数据库中上述滑坡易发性相关文献的统计分析可知，滑坡易发性研究的关注度近年来呈现持续上升的趋势。具体而言，2013 年该领域的发文量为 36 篇，2013−2023 年的发文量依次从 36，42，50，71，73，82，125，136，155，163 篇增长至 170 篇。论文发表数量的逐年增长充分表明滑坡易发性预测是目前滑坡领域的研究热点，吸引了越来越多的国内外学者投入其中。在精炼出的出版物来源中，发文量排名前 20 的出版物如表 1 所示，揭示了不同期刊在滑坡易发性研究领域的贡献和影响力。其中《Natural Hazards》期刊在滑坡易发性预测领域的发文量最多，达到了 120 篇，这反映出《Natural Hazards》期刊在该领域的活跃度和影响力。相比之下《Engineering Geology》期刊的发文量较少，为 27 篇。虽然《Engineering Geology》发表滑坡易发性论文的篇数相对较少，但其发表的论文通常具有较高的质量和专业性，在一定程度上体现了该期刊在滑坡易发性领域的专业性和深度。

表 1　2013–2023 年出版物发文数量

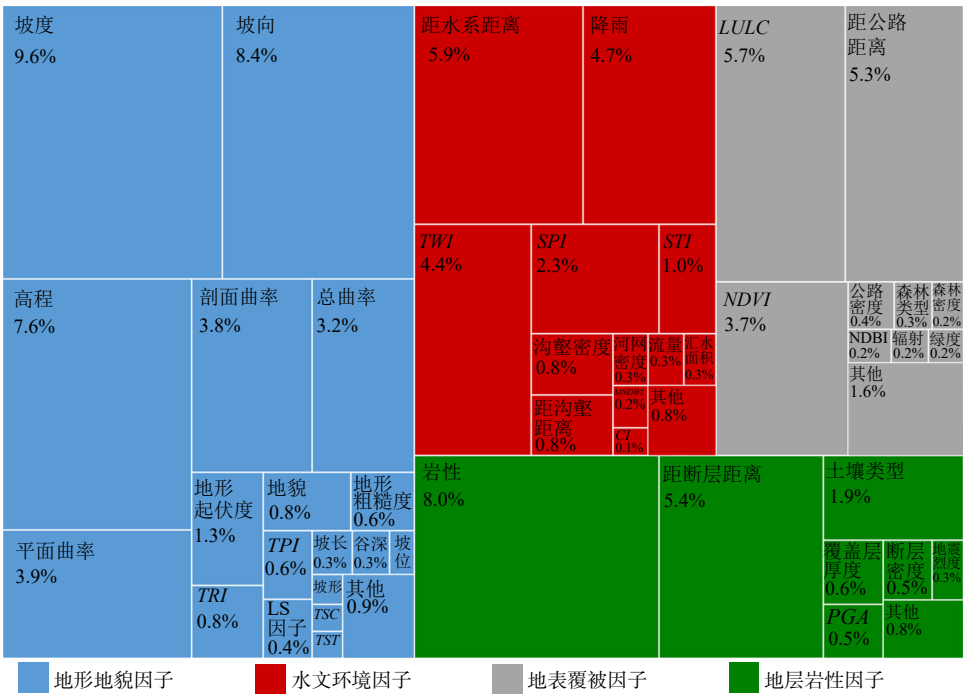
Table 1　Number of publications issued from 2013 to 2023

出版物名称	发文量/篇
Natural Hazards	120
Environmental Earth Sciences	118
Remote Sensing	102
Landslides	88
Bulletin of Engineering Geology and the Environment	75
Geocarto International	74
Catena	68
Geomatics Natural Hazards Risk	61
Geomorphology	53
Applied Sciences Basel	46
Journal of Mountain Science	45
Isprs International Journal of Geoinformation	43
Sustainability	43
Natural Hazards and Earth System Sciences	31
Frontiers in Earth Science	30
Engineering Geology	27
Water	23
Science of the Total Environment	20
Sensors	20
Geoscience Frontiers	17

1.3　致灾环境因子使用情况

通过对 767 篇文献的统计，共查找出 82 种不同的滑坡致灾环境因子，这些因子在滑坡易发性预测中被使用的频率有所差异，但均扮演着机器学习模型输入变量的重要角色。为了更系统地理解这些因子的分布与影响，我们将其归为四大类别：地形地貌、水文环境、地表覆被、地层岩性。由于自然地理环境和地质条件的差异性，导致不同滑坡易发性预测中研究区位置、滑坡类型和属性特征均有所不同，故所选用的致灾环境因子也有差异性，而且各类致灾环境因子的占比和使用频率反映了其在研究中的关注度和重要性。

从图 1 各类致灾环境因子使用频率占比中可以看出，地形地貌类因子在总数中占比最高，达到了 42.8%。在这一类别中坡度的使用频率尤为突出，占比 9.6%，显示出其在滑坡易发性研究中的关键作用。紧随其后的是坡向、高程、平面曲率、剖面曲率等因子，它们共同构成了影响滑坡易发性的重要地形地貌因素。水文环境类因子占比为 21.6%，其中距水系距离的使用频率最高，占比 5.9%，这表明学者们普遍重点关注了水系分布与滑坡易发性之间存在的密切联系。此外，地形湿度指数、降雨量、河流功率指数、沟壑密度等环境因子也是研究者们关注的焦点。地表覆被类因子占比为 17.8%，其中土地利用/土地覆盖因子占比最高，达到 5.7%，显示人类工程活动对滑坡易发性的影响不容忽视。与此同时，距



LULC. 土地利用/土地覆盖；*TWI*. 地形湿度指数；*SPI*. 水流强度指数；*STI*. 沉积物运移指数；*NDVI*. 归一化差异植被指数；*NDBI*. 归一化差异建筑指数；*MNDWI*. 修正的归一化差异水体指数；*TPI*. 地形位置指数；*TRI*. 地形韧性指数；*LS*. 坡长陡度；*PGA*. 地面峰值加速度；*TST*. 地形表面纹理；*TSC*. 地形表面凸度；*CI*. 收敛指数；下同

图 1　在 767 篇英文文献中各类致灾环境因子使用占比

Fig. 1　Proportion of various disaster-causing environmental factors used in 767 foreign literatures

公路距离、归一化植被指数等因子也反映了地表覆被状况对滑坡易发性的潜在影响。地层岩性类因子占比为 17.8%，其中岩性因子占 8.0%，显示了岩性是地层岩性中的核心因子。不同岩性对滑坡发育的影响机制各不相同，因此需深入探索岩性特征对滑坡易发性预测的影响机制。最后，所统计的致灾环境因子中有的出现比例不高，但其中也包含了一些具有显著意义或使用潜力的环境因子（如人口密度[15]、膨胀矿物含量[16]、永久冻土分布概率[17]、冻结深度[18]等），值得进一步探讨和挖掘。

随着科技的不断进步和研究的深入，因子类型的数量持续增加[19]。新技术的应用和更广泛的研究揭示了更多潜在因子。例如，高光谱遥感技术提供了新的植被指数[20]；时序 InSAR（合成孔径雷达干涉测量）技术能够捕捉 mm 级的地表形变，并将动态位移量转化为定量因子[21]；寒区边坡的反复冻胀–融沉作用可以通过永久冻土分布概率因子进行量化[17]。研究人员不仅应关注已知的关键因子，还需保持开放的心态，积极探索尚未被充分认识的新因子。跨学科合作在这一过程中至关重要，气象学、地质学、生态学等多个领域的专家共同参与，能够从不同视角揭示滑坡问题的复杂性。因此，未来的研究应紧密结合区域特异性和新兴机制因子，通过多学科交叉融合，深入挖掘滑坡中的关键因素，以实现对滑坡风险更全面的评估与预测。

2　致灾环境因子定义及其物理意义

2.1　致灾环境因子获取方法

理论上，滑坡易发性建模可采用的致灾环境因子种类繁多。然而，受限于基础数据源的获取以及空间分析技术的能力，多数研究仅选择了十余种较容易获取的致灾环境因子进行滑坡易发性预测[22]。部分文献则侧重于使用主控致灾环境因子来预测滑坡易发性[23]。然而，在构建滑坡易发性预测模型时，若仅依赖于少数易获取的致灾环境因子作为输入变量，则可能会因为信息不全面而难以完整揭示滑坡的发育特征[10]。这种局限性可能导致易发性预测结果的不准确和低可靠性。因此，获取到物理意义明确类型更丰富的致灾环境因子，能更全面地描述滑坡发育的属性特征，由此建立的易发性预测模型能更准确地反映滑坡与其致灾环境因子之间的交互作用关系[24]。表 2 介绍了主要致灾环境因子主要获取方法。

2.2　地形地貌因子

（1）数字高程模型（digital elevation model，简称 DEM）[25]，是一种在地理信息系统（geographic information system，简称 GIS）空间分析中常用的地形数据模型。它以一组有序数值阵列的形式来实现对地表高程的数字化模拟，即将地形表面的形态以高程数值的方式进行表达。DEM 可作为滑坡地质模型构建的基础数据，利用数值模拟方法来结合 DEM 中的地形信息和水文数据，以模拟滑坡发生的可能性、规模和影响范围。DEM 数据可为滑坡风险评估和应对措施的制定提供科学依据，也可为灾后救援和重建提供重要的基础数据支持。

（2）坡度（slope）[26]，表示地表单元陡缓的程度，可以用度（°）或百分比（%）来表示，通常把坡面的垂直高度和水平方向的距离的比叫作坡度（图 2a）。坡度的大小与其内部应力分布密切相关，一般来说，坡度较小的区域会限制坡面径流进而影响地下水的补给和排水。同时，坡度对边坡稳定性具有非常重要的影响，甚至直接决定了斜坡体上的松散物质能否保持稳定。坡度越大时斜坡上的松散物质越难保持稳定状态，越容易发生滑动。然而堆积层滑坡发生的概率与坡度的关系并非简单的线性递增，而是在特定坡度范围内达到峰值，这是因为在坡度较高的区域往往难以覆盖出足够厚度的堆积层。

（3）坡向（aspect）[27]，定义为坡面法线在水平面上的投影的方向，在 GIS 空间分析中系指地形坡度所面向的罗盘方向，通常以“北”为基准方向进行测量，单位为（°）（图 2c）。在北半球，南坡向因为接收太阳辐射更多而被视为阳坡，反之北坡则视为阴坡。这种坡向间的差异不仅会导致气温和湿度的变化，还会对植被的分布和生长状况造成显著影响，进而影响边坡的稳定性特征。

（4）剖面曲率（profile curvature）[28]，是沿着地面坡度的最大坡降方向，对地面高程变化率的度量（图 2d）。剖面曲率的值为正时表示曲面在剖面方向上是凸形，而当其值为负时则表示曲面是凹形。在凸形区域由于地面高程变化率较大，岩土体可能更容易受到应力集中和剪切作用，从而增加滑坡的风险；相反，在凹形区域地面高程变化率较小，可能相对更稳定，滑坡风险可能较低。此外，剖面曲率控制着沿坡流方向的水流流速，进一步影响着土壤侵蚀和沉积过程，从而对滑坡易发性产生影响。在 GIS 空间分析中，可以对特定区域的 DEM 高程数据进行二次坡度计算从而得到剖面曲率。

表 2　主要致灾环境因子获取方法

Table 2　Main methods of obtaining disaster-causing environmental factors

因子类别	致灾环境因子	获取方法
地形地貌	高程	来源于数字高程模型DEM
	坡度、坡向、剖面曲率、平面曲率、地形起伏度、地形粗糙度、高程变异系数、地表切割深度、总曲率、坡长、坡位、地貌	通过ArcGIS软件中spatial analyst工具基于高程提取
	谷深、地形韧性指数、相对坡度位置、地形位置指数、地形表面凸度、地形表面纹理	由SAGA软件中terrain analysis工具提取
水文环境	地形湿度指数、沟壑密度、流量、距水系距离	通过ArcGIS软件中spatial analyst工具基于高程提取，其中水系可通过流量和流向提取河网
	降雨量	通过国家气象科学数据中心下载
	MNDWI	通过遥感数据中的可见光波段和近红外波段的反射率，计算两者之间的差异获得
	水流强度指数、沉积物运移指数、闭合洼地、汇水面积、收敛指数	由SAGA软件中terrain analysis工具提取
地表覆被	森林类型、森林密度、公路密度、距公路距离、辐射	可通过91卫图助手获取
	NDBI、*NDVI*	通过遥感数据中的可见光波段和近红外波段的反射率，计算两者之间的差异获得
地层岩性	岩性、断层密度、距断层距离	岩性与断层可通过地质资料档案馆下载
	土壤类型、覆盖层厚度	土壤类型可通过91卫图助手下载，覆盖层厚度通过野外调查获取
	距震中距离、*PGA*、地震烈度	PGA、地震烈度由美国地质调查局（USGS）下载，距震中距离在ArcGIS软件中通过欧式距离分析得到

（5）平面曲率（plan curvature）[15, 29]，系指在地形表面上，用过某一点 P 的水平面沿水平方向切地形表面所得的曲线在该点的曲率值（图 2j）。平面曲率是该点所在的微小范围内坡向变化程度的度量，其通过控制水流在径流过程中的汇聚或发散来影响侵蚀过程，进而对滑坡易发性产生影响。在 GIS 空间分析中，可以对 DEM 高程数据进行坡向分析，然后再对坡向数据进行坡度计算即可得到平面曲率。

