

基于深度学习的四川省洪涝灾害损失预测模型

陈 曜¹, 张 杰¹, 黄伟军²

¹四川省水文水资源勘测中心, 四川 成都

²成都大学建筑与土木工程学院, 四川 成都

收稿日期: 2025年12月19日; 录用日期: 2026年2月11日; 发布日期: 2026年4月30日

摘 要

现有数据驱动的洪涝灾害损失模型普遍存在模型透明度不足和物理可解释性有限的问题, 洪涝灾害损失指标与气象因子均表现出明显的时间序列特性。本文提出一种融合注意力机制-卷积神经网络(CNN)-长短期记忆网络(LSTM)的深度学习预测模型, 用于四川省洪涝灾害损失预测。模型首先利用CNN提取多源气象因子及灾损序列的局部动态特征, 再通过LSTM捕捉长期时序依赖关系, 并引入注意力机制增强关键特征的贡献度, 从而提高模型对非线性、非平稳灾损序列的刻画能力。基于1950~2020年四川省气象与灾损数据进行验证, 结果表明在使用筛选出的9个强相关影响因子时, 该模型在经济损失比与人口损失比上的平均MAPE相比单LSTM模型降低约10.5%, 相比SVM模型降低约21.2%, 预测精度显著提升。

关键词

注意力机制, 长短期记忆网络(LSTM), 卷积神经网络(CNN), 多变量时间序列预测, 洪灾损失预测

Deep Learning-Based Prediction Model for Flood Disaster Loss in Sichuan Province

Yao Chen¹, Jie Zhang¹, Weijun Huang²

¹Sichuan Hydrology and Water Resources Survey Center, Chengdu Sichuan

²College of Architecture and Civil Engineering, Chengdu University, Chengdu Sichuan

Received: December 19, 2025; accepted: February 11, 2026; published: April 30, 2026

Abstract

Existing data-driven flood loss prediction models often suffer from limited transparency and insufficient physical interpretability. Flood-related damage indicators and meteorological factors exhibit strong temporal patterns. To address these issues, this study proposes a deep learning model that integrates an

作者简介: 陈曜(1973-), 男, 四川冕宁人, 博士, 高级工程师, 研究方向为水文水资源、水土保持和灾害防治, Email: 847144691@qq.com

文章引用: 陈曜, 张杰, 黄伟军. 基于深度学习的四川省洪涝灾害损失预测模型[J]. 水资源研究, 2026, 15(2): 151-159.

DOI: 10.12677/jwrr.2026.152018

attention mechanism, Convolutional Neural Network (CNN), and Long Short-Term Memory (LSTM) network for predicting flood losses in Sichuan Province. The CNN module extracts multidimensional dynamic features from meteorological factors and disaster loss sequences, and the LSTM component captures long-term temporal dependencies, while the attention mechanism further enhances informative features by adaptively learning their importance. Experiments using meteorological and disaster data from 1950 to 2020 show that, when using nine strongly correlated meteorological predictors, the proposed model reduces the mean absolute percentage error (MAPE) of economic and population loss ratios by approximately 10.5% compared with the single-LSTM model and by about 21.2% compared with the SVM model, demonstrating significantly improved prediction performance.

Keywords

Attention Mechanism, Long Short-Term Memory Network (LSTM), Convolutional Neural Network (CNN), Multivariate Time Series Prediction, Flood Damage Prediction

Copyright © 2026 by author(s) and Wuhan University & Bureau of Hydrology, Changjiang Water Resources Commission. This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

洪涝灾害是全球范围内发生频率最高、影响范围最广的自然灾害之一，造成的人员伤亡和经济损失长期居高不下。随着气候变化和人类活动强度的增加，极端降雨事件呈现出更强的不确定性和区域差异性，使得洪涝灾害损失的定量预测成为水文科学、灾害风险管理和应急决策中的核心科学问题之一。如何在有限观测条件下，准确刻画致灾因子与损失结果之间的复杂非线性关系，是当前研究面临的关键挑战[1] [2]。

