

深度学习技术在洪水预报中的应用进展及思考*

祁海霞^{1,2} 彭涛^{1,2} 智协飞³ 季焱⁴ 殷志远¹

沈铁元¹ 王俊超¹ 向怡衡¹ 胡泊¹

1 中国气象局武汉暴雨研究所 全国暴雨研究中心/中国气象局流域强降水重点开放实验室/
暴雨监测预警湖北省重点实验室, 武汉 430205

2 三峡国家气候观象台, 湖北宜昌 443099

3 南京信息工程大学气象灾害预报预警与评估协同创新中心, 南京 210044

4 无锡学院大气与遥感学院, 江苏无锡 214105

提 要: 洪水预报是降低洪灾损失、增强韧性非工程措施的有效途径, 实现精准洪水预报是水文领域的关键技术挑战之一。目前, 基于物理机制的洪水预报模型在模拟精度和效率上仍有不足, 而采用深度学习技术构建的预报模型则得到了迅猛发展。文章全面回顾和总结了洪水预报领域所应用的深度学习模型的原理和特点, 及其在洪水定量和概率预报中的应用进展和存在的问题。聚焦介绍和探讨了深度学习模型与洪水物理模型在物理过程参数化、可解释性研究、洪水预报模型误差校正等方面的契合点和应用前景。研究认为, 深度学习未来将走向与物理模型的深度耦合, 成为洪水时间序列预报的重要发展范式, 并将是实现未来水利智慧化的重要研究内容。最后针对深度学习在洪水预报中的难点给出几点思考, 对当前面临的挑战提出几点相应的解决方案, 以便更好地在洪水预报领域探索应用深度学习技术。

关键词: 深度学习, 洪水预报, 定量预报, 概率预报, 耦合物理模型

中图分类号: P456

文献标志码: A

DOI: 10.7519/j.issn.1000-0526.2025.031301

Progress and Reflection on Application of Deep Learning Techniques in Flood Forecasting

QI Haixia^{1,2} PENG Tao^{1,2} ZHI Xiefei³ JI Yan⁴ YIN Zhiyuan¹ SHEN Tiejuan¹

WANG Junchao¹ XIANG Yiheng¹ HU Po¹

1 Heavy Rainfall Research Center of China/CMA Basin Heavy Rainfall Key Laboratory/Hubei Key Laboratory for Heavy Rain Monitoring and Warning Research, Institute of Heavy Rain, CMA, Wuhan 430205

*湖北省自然科学基金创新发展联合基金项目(2022CFD129、2023AFD094)、中国气象局创新发展专项(CXFZ2024P043)、长江流域气象开放基金项目(CJLY2022Y06)、湖北省气象局面上基金项目(2022Y06)、贵州省科技厅自然科学面上项目(黔科合基础-zk[2025]面上 319)、湖南省气象局重点项目(XQKJ22A005)、中国气象局流域强降水重点开放实验室基金项目(2023BHR-Y26)和中国气象局武汉暴雨研究所基本科研业务专项(WHHRKYYW202404)共同资助

2024年12月3日收稿; 2025年3月13日收修定稿

第一作者: 祁海霞, 主要从事深度学习技术在气象和水文预报中的应用研究. E-mail: qxynl@163.com

通讯作者: 彭涛, 主要从事水文气象预报研究. E-mail: pt_mail@sohu.com

2 Sanxia National Climate Observatory, Hubei, Yichang 443099

3 Collaborative Innovation Center on Forecast and Evaluation of Meteorological Disasters (CIC-FEMD), Nanjing University of Information Science and Technology, Nanjing University of Information Science & Technology, Nanjing 210044

4 College of Atmosphere and Remote Sensing, Wuxi university, Jiangsu, Wuxi 214105

Abstract: Flood forecasting is an effective non engineering measure to reduce flood losses and enhance resilience. And accurate flood forecasting is one of the key technical challenges in the hydrological field. At present, flood forecasting models based on physical mechanisms still have shortcomings in simulation accuracy and efficiency, while forecasting models constructed by using deep learning techniques have experienced rapid development. This study comprehensively reviews the principles and characteristics of deep learning models applied in the field of flood forecasting. It summarizes the progress and problems in the application of deep learning models for quantitative and probabilistic flood forecasting. The study also explores the relevance and application prospects of deep learning models in relation to flood physics models, particularly in the parameterization of physical processes, interpretability studies, and error correction of flood forecasting models. It is believed that deep coupling with physical models is the future development direction of deep learning models, which will be an important development paradigm for the time series prediction of flood, and an important research component for realizing the water resource intelligence in the future. Finally, a few thoughts are given on the difficulties of deep learning in flood forecasting, and corresponding solutions are proposed for the current challenges, in order to better explore the application of deep learning technology in the field of flood forecasting.

Key words: deep learning, flood forecasting, quantitative forecasting, probabilistic forecasting, coupling physical model

引 言

洪水作为自然界中最致命且破坏性极强的灾害之一,直接威胁着人类的生命安全和财产安全。精准的洪水预报是科学防洪、抗旱、水资源管理和增强韧性非工程措施的有效途径。如何实现精准的洪水预报是水文领域的研究热点和关键挑战之一。目前,洪水预报技术主要采用物理过程模型和数据驱动模型两种主流方法。由于洪水过程在不同流域、不同空间尺度和不同时间尺度上存在较大差异,导致物理模型的可移植性较差。此外,物理模型存在结构复杂、参数率定困难和非线性强等问题,这在实际预报应用中往往限制了其效果(Hao et al, 2018; 刘攀等, 2021)。深度学习模型具有强大的特征学习、非线性映射和容错能力,可在没有物理公式约束下直接挖掘洪水数据内部的非线性特征。因此,在山区小流域观测数据欠缺、洪水预报物理机理不明确的情境下,深度学习模型展现出显著的优势(Hinton et al, 2006; 张然等, 2023)。在洪水预报中,通过挑选合适的深度学习框架并调整模型超参数,可以训练和预报涵盖时间和空间的长历史序列资料,从而挖掘洪水预报变量序列与其相关的预报因

子之间的映射关系，进而提高洪水预报精度。

本文系统地分析了深度学习技术在洪水定量预报和概率预报中的研究进展，总结了深度学习模型与物理模型的耦合方向，包括改进物理模型参数化模块、耦合物理模型的预报结果、研究模型的可解释性和校正物理模型预报误差等。针对深度学习模型在洪水预报方面的局限性和难点，提出了几点思考和展望，旨在为挖掘深度学习技术在洪水预报领域的应用提供参考和借鉴。

1 深度学习在洪水定量预报中的应用

在洪水预报中，目前常用的深度学习模型有循环神经网络(RNN)、长短期记忆神经网络(LSTM)、卷积神经网络(CNN)、门控制循环单元网络(GRU)、U-NET、Transformer、生成式对抗神经网络(GANs)、自编码器(AE)和图神经网络(GNN)等9种单一模型及其两种或多种网络构建的混合模型。深度学习模型主要流程如图1所示。

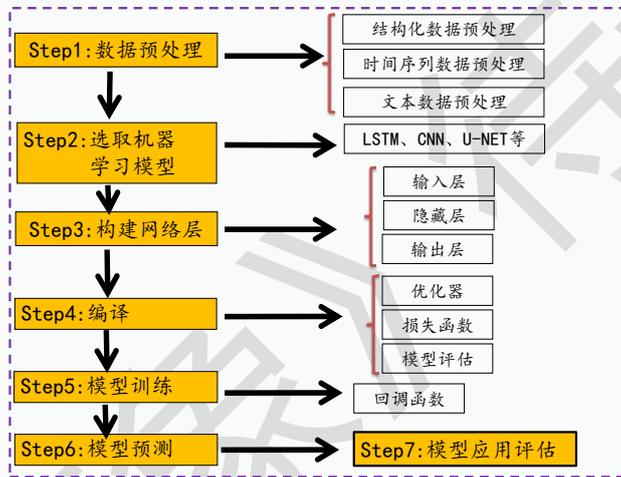


图1 深度学习流程图

Fig.1 Flowchart of deep learning

在洪水预报领域，有必要考虑到洪水预报属于时序预报问题，进而依据不同的深度学习框架特征，构建适用性强的预报模型(黄骄文等，2021；陈鹤等，2022；袁凯等，2022)。表1对多种深度学习框架的结构特征、优点和局限性及优化方法进行了归纳总结。

表1 洪水预报中常用的9种深度学习模型的结构特征、优点、局限性及优化方法

Table 1 Advantage and limitation of deep learning model for flood forecasting

网络框架	主要结构特征	优点	局限性及优化方法
RNN	递归神经网络，循环单元构成链式连接，随时间反向传播，双向循环神经网络和 LSTM 是常见的循环神经网络	存储能力强；具有记忆力，处理序列数据高效；参数共享，模型参数少；适用于时间序列数据分析	容易出现梯度消失和梯度爆炸；难以并行化；对于过长序列，无法有效捕捉长期依赖关系；对于过短序列，无法充分学习序列中的特征。可采用梯度截断、正则化、层归一化、LSTM、GRU 等有效解决