（6）地形起伏度（topographic relief）[30]，是对区域高程分布和地表切割程度的综合表征，指在一个特定的区域内最高点高程与最低点高程的差值（图 2k）。地形起伏度是水土流失评价的重要地形指标，山高坡陡地区地形起伏大，为土壤侵蚀提供了势能。在 GIS 空间分析中，地形起伏度计算如式（1）所示，其中 R_{el} 为地形起伏度；DEM_{max} 为所计算像元与搜索范围中像元 DEM 的最大值；DEM_{min} 为所计算像元与搜索范围中像元 DEM 的最小值。

$$R_{el} = DEM_{max} - DEM_{min}。\quad（1）$$

（7）地形粗糙度（terrain roughness or surface roughness）[31]，是地表单元的曲面面积与其在水平面上的投影面积之比，能够反映地形的起伏变化和侵蚀程度（图 2b）。较为粗糙的地形通常具有更多的凹凸和不规则的表面特征，这会影响滑体的分布形态及其与斜坡的接触面积。地形粗糙度的计算如式（2）所示，其中 R_{ou} 为地形粗糙度；*SLOPE* 为所计算栅格代表的坡度值。

$$R_{ou} = 1/\cos(SLOPE \times 3.1415926/180)。\quad（2）$$

（8）高程变异系数（coefficient of elevation variation）[32]，是一种以格网单元顶点的标准差与平均高程的比值来测量地形复杂度的指标，它反映了地形上每个位置与周围位置高程差异的大小（图 2e）。该指标的值越大则说明地形复杂度越高，可能属于山地或构造带地貌；反之则地形复杂度越低，可能属于平原或丘陵地貌。其计算如式（3），其中：COE_{ev} 为高程变异系数；DEM_{std} 为所计算像元与搜索范围中像元 DEM 的标准差；DEM_{mean} 为所计算像元与搜索范围中像元 DEM 的平均值。

$$COE_{ev} = DEM_{std}/DEM_{mean}。\quad（3）$$

（9）地表切割深度（surface cutting depth）[32]，是指地面某点的邻域范围平均高程与该邻域范围内最小高程之间的差值，它直观地反映了地表被侵蚀切割的情况。其计算如式（4）所示，其中 CUE_{de} 为地表切割深度。

$$CUE_{de} = DEM_{mean} - DEM_{min}。\quad（4）$$

（10）谷深（valley depth）[33]，是海拔高度与内插

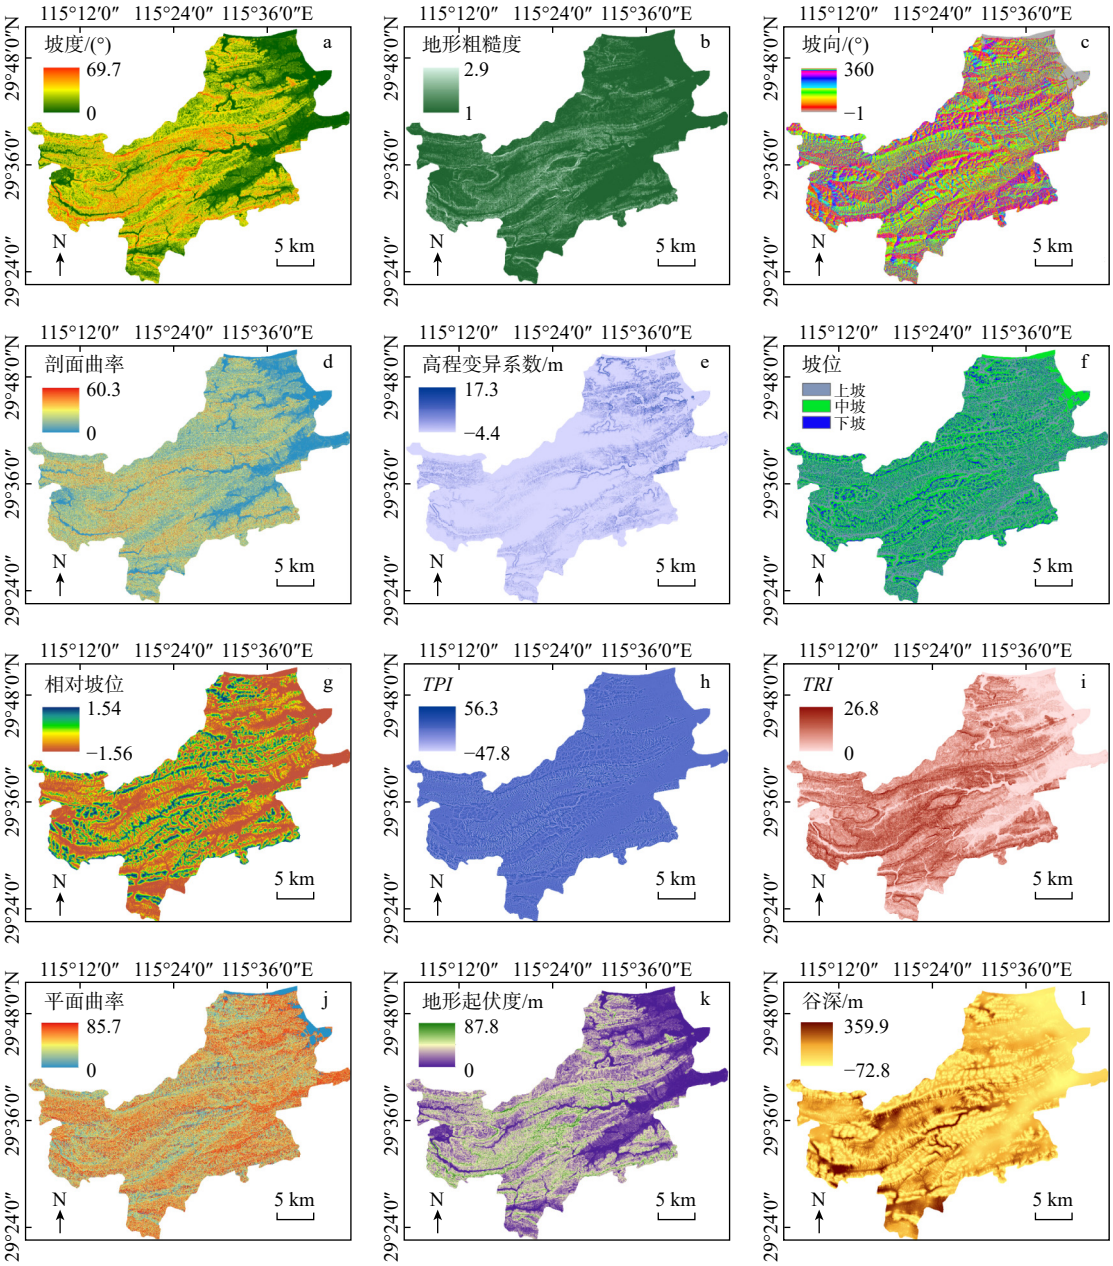


图 2　瑞昌市部分地形地貌因子图

Fig. 2　Part of the topographic and geomorphic factor map of Ruichang City

山脊高度之间的差值。山谷深度可以用于评估山谷的大小、陡峭程度和地形起伏（图 2l）。如式(5)所示，其中 VAL_{de} 为山谷深度；DEM_{rid} 为山脊高程值经水平插值后的高程；DEM 为原始高程值。

$$VAL_{de} = DEM_{rid} - DEM。 \tag{5}$$

(11)地形韧性指数(terrain ruggedness index，简称 TRI)[34]，是一种用于描述地形复杂程度和不规则程度的指标（图 2i）。TRI 通过测量地形表面的高程变化来评估地形的起伏和粗糙程度。TRI 值较高意味着地形起伏度较大，地表较为崎岖或复杂，往往增加了滑坡等地质灾害发生的风险；相反，TRI 值较低表示地形较为平坦或均匀，发生滑坡等地质灾害的风险相对较低。其计算如式(6)所示，其中 DEM 为计算 TRI 像元的 DEM 值，DEM_i 为邻域像元的 DEM 值，n 为搜索半径内有效像元的个数。

$$TRI = \sqrt{\left(\sum_{i=1}^{n}(DEM - DEM_i)\right)/n}。 \tag{6}$$

(12)相对坡位(relative slope position，简称 RSP)[35]，是一种用于描述地表坡度相对位置的指标，系指某一个点相较于山脊和山谷的位置。其计算如式(7)所示，其中 ALT_{ac} 代表山谷线以上的高度，ALT_{br} 代表山脊线以下的高度。

$$RSP = ALT_{ac}/(ALT_{ac}+ALT_{br})。\quad (7)$$

(13)地形位置指数(topographic position index,简称 TPI)[36],系指该点高程值与其某邻域内其他点的高程平均值之差(图 2h)。TPI 算法将 *DEM* 单元值与其相邻单元的平均值进行比较,平均值根据用户选择的形状计算得出,正值代表该点高于周围位置的高程,而负值代表该点位置较低,接近零值代表平坦或恒定坡度的区域。其计算如式(8)所示:

$$TPI = DEM - \left(\sum_{i=1}^{n} DEM_i\right)/n。\quad (8)$$

(14)地形表面凸度(terrain surface convexity,简称 TSC)[37],表示地表在某个点周围区域的凸起程度或曲率。TSC 可以用于分析地形起伏、地形复杂性以及地貌特征的形态。其计算如式(9)所示,其中 N_{po} 为在指定的搜索半径内具有正曲率的单元格数量,N 为指定的搜索半径内所有有效单元格的数量。

$$TSC = N_{po}/N。\quad (9)$$

(15)地形表面纹理(terrain surface texture,简称 TST)[37],是指地形表面在水平和垂直方向上的变化程度或复杂程度,被定义为指定搜索半径内凹坑和山峰的网格单元数,它描述了地形表面的细节级别、起伏和粗糙度。*TST* 值通常由高程数据计算得到,较高 *TST* 值表示地表纹理较粗糙,即存在较大的高程变化和复杂的地形细节,而较低 *TST* 值表示地表纹理较平滑,即地形相对平缓。

(16)坡长(slope length)[38],是水土保持、土壤侵蚀等研究中的基本因子。一般在地形的坡度方向上,径流从其起点向下流动至任意点的轨迹在平面上的投影被称为坡长。坡长是影响坡面能量演化和坡面径流与水流产沙过程的重要地貌因素之一。某网格单元的坡长计算是基于坡度变化的累计长度。

(17)坡长陡度因子(slope length and steepness factor,简称 LS-factor)[28],是一种用于评估坡面侵蚀和水土流失风险的指标,在坡面尺度上可通过实测坡度和坡长计算 LS 因子。它是美国农业部(USDA)所开发的通用土壤流失方程(universal soil loss equation,简称 USLE)中的一个参数。其计算如式(10)所示,其中 $(1+n)(l/22.13)^n$ 称为 *L* 系数,*L* 系数表示斜坡长度的影响;$((\sin SLOPE)/0.0896)^m$ 称为 *S* 系数,*S* 系数表示斜坡陡度的影响;*l* 表示所计算栅格的坡长;*m* 和 *n* 均为修正系数,一般取值分别为 1.3 和 0.4。

$$LS = (1+n)(l/22.13)^n((\sin SLOPE)/0.0896)^m。\quad (10)$$

2.3　水文环境因子

(1)收敛指数(convergence index)[39],用于衡量地表水流在河流网络中的汇集和发散程度,它描述了水流汇集到特定点的速度和程度,可用于分析河流网络的形态特征和水文过程(图 3i)。其计算如式(11)所示,其中 CON_{in} 为收敛指数值;θ 表示搜索半径内像元的坡向与其到中心像元的方向之间的差;n 为搜索半径内有效像元的个数,其值范围在−90°~90°之间。

$$CON_{in} = \left(\left(\sum_{i=1}^{n}\theta_i\right)/n\right) - 90°。\quad (11)$$

(2)闭合洼地(closed depressions)[40],也被称为地表坑洼或地下水坑洼。它们是由于地表或地下水体的溶蚀作用导致地表下陷形成的凹地或坑洞,最终形成了一个相对封闭的地形特征。其计算如式(12)所示,其中 CLO_{de} 为闭合洼地因子值;DEM_{fill} 为填洼后的 DEM 值;*DEM* 为原始 DEM 值。

$$CLO_{de} = DEM_{fill} - DEM。\quad (12)$$

(3)降雨量[41],是指在一定时间内某地区接收到的降水总量,通常以毫米(mm)为单位进行衡量(图 3g)。降雨量是气象学和水文学中的重要参数,用于描述降水的强度和时空分布特征。

(4)沟壑密度[42],是指在一个特定区域内沟壑(如河流、溪谷等)的长度与该区域面积的比值,沟壑密度是反映地表破碎程度的重要因子,在土壤侵蚀、地貌演变等研究中有重要作用。高沟壑密度意味着在该区域内沟壑的分布相对密集,地表水体和水流网络较为发达。

(5)地形湿度指数(topographic wetness index,简称 TWI)[43],是一种基于地形和降水数据计算的指数,它可以反映地表水分的分布情况(图 3a)。地形湿度指数通过 DEM 提取的坡度、流域汇流面积计算得到,能准确刻画地形变化及其对土壤径流的影响。其计算如式(13),(14)所示,其中 N_{cell} 为所计算像元上坡像元数,*C* 为像元长度,*SCA* 为特定集水区面积(每单位等高线长度的集水面积)。

$$TWI = \ln(SCA/\tan SLOPE),\quad (13)$$

$$SCA = (N_{cell}+0.5)C。\quad (14)$$

(6)修正的归一化差异水体指数(modified normalized difference water index,简称 MNDWI)[44],用于提取遥感图像中的水体信息(图 3h)。可以很容易地区分阴影和水体,解决了水体提取中难以消除阴影的难题。其计算如式(15)所示,其中 *GREEN* 代表

绿光波段的反射率，*MIR* 为中红外波段的反射率。

$$MNDWI=(GREEN-MIR)/(GREEN+MIR)。\quad（15）$$

（7）水流强度指数（stream power index，简称 SPI）[43, 45]，是用来衡量水流三维空间强度分布和速率的指标（图 3b），可定量描述水流侵蚀和地表演化的关系，通常被认为是影响边坡稳定性的一个影响因素之一。其计算如式（16）所示：

$$SPI=\ln(SCA\cdot\tan SLOPE)。\quad（16）$$

（8）沉积物运移指数（sediment transport index，简称 STI）[32]，能反映在沉积物本身属性和外动力作用下的沉积物运移状况，是一个用于描述地表坡面沉积物运移潜力的指数（图 3f）。它是由 RENARD[46] 提出的，用于评估土地退化和水土流失风险。STI 基于地形因素和流域特征，结合了坡度、坡向、地形曲率和流域贡献面积等因素来计算，如式（17）所示：

$$STI=(SCA/22.13)^{0.6}\cdot(\sin SLOPE/0.089\,6)^{1.3}。\quad（17）$$

（9）汇水面积（catchment area），也称为流域，是指一个地理区域内所有降水水分汇集到同一个出口点或水体的区域，是水文地理学和水资源管理中常用的概念。确定每个栅格的流向，就可得到每个栅格的汇流路径和汇水面积。

（10）距水系距离[43]，使用多环缓冲区工具分析生成栅格，以显示每个像素到最近水系的距离，能得到不同距离区间的分类属性表示，用于量化位置与水系网络的接近程度。

（11）流量[47]，通过在已经填洼的 DEM 基础上得到，是其上游所有栅格按照最大坡度的水流方向汇流下来的累积量。流量的数值越大，地表径流就越容易出现。

（12）河网密度（river density）[48]，表示的是单位区域内天然或人工河道总长度与区域面积的比值（图 3c），反映地表水文网络发育程度。高河网密度区域通常与强地表径流、地下水渗透加剧斜坡侵蚀相关，可能降低边坡稳定性。

（13）岩石风化指数（rock weathering index）[49]，反映降雨对岩石风化程度的影响（图 3d），是指在太阳辐射、空气、水和生物体等的作用下，岩土体的破

