

DOI: 10.13476/j.cnki.nsbqk.2022.0087

欧阳文宇, 叶磊, 顾学志, 等. 深度学习水文预报研究进展综述 II: 研究进展及展望[J]. 南水北调与水利科技(中英文), 2022, 20(5): 862-875. OUYANG W Y, YE L, GU X Z, et al. Review of deep learning for hydrological forecasting II: Research progress and prospect[J]. South-to-North Water Transfers and Water Science & Technology, 2022, 20(5): 862-875. (in Chinese)

深度学习水文预报研究进展综述 II

——研究进展及展望

欧阳文宇, 叶磊, 顾学志, 李晓阳, 张弛

(大连理工大学水利工程学院, 辽宁 大连 116024)

摘要:深度学习在数据驱动水文模型方向的应用研究是当前水文预报的研究热点。综述近期深度学习模型在水文预报中的应用研究进展, 归纳以往数据驱动模型未表现出的新特点, 分析深度学习在水利工程影响下水文建模、不确定性分析等问题中的应用潜力以及深度学习水文预报模型解释的知识发现作用。从物理机制模型中融入深度学习和物理机制指导的深度学习两方面讨论深度学习与水文物理机制整合的研究实例。总结深度学习水文预报研究仍面临的重要挑战, 展望可能的发展趋势, 以期深度学习在水文预报中的研究发展提供有效参考。

关键词:深度学习; 水文预报; 物理机制; 整合建模

中图分类号: TV214 文献标志码: A 开放科学(资源服务)标识码(OSID):



从埃及人根据天狼星出现的时间预测尼罗河洪水^[1]开始, 人们就在不停地探索水文预报方法以兴利除害。随着水文科学研究从定性分析发展到定量计算, 用于预报的工具也发生了很大变化, 特别是电子计算机的出现, 使得水文模型得到了广泛应用, 水文预报研究取得了长足进步。然而, 当前水文预报的发展仍面临一系列关键问题^[2-3], 比如大量水文观测和模拟数据正在快速积累, 同时如何从这些数据中提取能够解释的信息和知识是当前预报方法面临的巨大挑战; 由于目前对水文变量和水文过程的了解不够充分, 物理机制水文模型仍然面临参数难以区域化、预报不确定性强等关键问题; 人类活动影响增加了水文预报的复杂性, 如何在水文模型中考虑人类活动影响并有效地提升预报能力仍没有较好的解决方案^[4-5]。

近年来, 随着深度学习的快速发展和成功实践,

人工智能正在重塑各学科领域的科学研究, 由于其具有端到端的特征自动提取特性以及特征可迁移、表达复杂函数关系能力强等优点, 适合与复杂的水文预报问题相结合, 可望从“数据水文”的角度为上述关键问题提供新的解决思路, 因此在水文领域掀起了新的研究热潮。在此过程中, 物理机制水文模型由于具有可解释性、物理一致性强等优点, 与深度学习能够有效互补, 因此深度学习与物理机制相结合的研究也受到广泛关注^[5-6]。本文属于系列论文的第二篇, 综述 I^[7]从深度学习这一机器学习子领域与水文预报学科交叉的角度, 简要介绍了水文领域常用深度学习模型(即深度神经网络)的原理与结构及其应用于水文预报中的一般建模方法, 并在此基础上进一步介绍了深度学习与水文物理机制整合的基本方法。本文在文献 I 的基础上对深度学习及其与物理机制模型的整合在水文预报研究中的

收稿日期: 2022-04-01 修回日期: 2022-09-01 网络出版时间: 2022-09-29

网络出版地址: <https://kns.cnki.net/kcms/detail/13.1430.TV.20220927.1442.003.html>

基金项目: 国家自然科学基金项目(52179006; 51925902; 92047302)

作者简介: 欧阳文宇(1992—), 男, 河南周口人, 博士生, 主要从事流域水文预报研究。E-mail: wenyuouyang@outlook.com

通信作者: 叶磊(1989—), 男, 湖北武汉人, 副教授, 主要从事流域水文预报与水文分析研究。E-mail: yel@dlut.edu.cn

进展进行归纳和总结,并指出现有研究仍存在的主要问题和未来研究发展趋势。

1 基于深度学习的水文预报研究进展

在水文预报中人们重视模型的预测性能,同时也希望了解预测结果的不确定性,理解模型预测的过程,从而增强对模型的信任程度。数据驱动模型因其突出的数据挖掘能力在水文预报研究中很早就受到了关注^[8],但在新的模型结构和水文大样本数据条件下,深度学习模型在水文预报的应用中呈现出突出预报性能、有效整合水文大数据、易于参数区域化等崭新特点,在水利工程影响下的水文预报方面展示出良好的应用潜力,这些都有助于提升有或无观测流域的水文预报能力。已有的深度学习研究还能为水文模型不确定性量化提供较多可用方法;而随着可解释人工智能的发展^[9],对深度学习模型的解释有望揭示其所学内容,使其成为一种水文知识发现工具,这些都能增加模型可信度,有望推动深度学习模型在实际预报作业中的应用。

1.1 深度学习预报性能

相比于传统的基于物理机制水文模型和浅层机器学习模型,深度学习表现出了明显更强的预报性能。Fang 等^[10]最早在 2017 年引入长短记忆神经网络(LSTM)用于土壤含水量预测中,以网格气象数据、地理属性数据、Noah 模型模拟的表层土壤含水量等数据作为 LSTM 模型输入,预测土壤水分主被动探测计划(SMAP)观测的多时段表层土壤含水量,结果表明 LSTM 模型的平均偏差(Bias)、均方根误差(RMSE)和相关系数(R)等指标全面优于 Lasso、自回归模型和单层的前馈神经网络(NN)以及 Noah 模型模拟结果。在地下水位预测中,Zhang 等^[11]使用 LSTM 在我国河套地区 5 个灌溉区月尺度地下水位预测中获得了较好的性能指标,并指出其在无地下水位观测地区的应用价值;但 Wunsch 等^[12]指出地下水位预测通常属于小样本领域,应同样注重浅层神经网络的应用。在降雨径流预报方面,在大样本流域属性和气象数据集(CAMELS)^[13]等标准数据集下训练测试的 LSTM 模型同常见物理机制模型相比,在 Bias、RMSE、Nash-Sutcliffe 系数(NSE)、 R 及洪峰流量偏差等性能指标方面有一定优势,在低流量相对偏差等方面不同研究则有不同结论^[14-18]。在洪水预报方面,Kao 等^[19]提出了堆叠自解码器与 LSTM 耦合的模型,在我国台湾省宜兰