在洪涝灾害预测研究中，传统方法主要基于过程驱动模型，通过构建降雨 - 径流 - 淹没 - 损失的物理过程链条，对灾害形成机理进行模拟。这类模型具有明确的物理意义，在小尺度流域或资料完备区域中具有较强的解释能力。然而，随着模型由集中式向分布式发展，对高时空分辨率气象、水文和地形数据的依赖不断增强，模型结构与参数标定愈发复杂，计算成本显著提高，而预测精度的提升却并不总是成正比。此外，在地形复杂、气候条件多变、社会经济差异显著的区域，过程驱动模型往往面临可移植性和稳定性不足的问题[3]-[5]。

随着水利信息化和遥感技术的发展，大规模气象、水文与社会经济数据的可获得性显著提升，数据驱动方法逐渐成为洪涝灾害损失预测的重要补充。支持向量机、决策树、神经网络等模型能够在不显式刻画物理过程的情况下，从历史样本中自动学习致灾因子与损失之间的映射关系，具有建模灵活、计算效率高的优势。已有研究表明，这类方法在区域尺度灾害损失预测中具备较好的应用潜力[6]-[9]。然而，现有数据驱动研究仍普遍存在以下不足：一是模型结构和特征选择往往依赖经验，缺乏针对区域灾害特征的系统比较；二是对时间依赖性和多尺度信息的刻画能力有限，难以充分利用长时间序列气象数据；三是不同模型在复杂地理与气候背景下的适应性尚缺乏统一评估框架。

四川省地形起伏大、河网密集、降水时空分布高度不均，是中国洪涝灾害最为频发和严重的地区之一。历史统计表明，该区域洪涝灾害发生频率高、受灾范围广、损失规模大，具有显著的代表性和研究价值，将四川省作为研究对象，有助于检验不同数据驱动模型在高复杂度区域洪涝灾害损失预测中的适用性和稳定性。

本文不对洪涝灾害内部物理机理的严格建模，而是以多源气象因子和历史真实灾害损失数据为基础，构建经验型预测模型。通过多种数据预处理与特征构建方法，分别采用单一长短期记忆网络(LSTM)、支持向量机(SVM)以及引入注意力机制的 LSTM-CNN 组合模型，对四川省洪涝灾害直接经济损失进行训练与预测，旨在系统比较不同模型对洪涝灾害损失时序特征和非线性关系的刻画能力，筛选出最符合四川省灾害特征的预测方法，

为区域洪涝灾害风险评估与应急资源配置提供科学依据，同时为类似复杂区域的灾害损失预测研究提供参考。

2. 研究方法

2.1. 洪涝灾害影响因子分析

前期研究通过双指标法从 132 个气象因子中筛选出了一组影响洪涝灾害的强相关因子[10]。表征洪涝灾害损失的定量方法方式较多，各区域差异较大，文中选择“受灾人数”和“直接经济损失”做为衡量标准。受灾人数是指在洪涝灾害中受到直接威胁和影响的人口数量，洪涝灾害可能导致人员伤亡、失踪、被迫疏散等情况，因此关注受灾人口可以帮助评估灾害对人们生命安全的影响。直接经济损失是衡量灾害对经济发展的影响和破坏程度的重要指标之一，通过评估直接经济损失，可以了解灾害对生产力、就业、经济增长等方面的影响，有助于制定恢复和重建的经济计划。此外，受灾人数和经济损失通常是洪涝灾害损失统计中较容易获取和量化的指标，政府部门往往会收集和记录受灾人口和直接经济损失的数据，使得它们在跨地区和跨时间的比较中具有一定的可比性，其数据也相对稳定和可靠，有利于对洪涝灾害风险和损失的长期分析和研究。

洪涝灾害的影响是多方面的，包括社会、环境、基础设施等多个层面，选择受灾人数和直接经济损失作为衡量标准并不意味着忽视其他方面的影响，而是考虑到它们的重要性、可获得性和可比性，以便更有效地评估洪涝灾害的风险和损失。

首先根据 1950~2020 年四川省洪灾实测统计数据，选择全省受灾人口、直接经济损失为灾害因子，将(受灾人数)/(当年社会人口总数)称为人口损失比，(直接经济损失)/(当年国民生产总值)称为经济损失比，将以上两个比值作为洪灾中评价受灾人口和经济损失的变量，之后将 132 个气候监测指数(气象因子)进行数据归一化计算。

