

<https://doi.org/10.3799/dqkx.2025.186>



基于贝叶斯网络结构学习的短期 强震危险性概率预测

司 震¹, 袁 静^{1*}, 张 博², 陈 石^{3,4}

1. 应急管理大学计算机科学与工程学院, 河北三河 065201

2. 辽宁省地震局, 辽宁沈阳 110034

3. 北京白家疃地球科学国家野外科学观测研究站, 北京 100095

4. 中国地震局地球物理研究所, 北京 100081

摘 要: 为提升区域月尺度强震风险预测能力, 基于贝叶斯网络结构学习提出区域性月尺度地震危险性概率预测模型. 首先利用区域与全球地震目录数据构建预测指标, 作为网络节点变量; 其次采用群智能算法自动确定各节点阈值及节点间的有向连接; 最后通过参数估计, 目标节点输出目标区域未来一月内发生 $M_w 5.0$ 及以上强震的概率. 实验结果显示, 模型预报效能指标平均达 0.783, 经 Molchan 检验验证, 其有效性显著, 表明该模型能够充分挖掘地震预测指标与强震之间的潜在因果关系.

关键词: 贝叶斯网络结构学习; 地震危险性概率预测; 地震目录; 群智能算法; Molchan 检验; 地震学.

中图分类号: P315.08; P315.5

文章编号: 1000-2383(2026)01-043-13

收稿日期: 2025-06-09

Probabilistic Prediction of Short-Term Strong Earthquake Hazard Based on Bayesian Network Structure Learning

Si Zhen¹, Yuan Jing^{1*}, Zhang Bo², Chen Shi^{3,4}

1. School of Computer Science and Engineering, University of Emergency Management, Sanhe 065201, China

2. Liaoning Earthquake Agency, Shenyang 110034, China

3. Beijing Baijiatuan Earth Science National Observation and Research Station, Beijing 100095, China

4. Institute of Geophysics, China Earthquake Administration, Beijing 100081, China

Abstract: To enhance the capability for monthly-scale regional strong earthquake risk prediction, this paper introduces a probabilistic seismic hazard prediction model based on Bayesian network structure learning. Initially, a series of predictive indicators, serving as the nodes of the Bayesian network, are derived from the earthquake catalog. Subsequently, the thresholds for each node and the directed connections among nodes are determined using swarm intelligence algorithms. Ultimately, through parameter estimation, the target node outputs the probability of $M_w 5.0+$ strong earthquakes occurring in the target region within the next month. Experimental results indicate that the model achieves an average prediction efficiency metric of 0.783, and validation via the Molchan test confirms its significant effectiveness, demonstrating the model's capacity to comprehensively explore the latent causal relationships between seismic precursors and strong earthquakes.

基金项目: 民用航天技术预先研究项目(No.D040203); 2025 年度地震预测开放基金项目(No.XH25001D).

作者简介: 司震(2002—), 男, 硕士研究生, 主要从事地震危险性概率预测的研究. ORCID:0009-0001-8579-7041. E-mail:24661619@st.cidp.edu.cn

* **通讯作者:** 袁静, ORCID:0000-0002-1155-6093. E-mail: j-yuan11@tsinghua.org.cn

引用格式: 司震, 袁静, 张博, 陈石, 2026. 基于贝叶斯网络结构学习的短期强震危险性概率预测. 地球科学, 51(1):43–55.

Citation: Si Zhen, Yuan Jing, Zhang Bo, Chen Shi, 2026. Probabilistic Prediction of Short-Term Strong Earthquake Hazard Based on Bayesian Network Structure Learning. *Earth Science*, 51(1):43–55.

Key words: Bayesian network structure learning; probabilistic seismic hazard prediction; earthquake catalog; swarm intelligence algorithms; Molchan test; seismology.

0 引言

地震是最具破坏性且最难以预测的自然灾害之一(Andrić and Lu, 2017).地震预测作为推动现代地震学发展的重要动力,是防灾减灾工作中的核心环节,对预警策略的制定、资源分配以及基础设施抗震加固等实际决策具有关键意义(王芃等, 2019).然而,地震预测的复杂性和不确定性使其一直面临重大挑战.地震的孕育过程涉及的诸多变量难以准确测量和描述,且观测数据中存在大量干扰信号,这些信号的甄别与去除进一步增加了地震预测的难度.因此,尽管科学家长期尝试通过确定性预测技术准确预报地震的时间、地点和震级,但目前的技术和理论尚不足以克服这些困难.2009年意大利拉奎拉地震及其引发的社会事件促使学界重新审视地震预测中的不确定性表达.此后,地震概率预测作为新的研究方向迅速发展起来.概率预测不再试图精确确定地震的发生时间与地点,而是通过分析历史地震目录与当前观测数据,计算未来特定时间和区域内地震发生的概率(Aki, 1981).相比于传统确定性预测,地震风险概率预测结果更具科学性,能够更直观地展示各地区地震发生的危险性,有利于防震减灾工作决策部署(李冬梅等, 2025).近年来,随着统计方法、地震观测技术和计算能力的提升,地震概率预测逐渐成为地震科学的重要领域之一.

根据预测时间尺度的不同,地震概率预测方法可分为三类:长期概率预测、中期概率预测和短期概率预测.长期预测着眼于数十年甚至百年尺度,旨在评估特定区域未来发生强震的总体趋势和潜在危险性;中期预测则聚焦于数月至数年内的地震活动概率,适用于中期防震减灾规划;短期预测则尝试在数小时至数月的时间范围内评估地震发生的可能性,主要用于震前预警与应急响应部署.

(1)长期概率预测:主要基于地质构造活动、历史地震复发周期及断层滑动速率等数据,通过统计模型评估未来地震发生的累积概率.目前广泛应用的模型是应力释放模型(stress release model, SRM),该模型由 Vere-Jones(1978)提出,其理论基础是:假定某一地区的地震危险性概率与应力的积累释放密切相关,构造运动的持续积累使得给定区

域的应力水平随之增加进而发生地震使得应力得以释放.另一个经典的长周期预测模型是传染型余震序列模型(epidemic type aftershock sequence model, ETAS),由 Ogata(1988)首次提出.ETAS模型认为,在余震序列中,任何一次余震都可能触发更高阶的余震,而不仅仅是强震能够引发余震.SRM和ETAS被认为是长周期地震危险性概率中最有效的模型.为了克服SRM仅适合应用于单一断层地震危险性估计的局限性, Jiang *et al.* (2011)提出了多维应力释放模型(multidimensional stress release model, MSRM).MSRM被认为是一个较为优秀的长周期预测模型,能够在复杂地质条件下进行概率计算. Dieterich *et al.* (2000)将ETAS模型与状态-速率相依型摩擦律(rate- and state-dependent friction law)结合,用以解释微震过程中的相关现象.目前长期地震概率预测方法的探索已相对比较成熟.

