

DOI:10.3880/j.issn.1004-6933.2023.02.012

基于强化学习的海南岛山洪灾害易发性评估

徐奎¹, 潘昊¹, 宾零陵², 练继建¹

(1. 天津大学水利工程仿真与安全国家重点实验室, 天津 300350; 2. 天津师范大学地理与环境科学学院, 天津 300387)

摘要:采用多重共线性分析和极致梯度提升模型确定海南岛山洪灾害影响因子,提出了基于SAC强化学习算法的海南岛山洪灾害易发性评估模型。采用敏感性、特异性等指标和受试者工作特征曲线,将强化学习模型评估结果与卷积神经网络和深度神经网络模型评估结果进行对比。结果表明:强化学习模型具有较高的准确性和可靠性,测试数据集AUC指标达到0.931,高于卷积神经网络和深度神经网络模型的评估结果,可为海南岛山洪灾害风险评估提供科学依据。

关键词:山洪灾害易发性; 防洪减灾; 特征选择; 强化学习; 海南岛

中图分类号:X43;TV87 **文献标志码:**A **文章编号:**1004-6933(2023)02-0095-06

Evaluation of mountain torrent disaster vulnerability in Hainan Island based on reinforcement learning//XU Kui¹, PAN Hao¹, BIN Lingling², LIAN Jijian¹ (1. State Key Laboratory of Hydraulic Engineering Simulation and Safety, Tianjin University, Tianjin 300350, China; 2. School of Geography and Environmental Science, Tianjin Normal University, Tianjin 300387, China)

Abstract: The multi-collinearity analysis and the extreme gradient lifting model were used to determine the impact factors of mountain torrent disaster vulnerability of Hainan Island, and a reinforcement learning (RL) evaluation model of mountain torrent disasters was proposed based on the SAC (soft actor-critic) RL algorithm. The RL model results were compared with those of the convolution neural network (CNN) and deep neural network (DNN) models based on the sensitivity and specificity, as well as the receiver operating characteristic curve. Results show that the RL model has higher accuracy and reliability, and its area under curve (AUC) index of the test data set reaches 0.931, which is higher than those of the CNN and DNN models. The RL model can provide scientific basis for mountain torrent disaster risk assessment in Hainan Island.

Key words: mountain torrent disaster vulnerability; flood prevention and disaster reduction; feature selection; reinforcement learning; Hainan Island

洪水是全球最常见的自然灾害之一,每年均会造成巨大的生命和财产损失^[1]。据统计,世界每年因洪水灾害造成的经济损失达600亿美元^[2]。近年来,气候变化加剧了洪水发生的频率和强度,未来海南岛内极端天气事件会更加频繁和严重。因此,需要对洪涝灾害进行深入研究^[3]。

山洪灾害是由山区河道满溢的洪水引发的灾害,与降雨、地形、人口密度等因素相关。山洪灾害易发性为灾害的易发程度,即某区域内灾害事件发生概率的大小。多年来针对山洪灾害评估,学者们进行了大量研究,研究方法多聚焦于水文模型方法、

经验统计方法、机器学习方法等^[4]。传统的水文模型方法主要利用水文-水动力模型计算流量和水位,如暴雨洪水管理模型(storm water management model, SWMM)^[5-6]等,从而确定流域内山洪易发性。经验统计方法主要利用数理统计方法建立特定区域内地理环境因素与山洪灾害易发性之间的经验预报方程^[7]。经验统计方法过分依赖历史数据,结论只针对所述研究对象,普适性较差^[8];精准的水文-水动力模型模拟需要通过实地调查等收集大量数据,而研究区域的动态复杂性和非线性加大了数据收集的难度^[9]。

基金项目:国家自然科学基金(51809192,51509179);宁夏回族自治区重点研发计划(2022BEG02020)