在对数据进行初步处理后，根据皮尔逊相关性分析法和 HDBSCAN 聚类法，用双重指标对同月、相差三个月和相差六个月的 132 个气候监测指数进行分析，取两种方法得出的均为洪涝灾害相关因子的气象因子为影响洪涝灾害的强相关因子，南亚高压指数、副热带印度洋偶极子指数、太阳黑子指数、北非副热带高强度指数、北半球副热带高强度指数、北美-大西洋副热带高压区域指数、西太平洋副热带高压指数、北美副热带高面积指数、北非副热带高面积指数等 9 个气象因子对四川洪灾的范围和强度均具有较强的影响，为影响洪涝灾害强相关因子。

2.2. 基于深度学习模型预测洪涝灾害损失

基于筛选出的 9 个洪涝灾害强相关因子和 2 个洪涝灾害指标进行实验，将 1950~2017 年共 802 个月的数据作为训练集，将 2018~2020 年间的 36 个月的数据作为验证集，对洪涝灾害损失进行预测。

3. 模型构建与方法

3.1. 模型设计思路与总体框架

洪涝灾害损失演化具有多因子驱动、强非线性及显著时间依赖性特征，单一模型难以同时刻画局部波动与长期演变规律。为此，本文提出一种基于 CNN-LSTM-Attention 的数据驱动预测框架，通过模块化耦合实现多尺度特征提取与时序依赖建模。

模型总体思路包括：

- 1) CNN 模块用于对多维气象因子及历史灾损数据进行局部特征提取，刻画短期波动与变量组合模式[11][12]；
- 2) LSTM 模块对 CNN 提取的特征序列进行建模，捕捉灾害演变过程中的长期依赖关系[13][14]；
- 3) 注意力机制作用于 LSTM 输出层，对不同时间步的重要性进行自适应加权，突出关键阶段信息[15]-[17]。

3.2. CNN 特征提取模块

设输入为长度为 n 的多变量时间序列： $X = [x_1, x_2, \dots, x_t, \dots, x_n]^T$ ，其中 x_t 表示第 t 个时间步的多维特征向量。

CNN 模块由两层一维卷积与最大池化构成，其卷积操作定义为： $C_k = R_eLU(X \otimes W_k + b_k)$ ，其中 \otimes 表示一维卷积运算， W_k 和 b_k 分别为第 k 层卷积核权重与偏置。

池化层采用最大池化方式，对卷积特征进行降维与聚合： $P_k = \max(C_k)$ 。

经全连接层映射后，得到每个时间步的深层特征表示： $h_t^c = R_eLU(P_2W_c + b_c)$ 。

CNN 输出的特征序列表示为： $H^t = [h_1^c, h_2^c, \dots, h_t^c, \dots, h_n^c]^T$ 。

3.3. LSTM 时序依赖建模

LSTM 网络用于对 CNN 输出的特征序列 H^t 进行建模，以刻画洪涝灾害损失在更长时间尺度上的演变规律。其核心更新过程由遗忘门、输入门和输出门组成，计算公式如下：

遗忘门： $f_t = \sigma(W_f[h_{t-1}, x_t] + b_f)$ ；

输入门： $i_t = \sigma(W_i[h_{t-1}, x_t] + b_i)$ ；

候选记忆单元： $\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c)$ ；

细胞状态更新： $C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t$ ；

输出门： $o_t = \sigma(W_o[h_{t-1}, x_t] + b_o)$ ；

隐状态输出： $h_t = o_t \odot \tanh(C_t)$ ；

其中 $\sigma(\cdot)$ 表示 Sigmoid 激活函数， \odot 为逐元素乘法。

3.4. 时间注意力机制与模型耦合

为突出不同时间步对预测结果的重要性，在 LSTM 输出层引入加性时间注意力机制。设 LSTM 在各时间步的隐状态为 $\{h_t\}$ ，则注意力相关性得分定义为： $e_t = v^T \tanh(W_a h_t + b_a)$ ；

注意力权重通过 softmax 函数归一化： $a_t = \exp(e_t) / \sum_{j=1}^n \exp(e_j)$ ；

最终得到上下文向量： $s = \sum_{t=1}^n a_t h_t$ 。

3.5. 模型输出与训练设置

上下文向量 s 经输出层映射得到洪涝灾害损失预测值： $\hat{y} = W_{os} + b_o$ ；

模型训练采用 Adam 或 AdamW 优化器，性能评价指标采用平均绝对百分比误差(MAPE)：

$$MAPE = \frac{1}{n} \sum_{i=1}^n |(\hat{y}_i - y_i) / y_i| \times 100\%。$$

4. 实例分析

4.1. 数据来源

各月气象数据来源于省气象中心；各月降水数据，因洪涝灾害造成的受灾人口及直接经济损失数据来源于四川省人民政府防汛抗旱指挥部办公室的《洪涝灾害年度损失统计资料》(1950~2020)；人口以及国民生产总值数据来源于《四川省统计年鉴》(1950~2020)。