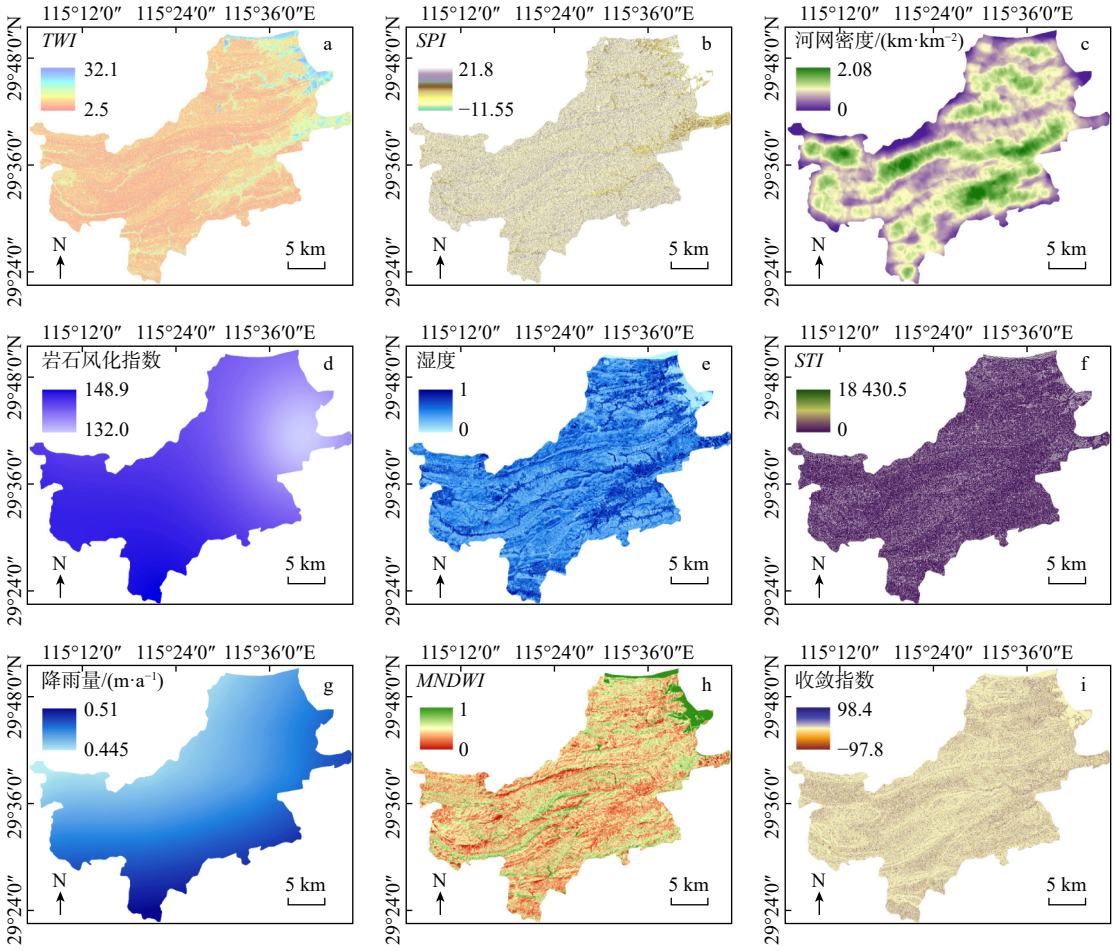


图 3　瑞昌市部分水文环境因子图

Fig. 3　Part of some hydrological environmental factor map in Ruichang City

碎、松动和矿物成分变化程度。岩石风化过程会破坏岩土体的结构，导致边坡稳定性整体下降。

（14）湿度（soil moisture）[50]，是指土壤孔隙中液态水的体积占比（图 3e），通过遥感（如 Sentinel-1 雷达反演）或原位传感器测定。高湿度增加土体自重并降低内摩擦角，是滑坡启动的关键触发因子。

2.4　地表覆被因子

（1）森林类型[51]，系指用遥感影像等数据根据植被组成、树种构成、生态特征和地理位置等因素对森林进行识别和分类制图。常见的森林类型主要包括：针叶林、阔叶林、混交林等。

（2）森林密度[52]，系指单位面积内森林植被的覆盖程度或植被的浓密程度，用于描述森林的结构特征之一，反映了森林中植被的数量和分布密集程度。高密度的森林具有更多的植被覆盖，能够提供更多的生态系统服务，如保持土壤水分、保护水源、减少土壤侵蚀等。

（3）公路密度[53]，系指在一个特定区域内公路的长度与该区域面积的比值（图 4h），用于描述公路在地理空间上的分布密度和集中程度，可以作为衡量交通发达程度和土地利用情况的指标。

（4）归一化差异建筑指数（normalized difference built-up index，简称 NDBI）[44]，是一种用于反映建筑用地分布特征的指数，它可以通过计算可见红波段和短波红外波段之间的归一化差异来获取（图 4b）。*NDBI* 数值越大表明建筑用地比例越高，其计算如式（18）所示，其中 *SWIR* 为短波红外波段的反射率；*NIR* 为近红外波段的反射率。

$$NDBI = (SWIR - NIR)/(SWIR + NIR)。\quad（18）$$

（5）归一化差异植被指数（normalized difference vegetation index，简称 NDVI）[44]，是一种常用的遥感指数，用于评估和量化地表植被的绿度和生长状况（图 4c）。它基于遥感数据中的可见光波段和近红外波段的反射率，通过计算两者之间的差异来表示植被的相对繁茂程度。其计算如式（19）所示，其中 *R* 为红波段的反射率：

$$NDVI = (NIR - R)/(NIR + R)。\quad（19）$$

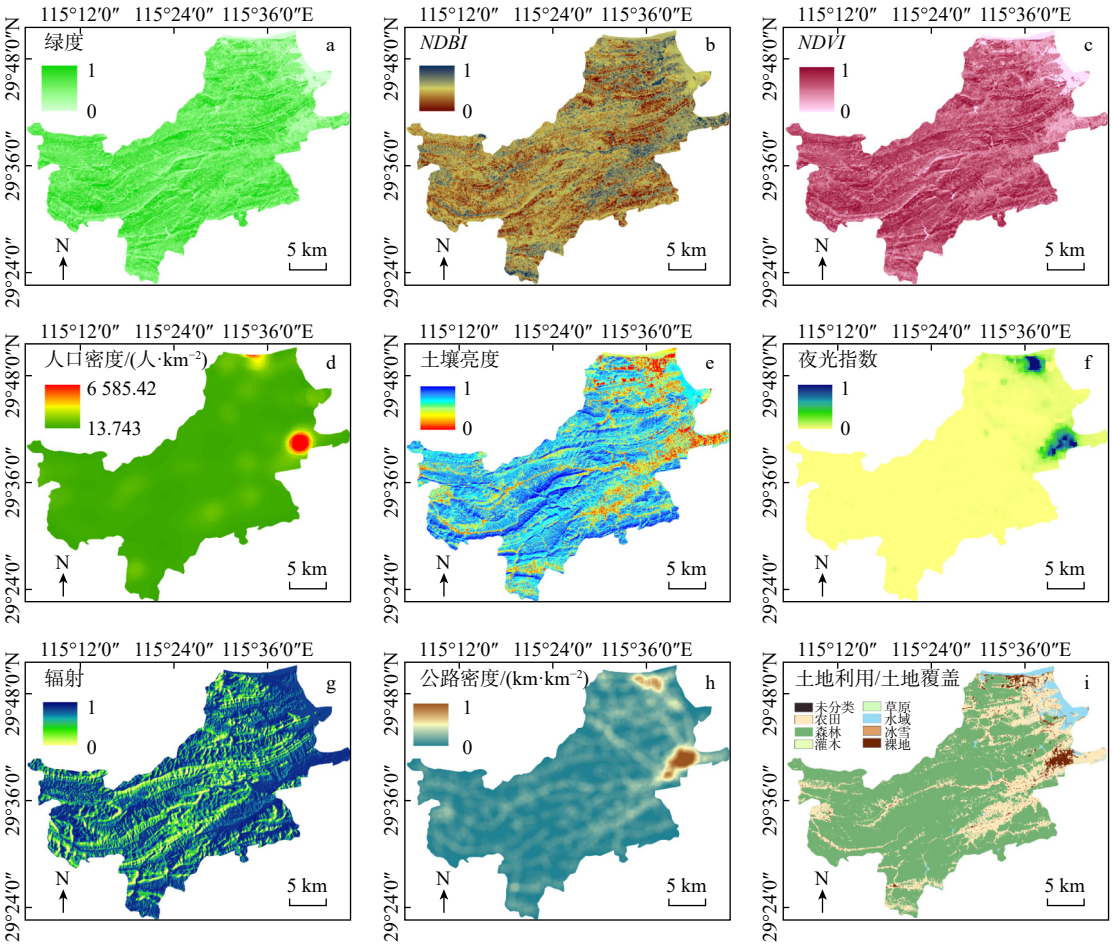


图 4　瑞昌市部分地表覆被因子图

Fig. 4　Part of land cover factor map of Ruichang City

(6)距公路距离[54]，系指用多环缓冲区工具分析生成的栅格来显示每个栅格到最近公路的距离，可用不同距离区间的分类属性表示，也可以根据欧式距离来获得距公路距离的连续属性，用于衡量某一地点与公路之间的空间关系。

(7)辐射[55]，系指地球表面接收到的来自太阳辐射的总能量（图 4g），它包括直接辐射和太阳辐射在大气层中散射后到达地表的间接辐射。

(8)土地利用/土地覆盖(land use/land cover，简称 LULC)[56]，是指根据土地的不同用途将其系统地划分为多种类型(图 4i)。土地利用对滑坡的影响主要通过改变植被覆盖、水文条件、地表形状及人类活动强度等途径实现，这些因素直接影响了滑坡的发生概率及其发展过程。

(9)绿度(greenness index)[57]，是基于遥感植被指数的量化指标(图 4a)，反映地表植被覆盖密度及生物量。高绿度区域植被根系可增强土体固结，但过度砍伐导致的绿度骤降会加速斜坡失稳。

(10)人口密度(population density)[58]，是指单位面积内常住人口数量(图 4d)，用于评估人口分布和地区承载能力。高密度区域人类活动(如切坡建房、修路)可能改变斜坡应力场，会放大滑坡灾害风险。

(11)土壤亮度(Soil Brightness)[59]，是基于多光谱遥感(如 Landsat SWIR 波段)反演的土壤表面反射率指标(图 4e)。高亮度值常与低有机质含量或土壤板结相关，可能指示地表渗透能力下降。

(12)夜光指数(nighttime light index)[60]，是指通过卫星夜光遥感数据量化的区域人工光源强度(图 4f)，用来表征人类活动强度。高夜光指数区域与城市扩张导致的自然斜坡改造相关，间接影响滑坡易发性。

2.5 地层岩性因子

(1)岩性[61]，是表层地质岩性的栅格表示（图 5d），可基于不同标准对其进行不同程度的分类，比如岩石成分、岩石结构和岩石构造等。一般地层岩性可粗略分为三大类：沉积岩、火成岩、变质岩。

(2)断层密度[62]，是指在一个特定区域内断层的长度与该区域面积的比值（图 5a）。断层是地壳中岩层断裂和错动的地质构造，通常是地震活动的主要原因之一。

(3)覆盖层厚度[63]，一般指基岩面以上第四系残坡积层与下伏全风化层的厚度，是影响堆积层边坡稳定性的非常重要的因素，但在往往难以准确获取大范围区域内覆盖层厚度分布。

(4)地面峰值加速度(peak ground acceleration，简称 PGA)[64]，是指地震时地面上观测到的最大加速度值，它表示地震震源释放的能量在地面上的最大影响程度。*PGA* 通常以加速度单位(如：m/s^2 或 gal)表示，*PGA* 的大小取决于地震的震级、震源距离、地质条件和地表类型等因素。

(5)距震中距离[65-66]，系指某一观测点与震中之间的地面距离。它通常用来描述观测点相对于地震事件的位置关系，可以影响地震的强度和震感程度，随着距震中距的增大斜坡失稳的可能性减小。

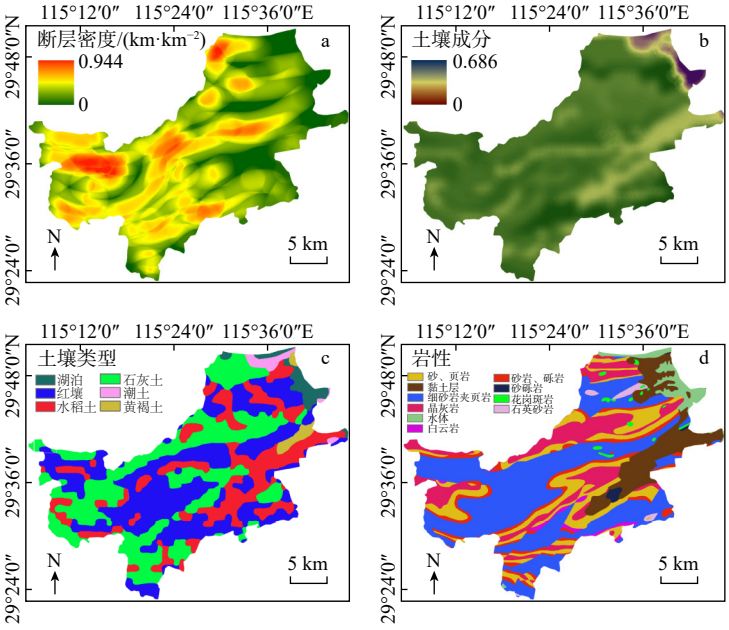


图 5 瑞昌市部分地层岩性因子图

Fig. 5 Part of the geological lithologic factor map of Ruichang City

(6)土壤成分(soil composition)[67], 是指土壤中矿物质(黏土、粉砂、砂砾)、有机质等的含量占比(图 5b)。土壤中黏土矿物如蒙脱石占比高时, 其渗透性差且遇水易膨胀, 显著影响斜坡抗剪强度。

(7)土壤类型(soil type)[68], 是指通过比较土壤间相似和差异性, 对研究区土壤进行分类组合(图 5c)。不同类型的土壤, 包括黏土、砂土、粉土、有机质土壤和岩石残积土等, 在渗透性和抗剪强度等方面的特性差异, 能够显著影响滑坡的发生。

(8)距断层距离[43], 系指每个栅格到最近断层的距离, 可用不同距离区间的分类属性表示, 当然也可以根据欧式距离来获得距断层距离的连续属性。它用于衡量某一地点与断层之间的空间关系。

(9)地震烈度(seismic intensity)[69], 是指地震时地面及各类建筑物遭受到地震影响的强弱程度。地震烈度通过对地表振动、土壤结构和水文条件的影响, 改变滑坡发生的可能性。

3　致灾环境因子相关讨论

3.1　各类致灾环境因子重要性讨论

由于研究区域和所使用机器学习模型的不同, 各个研究案例中的致灾环境因子重要性计算结果有所差异, 不过各个案例中环境因子的重要性在总体上也表现出了一定的规律性。本研究查找出开展了致灾环境因子重要性研究的文献总计 128 篇。记录每一篇所提及的致灾环境因子重要性值, 将同一种致灾环境因子的重要性值相加并除以对应的环境因子出现次数, 即可得出各环境因子的平均重要性值。可视化的统计结果如图 6 所示, 其中散点图显示了环境因子重要性数据的频数分布, 箱线图中 50% 的数据集中于箱体, 箱体大表示数据分布离散且波动较大而箱体小则表示数据集中; 概率密度图主要用来显示数据的分布形状, 在数据分布密度层面展示的效果更好。