LSTM	递归神经网络，监督和非监督学习，常见网络为双向循环神经网络和 LSTM，核心部分以链式相连的循环单元，前馈神经网络算法	具有记忆性，权重共享，可提取序列中随时间变化的特征；状态空间的紧致性没有限制；泛化能力强；是一个无限冲激响应滤波器；更适用于时间序列数据的分析	难以并行计算；容易出现梯度消失和梯度爆炸；可解释性差。可通过梯度截断、正则化、层归一化、跳跃连接、渗漏单元和门控单元等优化缓解；难处理长期依赖问题，可通过如 LSTM、双向循环神经网络、GRU、循环多层感知等方法优化。
GRU	GRU 是改进的 RNN，LSTM 的简化版，具有更新门和重置门	与 LSTM 相比，GRU 只有两个门，参数较少，结构更简单，效率更高；适用于长序列数据，有效捕捉长时间依赖关系	不能完全解决梯度消失和爆炸；不可并行计算；解决梯度消失可选择合适的激活函数，如 ReLU、Leaky ReLU、ELU 等、使用批规范化或残差结构等；解决梯度爆炸问题可采用梯度剪切、正则化或挑选优化算法，如 Adam、RMSprop 等
CNN	前馈神经网络；监督学习或非监督学习；隐含层包含卷积层、池化层、全连接层常见构筑；常用随机梯度下降和 Adam 算法	无额外特征工程要求；提取数据空间信息；特征降维，防止过拟合；采用共享卷积核，减少参数量；适合处理网格化数据	随着深度的增加，可能会发生网络退化；无法处理相对位置、方向、形状等特征；需要大量样本，且计算量大；可解释性差
U-NET	主要包括卷积层、池化层、上采样层和跳跃连接层；网络结构形如“U”型，左半部分是编码过程，右半部分是解码过程	支持小样本训练；学习率可自我调节；激活函数 ReLU 没有饱和区，不存在梯度消失问题；可提取不同尺度空间场特征信息；可避免像素失真问题	模型普适性差；需要较大的内存和计算资源，运行慢；会出现边界模糊或分割错误的情况；使用的卷积和池化操作，会导致分辨率的降低和信息的丢失
Transformer	注意力机制的编码器-解码器架构；多头缩放点注意力机制（多头注意力）；位置前馈神经网络算法	计算量少，并行训练效率高；无共享参数；能够处理长期和短期依赖关系；多头注意力机制，处理时间序列效果好；可解释性强	获取局部特征的能力差；即使加入位置解码，对序列位置信息的捕获依然不够；输入序列过长时，计算量极大
GAN	GAN 由两组神经网络组成，分别是生成器与判别器	无监督或半监督学习方法，无需大量标注；既关注细节又关注全局；能够生成足够逼真的数据；可学习数据的空间分布；可解决极端事件的小样本问题	训练过程难以拟合，容易出现模型震荡；容易生成模型坍塌；易出现梯度消失。可通过特征匹配、单边标记平滑、频谱标准化等削弱，无法根本解决震荡问题；可采用多个生成模型、匹配数据空间与潜在空间、批量辨别、增强生成模型和限制判别模型等方法优化模型坍塌问题
AE	无监督学习模型；具有编码器和解码器	泛化性强，不需要数据标注；提取潜在高阶空间特征信息；可用于数据去噪、可视化降维、特征提取、异常场景识别	潜在高维空间难以解释；复杂数据分布训练难度大；无监督学习，其稳定和可靠性略差；可通过自动编码器的变体开发，如稀疏自动编码器、去噪自动编码器解决；结合其他深度学习模型，如深度强化学习、生成对抗网络等
GNN	图由节点和边组成；消息传递机制、节点表示学习以及图卷积操作	可应用于非欧几里得结构；捕捉局部和全局结构信息；处理异质和动态数据	硬件依赖性强、计算复杂度高、数据存取延迟；面对不同的应用场景，调优难等

深度学习在洪水预报中的应用主要涵盖以下 4 个方面：（1）数据处理和特征提取，通过处理和分析洪水相关数据，提取出更有效的特征信息；（2）构建洪水预报模型，利用深度学习技术可以构建更加精准的洪水预报模型，预报未来的洪水发生情况；（3）评估洪水

风险，通过对历史洪水事件和相关因素的学习，建立洪水风险评估模型，为决策者提供科学依据和参考；（4）搭建洪水预警系统，通过对实时数据的分析和处理，搭建智能化的洪水预警系统，及时发现洪水的发生迹象，实现对洪水的实时监测和预警。

本文重点综述了最常见的 LSTM、CNN、U-NET 和 Transformer 4 种深度学习模型及其混合网络模型在洪水预报方面的研究进展和存在的问题。

1.1 LSTM 的洪水预报应用

在处理与历史数据相关的序列问题时，标准 RNN 难以捕捉较长时间之前的历史数据信息，容易出现梯度消失问题。针对该问题，Hochreiter and Schmidhuber (1997) 提出了 LSTM，有效缓解了 RNN 难处理长期依赖导致的梯度消失度问题（智协飞等，2020）。LSTM 是洪水预报处理长序列数据最具代表性的深度学习算法，包含输入门、输出门、遗忘门、候选细胞、隐含层和细胞单元(Gers et al, 2000)。

近年来，国内外学者通过输入特征优化、参数调整和构建混合模型等方式提升了 LSTM 模型的性能，使其被广泛应用于河道、水库以及无观测资料的中小河流洪水预报中，并能够实现实时洪水滚动预报。针对河道洪水预报方面，研究者通常使用不同预见期的日流量、水位和降雨量作为输入数据构建 LSTM 洪水预报模型（Kratzert et al, 2018; Le et al, 2019; 罗朝林等，2022）。针对水库洪水预报，研究指出，基于 LSTM 模型的入库流量和日流量预报效果达到甚至超过了传统水文模型的预报水平（Damavandi et al, 2019）。在实时洪水预报方面，典型工作如 Liu et al. (2020) 将 K 邻近算法与 LSTM 模型相结合，用于不同气候条件下的流域实时洪水预报，预报效果符合规范要求。

当前，深度学习洪水预报模型主要依赖沿河而建的观测站长历史数据，而对于缺乏观测资料的中小河流洪水预报，仍以经验和半经验方法为主导，尤其在流域产汇流参数计算方面，亟需结合深度学习技术进行改进（Song et al, 2020）。为了提升 LSTM 模型的洪水预报性能，研究者常从模型输入特征、模型参数以及先进的网络结构等方面进行优化或替换。在输入特征方面，典型的优化方案包括变分模式分解(VMD)和经验模式分解(EMD)法与 LSTM 模型的结合，这对高度非平稳和非线性的序列如流量和水速等具有良好的适应性和有效性（Zuo et al, 2020; 王亦斌等，2020）。在改进模型参数方面，例如引入感知注意力机制以优化权重分配，也是提高模型预报精度的重要途经之一（Wu et al, 2018）。在引进网络方面，基于编码-解码(ED)框架的 LSTM 等先进网络模型因其能够处理序列到序列的问题，具备获取多预见期洪水预报过程的能力，并拥有较高的可解释性，近年来受到水文学领域的

广泛关注 (Kao et al., 2020; Cui et al, 2022; 崔震等, 2023)。Google 洪水预报团队 (Nearing et al, 2024) 利用 LSTM-ED 框架以及现有的 5680 个测量仪资料库进行训练, 能够在全局范围内实现无观测资料流域 7 d 预见期内的日径流预报。特别是在预报重现期为 5 年的极端天气事件时, 该系统的准确性与全球洪水预警系统在 1 年重现期事件上的表现相当甚至更高。

尽管 LSTM 通过增加门控机制可以选择性遗忘和记忆, 解决了部分长期依赖问题, 并在短期洪水预报中取得了显著成效, 但随着预报时效的延长, LSTM 模型的预报效果仍然不尽如人意, 因此需要引入注意力机制 (Attention) 来解决信息过长而导致的信息丢失问题 (Ding et al, 2020)。此外, 有研究表明, 通过降阶模型 (ROM) 开发的 LSTM-ROM 模型可以扩展至洪水的空间预测, 不仅保持了与全模型一致的预测精度, 而且能够在数秒内完成空间分布的洪水预测, 实现了高水平的空间分布表征 (Hu et al, 2019)。

总体而言, 应用 LSTM 深度学习网络构建洪水序列预报模型已取得良好成效, 但 LSTM 模型本身也存在如下局限性: (1) 复杂的模型结构降低了训练效率; (2) 由于存在时间序列依赖关系, 难以实现数据并行化处理; (3) 虽然在一定程度上缓解了长期依赖问题, 但对于更长的数据序列仍需引入其他变体模型或优化策略; (4) 门控单元架构虽增强了时间步间的联系, 但难以充分捕捉物理机制或提供直观易懂的数据解释。