作者简介:徐奎(1987—),男,副教授,博士,主要从事洪涝风险管理研究。E-mail:kui.xu@tju.edu.cn

通信作者:宾零陵(1987—),女,讲师,博士,主要从事水文学及水资源研究。E-mail:bl1813@126.com

近年来,机器学习算法由于计算成本低、速度快,越来越多地应用于山洪灾害评估建模,机器学习算法包括单一机器学习模型、混合模型^[10]等。Ngo等^[11]比较了单一机器学习方法与基于专家知识的模型性能,发现机器学习算法优于基于专家知识的模型。混合模型较单一基准模型预测精度往往较高,Bui等^[12]结合了径向基神经网络和逻辑回归算法,结果表明该混合模型在洪水建模方面有广泛应用前景。尽管有大量机器学习算法用于山洪灾害评估建模,但其一般需要提供大量标签数据进行训练^[13]。强化学习(reinforcement learning, RL)是机器学习的一个重要分支,它不需要提供大量有标签训练数据,具有极强的通用性与准确性^[14-15],但RL还未用于山洪灾害易发性评估建模。基于此,本文提出基于SAC(soft actor-critic)的RL算法,并引入最大熵理论对海南岛山洪灾害易发性进行评估,确定山洪灾害易发性建模的关键因素,得到山洪灾害易发性分布,并将RL模型结果与深度神经网络(deep neural network, DNN)模型、卷积神经网络(convolution neural network, CNN)模型结果进行比较。

1 研究区概况和数据来源

海南岛地处中国最南端,位于北纬 $18^{\circ}10' \sim 20^{\circ}10'$ 、东经 $108^{\circ}37' \sim 111^{\circ}03'$,是中国受洪水影响最严重的地区之一。海南岛地势中间高、四周低,以五指山、鹦哥岭为隆起核心,向外围逐级下降,由山地、丘陵、台地、平原构成环形层状地貌。13条主要河流的总集水面积达 $23\,765\text{ km}^2$ 。该地区雨量充沛,年降水量最高可达 $2\,500\text{ mm}$,雨季降水量约占全年降水量的80%,洪水频繁发生并造成巨大损失。

参考海南省各市县2000—2014年地方志、年鉴、水利志、出版物记载的所有山洪灾害事件,若某地发生过山洪灾害,则量化为1,最终选取了348个发生过山洪灾害事件的坐标点。为保证数据的平衡性,在非洪灾区内随机选择相同数量的非山洪灾害点(348个),山洪灾害点与非山洪灾害点共同组成山洪灾害易发性建模所用的清单点。调用R软件中的SDM(sparse distributed memory)软件包,使用随机划分方法,将山洪灾害清单点数据的70%用于模型训练,30%用于模型验证。

2 研究方法

2.1 初选山洪灾害影响因子

根据文献分析结果及数据的可获得性,初选出高程、坡度、坡向、平面曲率、水流动力指数(stream

power index, SPI)、地形湿度指数(topographic wetness index, TWI)、泥沙输移指数(sediment transport index, STI)、土地利用类型、土壤类型、归一化差分植被指数(normalized difference vegetation index, NDVI)、岩性、距河距离、多年平均最大24 h降水量、人口密度共14个山洪灾害影响因子。考虑到因研究区域不同造成选择山洪灾害影响因子的差异,通过多重共线性分析及特征选择确定最终的山洪灾害影响因子。

2.2 多重共线性分析

多重共线性指模型中的变量之间存在精确相关关系或高度相关关系。在山洪灾害易发性建模中,如果山洪灾害影响因子间存在相关关系,直观来看不容易区分影响因子对山洪灾害易发性的单独影响。在计算方面会使模型参数估计值的方差变大,从而导致模型稳定性较差。为消除可能存在多重共线性的因子,本文采用方差膨胀因子进行多重共线性分析,计算公式为

$$F = \frac{1}{1 - R_i^2} \quad (1)$$

式中: F 为方差膨胀因子; R_i 为将第 i 个山洪灾害影响因子作为因变量与其余作为自变量的山洪灾害影响因子拟合回归方程的相关系数。 F 值越接近于1,多重共线性越弱,反之越强。通常以10作为判断阈值^[16],当 $F < 10$ 时,可认为不存在多重共线性;反之则存在多重共线性。

