



机器学习桥接城市内涝与气候风险:研究进展与展望

齐小刚, 张旭, 李家慧

引用本文:

齐小刚, 张旭, 李家慧. 机器学习桥接城市内涝与气候风险:研究进展与展望[J]. 智能系统学报, 2026, 21(5): 1106–1129.

QI Xiaogang, ZHANG Xu, LI Jiahui. Machine learning bridging urban waterlogging and climate risk: a review and outlook[J]. CAAI transactions on intelligent systems, 2026, 21(5): 1106–1129.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202511003>

您可能感兴趣的其他文章

系统故障因果关系分析的智能驱动方式研究

Intelligent analysis of system fault data and fault causal relationship

智能系统学报. 2021, 16(1): 92–97 <https://dx.doi.org/10.11992/tis.202003001>

弱标记不完备决策系统的增量式属性约简算法

An incremental attribute reduction algorithm for incomplete decision system with weak labeling

智能系统学报. 2020, 15(6): 1079–1090 <https://dx.doi.org/10.11992/tis.202001017>

可能性匹配知识迁移原型聚类算法

Possibility–matching based knowledge transfer prototype clustering algorithm

智能系统学报. 2020, 15(5): 978–989 <https://dx.doi.org/10.11992/tis.201810028>

结合度量融合和地标表示的自编码谱聚类算法

An autoencoder–based spectral clustering algorithm combined with metric fusion and landmark representation

智能系统学报. 2020, 15(4): 687–696 <https://dx.doi.org/10.11992/tis.201911039>

加权PageRank改进地标表示的自编码谱聚类算法

An autoencoder spectral clustering algorithm for improving landmark representation by weighted PageRank

智能系统学报. 2020, 15(2): 302–309 <https://dx.doi.org/10.11992/tis.201904021>

基于模糊不一致对的多标记属性约简

Multi–label attribute reduction based on fuzzy inconsistency pairs

智能系统学报. 2020, 15(2): 374–385 <https://dx.doi.org/10.11992/tis.201905046>

DOI: 10.11992/tis.202511003

网络出版地址: <https://link.cnki.net/urlid/23.1538.tp.20260708.1009.004>

机器学习桥接城市内涝与气候风险: 研究进展与展望

齐小刚^{1,2}, 张旭¹, 李家慧^{1,2}

(1. 西安电子科技大学 数学与统计学院, 陕西 西安 710071; 2. 西安市信息网络优化与数学方法重点实验室, 陕西 西安 710071)

摘要: 气候变化和城市化进程共同导致了极端天气事件频发, 城市内涝风险日益严峻, 传统方法却难以应对气候科学与城市内涝之间的割裂。本文通过系统综述与批判性分析现有文献, 首次总结提炼出机器学习作为连接两大领域的 3 种核心“桥梁”模式: 多尺度数据同化与特征转换的桥梁、物理机理与数据驱动融合的建模桥梁、不确定性量化与风险传递的评估桥梁。首先剖析了两者的耦合机制及关键挑战; 继而综述了支撑桥梁模式的关键技术; 并通过具体案例阐述了每种模式如何实质性解决相关核心问题。本文所归纳的研究框架为理解并应对气候变化下的城市内涝风险提供了新视角。

关键词: 机器学习; 城市内涝; 气候风险; 数据同化; 特征转换; 物理机理; 数据驱动; 不确定性量化; 风险传递
中图分类号: TP18; P4; TU998.4 **文献标志码:** A **文章编号:** 1673-4785(2026)05-1106-24

中文引用格式: 齐小刚, 张旭, 李家慧. 机器学习桥接城市内涝与气候风险: 研究进展与展望 [J]. 智能系统学报, 2026, 21(5): 1106-1129.

英文引用格式: QI Xiaogang, ZHANG Xu, LI Jiahui. Machine learning bridging urban waterlogging and climate risk: a review and outlook[J]. CAAI transactions on intelligent systems, 2026, 21(5): 1106-1129.

Machine learning bridging urban waterlogging and climate risk: a review and outlook

QI Xiaogang^{1,2}, ZHANG Xu¹, LI Jiahui^{1,2}

(1. School of Mathematics and Statistics, Xidian University, Xi'an 710071, China; 2. Xi'an Key Laboratory of Information Network Optimization and Mathematical Methods, Xi'an 710071, China)

Abstract: Climate change and urbanization have led to frequent extreme weather events and severe urban waterlogging risks, while conventional methods fail to bridge the gap between climate science and urban waterlogging management. Through systematic review and critical analysis, this paper for the first time summarizes three core “bridging” modes of machine learning connecting the two domains: multi-scale data assimilation and feature transformation bridge, modeling bridge integrating physical mechanisms and data-driven approaches, and assessment bridge for uncertainty quantification and risk transmission. This paper first analyzes the coupling mechanism between climate science and urban waterlogging research and key challenges, then reviews key technologies supporting these bridging modes, and elaborates how each mode addresses core issues through case studies. This summarized framework provides a novel perspective for understanding and mitigating urban waterlogging risks under climate change.

Keywords: machine learning; urban waterlogging; climate risk; data assimilation; feature transformation; physical mechanism; data-driven; uncertainty quantification; risk transmission

气候变化引发的极端天气越来越频繁, 导致城市内涝灾害时有发生, 这已经成为现代城市安全与稳定的严重威胁^[1-3]。政府间气候变化专门委员会 (Intergovernmental Panel on Climate Change,

IPCC) 发布的第六次评估报告显示, 许多地区检测到强降雨的次数有所增加, 未来此类事件会持续增长, 这无疑会极大地冲击人类的居住之地^[4]。同时, 城市化所引发的地表硬化、自然水文循环过程被阻断及排水系统老化等现象, 也给城市排水系统增加压力, 传统的城市排水系统越来越难

收稿日期: 2025-11-06. 网络出版日期: 2026-07-08.

基金项目: 国家自然科学基金项目 (62372354, 62373291).

通信作者: 齐小刚. E-mail: xgqi@xidian.edu.cn.

©《智能系统学报》编辑部版权所有

以应对极端降雨现象^[5-6]。因此,有必要对极端气候引起的城市内涝灾害进行预测和防御,并亟需新颖的研究方法和技术^[7-9]。

相关研究主要关注 2 个领域:气候科学领域侧重发展大尺度上的气候模式和提高降尺度技术,进而提高降水预报的精度^[10-13];城市水文学则专注于排水管网系统和排水模型的改进,关注地表径流和管道排水问题^[14-16]。2 个领域均取得了丰硕的研究成果,但存在着交叉困难。这种困难导致气候预测与城市水文模型之间存在着数据鸿沟和尺度不匹配等问题,气候模型给出的降水预报时空分辨率都难以满足城市尺度的合理模拟,而城市水文模型又缺乏对长期气候变化影响的关注,进一步阻碍了两者的融合发展。

机器学习的发展为解决这个问题提供了新的途径,其本身具有处理大量高维度数据、设计复杂模式和揭示非线性关系等方面的能力^[17-20]。但目前的研究大多关注特定算法在水文学或气候学单一领域内的应用和改进,缺乏一个可以把两者在尺度、数据与机理上的鸿沟进行整合的新视角^[21-22]。本文作为一篇综述,并非旨在提出全新的底层算法,而是对近年来交叉研究成果进行系统梳理与归纳。在此基础上,超越对机器学习方法的简单罗列,首次系统性地提炼并概述机器学习在连接气候科学和城市水文学中的 3 种主要“桥梁”模式:作为多尺度数据同化与特征转换的桥梁、作为物理机理与数据驱动融合的建模桥梁以及作为不确定性量化与风险传递的评估桥梁。这 3 种模式非常具体地解决了气候模型与城市模型间的尺度不匹配、物理一致性缺失及复合不确定性等核心挑战。

综上所述,气候与城市内涝在研究尺度、方法和数据上的割裂是研究的核心障碍。机器学习因其处理高维非线性问题的能力,被视为连接二者的潜在方式。然而,其应用需从零散的工具罗列走向系统化的“桥接”模式,本文旨在构建这样一个模式。

1 气候因素与城市内涝的关联机制

1.1 气候因素的分类与作用路径

当研究气候因素与城市内涝的关联时,首先需要有一个跨学科的研究框架。图 1 给出了如何用机器学习作为桥梁将气候风险与城市内涝研究进行融合。这清晰地反映出从宏观驱动到微观城市响应的传导路线,同时也是后续对气候因素进行探讨研究的基础。接下来,给出气候因素的科学

定义和分类体系,并对其影响机制进行讨论和研究。




图 1 机器学习桥接气候与内涝的研究体系

Fig. 1 Research system bridging climate and urban flooding via machine learning

1.1.1 气候因素的科学定义与分类体系

从内涝的视角来看,造成或影响城市内涝的各种气象要素和气候系统的状态变量均可被视为气候因素,气候因素可能会通过改变降雨与径流转换过程直接地影响城市内涝的发生概率和危害程度^[23]。不同类型的气候因素对城市内涝产生作用的方法和原因也不同,我们可以把其分为两类:直接作用因素和间接调制因素。直接作用因素通过物理过程直接影响地表径流的产生和管网排水能力^[24],从而引发城市内涝灾害,其主要由降雨特征参数(强度、降雨时长、降雨类型)及若干近地气象因素(温度、风速、湿度等)构成^[25]。间接调制因素则通过改变区域性气候特征或局部天气条件,进而间接地引发城市内涝,其涉及大尺度气候波动和局地气候相互作用等^[26]。这样的分类方法不仅考虑到气候因素发生作用的直接程度,而且反映了不同时空尺度上气候过程之间的层次关系。

1.1.2 直接作用因素的影响机制

在直接影响城市内涝的各种气候因素中,降雨的特征参数占据主要的地位,而降雨强度、降雨时长和降雨类型又是降雨特征中的关键因素。降雨强度直接决定了某一时段内的地表水量输入,如果超过城市土壤渗透率和排水系统容量时就会造成城市内涝;降雨时长则影响了城市内涝的持续时间,长时间降雨将会导致土壤饱和,加大地表径流比例;降雨类型的影响亦非常大,比如对流性降雨的高强度等特点通常会导致内涝的“突发性”^[27]。

温度会改变蒸发率,进而影响土壤的前期湿度。高温时,地表容易干燥,导致后期降雨过程

中的产流变得明显。风速可以影响雨水降落形态和位置,强风会导致斜向降雨,容易导致城市密集度道路区域出现内涝和积水不均,从而诱发城市内涝灾害。这些因素的综合作用使得城市内涝展现出复杂的时空分布^[28]。

1.1.3 间接调制因素的影响机制

大尺度气候模态通过大气遥相关过程调控区域降水格局^[29-30],例如,厄尔尼诺会影响东亚夏季风,使得长江中下游城市降水集中,导致比常年更频繁的内涝。局地气候反馈中,城市热岛效应最明显,热力圈环流使城市地区与郊区间温差增大,从而使得下风向城区对流旺盛,产生更多的降雨量^[31-32]。另外,人类活动和地球环境的变化也会间接地造成城市内涝等灾害的发生。这些间接因素虽然不直接参与产流过程,但改变气候背景场,对直接因素的作用效果有深刻的影响,从而形成多尺度协同的灾害链^[33]。

1.1.4 气候因素敏感性的量化

除使用传统的统计方法对内涝灾害中的气候因素敏感性进行研究,还可以运用机器学习中的模型。例如,随机森林(random forest, RF)算法可以通过计算气候因素在决策树分裂中使用的频率来量化其对内涝预测研究的贡献度,这种方法在洪水风险绘制研究中被成功应用。Kim等^[34]计算了总溢流量、地形高程和网格坐标等因素的重要性,较好地评估其在城市洪水危险等级预报方面的贡献。沙普利加和解释(Shapley additive explanations, SHAP)方法的根基在于博弈论中的Shapley值,可以用来为预测模型提供统一的局部解释框架,它将进一步加深人们对模型预测过程的认识。例如,Chu等^[35]提出结合动态空间杜宾模型与贝叶斯神经网络(Bayesian neural network, BNN)的混合框架,并用SHAP方法分析时空效应对于城市内涝预测的贡献,增强模型的可解释性和可靠性。类似地,Zhou等^[36]采用极限梯度提升(extreme gradient boosting, XGBoost)模型,结合SHAP和偏依赖图(partial dependence plot, PDP),得出了形态因子对淹水深度的影响占主导的结论,还探讨了其非线性关系和交互效应。以上新方法除验证理论知识外,还挖掘、讨论各种非线性关系和阈值效应,对于研究城市内涝做出了新的贡献。

1.2 气候因素与城市系统的耦合

1.2.1 城市下垫面的交互作用

城市下垫面,指地球表面与大气层直接接触的物质层,是气候与城市系统能量和物质交换的

界面,可分为不透水下垫面和透水下垫面两类,其比例和空间分布是决定城市水文响应的关键因素^[37]。城市下垫面与气候因素之间存在着复杂的非线性关系。降雨强度与不透水表面比例的耦合效应具有较为明显的阈值特征,当不透水率超过一定值时,相同降雨强度下的径流系数会呈现突变式增长。例如,燕超等^[38]通过模拟降雨实验发现,在降雨强度大于60 mm/h时,透水砖等透水下垫面的径流系数会出现显著增加,增幅可达0.21,说明存在明显的临界响应阈值;而在不透水表面(如沥青混凝土)上,径流系数始终接近0.9以上,受降雨强度变化的影响较小。这种关系在城市化较高的地区表现得尤为突出。城市的地表建筑和城市规划也会对降雨再分配产生影响,高层建筑群会改变近地面的风场和湍流特征,从而导致降雨空间分布呈现显著的局部差异,这种差异对精准预测城市内涝位置提出新的挑战。

1.2.2 气候与水文模型耦合的不确定性

在当前气候模式与城市水文模型耦合的相关研究中,不确定性传递是较为棘手的问题之一,不同排放情景、降尺度误差等诸多因素的作用,造成城市内涝风险评估及预测的可靠性严重下降。例如,Le等^[39]结合统计降尺度和水动力模型两种方法进行研究,发现高分辨率的区域气候模型会导致较大的变化范围,突出展现了降尺度过程中因区域气候模式的分辨率差异所引发的不确定性。Wang等^[40]进一步发现在不同气候情景和多模型组合下,中国各城市的年期望洪水体积会产生很大的变化,并且波动变化较大,即模型间存在很大的不确定性,表明排放情景及模式结构对洪水预测影响很大。另外,占车生^[41]的综述中也指出了气候模式和水文模型耦合时存在尺度不匹配、参数化方案不足以及高分辨率模拟中陆气反馈机制的描述不完善等问题,这又进一步加剧了跨尺度耦合过程中的误差传递与不确定性放大等问题。

机器学习的方法可以直接应用在解决不确定性问题上。与传统方法依赖于单独考虑一种不确定性来源不同,机器学习提供了一种全新的思路来理解所有的不确定性和它们产生的影响。凭借其强大的模式识别和函数逼近能力,机器学习模型可以对误差传播建立某种规则或映射关系,甚至直接给出从粗尺度气候预测到城市内涝结果的端对端映射关系,这在一定程度上可以降低不确定性累积。