由图 6 可知, 对于地形地貌类因子, 坡度的概率密度最大时对应的重要性值在 0.13 左右, 是重要性统计值最高的一类致灾环境因子, 说明坡度在滑坡易发性研究中的极端重要性; 其次, 高程概率密度最大时对应的重要性值在 0.1 左右, 并且所有地形地貌因子都是基于高程提取, 反映出高程的重要性不容忽视; 其余地形地貌环境因子如地形起伏度、平面曲率和剖面曲率等的重要性值大多在 0.03 ~ 0.1 之间。

对于水文环境类因子, 降雨量、距水系距离等的概率密度最大时对应的重要性值分别约为 0.09, 0.08, 说明降雨量、距水系距离对滑坡孕育的重要作用; 其余水文环境因子如收敛指数、地形湿度指数和水流强度指数等, 在降雨多发的东南丘陵地区对滑坡也有较大影响。

对于地表覆被类因子, 公路密度、土地利用等的概率密度最大时对应的重要性值分别约为 0.13, 0.09, 显示了较高的影响, 这是因为人类工程活动打破了原本处于平衡状态的边坡下滑/抗滑力; 其余地表覆被因子如 *NDVI*、*NDBI* 等对滑坡孕育也起到了一定的作用。

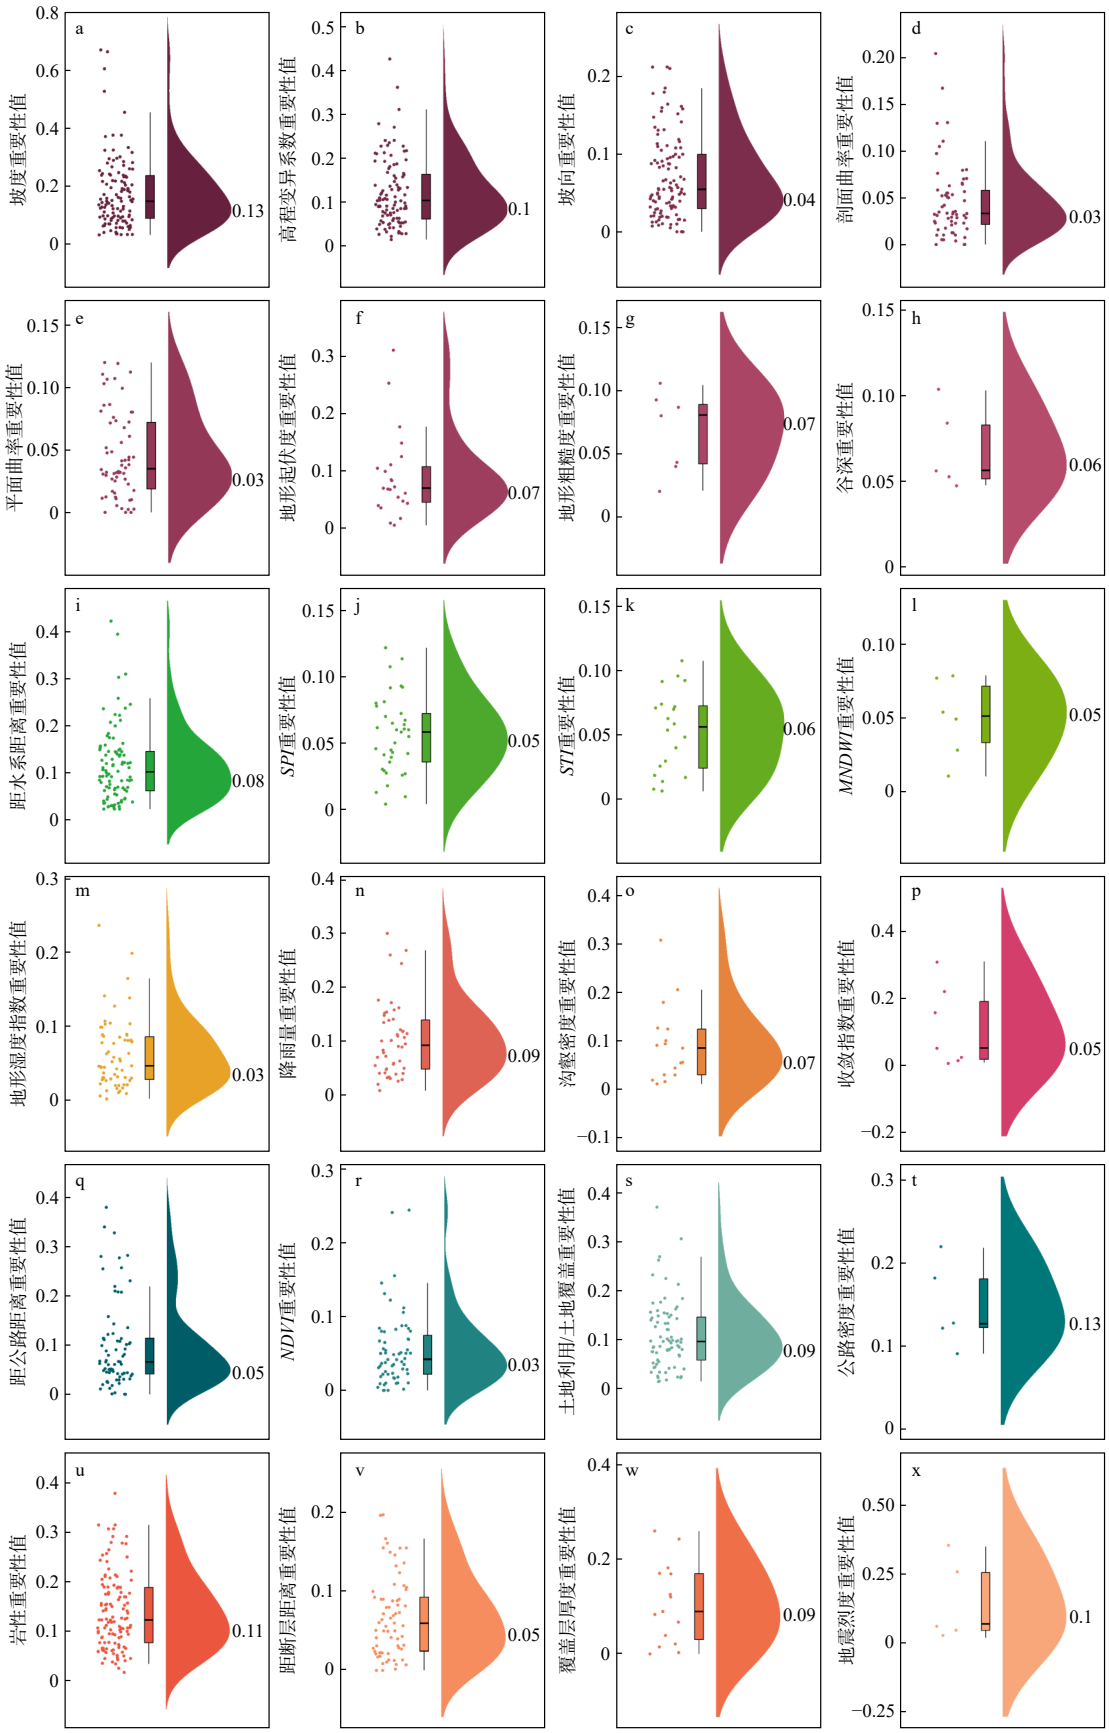
对于地层岩性类因子, 岩性、覆盖层厚度等因子的概率密度最大时对应的重要性值分别约为 0.11, 0.9, 说明这 2 个因子在地层方面对滑坡孕育的影响起到关键作用; 而其余地层岩性环境因子如距断层距离、地震烈度等, 在地震多发的西南地区地震滑坡易发性研究中显得尤为重要。

综上可知, 不同研究案例中所使用的致灾环境因子种类有所不同, 而且统计出的因子重要性值也有所差别, 为有效克服该问题, 本研究对致灾环境因子重要性值的综述直观地反映出了各类致灾环境因子对滑坡发育的重要程度。在所统计的致灾环境因子中, 坡度、高程、公路密度、岩性、降雨量等因子的重要性相对较高, 能在一定程度上反映出其对滑坡发生的影响很大; 而一些环境因子如平面曲率、剖面曲率、收敛指数、*TWI* 等因子的重要性相对较低, 对滑坡发生的影响较小。因子重要性在一定程度上反映了滑坡易发性模型的决策机制, 能够直观地展示哪些因子对滑坡的影响更为显著。它不仅提供了初步的解释功能, 还可以帮助识别异常因子[70]。

未来的研究应进一步优化和标准化因子重要性量化的方法。目前, 不同研究所采用的因子重要性量化方法存在显著差异, 这些方法与模型决策机制之间缺乏直接关联, 导致结果难以进行有效比较, 并降低了其可信度。通过引入统一的评估标准和技术手段, 例如基于夏普利加性解释(shapley additive explanations, 简称 SHAP)的因子重要性排序, 可以实现对现有大部分模型在全局、局部及单个样本层面上的因子重要性进行全面分析, 从而提高评估的准确性与一致性[71-73]。深化并规范化因子重要性量化的方法不仅是滑坡易发性研究深入发展的必要措施, 更是推动该领域向更高层次迈进的重要关键。

3.2　致灾环境因子适宜性的讨论

在上述文献综述中我们发现某些致灾环境因子



图中左侧为致灾环境因子重要性值散点图；中部为箱线图；右侧为概率密度图；图中数字表示概率密度最大时对应的重要性值

图 6　致灾环境因子重要性值统计

Fig. 6　Statistics of importance value of disaster-causing environmental factors

由于物理意义不明确或描述较为粗糙，而存在建模适宜性问题。其典型代表是大量文献中被广泛使用的距河网、公路或断层的距离等因子。现有在探究水系、公路和断层等线状环境因子时往往采用基于缓冲分析得到的距水系、公路和断层距离来表达[74]。然而这种对线状环境因子进行缓冲分析得到的离散型输入变量，通常将各样本点间的属性差别以同等的方式来对待；这种处理结果带有大小不等的随机波动性而且不能显示出点要素或线要素较为集中的地方，增加了易发性预测的不确定性[75]。此外笼统地认为距水系和公路距离等线状环境因子不仅会影响其临近的边坡，还会对距离较远的边坡产生影响，将使得滑坡易发性结果的可解释性较差。比如：河流或公路如何对距离其 1 000 m 以外的边坡产生影响？很显然河流或公路与距离其较远的边坡并无直接关联或物理上的作用关系[19]。

综上所述，对各类致灾环境因子的适宜性需要进行系统性的分析，尽可能采用物理意义明确、易于获取且准确度高的环境因子来表征滑坡发育过程。比如：为了有效反映河网、公路和断层等因子对滑坡发育的重要影响且提高因子表征的精度，可考虑提出河网密度、公路密度和断层密度等连续型因子来替换上述离散型因子，河网密度等因子具有更明确的物理意义且与滑坡发育的关联性更为紧密[76]。

3.3 致灾环境因子筛选与组合的讨论

特征选择是机器学习建模领域的一个重要研究方向，这是因为许多传统机器学习算法的性能可能受到冗余特征和大批量(样本数量庞大或样本特征维数高)数据处理的负面影响[77]。从现有文献综述来看，对于该使用多少种类的滑坡致灾环境因子、以及该使用什么方法来筛选因子并没有形成普遍认可的统一规则，现有滑坡易发性研究大多只选择了 10 余种易于获取的致灾环境因子[47, 78-79]。然而，将这些类别有限的 10 余种致灾环境因子用于滑坡易发性预测，显然难以全面反映边坡属性特征；同时将物理意义不明确或作用很小的致灾环境因子作为预测模型的输入变量，会使得模型性能下降且会因引入冗余信息而影响预测结果[10]。可见，开展致灾环境因子筛选以实现环境因子的优化组合具有非常重要的意义，目前常用的因子筛选方法包括地理探测器[80]、信息增益比[81]、递归特征消除[82]、相关系数法[83]、线性回归分析[10]、主成分分析[84]、粗糙集[85]和遗传算法[86]等。

①地理探测器是一种空间方差分析方法，其核心假设是如果自变量对因变量有重要影响，则自变量和因变量的空间分布应该是相似的，且这种相似性可以根据局部方差与全局方差的比率来衡量[80]。

②信息增益比是基于信息熵概念利用 10 倍交叉验证方法进行计算，以平均信息增益比作为平均价值，以此评价价值来评估致灾环境因子的重要性和排名[81]。

③递归特征消除的本质是基于线性判别分类器的权重值分配的贪婪算法，从整个输入的数据开始循环迭代，消除每次迭代中最不相关的致灾环境因子之一，最终选择出最优致灾环境因子的子集[87]。

④相关系数法用于衡量自变量之间相关性，2 个特征相关系数值越接近 0 表示越不相关，相关系数绝对值越接近 1 表示相关越强，最常用的是 Pearson 和 Spearman 相关系数[88]。

⑤线性回归分析法的核心思想是利用数理统计中回归分析方法的最小平方函数，从而确定一个及一个以上自变量与因变量之间相互依赖关系的一种分析统计方法[89]。

⑥主成分分析是一种线性变换方法，通过构建和分解方差–协方差矩阵以确定特征值和特征向量，首先选择特征值大于 1 的主成分，然后根据主成分对整体数据的方差贡献率来选择最具有解释性的主成分[84]。

⑦粗糙集基于信息系统、决策表和不可分辨性的概念，将多余的或相互干扰的致灾环境因子剔除，从而筛选出能够体现数据本质联系的重要环境因子[85]。

⑧遗传算法主要是基于自然选择和进化机制来建立，该方法模拟自然选择过程中的复制、杂交和变异现象，通过一代又一代的遗传进化来产生不同组合，可基于适应度值或模型 10 倍交叉验证得到的精度来实现致灾环境因子的筛选[90]。

这些方法在滑坡易发性预测研究中被广泛使用，比如 DU 等[47]、HUANG 等[91]、LEE 等[45]、CHEN 等[78]采用信息增益比或相关性分析法来剔除相关性强的致灾环境因子，以避免将冗余因子信息导入机器学习模型，在一定程度上提升了建模进度；KAVZOGLU 等[86]采用遗传算法从 16 个原始致灾环境因子中提取最优的 8 个环境因子，导入逻辑回归模型中预测土耳其 Macka 县的滑坡易发性，取得了最优的预测精度。吴雨辰等[85]采用粗糙集从 IBURI 地震区 17 种原始致灾环境因子中选出 8 种对滑坡易发性影响较大的环境因子，再导入 BP 神经网络中预测滑坡易