(2)中期概率预测:中期预测研究则聚焦于地震活动性异常等多参数融合模型的分析.在国内地震工程领域,概率预测主要依据 Cornell(1968)提出的地震危险性概率预测方法(PSHA),并在此基础上发展了改进方法——中国地震危险性概率评估(Chinese possibility seismic hazard assessment, CP-SHA).CPSHA方法认为,同一区域内地震活动在长时间上符合稳态泊松分布模型,且空间上存在不均匀分布,然而区域内部的地震活动符合均匀分布且满足 $G-R$ 关系(徐伟进和高孟谭, 2012).该方法在强震预测中发挥了重要作用,但仍存在一些显著的不足之处:由于区域内强震的发生周期较长,给基于泊松模型的估算强震平均发生率 λ 带来了巨大困难.此外, $G-R$ 关系在大地震发生时出现的“摆尾”现象(Xu *et al.*, 2015; Zhang *et al.*, 2017)也会导致由微震推算强震的 λ 出现较大偏差,从而导致该模型的危险性计算出现较大的不确定性.对于中期的危险性概率预测,国内外也已有较多探索.刘欢等(2024)提出一种基于高阶磁异常导数与高阶统计量的地震短临预测方法,将预测尺度缩短至4个月. Ma *et al.* (2024)将中国大陆划分东北、华北、华南等6大构造单元,提出将相对强度(RI)、矩比(MR)及三重平滑(Tripe-S)3种模型整合为混合概率预测模型,利用地震目录数据采用滑动回溯方法证明了模

型在5年尺度中的有效性,并验证了区域地震活动特征的时空异质性。 b 值作为表征地壳应力状态的关键参数,在国内中期预测研究中展现出显著应用潜力.史海霞等(2018)对汶川 $M_s8.0$ 地震的研究表明,其前震源区 b 值呈现趋势性下降,且在主震前约6个月出现快速且显著的异常变化;Wang *et al.*(2021)基于云南地区 b 值空间分布特征,通过 Molchan 图检验了其中长期预测中良好的效能;且 Wang *et al.*(2023)后续进一步将 AIC 准则引入 b 值分析,构建了优化的交通灯系统,并对2021年漾濞 $M_w6.7$ 地震序列的前震-主震-余震特征成功进行了识别.

(3)短期概率预测:尝试在月尺度的时间范围内评估地震发生的可能性,主要用于震前预警与应急响应部署.目前国内外短临概率预测仍以适用于中长周期的模型为基础研究(邓世广等,2019),未见高可靠且有效的新型月尺度周期预测模型研究工作.

综上,对地震危险性概率预测主要集中在数年至数十年的中长周期,目前尚未出现高效鲁棒的月尺度短周期地震危险性概率预测方法.人工智能为分析多维数据和解决地球科学中的复杂及非线性问题提供了新的机会(Kuglitsch *et al.*, 2023),使得基于人工智能的月尺度地震危险性概率预测模型成为可能.然而,随着模型复杂度提升,参数量的剧增使得其可解释性及预测可信度逐渐下降(Fleming *et al.*, 2021),在应对如地震等突发灾害时,模型的“黑盒性”可能导致专业人员对模型内部运作缺乏全面了解,对其结果产生信任危机,从而可能成为后续制定预防策略的阻碍(Dramsch *et al.*, 2025).

贝叶斯网络(bayesian network)作为统计学中的重要模型,因其“白盒性”和卓越的可解释性,以及在多变量不确定性知识推理的优势,使得基于贝叶斯网络的地震概率预测成为可能,但仍依赖基于专家经验设置的网络结构.相较于专家依赖,贝叶斯网络结构学习因可以充分挖掘数据隐含的逻辑关联,为建立如地震预测等复杂问题的可解释模型提供了有效技术途径.目前,网络结构学习方法可分为三种类型:基于约束、基于评分搜索以及混合学习方法.随着计算能力提升和机器学习技术的发展,基于评分搜索方法中的启发式或群智能算法逐渐成为近年的研究热点.Liu *et al.*(2023)提出了基于改进哈里斯鹰优化算法的贝叶斯网络结构学习方法,通过遗传算子增强了算法的全局搜索能力;Yang *et al.*(2024)则将散射搜索这一元启发式方

法应用于贝叶斯网络结构学习问题并表现出良好的性能;He *et al.*(2024)开发的基于邻接完整节点序的结构学习方法,通过寻找贝叶斯网络的节点序,再使用爬山(hill-climbing, HC)算法从而确定最佳网络结构.针对贝叶斯网络结构学习N-P难问题,研究者们正在探索更加高效和精确的启发式群智能策略.然而,选择何种算法仍需紧密结合具体应用场景的数据特性和模型需求.

为了从历史地震数据中自动提取变量之间的因果关系并挖掘地震数据中错综复杂的隐性逻辑关联,本文提出了基于贝叶斯网络结构学习的地震危险性评估模型:首先根据地震目录设计贝叶斯网络节点;然后采用群智能算法中秃鹰搜索(bald eagle search, BES)算法(Alsattar *et al.*, 2020),并结合爬山算法(Al-Betar, 2017)构建了秃鹰搜索贝叶斯网络(bald eagle search bayesian network, BESBN),接着利用秃鹰搜索算法进行了自动的阈值处理,这种组合有效利用了BES的优秀全局探索能力和HC的局部精细调优能力,更契合地震数据蕴含的复杂非线性关系挖掘需求;最后将该方法用于中国多个关注区域月尺度 $M_w5.0$ 以上强震危险性的概率预测,并通过国际公认的 Molchan 检验表明本算法有效且可靠.

1 数据集

地震目录是复杂的高维对象,其高维性使得地震学家很难对其进行探索,而上面提到的经验地震学方法似乎不太可能利用目录中更深层的丰富信息,但应用机器学习技术在识别它们之间的地震活动性中编码的新关系方面发挥着重要作用(Beroza *et al.*, 2021),尤其是基于目录的地震危险性概率评估方法,其构建过程摒弃了经验性潜在震源识别与参数化设定带来的认知偏差,使得在保持计算流程简洁性的同时提升了预测结果的客观性与可解释性(裴玮来等,2021).

为如实描述区域地震活动的主要特征,研究使用中国地震台网中心1970—2024年的地震目录.为保证数据集的高质量,利用Datist软件对目录进行清洗:依据精确经纬度剔除震中位于研究区域边界之外的震例及依据破裂范围和持续时间判定的余震或震群,确保每条记录都包括正确的经纬度、发生时间、震级和深度等信息.最终的数据由两部分组成:其一是1110条全球 $M_w7.0$ 以上特大震例;其二是81090条全国震例,包括2900条全国

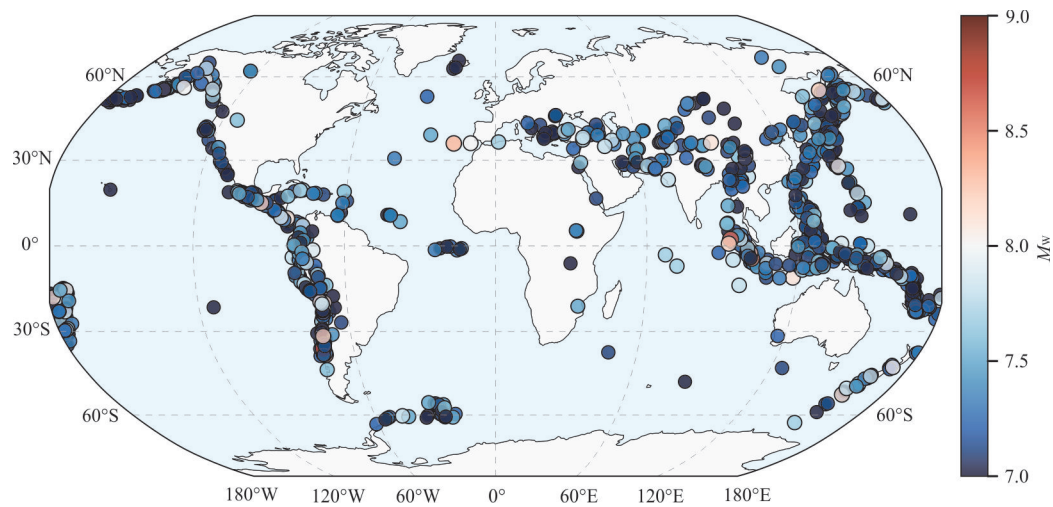


图1 全球1960—2024年 $M_w\geq 7.0$ 以上的地震分布

Fig.1 Global distribution of earthquakes with magnitude $M_w\geq 7.0$ from 1960 to 2024