1.2 CNN 的洪水预报应用

1989 年 Lecun et al 错误!未找到引用源。 (1989) 提出了 CNN, 这一创新技术解决了人工智能在图像处理领域面临的参数爆炸问题。CNN 因其具有处理二维化数据的能力, 避免了类图像数据输入输出的重构步骤。典型的 CNN 结构通常包含 3 个主要部分: 输入层、由多个卷积层构成的隐藏层以及输出层, 其中隐藏层包括池化层、全连接层和标准化层。由于 CNN 在捕捉空间特征方面的卓越性能, 被广泛应用于时空序列预报领域 (刘博等, 2020)。特别是三维 CNN, 其不仅能够提取时间维度的特征, 还能抽取空间维度的特征信息。

气候变化正在加剧极端天气事件的发生频率, 使城市洪灾风险持续上升。研究者通常基于气象卫星和测雨雷达、雨量站和水文站等多源数据, 开展深度学习的城市积水深度预报, 并进一步扩展至洪水的空间淹没范围、演进过程预测以及洪水风险评估等领域 (Kabir et al, 2020; Hosseiny, 2021)。尤其在沿海城市, 由于地理位置和人口聚集, 其受洪涝灾害的影响较内陆城市更为显著, 因此快速实现水位预报和洪涝淹没预警具有重要意义。邹长宏 (2023) 以上海市主城区为研究对象, 构建了耦合 CAESAR-Lisflood 与 CNN 的城市洪涝预报模型, 成功实现了水位预报和洪涝淹没情景推演。Ren et al (2025) 将深度卷积神经网络与梯度加

权类激活映射相结合，并嵌入分布式城市水动力模型，在多种降雨情景下能够有效识别和预报洪水的来源区域及其最大淹没深度。

在洪水要素预报方面，利用 CNN 可以同时实现要素的时间序列和空间特征提取能力，从而构建洪水水位和径流预报模型。目前，CNN 在洪水预报研究中大致可分为以下 3 个方向：（1）开展洪水要素预报，利用 CNN 模型预报实时洪峰水位、洪峰流量和峰现时间等要素（Wang et al, 2019; Anderson and Radić, 2022; 徐刚等, 2023）；（2）对比不同深度学习模型的洪水预报效果，如周唱（2021）和夏王萍^{错误!未找到引用源。}（2023）比较了 LSTM、CNN、GRU 以及组合模型 CNN-LSTM、CNN-GRU 在洪峰流量预报中的表现；（3）改进 CNN 模型，如赵松^{错误!未找到引用源。}（2021）设计了基于卷积自编码器结构的空时特征融合分析模型（CAe-RNN）、基于频域的图卷积神经网络空时特征融合分析模型（GC-RNN）以及基于空域的图注意力网络空时特征融合分析模型（GA-RNN）。

综上，尽管 CNN 模型在提取洪水变量的空间序列特征方面表现出色，但在捕捉时间依赖方面存在一定局限性。此外，CNN 对输入数据的尺度变化较为敏感，若训练期的洪水过程与测试期的洪水过程存在较大差异，则可能导致模型难以泛化至新的洪水场景。因此，可以通过引入擅长时间特征提取的网络构建混合模型，进一步提升 CNN 在洪水预报领域的应用效能。

1.3 U-NET 神经网络的洪水预报应用

U-NET 网络结构最初由 Ronneberger et al（2015）提出，其主要结构包括编码器、跳跃连接和解码器 3 个部分，整个网络结构呈现出“U”型布局。U-NET 在捕捉和表征空间特征方面展现出一定优势，能够有效学习不同空间尺度场上的信息。近年来，研究者通过多种方法对模型进行了改进，主要包括采用先进的数据处理技术对数据集进行降噪、筛选对洪水贡献较大的输入因子、优选模型的超参数设置以及改进深度学习框架等手段，使得 U-NET 在洪水预报领域得到了广泛应用（孙娜, 2019）。经过改进后的 U-NET 模型在洪水范围以及洪峰流量预报等方面表现突出。例如 Hosseiny（2021）提出的 U-NET River 模型可自动识别河流的几何形状、洪水覆盖范围，并预测洪水深度，其预测的最大洪水深度相较于传统水动力模型提高了 29%。Nguyen et al ^{错误!未找到引用源。}（2023）应用一维 CNN 和二维 U-NET 架构，生成了与卫星图像相似的洪水范围。此外，为了探究深度学习方法在雷达降雨临近预报耦合洪水预报中的可行性，李建柱等^{错误!未找到引用源。}（2023）尝试了 U-NET、采用 U-Net、嵌入注意力门的 Attention-UNET 和添加转换器的多级注意力 TransAtt-UNET3 种方法进行雷达降雨临近预报，并将预报结果耦合到水文模型中进行洪水预报。结果表明，在提前 1 h 预报情况下，模拟洪峰流量和径流量的相对误差均较小，而在提前 2 h 预报时，洪峰

流量及径流量预报均出现显著低估现象。

需要指出的是，由于 U-NET 结构中包含大量参数共享和特征重用，因此该模型对于训练数据的需求相对较少。然而，当训练数据集规模过小或者多样化不足时，可能会导致模型性能下降。另外，如果网络层数太浅且参数过少，则在训练过程中极易出现过拟合现象。为了解决这些问题，可以通过增加网络中的超参数配置或采用迁移学习等方式提高网络稳定性，避免陷入局部最优解，同时还能加快网络收敛速度。尽管如此，为了更深入地挖掘 U-NET 模型在洪水预报领域的潜力，还需克服诸多技术和理论挑战。

1.4 Transformer 神经网络的洪水预报应用

Google 研究团队于 2017 年提出的 Transformer 神经网络架构^{错误!未找到引用源。} (Vaswani et al, 2017) 是种完全基于注意力机制的生成式模型。相较于传统的 RNN，Transformer 的注意力机制能够实现并行计算，适合在分布式计算环境中进行大规模训练，其特征提取能力显著优于 RNN。与 CNN 相比，Transformer 的注意力机制可以看到全局数据，而 CNN 需要通过卷积核的缩小来获取全局变量。

为了探索 Transformer 在洪水预报领域中的适用性，Castangia et al^{错误!未找到引用源。} (2023) 的研究表明，利用河流过去的水位数据作为输入，Transformer 可以提前 1 d 预报出河流水位，并取得了可接受的预测精度。为进一步提升 Transformer 的时间序列预测精度能力和迁移学习能力，学者们尝试构建了 Transformer 的双编码器模型以及与 GRU 网络结合的混合模型，用于径流量的预报。研究表明，Transformer 在洪水预报中表现出较强的适用性，能够稳定地预报洪峰流量、小流量过程以及洪水退水阶段，但是随着预见期增加，容易出现低估洪峰现象 (Schwaller et al, 2019; Liu et al, 2022; 李文忠等, 2023)。Transformer 的迁移学习框架在跨流域洪水预报中也显示出优势，例如，使用数据丰富的盆地流域的模型来预报数据稀疏的流域中的洪水，其表现优于传统的水文模型 TOPMODEL 以及其他迁移学习模型如 TL-MLP 和 TL-LSTM 等^{错误!未找到引用源。} (Xu et al, 2023)。这表明，Transformer 的迁移学习能力能够充分利用流域水文数据的共性，从而有望提高观测数据有限甚至无资料地区的洪水预报精度。

虽然 Transformer 在洪水预报领域中适用性较强，但其要求的训练数据量较多，计算复杂度较高，因此对硬件资源的配置要求较高。同时，Transformer 采用自注意力机制，其预报结果往往难以解释，这对于洪水预报均构成了挑战。为了解决这些局限性，可以通过增强数据预处理技术、优化模型结构以及引入迁移学习等方法，进一步提高模型的性能和适用性。

1.5 混合模型的洪水预报应用

单一的深度学习模型在洪水预报领域应用虽然广泛，但其结构相对简单，在捕捉复杂的非线性洪水特征变化方面存在一定困难，同时预报精度也有待提高。通过集合不同网络框架的优势，构建混合预报模型，从而能够在一定程度上改善这些问题。但是混合模型也存在模型参数选择耗时长和不确定性大等挑战（Tripathy and Mishra, 2024）。

洪水预报本质上属于时序预测问题，而 LSTM 在时序预测方面混合模型优势突出，因此许多学者在 LSTM 基础上耦合其他网络模型，构建了多种深度学习模型，常见的混合模型有 CNN-LSTM、双向长短时记忆网络（Bi-LSTM）等。前人研究结果表明，混合深度学习洪水预报模型在预报径流量和不同时效水位方面具有很高的实用价值，较单一模型预报具有更高的准确率和更强的泛化能力（Moishin et al, 2021; 周勇强和朱跃龙, 2021; 刘艳等, 2021）。

在洪水预报领域，混合深度学习模型面临参数难以同时优化、训练局部极小、单个预报能力不佳等问题。为应对这些问题，研究者探索创新的解决方案，如将 K 最近邻方法与深度学习模型相耦合（错误!未找到引用源。 阚光远等, 2018）、图卷积神经网络与 GRU 相耦合以及 GRU 与 Transformer 相耦合（错误!未找到引用源。 错误!未找到引用源。 周茜, 2022），构建的混合模型在洪水不同长度预见期的径流量预报、洪峰流量预报以及洪水过程预报等表现出显著优势。