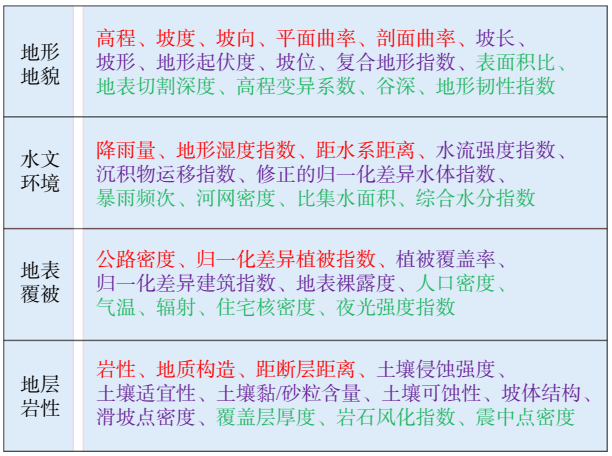
发性，结果显示粗糙集大幅提高了 BP 神经网络的精度；TANG 等[92] 从陕西某区域提取了 11 种致灾环境因子，再构建了基于原始环境因子和主成分分析结果的常规统计模型（证据权和逻辑回归等）预测滑坡易发性，结果显示主成分分析能有效提升常规统计模型的精度。这些文献中大多是采用 2000 年左右传统的信息量、逻辑回归、BP 神经网络或支持向量机等模型来预测滑坡的易发性，较少采用随机森林和深度学习等更为先进的机器学习模型。

进一步的文献挖掘表明，上述环境因子筛选方法能从自身算法特征出发寻找出对应的致灾环境因子组合方式，但是不同的因子筛选方法基于不同的假设或理论，意味着因子的重要性上并不能保持一致，可见对筛选方法本身的选择也存在不确定性，即难以确定哪一种筛选方法得到的环境因子重要性排名是更可靠的。更有甚者，部分学者发现环境因子筛选并不能显著提高滑坡易发性预测精度，甚至会因为有效信息丢失而导致精度下降。如 SUN 等[93] 采用递归特征法消除四川奉节县 22 种致灾环境因子中的多余因子，将得到的 13 种因子导入随机森林模型中预测滑坡易发性，结果显示 *AUC*（area under curve，指 ROC 曲线下与坐标轴围成的面积）精度仅提高了 0.9%；PHAM 等[94] 用卡方和逆向特征消除法去除 17 种环境因子中的冗余信息并导入神经网络中，结果显示易发性的 *AUC* 精度仅提高了 1.3%；LUCCHESE 等[95] 分别将 11 种原始环境因子、去相关的环境因子及其主成分分析结果导入神经网络中预测滑坡易发性，结果显示去相关性和主成分分析忽略了因子中的有效信息而导致精度下降。HUANG 等[91] 提取了贵州思南县总计 27 种致灾环境因子，在未开展因子剔除的情况下采用全连接稀疏自编码的深度学习方法来预测滑坡易发性，结果显示该深度学习能有效提取原始环境因子间的非线性和稀疏特征而无需担心因子间的信息冗余；ZHU 等[96] 提取了江西石城县 14 种致灾环境因子，再分别采用了主成分分析结果和原始环境因子作为多种机器学习的输入变量，结果显示消除环境因子的部分相关性并不一定能提高易发性预测精度。

综上可知，环境因子筛选对传统模型预测滑坡易发性具有一定的作用，但与近年发展起来的更先进的机器学习模型相比，则存在诸多不足：①没有从滑坡成因机制出发来获取类型更丰富的物理意义明确的环境因子，在建模初始阶段就难以全面反映滑坡发育特征[19]；②如果只考虑滑坡发育的主控因子，可能会难以识别相似的斜坡之间的细小差异，不利于精准预测滑坡易发性；③滑坡易发性建模过程较为复杂，如果额外增加环境因子筛选环节将进一步加大机器学习建模复杂度并引入新的不确定性；④未考虑机器学习的快速发展，现在较先进的机器学习模型对环境因子之间的相关性或冗余性的容忍度较高，若对环境因子进行筛选则可能会造成滑坡特征信息量的缺失从而影响建模准确性[91]；⑤大多数研究只是采用某一种环境因子筛选方法，而很少从不同环境因子筛选方法（也包括考虑全部环境因子）及不同机器学习深入对比的角度出发分析环境因子筛选的必要性[97]。现有环境因子获取研究中的缺陷，严重制约了高质量滑坡空间数据集的构建。因此，黄发明等[10] 认为在开展滑坡易发性建模时，可依据“数据准确、类型齐全、意义明确、操作可行和避免重复”原则构建出完善的致灾环境因子组合体系，以便先进的机器学习模型能更准确可靠地预测出滑坡易发性。未来的研究应在依据上述原则的基础上，获取足够多样且意义明确的致灾环境因子，从而进一步深化对环境因子的筛选与组合。结合地形地貌、水文环境、地表覆被、地层岩性等多种环境因子（图 7），依据不同的致灾环境因子筛选方法进行多因子组合分析。同时，可以利用可解释性方法揭示致灾环境因子间的耦合作用，以确保更深入、更全面、更准确地理解滑坡发生的机制。

3.4 致灾环境因子联接方法讨论

基于地理相似性规律即“地理环境越相似，地理特征越相近”可知，通过分析引发滑坡发生的致灾环



红色、紫色、绿色分别表示致灾环境因子在滑坡易发性预测中的使用频率高、中等、低

图 7 致灾环境因子汇总图（改自文献 [98]）

Fig. 7 Summary chart of disaster-causing environmental factors

境因子来建立预测模型，可有效预测将来可能发生滑坡的位置[99]。在建立滑坡易发性模型时，可开展滑坡与其致灾环境因子之间的非线性关联分析，其关联值可直接作为机器学习模型的输入变量。通过这种联接方法与机器学习模型的耦合，有可能提高滑坡易发性预测的可靠性，最重要的是能揭示出致灾环境因子对滑坡发育的非线性影响规律[100-101]。因此选择用以获取输入变量的滑坡–致灾环境因子联接方法非常重要，同时也应考虑各联接方法与机器学习模型耦合建模所产生的诸多不确定性[102]。目前常用的关联分析法包括确定性系数、频率比、熵指数、证据权、信息量、概率统计法等[103]：

①确定性系数是基于未来发生滑坡的条件和过去滑坡灾害发生的条件相似，根据致灾环境因子的子集中滑坡灾害面积和致灾环境因子的子集面积来计算[104]。

②频率比法通过滑坡与致灾环境因子之间的频率比值来表示致灾环境因子不同分级区间对滑坡的贡献程度[103, 105]（表 3）。

③熵指数是一种基于信息熵理论的客观赋权法，其通过各致灾环境因子的变异程度来计算各致灾环境因子对滑坡发育的影响程度[106]。计算熵指数前需对数据进行正向化和标准化，通过熵指数可计算出每个环境因子的权重。

④证据权是一种基于贝叶斯准则的综合各种证据层来预测某种事件发生概率的定量方法[107]。在进行证据权模型构建之前，需要对各评价因子之间进行独立性检验。

⑤信息量法认为滑坡灾害发生与否与预测过程中所获取的信息数量和质量有关，可以用信息量来衡量。具体采用滑坡发生过程中熵的减少来表征滑坡事件发生的可能性[108]。

⑥概率统计法定义为某一致灾环境因子属性区间内滑坡发生的面积与滑坡总面积的比值[103]。概率统计值可作为致灾环境因子对滑坡易发性的贡献依据，其值越接近 1 说明该分类对滑坡发育影响越大。

表 3 频率比法联接滑坡和环境因子[103]

Table 3 Frequency ratio method to connect landslide and environmental factors

环境因子	变量分类	频率比值
坡度/(°)	[0，3.6]	0.045
	(3.6，7.0]	0.550
	(7.0，10.6]	1.315
	(10.6，14.0]	1.651
	(14.0，17.6]	1.592
	(17.6，21.6]	1.391
	(21.6，26.8]	1.239
	(26.8，52.0]	0.892
岩性	变质岩	1.338
	碎屑岩	1.587
	岩浆岩	0.200
	碳酸盐岩	0.635
	水域	3.376
NDVI	[0，0.014]	0.429
	(0.014，0.120]	0.368
	(0.120，0.190]	0.688
	(0.190，0.243]	1.175
	(0.243，0.284]	1.182
	(0.284，0.322]	1.046
	(0.322，0.363]	1.027
	(0.363，1]	0.729

不同关联分析法的内在计算思路具有较大差异，导致各方法下的滑坡易发性预测存在不确定性[106, 109]。比如联接方法划分较粗糙会导致部分环境因子信息丢失，降低模型预测精度。可见，探讨不同联接方法与机器学习模型耦合下的滑坡易发性预测不确定性规律具有重要意义。比如李文彬等[103]通过概率统计法、频率比法（表 3）、信息量、熵指数和证据权 5 种联接方法分别耦合逻辑回归、BP 神经网络、支持向量机和随机森林模型共构建出 20 种耦合模型，对江西省瑞金市开展易发性预测研究，结果显示将原始环境因子数据直接用作输入变量的单独数据驱动模型预测的滑坡易发性精度整体略低于耦合模型。王启盛等[100]将信息量法、确定性系数法和频率比法 3 种联接方法分别与随机森林模型耦合，来预测四川省宁南县滑坡易发性，结果表明 3 种耦合模型性能均优于单一随机森林模型。

本研究认为，将原始致灾环境因子直接用作输入变量的单独机器学习模型具有较高的滑坡易发性建模效率，但仅用单独机器学习模型预测的滑坡易发性精度整体而言略低于经过因子联接方法处理后的精度。因此为了体现滑坡与其致灾环境因子的空间联接性或分析环境因子各子区间对滑坡发育的影响规律，在进行滑坡易发性预测时可考虑基于联接方法的耦合模型，当然为了提高建模效率也可以不考虑采纳联接方法。然而，当前研究中使用的致灾环境因子联接分析法主要基于小数据量（致灾环境因子少和样本数据少）场景。

随着研究的不断深入和数据量的持续增长，如何有效利用这些数据并优化因子联接方法或许是滑

坡易发性研究的关键问题[110]。为了更全面地理解这一问题，未来的研究应进一步探讨在丰富的致灾环境因子情况下，使用合理的环境因子联接方法与不使用时的精度差异，从而更好地评估联接分析方法的重要性。

3.5 致灾环境因子误差的讨论

在滑坡易发性预测过程中，滑坡空间数据源的误差（如：滑坡编录、致灾环境因子等）导致的建模不确定性会大幅降低预测精度。由于制图技术水平有限、致灾环境因子的空间分辨率不高、GIS 空间分析参数的不确定性以及专业人员的认知水平有限等因素的影响，滑坡数据源不可避免地会出现误差。这些误差直接影响模型输入和输出变量的可靠性，被认为是导致滑坡易发性预测模型性能不理想的最重要原因之一[111]。然而现有研究大多忽略了这些误差对易发性建模的影响，加剧了建模的不确定性。只有少部分研究重点关注了致灾环境因子误差对滑坡易发性预测的影响，同时也开发了一些工具和方法来解决这种不确定性问题。例如，QIN 等[112] 选择关注误差分析中最重要的制约因素，并使用蒙特卡洛模拟 DEM 误差来分析滑坡易发性建模中的不确定性；HUANG 等[12] 在所使用的连续性致灾环境因子中加入随机误差（图 8），并利用低通滤波法对其进行平滑处理来消除这些误差，探讨了不同致灾环境因子随机误差下滑坡易发性建模的不确定性。由于不可控因素所造成致灾环境因子的误差广泛存在，非常有必要对致灾环境因子的误差及其来源进行分析，探讨这些误差对建模不确定性的影响并进一步探索降低因子误差的方法。

对于各类连续型因子数据，如数字高程数据、遥感影像等（岩石类型可视为离散型因子），可将其中的误差分为系统误差和随机误差[12]。系统误差是在管理原始数据的过程中，由于仪器仪表或人工等不可避免的因素造成的；相比之下，随机误差受地球磁场、地形、植被特征、天气等因素的影响而形成。一般来说，通过校准仪器精度和调整成图数据可以减小系统误差。此外，通常可采用蒙特卡洛、低通滤波、小波分析和卡尔曼滤波等方法来估计随机误差，以减少其对易发性预测模型的影响。今后研究中建议进一步探索滑坡编录误差和致灾环境因子误差对滑坡易发性预测的影响规律，并提出更高效的方法来降低其中的误差影响。

此外，致灾环境因子并非静态不变，在环境变化显著的区域，使用过时的数据可能导致预测结果失真。通过集成实时监测数据并结合已构建的可靠模型，可以更准确地评估滑坡易发性的动态变化，并提前预警潜在的滑坡事件[113]。因此，研究这些因子的动态变化至关重要，需要综合考虑地质构造活动、气候变化和人类活动等因素对致灾环境因子数据的影响。建议通过长期监测和数据分析，构建时空连续的致灾环境因子集，系统评估各因子的重要性变化趋势，以深化滑坡易发性研究，从而深入了解其动态演变过程对滑坡的影响。

3.6 滑坡致灾环境因子可解释性研究

目前机器学习模型预测滑坡易发性存在的一个严重缺点是致灾环境因子作用于滑坡易发性的可解释性不足，比如人工神经网络、梯度增强模型或复杂的集成模型等的内部工作机制难以被解释、无法估计每个特征对易发性结果的重要性、难以理解不同致灾环境因子之间的相互作用关系等[114]。一些简单

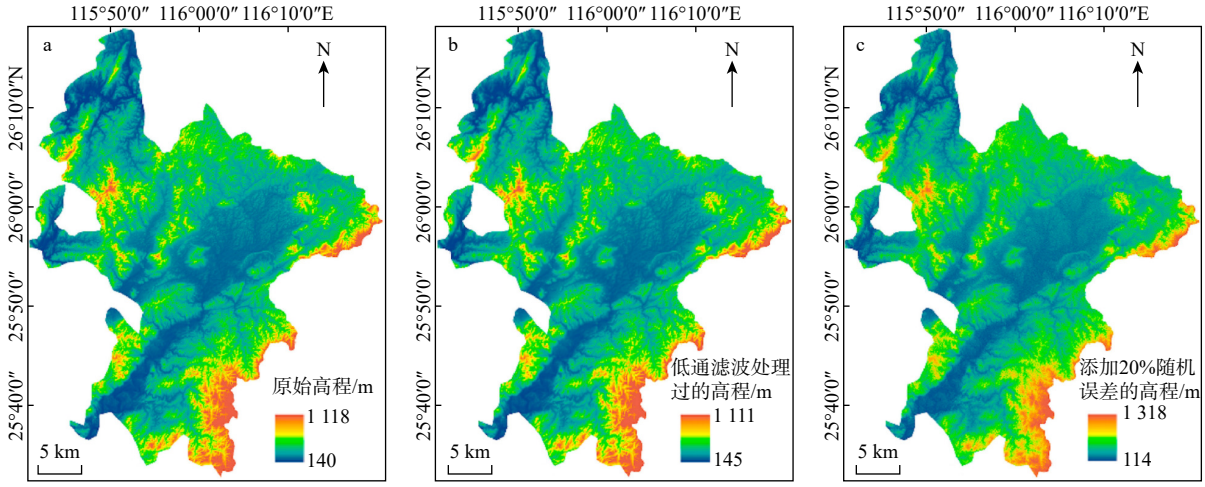


图 8 基于不同随机误差条件下的 3 种高程的滑坡易发性模拟

Fig. 8 Simulation of landslide susceptibility based on three different elevations under various random error conditions