4.2. 实验预测结果分析

基于归一化处理的 1950~2020 年间 9 个影响洪涝灾害强相关因子和 2 个洪涝灾害指标进行实验，将 1950~2017 年，共 802 个月的数据作为训练集，将 2018~2020 年间的 36 个月的数据作为验证集。

为了更好地验证所提出模型的有效性，基于 2018~2020 年间共计 36 个月的洪涝灾害数据，分别使用单 LSTM

模型、支持向量机(support vector machine, SVM)模型[16]和基于注意力机制的 LSTM-CNN 模型进行预测, 以上三种模型的预测结果如图 1 所示。

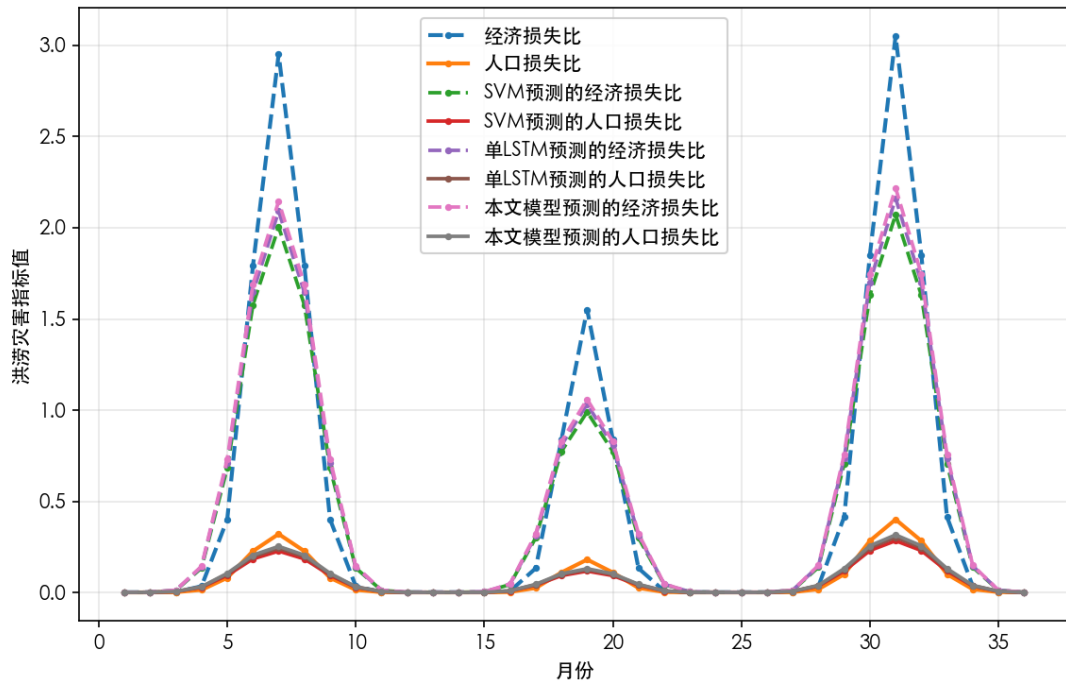


图 1. 基于 9 个强相关影响因子和三种模型预测的 2018~2020 年的洪涝灾害损失指标

另外, 由于国内气象部门多使用西太平洋副热带高压指数、东亚季风监测指数、南亚高压特征参数和太阳黑子指数等因子对洪涝灾害进行长期预测, 为对比以上 4 个常规预测因子和前期筛选的 9 个强相关影响因子对洪涝灾害损失的预测效果, 基于 1950~2020 年间 4 个常规预测因子和 2 个洪涝灾害指标再次进行实验。同样地, 将 1950~2017 年间的 802 个月的数据作为训练集, 将 2018~2020 年间的 36 个月的数据作为验证集, 最后得到的预测结果如图 2 所示。