然而，目前在洪水预报领域，针对小样本的极端洪水或超标准洪水的预报适用性问题研究还非常欠缺，如深度信念网络、Diffusion 扩散模型和深度强化学习等网络框架在洪水预报中的应用还相对较少，未来有望进一步拓展这些模型在洪水预报领域的应用。

2 深度学习在洪水概率预报中的应用

受模型参数、模型结构和输入要素等不确定性因素的综合影响，洪水预报一直存有不确定性问题（崔震等, 2023），因此深度学习模型除了开展洪水预报的确定性输出外，还有必要开展洪水概率预报，并对模型不确定性的量化进行分析。洪水概率预报方法主要有两种途径：基于要素耦合和基于误差分析。从计算方法角度看，主要包括预报残差分析、蒙特卡罗暂退算法和贝叶斯理论等（错误!未找到引用源。 Razavi, 2021; 错误!未找到引用源。 李大洋等, 2023）。其中贝叶斯理论是水文预报领域实现概率预报的常用框架，将其与深度学习模型相结合，是提高深度学习洪水预报结果可信度的有效途径（错误!未找到引用源。 错误!未找到引用源。 李大洋等, 2023）。近年来，通过深度学习技术来量化预报不确定性理论取得了较多突破，代表性方法如基于梯度下降的蒙特卡罗变种 No-U-Turn Sampler 不确定性量化方法（错误!未找到引用源。 错误!未找到引用源。 Krapu et al, 2019）和混合密度神经网络（错误!未找到引用源。 错误!未找到引用源。 Mian and Hung, 2020）等。

然后，众多学者将理论应用到洪水概率预报建模中，取得了显著成果，如采用多元高斯分布法、误差自回归递归网络等构建概率预报模型，评估河流水位异常的概率，并开展预报区间对洪水的不确定性的适应性分析（Zou et al., 2023）。崔震等（2023）融合 LSTM、混合密度神经网络和新安江水文模型构建了洪水概率预报模型，有效反映了预报洪水过程的不确定性，量化了洪水预报模型的可信度。

3 深度学习在洪水小时尺度预报中的适用性

小时尺度洪水预报在提前预警、应急响应和减少损失方面具有非常重要的作用。然而，传统水文模型在小时尺度上预报洪水往往存在较大误差（Anderson and Radić, 2022）。目前常用的深度学习模型通过长历史数据训练，可捕捉到更细微的水文规律，在小时尺度洪水预报中的适用性较强，表 2 列出了 9 种深度学习模型在小时尺度洪水预报的精度和适用性。

由表 2 可看出，RNN、LSTM 和 GRU 模型更适用于小时尺度洪水的时间和空间特征显著的序列预报，其中 LSTM 模型表现最佳（Liu et al, 2023; Dtissibe et al, 2024）。为了研究 LSTM 模型在中国众多流域中的适用性，张景帅和胡彩虹（2024）挑选海河、黄河、淮河、长江流域内 9 个子流域，训练并验证 LSTM 模型流量预报精度，并指出 1 h 预见期，LSTM 模型在各流域纳什效率系数（NSE）超过 0.95，适用性和泛化能力强；然而，当预见期大于 6 h 时，LSTM 模型不能很好地学习到降雨与出口断面径流量关系，预报效果差。CNN 模型对于逐小时尺度的洪水预报，主要用于提取局部的空间特征，对时间依赖关系的捕捉能力较弱，可将其与 LSTM 等网络构建混合模型，以提高洪水预报水平（Zhao et al, 2025）。U-NET、Transforme 和 GAN 等模型在洪水预报中也表现出良好的应用效果（Hofmann and Schüttrumpf, 2021）。AE 模型主要用于洪水数据降维和提取水文数据特征，不直接用于洪水预报（苑希民等, 2023）。GNN 模型则可挖掘监测点间的地理空间依赖，洪水预报精度较高（余宇峰等, 2022）。随着技术的不断进步和创新，多种深度学习模型有望在未来更好地应用于逐小时尺度的洪水预报中，为防洪减灾提供更有力的技术支持。

表 2 9 种常用深度学习模型在逐小时尺度洪水预报的应用

Table 2 Application of hourly scale flood forecasting of nine deep learning models

流域	深度学习模型	预报变量	预报精度和适用性
黄河流域洛德和华远口站	RNN	小时流量	在洛德站的 1h 预测周期内，对于 NSE、克林古普塔效率（KGE）、平均绝对误差（MAE）和均方根误差（RMSE）4 个性能指标，RNN 较 LSTM 模型分别提高了 1.72%、4.43%、35.52%和 25.34%；华远口站的

			模型性能也有所提高。RNN 模型的结构简单，洪水预报适用性较好 (Wang, 2023)
海河、黄河、淮河、长江流域内部分流域	LSTM	小时流量	在南坡、栾川、沙河、下孤山、寿溪、李青店、芦溪、竹溪坡、三口镇 9 个流域 1 h 预见期，LSTM 模型 NSE 超过 0.95，效果良好，适用性和泛化能力强 (张景帅和胡彩虹, 2024)
韩国首尔汉江流域	GRU	水库下游的小时洪水流量	情景 1 包括来自 3 个水库的数据，情景 2 仅关注其中 1 个水库。情景 1 中，GRU 模型的 NSE 值为 0.979，LSTM 为 0.981，适用性强。情景 2 中，没有模型显示出任何出色的表现 (Yi and Yi, 2024)
四川省清溪河流域	CNN	小时流量预报	混合模型预报指标临界成功指数 (CSI) 可达 0.83，适用性一般 (Zhao et al, 2025)
山东省乳山市	U-NET	洪水水深预报	内涝区域的 NSE 值均大于 0.8，模型可识别洪涝的“热点”地区，也可预测区域的水深大小，洪涝面积预测偏低 (Li et al, 2024)
黄河故县水库流域	Transformer	1~6 h 流量预报	具有较好的适用性，在预见期 1~6 h 洪水预报中，GRU-Transformer 模型校准期和验证期的 NSE 均大于 0.85 (李文忠等, 2023)
德国亚琛市	GAN	洪水水深	floodGAN 模型精确度高于召回率，F1 分数为 0.78~0.79。GAN 模型可以用来生成更多的训练样本，特别适用于小样本的极端洪水事件 (Hofmann and Schüttrumpf, 2021)
山东省小清河流域黄台桥水文站	AE	逐时流量预报	基于 AE 和残差卷积神经网络 (RCNN) 的洪水分级预报 AE-RCNN 模型，NSE 为 0.9，优于 CNN、RCNN 和降雨聚类 RCNN 模型。AE 一般通过有效提取水文数据特征，从而提高洪水预报精度，不直接用于洪水预报 (苑希民等, 2023)
安徽横江流域	GNN	1~6 h 洪水水位预报	采用时空图卷积网络 (STGCN) 模型开展洪水预报，未校正前 1~6 h 平均 NSE 为 0.87，STGCN 模型校正后平均 NSE 为 0.948，精度高，适用性强，可挖掘监测点间的地理空间依赖 (余宇峰等, 2022)

4 深度学习和传统洪水预报模型的融合

洪水预报模型主要分为基于物理过程的水文或水动力模型 (即传统洪水预报模型) 和基于数据驱动的深度学习的模型 (张然等, 2022)，这两类模型在原理和应用上存在显著差异 (表 3)。传统洪水预报模型以半经验半物理机制为基础，对洪水流量或水位等进行模拟或预报。由于这类模型在构建过程中需要大量的流域水文和下垫面信息，这导致了参数率定困难和算力成本高等问题。而深度学习模型无需预先假设条件，仅基于大量的输入数据和优化算法挖掘数据之间的非线性关系进行预报，其具有专业知识要求低和算力成本低等优势，在某些情况下较传统方法可节约 4%~8% 的计算资源 (Miro et al, 2021)。

表 3 深度学习模型与传统洪水预报模型对比

Table 3 Comparison of machine learning model and flood forecasting model

对比内容	深度学习模型	传统洪水预报模型
------	--------	----------

模型基础	数据驱动，通过输入变量、特征提取和参数优化等方式改善模型性能	理论驱动，基于严谨的数学物理定律和假设条件
数据量	历史数据量要求大，大样本计算	历史样本要求少，主要集中在模型初始化阶段
输入数据类型	种类要求少，如降水、水位、流量等历史数据，也可输入水文相关数据	种类多，如降水、径流、蒸散发、湿度等水文数据和地形、土壤及植被等下垫面数据
预测能力	较难预报到历史样本之外的极端事件	对于未出现过的事件或极端事件有预报能力
模型参数率定	参数多，有实际意义，率定相对困难	参数实际意义不大，与输入数据相关性较强
可解释性	可解释性差，需特定方法解释模型	可解释性和物理一致性强，符合理论和数值推演
算力成本	计算效率高，成本低	计算成本高