2.3 基于XGBoost的特征选择

为检验并消除对海南岛山洪易发性作用为0的因子,使用XGBoost算法^[17]获得山洪灾害影响因子的相对重要性。XGBoost算法进行特征选择取决于各个特征对模型贡献的重要度,以信息增益作为计算依据。XGBoost建模计算后即可统计山洪灾害影响因子的重要度,进行特征选择。

2.4 基于深度RL的山洪灾害易发性评估方法

RL框架包括环境、智能体、状态、动作、策略、奖励6要素。在RL任务过程中(图1),智能体在阶段 t 状态为 s_t , $\pi(a|s)$ 为动作到状态的映射,根据策略 π 选择一个动作 a_t ,执行该动作,使下一阶段的




图1 RL过程

Fig.1 RL process

状态变为 s_{t+1} ,并得到奖励 r_{t+1} ,以最大化累计奖励 (R) 为目标确定最优策略。

本文引入基于 SAC 的 RL 算法^[18] ,其最优策略表达式为

$$\pi^* = \operatorname{argmax} E(R + \alpha H) \tag{2}$$

式中: π^* 为最优策略; H 为熵; α 为熵的正则化系数。

在计算奖励的基础上考虑了熵,增加了训练过程的随机性。对于基于 SAC 的 RL 算法的山洪灾害易发性评估试验,状态空间由所有山洪灾害影响因子组成;动作空间以上述山洪灾害清单点是否为山洪灾害发生点为依据,是则量化为 1,否则量化为 0;奖励设置成负值,以期模型可以快速达到目标状态。奖励函数为

$$r = |p_{\text{lable}} - p_{\text{action}}| \times 10 \tag{3}$$

式中: p_{lable} 为训练过程中山洪灾害发生的概率; p_{action} 是每次预测采取的动作,量化为 1、0,分别表示上述山洪灾害是、否发生。奖励值 r 是判断模型是否收敛并达到最优的参数。

RL 算法中利用学习率控制学习进度,其值通常在 0.001 ~ 0.01 之间,本次试验设为 0.006。熵的正则化系数 α 会影响算法的收敛速度和训练模型的性能,试验中取 $\alpha = 0.2$ 。设置批处理样本数为 128,最大回合数为 10 000,最大时间步数为 1 000,优化器选择常用的 Adam 优化器。

2.5 灾害易发性评估模型性能比较

采用统计指标灵敏度 E 、特异性 P 和准确率 C 评估和比较模型的学习、预测能力。计算公式分别为

$$E = \frac{T_p}{T_p + F_N} \tag{4}$$

$$P = \frac{T_N}{T_N + F_p} \tag{5}$$

$$C = \frac{T_p + T_N}{T_p + T_N + F_p + F_N} \tag{6}$$

式中: T_p 、 T_N 分别为正确分类的真阳性和真阴性值; F_p 、 F_N 分别为错误分类的假阳性和假阴性值。真阳性指预测山洪灾害发生,实际也发生;真阴性指预测山洪灾害未发生,实际也未发生;假阳性指预测山洪灾害发生,而实际并未发生;假阴性指预测山洪灾害未发生,实际却发生。计算时以各种情况发生的次数表示。

采用训练数据集构造的受试者工作特征 (receiver operating characteristic, ROC) 曲线和 AUC (area under curve) 指标表征山洪灾害易发性评估模型的整体性能。当 AUC 值接近 1.0 时,说明该模型