1.2.3 人类活动的相关作用

人类活动也在不断地改变着城市气候系统。

例如城市扩张改变地表参数, 也明显改变局地能量平衡与微气候。研究表明, 城市化进程导致的“热岛效应”与热浪之间存在显著的协同增效作用, 二者叠加会进一步加剧城市的高温胁迫, 其核心机制与城市下垫面湿度匮乏以及热浪期间风速降低密切相关^[42]。此外, 城市基础设施亦会对城市的气候系统造成影响, 如大规模的地下空间开发建设会改变城市地下水文的循环路径, 海绵城市建设更是通过对城市地面的下渗功能加以改善来对地表径流进行控制和调节。以济南市为代表的研究表明, 下垫面不透水率的提升会系统性改变降水特征, 不仅使城区增雨系数显著大于郊区, 还会明显促进短时强降雨事件的发生^[43]。人类活动对城市气候系统的扰动效应普遍存在着时间滞后性, 城市形态的变化对微气候的调制作用需要很久的时间才能完全显现。例如, 在重庆这样的城市, 特殊地形与城市化进程相叠加, 显著改变区域的孕灾环境, 使得极端降雨更易转化为严重的洪涝灾害, 凸显滞后风险的复杂性^[44]。为明确并探讨这些问题, 本文给出如图 2 所示技术路线, 为后续的探讨提供参考。




图 2 应对耦合挑战的机器学习技术路线

Fig. 2 Machine learning technology route for addressing coupling challenges

2 机器学习的相关应用

对气候驱动城市内涝复杂路径的分析与探讨展现了跨尺度耦合与非线性的核心问题。机器学习方法众多, 但在研究中并非随意选择, 而是应紧密围绕待解决的核心问题。本文后续将阐述机器学习作为“桥梁”的 3 种典型模式, 每一种模式

都对应着特定的科学挑战和技术路线: 对于尺度不匹配挑战, 常使用时序分解、时空融合网络等技术构建数据同化桥梁; 对于物理一致性不足挑战, 倾向于采用物理信息神经网络等技术构建机理融合桥梁; 对于不确定性量化挑战, 则需依赖贝叶斯框架、可解释性人工智能等技术构建风险评估桥梁。本章将分类综述支撑这些“桥梁”的关键技术, 并探讨其在跨学科情况下的独特价值与固有局限。

2.1 面向气候因素的特征工程与模型构建

本小节将系统综述支撑“桥梁”模式构建的关键技术, 包括面向气候数据的特征工程、核心算法架构、模型性能分析以及物理机理融合等方向。这些技术并非孤立存在, 而是为后续解决特定科学问题、构建具体桥梁模式提供方法论基础。

2.1.1 气候时序特征的构造方法

气候时序特征构造是利用机器学习方法对城市内涝进行研究过程中的重要环节, 主要包括多尺度特征、非平稳特性和极值强化面的特征提取等。以往的时序特征分析方法在处理气候相关问题时具有一定的难度, 近年来在机器学习的引领下涌现了一批特征工程的方法。

气候数据本身拥有较为明显的多尺度特性, 例如其包含了小时级别暴雨事件和年际尺度干旱趋势等^[45]。一般的方法在对这种多尺度模式进行捕捉时, 很难检测出突发的、特殊的现象^[46], 机器学习方法具有更加灵活的信号分解与特征提取技术。例如, 基于局部加权回归的季节趋势分解法 (seasonal-trend decomposition using loess, STL) 能够将时间序列分解为长期趋势、季节波动和随机残差 3 个部分, 从而分别对变化较为缓慢的气候背景 (如多年干旱)、固定周期的季节行为 (如梅雨) 和短期随机事件 (如突发暴雨) 进行建模^[45]。这种分解有利于提高模型对不同时间尺度规律的学习能力, 特别适合具有较强周期性的气候数据。类似地, 小波能够将降雨时间序列信号分解为不同的频率成分, 可以捕捉不同频率的信息特征。例如, 用降雨的时间序列通过小波分解所得的每一层系数作为特征放入人工神经网络 (artificial neural network, ANN) 中进行训练时, 可以使模型同时学习到长期趋势和短期波动两种模式, 从而提升模型性能。小波神经网络 (wavelet neural network, WNN) 就是把小波函数直接作为激活函数, 这有利于模型对非平稳信号进行处理^[47-48]。类似地, 流形学习算法等也可以从高分辨率数据中提取时空分布特征, 使得气候处理分析更加精

细^[49]。这样的方法既可以增加模型对复杂气候现象的表征能力,又降低误报率。此外,在对极端降水事件进行研究时,不同时间分辨率数据会显著影响特征识别,多尺度分析方法有利于客观地刻画其时空演变特征^[50]。

气候时序数据本身具有内在不平稳特征,常表现为突变(如台风骤雨)或渐变(如持续干旱)等特性,传统的统计分析方法由于假设数据是平稳的,所以是不适用的。集合经验模态分解(ensemble empirical mode decomposition, EEMD)通过自适应分解非平稳信号为有限个本征模态函数(intrinsic mode function, IMF),显著提升模型对突发事件的敏感性。EEMD 与现代分析方法的结合,是提高气候变化研究及极端事件预警能力的重要途径。薛春芳等^[51]较早地将 EEMD 运用在渭河流域秋季降水序列的分析上,提取多尺度气候振荡信号,这表明 EEMD 在识别非平稳气候突变中具有优势;罗那那等^[52]应用 EEMD 对北疆降水进行多尺度分解,揭示不同时间尺度下降水的振荡特征和演变规律,是深入认识区域气候突变程度的有效途径;焦阜生等^[53]进一步将 EEMD 去趋势法用于生态系统水分利用效率对气候响应的研究中,在避免常规线性去趋势带来的伪相关影响的基础上,进一步提高计算准确性。因此,通过提取 IMF 分量中的多尺度特征并将其作为模型的输入,可以提取出气候数据中更深层次的信息,也能降低模型的误报率,为复杂气候现象的建模提供了新思路。

极端气候事件发生频率低但破坏性很大。例如,极端降雨事件发生的概率小,却造成大损失。因此,极端事件建模面临样本稀缺、模型敏感性不足等问题。特征增强可解决模型敏感性问题,物理约束嵌入和生成对抗网络(generative adversarial network, GAN)也成为当前的研究热点。Ji 等^[54]使用 GAN 构建多站点随机天气发生器,合成 30 年的小时降水序列,准确再现原始数据的时空分布特征,同时也显著提升空间相关性模拟的能力。Li 等^[55]将自注意力机制引入到 GAN 中,生成的结果更接近真实的雷达观测信息,有效地提升建模的准确性。GAN 通过对抗训练生成符合统计特征的合成数据,为缓解极端事件样本稀缺问题提供有效途径。另外,这类生成模型在气候变化情境下也能发挥重要作用,Chen 等^[56]基于第六阶段耦合模式比较计划(coupled model inter-comparison project phase 6, CMIP6)的多模型集合,发现尽管年总降雪天数减少,在特定气候强迫下

中国北方极端强降雪事件频率仍有上升的趋势。

上述方法侧重不同:STL 适合具有明确周期性成分的数据,但对突变信号的响应较慢;小波分解在时频域均有良好表现,但小波基的选择对结果影响显著;EEMD 无需预设基函数,自适应性强,但存在模态混叠和端点效应问题。总体而言,这些方法多为信号处理工具,其分解结果是否具有物理含义仍需结合领域知识判断。在应对未来非平稳气候情景时,这些方法均依赖于历史数据分布,其外推能力有限,需与物理模型或生成模型协同使用。

2.1.2 空间特征的融合表达

在城市内涝预测的相关研究中,亟需对多源异构空间数据进行融合。传统的数据融合方法难以有效整合气象、地形、建筑等多维度信息,而近年来深度学习为解决这一问题提供新的思路。多源遥感数据标准化处理、城市地形与气候场的张量融合以及异构神经网络构建是其中的典型研究方向。

遥感数据、历史记录数据和实地观测数据等是内涝预测中的重要输入源,这些数据在分辨率、坐标系和物理含义上存在着差异,在使用前需要对其进行标准化处理,可分为坐标对齐、物理量归一化和异常值清洗等步骤。坐标对齐是指通过投影变换统一地理参考基准,并运用双线性插值或卷积下采样将不同分辨率的数据匹配至同一网格,消除空间错位。例如,Lei 等^[57]通过集成卫星遥感、无人机遥感和地面测量数据,实现多源数据的空间配准,提高洪水灾害的监测精度。黄华兵等^[58]也特别关注数字高程模型(digital elevation model, DEM)和不透水面分布数据的正确配准以服务于精细化分析。物理量归一化是为消除数据之间的差异,使得数据能够进行比较和应用,会涉及 Min-Max 标准化或 Z-core 转换等一系列操作。高伟等^[59]在对洪涝淹没范围时序监测进行研究时,对植被指数和遥感数据等进行归一化,从而提取准确的水体信息。Ding 等^[60]在进行多源遥感数据融合时,通过对合成孔径雷达(synthetic aperture radar, SAR)和光学影像进行辐射归一化与直方图匹配,极大地提升数据一致性和融合效果。

多源数据进行标准化处理后,要转化成多通道时空张量,才可以统一描述城市下垫面特征和气象要素之间的耦合关系。许多研究采用编码器-解码器架构(encoder decoder architecture, EDA)提取多尺度特征,编码器利用卷积操作捕

获地形与降雨的局部关联, 解码器则使用上采样来恢复空间细节, 通过跳跃连接保留关键的几何特征, 这解决了城市空间异质性对降水再分配的影响^[61]。有些研究还引入注意力机制来动态确定不同区域的权重, 使得强降雨地带和脆弱地带的关联性更强, 削弱了无关背景噪声, 这种方法在完成网络敏感度提升的同时, 也不再受人工局限性的影响。毛宇涛^[62]针对轻量化多模态降水预测模型提出交互通道即空间注意力机制, 通过双向跨模态注意力融合雷达与站点数据, 有效抑制无关噪声并突出关键区域。该方法在浙江区域数据集上验证了多模态融合对提升短临降水预测鲁棒性的促进作用, 在高强度降水等事件中取得了良好的效果。近年来, 时空序列建模逐渐成为张量融合的新方向, 在结合卷积神经网络 (convolutional neural network, CNN) 与循环神经网络 (recurrent neural network, RNN) 的混合模型中, 能够通过门控机制调控时空状态传递, 从而提高短时降水预测的精度与效率。

异构图神经网络 (heterogeneous graph neural networks, HGNN) 也被广泛用于复杂交互关系的建模中^[63]。HGNN 通过整合多类型节点和多关系边, 能够有效捕捉多因素驱动机制。为解决异构特征维度差异的问题, 可以将节点的属性统一嵌入低维向量空间^[64]。图卷积与时空建模通过融合时序动态特征, 借助图结构来捕捉空间依赖关系。主流的方法是采用基于元路径的图卷积操作, 通过聚合多条邻居信息来模拟局部空间依赖关系^[65]。同时, 静态图结构在与时序模型结合的情况下, 能对降雨强度、管网负荷等时序动态性进行处理^[66]。

2.2 核心算法架构与优化

2.2.1 气候情景增强技术

气候具有特殊性, 其观测数据稀疏且历史极端事件的样本也有限, 传统的气候模型由于受到限制难以充分捕捉气候变化的复杂模式。气候情景增强技术是扩展数据资源和提升模型泛化能力的关键手段, 尤其针对极端气候事件预测和区域气候风险评估场景。常见的方法有基于数值模式的合成数据生成、利用 GAN 对数据进行扩充、跨区域迁移学习和参数优化等。

在基于数值模式的合成数据生成方面, 门宝辉等^[67]通过耦合 CMIP6 与天气研究与预报模式 (weather research and forecasting model, WRF), 发展一种动力降尺度方法, 生成高精度气象数据, 用于识别不同情景下黄河上游复合干旱热浪事件的演变规律。此类方法的优势在于物理一致性高,

但计算成本高昂, 且对参数化方案敏感^[68]。近年来, 通过引入气候相关指数作为条件约束, 条件生成对抗网络 (conditional generative adversarial network, CGAN) 在生成符合物理规律的数据的同时, 还能保留极端事件的统计特征。通过生成合成数据、迁移学习等方法, 训练数据的时空覆盖范围和物理多样性都得到扩展, 为相关研究提供更有力支撑^[69]。针对数据稀缺难题, 迁移学习可以通过特征分布对齐实现模型参数的跨区域迁移。在源域训练的模型通过特征适配后, 可提升目标域的降雨预测精度^[70-71]。

2.2.2 时空融合神经网络

城市内涝受气候因素和城市下垫面情况等因素的共同影响, 很难用单一因素确定。传统预测模型受计算效率和精度的限制, 难以满足高分辨率的需求。时空融合神经网络 (spatio-temporal fusion neural networks, STFNN) 可以把空间与时间维度的异构特征并行处理, 也可以确保内涝预测的精度与实时性。目前, 主流的 STFNN 采用时空双通路设计。空间通路使用三维卷积神经网络 (3D-CNN), 通过多尺度卷积核提取降雨场、地形高程数据的空间演变特征和相关性^[72]。时间通路采用 RNN 或时序卷积 (temporal convolutional network, TCN), 从而对雨量站、管网流量等时序数据的动态规律进行建模, 双向长短期记忆网络 (bidirectional long short-term memory, BiLSTM) 能够同时捕捉历史与未来时间步的依赖关系, 增强对降雨峰值的预测能力。当把两者进行融合时候, 可以引入注意力机制, 其可通过学习权重动态分配时间和空间特征的贡献度, 例如对强降雨地区的空间特征或者是关键时间点的雨峰信号进行强化^[69]。STFNN 通过时空插值和特征级对齐等方法来解决多源数据中的数据对齐问题。时空插值可以把非均匀采样的传感器数据进行网格化, 如基于克里金插值处理稀疏的管网水位数据, 生成城市的水位网格图^[73]。特征级对齐可以减少分布差异, 其一般通过共享编码器或对抗训练将多源数据对齐到公共特征空间上。STFNN 通过端到端的时空特征提取与自适应融合, 给出城市内涝预测的新思路。

与传统的物理降尺度方法相比, STFNN 减少了计算成本, 且能够实现从气候到内涝的端到端映射, 然而这也牺牲了物理可解释性。目前的 STFNN 多为黑箱模型, 未能解释中间的物理过程。此外, 其在训练数据分布之外的外推能力也存在疑问, 也难以量化预测结果的不确定性。因

此,其更适合作为快速预警的代理模型,而不是取代物理机理分析的最终工具。

2.3 模型性能与适应性分析

2.3.1 监督学习模型的优势

监督学习 (supervised learning, SL), 其本身具有可解释性, 并能够有效利用标注数据, 相关模型能够处理气候因素的动态特征。RF 通过对多棵决策树进行集成, 提升小样本场景下模型的泛化能力^[74], 所以其在气候数据非平稳性或噪声干扰的情况中适用。这些方法的优势在于能够自动评估特征的重要性, 对气候驱动因子与城市排水之间的非线性关系进行识别^[75]。XGBoost 等梯度提升算法则通过优化损失函数和正则化项, 对气候变量与内涝深度之间的阈值效应进行捕捉, 例如识别临界雨强下积水风险的突变特征^[76-77]。得益于集成方法融合的异构模型预测能力, SL 的适应性得到提升。例如, 堆叠 (stacking) 等策略可将气候模式输出与机器学习模型的预测结果相结合, 增强模型在不确定性下的稳定性^[78]。这类方法的核心在于通过多源数据协同建模来弥补单一模型的不足, 在复杂气候城市系统中实现更稳健的预测性能。