表 1 划定研究区域的范围及构造背景

Table 1 Delineation of the extent of the study region and its structural background

研究区域	划分范围	构造背景
T01(HH)	红河断裂带周边	印度-欧亚板块碰撞应力控制,历史强震反映走滑断层闭锁
T02(DX)	滇西和澜沧江地震带	滇缅块体走滑-逆冲复合,地震机制多样
T03(HX)	河西走廊、六盘山、兰州、天水	闭锁段应力积累特征突出,历史强震密集
T04(TK)	塔里木盆地西南和昆仑山东部	耦合板缘俯冲受印度板块北向推挤,应力加载引发逆冲型地震丛集
T05(TS)	天山山脉	印度-欧亚碰撞远场效应显著,断层闭锁度高
T06(FB)	福建省东南沿海、渤海地区和山西东部	历史强震受板块内部弱变形与局部应力集中控制
T07(TG)	唐古拉山脉东部	唐古拉山脉东缘走滑断裂网络,地震活动反映高原东向扩展变形机制
T08(TD)	台湾东部及沿海	高角度逆冲及走滑断层发育,地震频发源于板块边界强耦合

$M_w5.0$ 以上强震例.全球的强震分布如图1所示.

地震危险性的确定是通过划定区域(即预计地震发生在圈内,而不发生在圈外)来进行的,其主要思路是利用震例研究成果结合专家经验,圈定可能发生破坏性地震的地区,即地震危险区,如表1所示的区域划分均出自地震危险区,划分范围主要基于断裂带的空间展布特征及历史强震活动格局,确保各单元具有独立的地震构造背景.

2 方法

本文基于贝叶斯网络结构学习方法对不同区域计算 $M_w5.0$ 以上地震危险性概率的总体流程步骤如图2所示.该研究流程主要包括数据处理、结构学习、阈值优化、模型评估.方法研究细节将在后续详细介绍.

2.1 数据处理

基于月尺度滑动窗口,对预处理后的地震目录进行多级划分,其节点设置如表2所示.网络节点架构参

考我国震情短临跟踪技术规范中“全球-全国-区域”多尺度层级融合策略,集成不同空间尺度的地震活动特征,构建具有层级关联性的预测指标体系.数据集的90%用于模型参数估计,10%用于推断测试.为避免因划分不当而导致学习过拟合问题,本研究在不同区域通过分层抽样,使有震与无震样本在训练集与测试集中保持9:1,且确保在时间维度上不存在重叠.

2.2 结构学习

由于网络拓扑结构随节点数量的增加而呈超指数级增长,使得大部分算法结构学习成本过高,导致效果无法接近理论最优.为克服结构学习过程中收敛速度慢和易陷入局部最优的问题,并比较不同搜索算法及超参数配置的性能差距,表3列出了与传统的蚁群优化算法(ant colony optimization, ACO)(Dorigo *et al.*, 1996),以及近年较为优秀的麻雀搜索算法(sparrow search algorithm, SSA)(Xue and Shen, 2020)、灰狼优化算法(grey wolf optimizer, GWO)(Mirjalili *et al.*, 2014)和鲸鱼优

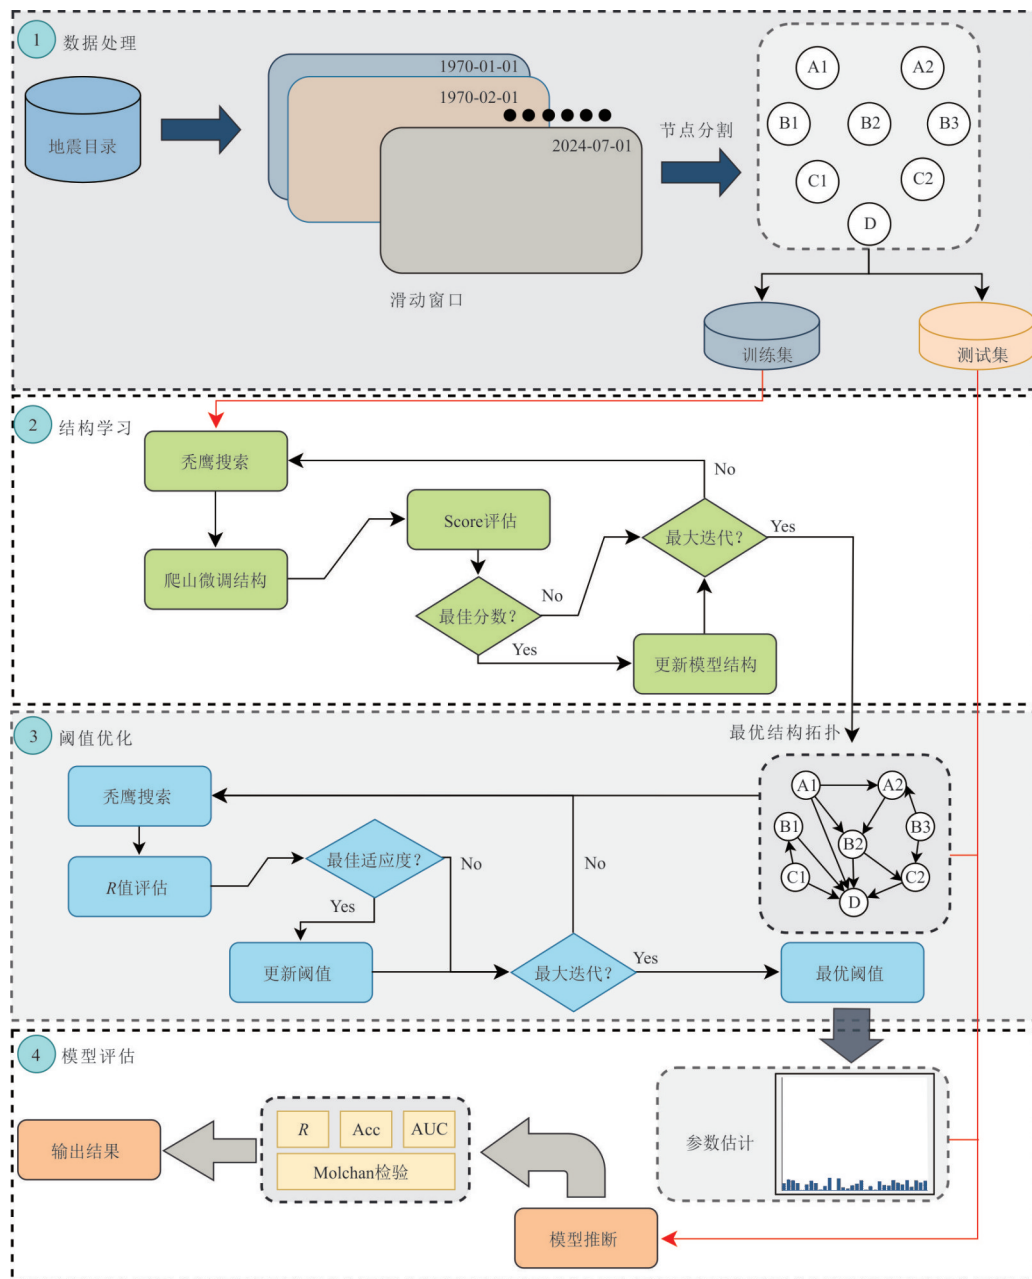


图2 研究方法的框架与流程

Fig.2 Framework and process of the research methodology

表2 贝叶斯网络每个节点的设计细节

Table 2 Design specifics of each node in the Bayesian network

节点	内容	状态0	状态1
A1	全球10年内 $M_w7.0$ 以上地震频率	平静	活跃
A2	全国3年内 $M_w6.0$ 以上地震频率	平静	活跃
B1	区域3年内 $M_L3.0$ 以上地震频率	平静	活跃
B2	全国1年内 $M_w7.0$ 以上地震频率	平静	活跃
B3	全国1年内 $M_w5.0$ 以上地震频率	平静	活跃
C1	区域1年内 $M_L3.0$ 以上地震频率	平静	活跃
C2	区域 $M_w4.0$ 以上地震平静期天数	长时间平静	平静时间短
D	下个月是否发生 $M_w5.0$ 以上地震	不发生	发生