能够正确地对山洪灾害区域进行分类;当 AUC 值接近 0.5 时,则说明该模型信息不充分,分类是偶然实现的。

3 结果与分析

3.1 初选山洪灾害影响因子多重共线性分析

对初选山洪灾害影响因子进行多重共线性分析,结果见表 1。对于每个变量,方差膨胀因子都小于多重共线性理论阈值 10,故所有变量不存在多重共线性。

表 1 多重共线性及特征重要度分析结果

Table 1 Results of multi-collinearity and characteristic importance analysis

影响因子	方差膨胀因子	特征重要度
土壤类型	1.835	55
岩性	1.042	168
距河距离	1.093	139
土地利用类型	1.082	5
TWI	4.219	312
STI	1.274	92
SPI	3.285	0
坡度	3.117	321
多年平均最大 24 h 降水量	1.078	181
人口密度	1.376	175
NDVI	2.180	251
高程	2.497	140
平面曲率	1.116	159
坡向	1.027	163

3.2 特征选择分析及结果

采用 XGBoost 算法对山洪灾害影响因子进行特征选择,结果见表 1。由表 1 可知,并非所有山洪灾害影响因子对山洪灾害易发性都具有正向作用。其中,SPI 的特征重要度计算结果为 0。从致灾机理方面考虑,海南岛台地、丘陵、山地占岛内面积的 2/3 以上,地质坚硬,水流侵蚀能力不强;从算法方面考虑,XGBoost 算法以信息增益为量化特征重要度的标准,海南岛内 SPI 空间分异特征小,对算法分类过程贡献度小,以致其特征重要度为 0。因此,在进行海南岛山洪灾害易发性评估时可将 SPI 视作非山洪灾害影响因子,在建模过程中不考虑此因素。特征重要度值较大的因子为坡度、TWI,除 SPI 外,最小值对应于土地利用类型。一般而言,陡峭的斜坡产生更快的水流,而在低海拔或平坦地区往往会发生洪水,造成洪灾,可见坡度与洪涝灾害有直接对应关系。同时海南岛内坡度的空间分异较大,对于基于信息熵减小的特征重要度计算,算法在坡度中获得的信息多,对于分析山洪灾害的贡献度也最大。TWI 用于描述地形对一个地区水分分布的影响,能够预测可能产生地表径流的区域,可直接反映地表

径流情况。TWI 与洪涝灾害具有直接对应关系,为重要的山洪灾害影响因子。基于以上分析,本研究选取坡度、TWI、NDVI、多年平均最大 24 h 降水量、岩性、坡向、平面曲率、高程、距河距离、STI、土壤类型、土地利用类型共 13 个山洪灾害影响因子进行山洪灾害易发性建模。

3.3 模型验证和对比

RL 算法训练时奖励值的变化如图 2 所示,基于 SAC 的山洪易发性训练获得的奖励值最终趋于收敛,趋近最大值 0,且收敛比较稳定,波动较小。采用训练及验证数据集绘制 3 种模型(DNN、CNN 与 RL)的 ROC 曲线,如图 3 所示。结果表明,对于训练数据集,RL 模型的 AUC 值最高,为 0.951,标准误差最低,为 0.010;CNN 模型的 AUC 值为 0.932,标准误差为 0.013;DNN 模型得到的 AUC 值为 0.911,标准误差为 0.015。从分析结果可以看出,3 种模型的 ROC 曲线值都比较合理,RL 模型评估效果最好。对于验证数据集,RL 模型的 AUC 值最高,为 0.931,标准误差最低,为 0.011;CNN 模型的 AUC 值为 0.899,标准误差为 0.020;DNN 模型的 AUC 值为 0.886,标准误差为 0.024。对于验证数据集,3 种模型的 ROC 曲线值均处于合理范围内,RL 模型评估效果最好。




图 2 训练过程奖励变化

Fig. 2 Reward changes during training process




图 4 不同模型的海南岛山洪灾害易发性分布评估结果

Fig. 4 Distribution of mountain torrent disaster vulnerability in Hainan Island obtained with different models