监督学习模型的作用有所不同: RF 在特征重要性评估和小样本场景下表现平稳, 但容易受噪声的影响; XGBoost 可以通过正则化和梯度提升把预测精度提高, 但其涉及的超参数调优较为复杂; Stacking 集成策略可以融合多模型的优势, 但是计算成本偏高且会有过拟合的风险。监督学习模型的可解释性强、计算效率高, 适合被应用于简单的风险因子识别与快速评估, 但其建模能力有限, 难以展现深层次的非线性耦合关系。

2.3.2 深度学习模型的核心构架与前沿进展

基于大量异构数据的深度学习可以直接进行端到端的学习, 提取气候时空特征以及城市响应之间的复杂映射关系对城市内涝预测也是有帮助的。Transformer 架构可以凭借自注意力机制对气候数据中的跨尺度依赖关系进行描述, 这比较适用于极端降雨事件的时空传播。Transformer 中的多头注意力层可以对局部暴雨事件和区域气候振荡的关联性进行捕捉, 从而提升短时预报的准确性。例如, Burrichter 等^[79]将降水信息、空间地形属性和溢流预测编码为图结构, 并使用时序图卷积网络节点间的物理连接与动态交互效应进行量化, 从而完成内涝过程的时空预测。在气候和城市内涝的研究中还应用了很多深度学习的方法, 例如 CNN 可以有效地提取降雨空间分布、地形高

程和地表覆盖类型等多源数据的局部特征, 所以其可以被应用于积水水深和范围的快速预测^[80]。长短期记忆网络 (long short-term memory, LSTM) 能够处理气候时间序列的非平稳性和长期依赖的关系, 可用于展现降雨强度、历时与内涝积水深度之间的动态响应关系, Huang 等^[81]利用一个耦合 CNN-LSTM 模型, 在流域径流预测中实现时空特性的有机组合, 并通过 SHAP 技术对结果进行解释。卷积长短期记忆网络 (convolutional long short-term memory network, ConvLSTM) 把 CNN 的空间特征提取能力与 LSTM 的时间动态建模能力进行融合, 使得其能同步捕捉时空依赖性, 被广泛应用到构建端到端的“气候驱动-内涝响应”模型中, 有效地实现了从降雨输入到积水输出的直接映射, 适用于模拟时空变化下暴雨引起的内涝情况^[82]。EDA 也可以结合注意力机制进行改进, 从而实现时序动态、空间静态条件下异构数据驱动的内涝模拟, 所以其可以支持道路级积水的实时预测和风险可视化。集成学习法不仅可以提升泛化性能, 而且在某种程度上对模型结果具有改善作用。Du 等^[83]通过 Stacking 集成框架对多层感知机 (multilayer perceptron, MLP)、RF、XGBoost 和梯度提升回归器 (gradient boosting regressor, GBR) 等多个基模型进行融合, 提升了内涝预测的准确性与稳定性。总体而言, 深度学习方法在城市内涝预测中具有广泛的应用前景, 其多样化的模型架构也推动了该领域进步。

在深度模型中, CNN 能提取局部空间特征, 但难以捕捉长距离时空的依赖; LSTM 能较好地处理时间序列的非平稳性, 但难以独立建模空间结构; ConvLSTM 通过卷积门控机制实现了时空同步建模, 是目前最流行的端到端映射架构; Transformer 则依靠自注意力机制, 在理论上能发现任意尺度的依赖关系, 但其计算复杂度较高, 在小样本场景下容易发生过拟合现象。当然, 这些模型的性能非常依赖于训练数据的质量和数量, 且普遍存在泛化能力弱的共同缺陷。未来研究的关注点或许应该放在增强物理一致性与可解释性上面。

2.3.3 半监督与非监督学习的补充

半监督学习 (semi-supervised learning, SSL) 是机器学习中较为重要的一部分, 特点是在训练中可以同时使用少量有标签和大量无标签的数据^[84]。SSL 可以充分利用未标注数据中的潜在信息和模式来提高模型的效率和准确性^[85]。在气候学和城市内涝的研究中, 标注数据往往比较少且其获得

成本较高, 而未标注数据则相对较多^[86-87], SSL 就可以利用未标注的数据来提高模型的性能。

非监督学习 (unsupervised learning, UL), 能够从无标注的数据中寻找出隐藏的规律^[88-89]。和监督学习不同的是, UL 允许机器自发地进行探测和学习, 使其更加真实地贴近于现实世界中的数据分析过程。对于气候研究和内涝预测的相关应用领域, UL 的主要应用形式有聚类分析、降维技术、异常检测以及生成模型等。

随着极端天气事件增多和城市内涝风险加剧, SSL 和 UL 都给气候数据标注不足的场景提供了很大的便利性。

2.4 物理机理与数据驱动融合

2.4.1 物理机理与数据驱动的融合模式

现今的研究中, 物理机理与数据驱动的融合也比较受欢迎^[90]。对气候系统的物理规律和机器学习的数据挖掘优势进行整合, 可以开发出具有机理一致性和场景适应性的预测框架。在受物理约束的损失函数中, 守恒律和过程驱动方程被嵌入到模型的训练之中, 使得模型的输出结果符合实际物理机理^[91]。这些约束有助于提升模型的外推能力, 还能增强在数据稀疏区域保持合理预测的性能, 从而提升模型的鲁棒性和可信度。

嵌入微分方程的神经网络可以进一步强化物理与数据之间的互馈。物理信息神经网络 (physics-informed neural networks, PINNs) 的核心是将物理方程直接嵌入损失函数中进行硬约束, 这可以实现从宏观气候到城市微尺度的跨尺度耦合连接, 能够在提高模型整体预测能力的同时保证其较好地满足物理规律^[92]。

运用机器学习进行研究时, 在多尺度物理参数耦合方面仍面临诸多核心挑战: 宏观气候模式与城市水文模型间的时空分辨差异需通过动态降尺度技术衔接^[93]; 参数传递过程中的不确定性需借助主成分分析等降维方法处理; 时空异质场景下的迁移效率仍有待提高。元学习驱动的区域气候参数自适应调整策略可以对参数的迁移效率进行优化^[94], 但其需要与计算成本和结果精度进行权衡。邱伟峰^[95]研发基于神经微分方程的分钟级降雨估测方法, 展现数据驱动技术在短期降水预测中的优势, 为城市内涝预警提供支撑。

PINNs 通过在损失函数中嵌入物理方程, 显著提升了模型在数据稀疏区域的推理能力, 是解决“物理一致性不足”问题的有效手段。然而, 其训练过程对物理先验的准确性高度敏感——若控制方程不完全或参数化方案不合理, 反而可能

引入系统性偏差。此外, PINNs 的训练收敛速度慢, 且物理约束项与数据拟合项之间的权重平衡缺乏通用准则。相比之下, 可微分建模通过将物理过程转化为可微计算图, 在保持机理骨架的同时赋予了参数学习的能力, 在泛化性与灵活性之间取得了更好的平衡。

2.4.2 可解释性技术提升

灾害防控决策依赖于对预测结果的解析, 可解释性技术正是连接两者之间的桥, 如 SHAP, 能够量化各输入特征对模型预测的贡献度, 提升模型的透明度, 对于理解内涝成因至关重要^[96]。

动态特征重要性可视化技术将模型关注区域空间化, 通过热力图定位高风险积水点与管网拓扑瓶颈。Selvaraju 等^[97]开发的梯度加权类激活映射 (gradient-weighted class activation mapping, Grad-CAM) 技术不仅提供类别判别定位, 还通过与引导反向传播结合生成高分辨率可视化, 增强模型透明度。在多模态数据融合场景中, 此类技术可生成因果图以解析建筑布局对热岛效应增强降雨的链式机制, 为韧性规划提供空间显式依据。

不确定性量化方法主要被应用在模型的可靠性评估过程。通过融合蒙特卡洛 Dropout 技术与气候模式, 可区分不确定性来源从而对风险概率分布进行可视化。Gal 等^[98]把 Dropout 视为贝叶斯近似来表示深度学习中的模型不确定性, 从而生成风险概率分布图。BNN 则能够将参数不确定性纳入概率输出的结果, 从而给应急预案的资源分级调配提供置信度参考。Rudin^[99]主张在高风险决策中避免黑盒模型, 尽量使用内在可解释模型来确保公平性和透明度; 靳庆文^[100]则从情报分析角度综述可解释性技术的评价方法, 强调其在多领域应用中的价值。

SHAP、Grad-CAM 等技术是构建不确定性量化与风险传递桥梁的关键, 它们将机器学习模型的预测转化为可理解的决策依据。然而, 这些事后解释方法本身也存在计算复杂、稳定性不一等问题, 且其解释结论仍需与领域知识交叉验证。

2.4.3 跨区域知识迁移技术

跨区域知识迁移技术能解决模型泛化能力不足的问题。由于历史背景不同, 城市在气候特征、地形条件、排水系统建设和历史记录保存等方面有着很多的不同, 一个城市的训练模型并不能直接应用于其他城市。迁移学习可将数据丰富区域学习到的知识迁移到数据稀缺区域。正如 Wang 等^[101]通过集成仿真与 3D 可视化技术所展示的, 多源数据融合与跨尺度建模有助于提升

模型的适应性与可迁移性。Xia 等^[102]提出的高效水力模型,通过改进底坡源项和摩擦项离散化方法,增强模型在不同地形条件下的泛化能力,为跨区域模型迁移提供技术支持。

跨区域迁移仍面临挑战。区间气候模态差异和城市下垫面差异性会导致负迁移,对预测区域和结果产生影响。例如,薛丰昌等^[103]提出的基于空间模态识别与尺度转换模型在单一实验区内精度较高,但其依赖于代表性降水数据集的构建与本地化参数调整,这表明跨气候区迁移时面临一些困难。城市下垫面的复杂性也增加迁移难度,王兆礼等^[104]在研究相关耦合模型时指出,即使在同一个城市内,不同区域的排水系统标准和地形特征差异也会对模型性能产生影响,跨区域时这类问题会更加突出。

未来的研究需要考虑更多种类的气候区域,尤其是在跨雨境、跨区域等方面的研究。尝试凭借元学习驱动自适应策略,在迁移过程中改变参数设置或结构优化,是具有可行性的研究方案。

2.4.4 社会物理协同系统建模

社会物理协同建模,通过将人类活动纳入相关循环中,对城市的反馈进行动态研究^[105]。在相关研究中,土地利用变化是重要的干预变量,其

通过改变地表径流系数和热岛强度,间接地增加内涝风险。机器学习模型与遥感和社会经济数据相耦合,可对内涝风险的演变轨迹进行量化。

基于 Agent 的模型 (agent-based model, ABM) 可以被应用于模拟不同类型决策群体的应急响应行为及链式反应,为灾后应急、恢复和适应提供行动指引。通过给不同决策主体设计的行动规则,ABM 可以模拟推演灾前预防、灾中应急处置、灾后重建规划等不同环节的策略组合和交互效果,并进一步对这些措施的效果和长期作用进行评估^[106],其还可以评估政策干预对系统韧性的长期影响。

跨空间数据关联技术是社会物理建模的支撑。整合物理空间、信息空间、社会空间等多源数据的过程中,需要解决匹配与时空对齐等问题。如图神经网络方法可通过匹配社交媒体的位挑战词来获取高覆盖度、灾情动态图,进而推动将原先的灰色城市设施导向驱动治理,转向为面向社会、生态与工程协同的综合范式^[107]。

至此,我们对机器学习在城市内涝研究中的应用和相关内容进行了详细阐述和分析,为更加清晰地展示出两者之间的融合与研究,给出如图 3 所示的融合方式示意。

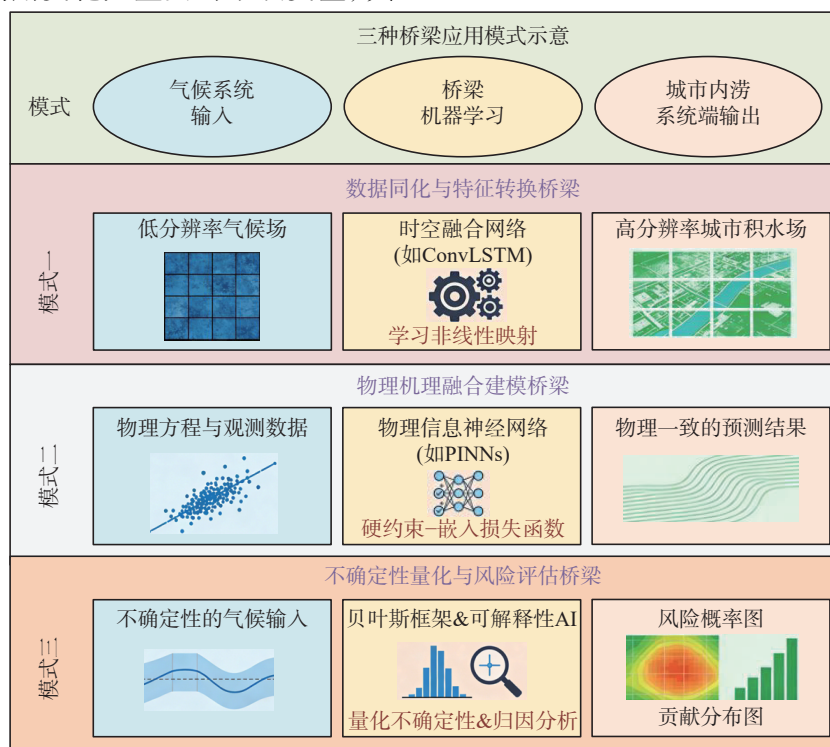


图 3 机器学习作为桥梁的 3 种典型应用模式

Fig. 3 Three typical application modes of machine learning as a bridge

3 关键挑战与前沿方向

机器学习确实为城市内涝的研究提供强大的

方法论支持,然而其在某些方面也面临着技术瓶颈和实践障碍,如数据融合、模型泛化、计算效率及实际应用等。本章节将对当前研究的局限之处

进行更深入地分析, 并对物理引导建模、数字孪生等前沿方向进行展望。

3.1 技术瓶颈与局限性

3.1.1 模型泛化能力的挑战

机器学习模型在实际应用中面临严峻的泛化能力挑战, 原因在于气候系统非平稳性与城市系统异质性, 全球气候逐渐发生变化, 基于历史数据训练的模型难以适应未来的情景。熊立华等^[108]研究表明, 在变化环境下, 设计暴雨的“一致性假设”会被破坏, 强度-历时-频率(intensity-duration-frequency, IDF)曲线需基于非平稳性序列进行修订, 否则会低估未来暴雨强度及内涝风险。

跨区域迁移会造成精度损失, 对模型普适性造成进一步阻碍。不同的城市存在着差异, 在数据丰富区域训练的模型被迁移到数据稀缺区域, 会导致性能下降。例如, 沿海城市模型在内陆城市的应用就会受到限制。现有的域自适应技术在复杂城市系统中的适配效率仍不足, 难以实现跨区域的鲁棒性建模。根本原因在于, 大多数机器学习模型基于历史数据的独立同分布假设进行训练, 而气候系统的非平稳性与城市的空间异质性共同打破了这一假设, 导致模型难以泛化至未知情景和区域。

微观与宏观之间尺度的衔接问题则源自多尺度物理过程的衔接困难。宏观气候模式的输出与城市微尺度水文模型的输入之间存在分辨率差异, 这会导致降水空间的降尺度误差传递至最终的结果。即使能用代理模型克服这一差距, 如何更准确地传递参数仍难以解决。这实质上是跨尺度耦合过程中物理信息丢失与误差传递的经典难题, 单纯地统计降尺度或代理模型难以完全保持物理一致性, 需要发展机理嵌入的数据同化方法。Rasp 等^[109]强调, 基于深度学习的参数化方案虽能替代传统模型中的一些物理参数化过程, 但如何在高分辨率城市模型中实现跨尺度耦合仍是一个有待深入研究的方向。