表 3 不同算法在 8 个区域的训练集上性能比较

Table 3 Comparison of average performance of different algorithms on training set of 8 regions

算法	AET	ASD	AKS	迭代轮数	种群数量
ACO+HC	243±2.5	2.75±1.24	939.52±10.25	50	40
SSA+HC	230±3.1	2.12±0.63	1 142.79±1.16	50	40
GWO+HC	238±1.7	1.83±0.53	1 211.68±3.50	50	40
WOA+HC	202±18.0	3.58±1.37	1 416.37±2.44	50	40
BES+HC	203±8.6	1.03±0.11	2 087.29±0.00	50	40
BES+HC	235±11.3	1.00±0.00	2 099.85±0.00	50	50

化算法 (whale optimization algorithm, WOA) (Mirjalili and Lewis, 2016) 的性能对比. 为减少算法固有的随机性和结构学习 N-P 难带来的影响, 对每个区域重复 50 次, 取算法在 8 个研究区域的平均值. 其中 AET 表示所有区域的平均执行时间; ASD 表示模型收敛的平均结构差异; AKS 表示模型在所有区域中获得的平均分数. 结果表明秃鹰搜索算法表现最佳, 因此选其作为网络结构学习算法. 为突破结构学习易导致局部最优解的问题, 本研究将群智能算法与爬山算法结合. 爬山算法是一种基于贪婪搜索的局部优化策略, 该算法从种群随机生成的初始网络拓扑结构开始, 通过对执行添加、删除或反转边的操作对网络拓扑进行微调, 从而更新候选结构, 使其收敛速度更快并让最终学习的网络结构质量更高. 本文实验环境如下: Windows11 操作系统, CPU 为 13th Gen Intel(R) Core(TM) i9-13900K 3.00 GHz, NVIDIA GeForce RTX 4080 SUPER 图形处理器, 概率相关计算采用 pgmpy0.1.25 框架. 所有对比实验均在此环境下进行.

采用 BES+HC 进行结构学习算法的伪代码如附录 1 所示. 通过秃鹰搜索算法特有的动态调整搜索范围和灵活修改种群个体飞行路径来优化对网络拓扑结构空间的搜索策略, 且由于引入了信息共享机制, 使种群个体在搜索时会观察其他个体的行为, 此特点使得该算法特别适用于复杂的网络拓扑学习问题. 在首先的选择阶段, 算法通过随机生成个体位置来建立初始种群, 模拟秃鹰选择局部搜索空间的过程; 此后的搜索阶段, 搜索范围逐渐缩小以提高个体局部搜索的精度. 最后的俯冲阶段, 算法模仿秃鹰狩猎时的俯冲行为, 迅速收敛到本轮迭代的最优解.

算法伪代码中, β 为缩放因子, 取值为 (1.5, 2) 的随机数. P_i 指的是秃鹰 i 在种群中的位置. P_{mean} 表示在种群中选出的平均位置, P_{best} 是当前种群的最佳位置, $P_{\text{candidate}}$ 是当前的候选位置. c_1 和

c_2 是秃鹰向最佳位置和中心位置移动的强度, 取值为 (1, 2) 间的随机数. $x_1(i)$ 和 $y_1(i)$ 用于表示秃鹰的极坐标, 取值范围为 (1, 2) 间的随机数.

2.3 阈值优化

阈值优化分为两方面, 其一为数据离散阈值. 地震目录中的连续型观测数据 (地震频次、平静期天数) 需离散化为二元状态变量. 传统方法多采用经验四分位数或均值分割法, 但易产生重要特征信息损失. BES 在此过程中根据灵活的动态搜索机制离散为信息损失最小的最佳二元变量. 其二为报警概率阈值, 模型输出的后验概率 $P(D=1|E)$ 需通过决策阈值转化为二元预警信号. 考虑到对漏报的敏感性, 二者均采用 R 值最大化为优化目标:

$$\alpha^* = \operatorname{argmax}_{\alpha \in [0, 1]} R(\alpha), \tag{1}$$

式中, $R(\alpha)$ 随 α 变化的函数关系可通过遍历训练集输出. BES 在多维数据区间进行搜索, 能迅速定位使 R 值最大的最优阈值 α^* . 训练过程中, 模型的参数估计采用先验分布为 Dirichlet 分布的贝叶斯估计 (Bayesian estimation, BE), 在测试集推断后验概率采用变量消除法 (variable elimination, VE), 其公式如下所示:

$$P(D|E) = \frac{P(E|D) \times P(D)}{P(E)}, \tag{2}$$
$$P(D|E) = \frac{\sum_H \prod_{i=1}^n P(X_i | \text{Parents}(X_i))}{\sum_{D'} \sum_H \prod_{i=1}^n P(X_i | \text{Parents}(X_i))}, \tag{3}$$

式 (2) 中: $P(D|E)$ 是给定观测证据集合 E 的条件下目标变量 D 发生的后验概率, $P(E|D)$ 是在目标变量 D 已知时观测证据 E 发生的条件概率, 或称为“似然”, $P(D)$ 是目标变量 D 的先验概率, 反映地震目录中的初始假设; $P(E)$ 是观测证据 E 的边缘概率作为归一化常数. 式 (3) 中: X_i 为贝叶斯网络节点, E 为观测证据集合, H 为需要消除的非证据非目标变量, D' 表示目标变量 D 的所有可能取值 (即 D 的

表 4 本研究中混淆矩阵的定义

Table 4 The definition of confusion matrix in this study

混淆矩阵	下个月发生 $M_w 5.0$	下个月未发生
	以上强震	$M_w 5.0$ 以上强震
后验概率超过报警值	TP	FP
后验概率未超过报警值	FN	TN

全域集合). 分子为联合概率在目标变量 D 上的边缘化, 分母为归一化常数. 将对 D 的后验概率超过报警阈值的样本归为正样本, 否则归为负样本, 后续可对模型的评估采用可量化的评价指标.

2.4 评估指标

根据模型训练得到的报警阈值, 可对模型的概率预测结果进行分类评估. 网络的结构学习使用 Cooper and Herskovits (1992) 提出的基于评分搜索方法, 评分函数 Score 采用贝叶斯信息准则 (Bayesian information criterion, BIC), 取相反数是为方便比较. BIC 作为一种基于贝叶斯统计的模型选择工具, 旨在权衡模型的拟合优劣和复杂程度, 通过惩罚参数数量来鼓励选择相对简单的模型, 引导模型向更好的结构发展, 从而避免过拟合. 对于模型在测试集上的表现, 采用适用于机器学习的 R 值 (Peng *et al.*, 2006; Panakkat and Adeli, 2007; Adeli and Panakkat, 2009)、ROC 曲线下面积 (AUC) 和准确率 (Acc) 来评估模型. 其公式分别为:

$$BIC = -2\ln L + k\ln n, \quad (4)$$

$$Score = -BIC, \quad (5)$$

$$R = \frac{TP}{TP + FN} - \frac{FP}{TN + FP}, \quad (6)$$

$$Acc = \frac{TP + TN}{TP + TN + FP + FN}, \quad (7)$$

$$AUC = \int_0^1 TPR(FPR) d(FPR), \quad (8)$$

式中: L 为似然函数的最大值, k 为模型中自由参数的数量, n 为样本量的大小. R 值量化了模型识别地震时空特征和反映捕捉真实震例的能力, 尤其适用于正负样本不平衡、不确定性较大的地震概率预测中, R 值为 0 表示模型决策完全随机; 为 1 表示模型完全预测正确. 准确率可以反映模型的整体预测能力, 而 AUC 弥补了准确度在不平衡数据集上的局限性. TP、FP、TN、FN 的定义如表 4 所示. TPR, 也称为召回率或灵敏度, 表示模型正确识别的正样本比例, FPR 为衡量负样本中被模型错误归类为阳性的比例.