县洪水风险区域上的洪水淹没水位预报实验中,获取到低 RMSE 和高确定性系数结果,说明该模型能为受洪灾影响地区提供准确及时的未来洪水淹没动态信息。在水质等相关领域,Rahmani 等^[20]在美国 118 个水温监测数据丰富的流域,利用 LSTM 实现了河流水温长序列准确预测;Zhi 等^[21]基于 LSTM 在 CAMELS 中的 236 个流域上建立了河流溶解氧预测模型,结果表明该模型能揭示溶解氧随水温升高而下降的趋势,显示出在无水质测量的流域预测溶解氧的潜力;Sahraei 等^[22]只使用水温、pH 值和电导率等数据,利用 LSTM 预测了河流和地下水的稳定同位素含量,相比于高精度的激光光谱测量,提供了一种更易实现推广的低成本方式。

以 LSTM 为代表的深度学习模型展示了以往模型结构或数据条件下难获取的较好的预报性能指标。但除了以 LSTM 为代表的循环神经网络,还有多种类型神经网络能用于预报建模,比如卷积神经网络(CNN)^[23]、时间卷积网络(TCNN)^[24]、CNN-LSTM^[25]以及卷积长短期记忆神经网络(ConvLSTM)^[26]等。不过根据目前的研究情况,LSTM 已经成为水文预报研究中事实上的基准模型,且大样本水文数据集^[27]的完善正在推动基准数据和基准模型的进一步发展。

1.2 水文大数据整合

深度学习模型因其结构灵活的特点,原则上可以向模型添加任何类型的相关因子作为模型输入^[6]。利用近期观测数据提升短期水文预报精度是一种常见数据整合方式^[28]。Feng 等^[15]在 CAMELS 上研究了不同时段和类型的近期观测对径流预测的改善效果,在包含前一时段径流时获取到最优性能指标,NSE 中位数可达到 0.86,而降雨径流模型该指标为 0.74,但前期径流距预报初始越远对预报提升越弱,限制了该模型在较长预见期预报中的应用。Xiang 等^[29]基于前序历史观测径流等数据,使用编码解码 LSTM 开展了未来 24 小时径流预报研究,结果表明各预报时段性能指标随时间推进有明显下降趋势。Fang 等^[30]在土壤含水量预测中,使用 CNN 提取特征核的方法整合历史观测用于预报,相比于不使用前期观测的模型,模型预测精度明显提升,表明核提取方法在整合观测数据方面的有效性。

除了对历史观测数据的整合外,对不同信息源数据,通过特定的手段、方法和工具进行处理,提高

数据质量的数据融合也有益于提升水文预报能力^[31]。Kratzert 等^[32] 尝试在 LSTM 模型中同时输入 CAMELS 中 3 种来源不同但变量类型相同的气象数据来预报径流, 在 447 个 CAMELS 流域上的预报结果表明, 其精度高于只输入一种或任意两种来源气象数据组合的方案, 且差异在统计意义上显著。Wang 等^[33] 利用生成对抗网络(GAN)融合了被动微波和红外降水估计, GAN 生成器接收两者输入后生成融合样本, 再和地面雷达观测真实样本一起输入 GAN 判别器中计算交叉熵等损失来训练模型, 最终使判别器难以判别出其输入是融合样本还是真实样本。训练后的生成器可用于获取融合降水, 从降水强度和发展形势等方面分析的结果表明, 该方法得到了比全球降水计划多卫星降水联合反演(IMERG)卫星降水产品更接近于地面雷达观测的结果。

深度学习还能够有效利用分布式数据捕捉水文过程中的复杂时空动态特征来改善预测。例如, Anderson 等^[34] 和 Wunsch 等^[35] 基于涵盖多水文站点的区域分布式水文气象数据, 利用 CNN 提取气象数据的空间特征, 并结合 LSTM 寻找多时段长序列降雨径流相关关系, 实现了加拿大西南区域 279 个站点的径流预报, 该 CNN-LSTM 模型在测试期内日径流预报 NSE 中位数为 0.68, 相比于同区域已有相关研究结果, 在绝大多数站点上预测性能更好。Wunsch 等^[35] 同样利用二维 CNN 处理网格气象数据, 再将提取的特征输入一维 CNN 实现喀斯特流域泉水径流预报, 相较于不输入分布式数据的一维 CNN, 考虑分布式气象数据的模型更适用于喀斯特泉水径流预测。

1.3 模型参数区域化

深度学习模型受到水文预报研究积极关注的原因之一, 是其能在多流域上训练一套参数比各流域单独训练能获取更优预报性能指标, 而经典的物理机制水文模型情况则相反^[6-14]。Fang 等^[36] 在土壤含水量和径流预报两方面印证了这一点, 在美国环境保护署划分的 18 个生态区域上, 分别比较了对每个生态区域中所有流域进行 LSTM 建模和全部流域建立一个 LSTM 模型的预报结果, 后者在所有 18 个区域上的 RMSE 和 NSE 等结果指标几乎都优于前者, 他们称这种现象为“数据协同”。