此外, 不确定性量化也是薄弱之处。内涝预测的不确定性不仅来自输入(如降雨观测及预报不确定), 也来自模型参数, 甚至来自模型结构本身。现有方法很少系统地区分这些不确定性来源, 也未积极引入概率框架或贝叶斯方法进行量化。当前研究往往孤立看待不同来源的不确定性, 缺乏一个统一的框架来量化并追溯从气候情景输入到内涝风险输出的全链条不确定性传递, 这限制风险评估结果的可靠性与决策支持价值。Tsai 等^[110]提出的可微分参数学习框架被用于从大数据中学习参数映射规律, 展现出较好的物理

一致性和泛化能力, 但仍需进一步对不确定性估计进行研究。Reichstein 等^[111]也希望在深度学习与物理模型融合的框架中, 发展能够同时处理随机性与认知不确定性的方法。

现有的机器学习方法在内涝和气候的耦合研究中呈现出效率与保真度的权衡: 纯数据驱动模型计算效率高, 但物理一致性与可解释性不足; 物理约束模型保留了机理可信度, 但训练成本高且对先验知识依赖性强; 混合建模(如可微分水文模型)在两者之间找到了折中点, 但技术门槛高, 尚处于发展初期。目前还不能做到将跨尺度耦合、物理一致性与不确定性量化三大核心挑战同时解决。未来研究可能更倾向于发展能动态平衡物理置信度与数据置信度的自适应融合框架。

3.1.2 数据与方法的限制

数据层面的阻碍主要表现为极端事件样本稀缺性与多源异构性并存。百年一遇暴雨等低频灾害的样本不足, 导致模型在关键场景的泛化能力不足, 且易对高频常规事件过拟合^[112]。极端事件样本稀缺的本质是气候风险的长尾分布特性, 这要求机器学习模型不仅要有强大的插值能力, 更需具备在数据稀缺区间的外推鲁棒性。GAN 虽可合成物理约束的极端降雨场^[113], 但其合理性验证依赖高保真度水文模型, 形成“生成-验证”的闭环依赖, 且合成数据会引入虚假关联。

多源异构数据融合的困难主要是时空对齐与语义统一。气象雷达、物联网传感器与社交媒体数据的时空分辨率、坐标系及量纲存在很大差异, 需要通过动态图神经网络进行统一编码^[111], 现在的方法对非结构化数据的兼容性不高。

另一个较大的问题是在方法论方面, 即物理机理模型与数据驱动范式的冲突。纯数据模型没有考虑物理规律, 其预测缺乏实际意义; 而物理模型因其本身结构复杂, 难以适应城市的复杂性。目前常用的 PINNs 虽然可以通过嵌入守恒约束来缓解这些矛盾^[114], 但微分方程先验设定会遮盖一些尚未确定的城市水文过程, 从而导致模型的灵活性下降。这揭示物理约束的“硬嵌入”与数据驱动的“灵活学习”之间的内在张力。其核心在于如何量化与调和“物理置信度”与“数据置信度”。近年来, 有研究提出通过硬约束嵌入网络结构, 在保障物理一致性的同时增强泛化能力, 为调和机理与数据关系提供新的思路^[115]。

3.2 计算与实践挑战

3.2.1 技术实践阻碍

高分辨率模拟的算力需求也是城市内涝预测

研究的一大阻碍。如果需要处理米级精度的积水空间分布预测,需要处理跨尺度耦合问题,其计算复杂度也会非常高。传统水动力模型在模拟城市内涝的研究中耗时显著,难以满足动态预警的时效性需求^[116]。为缓解算力需求的压力,研究人员设计了轻量化模型,但其物理过程保真度会受到破坏,特别是建筑群对降雨再分配等微观机制的表征中易产生偏差。

实时预警延迟问题来自于数据同化与模型计算。气象雷达数据的分钟级更新频率与管网传感器秒级采样率之间的时序异步性,这使得多源流数据难以实时融合。传统模型依赖静态历史数据训练,缺乏实时反馈机制,无法动态修正预测结果^[117]。边缘计算部署虽能压缩端到端延迟,但受限于设备容量与能耗约束,难以支持高分辨率模型,尤其在面对极端降雨事件时易出现响应滞后的情况。

精度权衡与可解释性是机器学习模型的内在矛盾。这一矛盾根源在于模型复杂度与可解释性往往存在此消彼长的关系。追求高精度常需复杂的深度网络,而这会牺牲透明度。因此,发展结构可解释的模型(如可解释的神经网络结构)或高保真的事后解释技术,是打破此僵局的关键。深度学习确实能够捕捉降雨与积水间的复杂关系,但由于黑箱性,使得官方部门无法完全相信预测结果。SHAP 值分析等可解释性技术虽然可以提升决策透明度,却显著地增加计算消耗,并且无法保障物理一致性。因此,开发兼具实时性、可解释性与物理一致性的新型模型架构,是打破当前困局的关键。研究表明,通过粒子群优化(particle swarm optimization, PSO)与深度神经网络结合,可在保持高精度的同时提升模型响应速度,但物理约束的嵌入机制仍需进一步探索^[118]。

联邦学习是解决数据孤岛困境的方法之一,不同部门的数据无法共享且缺少权限,可以结合联邦学习在隐私保护下进行联合训练^[119]。然而,还有很多困难有待研究和解决,它们阻碍联邦学习在内涝研究中的落地应用。

3.2.2 应用落地障碍

技术到决策转化的断层,来源于预警系统与应急响应系统的脱节。内涝预测模型的输出可能只涉及积水深度或者范围,没有对疏散路径、资源调度等进行整合,导致预警信息没有办法直接作用于应急救援等活动。动态路径规划需要结合实时的交通数据与积水预测,一般要求在极短时间内生成疏散方案,但现有的系统由于缺少耦合

接口难以实现协同优化^[120]。例如,相关研究表明尽管太湖流域模型等先进技术能够高效模拟内涝过程,但其主要关注点仍停留在水文水动力过程本身,缺乏与应急决策系统的深度整合^[116]。

鉴于不同研究关注的时间尺度不同,长期规划决策与短期预测会面临脱节。机器学习模型一般适用于短时预测,而城市建设等韧性规划则需要对气候变化的长期影响进行研究^[121]。气候模式输出与城市发展模型耦合存在困难,导致规划方案无法适应气候不确定性。例如,一些城市项目需量化未来几十年不同排放路径下的内涝风险,但现有的模型尚难以支撑多时间尺度的协同分析。

跨部门数据共享机制的不足制约信息的有效融合。城市、气象和交通等信息分别属于不同的机构,且数据采集形式与存储技术存在差异,无法整合成统一的框架进行数据共享^[117]。同时,在不失去数据的所有权和控制权的情况下,跨系统的数据共享方式与流程还缺少共识和技术支持,甚至面临同步传输技术瓶颈。

技术的快速发展不能够与治理体系、政策法规等相互配合,所以社会接受度并不高。大家对预警结果的信任度取决于机器学习等方法的可解释程度,同时黑箱决策也很难获得官方部门认可^[118]。在现实生活中,政策法规会滞后于技术创新,联邦学习的合规性、合成数据的法律效力等都存在着争议。此外,边缘设备部署也面临着很多难题,比如供电稳定、环境适应等,这些问题进一步增加成本。

3.3 前沿研究方向

3.3.1 下一代建模技术

物理引导的混合建模,使用物理机理对数据驱动范式的外推力进行加强。这类模型在神经网络架构中嵌入水动力学方程,从而避免产生不符合物理实际的结果,并保留对城市复杂性的适应能力。其主要思想是根据数据置信度对物理约束权重进行动态调整,以平衡机理依赖性和模型灵活性,例如在极端气候场景下加强约束,在普通区域弱化约束以保留相应的特征,这要求发展可学习的自适应损失函数,使物理残差项的权重能随输入数据的分布特征而动态演变。

数字孪生技术,推动城市内涝研究向“虚实协同”范式演进。城市内涝数字孪生体,基于标准化接口进行构建,整合物联网传感器、气候模式输出与社交媒体等多源实时数据,形成监测、模拟、预警及响应的闭环,其构建与运行面临两大核心

挑战: 一是多源异步流数据的实时同化与融合算法, 二是虚拟模型与物理实体间持续、双向校准的驱动机制。未来, 借助于高性能计算与动态数据的同化能力, 有希望构建高保真的虚拟推演环境, 支持多主体协同演练应急策略, 并利用智能优化算法规划最优疏散路径与资源调度方案。

可解释人工智能和因果推断相结合, 有利于打破机器学习模型的黑箱困境。例如, 通过结构因果模型 (structural causal model, SCM) 与 SHAP, 识别特征间的相关性与因果性, 建筑密度混杂因子会对不透水面比例与内涝深度的关联产生影响。这些方法提升决策的透明度, 也识别出关键影响点, 有利于相关部门进行科学精准的规划。

3.3.2 未来可行研究方向

面对多源数据时空统一的问题, 需要开发一些多模态数据动态对齐的相关算法, 也可以利用区块链技术实现数据追踪与质量检查, 保证合成数据符合物理规律和标准。同时, 灾害数据标准化共享平台的研发和建设也是十分必要的, 以便于多源数据的获取和利用。

微分方程嵌入的神经网络压缩技术能解决高分辨率计算的瓶颈问题。例如, 在 PINNs 中引入自适应权重分配机制, 对质量守恒方程等核心物理约束保留高精度计算, 对次要过程则采用代理模型, 从而实现效率与精度的优化。另外, 边缘计算部署、蒸馏压缩技术等也都是合适的方法。

发展因果驱动的可解释性技术是破解气候与城市内涝研究中黑箱问题的重要途径。例如, 通过引入工具变量或结构因果模型, 定量区分气候因素 (如降雨强度) 和城市形态因子 (如不透水面比例) 对内涝风险的直接效应与以城市微气候为中介的间接效应, 从而识别真正可干预的关键杠杆点。同时还可以建立混合不确定性传播框架, 融合蒙特卡洛 Dropout 与气候模式集合, 从而生成风险概率分布图, 此类框架旨在耦合来自气候情景 (偶然不确定性)、模型结构 (认知不确定性) 及城市暴露性参数 (知识不确定性) 的多源不确定性, 实现其传递、放大与聚合过程的端到端概率表征。

为应对上述挑战, 机器学习技术正从分散的工具应用, 演变为一系列结构化的“桥接”模式。下面将透过多尺度数据同化与特征转换、物理机理与数据驱动融合及不确定性量化与风险传递这 3 种具体模式及其案例分析, 系统阐释机器学习如何实质性地连接宏观气候系统与微观城市水文过程。

4 应对挑战的“桥梁”

经过系统的剖析, 可以发现城市内涝与气候风险耦合研究在数据、模型与验证等方面面临挑战。机器学习技术的价值, 在于其为系统性地应对这些跨学科难题提供结构化的“桥接”模式, 而不仅仅是分散的技术工具。在方法罗列基础之上, 本章节通过阐释 3 种典型的“桥梁”应用模式及其对应案例, 具体地展现机器学习如何实质性地连接宏观气候系统与微观城市水文过程, 从而推动研究从“技术应用”迈向“模式融合”。

4.1 多尺度数据同化与特征转换的桥梁

气候模型与城市水文模型之间存在着尺度不匹配及数据异构性方面的挑战。在这种情况下, 机器学习充当高维、跨尺度数据的“翻译器”与“融合器”。其核心功能在于, 将低分辨率、异构的气候系统输出 (如全球或区域气候模式结果) 转化为城市尺度模型可用的、具有物理一致性的高分辨率输入场, 直接弥合从千米级到米级的数据鸿沟。

实现这个过程主要依赖于时空融合神经网络, 它能够直接学习从粗尺度气候场到细尺度城市环境的复杂非线性映射函数^[72]。ConvLSTM 凭借其同步捕捉时空依赖性的能力被应用于构建端到端的“气候驱动-内涝响应”模型, 降低了对传统动力降尺度与分布式水文模型的过度依赖。Liao 等^[82]的研究是这一情况的典型例子, 他们开发了一种基于 ConvLSTM 的端到端城市洪水淹没快速预测模型, 该模型可以直接输入区域气候模式的输出或雷达反演的降雨场, 运用深度网络来学习历史暴雨事件中降雨时空模式与积水深度时空分布的复杂关系, 完成了从大范围降雨预报到街区级积水深度的快速映射。上面这个例子说明, 机器学习可以被看成一个高效的“数据转换桥梁”, 直接弥补了气候系统与城市系统间的尺度缺失, 大大提升了内涝预警的时空精度与时效性, 图 4 详细给出了整个研究过程。Xiao 等^[122]的实验强化了 ConvLSTM 的桥梁作用, 他们不但构建端到端的预测模型, 更重要的是系统设计了包含移动雨团中心的多样化降雨情景, 迫使模型必须学习降雨场动态空间结构与城市地表积水时空演化之间的复杂映射关系。该项研究表明机器学习桥梁能够有效编码并转换包含运动特征的降雨时空信息, 尽管机器学习模型本身是数据驱动的, 但其可以通过学习包含物理运动特征的降雨场, 得到比传统物理模型更高效的数据转换和高精度的淹没图。