模型本身就基于一些易于理解的统计知识而具备一定的可解释性，但是复杂机器学习模型往往需要依赖事前或事后解释方法等，其中事后解释方法被关注的更多。相对于模型特定解释方法，事后解释方法的优势是它们兼具基础模型的性能和可解释性，包括部分依赖图 、个体条件期望图、累积局部效应图、LIME 法（局部可解释模型不可知性解释，loacl interpretable model-agnostic explanations）和 SHAP 法（图 9）等[116]。SHAP 法在滑坡易发性预测的可解释性建模方面的应用相对更广泛，其通过将合作博弈论中的 SHAPLEY 值引入机器学习模型解释，计算并可视化每个致灾环境因子对模型预测结果的平均贡献，具有计算速度快和解释效果显著的优点[8]。

鉴于滑坡灾害的频发和复杂性，确保滑坡易发性预测模型不仅准确而且易于理解，已经成为研究者和工程实践者十分关注的问题[117-118]。比如，孙德亮等[119] 基于随机森林–特征递归消除模型预测合川区滑坡易发性，通过 SHAP 方法和部分依赖图，成功揭示了影响滑坡易发性的关键致灾环境因子及其作用机制；YOUSSEF 等[120] 提出了一种用于预测滑坡易发性的可解释性神经网络模型，在东部喜马拉雅地区的实际应用中，该模型展示了优秀的性能，不仅能够精准识别关键影响因素，还能对背后的物理机制给出合理的诠释；SUN 等[121] 使用地理探测器筛选关键致灾环境因子输入随机森林模型，并运用部分依赖图和 LIME 方法，增强了山区高速公路滑坡易发性预测模型的可解释性，揭示了影响滑坡预测的关键致灾环境因子及其作用机制。不过这种滑坡易发性建模解释工作的深度和广泛性还不够，还有待进一步将“黑色”或“灰色”建模转为“白色”建模。比如，通过分析人类工程活动造成的植被覆盖的减少对滑坡风险的影响，并采用可解释性方法，可以制定更为合理的土地利用规划和生态保护政策[71]。

综上所述，可解释性方法已逐渐成为滑坡易发性预测过程中非常重要的一个步骤。通过可解释性方法的应用，不仅能提高模型的预测准确性，还能在一定程度上增强对模型预测行为的理解，即揭示致灾环境因子之间的内在联系以及致灾环境因子与滑坡之间的交互作用规律。可解释性方法使研究人员和决策者更好地理解模型的预测结果，从而为科学

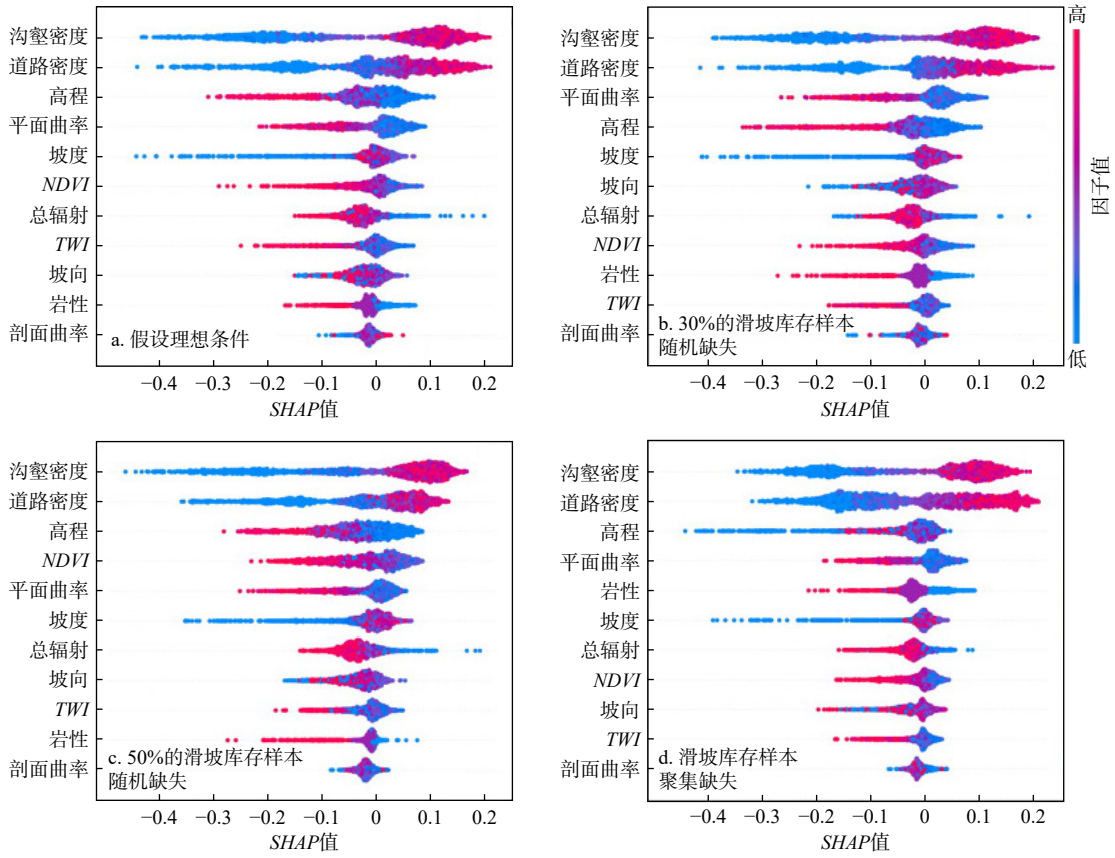


图 9　基于 SHAP 法解释不同滑坡样本缺失条件下的滑坡易发性预测结果[115]

Fig. 9　Interpretation of landslide susceptibility prediction results under different landslide sample missing conditions based on the SHAP method

决策和政策制定提供了坚实的依据[73]。因此，未来的研究应进一步深化对可解释性方法的开发和应用，以提升滑坡易发性预测的可靠性和实用性。

4 结论

（1）本研究共统计出被使用过的致灾环境因子高达 82 种，其中坡度、坡向、高程、岩性是使用频率最高的 4 种环境因子；通过重要性标准化统计发现，坡度、高程、公路密度、岩性、降雨量等因子在滑坡易发性预测时重要性依次增高。建议着重挖掘区域特异性和新兴机制因子，并对因子重要性的分析进行规范化。

（2）对某些致灾环境因子的适宜性问题进行了讨论，结果表明研究中需要采用物理意义更明确的环境因子作为模型输入变量。环境因子筛选对传统模型预测滑坡易发性具有一定的作用，但对近年发展起来的更先进的机器学习模型则作用不大，可依据“数据准确、类型齐全、意义明确、操作可行和避免重复”原则构建出完善的致灾环境因子组合体系。

（3）通过对致灾环境因子联接分析法讨论，发现将原始环境因子数据直接用作输入变量具有较高的滑坡易发性建模效率，但是经过因子联接方法处理后的易发性预测精度普遍高于未经处理时的精度。建议进一步研究该方法在大数据量情况下的精度变化，以全面评估其适用性和可靠性。

（4）可以采用蒙特卡罗、低通滤波、小波分析和卡尔曼滤波等方法来消除连续型环境因子中的随机误差以减少建模中的不确定性；建议通过长期监测和数据分析，构建时空连续的致灾环境因子集，以深化滑坡易发性研究；此外，建议加强机器学习可解释性的研究，以便更深入全面地揭示致灾环境因子之间的内在联系以及滑坡与环境因子之间的交互作用规律。

所有作者声明不存在利益冲突。

The authors declare that no competing interests exist.

参考文献：

[1] 石菊松. 基于遥感和地理信息系统的滑坡风险评估关键技术研究 [D]. 北京：中国地质科学院，2008.
SHI J S. Key techniques study of remote sensing and geographic information system based landslide risk assessment[D]. Beijing: Chinese Academy of Geological Sciences, 2008.（in Chinese with English abstract）

[2] 窦杰，向子林，许强，等. 机器学习在滑坡智能防灾减灾中的应用与发展趋势 [J]. 地球科学，2023，48(5)：1657-1674.
DOU J, XIANG Z L, XU Q, et al. Application and development trend of machine learning in landslide intelligent disaster prevention and mitigation[J]. Earth Science, 2023, 48(5): 1657-1674.（in Chinese with English abstract）

[3] CHENG L B, LI J, DUAN P, et al. A small attentional YOLO model for landslide detection from satellite remote sensing images[J]. Landslides, 2021, 18(8): 2751-2765.

[4] 黄发明，胡松雁，闫学涯，等. 基于机器学习的滑坡易发性预测建模及其主控因子识别 [J]. 地质科技通报，2022，41(2)：79-90.
HUANG F M, HU S Y, YAN X Y, et al. Landslide susceptibility prediction and identification of its main environmental factors based on machine learning models[J]. Bulletin of Geological Science and Technology, 2022, 41(2): 79-90.（in Chinese with English abstract）

[5] LOMBARDO L, MAI P M. Presenting logistic regression-based landslide susceptibility results[J]. Engineering Geology, 2018, 244: 14-24.

[6] 郭衍昊，窦杰，向子林，等. 基于优化负样本采样策略的梯度提升决策树与随机森林的汶川同震滑坡易发性评价 [J]. 地质科技通报，2024，43(3)：251-265.
GUO Y H, DOU J, XIANG Z L, et al. Susceptibility evaluation of Wenchuan coseismic landslides by gradient boosting decision tree and random forest based on optimal negative sample sampling strategies[J]. Bulletin of Geological Science and Technology, 2024, 43(3): 251-265.（in Chinese with English abstract）

[7] EKMEKCIOĞLU Ö, KOC K. Explainable step-wise binary classification for the susceptibility assessment of geo-hydrological hazards[J]. Catena, 2022, 216: 106379.

[8] ZHANG J Y, MA X L, ZHANG J L, et al. Insights into geospatial heterogeneity of landslide susceptibility based on the SHAP-XGBoost model[J]. Journal of Environmental Management, 2023, 332: 117357.

[9] 黄发明，曹昱，范宣梅，等. 不同滑坡边界及其空间形状对滑坡易发性预测不确定性的影响规律 [J]. 岩石力学与工程学报，2021，40(增刊 2)：3227-3240.
HUANG F M, CAO Y, FAN X M, et al. Effects of different landslide boundaries and their spatial shapes on the uncertainty of landslide susceptibility prediction[J]. Chinese Journal of Rock Mechanics and Engineering, 2021, 40(S2): 3227-3240.（in Chinese with English abstract）

[10] 黄发明，刘科技，曾子强，等. 环境因子筛选及组合方法对滑坡易发性预测的影响规律 [J]. 应用基础与工程科学学报，2024，32(1)：49-71.
HUANG F M, LIU K J, ZENG Z Q, et al. Influence of environmental factor selection and combination on landslide susceptibility prediction modeling[J]. Journal of Basic Science and Engineering, 2024, 32(1): 49-71.（in Chinese with English abstract）

[11] CHANG Z L, CATANI F, HUANG F M, et al. Landslide susceptibility prediction using slope unit-based machine learning models considering the heterogeneity of conditioning factors[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2023, 15(5): 1127-1143.

[12] HUANG F M, TENG Z K, YAO C, et al. Uncertainties of landslide susceptibility prediction: Influences of random errors in landslide conditioning factors and errors reduction by low pass filter method[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2024, 16(1): 213-230.

[13] YANG Z L, LU H, ZHANG Z J, et al. Visualization analysis of rainfall-induced landslides hazards based on remote sensing and geographic information system: An overview[J]. International Journal of Digital Earth, 2023, 16(1): 2374-2402.

[14] RAHMATI O, TAHMASEBIPOUR N, HAGHIZADEH A, et al. Evaluating the influence of geo-environmental factors on gully erosion in a semi-arid region of Iran: An integrated framework[J]. Science of the Total Environment, 2017, 579: 913-927.

[15] HUANG F M, CAO Z S, GUO J F, et al. Comparisons of heuristic, general statistical and machine learning models for landslide susceptibility prediction and mapping[J]. Catena, 2020, 191: 104580.

[16] WANG H, YANG T H, ZHANG P H, et al. Landslide susceptibility prediction considering rock integrity and stress state: A case study[J]. Bulletin of Engineering Geology and the Environment, 2023, 82(7): 259.

[17] BEHNIA P, BLAIS-STEVENS A. Landslide susceptibility modelling using the quantitative random forest method along the northern portion of the Yukon Alaska Highway Corridor, Canada[J]. Natural Hazards, 2018, 90(3): 1407-1426.

[18] LIU Q, TANG A P, HUANG Z Y, et al. Discussion on the tree-based machine learning model in the study of landslide susceptibility[J]. Natural Hazards, 2022, 113(2): 887-911.

[19] REICHENBACH P, ROSSI M, MALAMUD B D, et al. A review of statistically-based landslide susceptibility models[J]. Earth-Science Reviews, 2018, 180: 60-91.

[20] ZHANG Y G, MIGLIAVACCA M, PENUELAS J, et al. Advances in hyperspectral remote sensing of vegetation traits and functions[J]. Remote Sensing of Environment, 2021, 252: 112121.

[21] ZHOU C, GAN L L, CAO Y, et al. Landslide susceptibility assessment of the Wanzhou district: Merging landslide susceptibility modelling (LSM) with InSAR-derived ground deformation map[J]. International Journal of Applied Earth Observation and Geoinformation, 2025, 136: 104365.

[22] 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 F, LAI P, HUANG F M, et al. Literature review and research progress of landslide susceptibility mapping based on knowledge graph[J]. Earth Science, 2024, 49(5): 1584-1606. (in Chinese with English abstract)

[23] 罗路广, 裴向军, 黄润秋, 等. GIS 支持下 CF 与 Logistic 回归模型耦合的九寨沟景区滑坡易发性评价 [J]. 工程地质学报, 2021, 29(2): 526-535.
LUO L G, PEI X J, HUANG R Q, et al. Landslide susceptibility assessment in Jiuzhaigou Scenic Area with GIS based on certainty factor and logistic regression model[J]. Journal of Engineering Geology, 2021, 29(2): 526-535. (in Chinese with English abstract)

[24] 常志璐, 黄发明, 蒋水华, 等. 基于多尺度分割方法的斜坡单元划分及滑坡易发性预测 [J]. 工程科学与技术, 2023, 55(1): 184-195.
CHANG Z L, HUANG F M, JIANG S H, et al. Slope unit extraction and landslide susceptibility prediction using multi-scale segmentation method[J]. Advanced Engineering Sciences, 2023, 55(1): 184-195. (in Chinese with English abstract)

[25] SCHLÖGEL R, MARCHESINI I, ALVIOLI M, et al. Optimizing landslide susceptibility zonation: Effects of DEM spatial resolution and slope unit delineation on logistic regression models[J]. Geomorphology, 2018, 301: 10-20.