这一特点有望促进无资料流域预报问题(PUB)研究^[37]。Kratzert 等^[38] 使用 CAMELS 数据集, 基于 LSTM 模型设计了流域交叉验证实验, 即随机抽选

部分流域为训练集, 另一部分流域为测试集, 进行多次抽选实验后计算各测试结果平均值, 也可以称之为模型空间泛化能力验证实验。与直接在被测试流域上建立 SAC-SMA 等水文模型比较, 结果显示两者 NSE 中位数分别为 0.69 和 0.64。Ma 等^[39] 利用迁移学习方法拓展了该思路, 并在跨洲际更广泛范围流域进行了验证: 他们利用 CAMELS 数据集预训练模型, 然后在我国四川省部分流域再训练, 并和只在本地流域训练的模型比较, 结果发现本地多年数据训练模型的测试 NSE 均值为 0.67, 而迁移学习后达 0.73。尽管 PUB 问题的解决仍然存在很大挑战, 但深度学习显示了其在数据稀缺环境下的建模能力。

1.4 水利工程影响下的水文建模

目前世界上超过 2/3 河流都已建有水库等水利工程^[40], 我国更是世界上水库数量最多的国家^[41]。水利工程对水文过程的影响给预报建模带来了挑战。然而在深度学习水文预报研究中, 现有大多数研究仍主要集中于受水利工程影响较小的流域^[42]。为了检验深度学习模型能否在水利工程影响较大的流域较好地完成降雨径流多时段预报, Ouyang 等^[42] 将 CAMELS 数据集的 671 个流域扩展到 3557 个(80% 以上有水库影响), 仍以气象数据和流域属性为输入构建了 LSTM 降雨径流模型。结果表明, 整体库容系数较大的流域 LSTM 表现较差, 且难以兼顾拟合库容系数大和小的流域降雨径流过程规律, 数据协同^[36] 受到了挑战。此外, 将 CAMELS 上训练的模型迁移至其他非 CAMELS 所属的、人类活动影响较大的流域时性能会显著下降, 表明了现有基于 CAMELS 的深度学习径流预报研究结论存在不足, 指出了建模时考虑更多人类活动影响流域的必要性。

以往考虑水库调度影响建模的主要方法是在水文模型中嵌入水库运行模块以表达水库影响^[43-44]。由于水库调度非线性及受人为因素影响等特点, 相比于预先设定的调度规则, 深度学习模型能更好地模拟现实调度情形。Zhang 等^[45] 和 Yang 等^[46] 均利用深度学习模型构建了能很好拟合调度过程的高精度水库模块, 但是水库模块和水文模型耦合时, 在预报精度较低条件下, 调度模块的精度提升对最终径流的预测可能没有明显帮助^[47], 如何统一构建更好地考虑水利工程影响的水文预报模型仍待

进一步分析。

1.5 模型不确定性分析

水文预报模型空间构建过程以及将测试流域投影到模型空间过程中都存在不确定性,因此对模型不确定性的量化分析是深度学习水文预报中需要考虑的^[48]。而尽管计算机领域处理的大部分问题都是完全确定和必然的,但由于必须在系统内在随机性和观测不充分等不确定性存在的情况下进行推理预测,深度学习模型大量涉及了概率分析^[49],这为水文模型不确定性量化提供了较多可用方法。例如:Fang等^[50]使用蒙特卡洛 Dropout(MCD)来估计模型网络权重的不确定性,并在输出层增加一项额外输出来表达噪声项,构建了称为 MCD+N 的不确定性估计框架,用以量化 SMAP 地表土壤含水量时序预测中的不确定性。他们分析了各网格预报结果的方差,并通过误差超越概率图及 Kolmogorov-Smirnov 距离等评估了不确定性量化的质量,指出只有同时考虑输入不确定性和参数不确定性才能较好地量化整体不确定性。Klotz等^[51]采用了另一种可直接根据输入提供概率预报,而不需要在深度网络上再额外增补结构以表述不确定性的方法——混合密度神经网络方法^[52]。利用此方法可直接由神经网络输出多个高斯分布的均值、方差及它们混合时的权重,来构建输出的概率分布,结果表明此方法和只考虑权重不确定性的 MCD 方法相比,在预报值观测值分位数关系图^[53]上更接近 1:1 直线,能获取更高质量的不确定性估计。Krapu等^[54]利用统计编程框架 PyMC3 实现了基于梯度下降的哈密顿蒙特卡洛变种 No-U-Turn Sampler 和自动微分变分推理不确定性量化方法,验证了它们在降雨径流模型反演估计问题上的适用性,结果表明相比于非梯度类的随机游走 Metropolis 和微分进化 Metropolis 算法,它们收敛到后验分布的速度更快,指出了梯度下降类算法在高维参数空间不确定性量化方面的优势。

1.6 预报模型解释

深度学习模型的应用需要权衡高性能和可解释性两方面,高性能往往伴随着复杂的非线性结构,难以解释模型做出最终预测的原因,使得可解释性成为深度神经网络的劣势,这一问题推动了近些年可解释人工智能方法的研究^[55]。尽管当前研究还不能直接构建完全自解释的模型^[56],水文领域内研究者也认为深度学习仍难以在过程理解方面给出较

多信息^[48],但神经网络还是能够通过模型结果归因分析、模型结构及参数可视化等方式实现初步的知识提取。此外,基于“数据水文”由果及因的分析思路^[57],这类灰箱模型可能在不受现有知识体系限制条件下,为水文研究领域提供新见解^[6]。