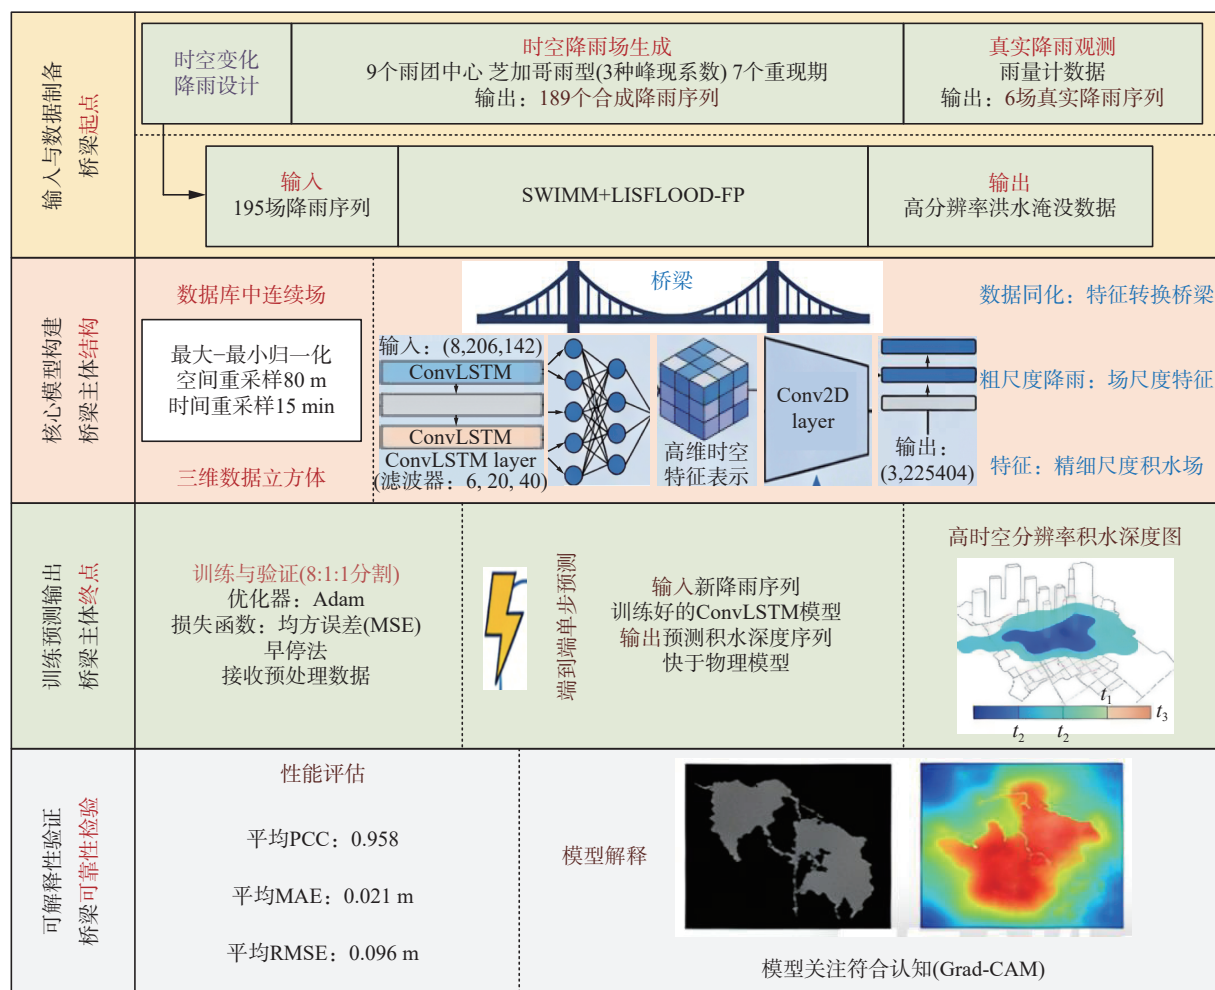


图 4 基于 ConvLSTM 的数据同化桥梁实现流程

Fig. 4 Implementation process of the data assimilation bridge based on ConvLSTM

此外, GAN 通过对抗性训练生成符合历史统计特征的合成气候极端场, 为数据稀缺场景的模型训练提供有效的数据增强手段^[54-55]。在应对极端事件数据稀缺方面, Sattari 等^[123]的工作提供“桥梁”在数据层面的具体构建方案。他们利用时间序列生成对抗网络 (TimeGAN), 融合气象驱动数据与观测流量, 生成物理统计特征一致的合成洪水事件序列。将生成数据用于训练 LSTM 预测模型后, 显著提升在飓风“哈维”等极端事件中的预报精度。这证明 GAN 可作为可靠的“数据合成桥梁”, 为下游的灾害预测模型提供丰富、合理的训练样本, 有效弥补历史极端样本不足的缺口。

然而, 这类纯数据驱动方法在训练数据范围外的物理一致性与可解释性, 仍是其面临的主要挑战。近期研究进一步探索基于 Transformer 等新型架构的时空序列预测方法在气象降尺度中的应用, 为提升跨尺度映射的精度与效率提供新方向。为了提高桥梁的物理可靠性和泛化性, Jin 等^[124]探索了物理引导和数据驱动方法的结合, 他们提

出了一种集成改进 Transformer 与物理耦合模型的新方法, 首先利用物理模型产生训练数据, 保证数据具有物理机理一致性; 然后再训练 Transformer 模型学习从降雨、地形等到淹没深度的复杂映射。这种方法其实是在架设“双驱动桥梁”: 物理模型保证知识基础的可靠性, 而深度学习模型则负责高效率、高精度的映射计算, 它们相互协同实现从复杂气候输入到城市内涝场景快速可信的转换。此外, Zhang^[125]在径流预测中引入的时空注意力门控循环单元 (STA-GRU) 模型的设计思路对“内涝预测桥梁”的改进很有启发, 该模型通过时空注意力机制, 能动态聚焦于输入序列中关键时间步与上游关键站点的信息, 从而更精准地捕捉影响下游流量的核心时空驱动因子。这样的机制若应用于城市内涝预测, 能够让模型更好地识别一场移动暴雨中对特定易涝区产生决定性影响的降雨时空片段, 从而提高“桥梁”的信息筛选与传递效率。

综上所述, 借助于各种技术手段, 机器学习在

很多层面扮演着连接气候系统与城市内涝系统的“数据同化与特征转换桥梁”, 促使相关研究从概念机制转向可验证、可优化的工程实践。

4.2 物理机理融合的建模桥梁

对于城市内涝和气候的相关研究, 纯数据驱动模型缺少物理一致性, 复杂机理模型的计算成本又比较高。在这种情况下, 机器学习可以充当物理规律的“编码器”与复杂系统的“代理模型”, 它能够将物理规律以软约束或硬约束形式嵌入到学习框架中, 或直接学习并替代昂贵的计算物理模型组件, 从而在保证满足现实物理规律的同时, 大幅提高效率, 实现机理可信性与模型灵活性的平衡。

PINNs 就是这种模式的代表, 通过将控制方的残差作为损失函数的一部分, 强制神经网络在训练中符合物理定律, 进而在数据稀疏区域也能产生合理的预测。Raissi 等^[91]提出的 PINNs 框架为用偏微分方程描述自然现象的求解提供了新范式。在水文研究方向, 李怡昕等^[92]利用 PINNs 求解扩散波方程对降雨强度进行预测, 成功将水动

力学方程作为先验知识硬性嵌入网络训练过程。该方法确保模型输出即使在数据不足的区域也能严格遵循物理机理, 显著提升了模型的泛化能力和可靠性。一个更具体的研究案例来自于 Donnelly 等^[126]的研究, 他们为两个广泛使用的水动力模拟器 (LISFLOOD-FP 用于内陆洪水, Delft3D 用于海岸洪水) 开发了新颖的 PINNs 代理模型。该模型的核心创新在于并非简单地将偏微分方程残差加入损失函数, 而是设计一个直接编码质量守恒定律的定制化物理约束损失函数。该模型以时空边界条件为输入, 直接输出全域高分辨率的水深或水位场。实验表明, 与纯数据驱动的卷积神经网络代理模型相比, 这种物理信息代理模型在预测精度有所提升, 同时其预测结果在体积守恒上更符合物理规律。此工作清晰地展示 PINNs 如何作为一个高效的“代理模型桥梁”, 一端接入气候或水文驱动条件, 另一端直接产出高保真的淹没模拟结果, 在保持物理一致性的同时, 将计算时间大大缩短。图 5 更为直接地体现了 PINNs 的桥梁融合过程。

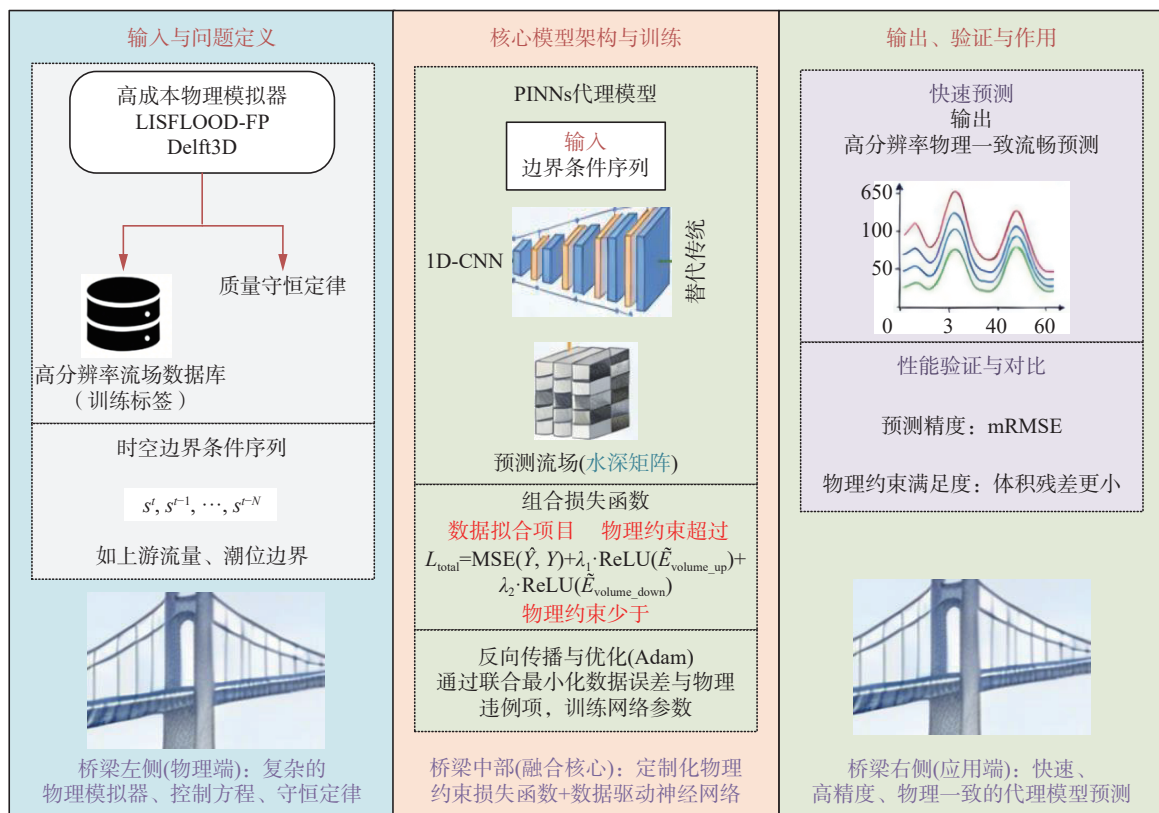


图 5 基于物理约束 PINNs 的机理融合桥梁实现流程

Fig. 5 Implementation process of the mechanism integration bridge based on physical constraint PINNs

混合建模则是将机器学习组件与传统物理模型结合, 如将机器学习用于参数化未解析过程或替代某个计算密集型子模块, 这种方法既能保持

核心机理可解释性也能提升整体的模拟效率^[90]。目前的相关研究致力于发展可微分物理模拟等框架, 以更好地实现物理定律与数据驱动的融合,

可微分建模就是这方面的一个典型。Feng 等^[127]的研究工作开发了一个可微分的水文模型,它将传统概念性水文模型的物理过程转化为可微分的计算图,并利用 LSTM 从流域特征和气象数据中学习模型的动态参数。整个系统以流域出口流量观测为唯一监督信号进行端到端训练。这种方法搭建了一个“学习型参数化桥梁”:物理模型框架保证水量平衡和过程机理,深度学习模块负责从数据中自适应地学习最优、最普适的参数映射关系。结果分析表明该模型在数据充沛区域的日径流预测性能接近顶尖的纯数据驱动 LSTM 模型,而在数据稀缺的外推区也展现出强壮稳健性和优秀的物理一致性。这标志着通过可微分编程将物理机理与数据驱动深度融合能够创建既可靠又可外推的学习系统,有效连接了气候强迫与水文响应。

这标志着机器学习已经从纯粹的“数据拟合器”转变为“物理规律的求解器”或“物理模型的加强器”,成为连接确定物理世界和不确定数据世界的桥梁。

4.3 不确定性量化与风险传递的评估桥梁

不确定性会贯穿从气候情景到内涝损失预测的整体研究过程。其中,复合不确定性管理的不足和预测可靠性评估的缺失一直是目前研究所面对的重要挑战。面临这种现状,机器学习能够充当不确定性“量化器”与风险贡献“追溯器”。它不仅能给出确定性的点预测,还能给出预测结果的概率分布,也能解析各类输入因素(气候因子、城市参数)对最终风险交互贡献度,以便能够基于风险做“精细”决策。

通过将网络权重视为概率分布, BNN 能够自然地给出关于预测的不确定性估计^[98]。近期的一些研究进一步展现了此类方法作为“不确定性量化桥梁”的具体实践。Houénafa 等^[128]的工作为物理模型与贝叶斯深度学习的结合提供了范例,他们将基于最小作用原理的水文模型(HyMoLAP)与贝叶斯 LSTM 相结合,构建一个多步径流与不确定性预报框架,在这个框架中 HyMoLAP 负责生成确定性的多日径流模拟序列,而贝叶斯 LSTM 则把这个序列作为输入,并输出未来径流的概率分布。在后续的相关应用中,该混合框架不仅能提供可靠的确定性预测,其不确定性量化结果也具有高可靠性。这也清晰地构建了一条从“物理模型模拟”到“概率化风险预报”的桥梁。另一项研究是从数据源角度拓展不确定性量化的边界,Zheng 等^[129]的工作利用贝叶斯深度学习框架,利

用城市监控摄像头视频这一非传统的数据源,转化为高时空分辨率的降雨强度估计及其不确定性。他们构建的贝叶斯 CNN-LSTM 模型,能够依靠视频图像序列实时估计降雨的强度,并同步得到结果的不确定性(如预测方差)。该方法为城市内涝模型的输入提供了包含可靠性信息的高分辨率降雨场,从本质上构建了一座从“新型观测数据”到“带不确定性量化的关键输入变量”的桥梁,降低了因输入数据不准确而造成的模型整体的不确定性。

通过结合可解释性人工智能技术(如 SHAP)可以量化不同驱动因子对内涝灾害的影响程度,并揭示深层次的非线性机制^[96]。Chu 等^[35]提出一个融合贝叶斯神经网络与 SHAP 方法的混合框架用于城市内涝预测,该框架不仅能输出积水深度的点估计和其置信区间,还能定量分解并确定时空效应对预测结果的贡献度,在图 6 中详细给出了该研究的过程,并凸显了机器学习相关方法是如何扮演研究中不确定性桥梁的。例如,分析能清晰揭示某次特定内涝事件中,极端降雨强度、局部地形低洼与排水管网容量不足各自的影响比例。这种基于博弈论的可解释性方法,在更大尺度的风险归因研究中发挥了关键作用。Liu 等^[130]整合遥感与机器学习,对哈萨克斯坦的洪水进行高分辨率时空分析与驱动因子归因。他们利用 RF 和 XGBoost 模型进行洪水分类,并采用 SHAP 框架定量解析降水量等多种环境与社会经济因子对洪水风险的贡献度。研究表明,降水变化、气温和土壤湿度是驱动该国北部、西南部和西部地区高洪水风险的主要因素。这个工作展示机器学习如何作为“风险归因桥梁”,连接“多源地理气候数据”与“明晰的致灾因子贡献图谱”,为制定有针对性的区域防洪减灾策略提供科学依据。在更精细的城市尺度上,Huang 等^[131]针对深圳市的城市内涝问题,系统比较多种回归方法与 SHAP 在量化致灾因子贡献中的表现。他们的研究发现,RF 模型能很好地捕捉某些因子与内涝之间的复杂非线性关系。SHAP 分析不仅给出全局性的因子重要性排序,更重要的是揭示关键驱动因子贡献度的空间异质性,即在城市不同区域,同一因子对内涝风险的影响程度与方式存在显著差异。这标志着机器学习作为“风险诊断桥梁”,已能从“整体风险评估”深入到“局部致灾机理解析”,为基于空间的差异化内涝治理措施提供直接决策支持。