图 3 3 种模型的 ROC 曲线

Fig. 3 ROC curves of three models

3.4 山洪灾害易发性评估结果

海南岛山洪灾害易发性分布评估结果如图 4 所示。山洪灾害易发性以 30 m 精度的山洪灾害影响因子格点数据为输入,由训练好的模型计算所得。运用 ArcGIS 内的自然断点法以及分区统计功能,将易发性分为 5 类,即极低、低、中、高和极高,并计算面积占比。在基于 SAC 的 RL 模型计算结果中,山洪灾害易发性极低的面积占比最大,为 39.1%,山洪灾害易发性低、中等、高和极高的面积占比分别为 20.1%、27.6%、10.7% 和 2.3%;在 CNN 模型计算结果中,山洪灾害易发性极低、低、中、高、极高的面积占比分别为 27.5%、30.6%、28.7%、10.9% 和 2.3%;在 DNN 模型计算结果中,山洪灾害易发性极低、低、中、高和极高的面积占比分别为 28.3%、31.1%、28.4%、10.0% 和 2.2%。采用 RL 模型进

行山洪灾害易发性评估时,对于训练和验证数据集,AUC 值最高,标准误差最小,对山洪灾害易发性等级区分度大,评估效果最好。

4 结 论

a. 不同山洪灾害影响因子对不同区域山洪灾害易发性的作用存在差异,在建模前进行特征选择对提高机器学习效果具有重要作用。本文采用 XGBoost 算法对初选山洪灾害影响因子进行特征重要性计算,排除了山洪灾害发生特征重要度为 0 的 SPI 因子,降低了数据维度,提高了模型学习效率。

b. RL 模型具有较高的洪水易发性评估性能(AUC 值为 0.931),与 CNN 模型和 DNN 模型相比,RL 模型评估能力有较大提高,更能满足防洪减灾需要。

参考文献:

- [1] 蒋云钟,冶运涛,赵红莉,等. 水利大数据研究现状与展望[J]. 水力发电学报,2020,39(10):1-32. (JIANG Yunzhong, YE Yuntao, ZHAO Hongli, et al. Research status and prospects on water conservancy big data[J]. Journal of Hydroelectric Engineering, 2020, 39(10):1-32. (in Chinese))
- [2] HOCINI N, PAYRASTRE O, BOURGIN F, et al. Performance of automated methods for flash flood inundation mapping: a comparison of a digital terrain model(DTM) filling and two hydrodynamic methods[J]. Hydrology and Earth System Sciences,2021,25(6):2979-2995.
- [3] 俞彦,张行南,张鹏,等. 基于 SCS 模型和新安江模型的雨量预警指标综合动态阈值对比[J]. 水资源保护,2020,36(3):28-33. (YU Yan, ZHANG Xingnan, ZHANG Peng, et al. Comparison of comprehensive dynamic threshold of rainfall warning indicators based on SCS model and Xin'anjiang model[J]. Water Resources Protection,2020,36(3):28-33. (in Chinese))
- [4] 李致家,朱跃龙,刘志雨,等. 中小河流洪水防控与应急管理关键技术的思考[J]. 河海大学学报(自然科学版),2021,49(1):13-18. (LI Zhijia, ZHU Yuelong, LIU Zhiyu, et al. Thoughts on key technologies of flood prevention and emergency management in small and medium-sized rivers [J]. Journal of Hohai University (Natural Sciences), 2021, 49(1):13-18. (in Chinese))
- [5] 冯文强,徐奎,郭祺忠,等. 城市内涝风险区划集成模型及其敏感性研究[J]. 水力发电学报,2021,40(5):56-67. (FENG Wenqiang, XU Kui, GUO Qizhong, et al. Integrated model and sensitivity analysis of urban waterlogging risk zoning [J]. Journal of Hydroelectric Engineering, 2021, 40(5):56-67. (in Chinese))