目前在水文预报相关研究中结果反推类的方法使用较多,比如 Kratzert 等^[14]使用 Morris 方法^[58]研究了输入属性的重要性,他们给某个属性随机扰动值,然后输入训练好的网络,观察输出结果相对于无扰动时的变化,由此给出了各流域影响预报结果的关键属性。层次相关传播(LRP)^[59]和 SHapley Additive exPlanation (SHAP)^[60]也是常用的归因分析法,在干旱、径流、蒸散发及河流水质预测等多项研究^[61-64]中得到了应用。Local Interpretable Model-agnostic Explanations (LIME)^[65]是通过构建简洁模型来帮助理解复杂深度学习模型的方法中较常见的一种。比如 Worland 等^[66]构建了根据流域属性推求流量历时曲线(FDC)的多层感知机(MLP)模型,然后使用 LIME 方法得出了影响预报径流各分位数最重要的属性为流域坡度、平均降水、径流记录长度和基流指数等。可视化方法中比较典型的是对神经网络中间隐含层结果的分析,比如 Pan 等^[67]构建 CNN 来提升降水降尺度估计能力,他们可视化了训练后 CNN 的前两个卷积层,发现对于程度强弱不同的降雨事件,卷积层的神经元激活模式不同。

模型解释不仅能帮助发掘影响模型输出的关键因子及其模式,还能帮助检验一些水文预报研究关注的重要问题。比如:Schmidt 等^[68]使用置换特征重要性(PFI)方法^[69]分析了不同机器学习模型在降雨径流建模中的关键影响因子,发现获得近似预报性能的不同机器学习模型的关键因子并不相同,指出了传统水文模型的异参同效问题在机器学习模型中仍然是挑战。Yokoo 等^[70]修改积雪期降水输入为常量,并输入训练后的 LSTM 降雨径流模型中,发现模型得到的径流结果只反映了给定降水量下应有年总径流的 17%~39%,说明了模型不能很好地捕捉到水量平衡规律。

2 物理机制与深度学习整合的水文预报研究进展

深度学习在水文预报方面的应用研究显示了其擅于处理分析大数据,挖掘复杂变量联系,建模灵活且预报性能突出以及一定程度的普适性等优点,也在水利工程影响下建模、模型不确定性分析及解

释等方面有了初步进展,但仍存在超出现有数据范围时预报性能降低,模型不符合一般物理规律等问题,而物理机制水文模型则能起到与之互补的作用,因此推动了物理机制与深度学习整合的水文预报研究的发展^[56-71]。本文在文献 I 的基础上从物理机制模型中融入深度学习和物理机制指导的深度学习两方面展开讨论。

2.1 物理机制模型中融入深度学习

物理机制水文预报模型在理论研究和生产实践中都受到了广泛关注与应用,但由于对水文过程认识的局限,水文尺度问题等^[72],水文模型只是流域水文形成机理的一种近似,而有限数据条件下的模型参数化进一步降低了其性能;另一方面,尽管深度学习较依赖于大数据,且是灰箱模型,但在数据条件满足的情况下能够提供优异的性能,因此物理机制模型中融入深度学习模型能够在保持物理一致性等优点的基础上提升模型性能。Tsai 等^[73]提出了“参数学习”方法完成 HBV 模型参数率定过程,如图 1 DL_{θ} 所示,DL 表示深度学习, θ 表示物理机制模型参数,输入变量进入 DL_{θ} 模型后不直接得到最终输出变量预测值,而是生成 θ ,再和输入变量一同输入到物理机制模型中得到预测结果。他们在 1 802 个流域上开展了流域交叉验证实验,即参数学习模型空间泛化能力的分析。相比于利用进化算法完成模型率定后,再依据多元线性回归完成流域属性到模型参数相关关系的参数区域化方法,Kling-Gupta 系数(KGE)中位数从 0.48 提升至 0.59,且参与训练的流域越多时这种提升越明显。

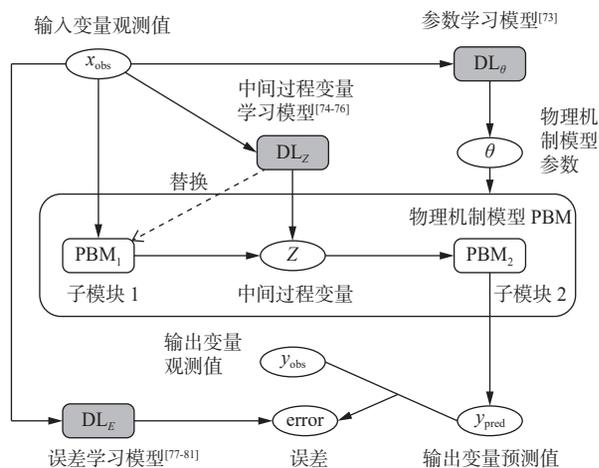


图 1 物理机制模型中融入深度学习结构

Fig. 1 The structure diagram of integration of deep learning in physics-based models

使用神经网络学习水文变量是更常见的在水文模型中融入深度学习的方式。如图 1 中 DL_Z 所示,

Z 表示中间过程变量, DL_Z 模型能直接替换物理机制模型子模块, 作为原模型的一部分, 其余部分仍保持物理机制模型原始模块不变, 从而得到最终输出变量预测值, 由此来结合深度学习与物理机制模型。例如, Zhao 等^[74]不直接使用 MLP 预测潜热通量(LE), 而是预测彭曼公式中的中间变量表面阻力(r_s), 再利用彭曼公式计算 LE 并和观测值比较, 结果表明由于基于能量平衡公式, 模型具备较好的物理一致性, 且获得了和标准神经网络模型相当的预测性能。Bennett 等^[75]则使用 MLP 替换了 SUMMA 水文模型^[76]中的热通量计算模块, 该神经网络以热通量计算参数和气象数据为输入预测热通量, 在训练后被置换入原 SUMMA 模型, 在 60 个通量观测站上的测试结果显示潜热、显热通量的 NSE 中位数分别最多能提高 0.10 和 0.14, KGE 中位数提高 0.21 和 0.23, 验证了该整合方法的有效性。