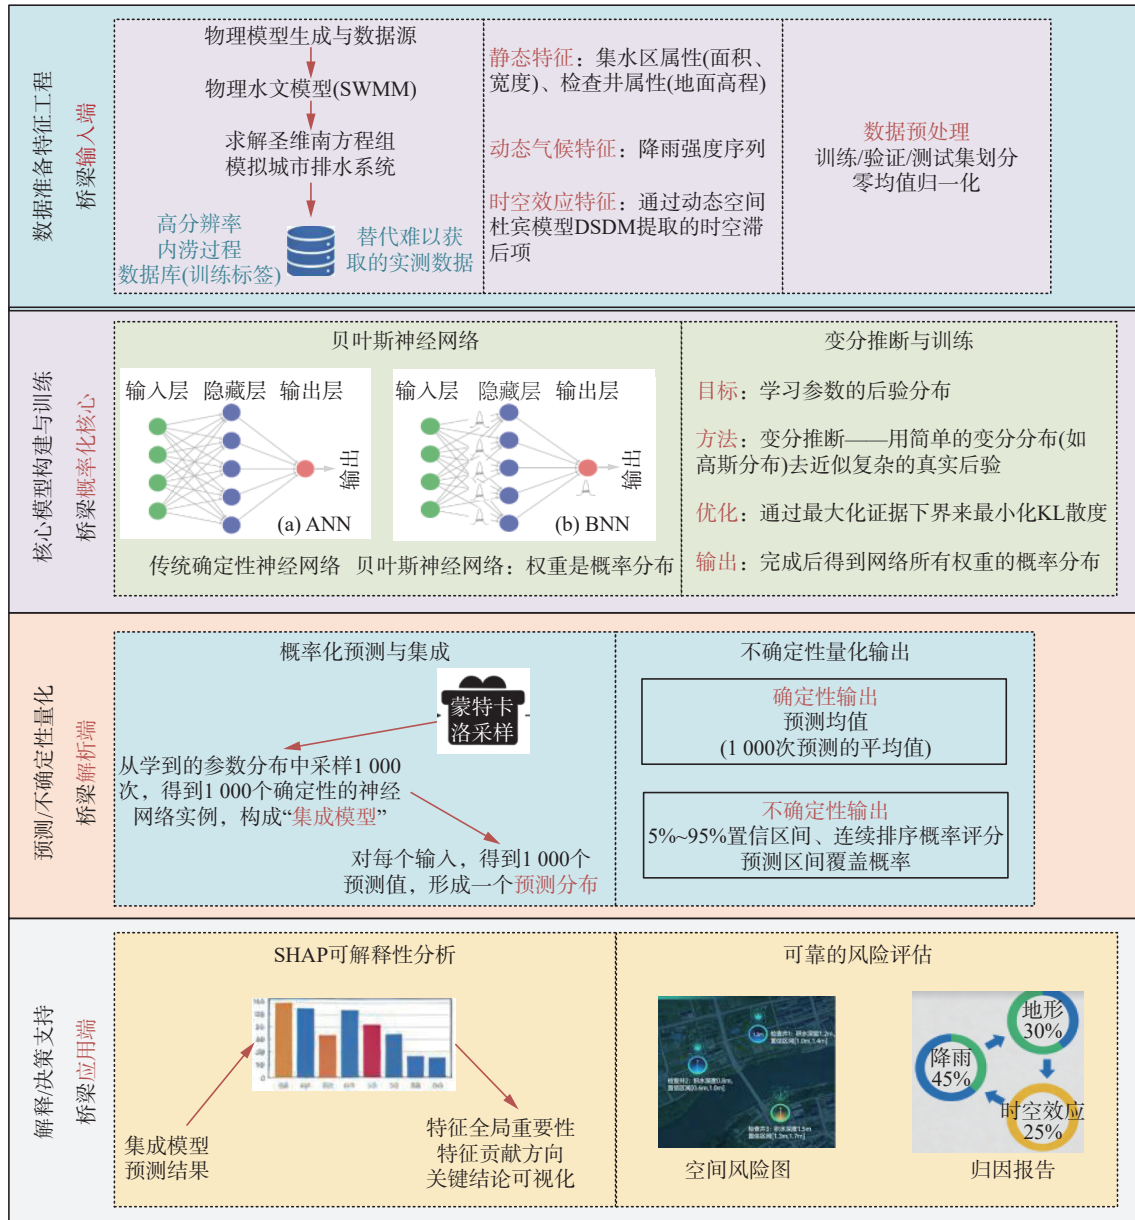


图 6 基于 BNN-SHAP 的不确定性量化与风险评估桥梁实现流程

Fig. 6 Implementation process of the bridge for uncertainty quantification and risk assessment based on BNN-SHAP

这些方法将机器学习从“黑箱”预测工具提升为“透明”的风险诊断系统, 构建从充满不确定性的气候输入到量化、可解释的风险决策输出的完整评估链条。未来的研究前沿在于发展统一的概率集成框架, 能够协同量化并追溯这些异质性不确定性的产生、放大与传递过程。例如, 构建深度集成模型以评估不同机器学习架构与输入数据扰的联合效应; 或开发耦合气候集合预报、水文模型集合与贝叶斯深度学习模型的级联不确定性传递分析系统。这类研究将推动机器学习从“局部不确定性量化器”向“系统风险透视镜”演进, 最终构建起从混沌的气候输入到透明、可靠的风险决策的坚固评估桥梁。

4.4 小结

综上所述, 机器学习并非以单一、模糊的方式充当“桥梁”, 而是通过多尺度数据同化与特征转换、物理机理与数据驱动融合、不确定性量化与风险传递这 3 种具体且互补的模式, 系统地应对城市内涝—气候风险耦合研究中的核心科学挑战。每一种模式都对应着从“核心科学问题”到“机器学习解决方案”的明确技术路径, 并有相应的实证研究案例作为支撑。未来的研究应致力于这 3 种模式的深度融合, 例如发展能够同时处理跨尺度、嵌入物理规律并提供不确定性估计的下一代智能模型, 以更全面地支撑气候适应型城市的规划与建设。

5 结束语

气候变化与城市发展的相互影响,使得城市内涝灾害日益频发,传统相对独立的气候科学与城市水文学研究之间存在明显的尺度、方法与耦合鸿沟。本文系统探讨机器学习作为连接这两大领域的桥梁作用,构建系统化的研究模式。

本文首先讨论气候因素与城市内涝的耦合机制及核心挑战,然后对机器学习在相关领域的关键技术进行综述。最重要的结果是通过总结对比,明确提出了机器学习充当“桥梁”的 3 种具体应用模式:作为多尺度数据同化与特征转换的桥梁、作为物理机理与数据驱动融合的建模桥梁以及作为不确定性量化与风险传递的评估桥梁。通过对相应的案例进行分析,这些模式能够实质性地解决核心科学问题,将宏观气候系统与微观城市水文过程有机结合起来;具体来说,数据同化与特征转换桥梁主要应对尺度不匹配和数据异构的挑战,物理机理融合的建模桥梁致力于解决物理一致性不足与模型效率的问题,不确定性量化与风险传递的评估桥梁则为管理复合不确定性提供了系统的工具。这些都展现了相关研究正从零散的技术应用迈向以机器学习为核心工具、旨在深度融合跨学科知识的系统化模式。

该领域也面临着挑战。在理论与方法层面,需推动 3 种“桥梁”模式的深度融合,探索能够同步处理跨尺度数据转换、嵌入物理约束并提供可靠不确定性估计的一体化智能模型框架。例如,发展可微分的、物理信息引导的生成模型,以协同解决数据生成、机理约束与风险量化问题。在技术与数据层面,需构建跨学科、跨部门的动态数据协作生态,利用联邦学习、区块链等隐私计算技术,在保障数据安全的前提下,实现多源异构数据的融合与共。在应用与决策层面,需发展基于“桥梁”模式的因果推断与决策支持系统,深度融合可解释性人工智能与因果发现技术,将模型的透明化输出对接至城市规划、应急管理和韧性评估的闭环决策流程中。

本文所阐释的跨学科研究框架与“桥梁”模式,为理解并应对气候变化下的城市内涝风险提供新视角和新路径,有助于推动城市水文学从被动响应向主动适应、智能调控的模式转变,为实现韧性与可持续的城市贡献力量。

参考文献:

[1] 赵超辉, 万金红, 张云霞, 等. 城市内涝特征、成因及应

对研究综述[J]. *灾害学*, 2023, 38(1): 220–228.

ZHAO Chaohui, WAN Jinhong, ZHANG Yunxia, et al. Review of the characteristics, causes and governance of urban flood in China[J]. *Journal of catastrophology*, 2023, 38(1): 220–228.

[2] 舒章康, 李文鑫, 张建云, 等. 中国极端降水和高温历史变化及未来趋势[J]. *中国工程科学*, 2022, 24(5): 116–125.

SHU Zhangkang, LI Wenxin, ZHANG Jianyun, et al. Historical changes and future trends of extreme precipitation and high temperature in China[J]. *Strategic study of CAE*, 2022, 24(5): 116–125.

[3] 张金良, 罗秋实, 王冰洁, 等. 城市极端暴雨洪涝灾害成因及对策研究进展[J]. *水资源保护*, 2024, 40(1): 6–15.

ZHANG Jinliang, LUO Qiushi, WANG Bingjie, et al. Research progress on causes and countermeasures for extreme rainstorm-induced urban flood disasters[J]. *Water resources protection*, 2024, 40(1): 6–15.

[4] IPCC. 气候变化 2023: 综合报告 [R]. 日内瓦: IPCC, 2023.

[5] 徐宗学, 陈浩, 任梅芳, 等. 中国城市洪涝致灾机理与风险评估研究进展[J]. *水科学进展*, 2020, 31(5): 713–724.

XU Zongxue, CHEN Hao, REN Meifang, et al. Progress on disaster mechanism and risk assessment of urban flood/waterlogging disasters in China[J]. *Advances in water science*, 2020, 31(5): 713–724.

[6] RIJAL M, LUO Pingping, MISHRA B K, et al. Global systematical and comprehensive overview of mountainous flood risk under climate change and human activities[J]. *Science of the total environment*, 2024, 941: 173672.

[7] XUE Fengchang, CHENG Yannian, SHEN Yufang, et al. Urban flood inundation area detection using YOLOv8 model[J]. *Water resources management*, 2025, 39(11): 5443–5460.

[8] GU Qian, CHAI Fuxin, ZANG Wenbin, et al. A two-level early warning system on urban floods caused by rainstorm[J]. *Sustainability*, 2025, 17(5): 2147.

[9] YANG Wenyu, ZHAO Ziyong, PAN Liping, et al. Integrated risk analysis for urban flooding under changing climates[J]. *Results in engineering*, 2024, 24: 103243.

[10] WANG Xiaorong, SUN Jichao. The temporal evolution characteristics of extreme rainfall in Shenzhen City, China[J]. *Sustainability*, 2025, 17(8): 3512.

[11] 林炜洁. 上海市降雨时空分布特征与城市内涝风险研究[D]. 北京: 中国水利水电科学研究院, 2024.

LIN Weijie. Research on the spatiotemporal distribution

- characteristics of rainfall and urban flood risk in Shanghai[D]. Beijing: China Institute of Water Resources and Hydropower Research, 2024.
- [12] 初祁, 周晋军, 徐宗学. 适用北京地区短历时强降水模拟的 WRF 模型物理参数化方案研究[J]. 北京师范大学学报 (自然科学版), 2019, 55(5): 617–626.
- CHU Qi, ZHOU Jinjun, XU Zongxue. Evaluation of the WRF model with different physical parameterization schemes in simulating short-duration heavy rainfall events in Beijing[J]. *Journal of Beijing Normal University (natural science)*, 2019, 55(5): 617–626.
- [13] GALANAKI E, LAGOUVARDOS K, KOTRONI V, et al. Implementation of WRF-Hydro at two drainage basins in the region of Attica, Greece, for operational flood forecasting[J]. *Natural hazards and earth system sciences*, 2021, 21(7): 1983–2000.
- [14] 侯精明, 董美君, 李东来, 等. 超标暴雨下城市雨水管网排水效果: 以西安市沣西新城为例[J]. *地球科学与环境学报*, 2023, 45(2): 427–436.
- HOU Jingming, DONG Meijun, LI Donglai, et al. Drainage effect of urban drainage-pipe network under extreme rainstorms: taking Fengxi new city in Xi'an City, China as an example[J]. *Journal of earth sciences and environment*, 2023, 45(2): 427–436.
- [15] LUO Pingping, YAN Peiyao, WANG Xiaohui, et al. Historical and comparative overview of sponge campus construction and future challenges[J]. *Science of the total environment*, 2024, 907: 167477.
- [16] CHEN Zhiwei, HUANG Guoru. Numerical simulation study on the effect of underground drainage pipe network in typical urban flood[J]. *Journal of hydrology*, 2024, 638: 131481.
- [17] JANG S D, YOO J H, LEE Y S, et al. Flood prediction in urban areas based on machine learning considering the statistical characteristics of rainfall[J]. *Progress in disaster science*, 2025, 26: 100415.
- [18] RASOOL U, YIN Xinan, XU Zongxue, et al. Rainfall-driven machine learning models for accurate flood inundation mapping in Karachi, Pakistan[J]. *Urban climate*, 2023, 49: 101573.
- [19] 林凯荣, 欧阳佳娜, 马旭民, 等. 基于深度学习的城市内涝积水水深预测模型[J]. *水资源保护*, 2025, 41(1): 56–63.
- LIN Kairong, OUYANG Jiana, MA Xumin, et al. Prediction model of urban waterlogging water depth based on deep learning[J]. *Water resources protection*, 2025, 41(1): 56–63.
- [20] 黄楚雯, 管永乐, 王洪发. 基于 RF-LSTM 模型的城市洪涝积水模拟研究[J]. *人民黄河*, 2025, 47(6): 50–56.
- HUANG Chuwen, GUAN Yongle, WANG Hongfa. Study on urban flood simulation based on RF-LSTM model[J]. *Yellow River*, 2025, 47(6): 50–56.
- [21] 陈泽明, 方序鸿, 李家叶, 等. 机器学习模型在城市内涝模拟预报中的应用综述[J]. *人民珠江*, 2025, 46(1): 9–22.
- CHEN Zeming, FANG Xuhong, LI Jiaye, et al. An overview of application of machine learning models in urban flood simulation and forecasting[J]. *Pearl river*, 2025, 46(1): 9–22.
- [22] 王化齐, 张戈, 李林, 等. 城市内涝风险识别、预警与韧性评估研究进展[J]. *灾害学*, 2023, 38(1): 136–140.
- WANG Huaqi, ZHANG Ge, LI Lin, et al. Risk identification, alarming, and resilience assessment of the urban waterlogging[J]. *Journal of catastrophology*, 2023, 38(1): 136–140.
- [23] IPCC. 气候变化 2021: 自然科学基础: 第一工作组报告[R]. 剑桥: 剑桥大学出版社, 2021.
- [24] 陈佩琪, 王兆礼, 曾照洋, 等. 城市化对流域水文过程的影响模拟与预测研究[J]. *水力发电学报*, 2020, 39(9): 67–77.
- CHEN Peiqi, WANG Zhaoli, ZENG Zhaoyang, et al. Assessing influence of future urbanization on hydrological process in typical river basin[J]. *Journal of hydro-electric engineering*, 2020, 39(9): 67–77.
- [25] 周添红, 唐佐槐, 褚俊英, 等. 极端暴雨条件下城市内涝模拟研究进展与展望[J]. *人民长江*, 2025, 56(5): 14–22, 30.
- ZHOU Tianhong, TANG Zuohuai, CHU Junying, et al. Progress and prospects of urban waterlogging simulation under extreme rainstorm conditions[J]. *Yangtze river*, 2025, 56(5): 14–22, 30.
- [26] ZHANG Chi, GU Xuezhi, YE Lei, et al. Climate informed non-stationary modeling of extreme precipitation in China[J]. *Water resources management*, 2023, 37(9): 3319–3341.
- [27] 张弛, 钟华, 江衍铭, 等. 不同雨型降雨对城市内涝的影响研究[J]. *自然灾害学报*, 2025, 34(3): 88–98.
- ZHANG Chi, ZHONG Hua, JIANG Yanming, et al. Study on effects of different rainfall patterns on urban flooding[J]. *Journal of natural disasters*, 2025, 34(3): 88–98.
- [28] DING Xingchen, LIAO Weihong, LEI Xiaohui, et al. Assessment of the impact of climate change on urban flooding: a case study of Beijing, China[J]. *Journal of water and climate change*, 2022, 13(10): 3692–3715.
- [29] AHN K H, AHMAD NAYAK M. Atmospheric River activities and their effects on precipitation over South Korea[J]. *Journal of hydrology*, 2022, 610: 127886.