[26] 黄发明, 李金凤, 王俊宇, 等. 考虑线状环境因子适宜性和不同机器学习模型的滑坡易发性预测建模规律 [J]. 地质科技通报, 2022, 41(2): 44-59.
HUANG F M, LI J F, WANG J Y, et al. Modelling rules of landslide susceptibility prediction considering the suitability of linear environmental factors and different machine learning models[J]. Bulletin of Geological Science and Technology, 2022, 41(2): 44-59. (in Chinese with English abstract)

[27] HUANG F M, YAO C, LIU W P, et al. Landslide susceptibility assessment in the Nantian area of China: A comparison of frequency ratio model and support vector machine[J]. Geomatics, Natural Hazards and Risk, 2018, 9(1): 919-938.

[28] YOUSSEF A M, POURGHASEMI H R. Landslide susceptibility mapping using machine learning algorithms and comparison of their performance at Abha Basin, Asir region, Saudi Arabia[J]. Geoscience Frontiers, 2021, 12(2): 639-655.

[29] LIU L L, ZHANG Y L, XIAO T, et al. A frequency ratio-based sampling strategy for landslide susceptibility assessment[J]. Bulletin of Engineering Geology and the Environment, 2022, 81(9): 360.

[30] HUANG F M, TAO S Y, LI D Y, et al. Landslide susceptibility prediction considering neighborhood characteristics of landslide spatial datasets and hydrological slope units using remote sensing and GIS technologies[J]. Remote Sensing, 2022, 14(18): 4436.

[31] YANG Y, YANG J T, XU C D, et al. Local-scale landslide susceptibility mapping using the B-GeoSVC model[J]. Landslides, 2019, 16(7): 1301-1312.

[32] LIAO M Y, WEN H J, YANG L. Identifying the essential conditioning factors of landslide susceptibility models under different grid resolutions using hybrid machine learning: A case of Wushan and Wuxi Counties, China[J]. Catena, 2022, 217: 106428.

[33] MEINHARDT M, FINK M, TüNSCHEL H. Landslide susceptibility analysis in central Vietnam based on an incomplete landslide inventory: Comparison of a new method to calculate weighting factors by means of bivariate statistics[J]. Geomorphology, 2015, 234: 80-97.

[34] GRABOWSKI D, LASKOWICZ I, MAŁKA A, et al. Geoenvironmental conditioning of landsliding in river valleys of lowland regions and its significance in landslide susceptibility assessment: A case study in the Lower Vistula Valley, Northern Poland[J]. Geomorphology, 2022, 419: 108490.

[35] NICU I C, LOMBARDO L, RUBENSDOTTER L. Preliminary

assessment of thaw slump hazard to Arctic cultural heritage in Nordenskiöld Land, Svalbard[J]. Landslides, 2021, 18(8): 2935-2947.

[36] OH H J, KADAVI P R, LEE C W, et al. Evaluation of landslide susceptibility mapping by evidential belief function, logistic regression and support vector machine models[J]. Geomatics, Natural Hazards and Risk, 2018, 9(1): 1053-1070.

[37] SENA N C, VELOSO G V, FERNANDES-FILHO E I, et al. Analysis of terrain attributes in different spatial resolutions for digital soil mapping application in southeastern Brazil[J]. Geoderma Regional, 2020, 21: e00268.

[38] POURGHASEMI H R, PRADHAN B, GOKCEOGLU C. Application of fuzzy logic and analytical hierarchy process (AHP) to landslide susceptibility mapping at Haraz watershed, Iran[J]. Natural Hazards, 2012, 63(2): 965-996.

[39] CHEN W, YANG Z F. Landslide susceptibility modeling using bivariate statistical-based logistic regression, naïve Bayes, and alternating decision tree models[J]. Bulletin of Engineering Geology and the Environment, 2023, 82(5): 190.

[40] PARDO-IGúZQUIZA E, DOWD P A. The mapping of closed depressions and its contribution to the geodiversity inventory[J]. International Journal of Geoheritage and Parks, 2021, 9(4): 480-495.

[41] HUANG F M, CHEN J W, LIU W P, et al. Regional rainfall-induced landslide hazard warning based on landslide susceptibility mapping and a critical rainfall threshold[J]. Geomorphology, 2022, 408: 108236.

[42] CHEN Z, YE F, FU W X, et al. The influence of DEM spatial resolution on landslide susceptibility mapping in the Baxie River Basin, NW China[J]. Natural Hazards, 2020, 101(3): 853-877.

[43] CHEN W, LI Y. GIS-based evaluation of landslide susceptibility using hybrid computational intelligence models[J]. Catena, 2020, 195: 104777.

[44] HUANG F M, XIONG H W, YAO C, et al. Uncertainties of landslide susceptibility prediction considering different landslide types[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2023, 15(11): 2954-2972.

[45] LEE D H, KIM Y T, LEE S R. Shallow landslide susceptibility models based on artificial neural networks considering the factor selection method and various non-linear activation functions[J]. Remote Sensing, 2020, 12(7): 1194.

[46] RENARD K G. Predicting soil erosion by water: A guide to conservation planning with the revised universal soil loss equation (RUSLE)[M]. Washington, D. C: U. S. Dept. of Agriculture, Agricultural Research Service, 1997.

[47] DU J, GLADE T, WOLDAI T, et al. Landslide susceptibility assessment based on an incomplete landslide inventory in the Jilong Valley, Tibet, Chinese Himalayas[J]. Engineering Geology, 2020, 270: 105572.

[48] CHEN W, PANAHI M, TSANGARATOS P, et al. Applying population-based evolutionary algorithms and a neuro-fuzzy system for modeling landslide susceptibility[J]. Catena, 2019, 172: 212-231.

[49] BORRELLI L, CIURLEO M, GULLÀ G. Shallow landslide susceptibility assessment in granitic rocks using GIS-based statistical methods: The contribution of the weathering grade map[J]. Landslides, 2018, 15(6): 1127-1142.

[50] DORIGO W, WAGNER W, ALBERGEL C, et al. ESA CCI soil Moisture for improved Earth system understanding: State-of-the art and future directions[J]. Remote Sensing of Environment, 2017, 203: 185-215.

[51] HAKIM W L, REZAIE F, NUR A S, et al. Convolutional neural network (CNN) with metaheuristic optimization algorithms for landslide susceptibility mapping in Icheon, South Korea[J]. Journal of Environmental Management, 2022, 305: 114367.

[52] PANAHI M, RAHMATI O, REZAIE F, et al. Application of the group method of data handling (GMDH) approach for landslide susceptibility zonation using readily available spatial covariates[J]. Catena, 2022, 208: 105779.

[53] 黄发明, 吴敦筱, 常志璐, 等. 滑坡样本缺失下易发性规律和潜在滑坡识别的易发性–InSAR 多源信息法 [J]. 岩石力学与工程学报, 2025, 44(3): 584-601.
HUANG F M, WU D X, CHANG Z L, et al. Landslide susceptibility law under the absence of landslide sample and the susceptibility-InSAR multi-source information method considering the potential landslide identification[J]. Chinese Journal of Rock Mechanics and Engineering, 2025, 44(3): 584-601. (in Chinese with English abstract)

[54] POURGHASEMI H R, RAHMATI O. Prediction of the landslide susceptibility: Which algorithm, which precision?[J]. Catena, 2018, 162: 177-192.

[55] ALI S A, PARVIN F, VOJTEKOVÁ J, et al. GIS-based landslide susceptibility modeling: A comparison between fuzzy multi-criteria and machine learning algorithms[J]. Geoscience Frontiers, 2021, 12(2): 857-876.

[56] PACHECO QUEVEDO R, VELASTEGUI-MONTOYA A, MONTALVáN-BURBANO N, et al. Land use and land cover as a conditioning factor in landslide susceptibility: A literature review[J]. Landslides, 2023, 20(5): 967-982.

[57] BALOGUN A L, YEKEEN S T, PRADHAN B, et al. Spatio-temporal analysis of oil spill impact and recovery pattern of coastal vegetation and wetland using multispectral satellite landsat 8-OLI imagery and machine learning models[J]. Remote Sensing, 2020, 12(7): 1225.

[58] WANG J N, WANG Y Q, LI C, et al. Landslide susceptibility evaluation based on landslide classification and ANN-NFR modelling in the Three Gorges Reservoir area, China[J]. Ecological Indicators, 2024, 160: 111920.

[59] BAG R, MONDAL I, DEHBOZORGI M, et al. Modelling and mapping of soil erosion susceptibility using machine learning in a tropical hot sub-humid environment[J]. Journal of Cleaner Production, 2022, 364: 132428.

[60] CHEN T K, PRISHCHEPOV A V, FENSHOLT R, et al. Detecting and monitoring long-term landslides in urbanized areas with nighttime light data and multi-seasonal landsat imagery across Taiwan from 1998 to 2017[J]. Remote Sensing of Environment,

2019, 225: 317-327.

[61] SEGONI S, PAPPAFICO G, LUTI T, et al. Landslide susceptibility assessment in complex geological settings: Sensitivity to geological information and insights on its parameterization[J]. Landslides, 2020, 17(10): 2443-2453.

[62] THI NGO P T, PANAHI M, KHOSRAVI K, et al. Evaluation of deep learning algorithms for national scale landslide susceptibility mapping of Iran[J]. Geoscience Frontiers, 2021, 12(2): 505-519.

[63] PHAM B T, PRAKASH I, SINGH S K, et al. Landslide susceptibility modeling using Reduced Error Pruning Trees and different ensemble techniques: Hybrid machine learning approaches[J]. Catena, 2019, 175: 203-218.

[64] SHRESTHA S, KANG T S. Assessment of seismically-induced landslide susceptibility after the 2015 Gorkha earthquake, Nepal[J]. Bulletin of Engineering Geology and the Environment, 2019, 78(3): 1829-1842.

[65] DAI L X, FAN X M, WANG X, et al. Coseismic landslides triggered by the 2022 Luding Ms6.8 earthquake, China[J]. Landslides, 2023, 20(6): 1277-1292.

[66] 罗路广, 裴向军, 崔圣华, 等. 九寨沟地震滑坡易发性评价因子组合选取研究 [J]. 岩石力学与工程学报, 2021, 40(11): 2306-2319.
LUO L G, PEI X J, CUI S H, et al. Combined selection of susceptibility assessment factors for Jiuzhaigou earthquake-induced landslides[J]. Chinese Journal of Rock Mechanics and Engineering, 2021, 40(11): 2306-2319. (in Chinese with English abstract)

[67] CARPENTIER S, KONZ M, FISCHER R, et al. Geophysical imaging of shallow subsurface topography and its implication for shallow landslide susceptibility in the Urseren Valley, Switzerland[J]. Journal of Applied Geophysics, 2012, 83: 46-56.

[68] ZOU Q, JIANG H, CUI P, et al. A new approach to assess landslide susceptibility based on slope failure mechanisms[J]. Catena, 2021, 204: 105388.

[69] YANG Z H, LAN H X, GAO X, et al. Urgent landslide susceptibility assessment in the 2013 Lushan earthquake-impacted area, Sichuan Province, China[J]. Natural Hazards, 2015, 75(3): 2467-2487.

[70] MIAO F S, WU Y P, LI L W, et al. Triggering factors and threshold analysis of Baishuihe landslide based on the data mining methods[J]. Natural Hazards, 2021, 105(3): 2677-2696.

[71] ZHAO F C, MIAO F S, WU Y P, et al. Landslide dynamic susceptibility mapping in urban expansion area considering spatiotemporal land use and land cover change[J]. Science of the Total Environment, 2024, 949: 175059.

[72] AL-NAJJAR H A H, PRADHAN B, BEYDOUN G, et al. A novel method using explainable artificial intelligence (XAI)-based Shapley Additive Explanations for spatial landslide prediction using Time-Series SAR dataset[J]. Gondwana Research, 2023, 123: 107-124.

[73] WANG N, ZHANG H Y, DAHAL A, et al. On the use of explainable AI for susceptibility modeling: Examining the spatial pattern of SHAP values[J]. Geoscience Frontiers, 2024, 15(4): 101800.

[74] 田乃满, 兰恒星, 伍宇明, 等. 人工神经网络和决策树模型在滑坡易发性分析中的性能对比 [J]. 地球信息科学学报, 2020, 22(12): 2304-2316.
TIAN N M, LAN H X, WU Y M, et al. Performance comparison of BP artificial neural network and CART decision tree model in landslide susceptibility prediction[J]. Journal of Geo-Information Science, 2020, 22(12): 2304-2316. (in Chinese with English abstract)

[75] DOU J, YUNUS A P, TIEN B D, et al. Assessment of advanced random forest and decision tree algorithms for modeling rainfall-induced landslide susceptibility in the Izu-Oshima Volcanic Island, Japan[J]. Science of the Total Environment, 2019, 662: 332-346.

[76] 白剑锋, 唐融, 王正宇, 等. 基于关联规则和熵权理论的架空输电线路滑坡孕灾环境敏感性评估 [J/OL]. 内蒙古电力技术, 2025: 1-8. (2025-03-28). https://kns.cnki.net/kcms/detail/15.1200.TM.20250328.1131.002.html.
BAI J F, TANG R, WANG Z Y, et al. Environmental sensitivity assessment of landslides on overhead transmission lines based on association rules and entropy weight theory[J/OL]. Inner Mongolia Electric Power, 2025: 1-8. (2025-03-28). https://kns.cnki.net/kcms/detail/15.1200.TM.20250328.1131.002.html.(in Chinese with English abstract)

[77] 崔鸿雁, 徐帅, 张利锋, 等. 机器学习中的特征选择方法研究及展望 [J]. 北京邮电大学学报, 2018, 41(1): 1-12.
CUI H Y, XU S, ZHANG L F, et al. The key techniques and future vision of feature selection in machine learning[J]. Journal of Beijing University of Posts and Telecommunications, 2018, 41(1): 1-12. (in Chinese with English abstract)

[78] CHEN W, CHEN X, PENG J B, et al. Landslide susceptibility modeling based on ANFIS with teaching-learning-based optimization and Satin bowerbird optimizer[J]. Geoscience Frontiers, 2021, 12(1): 93-107.

[79] PHAM B T, TIEN BUI D, PRAKASH I, et al. Hybrid integration of multilayer perceptron neural networks and machine learning ensembles for landslide susceptibility assessment at Himalayan area (India) using GIS[J]. Catena, 2017, 149: 52-63.

[80] YANG J T, SONG C, YANG Y, et al. New method for landslide susceptibility mapping supported by spatial logistic regression and GeoDetector: A case study of Duwen Highway Basin, Sichuan Province, China[J]. Geomorphology, 2019, 324: 62-71.

[81] TANYU B F, ABBASPOUR A, ALIMOHAMMADLOU Y, et al. Landslide susceptibility analyses using Random Forest, C4.5, and C5.0 with balanced and unbalanced datasets[J]. Catena, 2021, 203: 105355.