使用深度学习模型学习物理机制模型预报误差规律也能有效改善模型预报能力。如图 1 中 DL_E 所示, E 表示物理机制模型预测结果与观测值之间的误差, DL_E 训练过程中以影响误差的各类时空动态信息为输入, 以物理机制模型预报误差为输出, 训练后可用于校正预报结果。例如, Sun 等^[77]通过 CNN 学习 Noah 模拟与 GRACE 观测的陆地蓄水异常(Total Water Storage Anomaly)之间的时空不匹配模式, 并使用训练后的模型完成误差校正, 结果表明, 校正后的 R 与 NSE 分别提高了 14% 和 52%。Cho 和 Kim^[78]利用 LSTM 学习气象数据与 WRF-Hydro 预报误差之间的相关关系并用于预测误差来校正 WRF-Hydro, 在韩国一流域上的实验结果表明, 该方法 NSE 可达到 0.95, 而校正前 NSE 仅为 0.72; 类似地, Han 等^[79]和 Frame 等^[80]都使用 LSTM 实现了对美国国家水模型多时段预报结果的误差校正后处理。Boucher 等^[81]利用率定好的 GR4J 水文模型模拟的径流以及观测水温等为输入, 以 GR4J 状态变量为输出构建了 MLP 模型, 并用通过近期径流、水温等观测数据输入 MLP 获取最新的 GR4J 状态变量, 以此来改善 GR4J 模型预报, 结果表明相比于没有同化的模型取得了明显的提升。

2.2 物理机制指导的深度学习

物理机制指导的深度学习目的在于在提升模型预报性能的同时, 提高样本使用效率、可解释性和物理规律一致性等^[82]。引入物理机制改进深度学习模型的损失函数是最常见的方式之一, 如图 2 中物

理机制指导的损失函数部分所示。Worland 等^[66] 使用多输出 MLP 构建了预测 FDC 各分位值的模型,并在损失函数中融入了 FDC 单调性的约束,结果表明相比于不考虑 FDC 单调性的 MLP 模型,其预测曲线不仅能很好地遵守单调性,和观测数据生成的 FDC 也更接近。Wang 等^[83] 不仅把物理规律等加入到损失函数中,还以不等式形式融合了专家经验,构建了物理机制指导的神经网络(TgNN),结果表明 TgNN 预测性能优于标准深度学习模型。Karpatne 等^[84] 通过利用湖水水温-密度关系以及密度-水深的单调性构建了不等式约束,并结合 ReLU 加入到损失函数中,结果表明 TgNN 获取了较高性能的同时不违反密度-水深的单调性。Xie 等^[85] 将降雨径流预报过程中涉及的 3 种物理条件编码入损失函数,在 CAMELS 的 531 个流域的实验结果表明该模型相比于 LSTM 在 NSE 均值从 0.52 提升至 0.61 的同时,还增强了峰值预报能力,减少了不合理的负值出现情况。

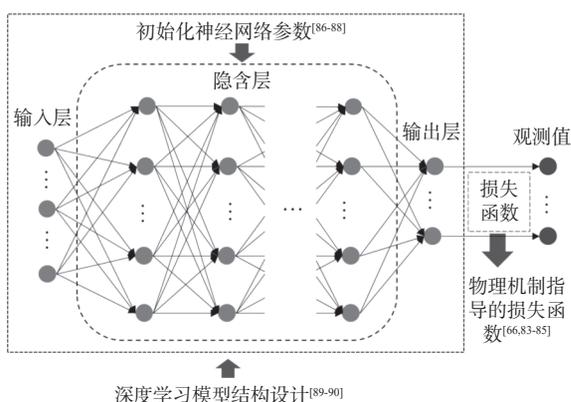


图 2 物理机制指导的深度学习结构

Fig. 2 The structure diagram of physics-guided deep learning

在实际中很多流域不具备充分数据条件时,利用基于物理机制的模型生成模拟数据初始化深度学习神经网络参数,能够加速神经网络训练并提高训练样本利用效率,起到数据增强的效果^[86],如图 2 中初始化神经网络参数部分所示。Yang 等^[87] 利用随机降雨生成器和分布式水文模型作为训练样本的构造器,然后用模拟结果来训练 LSTM,规避了训练数据不足的缺点,在泰国 3 个流域上的测试结果显示,相比于无构造样本条件下训练的神经网络,其 NSE 和 RMSE 等指标均有提升。Read 等^[88] 在观测数据不足的情况下采用了湖温物理模型模拟预热来初始化启动 LSTM 模型,结果表明相比于随机的初始化,利用物理知识带来信息训练后的神经网络初值能够使神经网络获得更好的训练和验证效果。

根据物理机制设计深度学习模型,将规则直接编码入神经网络是直接融合两类模型的典型形式,如图 2 中深度学习模型结构设计部分所示。Hoedt 等^[89] 修改了 LSTM 循环单元结构,使其能满足一定时间范围内的水量平衡,在 CAMELS 数据集 531 个流域上的实验结果表明,虽然整体的 NSE 等指标没有提升,但是在峰值流量条件下能表现出更好的性能;Jiang 等^[90] 同样修改了循环神经网络的循环单元结构,将概念性水文模型 EXP-HYDRO 的土壤含水等状态量作为循环单元状态变量,将径流等通量作为单元的输出量,从而将方程直接写入循环单元,并结合其他神经网络层构建了称为物理过程装配的循环神经网络,在 CAMELS 的 671 个流域上实验表明,相比于构建的标准 LSTM 模型,NSE、峰值流量偏差和基流 NSE 中位数分别从 0.60、28.40 和 0.47 改善为 0.71、15.69 和 0.52。

3 存在的问题与发展趋势

深度学习技术的发展和水文数据的积累推动了深度学习在水文预报中的研究,但研究整体上仍处于起步不久的快速发展阶段。目前深度学习水文预报研究多基于小样本数据或者国外部分标准大样本数据集,数据体系建设有待完善,深度学习应用潜力还需挖掘。尽管已有整合物理机制与深度学习的水文预报研究,但目前预报中应用的深度学习模型仍以标准神经网络模型为主,对物理机制的整合仍处于简单结合阶段,预报中仍面临流域异构性表达等难题,两者的深度融合还有待研究。作为一项实用先进技术,深度学习在水文预报工程实践中如何应用,能发挥什么作用仍有待探讨。