图 2. 基于 4 个常规预测因子和三种模型预测的 2018~2020 年的洪涝灾害损失指标

基于以上三种模型预测的 2018~2020 年间的洪涝灾害指标的平均绝对百分比误差(MAPE 值)如表 1 所示。为了进一步分析气象因子数量对模型训练和预测效果的影响,扩充了部分影响因子。在原先筛选出的 9 个强相关因子的基础上,加入了其他研究得出的 6 个影响因子,形成了总共 15 个影响因子的组合。9 个强相关因子包括北非副热带高面积指数、北美副热带高面积指数、西太平洋副热带高压指数、北美-大西洋副热带高压区域指数、北半球副热带高强度指数、北非副热带高强度指数、太阳黑子指数、副热带印度洋偶极子指数和南亚高压指数,另外四个常规因子(北非副热带高面积指数、北美副热带高面积指数、西太平洋副热带高压指数、北美-大西洋副热带高压区域指数)已包含在这 9 个强相关因子中。最终的 15 个因子包括上述 9 个强相关因子以及北非-北大西洋-北美-副热带高压指数、青藏高原积雪指数、北美副热带高强度指数、东亚副热带季风指数、北大西洋副热带高强度指数和北美-北大西洋副热带高强度指数。结果如表 1 所示。

表 1. 使用两类相关因子与三种模型预测洪涝灾害损失指标结果平均绝对百分比误差

模型	洪涝灾害损失指标	基于 9 个强相关因子	基于 4 个常规因子	基于 15 个影响因子
SVM	经济损失比	31.70	34.60	31.84
	人口损失比	46.57	58.83	47.66
单 LSTM	经济损失比	25.20	28.66	25.08
	人口损失比	31.82	40.90	45.38
注意力机制模型	经济损失比	16.25	20.33	16.83
	人口损失比	19.68	33.68	19.98

为了进一步分析不同气象因子对洪水预测模型的影响进行了消融实验。如图 3 所示,实验逐个去除不同的气象因子,观察去除每个因子后模型在测试集上的表现变化。图 3 中展示了各个因子去除后对测试损失的百分比变化。正值表示去除该因子后模型性能有所提升,而负值则表明去除该因子后模型性能下降。实验结果表明,




图 3. 四川省洪涝灾害预测模型关键因子消融影响分析

一些因子的去除对模型预测效果有显著影响,特别是与热带高压相关的因子(如北美副热带高压指数和北非副热带高压指数),其去除后对模型的损失变化较为明显,显示这些因子在洪水预测模型中起着重要作用。去除北非副热带高压指数后,模型损失的百分比变化最大,达到了-0.33%,而去除南亚高压指数后,模型损失的百分比变化最小,仅为0.03%。此外,去除其他一些因子,如太阳黑子指数和副热带印度洋偶极子指数,虽然会导致模型性能有所下降,但变化幅度相对较小,分别为-0.06%和-0.15%,表明部分气象因子对洪水预测模型的贡献较大,尤其是与热带高压、海温和季风等相关的因子。

5. 讨论

四川省地形地貌复杂,盆地与高山峡谷并存,降水时空分布不均,受季风、水汽输送及复杂下垫面共同影响,洪涝灾害具有季节性强、突发性强、空间差异显著等特点。在防灾减灾实践中,灾害损失指标往往在汛期呈现快速上升、非线性波动明显的变化规律,难以用传统“平稳增长”假设进行刻画。因此,针对四川省洪涝灾害损失指标的预测不仅需要关注模型误差大小,更应结合本地区灾害特征与防控需求,对预测结果的可解释性与应用价值进行讨论。

图1表明在2018~2020年洪涝灾害损失指标预测中,相较于SVM模型和单LSTM模型,本文提出的基于注意力机制的LSTM-CNN模型在经济损失比与人口损失比两项指标上整体拟合更贴近真实变化过程。四川省洪涝灾害损失指标在年内变化具有明显的“汛期峰值”特征,且峰值出现时常伴随短时强降雨、山洪、泥石流及城市内涝等复合灾害链效应,使得损失序列呈现显著的非线性与非平稳性。本文模型通过CNN层对输入序列进行局部特征提取,可在一定程度上增强对突发变化的识别能力,并抑制噪声干扰;同时引入软性注意力机制对不同时间步输入赋予差异化权重,使模型能够更关注对灾害损失形成具有更强指示意义的关键阶段,从而提升预测精度。