为了比较传统水文模型与深度学习模型在不同时空尺度以及不同流域大小(通常面积大于 10000 km² 定义为大流域，小于 1000 km² 为小流域，介于两者之间的为中流域)的预报精度，表 4 给出了深度学习模型在洪水预报应用方面的实例。由表 4 可得出如下结论：(1) 无论是在预报流域、所使用的水文模型还是深度学习模型类型、预报变量，亦或是预报的时间和空间尺度等方面存在差异的情况下，深度学习模型的表现均有所不同；(2) 采用纯数据驱动方式或将水文模型与深度学习相结合的混合模型，在洪水预报领域的表现突出，其适应性也更强；(3) 针对大流域地区 2 h、6 h 和日径流量预报，深度学习模型可以使 NSE 提高 10%~70%(衣学军等, 2023); 中流域地区 NSE 预报精度可提高 10%~20%左右(Hosseiny, 2021; 孙明博等, 2024; 吴垚等, 2024); 小流域地区 6 h 或 1 h 径流量 NSE 可提高 10%~50% (徐刚等, 2023; Zhao et al, 2025)。

表 4 深度学习模型的洪水预报应用

Table 4 Application of deep learning models for flood forecasting

流域(空间尺度)	模型	预报时间尺度	性能指标	精度对比
临沂流域(10315 km ²)	LSTM-Transformer	2 h 和 6 h 流量	洪峰相对误差	对于平均 REP 和 NSE 评估指标, TOPKAPI 分别为 11.34%和 0.66, 2 h

	组合校正和 TOPKAPI 模型		(REP), NSE	预见期 LSTM-Transformer 组合校正为 3.59%和 0.97 (分别提高 68%和 47%), 6 h 预见期 LSTM-Transformer 组合校正为 10.40 和 0.84 (分别提高 -8%和 18%) (衣学军等, 2023)
雅鲁藏布江 (21 万 km ²)	LSTM 校正模型和 ERRIS 模型	日径流量	NSE、RMSE	与 ERRIS 模型相比, ERRIS-LSTM 模型对雅鲁藏布江流域 NSE 提高 4.1%, RMSE 减小 67.7% (刘莉等, 2024)
山东省黄河支流大汶河流域 (9069 km ²)	LSTM 和新安江水文模型	12、24、36h	确定性系数	新安江模型确定性系数平均为 0.87, LSTM 12 h 为 0.93 (提高 6.9%), 24 h、36 h 分别为 0.87、0.85 (与新安江相当或略低) (赵慧, 2023)
湖北清江上游流域 (2928 km ²)	嵌入递归神经网络 (P-RNN) 混合模型 (Hybrid-DL) 和概念水文模型 (EXP-Hydro)	日径流	NSE、RMSE、KGE	相较于 EXP-Hydro, Hybrid-DL 的 NSE 提高 21.01%, RMSE 降低 33.73%, KGE 提高 12.68% (孙明博等, 2024)
浙江省台州市永安溪流域 (2704 km ²)	CNN-LSTM 和网格化 GRID-HBV 模型	日径流	NSE	GRID-HBV 模型平均 NSE 为 0.81, LSTM、CNN-LSTM、基于两种产流要素 (快速径流和基流) 的 bi-CNN-LSTM 模型 NSE 分别为 0.89、0.92 和 0.92, 分别提高 10.9%、17.2%和 14.2% (吴垚等, 2024)
涪漳河流域 (953 km ²)	CNN 和前期影响雨量模型 API	6 h 径流量	NSE, REP	CNN 精度为 90%, API 精度为 78.1%, 提高 15% (徐刚等, 2023)
四川省清溪河山区小流域 (297 km ²)	CNN-LSTM-Multihead 混合模型 CLMA 和新安江模型	小时流量	临界成功指数 (CSI)	CLMA 模型的 CSI(0.83)较新安江模型的(0.54)提高 54% (Zhao et al, 2025)
犹他州格林河 (3.5 km)	CNN 和 U-Net 的混合模型 U-NET-River 和 iRIC	小时水位	洪水深度 (m)	与 iRIC 模型相比, U-NET-River 模型预测最大洪水深度提高 29% (Hosseiny, 2021)

目前深度学习模型与传统洪水预报模型相比,可解释性略显不足,催生了数据驱动模型与物理机制融合的新范式得到了广泛的研究 (Karpatne et al, 2017), 如利用深度学习技术代替物理过程参数化模块或利用深度学习代替传统的统计后处理方法等。

4.1 改进传统洪水预报模型参数化子模块

目前传统水文模拟在参数化方面的难点主要为：参数率定不统一、参数移植不匹配以及参数最优化难度大等问题（张家正，2023）。传统参数敏感性分析方法多依赖于手动优化校准，限制了洪水模型敏感性分析效率。而借助于深度学习敏感性分析等手段，不仅可以筛选和优化部分参数，还可以在参数化方案支持下添加物理约束条件**错误!未找到引用源。**（李扬等，2021；杨淑贤等，2022），这为融合深度学习与物理知识提供了有效途径。

国内外学者就如何利用深度学习改善模式参数化子模块开展了大量工作，如采用深度学习实现径流预报参数自动校准**错误!未找到引用源。**（袁绍春等，2021）；引入 *K-means* 算法探索模型中不确定参数的聚类模式和神经网络来识别敏感参数**错误!未找到引用源。**（Jin et al, 2024）；基于深度学习技术对水动力模型糙率参数实施反演，排除人工率定的主观性因素干扰（夏弘，2022）。由此可见，利用深度学习技术优化传统水文模型参数进而构建混合洪水预报模型，是洪水预报颇具潜力的发展方向之一。深度学习技术在处理模型参数区域化或数据协同方面也有一定的优势，有望解决无资料流域一直被困扰的预报难题。具体而言，可以利用洪水预报物理模型完成参数率定，随后借助深度学习技术对参数移植指标加以量化，从而确定适宜的参数区域移植方案，为无资料地区的参数区域化提供技术支撑（张家正，2023）。

4.2 探究深度学习洪水预报模型的可解释性

近年来，可解释人工智能（Explainable AI, XAI）已成为学术界关注的热点领域（McGovern and Aha, 2019；Gunnin et al, 2019）。解释性机器学习可分为本质、事后全局和事后局部可解释性 3 大类（Brenowitz et al, 2020）。解释性方法主要包括特征重要性评价、梯度分析、特征可视化以及可解释模型等。常见的解释性技术包括置换特征重要性（PFI）、树模型的不纯重要性、基于均方误差的特征重要性评估方法、Shapley 值方法（SHAP）、顺序向后选择/顺序向前选择以及内嵌物理知识神经网络（PINN）等。此外，还有部分依赖图和累积局部效应图等用于可视化模型输出的评估指标方法。

在洪水预报过程中，深度学习模型学到何种有效特征和如何做出预报的过程是模型被信任的关键。一般可以通过可解释性方法来解决该科学问题，如 PFI、SHAP 方法、排列重要性法、积分梯度法、对抗样本、规则提取、激活最大化、可视化方法和局部可解释模型不可知解释等。典型的研究成果包括使用 PFI 不可知框架来推导模型预报因子在降雨径流建模中的影响**错误!未找到引用源。**（Schmidt et al, 2020），基于期望梯度法的解释方法揭示 LSTM 径流模型所获得的融雪、近期降雨和历史降雨 3 种不同的输入与洪水诱发机制的联系**错误!未找到引用源。**（Jiang et al, 2022），利用时空注意权重的可视化方法反映传统洪水预报模型的合理性（Ding et al, 2020）以及可视化 CNN 网络神经元激活值等**错误!未找到引用源。**

(欧阳文字等, 2022)。

综上所述,随着解释性机器学习技术的发展,人们正在努力提高深度学习模型在洪水预报领域的透明度和可靠性,以便更好地理解和应用这些复杂模型。

4.3 耦合物理模型,增强物理机制

与具有物理机制的水文模型相比,深度学习模型仍然难以真正理解水文过程及其背后的物理规律(李大洋等, 2023)。因此,将深度学习技术与理论驱动的物理模型相结合,已成为国际水文研究的前沿方向之一。这种耦合的途径主要有两种:一是将传统洪水预报模型输出结果作为深度学习模型的输入变量,构建混合预报模型;二是采用水动力模型对初始损失进行优化处理,然后将其引入深度学习网络中,同时将深度学习模型生成的洪水要素过程作为水动力学模型的入流边界条件,从而构建深度学习和水动力学耦合的洪水预报模型。

通过上述两种耦合途径,不仅增强了数据驱动模型的内部可解释性,还能深化水文模拟的物理机制的理解,进而提高洪水要素预报精度。由此可见,将深度学习与物理模型进行深度融合,不仅是洪水时间序列预报领域发展的必然趋势,更是实现未来水利智能化的重要研究内容。