3.1 仍面临的问题

3.1.1 水文大数据方面

人工智能的快速发展离不开大数据,深度学习水文预报也依赖于水利大数据^[91] 的建设,而构建水利大数据的基础在于观测体系的完善以及数据的长期高质量积累。我国观测和数据共享体系在快速发展中^[92],比如国家地球系统科学数据中心^[93]、中国西部环境与生态科学数据中心^[94] 等,但在水文预报方面还有待进一步完善。比如我国也有类似 CAMELS 的数据集制作^[95],但主要以流域气象及地理属性数据为主,地表径流数据仅在部分流域站点有归一化处理后的长时段间隔的可公开数据。

另一方面,从观测对象上说,水文气象数据相对

较多,但地面和地下水文数据相对少,能直接观测的数据积累比间接观测的多。比如:径流数据通常是间接获取的数据,在水位观测的基础上,根据前期测量好的水位-流量曲线来获取对应流量数据,使用时会引入较大不确定性^[96],且大多数测水位点没有对应相应水位流量曲线,不利于大规模的水文径流建模^[97]。蒸发数据也多根据蒸发皿观测或卫星遥感观测结果,结合物理机制模型等间接获取,这使人们有理由对水文学某些结论提出质疑^[57]。如何增强对这些水文变量的观测能力以及如何更有效在深度学习水文预报中考虑这些变量需要深入研究。

3.1.2 水文建模方面

考虑水文模型面临的经典问题,流域异构性的表达仍是难题,现有的深度学习水文预报研究多基于变量的流域平均值构建模型,影响水文过程的各异性物理要素的时变特征如何分析,类似于水文模型的“分布式”概念是否适用于深度学习水文预报,均需要进一步讨论。其次, Schmidt等^[68]研究表明异参同效问题在机器学习模型中同样存在。此外,水利工程影响下的深度学习水文建模仍处于初始研究阶段,受人类活动影响较大流域的水文建模仍是难题。

从模型结构角度考虑,以 LSTM 为代表的标准循环神经网络仍是现阶段深度学习水文预报核心的模型结构,与物理机制的整合也更多地集中于损失函数修改等松散耦合方式,是否有更适合于水文预报问题的深度学习模型,水文物理机制如何充分地融入神经网络结构中,构建物理一致性且预报性能良好的模型,并推动更多水文规律的发现仍需探索。

3.1.3 工程实际应用方面

实际生产预报中更关注洪水等极端事件的预报预警,对洪峰、洪量的精度和预见期等有更高要求,而由于极端事件属于小概率事件,相应的样本量较少,给深度学习模型的训练带来了较大困难,如何进一步提高这些更受关注指标的预报能力值得探讨。由于公开的大样本数据集多集中在日尺度^[27],因此现有研究多在日尺度层面开展,而实际生产中对实时预报需求更频繁,需要更多更小时间尺度的问题研究。此外,考虑到工程实际中对于预报信息的利用,比如水库调度等方案的制定,需要更多关于不确定性分析的内容以衡量方案风险,因此需要进一步探索基于深度学习的预报不确定性分析。

3.2 可能的发展趋势

针对上述问题与挑战,可以考虑在以下几个方面推进相关工作,推动深度学习水文预报的进一步发展。

进一步发展标准数据集。标准数据集的构建能为后续研究起到关键基础性作用,一方面提供了研究必要条件,另一方面也提供了对比基准,有利于形成研究领域共识,推动研究进展。比如,类似于机器学习领域 ImageNet^[98]数据集,扩展现有的 CAMELS 等数据集,构建数据源一致,格式统一,包含更多不同地区流域和多种时段类型的水文、气象观测和预报等数据的数据集。在此基础上,能开展基于标准数据集的深度学习模型研究,提供已训练模型参数作为模型标准,为无资料地区预报提供迁移学习源模型。

改善对观测数据的利用。对于间接观测的水文变量,可以利用深度学习技术针对能直接观测数据建模,从而减少不确定性较大的中间处理过程,并充分利用数据驱动知识发现的优点。比如洪水预报中,可以考虑以水位为学习目标训练深度学习模型,最后如有流量数据需要,再根据实际观测点的水位流量关系做转换。也可以直接从观测源数据中提取目标信息,比如基于图像识别的降雨^[99]、径流^[100]和水位^[101]等的测量,再融入端到端的整体预报建模过程中。

开展多任务学习研究。注重多任务学习研究^[102],即同时预报水循环过程的多个组成变量。水循环过程中所涉变量间并不孤立,同时考虑多变量预报有望减少单一变量过拟合现象,提升模型泛化性能。比如已有研究证实了河流水温和径流^[20]之间的预报协同互助作用,也有研究使用概念性水文模型验证了通过率定模型输出的蒸发有助于提高无资料流域径流预报精度^[103]。

借鉴分布式模型思想。考虑深度学习在流域水文过程异构性表达中的作用,能从利用分布式数据建模入手。尽管已有一些研究成果^[34-35],但仍局限于局部区域性研究,尚未充分挖掘各类水文时空要素信息,可进一步开展更大尺度范围内的研究。尽管分布式模型的概念在深度学习中应该如何表达还不明确,但能考虑构建深度学习半分布式水文模型,更充分考虑流域内水文要素的变化及子流域间影响,比如 Moshe等^[104]和 Vaswani等^[105]构建的基于树状数据结构河流拓扑的神经网络径流预报模型。