3 结果

3.1 效能量化

通过贝叶斯网络结构学习, 本研究构建了 8 个研究区域的地震危险性概率预测模型 BESBN, 表 5 展示了各区域节点的离散化阈值与报警概率阈值, 不同区域的阈值差异较为明显, T06(FB) 的报警阈值最低 ($\alpha=0.0146$), 而 T04(TK) 的阈值最高 ($\alpha=0.1948$). 其空间异质性反映各构造单元地震活动特征的差异性: 板内断裂带因微震活动频繁, 需更低阈值捕捉异常信号; 而板缘俯冲带受全球强震远程加载作用, 需更高阈值过滤噪声干扰. 表 6 给出了在相同实验条件下 BESBN 与其他统计学模型的性能对比, 其中 ETAS 模型采用 Ogata (1988) 提出的经典模型进行对比, 参数采用最大似然估计拟合, 其中地震发生率取值 0.01, 生产率设为 0.034, 震级影响参数设为 1.027, 时间延迟参数取 0.007, 衰减指数设定为 1.012, 随后基于拟合参数计算条件强度函数获得各区域时间窗口内的地震发生概率, 并与 BESBN 采用相同的 R 值等评估指标进行性能对比. 经分析可见 BESBN 在不同区域的表现均优于目前主流的统计学模型 ETAS 及 Poisson 模型. 对于 BESBN, T03(HX) 的 R 值最高, 为 0.892, AUC 达 0.949, 其 FPR=0.107 为全区域最低, 表明该模型对青藏高原东北缘强震的预测效能最优. 相反, T02(DX) 的 R 值 (0.649)、AUC (0.808) 相对较低, 可能与滇缅块体复杂的走滑-逆冲复合型地震机制有关. 图 3 为 8 个区域对应 BESBN 的混淆矩阵, 综合来看 BESBN 的强震漏报率较低, 根据风险决策理论, 漏报造成的潜在损失往往远超误报损失, 符合防震减灾中“宁可误报、不可漏报”的策略. 网络拓扑结构如图 4 所示, 所有区域的贝叶斯网络均呈现出“全球大震-全国强震-区域微震-区域强震”的跨尺度正反向因果传导路径, 多数区域的节点 C2 与目标节点形成强连接, 表明该区域 4.0 级地震平静期缩短对后续强震具有指示作用, 印证了板块运动通过应力传递影响区域地震活动, 证明该网络结构对区域应力积累-释过程的物理表征能力.

图 5 的条件概率表 (conditional probability table, CPT) 揭示了不同构造单元强震发生概率 ($D=1$) 的空间分异. 属于板缘俯冲带的 T04(TK)、T08(TD) $D=1$ 概率在 0.2~0.4 区间形成明显峰值, 反映印度板块俯冲带和台湾弧陆碰撞带因板块边界

表 5 不同区域 BESBN 的阈值

Table 5 Thresholds for BESBN in different regions

模型	α_{warn}	α_{A1}	α_{A2}	α_{B1}	α_{B2}	α_{B3}	α_{C1}	α_{C2}
BESBN-T01	0.065 6	175.41	21.02	52.93	4.44	52.74	82.20	661.75
BESBN-T02	0.055 3	192.86	19.98	25.57	3.48	30.24	10.39	151.57
BESBN-T03	0.047 2	196.42	16.65	9.74	2.48	35.19	2.98	604.50
BESBN-T04	0.194 8	176.32	17.73	75.16	2.81	45.73	11.43	214.70
BESBN-T05	0.057 5	209.92	17.16	5.91	3.81	40.36	12.82	669.81
BESBN-T06	0.014 6	153.80	20.71	7.76	1.90	34.96	3.19	1187.76
BESBN-T07	0.093 8	147.01	22.26	11.48	4.44	34.78	9.18	607.50
BESBN-T08	0.159 3	174.15	17.92	2.97	1.42	79.14	13.96	378.22




图 3 模型在测试集上推理结果的混淆矩阵

Fig.3 Confusion matrix for BESBN inference results on the test set

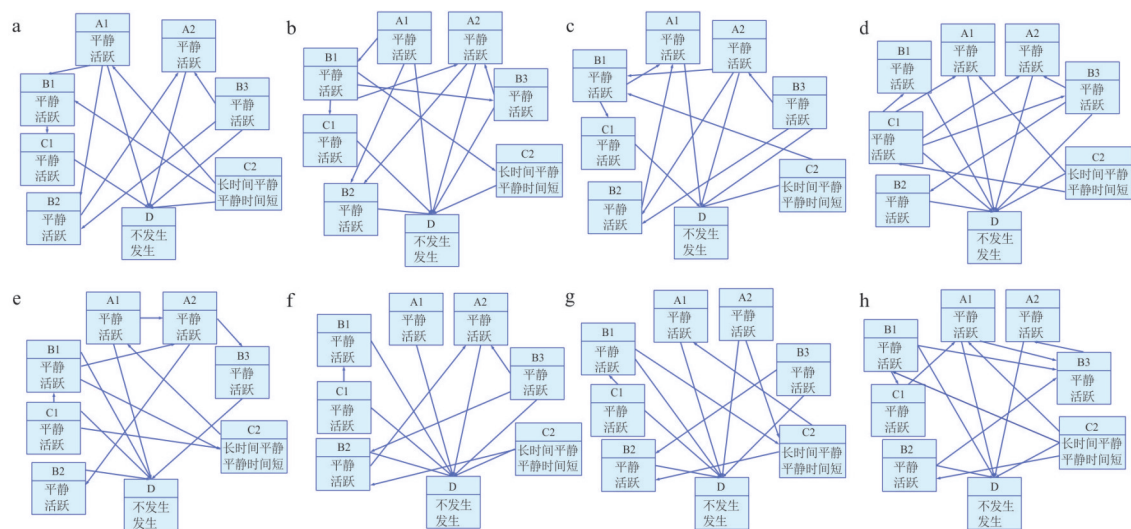


图 4 不同区域 BESBN 网络结构对比

Fig.4 Comparison of BESBN network structures in different regions




图 5 8 个区域中 BESBN 的条件概率表

Fig.5 Conditional probability tables for BESBN in 8 regions

表 6 不同区域的模型性能比较

Table 6 Comparison of model performances in different regions

研究区域	模型	R	Acc	AUC	FPR
T01(HH)	BESBN-T01	0.873	0.880	0.980	0.127
	ETAS	0.742	0.821	0.876	0.179
	Poisson	0.612	0.746	0.723	0.254
T02(DX)	BESBN-T02	0.649	0.768	0.808	0.240
	ETAS	0.548	0.716	0.745	0.284
	Poisson	0.421	0.642	0.651	0.358
T03(HX)	BESBN-T03	0.892	0.894	0.949	0.107
	ETAS	0.769	0.835	0.882	0.165
	Poisson	0.634	0.752	0.731	0.248
T04(TK)	BESBN-T04	0.659	0.777	0.825	0.250
	ETAS	0.556	0.716	0.748	0.284
	Poisson	0.418	0.627	0.642	0.373
T05(TS)	BESBN-T05	0.825	0.836	0.897	0.175
	ETAS	0.697	0.776	0.824	0.224
	Poisson	0.573	0.701	0.692	0.299
T06(FB)	BESBN-T06	0.832	0.835	0.871	0.168
	ETAS	0.714	0.775	0.812	0.225
	Poisson	0.588	0.695	0.698	0.305
T07(TG)	BESBN-T07	0.790	0.809	0.898	0.210
	ETAS	0.672	0.750	0.821	0.250
	Poisson	0.534	0.676	0.687	0.324
T08(TD)	BESBN-T08	0.740	0.866	0.890	0.136
	ETAS	0.628	0.806	0.823	0.194
	Poisson	0.495	0.731	0.708	0.269