- [30] CANNON F, HECHT C W, CORDEIRA J M, et al. Synoptic and mesoscale forcing of southern California extreme precipitation[J]. *Journal of geophysical research: atmospheres*, 2018, 123(24): 13, 714–13, 730.
- [31] 宋晓猛, 徐楠涛, 张建云, 等. 中国城市洪涝问题: 现状、成因与挑战[J]. *水科学进展*, 2024, 35(3): 357–373. SONG Xiaomeng, XU Nantao, ZHANG Jianyun, et al. Urban flooding in China: current status, causes and challenges[J]. *Advances in water science*, 2024, 35(3): 357–373.
- [32] ZHAO Lei, LEE X, SMITH R B, et al. Strong contributions of local background climate to urban heat islands[J]. *Nature*, 2014, 511(7508): 216–219.
- [33] ROSENZWEIG C, KAROLY D, VICARELLI M, et al. Attributing physical and biological impacts to anthropogenic climate change[J]. *Nature*, 2008, 453(7193): 353–357.
- [34] KIM H I, KIM B H. Flood hazard rating prediction for urban areas using random forest and LSTM[J]. *KSCE journal of civil engineering*, 2020, 24(12): 3884–3896.
- [35] CHU Wenhao, ZHANG Chunxiao, LI Heng, et al. SHAP-powered insights into spatiotemporal effects: Unlocking explainable Bayesian-neural-network urban flood forecasting[J]. *International journal of applied earth observation and geoinformation*, 2024, 131: 103972.
- [36] ZHOU Shiqi, JIA Weiye, WANG Mo, et al. Synergistic assessment of multi-scenario urban waterlogging through data-driven decoupling analysis in high-density urban areas: a case study in Shenzhen, China[J]. *Journal of environmental management*, 2024, 369: 122330.
- [37] 刘家宏, 石虹远, 梅超, 等. 城市下垫面空间格局对社区尺度内涝过程的影响模拟[J]. *水科学进展*, 2022, 33(6): 881–893. LIU Jiahong, SHI Hongyuan, MEI Chao, et al. Effect of urban subsurface spatial pattern on community-scale flooding processes via numerical simulation[J]. *Advances in water science*, 2022, 33(6): 881–893.
- [38] 燕超, 胡海波, 徐晓梅, 等. 模拟降雨条件下城市下垫面径流系数变化规律[J]. *中国水土保持科学 (中英文)*, 2022, 20(5): 24–30. YAN Chao, HU Haibo, XU Xiaomei, et al. Changing pattern of runoff coefficients in urban underlying surfaces under simulated rainfall conditions[J]. *Science of soil and water conservation*, 2022, 20(5): 24–30.
- [39] LE T T A, LAN-ANH N T, DASKALI V, et al. Urban flood hazard analysis in present and future climate after statistical downscaling: a case study in Ha Tinh city, Vietnam[J]. *Urban water journal*, 2021, 18(4): 257–274.
- [40] WANG Luyao, HUANG Zhenyu, GAN Bin, et al. Climate change impacts on magnitude and frequency of urban floods under scenario and model uncertainties[J]. *Journal of environmental management*, 2024, 366: 121679.
- [41] 占车生, 宁理科, 邹靖, 等. 陆面水文—气候耦合模拟研究进展[J]. *地理学报*, 2018, 73(5): 893–905. ZHAN Chesheng, NING Like, ZOU Jing, et al. A review on the fully coupled atmosphere-hydrology simulations[J]. *Acta geographica sinica*, 2018, 73(5): 893–905.
- [42] LI Dan, BOU-ZEID E. Synergistic interactions between urban heat islands and heat waves: the impact in cities is larger than the sum of its parts[J]. *Journal of applied meteorology and climatology*, 2013, 52(9): 2051–2064.
- [43] 宋鹏越, 徐宗学, 宋苏林, 等. 城市化进程对汛期降水特征的影响: 以济南市为例[J]. *北京师范大学学报 (自然科学版)*, 2024, 60(5): 617–624. SONG Pengyue, XU Zongxue, SONG Sulin, et al. Impact of urbanization on precipitation characteristics during flood period: case of Jinan city[J]. *Journal of Beijing Normal University (natural science)*, 2024, 60(5): 617–624.
- [44] 仇文岗, 王云浩, 胡庆芳, 等. 超大城市洪涝灾害成因综合解析: 以重庆市为例[J]. *土木与环境工程学报 (中英文)*, 2025, 47(1): 1–10. ZHANG Wengang, WANG Yunhao, HU Qingfang, et al. Comprehensive analysis on causes of flood disaster in megacities: a case study of Chongqing[J]. *Journal of civil and environmental engineering*, 2025, 47(1): 1–10.
- [45] SCHERRER S C, DE VALK C, BEGERT M, et al. Estimating trends and the current climate mean in a changing climate[J]. *Climate services*, 2024, 33: 100428.
- [46] 张伟, 王璇, 孙慧超, 等. 基于多重精度降雨数据的北京市极端降雨事件研究[J]. *水资源保护*, 2025, 41(2): 123–132, 157. ZHANG Wei, WANG Xuan, SUN Huichao, et al. Research on extreme precipitation events in Beijing based on multi-resolution rainfall data[J]. *Water resources protection*, 2025, 41(2): 123–132, 157.
- [47] KÜLLAHCİ K, ALTUNKAYNAK A. Maximizing daily rainfall prediction accuracy with maximum overlap discrete wavelet transform-based machine learning models [J]. *International journal of climatology*, 2024, 44(10): 3405–3426.
- [48] RAY M, SINGH K N, RAMASUBRAMANIAN V, et al. Integration of wavelet transform with ANN and WNN for time series forecasting: an application to Indian Monsoon rainfall[J]. *National academy science letters*, 2020, 43(6): 509–513.

- [49] 刘媛媛, 刘业森, 刘方华, 等. 基于流形学习算法的降雨数据时空分布特征提取及重构[J]. 水利水电技术(中英文), 2024, 55(9): 85–98.
- LIU Yuanyuan, LIU Yesen, LIU Fanghua, et al. Spatiotemporal distribution features of rainfall data extracting and reconstructing based on manifold learning algorithm[J]. Water resources and hydropower engineering, 2024, 55(9): 85–98.
- [50] 李超, 王贺, 付真真, 等. 河北“23·7”特大暴雨过程的多尺度特征分析[J]. 气候与环境研究, 2024, 29(4): 443–456.
- LI Chao, WANG He, FU Zhenzhen, et al. Multi-scale characteristics of the torrential rainfall in Hebei Province in July 2023[J]. Climatic and environmental research, 2024, 29(4): 443–456.
- [51] 薛春芳, 侯威, 赵俊虎, 等. 集合经验模态分解在区域降水变化多尺度分析及气候变化响应研究中的应用[J]. 物理学报, 2013, 62(10): 504–511.
- XUE Chunfang, HOU Wei, ZHAO Junhu, et al. The application of ensemble empirical mode decomposition method in multiscale analysis of region precipitation and its response to the climate change[J]. Acta physica sinica, 2013, 62(10): 504–511.
- [52] 罗那那, 巴特尔·巴克, 吴燕锋. 基于集合经验模态分解北疆降水多尺度变化特征[J]. 水土保持研究, 2017, 24(4): 362–367.
- LUO Nana, BAKE Batur, WU Yanfeng. Precipitation multi-scale characteristics by ensemble empirical mode decomposition in northern Xinjiang[J]. Research of soil and water conservation, 2017, 24(4): 362–367.
- [53] 焦阜生, 许小娟, 龚海波, 等. 基于集合经验模态分解去趋势的水分利用效率对气候变化响应的高程分异: 以“21 世纪海上丝绸之路”沿线省份为例[J]. 生态学报, 2022, 42(17): 6985–6996.
- JIAO Fusheng, XU Xiaojuan, GONG Haibo, et al. Elevation differences in the response of ecosystem water use efficiency to climate change based on EEMD detrending: a case study of the provinces along the “21st Century Maritime Silk Road”[J]. Acta ecologica sinica, 2022, 42(17): 6985–6996.
- [54] JI Hong kang, MIRZAEI M, LAI S H, et al. Implementing generative adversarial network (GAN) as a data-driven multi-site stochastic weather generator for flood frequency estimation[J]. Environmental modelling & software, 2024, 172: 105896.
- [55] LI Chen, ZHAO Zheng yang, LI Jia, et al. Attention-generative adversarial networks for simulating rain field[J]. IET image processing, 2024, 18(6): 1540–1549.
- [56] CHEN Huopo, SUN Jianqi. Future changes in daily snowfall events over China based on CMIP6 models[J]. Atmospheric and oceanic science letters, 2022, 15(5): 100137.
- [57] LEI Tianjie, WANG Jiabao, LI Xiangyu, et al. Flood disaster monitoring and emergency assessment based on multi-source remote sensing observations[J]. Water, 2022, 14(14): 2207.
- [58] 黄华兵, 王先伟, 柳林. 城市暴雨内涝综述: 特征、机理、数据与方法[J]. 地理科学进展, 2021, 40(6): 1048–1059.
- HUANG Huabing, WANG Xianwei, LIU Lin. A review on urban pluvial floods: Characteristics, mechanisms, data, and research methods[J]. Progress in geography, 2021, 40(6): 1048–1059.
- [59] 高伟, 沈秋, 李梦璠, 等. 基于多源遥感数据的洪涝淹没范围时序监测分析[J]. 测绘与空间地理信息, 2018, 41(7): 8–10, 14.
- GAO Wei, SHEN Qiu, LI Mengfan, et al. Analysis of time-serial monitoring of flood extent based on multi-source remote sensing data[J]. Geomatics & spatial information technology, 2018, 41(7): 8–10, 14.
- [60] DING Pengfei, LI Rong, DUAN Chenfei, et al. Flood monitoring based on multi-source remote sensing data fusion driven by HIS-NSCT model[J]. Water, 2025, 17(3): 396.
- [61] JIANG Wei, DANG Xupeng, ZHANG Rui. Empowering regional rainfall-runoff modeling through encoder–decoder based on convolutional neural networks[J]. Water, 2025, 17(3): 339.
- [62] 毛宇涛. 基于轻量化注意力机制与多模态特征融合的短临降水预测[D]. 杭州: 杭州电子科技大学, 2025.
- MAO Yutao. Design of lightweight attention mechanism and multimodal feature fusion for nowcasting precision plasmons[D]. Hangzhou: Hangzhou Dianzi University, 2025.
- [63] YANG Xu, DENG Cheng, LIU Tongliang, et al. Heterogeneous graph attention network for unsupervised multiple-target domain adaptation[J]. IEEE transactions on pattern analysis and machine intelligence, 2022, 44(4): 1992–2003.
- [64] 胡勇, 罗文, 俞肇元, 等. 多维时空场数据的多模式张量表达模型[J]. 武汉大学学报(信息科学版), 2015, 40(7): 977–982.
- HU Yong, LUO Wen, YU Zhaoyuan, et al. Multi-mode tensor expression model of multidimensional spatio-temporal field data[J]. Geomatics and Information Science of Wuhan University, 2015, 40(7): 977–982.
- [65] 单晶, 薛丰昌, 程瑶. 城市内涝 ChebNet-LSTM 积水预测模型[J]. 武汉大学学报(信息科学版), 2025, 50(6):

- 1225–1234.
- SHAN Jing, XUE Fengchang, CHENG Yao. ChebNet-LSTM waterlogging prediction model for urban flooding[J]. *Geomatics and Information Science of Wuhan University*, 2025, 50(6): 1225–1234.
- [66] 代鑫, 黄弘, 汲欣愉, 等. 基于机器学习的城市暴雨内涝时空快速预测模型[J]. *清华大学学报(自然科学版)*, 2023, 63(6): 865–873.
- DAI Xin, HUANG Hong, JI Xinyu, et al. Spatiotemporal rapid prediction model of urban rainstorm waterlogging based on machine learning[J]. *Journal of Tsinghua University (science and technology)*, 2023, 63(6): 865–873.
- [67] 门宝辉, 吕行, 陈仕豪, 等. 基于 CMIP6 耦合 WRF 的黄河上游复合干旱热浪事件演变规律[J]. *水利学报*, 2024, 55(8): 908–919.
- MEN Baohui, LÜ Xing, CHEN Shihao, et al. Evolution law of compound drought and heatwave events in the upper Yellow River Basin based on CMIP6 coupled WRF[J]. *Journal of hydraulic engineering*, 2024, 55(8): 908–919.
- [68] 王懿雯. 基于 CMIP6 的城市降雨预估及 LID 设施气候适应性优化布局研究[D]. 北京: 北京建筑大学, 2024.
- WANG Yiwen. CMIP6-based urban rainfall prediction and optimal layout of LID facilities for climate adaptation[D]. Beijing: Beijing University of Civil Engineering and Architecture, 2024.
- [69] RAMPAL N, GIBSON P B, SHERWOOD S, et al. A reliable generative adversarial network approach for climate downscaling and weather generation[J]. *Journal of advances in modeling earth systems*, 2025, 17: e2024MS004668.
- [70] 殷仕明, 徐炜, 熊一橙, 等. 基于迁移学习的长短时记忆神经网络水文模型[J]. *水力发电学报*, 2022, 41(6): 53–64.
- YIN Shiming, XU Wei, XIONG Yicheng, et al. Hydrological model based on long short-term memory neural network and transfer learning[J]. *Journal of hydroelectric engineering*, 2022, 41(6): 53–64.
- [71] 栾定彬. 基于生成对抗网络和迁移学习的洪水预测模型增强方法研究[D]. 西安: 西安电子科技大学, 2023.
- LUAN Dingbin. Research on flood forecast model enhancement method based on generative adversarial networks and transfer learning[D]. Xi'an: Xidian University, 2023.
- [72] 赵杏杏, 左翔, 蔡文静, 等. 考虑时空特征的城市内涝智能预报模型研究[J]. *人民长江*, 2024, 55(7): 20–28.
- ZHAO Xingxing, ZUO Xiang, CAI Wenjing, et al. Study on urban waterlogging intelligent forecast model considering temporal and spatial characteristics[J]. *Yangtze river*, 2024, 55(7): 20–28.
- [73] 徐楠涛, 宋晓猛, 陈昊, 等. 土地利用变化情景下南京市内涝风险演化与预测[J]. *中国农村水利水电*, 2024(12): 35–42, 51.
- XU Nantao, SONG Xiaomeng, CHEN Hao, et al. Evolution and prediction of waterlogging risk in Nanjing City under the land use changes[J]. *China rural water and hydropower*, 2024(12): 35–42, 51.
- [74] BREIMAN L. Random forests[J]. *Machine language*, 2001, 45(1): 5–32.
- [75] 盛志军, 周雨, 孟明华, 等. 基于随机森林算法的城市内涝风险预估方法及应用—以南昌市为例[J]. *暴雨灾害*, 2025, 44(1): 93–101.
- SHENG Zhijun, ZHOU Yu, MENG Minghua, et al. Method and application of urban waterlogging risk prediction based on the random forest algorithm-taking Nanchang as an example[J]. *Torrential rain and disasters*, 2025, 44(1): 93–101.
- [76] 佟金萍, 张涵玥, 刘辉, 等. 基于 XGBoost 的长三角核心城市内涝风险评估及影响因素分析[J]. *水利水电技术(中英文)*, 2021, 52(10): 1–11.
- TONG Jinping, ZHANG Hanyue, LIU Hui, et al. XGBoost model-based risk assessment and influencing factors analysis of waterlogging in core cities of Yangtze River Delta[J]. *Water resources and hydropower engineering*, 2021, 52(10): 1–11.
- [77] MA Meihong, ZHAO Gang, HE Bingshun, et al. XGBoost-based method for flash flood risk assessment[J]. *Journal of hydrology*, 2021, 598: 126382. [LinkOut]
- [78] 宋晓猛, 张建云, 王国庆, 等. 变化环境下城市水文学的发展与挑战: II. 城市雨洪模拟与管理[J]. *水科学进展*, 2014, 25(5): 752–764.
- SONG Xiaomeng, ZHANG Jianyun, WANG Guoqing, et al. Development and challenges of urban hydrology in a changing environment: II: Urban stormwater modeling and management[J]. *Advances in water science*, 2014, 25(5): 752–764.
- [79] BURRICHTER B, HOFMANN J, KOLTERMANN DA SILVA J, et al. A spatiotemporal deep learning approach for urban pluvial flood forecasting with multi-source data[J]. *Water*, 2023, 15(9): 1760.
- [80] CHEN Jian, LI Yaowei, ZHANG Shanju. Fast prediction of urban flooding water depth based on CNN-LSTM[J]. *Water*, 2023, 15(7): 1397.
- [81] HUANG Hao, WANG Zhaoli, LIAO Yaoxing, et al. Improving the explainability of CNN-LSTM-based flood prediction with integrating SHAP technique[J]. *Ecology*