利用更多先进深度学习模型。基于更多先进的深度学习技术可构建适用于更多场景的水文预报模型。基于注意力机制的模型^[105-106]可能在时序建模问题上提供更好的预测性能。图神经网络^[107]和常微分方程循环神经网络^[108]等能从结构更复杂和更不规则的数据中提取有价值信息,适合于流域内观测站点拓扑复杂和缺失数据不规律等情况下的建模。生成式模型则由于能学习多维变量的联合概率分布,相比于判别式模型,有构建泛化能力更强预报模型的潜力,并能用于模型不确定性分析^[109]。

拓展物理机制与深度学习的整合。推进整合物理机制与深度学习的水文预报模型研究仍是无资料地区预报、水利工程影响下预报和小样本事件预报等诸多问题的主要解决思路之一。微分方程和神经网络的结合^[110]有望为深度学习水文预报提供更多研究思路和工具。比如,能利用自动微分从神经网络中提取出偏微分方程中偏导项的值并构建损失函数^[111],微分方程求解器能直接参与神经网络前馈及反向传播计算^[112]。

4 结语

近年来,深度学习在水文预报的应用开启了新一轮水文数据驱动模型的研究热潮。本文总结了深度学习在水文预报性能提升、大数据利用、参数区域化以及水利工程影响下建模,和预报模型不确定性分析及模型解释等方面问题的研究。由于水文预报研究者不仅从技术层面关心模型预报性能,还关注深度学习模型结果的可解释性和外延性及物理一致性等,因此归纳了近期在整合深度学习与物理机制的水文预报研究方面的进展。在此基础上,从数据现状、模型研究及工程实践等不同方面讨论了仍存在的主要问题,并分析总结了未来研究趋势,以期对深度学习水文预报的进一步发展提供参考。

参考文献(References):

- [1] YAN F. Floods and culture[M]//HUANG G, SHEN Z. Urban planning and water-related disaster management. Cham: Springer International Publishing, 2019: 13-22. DOI: [10.1007/978-3-319-90173-2_2](https://doi.org/10.1007/978-3-319-90173-2_2)
- [2] 包为民. 水文预报[M]. 4版,北京:中国水利水电出版社, 2009. (BAO W M. Hydrological forecasting[M]. 4th ed, Beijing:China Water & Power Press, 2009. (in Chinese))
- [3] BLÖSCHL G, BIERKENS M F P, CHAMBEL A, et al. Twenty-three unsolved problems in hydrology (UPH): A community perspective[J]. *Hydrological Sciences Journal, Taylor & Francis*, 2019, 64(10): 1141-1158. DOI: [10.1080/02626667.2019.1620507](https://doi.org/10.1080/02626667.2019.1620507).
- [4] MCCABE M F, RODELL M, ALSDORF D E, et al. The future of earth observation in hydrology[J]. *Hydrology and Earth System Sciences*, 2017, 21(7): 3879-3914. DOI: [10.5194/hess-21-3879-2017](https://doi.org/10.5194/hess-21-3879-2017).
- [5] SHEN C. A transdisciplinary review of deep learning research and its relevance for water resources scientists[J]. *Water Resources Research*, 2018, 54(11): 8558-8593. DOI: [10.1029/2018WR022643](https://doi.org/10.1029/2018WR022643).
- [6] NEARING G S, KRATZERT F, SAMPSON A K, et al. What role does hydrological science play in the age of machine learning?[J]. *Water Resources Research*, 2021, 57(3): e2020WR028091. DOI: [10.1029/2020WR028091](https://doi.org/10.1029/2020WR028091).
- [7] 欧阳文字,叶磊,王梦云,等.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(中英文)*,2022,20(4):650-659.(OUYANG W Y, YE L, WANG M Y, MENG Z W, et al. Review of deep learning on hydrological forecasting I: Common models and applying methods[J]. *South-to-North Water Transfers and Water Science & Technology*, 2022, 20(4): 650-659. (in Chinese)) DOI: [10.13476/j.cnki.nsbjtk.2022.0067](https://doi.org/10.13476/j.cnki.nsbjtk.2022.0067).
- [8] 张弛,王本德,李伟.数据挖掘技术在水文预报中的应用及水文预报发展趋势研究[J].*水文*, 2007, 27(2): 74-77,85. (ZHANG C, WANG B D, LI W. Application of data mining technology in hydrological forecasting and research on development trend of hydrological forecasting[J]. *Journal of China Hydrology*, 2007, 27(2): 74-77,85. (in Chinese)) DOI: [10.3969/j.issn.1000-0852.2007.02.019](https://doi.org/10.3969/j.issn.1000-0852.2007.02.019).
- [9] LINARDATOS P, PASTEFANOPOULOS V, KOTSIANTIS S. Explainable AI: A review of machine learning interpretability methods[J]. *Entropy*, 2021, 23(1): 18. DOI: [10.3390/e23010018](https://doi.org/10.3390/e23010018).
- [10] FANG K, SHEN C, KIFER D, et al. Prolongation of SMAP to spatiotemporally seamless coverage of continental U S using a deep learning neural network[J]. *Geophysical Research Letters*, 2017, 44(21): 11030-11039. DOI: [10.1002/2017GL075619](https://doi.org/10.1002/2017GL075619).
- [11] ZHANG J, ZHU Y, ZHANG X, et al. Developing a long short-term memory (LSTM) based model for predicting water table depth in agricultural areas[J]. *Journal of Hydrology*, 2018, 561: 918-929. DOI: [10.1016/j.jhydrol.2018.04.065](https://doi.org/10.1016/j.jhydrol.2018.04.065).
- [12] WUNSCH A, LIESCH T, BRODA S. Groundwater