持续应力加载,导致断层闭锁段更易发生应力失稳。相反,属于板内断裂带区域的 T01(HH)、T02(DX)、T03(HX)、T05(TS)、T06(FB)的 $D=1$ 概率普遍低于 0.2,特别是 T02(DX) 在 0.1 处出现主

峰,可能预示走滑-逆冲复合型断层系统的应力释放更为分散。T04(TK) 在 0.2 和 0.4 处呈现双峰分布,可能对应全球强震远程触发与本地应力积累两种机制共存,其概率结构的空分特征与各区

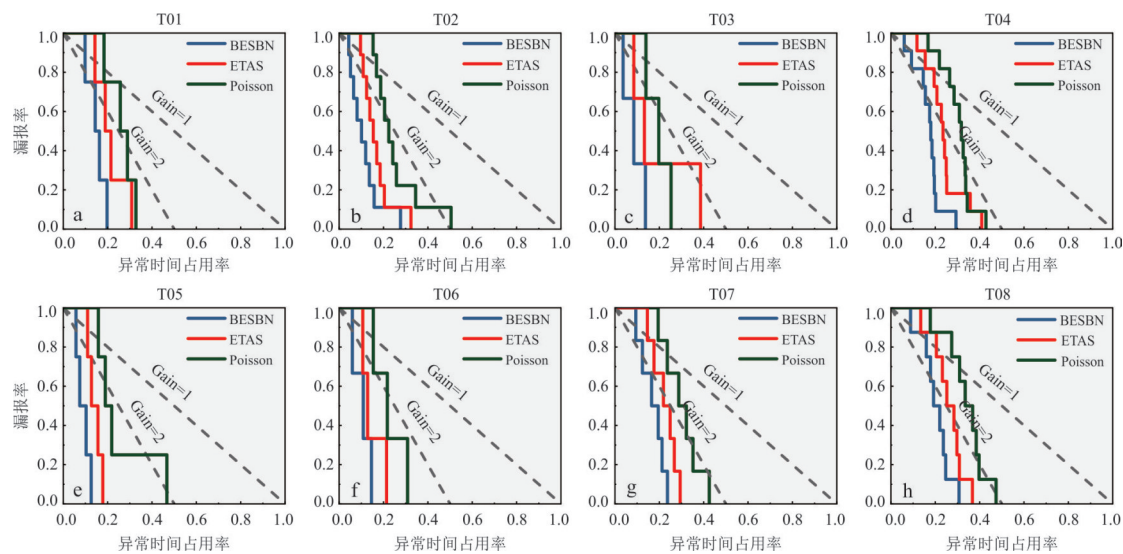


图 6 不同区域模型的 Molchan 图
Fig.6 Molchan plots of models in different regions

表 7 Molchan 检验结果
Table 7 Molchan test results

研究区域	模型	1-S	$G_{avg}(0.1\tau)$	$G_{avg}(0.2\tau)$	G_{avg}	G_{max}
T01(HH)	BESBN-T01	0.839 7	2.540 1	3.918 4	3.918 4	5.064 6
	ETAS	0.765 5	-	2.197 1	2.781 9	3.490 7
	Poisson	0.717 5	-	1.359 1	2.236 5	3.053 5
T02(DX)	BESBN-T02	0.872 4	4.375 8	4.993 1	4.840 0	5.717 7
	ETAS	0.820 4	1.153 9	2.980 4	3.145 7	4.360 5
	Poisson	0.726 4	-	1.275 1	2.089 5	3.010 1
T03(HX)	BESBN-T03	0.896 9	8.470 7	8.072 5	8.072 5	9.082 6
	ETAS	0.748 6	3.923 8	4.472 9	3.845 7	5.022 0
	Poisson	0.784 5	-	2.882 9	3.240 3	3.954 9
T04(TK)	BESBN-T04	0.818 8	1.741 3	2.745 9	2.966 7	4.510 2
	ETAS	0.746 2	-	1.116 7	2.110 2	3.254 8
	Poisson	0.683 3	-	0.543 4	1.673 0	2.643 8
T05(TS)	BESBN-T05	0.901 2	5.531 3	6.570 4	6.570 4	7.934 6
	ETAS	0.848 5	-	4.151 8	4.151 8	5.605 7
	Poisson	0.703 0	-	2.108 8	2.447 8	3.434 2
T06(FB)	BESBN-T06	0.881 0	5.593 7	6.195 6	6.195 6	6.864 4
	ETAS	0.832 5	-	4.161 6	4.333 2	5.192 5
	Poisson	0.747 7	-	2.165 2	2.825 0	3.242 9
T07(TG)	BESBN-T07	0.817 0	1.777 6	2.729 0	3.178 6	4.228 1
	ETAS	0.762 7	-	1.519 2	2.421 3	3.403 1
	Poisson	0.678 0	-	0.855 8	1.800 0	2.368 4
T08(TD)	BESBN-T08	0.782 8	1.412 3	1.922 1	2.563 8	3.545 5
	ETAS	0.725 4	-	0.930 8	2.004 3	2.835 7
	Poisson	0.614 6	-	0.704 7	1.535 3	2.201 9

域断裂带闭锁程度、应力加载速率等具有相关性。

3.2 Molchan 检验

对地震危险性概率预测领域,研究提出的预测

方法是否真的有效需要进行严格透明的检验,概率性预测模型的有效测量标准尤以“概率增益”(probability gain)最为重要(Aki, 1981).为了对本研究方法

进行严格透明的检验,采用了被广泛应用于地震预测的统计方法——Molchan 检验.该方法由 Molchan (2010)提出,通过构建 Molchan 图来量化模型预测能力的优劣,尤其适用于基于概率的危险性预测模型.

在 Molchan 图中,横轴 τ 表示异常时间占用率,即预测的警报范围占总观测时间的比例;纵轴 ν 代表漏报率,即未预测成功的地震事件占总地震事件的比例.理想情况下,模型的预测效能图中应尽可能位于左下角,即捕捉到较小警报范围内的大部分地震事件.图中的对角线代表随机猜测,任何有效的预测方法都应低于这条对角线(孙小龙等,2018).

在本研究中,首先根据不同区域确定模型不同的预警阈值,并将高于这些阈值的后验概率视为警报(Molchan, 1991; Zechar *et al.*, 2008).其次,根据 Molchan 图可计算每个震例的概率增益,计算公式如下:

$$G = \frac{1 - \nu}{\tau}. \quad (9)$$

式中: G 大于 1 表示优于随机猜测, G 越大预测效果越好.最后,根据绘制的曲线图计算出曲线下的面积 S ,模型的预测效能定义为 $1-S$.图 6 显示了不同模型的 Molchan 检验结果,且经检验证明 BESBN 在不同区域中均具有与主流模型相比更好的效能.表 7 显示了 Molchan 检验的计算细节:当 $\tau < 0.2$ 时所有区域的平均 G 值均大于 1.5,证明模型在预警时间占比 20% 以内,其月尺度决策是高可靠的,此特性得益于贝叶斯网络对多时间尺度预测指标的协同推理能力,特别是通过结构学习发现的“全球特大地震-全国强震-区域微震”的复杂因果关联机制,从而在较小 τ 值时实现高地震覆盖率.通过 8 个构造区的对比分析,发现模型在活动断裂带密集地如 T03(HX)表现最优,其曲线最贴近坐标原点,最大概率增益达 9.08,而 ETAS 及 Poisson 模型只有 5.02 和 3.95,表明传统模型难以捕捉区域微震活动自组织演化的非线性特征.这种空间差异性可能源于不同构造单元的地震活动特征:板缘俯冲带 T08(TD)的强震受全球板块运动影响显著,而板内断裂区 T03(HX)更多依赖区域微震活动的自组织演化,这与网络结构学习中发现的跨尺度因果关系吻合.