4.4 洪水预报模型误差校正

由于洪水是多种因素的综合、非常复杂且带有随机性的自然过程叠加资料的收集和传输环节误差、模型参数的率定误差、模型结构误差等,模型预报误差不可避免。因此,将洪水预报模型输出的预报变量进行统计后处理或误差校正尤为必要。深度学习在开展洪水预报时,前期可以通过优化模型的经验或半经验参数化方案,通过多样化的解释方法探索更多的洪水物理机制;而在后期,可以进行模型预报结果后处理,以提高洪水预报的精度和可靠性。

传统的洪水预报模型误差校正方法包括误差自回归、 K 最邻近、卡尔曼滤波以及BP神经网络等。然而,这些传统方法受预报残差分布不均、近邻样本量限制、模型的收敛速度缓慢以及去噪能力不足等问题的制约,需要进一步改进和完善。近年来,深度学习技术也逐渐被应用于洪水预报误差校正任务中,如基于LSTM和Transformer对TOPKAPI模型模拟不同预见期洪水流量预报进行校正(衣学军等, 2023)以及通过时空图卷积网络构建映射函数对洪水水位预报实时校正(余宇峰等, 2022)。这些研究成果表明,深度学习在洪水预报误差校正领域具有广阔的应用前景和发展潜力。

5 结论和思考

本文系统梳理了深度学习技术在洪水预报领域的常用模型以及发展现状。传统的水文模

型基于物理机制建模，深度学习模型则基于大数据建模。当前，深度学习模型尚无法完全替代传统洪水预报模型，两者应相互补充、深度融合。深度学习模型可通过嵌入物理机制来增强自身的合理性，同时，传统水文模型中的内部参数也可借助高效的深度学习技术加以改进，以期两种洪水预报建模范式均能进一步提升洪水预报效果。

深度学习技术在洪水预报领域面临的主要难点集中在长序列数据获取困难、模型参数优化难、模型移植泛化能力差、模型可解释性弱以及模型结果与物理规律不符等方面。如何克服上述难点，将直接影响深度学习技术在洪水预报领域的发展。为此，主要有以下几个方面的思考。

(1) 跨学科融合，实现数据协作共享。可以新增多种新型智能观测设备，如时差法、视频法、无人机和无人船监测等，结合气象学、地质学等多学科的优势，从时空尺度上采集更加精细的实时观测数据。同时，应对观测数据以及衍生数据进行质量控制，对缺失资料进行插补，并构建统一格式的共享数据库，确保科研人员能够快捷地获取所需资源。

(2) 增强数据处理技术，提升模型输入质量。在模型训练之前，需对输入数据进行充分预处理，如数据清洗、数据填充、自动遴选物理因子和剔除离群值或噪音过滤等方法，提高数据可用性。还可通过数据增强技术，如时差法、合成新数据、标签变换等方法扩充数据集规模，提高模型的鲁棒性和适应性。

(3) 优化模型结构，增强泛化能力。深度学习网络中的超参数设置（如隐含层节点数、正则化技术、学习率、优化器、数据批量大小、迭代次数以及损失函数等）对模型的性能起着决定性作用。可以利用自动网格搜索参数技术寻找最优配置方案，并探索迭代更新的网络框架以适应洪水预报需求。针对不同区域尺度或下垫面环境的洪水问题，结合多种深度学习算法开发洪水预报大模型，实现高效、精确的洪水预报。对于洪水资料缺乏或无资料地区，可借助迁移学习或强化学习技术将成熟、稳定的模型推广并移植应用。

(4) 构建混合模型，集成模型优势。混合模型是深度学习洪水预报的重要趋势，可以将深度学习模型与物理机制水文模型相耦合，用更高效的深度学习算法替换物理模型的部分参数化方案；也可以集成多种深度学习模型的优点，构建综合性混合模型，从而提高洪水时空预报的精度和迁移泛化能力。

(5) 强化可解释性，量化物理未知规律。目前，深度学习在洪水预报中的研究主要集中于提升预报精度，难以深入剖析物理因子间的作用过程，进而导致研究结果信服力不足。若能实现模型的可解释性，将有助于更好地量化物理因子间的未知关系。措施包括构建自解

释模型、解释方法模块、可视化以及构建物理约束模型等方法，增强模型预报的可解释性，促进模型结果与物理规律相符。

虽然深度学习技术在洪水预报领域还存在较多挑战，但其应用前景不容忽视。未来，随着深度学习技术不断进步，有望大幅度提高洪水预报的精准性和时效性，为防洪减灾决策提供有力的支持。

参考文献

- 陈鹤, 蔡荣辉, 陈静静, 等, 2022. 基于深度学习的气温预报技术应用与评估[J]. 气象, 48(11): 1373-1383. Chen H, Cai R H, Chen J J, et al, 2022. Application and evaluation of temperature forecast based on deep learning method[J]. Meteor Mon, 48(11): 1373-1383 (in Chinese).
- 崔震, 郭生练, 汪芸, 等, 2023. 三峡入库洪水概率预报的深度学习模型[J]. 水力发电学报, 42(4): 1-10. Cui Z, Guo S L, Wang Y, et al, 2023. Deep learning model for probability forecasting of flood to Three Gorges Reservoir[J]. J Hydroel Eng, 42(4): 1-10 (in Chinese).
- 黄骄文, 蔡荣辉, 姚蓉, 等, 2021. 深度学习网络在降水相态判别和预报中的应用[J]. 气象, 47(3): 317-326. Huang J W, Cai R H, Yao R, et al, 2021. Application of deep learning method to discrimination and forecasting of precipitation type[J]. Meteor Mon, 47(3): 317-326 (in Chinese).
- 李大洋, 姚轶, 梁忠民, 等, 2023. 基于变分贝叶斯深度学习的水文概率预报方法[J]. 水科学进展, 34(1): 33-41. Li D Y, Yao Y, Liang Z M, et al, 2023. Probabilistic hydrological forecasting based on variational Bayesian deep learning[J]. Adv Water Sci, 34(1): 33-41 (in Chinese).
- 李建柱, 李磊菁, 冯平, 等, 2023. 基于深度学习的雷达降雨临近预报及洪水预报[J]. 水科学进展, 34(5): 673-684. Li J Z, Li L J, Feng P, et al, 2023. Radar rainfall nowcasting and flood forecasting based on deep learning[J]. Adv Water Sci, 34(5): 673-684 (in Chinese).
- 李文忠, 刘成帅, 邬强, 等, 2023. GRU-Transformer 洪水预报模型构建与应用[J]. 中国农村水利水电, (11): 35-44. Li W Z, Liu C S, Wu Q, et al, 2023. Construction and application of GRU-Transformer flood forecasting model[J]. China Rural Water and Hydropower, (11): 35-44 (in Chinese).
- 李扬, 刘玉宝, 许小峰, 2021. 基于深度学习改进数值天气预报模式和预报的研究及挑战[J]. 气象科技进展, 11(3): 103-112. Li Y, Liu Y B, Xu X F, 2021. Advances and challenges for improving numerical weather prediction models and forecasting using deep learning[J]. Adv Meteor Sci Technol, 11(3): 103-112 (in Chinese).
- 刘博, 王明烁, 李永, 等, 2021. 深度学习在时空序列预测中的应用综述[J]. 北京工业大学学报, 47(8):17. Liu B, Wang M S, Li Y, et al, 2021. Deep Learning for spatio-temporal sequence forecasting: a survey[J]. J Beijing Univ Techn, 47(8):925-941.
- 刘莉, 梁霄, WANG Quanjun, 等, 2024. 基于深度学习的改进 ERRIS 径流预报实时校正模型[J]. 水资源保护, 40(6):155-164. Liu L, Liang X, Wang Q J, et al, 2024. Improved ERRIS model for real-time correction of streamflow forecast based on deep learning[J]. Water Resou Protec, 40(6):155-164 (in Chinese).
- 刘攀, 郑雅莲, 谢康, 等, 2021. 水文水资源领域深度学习研究进展综述[J]. 人民长江, 52(10):