- [6] 马勇,顾正华,王庭辉,等. 基于 SWMM 的山丘城区防洪排涝能力分析[J]. 河海大学学报(自然科学版),2021,49(6):499-505. (MA Yong, GU Zhenghua, WANG Tinghui, et al. Analysis of flood control and drainage capacity of hilly city based on SWMM [J]. Journal of Hohai University (Natural Sciences), 2021, 49(6):499-505. (in Chinese))
- [7] FORTIN J P, TURCOTTE R, MASSICOTTE S, et al. Distributed watershed model compatible with remote sensing and GIS data: I. description of model [J]. Journal of Hydrologic Engineering, 2001, 6(2):91-99.
- [8] 刘志雨,刘玉环,孔祥意. 中小河流洪水预报预警问题与对策及关键技术应用[J]. 河海大学学报(自然科学版),2021,49(1):1-6. (LIU Zhiyu, LIU Yuhuan, KONG Xiangyi. Problems, strategies and key technology research of flood forecasting and early warning for small and medium-sized rivers [J]. Journal of Hohai University (Natural Sciences), 2021, 49(1):1-6. (in Chinese))
- [9] 王波,黄津辉,郭宏伟,等. 基于遥感的内陆水体水质监测研究进展[J]. 水资源保护,2022,38(3):117-124. (WANG Bo, HUANG Jinhui, GUO Hongwei, et al. Progress in research on inland water quality monitoring based on remote sensing [J]. Water Resources Protection, 2022, 38(3):117-124. (in Chinese))
- [10] 万定生,王坤,朱跃龙,等. 中小河流洪水预报智能调度平台关键技术[J]. 河海大学学报(自然科学版),2021,49(3):204-212. (WAN Dingsheng, WANG Kun, ZHU Yuelong, et al. Key technologies of intelligent flood forecasting and dispatching platform for small and medium-sized basins [J]. Journal of Hohai University (Natural Sciences), 2021, 49(3):204-212. (in Chinese))
- [11] NGO P T T, PANAH 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.
- [12] BUI D T, NGO P T T, PHAM T D, et al. A novel hybrid approach based on a swarm intelligence optimized extreme learning machine for flash flood susceptibility mapping [J]. Catena, 2019, 179:184-196.
- [13] CHEN Lu, SUN Na, ZHOU Chao, et al. Flood forecasting based on an improved extreme learning machine model combined with the backtracking search optimization algorithm [J]. Water, 2018, 10(10):1362.
- [14] 王晓昌,吴璠,孙彦赞,等. 基于深度强化学习的车联网资源管理[J]. 工业控制计算机,2021,34(9):31-33. (WANG Xiaochang, WU Fan, SUN Yanzan, et al. Internet of vehicles resource management based on deep reinforcement learning [J]. Industrial Control Computer, 2021, 34(9):31-33. (in Chinese))
- [15] 舒凌洲,吴佳,王晨. 基于深度强化学习的城市交通信