相较于传统固定阈值策略,BESBN 这种基于地震目录数据驱动的动态阈值选择机制可使每个研究区域的预警灵敏度与其地震活动水平自动适配.在地震频发的 T04(TK)需要更高预警时间占比来维持低漏报率,而相对地震活动较为平静的 T06(FB)则需要极高敏感阈值 $\alpha =$

0.015 来快速响应,这种差异化策略使得 T06 (FB)在 Molchan 图中斜率表现更加陡峭.

4 结论及讨论

本研究基于贝叶斯网络结构学习方法,构建了适用于多区域的月尺度强震危险性概率预测模型.与传统确定性地震预测模型不同,贝叶斯网络这种基于统计学的模型通过概率公式推理,直观解释不同区域的短期地震危险性.有别于基于预设的专家知识网络,BESBN 通过数据驱动发现潜在因果,学习的网络拓扑往往具有更高复杂性,一定程度降低了由于主观经验导致忽略潜在问题的隐患,为及时调整地震灾害预防策略提供有效支撑.

针对目前月尺度地震预测缺少可靠方法或模型的问题,本文提出的方法经过多研究区域的 Molchan 检验,在低异常时间占比($\tau < 0.2$)时,所有区域平均概率增益可达 4.64,证明其是有效的.

对于本研究采用分区域建模策略而非全国尺度建模,主要基于以下科学考量:国内地震活动受控于复杂的构造背景,且各单元的应力场分布、断层几何结构等存在较大差异,全国尺度的建模将面临参数空间异质性过大的局限性,不同构造区域的地震触发机制从逆冲型、走滑型到拉张型变化剧烈,其震源深度、破裂尺度等关键参数的分布特征差异较大.若采用全国统一的网络结构和参数体系,可能会导致模型过度平滑区域差异,丧失对局部地震活动特征的敏感性,最终影响预测精度.相比之下分区域建模策略通过构造单元的独立划分,使每个子模型能够充分适应其特定的地震构造环境,确保了参数估计的稳健性和预测结果的可靠性.

本研究为短期地震危险性预测提供了可解释的数据驱动因果关联,其结构学习机制对揭示地震产生的因果具有普适意义,但对于个别区域的 BESBN 模型漏报的强震例,原因需后续进一步研究.该方法为现有的地震危险性概率预测体系提供了补充,未来将探索网络拓扑结构与地壳形变、地球化学等多源学科数据融合,优化算法提升学习效率,增强模型对复杂构造环境的适应性.

致谢:北京白家疃地球科学国家野外科学观测研究站为节点设计提供指导意见;辽宁省地震局为选择研究区域提供宝贵意见;感谢审稿专家提出的宝贵修改意见!

附录见 <https://doi.org/10.3799/dqkx.2025.186>.

References

- Adeli, H., Panakkat, A., 2009. A Probabilistic Neural Network for Earthquake Magnitude Prediction. *Neural Networks*, 22(7): 1018–1024. <https://doi.org/10.1016/j.neunet.2009.05.003>
- Aki, K., 1981. A Probabilistic Synthesis of Precursory Phenomena. In: Simpson D. W., Richards P. G., eds., *Earthquake Prediction*. American Geophysical Union, Washington, D. C., 566–574. <https://doi.org/10.1029/me004p0566>
- Al-Betar, M. A., 2017. B-Hill Climbing: An Exploratory Local Search. *Neural Computing and Applications*, 28(Suppl. 1): 153–168. <https://doi.org/10.1007/s00521-016-2328-2>
- Alsattar, H. A., Zaidan, A. A., Zaidan, B. B., 2020. Novel Meta-Heuristic Bald Eagle Search Optimisation Algorithm. *Artificial Intelligence Review*, 53(3): 2237–2264. <https://doi.org/10.1007/s10462-019-09732-5>
- Andrić, J. M., Lu, D. G., 2017. Fuzzy Probabilistic Seismic Hazard Analysis with Applications to Kunming City, China. *Natural Hazards*, 89(3): 1031–1057. <https://doi.org/10.1007/s11069-017-3007-z>
- Beroza, G. C., Segou, M., Mostafa Mousavi, S., 2021. Machine Learning and Earthquake Forecasting—Next Steps. *Nature Communications*, 12: 4761. <https://doi.org/10.1038/s41467-021-24952-6>
- Cooper, G. F., Herskovits, E., 1992. A Bayesian Method for the Induction of Probabilistic Networks from Data. *Machine Learning*, 9(4): 309–347. <https://doi.org/10.1007/BF00994110>
- Cornell, C. A., 1968. Engineering Seismic Risk Analysis. *Bulletin of the Seismological Society of America*, 58(5): 1583–1606. <https://doi.org/10.1785/bssa0580051583>
- Deng, S. G., Zhou, L. Q., Ma, Y. W., et al., 2019. Research on Probability Prediction of Earthquake Risk Based on Bayesian Theorem. *Earthquake Research in China*, 35(1): 1–13 (in Chinese with English abstract).
- Dieterich, J., Cayol, V., Okubo, P., 2000. The Use of Earthquake Rate Changes as a Stress Meter at Kilauea Volcano. *Nature*, 408(6811): 457–460. <https://doi.org/10.1038/35044054>
- Dorigo, M., Maniezzo, V., Colomi, A., 1996. Ant System: Optimization by a Colony of Cooperating Agents. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 26(1): 29–41. <https://doi.org/10.1109/3477.484436>
- Drams, J. S., Kuglitsch, M. M., Fernández-Torres, M. Á., et al., 2025. Explainability can Foster Trust in Artificial Intelligence in Geoscience. *Nature Geoscience*, 18(2): 112–114. <https://doi.org/10.1038/s41561-025-01639-x>
- Fleming, S. W., Watson, J. R., Ellenson, A., et al., 2021. Machine Learning in Earth and Environmental Science Requires Education and Research Policy Reforms. *Nature Geoscience*, 14(12): 878–880. <https://doi.org/10.1038/s41561-021-00865-3>
- He, C. C., Wang, P., Tian, L. Y., et al., 2024. A Novel Structure Learning Method of Bayesian Networks Based on the Neighboring Complete Node Ordering Search. *Neurocomputing*, 585: 127620. <https://doi.org/10.1016/j.neucom.2024.127620>
- Jiang, M. M., Zhou, S. Y., Chen, Y. J., et al., 2011. A New Multidimensional Stress Release Statistical Model Based on Coseismic Stress Transfer. *Geophysical Journal International*, 187(3): 1479–1494. <https://doi.org/10.1111/j.1365-246X.2011.05208.x>
- Kuglitsch, M. M., Albayrak, A., Luterbacher, J., et al., 2023. When It Comes to Earth Observations in AI for Disaster Risk Reduction, Is It Feast or Famine? A Topical Review. *Environmental Research Letters*, 18(9): 093004. <https://doi.org/10.1088/1748-9326/acf601>
- Li, D. M., Zheng, J. C., Yuan, Z. Y., 2025. Probabilistic Prediction of the Earthquake Risk in North China and Test of Forecast Efficiency. *Journal of Seismological Research*, 48(2): 281–288 (in Chinese with English abstract).
- Liu, H., Zhao, R. Z., Dong, H. B., 2024. Short-Impending Earthquake Prediction Method Based on High-Order Magnetic Anomaly Derivative and High-Order Statistic. *Earth Science*, 49(8): 2952–2960 (in Chinese with English abstract).
- Liu, H. R., Cai, Y. B., Shi, Q. R., et al., 2023. An Improved Harris Hawks Optimization for Bayesian Network Structure Learning via Genetic Operators. *Soft Computing*, 27(20): 14659–14672. <https://doi.org/10.1007/s00500-023-09107-7>
- Ma, Y., Bi, J. M., Dong, D. M., 2024. Seismic Activity Characteristics of the Chinese Continent Based on a “Hybrid” Probability Forecasting Model. *Applied Geophysics*, 21(4): 1–13. <https://doi.org/10.1007/s11770-024-1139-y>
- Mirjalili, S., Lewis, A., 2016. The Whale Optimization Algorithm. *Advances in Engineering Software*, 95: 51–67. <https://doi.org/10.1016/j.advengsoft.2016.01.008>
- Mirjalili, S., Mirjalili, S. M., Lewis, A., 2014. Grey Wolf Optimizer. *Advances in Engineering Software*, 69: 46–61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>
- Molchan, G., 2010. Space-Time Earthquake Prediction: The Error Diagrams. In: Savage, M. K., Rhoades, D. A., Smith, E. G. C., et al., eds., *Seismogenesis and Earthquake Forecasting: The Frank Evison (Volume II)*. Springer, Basel,