- 76-83. Liu P, Zheng Y L, Xie K, et al, 2021. Review of research progress in deep learning for hydrology and water resources[J]. Yangtze River, 52(10): 76-83 (in Chinese).
- 刘艳, 2021. 基于深度学习的水文要素模拟与预测研究[D]. 天津: 天津大学. Liu Y, 2021. Research on hydrological elements simulation and prediction using deep-learning methods[D]. Tianjin: Tianjin University (in Chinese).
- 罗朝林, 张波, 孟庆魁, 等, 2022. 基于长短时记忆神经网络的水库洪水预报[J]. 人民珠江, 43(12): 128-134. Luo Z L, Zhang B, Meng Q K, et al, 2022. Reservoir flood forecasting based on long-short-term memory neural network[J]. Pearl River, 43(12): 128-134 (in Chinese).
- 欧阳文字, 叶磊, 王梦云, 等, 2022. 深度学习水文预报研究进展综述I—常用模型与建模方法[J]. 南水北调与水利科技, 20(4): 650-659. Ouyang W Y, Ye L, Wang M Y, et al, 2022. Review of deep learning on hydrological forecasting I: Common models and applying methods[J]. South-to-North Water Transfers and Water Science & Technology, 20(4): 650-659 (in Chinese).
- 孙明博, 闫宝伟, 常建波, 等, 2024. 基于物理机制和深度学习的混合模型及应用研究[J]. 中国农村水利水电, (8): 67-72, 80. Sun M B, Yan B W, Chang J B, et al, 2024. A hybrid deep learning model coupled with physical mechanism and its application[J]. China Rural Water and Hydropower, (8): 67-72, 80 (in Chinese).
- 孙娜, 2019. 机器学习理论在径流智能预报中的应用研究[D]. 武汉: 华中科技大学. Sun N, 2019. The theory of machine learning and its applications in the hydrological forecasting[D]. Wuhan: Huazhong University of Science and Technology (in Chinese).
- 王亦斌, 孙涛, 梁雪春, 等, 2020. 基于 EMD-LSTM 模型的河流水流量水位预测[J]. 水利水电科技进展, 40(6): 40-47. Wang Y B, Sun T, Liang X C, et al, 2020. Prediction of river water flow and water level based on EMD-LSTM model[J]. Adv Sci Technol Water Resour, 40(6): 40-47 (in Chinese).
- 吴垚, 许月萍, 刘莉, 等, 2024. 基于分布式产流要素和时空深度学习算法的径流后处理研究[J]. 水利学报, 55(9): 1123-1134. Wu Y, Xu Y P, Liu L, et al, 2024. Streamflow post-processing based on distributed hydrological fluxes and spatio-temporal deep learning algorithm[J]. J Hydraulic Eng, 55(9): 1123-1134 (in Chinese).
- 夏弘, 2022. 深度学习和水动力学模型结合的中小河流洪水预报研究[D]. 济南: 山东大学. Xia H, 2022. Study on flood forecasting of small and medium-sized rivers based on deep learning and hydrodynamic models[D]. Ji'nan: Shandong University (in Chinese).
- 夏王萍, 2023. 基于 VMD-OOYO-CNN-GRU 混合深度学习模型的研究及其应用[D]. 郑州: 华北水利水电大学. Xia W P, 2023. Research on VMD-OOYO-CNN-GRU based hybrid deep learning model and application[D]. Zhengzhou: North China University of Water Resources and Electric Power (in Chinese).
- 杨淑贤, 零丰华, 应武杉, 等, 2022. 人工智能技术气候预测应用简介[J]. 大气科学学报, 45(5): 641-659. Yang S X, Ling F H, Ying W S, et al, 2022. A brief overview of the application of artificial intelligence to climate prediction[J]. Trans Atmos Sci, 45(5): 641-659 (in Chinese).
- 衣学军, 汤岭, 李致家, 等, 2023. 基于机器学习的洪水预报实时校正[J]. 水电能源科学, 41(12): 78-81, 67. Yi X J, Tang L, Li Z J, et al, 2023. Real-time correction of flood forecasting based on machine learning[J]. Water Resour Power, 41(12): 78-81, 67 (in Chinese).
- 余宇峰, 李薇, 李珂, 等, 2022. 基于 STGCN 的洪水预报误差实时校正方法[J]. 水文, 42(5): 35-40. Yu Y F, Li W, Li K, et al, 2022. Real-time correction method of flood forecasting error based on STGCN[J]. J China Hydrol, 42(5): 35-40 (in Chinese).

- 袁凯, 李武阶, 李明, 等, 2022. 四种机器深度学习算法对武汉地区雷达回波临近预报的检验和评估[J]. 气象, 48(4): 428-441. Yuan K, Li W J, Li M, et al, 2022. Examination and evaluation of four machine deep learning algorithms for radar echo nowcasting in Wuhan Region[J]. Meteor Mon, 48(4): 428-441 (in Chinese).
- 袁绍春, 李迪, 陈垚, 等, 2021. 基于 BP 神经网络算法的 SWMM 参数自动率定方法[J]. 中国给水排水, 37(21): 125-130. Yuan S C, Li D, Chen Y, et al, 2021. Automatic calibration procedure of storm water management model parameters based on back propagation neural network algorithm[J]. China Water Wastewater, 37(21): 125-130 (in Chinese).
- 苑希民, 李达, 田福昌, 等, 2023. 基于 AE-RCNN 的洪水分级智能预报方法研究[J]. 水利学报, 54(9): 1070-1079. Yuan X M, Li D, Tian F C, et al, 2023. Research on flood classified intelligent forecasting method based on AE-RCNN[J]. J Hydraulic Eng, 54(9): 1070-1079 (in Chinese).
- 张景帅, 胡彩虹, 2024. 基于深度学习模型的中小河流洪水模拟[J]. 水电能源科学, 42(10): 11-15. Zhang J S, Hu C H, 2024. Flood simulation of small and medium-sized rivers based on deep learning model[J]. Water Resour Power, 42(10): 11-15 (in Chinese).
- 张家正, 2023. 基于机器学习的无资料区洪水预报模型参数区域化研究[D]. 郑州: 华北水利水电大学. Zhang J Z, 2023. Parameter regionalization of uninformed regional flood forecasting model based on machine learning[D]. Zhengzhou: North China University of Water Resources and Electric Power (in Chinese).
- 张然, 柴志勇, 张婷, 等, 2023. 基于机器学习模型的洪水预报研究进展[J]. 水利水电技术(中英文), 54(11): 89-101. Zhang R, Chai Z Y, Zhang T, et al, 2023. Research progress of flood forecasting based on machine learning[J]. Water Resour Hydropower Eng, 54(11): 89-101 (in Chinese).
- 赵慧, 2023. 于 LSTM 神经网络与新安江模型的大汶河流域洪水预报研究[D]. 辽宁: 辽宁师范大学. Zhao H, 2023. Research on flood forecasting in Dawen River Basin based on LSTM neural network and Xin'an River Model[D]. Liaoning: Liaoning Normal University.
- 赵松, 2021. 基于机器学习与空时特征融合的洪水预测[D]. 西安: 西安电子科技大学. Zhao S, 2021. Flood prediction based on machine learning and fusion of space-time features[D]. Xi'an: Xidian University (in Chinese).
- 智协飞, 王田, 季焱, 2020. 基于深度学习的中国地面气温的多模式集成预报研究[J]. 大气科学学报, 43(3): 435-446. Zhi X F, Wang T, Ji Y, 2020. Multimodel ensemble forecasts of surface air temperature over China based on deep learning approach[J]. Trans Atmos Sci, 43(3): 435-446 (in Chinese).
- 周唱, 2021. 基于深度学习的水库洪水预报研究[D]. 济南: 山东大学. Zhou C, 2021. Research on reservoir flood forecast based on deep learning[D]. Ji'nan: Shandong University (in Chinese).
- 周勇强, 朱跃龙, 2021. 基于 SFLA-CNN 和 LSTM 组合模型的水位预测[J]. 计算机与现代化, (4): 1-7. Zhou Y Q, Zhu Y L, 2021. Water level prediction based on SFLA-CNN and LSTM combined model[J]. Computer Modernizat, (4): 1-7 (in Chinese).
- 周茜, 2022. 机理和数据驱动的水文预报模型应用研究——以汉江流域为例[D]. 邯郸: 河北工程大学. Zhou X, 2022. Study on application of hydrological forecasting model driven by mechanism and data—take the Hanjiang River Basin as an example[D]. Handan: Hebei University of Engineering (in Chinese).