值得注意的是,图1中预测序列相对于真实值仍存在一定程度的“滞后”现象,这一现象在灾害损失指标的预测中具有普遍性,其根本原因在于经济损失比与人口损失比均为典型的非线性非平稳序列。当预测步长为 n 时,模型对 x_t 的预测主要依赖 $\{x_{t-n+1}, \dots, x_{t-1}\}$ 的历史信息;若在 t 附近发生由强降雨或突发灾害过程触发的非线性转折(例如损失指标快速下降或快速回落),仅依赖过去窗口信息的模型可能难以及时捕捉到突变后的下降趋势,从而表现为预测峰值或拐点的滞后。考虑到四川省洪涝灾害具有“短历时、强突发”的特征,本文在模型构建中引入更多维度的影响因子以增强对灾害过程变化的感知能力,从而尽量降低滞后效应对预测结果的影响。

为进一步量化不同模型的综合预测效果,本文将洪涝灾害损失指标的MAPE定义为经济损失比MAPE与人口损失比MAPE的均值。结果表明,在2018~2022年期间,本文模型的MAPE相较于SVM模型与单LSTM模型分别降低了21.17%和10.545%。这说明在四川省洪涝灾害损失指标预测任务中,本文提出的LSTM-CNN模型在整体误差控制方面具有更强优势,能够更稳定地刻画灾害损失随时间变化的主要趋势。

从图2、图3及表1可以看出,相较于使用常规因子进行预测,采用筛选得到的9个强影响因子后,三种模型的预测MAPE均有所降低,说明强影响因子能够更有效地反映四川省洪涝灾害损失变化的驱动机制。该结果对于灾害防控具有实际意义:强影响因子可作为监测与预警体系中的关键输入变量,为汛期风险研判提供更具针对性的依据。进一步地,当在9个强影响因子的基础上叠加其他研究中常用的影响因子(共15个)进行训练与预测时,预测结果与仅使用9个强影响因子的差异不大,表明本文筛选出的强影响因子具有较高的信息密度与代表性。这一结论提示,在四川省洪涝灾害风险预测与业务化应用中,适度精简输入变量不仅有助于降低模型复杂度与数据采集成本,也有利于提升模型部署的稳定性与可推广性。

总体而言,本文从时间序列数据与多维影响因子之间的隐含关联出发,构建了面向四川省洪涝灾害损失指标预测的机器学习方法。该方法不依赖对灾害成因机理的完全刻画,而是通过数据驱动方式实现对灾害损失变

化的有效预测,具有可行性与实用性。对四川省洪涝灾害防控而言,该预测结果可为汛期重点时段风险提示、应急资源预置、重点区域防御部署提供参考,具有一定的应用价值。

6. 结语

本文面向四川省洪涝灾害损失指标具有非线性、非平稳、汛期突发波动显著等特点,构建了基于注意力机制的 LSTM-CNN 预测模型,从时间序列自身及多维气象因子信息出发挖掘灾害损失变化规律,并与气象水文领域常用的长短期记忆网络(long short-term memory, LSTM)和支持向量机(support vector machine, SVM)模型进行了对比分析。结果表明,本文提出的影响因子筛选方法能够有效提取与四川省洪涝灾害损失变化密切相关的强影响因子,结合注意力机制的 LSTM-CNN 模型在经济损失比与人口损失比预测中表现出更高的精度与更好的趋势跟踪能力,具有一定的应用价值。

从防灾减灾实践角度来看,四川省地形复杂、降水时空分布不均,洪涝灾害易在汛期集中发生并呈现快速增强与突变特征。本文方法能够在一定程度上提高对损失指标峰值阶段及关键转折过程的识别能力,为汛期风险研判、应急资源预置与重点区域防控部署提供数据支撑和辅助决策依据。因此,该研究不仅在方法层面验证了深度学习模型在灾害损失预测中的可行性,也为四川省洪涝灾害风险管理提供了可参考的技术路线。

需要指出的是,洪涝灾害损失指标通常以月尺度统计,且可用样本量仅有 800 余月,就机器学习建模而言样本规模仍相对有限,模型预测精度与泛化能力仍存在提升空间。未来研究可从以下方面进一步完善:一是持续积累更长时间跨度的样本数据,并结合更高时间分辨率的降雨与水文过程信息,提高对突发性灾害过程的刻画能力;二是优化模型输入输出策略(如多步预测、动态窗口或滚动更新机制),减轻非平稳序列引起的滞后效应;三是结合四川省不同地形区(盆地、丘陵、山地)灾害差异开展分区建模与对比分析,以提升模型在区域防控中的适用性与可解释性。通过上述改进,有望进一步降低预测误差并增强模型在实际业务场景中的推广应用能力。