- 53—63. https://doi.org/10.1007/978-3-0346-0500-7_5
- Molchan, G. M., 1991. Structure of Optimal Strategies in Earthquake Prediction. *Tectonophysics*, 193(4): 267—276. [https://doi.org/10.1016/0040-1951\(91\)90336-Q](https://doi.org/10.1016/0040-1951(91)90336-Q)
- Ogata, Y., 1988. Statistical Models for Earthquake Occurrences and Residual Analysis for Point Processes. *Journal of the American Statistical Association*, 83(401): 9—27. <https://doi.org/10.1080/01621459.1988.10478560>
- Panakkat, A., Adeli, H., 2007. Neural Network Models for Earthquake Magnitude Prediction Using Multiple Seismicity Indicators. *International Journal of Neural Systems*, 17(1): 13—33. <https://doi.org/10.1142/S0129065707000890>
- Pei, W. L., Zhou, S. Y., Zhuang, J. C., et al., 2021. Application and Discussion of Statistical Seismology in the Study of Probability Prediction Method of Seismic Risk. *Scientia Sinica Terrae*, 51(12): 2035—2047 (in Chinese).
- Peng, K. Y., Yin, X. C., Zhang, L. P., 2006. A Statistical Investigation of the Earthquake Predictions Using LURR. *Pure and Applied Geophysics*, 163(11): 2353—2362. <https://doi.org/10.1007/s00024-006-0124-0>
- Shi, H. X., Meng, L. Y., Zhang, X. M., et al., 2018. Decrease in b Value Prior to the Wenchuan Earthquake (M_s 8.0). *Chinese Journal of Geophysics*, 61(5): 1874—1882 (in Chinese with English abstract).
- Sun, X. L., Xiang, Y., Yang, P. T., 2018. Earthquake Prediction Efficiency Inspection of Water Level in Huize Well and Its Anomaly Mechanism. *Acta Seismologica Sinica*, 40(2): 185—194 (in Chinese with English abstract).
- Vere-Jones, D., 1978. Earthquake Prediction—A Statistician's View. *Journal of Physics of the Earth*, 26(2): 129—146. <https://doi.org/10.4294/jpe1952.26.129>
- Wang, P., Shao, Z. G., Liu, Q., et al., 2019. Probabilistic Forecasting of Earthquakes Based on Multidisciplinary Physical Observations and Its Application in Sichuan and Yunnan. *Chinese Journal of Geophysics*, 62(9): 3448—3463 (in Chinese with English abstract).
- Wang, R., Chang, Y., Han, P., et al., 2023. Optimized Traffic Light System with AIC and Application to the 2021 $M6.7$ Yangbi Earthquake Sequence. *Entropy*, 25(5): 759. <https://doi.org/10.3390/e25050759>
- Wang, R., Chang, Y., Miao, M., et al., 2021. Assessing Earthquake Forecast Performance Based on b Value in Yunnan Province, China. *Entropy*, 23(6): 730. <https://doi.org/10.3390/e23060730>
- Xu, J. K., Zhang, H. M., Chen, X. F., 2015. Rupture Phase Diagrams for a Planar Fault in 3-D Full-Space and Half-Space. *Geophysical Journal International*, 202(3): 2194—2206. <https://doi.org/10.1093/gji/ggv284>
- Xu, W. J., Gao, M. T., 2012. Calculation of Upper Limit Earthquake Magnitude for Northeast Seismic Region of China Based on Truncated G-R Model. *Chinese Journal of Geophysics*, 55(5): 1710—1717 (in Chinese with English abstract).
- Xue, J. K., Shen, B., 2020. A Novel Swarm Intelligence Optimization Approach: Sparrow Search Algorithm. *Systems Science & Control Engineering*, 8(1): 22—34. <https://doi.org/10.1080/21642583.2019.1708830>
- Yang, W. T., Tamssaouet, K., Dauzère-Pérès, S., 2024. Bayesian Network Structure Learning Using Scatter Search. *Knowledge - Based Systems*, 300: 112149. <https://doi.org/10.1016/j.knosys.2024.112149>
- Zechar, J. D., Jordan, T. H., 2008. Testing Alarm-Based Earthquake Predictions. *Geophysical Journal International*, 172(2): 715—724. <https://doi.org/10.1111/j.1365-246X.2007.03676.x>
- Zhang, Z. G., Xu, J. K., Huang, H. Q., et al., 2017. Seismic Characteristics of Supershear and Sub-Rayleigh Earthquakes: Implication from Simple Cases. *Geophysical Research Letters*, 44(13): 6712—6717. <https://doi.org/10.1002/2017GL074158>

中文参考文献

- 邓世广, 周龙泉, 马亚伟, 等, 2019. 基于贝叶斯定理的地震危险性概率预测研究. *中国地震*, 35(1): 1—13.
- 李冬梅, 郑建常, 苑争一, 2025. 华北地区地震风险概率预测及预报效能检验. *地震研究*, 48(2): 281—288.
- 刘欢, 赵润卓, 董浩斌, 2024. 基于高阶磁异常导数与高阶统计量的地震短临预测方法. *地球科学*, 49(8): 2952—2960.
- 裴玮来, 周仕勇, 庄建仓, 等, 2021. 统计地震学在地震危险性概率预测方法研究中的应用与讨论. *中国科学: 地球科学*, 51(12): 2035—2047.
- 史海霞, 孟令媛, 张雪梅, 等, 2018. 汶川地震前的 b 值变化. *地球物理学报*, 61(5): 1874—1882.
- 孙小龙, 向阳, 杨朋涛, 2018. 云南会泽井水位地震预测效能检验及其机理分析. *地震学报*, 40(2): 185—194.
- 王芃, 邵志刚, 刘琦, 等, 2019. 基于多学科物理观测的地震概率预测方法在川滇地区的应用. *地球物理学报*, 62(9): 3448—3463.
- 徐伟进, 高孟潭, 2012. 根据截断的 G-R 模型计算东北地震区震级上限. *地球物理学报*, 55(5): 1710—1717.