- 邹长宏, 2023. 耦合 CAESAR-Lisflood 和 CNN 的上海洪涝模拟与预报研究[D]. 上海: 华东师范大学. Zou C H, 2023. Research on Shanghai flood simulation and forecasting coupling CAESAR-Listflood and CNN[D]. Shanghai: East China Normal University (in Chinese).
- 阚光远, 洪阳, 梁珂, 2018. 基于耦合机器学习模型的洪水预报研究[J]. 中国农村水利水电, (10): 165-169, 176. Kan G Y, Hong Y, Liang K, 2018. Research on the flood forecasting based on coupled machine learning model[J]. China Rural Water Hydropower, (10): 165-169, 176 (in Chinese).
- Anderson S, Radić V, 2022. Evaluation and interpretation of convolutional long short-term memory networks for regional hydrological modelling[J]. Hydrol Earth Syst Sci, 26(3): 795-825.
- Brenowitz N D, Beucler T, Pritchard M, et al, 2020. Interpreting and stabilizing machine-learning parametrizations of convection[J]. J Atmos Sci, 77(12): 4357-4375.
- Burrichter B, Hofmann J, da Silva J K, et al, 2023. A spatiotemporal deep learning approach for urban pluvial flood forecasting with multi-source data[J]. Water, 15(9): 1760.
- Castangia M, Grajales L M M, Aliberti A, et al, 2023. Transformer neural networks for interpretable flood forecasting[J]. Environ Modell Softw, 160: 105581.
- Cui Z, Zhou Y L, Guo S L, et al, 2022. Effective improvement of multi-step-ahead flood forecasting accuracy through encoder-decoder with an exogenous input structure[J]. J Hydrol, 609: 127764.
- Damavandi H G, Shah R, Stampoulis D, et al, 2019. Accurate prediction of streamflow using long short-term memory network: a case study in the Brazos River Basin in Texas[J]. Int J Environ Sci Dev, 10(10): 294-300.
- Ding Y K, Zhu Y L, Feng J, et al, 2020. Interpretable spatio-temporal attention LSTM model for flood forecasting[J]. Neurocomputing, 403: 348-359.
- Dtissibe F Y, Ari A A A, Abboubakar H, et al, 2024. A comparative study of Machine Learning and Deep Learning methods for flood forecasting in the Far-North region, Cameroon[J]. Sci African, 23: e02053.
- Gers F A, Schmidhuber J, Cummins F, 2000. Learning to forget: continual prediction with LSTM[J]. Neural Comput, 12(10): 2451-2471.
- Gunning D, Aha D W, 2019. DARPA's explainable artificial intelligence (XAI) program[J]. AI Mag, 40(2): 44-58.
- Hao G R, Li J K, Song L M, et al, 2018. Comparison between the TOPMODEL and the Xin'anjiang model and their application to rainfall runoff simulation in semi-humid regions[J]. Environ Earth Sci, 77(7): 279.
- Hinton G E, Osindero S, Teh Y W, 2006. A fast learning algorithm for deep belief nets[J]. Neural Comput, 18(7): 1527-1554.
- Hochreiter S, Schmidhuber J, 1997. Long short-term memory[J]. Neural Comput, 9(8): 1735-1780.
- Hofmann J, Schüttrumpf H, 2021. floodGAN: Using Deep Adversarial Learning to Predict Pluvial Flooding in Real Time[J]. Water, 13(2255): 2255.
- Hosseiny H, 2021. A deep learning model for predicting river flood depth and extent[J]. Environ Modell Softw, 145: 105186
- Hu R, Fang F, Pain C C, et al, 2019. Rapid spatio-temporal flood prediction and uncertainty quantification using a deep learning method[J]. J Hydrol, 575: 911-920.
- Jiang S J, Zheng Y, Wang C, et al, 2022. Uncovering flooding mechanisms across the contiguous United States through interpretive deep learning on representative catchments[J]. Water Resour

Res, 58(1): e2021WR030185.

- Jin H X, Zhao Y, Lu P C, et al, 2024. Using machine learning to identify and optimize sensitive parameters in urban flood model considering subsurface characteristics[J]. *Int J Disaster Risk Sci*, 15(1): 116-133.
- Kabir S, Patidar S, Xia X L, et al, 2020. A deep convolutional neural network model for rapid prediction of fluvial flood inundation[J]. *J Hydrol*, 590: 125481.
- Kao I F, Zhou Y L, Chang L C, et al, 2020. Exploring a long short-term memory based encoder-decoder framework for multi-step-ahead flood forecasting[J]. *J Hydrol*, 583: 124631.
- Karpatne A, Atluri G, Faghmous J H, et al, 2017. Theory-guided data science: a new paradigm for scientific discovery from data[J]. *IEEE Trans Knowl Data Eng*, 29(10): 2318-2331.
- Krapu C, Borsuk M, Kumar M, 2019. Gradient-based inverse estimation for a rainfall-runoff model[J]. *Water Resour Res*, 55(8): 6625-6639.
- Kratzert F, Klotz D, Brenner C, et al, 2018. Rainfall-runoff modelling using Long Short-Term Memory (LSTM) networks[J]. *Hydrol Earth Syst Sci*, 22(11): 6005-6022.
- Le X H, Ho H V, Lee G, et al, 2019. Application of long short-term memory (LSTM) neural network for flood forecasting[J]. *Water*, 11(7): 1387.
- LeCun Y, Boser B, Denker J S, et al, 1989. Backpropagation applied to handwritten zip code recognition[J]. *Neural Comput*, 1(4): 541-551.
- Li W Z, Liu C S, Xu Y Y, et al, 2024. An interpretable hybrid deep learning model for flood forecasting based on Transformer and LSTM[J]. *J Hydrol: Regional Studies*:101873.
- Liu C F, Liu D R, Mu L, 2022. Improved transformer model for enhanced monthly streamflow predictions of the Yangtze River[J]. *IEEE Access*, 10: 58240-58253.
- Liu M Y, Huang Y C, Li Z J, et al, 2020. The applicability of LSTM-KNN model for real-time flood forecasting in different climate zones in China[J]. *Water*, 12(2): 440.
- Liu Y Z, Yang Y, Chin R J, et al, 2023. Long Short-Term Memory (LSTM) based model for flood forecasting in Xiangjiang River[J]. *KSCE J Civil Eng*, 27(11): 5030-5040.
- McGovern A, Lagerquist R, Gagne II D J, et al, 2019. Making the black box more transparent: understanding the physical implications of machine learning[J]. *Bull Amer Meteor Soc*, 100(11): 2175-2199.
- Miau S, Hung W H, 2020. River flooding forecasting and anomaly detection based on deep learning[J]. *IEEE Access*, 8: 198384-198402.
- Miro M E, Groves D, Tincher B, et al, 2021. Adaptive water management in the face of uncertainty: integrating machine learning, groundwater modeling and robust decision making[J]. *Climate Risk Manag*, 34: 100383.
- Moishin M, Deo R C, Prasad R, et al, 2021. Designing deep-based learning flood forecast model with ConvLSTM hybrid algorithm[J]. *IEEE Access*, 9: 50982-50993.
- Nearing G, Cohen D, Dube V, et al, 2024. Global prediction of extreme floods in ungauged watersheds[J]. *Nature*, 627(8004): 559-563.
- Nguyen C, Tan C W, Daly E, et al, 2023. Efficient analysis of hydrological connectivity using 1D and 2D convolutional neural networks[J]. *Adv Water Resour*, 182: 104583.
- Razavi S, 2021. Deep learning, explained: fundamentals, explainability, and bridgeability to process-based modelling[J]. *Environ Modell Softw*, 144: 105159.
- Ren H C, Pang B, Zhao G, et al, 2025. Rapid flood simulation and source area identification in

- urban environments via interpretable deep learning[J]. *J Hydrol*, 651: 132551, doi: 10.1016/j.jhydrol.2024.132551.
- Ronneberger O, Fischer P, Brox T, 2015. U-Net: convolutional networks for biomedical image segmentation[C]//18th International Conference on Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015. Munich, Germany: Springer: 234-241.
- Schmidt L, Heße F, Attinger S, et al, 2020. Challenges in applying machine learning models for hydrological inference: a case study for flooding events across Germany[J]. *Water Resour Res*, 56(5): e2019WR025924.
- Schwaller P, Laino T, Gaudin T, et al, 2019. Molecular transformer: a model for uncertainty-calibrated chemical reaction prediction[J]. *ACS Central Sci*, 5(9): 1572-1583.
- Song T Y, Ding W, Wu J, et al, 2020. Flash flood forecasting based on long short-term memory networks[J]. *Water*, 12(1): 109.
- Tripathy K P, Mishra A K, 2024. Deep learning in hydrology and water resources disciplines: concepts, methods, applications, and research directions[J]. *J Hydrol*, 628: 130458.
- Vaswani A, Shazeer N, Parmar N, et al, 2017. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, CA, USA: Curran Associates Inc.: 6000-6010.
- Wang J H, Lin G F, Chang M J, et al, 2019. Real-time water-level forecasting using dilated causal convolutional neural networks[J]. *Water Resour Manag*, 33(11): 3759-3780.
- Wang Y Y, Wang W C, Zang H F, et al, 2023. Is the LSTM model better than RNN for flood forecasting tasks? a case study of Huayuankou Station and Loude Station in the Lower Yellow River Basin[J]. *Water*, 15(22):3928.
- Wu Y, LIU Z, XU W, et al, 2018. Context-aware attention LSTM network for flood prediction[C]//24th International Conference on Pattern Recognition (ICPR).
- Xu Y H, Lin K R, Hu C H, et al, 2023. Deep transfer learning based on transformer for flood forecasting in data-sparse basins[J]. *J Hydrol*, 625: 129956.
- Yi S, Yi J, 2024. Reservoir-based flood forecasting and warning: deep learning versus machine learning[J]. *Appl Water Sci*, 14(11): 237.
- Zhao Y T, Wu X M, Zhang W J, et al, 2025. A deep learning-based probabilistic approach to flash flood warnings in mountainous catchments[J]. *J Hydrol*, 652: 132677.
- Zou Y S, Wang J, Lei P, et al, 2023. A novel multi-step ahead forecasting model for flood based on time residual LSTM[J]. *J Hydrol*, 620: 129521.
- Zuo G G, Luo J G, Wang N, et al, 2020. Decomposition ensemble model based on variational mode decomposition and long short-term memory for streamflow forecasting[J]. *J Hydrol*, 585: 124776. DOI: 10.1016/j.jhydrol.2020.124776.