[82] 曹文庚, 潘登, 徐郅杰, 等. 河南省滑坡灾害易发性制图研究: 多种机器学习模型的对比 [J]. 地质科技通报, 2025, 44(1): 101-111.
CAO W G, PAN D, XU Z J, et al. Landslide disaster vulnerability mapping study in Henan Province: Comparison of different machine learning models[J]. Bulletin of Geological Science and Technology, 2025, 44(1): 101-111. (in Chinese with English abstract)

[83] YANG C, LIU L L, HUANG F M, et al. Machine learning-based

landslide susceptibility assessment with optimized ratio of landslide to non-landslide samples[J]. Gondwana Research, 2023, 123: 198-216.

[84] GOYES-PEÑAFIEL P, HERNANDEZ-ROJAS A. Landslide susceptibility index based on the integration of logistic regression and weights of evidence: A case study in Popayan, Colombia[J]. Engineering Geology, 2021, 280: 105958.

[85] 吴雨辰, 周晗旭, 车爱兰. 基于粗糙集–神经网络的 IBURI 地震滑坡易发性研究 [J]. 岩石力学与工程学报, 2021, 40(6): 1226-1235.
WU Y C, ZHOU H X, CHE A L. Susceptibility of landslides caused by IBURI earthquake based on rough set-neural network[J]. Chinese Journal of Rock Mechanics and Engineering, 2021, 40(6): 1226-1235. (in Chinese with English abstract)

[86] KAVZOGLU T, KUTLUG SAHIN E, COLKESEN I. Selecting optimal conditioning factors in shallow translational landslide susceptibility mapping using genetic algorithm[J]. Engineering Geology, 2015, 192: 101-112.

[87] ZHOU X Z, WEN H J, ZHANG Y L, et al. Landslide susceptibility mapping using hybrid random forest with GeoDetector and RFE for factor optimization[J]. Geoscience Frontiers, 2021, 12(5): 101211.

[88] HONG H Y, LIU J Z, ZHU A X. Modeling landslide susceptibility using LogitBoost alternating decision trees and forest by penalizing attributes with the bagging ensemble[J]. Science of the Total Environment, 2020, 718: 137231.

[89] ARABAMERI A, PRADHAN B, REZAEI K, et al. GIS-based landslide susceptibility mapping using numerical risk factor bivariate model and its ensemble with linear multivariate regression and boosted regression tree algorithms[J]. Journal of Mountain Science, 2019, 16(3): 595-618.

[90] CHEN W, CHEN Y Z, TSANGARATOS P, et al. Combining evolutionary algorithms and machine learning models in landslide susceptibility assessments[J]. Remote Sensing, 2020, 12(23): 3854.

[91] HUANG F M, ZHANG J, ZHOU C B, et al. A deep learning algorithm using a fully connected sparse autoencoder neural network for landslide susceptibility prediction[J]. Landslides, 2020, 17(1): 217-229.

[92] TANG Y M, FENG F, GUO Z Z, et al. Integrating principal component analysis with statistically-based models for analysis of causal factors and landslide susceptibility mapping: A comparative study from the Loess Plateau area in Shanxi (China)[J]. Journal of Cleaner Production, 2020, 277: 124159.

[93] SUN D L, SHI S X, WEN H J, et al. A hybrid optimization method of factor screening predicated on GeoDetector and random forest for landslide susceptibility mapping[J]. Geomorphology, 2021, 379: 107623.

[94] PHAM B T, VAN DAO D, ACHARYA T D, et al. Performance assessment of artificial neural network using Chi-square and backward elimination feature selection methods for landslide susceptibility analysis[J]. Environmental Earth Sciences, 2021, 80(20): 686.

[95] LUCCHESE L V, DE OLIVEIRA G G, PEDROLLO O C. Attribute selection using correlations and principal components for artificial neural networks employment for landslide susceptibility assessment[J]. Environmental Monitoring and Assessment, 2020, 192(2): 129.

[96] ZHU L, WANG G J, HUANG F M, et al. Landslide susceptibility prediction using sparse feature extraction and machine learning models based on GIS and remote sensing[J]. IEEE Geoscience and Remote Sensing Letters, 2021, 19: 3001505.

[97] 刘瑞, 李露瑶, 杨鑫, 等. 基于因子强关联分析方法的滑坡易发性评价 [J]. 地球与环境, 2021, 49(2): 198-206.
LIU R, LI L Y, YANG X, et al. Landslide susceptibility mappping based on factor strong correlation analysis method[J]. Earth and Environment, 2021, 49(2): 198-206. (in Chinese with English abstract)

[98] HUANG F M, XIONG H W, JIANG S H, et al. Modelling landslide susceptibility prediction: A review and construction of semi-supervised imbalanced theory[J]. Earth-Science Reviews, 2024, 250: 104700.

[99] 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 A X, LÜ G N , ZHOU C H, et al. Geographic similarity: Third law of geography?[J]. Journal of Geo-Information Science, 2020, 22(4): 673-679. (in Chinese with English abstract)

[100] 王启盛, 熊俊楠, 程维明, 等. 耦合统计方法、机器学习模型和聚类算法的滑坡易发性评价方法 [J]. 地球信息科学学报, 2024, 26(3): 620-637.
WANG Q S, XIONG J N, CHENG W M, et al. Landslide susceptibility mapping methods coupling with statistical methods, machine learning models and clustering algorithms[J]. Journal of Geo-Information Science, 2024, 26(3): 620-637. (in Chinese with English abstract)

[101] 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 J X, ZHUANG J Q, PENG J B, 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. (in Chinese with English abstract)

[102] HUANG F M, YE Z, JIANG S H, et al. Uncertainty study of landslide susceptibility prediction considering the different attribute interval numbers of environmental factors and different data-based models[J]. Catena, 2021, 202: 105250.

[103] 李文彬, 范宣梅, 黄发明, 等. 不同环境因子联接和预测模型的滑坡易发性建模不确定性 [J]. 地球科学, 2021, 46(10): 3777-3795.
LI W B, FAN X M, HUANG F M, et al. Uncertainties of landslide susceptibility modeling under different environmental factor connections and prediction models[J]. Earth Science, 2021, 46(10): 3777-3795. (in Chinese with English abstract)

[104] JIANG C C, FAN W, YU N Y, et al. Spatial modeling of gully head erosion on the Loess Plateau using a certainty factor and random forest model[J]. Science of the Total Environment, 2021, 783: 147040.

[105] 黄发明, 欧阳慰平, 蒋水华, 等. 考虑机器学习建模中训练/测试集时空划分原则的滑坡易发性预测建模 [J]. 地球科学, 2024, 49(5): 1607-1618.
HUANG F M, OUYANG W P, JIANG S H, et al. Landslide susceptibility prediction considering spatio-temporal division principle of training/testing datasets in machine learning models[J]. Earth Science, 2024, 49(5): 1607-1618. (in Chinese with English abstract)

[106] 徐胜华, 刘纪平, 王想红, 等. 熵指数融入支持向量机的滑坡灾害易发性评价方法: 以陕西省为例 [J]. 武汉大学学报(信息科学版), 2020, 45(8): 1214-1222.
XU S H, LIU J P, WANG X H, et al. Landslide susceptibility assessment method incorporating index of entropy based on support vector machine: A case study of Shaanxi Province[J]. Geomatics and Information Science of Wuhan University, 2020, 45(8): 1214-1222. (in Chinese with English abstract)

[107] 范强, 巨能攀, 向喜琼, 等. 证据权法在区域滑坡危险性评价中的应用: 以贵州省为例 [J]. 工程地质学报, 2014, 22(3): 474-481.
FAN Q, JU N P, XIANG X Q, et al. Landslides hazards assessment with weights of evidence: A case study in Guizhou, China[J]. Journal of Engineering Geology, 2014, 22(3): 474-481. (in Chinese with English abstract)

[108] 张玘恺, 凌斯祥, 李晓宁, 等. 九寨沟县滑坡灾害易发性快速评估模型对比研究 [J]. 岩石力学与工程学报, 2020, 39(8): 1595-1610.
ZHANG Q K, LING S X, LI X N, et al. Comparison of landslide susceptibility mapping rapid assessment models in Jiuzhaigou County, Sichuan Province, China[J]. Chinese Journal of Rock Mechanics and Engineering, 2020, 39(8): 1595-1610. (in Chinese with English abstract)

[109] 黄发明, 石雨, 欧阳慰平, 等. 基于证据权和卡方自动交互检测决策树的滑坡易发性预测 [J]. 土木与环境工程学报(中英文), 2022, 44(5): 16-28.
HUANG F M, SHI Y, OUYANG W P, et al. Landslide susceptibility prediction modeling based on weight of evidence and Chi-square automatic interactive detection decision tree[J]. Journal of Civil and Environmental Engineering, 2022, 44(5): 16-28. (in Chinese with English abstract)

[110] LIMA P, STEGER S, GLADE T. Counteracting flawed landslide data in statistically based landslide susceptibility modelling for very large areas: A national-scale assessment for Austria[J]. Landslides, 2021, 18(11): 3531-3546.

[111] PANAHI M, GAYEN A, POURGHASEMI H R, et al. Spatial prediction of landslide susceptibility using hybrid support vector regression (SVR) and the adaptive neuro-fuzzy inference system (ANFIS) with various metaheuristic algorithms[J]. Science of the Total Environment, 2020, 741: 139937.

[112] QIN C Z, BAO L L, ZHU A X, et al. Uncertainty due to DEM error in landslide susceptibility mapping[J]. International Journal of Geographical Information Science, 2013, 27(7): 1364-1380.

[113] CASAGLI N, INTRIERI E, TOFANI V, et al. Landslide detection, monitoring and prediction with remote-sensing techniques[J]. Nature Reviews Earth & Environment, 2023, 4(1): 51-64.

[114] GOETZ J N, BRENNING A, PETSCHKO H, et al. Evaluating machine learning and statistical prediction techniques for landslide susceptibility modeling[J]. Computers & Geosciences, 2015, 81: 1-11.

[115] HUANG F M, MAO D X, JIANG S H, et al. Uncertainties in landslide susceptibility prediction modeling: A review on the incompleteness of landslide inventory and its influence rules[J]. Geoscience Frontiers, 2024, 15(6): 101886.

[116] MALONEY K O, BUCHANAN C, JEPSEN R D, et al. Explainable machine learning improves interpretability in the predictive modeling of biological stream conditions in the Chesapeake Bay Watershed, USA[J]. Journal of Environmental Management, 2022, 322: 116068.

[117] 张锦瑞, 汪洋, 冯霄, 等. 考虑地表形变和土地利用变更的滑坡时空易发性差异分析 [J]. 地质科技通报, 2024, 43(6): 184-195.
ZHANG J R, WANG Y, FENG X, et al. Analysis of spatial-temporal variations in landslide susceptibility assessment considering surface deformation and land use dynamics[J]. Bulletin of Geological Science and Technology, 2024, 43(6): 184-195. (in Chinese with English abstract)

[118] 崔玉龙, 朱路路, 徐敏, 等. 基于环境因子优化 TSES 法选择负样本及其在滑坡易发性评价中的应用 [J]. 地质科技通报, 2024, 43(3): 192-199.
CUI Y L, ZHU L L, XU M, et al. Optimizing TSES method based on the environmental factors to select negative samples and its application in landslide susceptibility evaluation[J]. Bulletin of Geological Science and Technology, 2024, 43(3): 192-199. (in Chinese with English abstract)

[119] 孙德亮, 陈丹璐, 密长林, 等. 基于随机森林–特征递归消除模型的可解释性缓丘岭谷地貌滑坡易发性评价 [J]. 地质力学学报, 2023, 29(2): 202-219.
SUN D L, CHEN D L, MI C L, et al. Evaluation of landslide susceptibility in the gentle hill-valley areas based on the interpretable random forest-recursive feature elimination model[J]. Journal of Geomechanics, 2023, 29(2): 202-219. (in Chinese with English abstract)

[120] YOUSSEF K, SHAO K, MOON S, et al. Landslide susceptibility modeling by interpretable neural network[J]. Communications Earth & Environment, 2023, 4: 162.

[121] SUN D L, GU Q Y, WEN H J, et al. Assessment of landslide susceptibility along mountain highways based on different machine learning algorithms and mapping units by hybrid factors screening and sample optimization[J]. Gondwana Research, 2023, 123: 89-106.

Summary for “滑坡易发性相关致灾环境因子研究的综述与展望”

A review and prospect of disaster-causing environmental factors related to landslide susceptibility prediction

HUANG Faming[1,2]，CHEN Jie[1]，YANG Yang[1]，CHEN Xi[1]，ZHOU Chuangbing[1]，JIANG Bingchen[1]，GUO Fei[2*]

1. School of Infrastructure Engineering, Nanchang University, Nanchang 330031, China；
2. Key Laboratory of Geological Hazards on Three Gorges Reservoir Area (China Three Gorges University), Ministry of Education, Yichang Hubei 443002, China

First author，E-mail：faminghuang@ncu.edu.cn

* Corresponding author， E-mail：ybbnui.2008@163.com

Abstract：[**Objective**] Disaster-causing environmental factors serve as input variables for landslide susceptibility prediction modeling，referring to various natural attribute factors influencing the occurrence，development，and distribution of landslides on slopes. A comprehensive and clearly-defined set of disaster-causing environmental factors is of vital importance for enhancing the accuracy and reliability of landslide susceptibility outcomes. [**Methods**] To further clarify the research status and future prospects of disaster-causing environmental factors，this paper conducted a literature search in the core collection database of Web of Science，with the titles containing "landslide susceptibility" and the publication date ranging from 01/01/2013 to 31/12/2023，collecting 767 English papers on landslide susceptibility to form a literature database. Firstly，information such as the quantity of disaster-causing environmental factors，acquisition methods，sources，importance，and acceptance in each paper was statistically analyzed. Then，the definitions and physical meanings of disaster-causing environmental factors were elaborated in detail. Subsequently，characteristics such as the optimization selection/combination methods of disaster-causing environmental factors，factor connection methods，factor errors，and suitability were discussed，providing a reference for the uncertainty research of selecting disaster-causing environmental factors when predicting landslide susceptibility. [**Results and Conclusion**] The review results indicate that: (1) A total of 82 types of disaster-causing environmental factors were statistically analyzed in the literature database，with over 40 frequently used ones. Among them，slope，aspect，elevation，and lithology are the four most frequently used factors. The importance of factors such as slope，elevation，road density，lithology，and rainfall in landslide susceptibility prediction is the highest in sequence. (2) It was discovered that research on using comprehensive and physically meaningful disaster-causing environmental factors，constructing model input variables based on environmental factor connection methods，eliminating random errors in environmental factors，enhancing the suitability of environmental factors，and employing various explainable methods can effectively improve the performance of machine learning in predicting landslide susceptibility. Therefore，in future research on the disaster-causing environmental factors of landslides，it is necessary to focus on these key issues.

Key words: landslide susceptibility；disaster-causing environmental factor；machine learning；uncertainty discussion；topographic and geomorphic factor；hydrological environmental factor；land cover factor；geological lithologic factor

Received：2024-12-16；Revised：2025-03-03；Accepted：2025-03-11

doi：10.19509/j.cnki.dzkq.tb20240766