- 号控制算法[J]. 计算机应用,2019,39(5):1495-1499. (SHU Lingzhou, WU Jia, WANG Chen. Urban traffic signal control based on deep reinforcement learning[J]. Journal of Computer Applications, 2019, 39(5): 1495-1499. (in Chinese))
 - [16] TURPIN D L. Aging gracefully: your *American Journal of Orthodontics & Dentofacial Orthopedics*, 1915 to 2015[J]. *American Journal of Orthodontics & Dentofacial Orthopedics*, 2014, 145(3): 271-272.
 - [17] 王丽,王涛,肖巍,等. XGBoost 启发的双向特征选择算法[J]. 吉林大学学报(理学版), 2021, 59(3): 627-634. (WANG Li, WANG Tao, XIAO Wei, et al. Bidirectional feature selection algorithm inspired by XGBoost[J]. Journal of Jilin University (Science Edition), 2021, 59(3): 627-634. (in Chinese))
 - [18] XI Bao, WANG Rui, CAI Yinghao, et al. A novel heterogeneous actor-critic algorithm with recent emphasizing replay memory[J]. *International Journal of Automation and Computing*, 2021, 18(4): 619-631. (收稿日期:2022-02-27 编辑:施业)
- +++++
- (上接第 58 页)
- [24] 刘永佳,黄生志,方伟,等. 不同季节气象干旱向水文干旱的传播及其动态变化[J]. 水利学报, 2021, 52(1): 93-102. (LIU Yongjia, HUANG Shengzhi, FANG Wei, et al. Propagation and dynamic change of meteorological drought to hydrological drought in different seasons[J]. Journal of Hydraulic Engineering, 2021, 52(1): 93-102. (in Chinese))
 - [25] SHEFFIELD J, WOOD E F. Characteristics of global and regional drought, 1950-2000: analysis of soil moisture data from off-line simulation of the terrestrial hydrologic cycle[J]. *Journal of Geophysical Research: Atmospheres*, 2007, 112(D17): 115.
 - [26] 吴喜之,王兆军. 非参数统计方法[M]. 北京:高等教育出版社,1996.
 - [27] AKAINKE H. Information theory and an extension of the maximum likelihood principle[C]// *Proceedings of the International Symposium on Information Theory. Akademia Kiado: Budapest*, 1973
 - [28] GRINGORTEN I I. A plotting rule for extreme probability paper[J]. *Journal of Geophysical Research*, 1963, 68(3): 813-814.
 - [29] WEI W, ZHANG J, ZHOU L, et al. Comparative evaluation of drought indices for monitoring drought based on remote sensing data[J]. *Environmental Science and Pollution Research*, 2021, 28(16): 20408-20425.
 - [30] 王晓峰,张园,冯晓明,等. 基于游程理论和 Copula 函数的干旱特征分析及应用[J]. 农业工程学报, 2017, 33(10): 206-214. (WANG Xiaofeng, ZHANG Yuan, FENG Xiaoming, et al. Analysis and application of drought characteristics based on run theory and Copula function[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2017, 33(10): 206-214. (in Chinese))
 - [31] 王丹云,吕世华,韩博,等. 黄土高原春季植被变化分布与变化特征及其对春旱的响应研究[J]. 高原气象, 2018, 37(5): 1208-1219. (WANG Danyun, LYU Shihua, HAN Bo, et al. The characteristics of spring vegetation cover and its response to spring drought over the Loess plateau[J]. *Plateau Meteorology*, 2018, 37(5): 1208-1219. (in Chinese))
 - [32] LIU Q, YANG Z, HAN F, et al. NDVI-based vegetation dynamics and their response to recent climate change: a case study in the Tianshan mountains, China[J]. *Environmental Earth Sciences*, 2016, 75(16): 1189.
 - [33] 马琼,张勃,王东,等. 1960-2012 年甘肃黄土高原干旱时空变化特征分析: 基于标准化降水蒸散指数[J]. 资源科学, 2014, 36(9): 1834-1841. (MA Qiong, ZHANG Bo, WANG Dong, et al. The temporal and spatial distribution of drought on the Loess plateau based on the standardized precipitation evapotranspiration Index from 1960 to 2012[J]. *Resources Science*, 2014, 36(9): 1834-1841. (in Chinese))
 - [34] FANG Y, QIAN H, CHEN J, et al. Characteristics of spatial-temporal evolution of meteorological drought in the Ningxia Hui autonomous region of Northwest China[J]. *Water*, 2018, 10(8): 1-22.
 - [35] WANG Y, KONG Y, CHEN H, et al. Spatial-temporal characteristics of drought detected from meteorological data with high resolution in Shaanxi Province, China[J]. *Journal of Arid Land*, 2020, 12(4): 561-579.
 - [36] 邵志忠,董安详,王鹏祥,等. 中国气象灾害大典·甘肃卷[M]. 北京:气象出版社,2004.
 - [37] 夏普明,尚永生,梁旭,等. 中国气象灾害大典·宁夏卷[M]. 北京:气象出版社,2007.
 - [38] 王莘,张国胜,李锡福,等. 中国气象灾害大典·青海卷[M]. 北京:气象出版社,2007.
 - [39] 崔讲学,翟佑安,李长安,等. 中国气象灾害大典·陕西卷[M]. 北京:气象出版社,2005.
 - [40] 史玉光,任宜勇,陈洪武,等. 中国气象灾害大典·新疆卷[M]. 北京:气象出版社,2006. (收稿日期:2022-04-03 编辑:王芳)