- gical informatics, 2024, 84: 102904.
- [82] LIAO Yaoxing, WANG Zhaoli, YU Haijun, et al. Accelerating urban flood inundation simulation under spatiotemporally varying rainstorms using ConvLSTM deep learning model[J]. *Water resources research*, 2025, 61(8): e2025WR040433.
- [83] DU Bingkun, WANG Min, ZHANG Jinping, et al. Urban flood prediction based on PCSWMM and stacking integrated learning model[J]. *Natural hazards*, 2025, 121(2): 1971–1995.
- [84] VAN ENGELEN J E, HOOS H H. A survey on semi-supervised learning[J]. *Machine learning*, 2020, 109(2): 373–440.
- [85] HARRIS L, MCRAE A T T, CHANTRY M, et al. A generative deep learning approach to stochastic downscaling of precipitation forecasts[J]. *Journal of advances in modeling earth systems*, 2022, 14(10): e2022MS003120.
- [86] PARMAR A, MISTREE K, SOMPURA M. Machine learning techniques for rainfall prediction: a review[C]//International Conference on Innovations in Information Embedded and Communication Systems. 2017, 3: 6.
- [87] CHEN Liuyi, HAN Bocheng, WANG Xuesong, et al. Machine learning methods in weather and climate applications: a survey[J]. *Applied sciences*, 2023, 13(21): 12019.
- [88] HANNACHI A, JOLLIFFE I T, STEPHENSON D B. Empirical orthogonal functions and related techniques in atmospheric science: a review[J]. *International journal of climatology*, 2007, 27(9): 1119–1152.
- [89] LIU F T, TING Kai ming, ZHOU Zhihua. Isolation forest[C]//2008 Eighth IEEE International Conference on Data Mining. Pisa: IEEE, 2008: 413–422.
- [90] KARPATNE A, ATLURI G, FAGHMOUS J H, et al. Theory-guided data science: a new paradigm for scientific discovery from data[J]. *IEEE transactions on knowledge and data engineering*, 2017, 29(10): 2318–2331.
- [91] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. *Journal of computational physics*, 2019, 378: 686–707.
- [92] 李怡昕, 侯庆志, 孙泽玮. 基于物理信息神经网络和扩散波模型的降雨强度预测[C]//第六届城市水安全与水管理学术研讨会论文集. 天津: 中国水利学会城市水利专业委员会, 《中国防汛抗旱》杂志社, 水利部防洪抗旱减灾工程技术研究中心, 2023: 152–156.
- [93] MARAUN D, WETTERHALL F, IRESO A M, et al. Precipitation downscaling under climate change: Recent developments to bridge the gap between dynamical models and the end user[J]. *Reviews of geophysics*, 2010, 48(3): RG3003.
- [94] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[C]//Proceedings of the 34th International Conference on Machine Learning. Sydney: PMLR, 2017: 1126–1135.
- [95] 邱伟峰. 基于隐特征连续化的分钟级定量降水估计算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2021.
- QIU Weifeng. Research on minute-level quantitative precipitation estimation algorithm based on hidden feature continuation[D]. Harbin: Harbin Institute of Technology, 2021.
- [96] FU Xiaoping, WANG Mo, ZHANG Dongqing, et al. An XGBoost-SHAP framework for identifying key drivers of urban flooding and developing targeted mitigation strategies[J]. *Ecological indicators*, 2025, 175: 113579.
- [97] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization[C]//2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 618–626.
- [98] GAL Y, GHAHRAMANI Z. Dropout as a Bayesian approximation: representing model uncertainty in deep learning[C]//Proceedings of the 33rd International Conference on International Conference on Machine Learning. New York: PMLR, 2016: 1050–1059.
- [99] RUDIN C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead[J]. *Nature machine intelligence*, 2019, 1(5): 206–215.
- [100] 靳庆文. 情报分析中的可解释性技术及其评价方法研究[J]. *情报资料工作*, 2023, 44(4): 24–34.
- JIN Qingwen. Research on interpretability technology and evaluation method in information analysis[J]. *Information and documentation services*, 2023, 44(4): 24–34.
- [101] WANG Chen, HOU Jingming, MILLER D, et al. Flood risk management in sponge cities: The role of integrated simulation and 3D visualization[J]. *International journal of disaster risk reduction*, 2019, 39: 101139.
- [102] XIA Xilin, LIANG Qihua, MING Xiaodong, et al. An efficient and stable hydrodynamic model with novel source term discretization schemes for overland flow and flood simulations[J]. *Water resources research*, 2017, 53(5): 3730–3759.
- [103] 薛丰昌, 孙琳丽, 李育慧, 等. 城市内涝空间模态识别及其尺度转换模型[J]. *武汉大学学报(信息科学版)*, 2025, 50(6): 1191–1199.

- XUE Fengchang, SUN Linli, LI Yuhui, et al. Spatial modal identification of urban waterlogging and its scale conversion model[J]. *Geomatics and Information Science of Wuhan University*, 2025, 50(6): 1191–1199.
- [104] 王兆礼, 陈昱宏, 赖成光. 基于 TELEMAC-2D 和 SWMM 模型的城市内涝数值模拟[J]. *水资源保护*, 2022, 38(1): 117–124.
- WANG Zhaoli, CHEN Yuhong, LAI Chengguang. Numerical simulation of urban waterlogging based on TELEMAC-2D and SWMM model[J]. *Water resources protection*, 2022, 38(1): 117–124.
- [105] 陈明星, 先乐, 王朋岭, 等. 气候变化与多维度可持续城市化[J]. *地理学报*, 2021, 76(8): 1895–1909.
- CHEN Mingxing, XIAN Yue, WANG Pengling, et al. Climate change and multi-dimensional sustainable urbanization[J]. *Acta geographica sinica*, 2021, 76(8): 1895–1909.
- [106] 徐宗学, 舒心怡, 叶陈雷. 融合自然-社会属性的城市洪涝韧性评估[J]. *人民黄河*, 2025, 47(9): 55–61, 69.
- XU Zongxue, SHU Xinyi, YE Chenlei. Urban flood resilience assessment integrating natural-social attributes[J]. *Yellow river*, 2025, 47(9): 55–61, 69.
- [107] 叶陈雷, 徐宗学, 李小雁. 城市洪涝智慧控制与社会系统响应思考及探讨[J]. *中国水利*, 2025(5): 37–43.
- YE Chenlei, XU Zongxue, LI Xiaoyan. Exploration and discussion on smart control and social system response of urban flooding[J]. *China water resources*, 2025(5): 37–43.
- [108] 熊立华, 闫磊, 李凌琪, 等. 变化环境对城市暴雨及排水系统影响研究进展[J]. *水科学进展*, 2017, 28(6): 930–942.
- XIONG Lihua, YAN Lei, LI Lingqi, et al. Advances in analysis of impacts of changing environments on extreme urban rainfall and drainage infrastructure[J]. *Advances in water science*, 2017, 28(6): 930–942.
- [109] RASP S, PRITCHARD M S, GENTINE P. Deep learning to represent subgrid processes in climate models[J]. *Proceedings of the national academy of sciences of the United States of America*, 2018, 115(39): 9684–9689.
- [110] TSAI W P, FENG Dapeng, PAN Ming, et al. From calibration to parameter learning: Harnessing the scaling effects of big data in geoscientific modeling[J]. *Nature communications*, 2021, 12: 5988.
- [111] REICHSTEIN M, CAMPS-VALLS G, STEVENS B, et al. Deep learning and process understanding for data-driven Earth system science[J]. *Nature*, 2019, 566(7743): 195–204.
- [112] KENDON E J, BAN N, ROBERTS N M, et al. Do convection-permitting regional climate models improve projections of future precipitation change?[J]. *Bulletin of the American meteorological society*, 2017, 98(1): 79–93.
- [113] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//*Proceedings of the 28th International Conference on Neural Information Processing Systems*. Montreal: Curran Associates Inc. , 2014: 2672–2680.
- [114] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. *Journal of computational physics*, 2019, 378: 686–707.
- [115] BEUCLER T, PRITCHARD M, RASP S, et al. Enforcing analytic constraints in neural networks emulating physical systems[J]. *Physical review letters*, 2021, 126(9): 098302.
- [116] 王船海, 郑世威, 李小宁, 等. 基于太湖流域模型的城市内涝过程高效模拟[J]. *水科学进展*, 2022, 33(3): 462–473.
- WANG Chuanhai, ZHENG Shiwei, LI Xiaoning, et al. Efficient simulation of urban flood inundation based on Taihu Lake basin model[J]. *Advances in water science*, 2022, 33(3): 462–473.
- [117] 王俊琿, 侯精明, 同玉, 等. 局部时间步长与 GPU 加速的非均匀网格模型在内涝模拟中的应用[J]. *水动力学研究与进展 A 辑*, 2023, 38(5): 718–728.
- WANG Junhui, HOU Jingming, TONG Yu, et al. Application of local time step and GPU-accelerated non-uniform grid model in waterlogging simulation[J]. *Chinese journal of hydrodynamics*, 2023, 38(5): 718–728.
- [118] HU Xiande, GU Fenfei. Optimization strategies for urban waterlogging warning in complex environments: based on particle swarm optimization and deep neural networks[J]. *Advances in civil engineering*, 2024, 2024(1): 9601590.
- [119] GUO Zifeng, LEITÃO J P, SIMÕES N E, et al. Data-driven flood emulation: Speeding up urban flood predictions by deep convolutional neural networks[J]. *Journal of flood risk management*, 2021, 14: e12684.
- [120] ADADI A, BERRADA M. Peeking inside the black-box: a survey on explainable artificial intelligence (XAI)[J]. *IEEE access*, 2018, 6: 52138–52160.
- [121] 张建云, 王银堂, 贺瑞敏, 等. 中国城市洪涝问题及成因分析[J]. *水科学进展*, 2016, 27(4): 485–491.
- ZHANG Jianyun, WANG Yintang, HE Ruimin, et al. Discussion on the urban flood and waterlogging and causes analysis in China[J]. *Advances in water science*,

- 2016, 27(4): 485–491.
- [122] XIAO Jiaqi, WANG Zhaoli, LIAO Yaoxing, et al. A ConvLSTM-based model for urban flood prediction under dynamic rainfall patterns and exploration on its extrapolation capability[J]. *International journal of disaster risk science*, 2025, 16(6): 1057–1073.
- [123] SATTARI A, MORADKHANI H. Coping with data scarcity in extreme flood forecasting: a deep generative modeling approach[J]. *Advances in water resources*, 2025, 204: 105063.
- [124] JIN Hengxu, LU Haipeng, ZHAO Yu, et al. Integration of an improved transformer with physical models for the spatiotemporal simulation of urban flooding depths[J]. *Journal of hydrology: regional studies*, 2024, 51: 101627.
- [125] ZHANG Yue, ZHOU Zimo, DENG Ying, et al. Daily streamflow forecasting using networks of real-time monitoring stations and hybrid machine learning methods[J]. *Water*, 2024, 16(9): 1284.
- [126] DONNELLY J, DANESHKHAH A, ABOLFATHI S. Physics-informed neural networks as surrogate models of hydrodynamic simulators[J]. *Science of the total environment*, 2024, 912: 168814.
- [127] FENG Dapeng, BECK H, LAWSON K, et al. The suitability of differentiable, physics-informed machine learning hydrologic models for ungauged regions and climate change impact assessment[J]. *Hydrology and earth system sciences*, 2023, 27(12): 2357–2373.
- [128] EZÉCKIEL HOUÉNAFA S, JOHNSON O, RONO E K, et al. Multi-step ahead streamflow and uncertainty forecasting using a HyMoLAP rainfall-runoff model-based framework integrated with Bayesian neural networks in the Ouémé river basin, Benin[J]. *PLoS One*, 2025, 20(10): e0333590.
- [129] ZHENG Feifei, YIN Hang, ZHANG Jiangjiang, et al. A Bayesian deep learning approach for video-based estimation and uncertainty quantification of urban rainfall intensity[J]. *Journal of hydrology*, 2024, 640: 131706.
- [130] LIU Yixuan, SAMAT A, DU Peijun, et al. High-resolution spatiotemporal analysis and driver attribution of floods in Kazakhstan using SHAP and remote sensing integration[J]. *Climate risk management*, 2026, 51: 100783.
- [131] HUANG Xi, YANG Linhan, YANG Guicheng, et al. Exploring the optimal method for quantifying the contribution of driving factors of urban floods[J]. *International journal of applied earth observation and geoinformation*, 2025, 140: 104597.

作者简介:



齐小刚, 教授, 博士生导师, 博士, 主要研究方向为复杂系统建模与仿真、网络算法设计与应用。主持国家自然科学基金项目等国家和省部级项目 20 余项。发表学术论文 100 余篇。E-mail: xgqi@xidian.edu.cn。



张旭, 博士研究生, 主要研究方向为数据挖掘、大数据与人工智能、城市内涝自然灾害预防与治理。E-mail: zhangxu_0984@163.com。



李家慧, 博士后, 助理研究员, 主要研究方向为数据处理、网络优化、故障诊断。E-mail: lijiahui@xidian.edu.cn。