基金项目

高原与盆地暴雨旱涝灾害四川省重点实验室开放研究基金项目“基于高原与盆地气象因子的四川省洪旱灾害损失长期预报研究”(SZKT201908)。

参考文献

- [1] ROZALIS, S., MORIN, E., YAIR, Y. and PRICE, C. Flash flood prediction using an uncalibrated hydrological model and radar rainfall data in a Mediterranean watershed under changing hydrological conditions. *Journal of Hydrology*, 2010, 394(1-2): 245-255. <https://doi.org/10.1016/j.jhydrol.2010.03.021>
- [2] 刘自强. 黄河下游洪水灾害损失预估研究[D]: [硕士学位论文]. 乌鲁木齐: 新疆师范大学, 2005.
- [3] 王腊春, 周寅康, 许有鹏, 付重林, 许定庆. 太湖流域洪涝灾害损失模拟及预测[J]. *自然灾害学报*, 2000(1): 33-39.
- [4] AHMAD, N., HUSSAIN, M., RIAZ, N., SUBHANI, F., HAIDER, S., ALAMGIR, K. S. and SHINWARI, F. Flood prediction and disaster risk analysis using GIS based wireless sensor networks, a review. *Journal of Basic and Applied Scientific Research*, 2013, 3(8): 632-643.
- [5] 李谢辉, 韩荟芬. 河南省黄河中下游地区洪灾损失评估与预测[J]. *灾害学*, 2014, 29(1): 87-92.
- [6] 王平, 黄河, 吴玮. 基于支持向量机的湖北省洪涝农业损失预测模型[J]. *湖北农业科学*, 2014, 53(18): 4437-4440.
- [7] 龚艳冰, 向林, 刘高峰. 基于高斯过程回归模型的洪涝灾害损失预测研究——以重庆市为例[J]. *长江流域资源与环境*, 2019, 28(6): 1502-1510.
- [8] 吉中会, 李宁, 吴吉东, 等. 区域洪涝灾害损失评估及预测的 CART 模型研究——以湖南省为例[J]. *地域研究与开发*, 2012, 31(6): 106-110+144.
- [9] 喻寅昀, 田云, 王昶, 许可. 洪水灾害经济损失的预测研究[J]. *沈阳理工大学学报*, 2016, 35(2): 85-89.
- [10] 陈民瑞, 黄伟军. 影响四川省洪灾损失的气象因子分析[J]. *东北水利水电*, 2022, 40(12): 46-50.
- [11] SIMONYAN, K., ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. 2014.

- [12] Nair, V., Hinton, G. E. Rectified linear units improve restricted boltzmann machines. In Proceedings of the 27th International Conference on International Conference on Machine Learning. ACM, Inc., 2010: 807-814.
- [13] HOCHREITER, S., SCHMIDHUBER, J. Long short-term memory. *Neural Computation*, 1997, 9(8): 1735-1780.
<https://doi.org/10.1162/neco.1997.9.8.1735>
- [14] GREFF, K., SRIVASTAVA, R. K., KOUTNÍK, J., STEUNEBRINK, B. R. and SCHMIDHUBER, J. LSTM: A search space odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 28(10): 2222-2232.
<https://doi.org/10.1109/tnnls.2016.2582924>
- [15] NIU, Z., ZHONG, G. and YU, H. A review on the attention mechanism of deep learning. *Neurocomputing*, 2021, 452: 48-62.
<https://doi.org/10.1016/j.neucom.2021.03.091>
- [16] NOBLE, W. S. What is a support vector machine? *Nature Biotechnology*, 2006, 24(12): 1565-1567.
<https://doi.org/10.1038/nbt1206-1565>
- [17] ZHANG, Z., LI, M., LIN, X., WANG, Y. and HE, F. Multistep speed prediction on traffic networks: A deep learning approach considering spatio-temporal dependencies. *Transportation Research Part C: Emerging Technologies*, 2019, 105: 297-322.
<https://doi.org/10.1016/j.trc.2019.05.039>