- level forecasting with artificial neural networks: A comparison of long short-term memory (LSTM), convolutional neural networks (CNNs), and non-linear autoregressive networks with exogenous input (NARX)[J]. *Hydrology and Earth System Sciences*, 2021, 25(3): 1671-1687. DOI: [10.5194/hess-25-1671-2021](https://doi.org/10.5194/hess-25-1671-2021).
- [13] ADDOR N, NEWMAN A J, MIZUKAMI N, et al. The CAMELS data set: Catchment attributes and meteorology for large-sample studies[J]. *Hydrology and Earth System Sciences*, 2017, 21(10): 5293-5313. DOI: [10.5194/hess-21-5293-2017](https://doi.org/10.5194/hess-21-5293-2017).
- [14] KRATZERT F, KLOTZ D, SHALEV G, et al. Towards learning universal, regional, and local hydrological behaviors via machine learning applied to large-sample datasets[J]. *Hydrology and Earth System Sciences*, 2019, 23(12): 5089-5110. DOI: [10.5194/hess-23-5089-2019](https://doi.org/10.5194/hess-23-5089-2019).
- [15] FENG D, FANG K, SHEN C. Enhancing streamflow forecast and extracting insights using long-short term memory networks with data integration at continental scales[J]. *Water Resources Research*, 2020, 56(9): e2019WR026793. DOI: [10.1029/2019WR026793](https://doi.org/10.1029/2019WR026793).
- [16] KRATZERT F, KLOTZ D, BRENNER C, et al. Rainfall-runoff modelling using long short-term memory (LSTM) networks[J]. *Hydrology and Earth System Sciences*, 2018, 22(11): 6005-6022. DOI: [10.5194/hess-22-6005-2018](https://doi.org/10.5194/hess-22-6005-2018).
- [17] KIM T, YANG T, GAO S, et al. Can artificial intelligence and data-driven machine learning models match or even replace process-driven hydrologic models for streamflow simulation?: A case study of four watersheds with different hydro-climatic regions across the CONUS[J]. *Journal of Hydrology*, 2021, 598: 126423. DOI: [10.1016/j.jhydrol.2021.126423](https://doi.org/10.1016/j.jhydrol.2021.126423).
- [18] LEES T, BUECHEL M, ANDERSON B, et al. Benchmarking data-driven rainfall-runoff models in Great Britain: A comparison of long short-term memory (LSTM)-based models with four lumped conceptual models[J]. *Hydrology and Earth System Sciences*, 2021, 25(10): 5517-5534. DOI: [10.5194/hess-25-5517-2021](https://doi.org/10.5194/hess-25-5517-2021).
- [19] KAO I F, LIOU J Y, LEE M H, et al. Fusing stacked autoencoder and long short-term memory for regional multistep-ahead flood inundation forecasts[J]. *Journal of Hydrology*, 2021, 598: 126371. DOI: [10.1016/j.jhydrol.2021.126371](https://doi.org/10.1016/j.jhydrol.2021.126371).
- [20] RAHMANI F, LAWSON K, OUYANG W, et al. Exploring the exceptional performance of a deep learning stream temperature model and the value of streamflow data[J]. *Environmental Research Letters*, IOP Publishing, 2021, 16(2):024025. DOI: [10.1088/1748-9326/abd501](https://doi.org/10.1088/1748-9326/abd501).
- [21] ZHI W, FENG D, TSAI W P, et al. From hydrometeorology to river water quality: Can a deep learning model predict dissolved oxygen at the continental scale?[J]. *Environmental Science & Technology*, American Chemical Society, 2021, 55(4): 2357-2368. DOI: [10.1021/acs.est.0c06783](https://doi.org/10.1021/acs.est.0c06783).
- [22] SAHRAEI A, HOUSKA T, BREUER L. Deep learning for isotope hydrology: The application of long short-term memory to estimate high temporal resolution of the stable isotope concentrations in stream and groundwater[J]. *Frontiers in Water*, 2021,55(4): 2357-2368. DOI: [10.3389/frwa.2021.740044](https://doi.org/10.3389/frwa.2021.740044).
- [23] ADIKARI K E, SHRESTHA S, RATNAYAKE D T, et al. Evaluation of artificial intelligence models for flood and drought forecasting in arid and tropical regions[J]. *Environmental Modelling & Software*, 2021, 144: 105136. DOI: [10.1016/j.envsoft.2021.105136](https://doi.org/10.1016/j.envsoft.2021.105136).
- [24] DUAN S, ULLRICH P, SHU L. Using convolutional neural networks for streamflow projection in California[J]. *Frontiers in Water*, 2020, 2: 28. DOI: [10.3389/frwa.2020.00028](https://doi.org/10.3389/frwa.2020.00028).
- [25] GHIMIRE S, YASEEN Z M, FAROOQUE A A, et al. Streamflow prediction using an integrated methodology based on convolutional neural network and long short-term memory networks[J]. *Scientific Reports*, 2021, 11(1): 17497. DOI: [10.1038/s41598-021-96751-4](https://doi.org/10.1038/s41598-021-96751-4).
- [26] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting[C]// Proceedings of the 28th International Conference on Neural Information Processing Systems. Cambridge, MA, USA: MIT Press, 2015: 802-810.
- [27] ADDOR N, DO H X, ALVAREZ-GARRETON C, et al. Large-sample hydrology: Recent progress, guidelines for new datasets and grand challenges[J]. *Hydrological Sciences Journal*, Taylor & Francis, 2020, 65(5): 712-725. DOI: [10.1080/02626667.2019.1683182](https://doi.org/10.1080/02626667.2019.1683182).
- [28] CLARK M P, RUPP D E, WOODS R A, et al. Hydrological data assimilation with the ensemble Kalman filter: Use of streamflow observations to update states in a distributed hydrological model[J].

- Advances in Water Resources*, 2008, 31(10): 1309-1324. DOI: [10.1016/j.advwatres.2008.06.005](https://doi.org/10.1016/j.advwatres.2008.06.005).
- [29] XIANG Z, YAN J, DEMIR I. A rainfall-runoff model with lstm-based sequence-to-sequence learning[J]. *Water Resources Research, John Wiley & Sons, Ltd*, 2020, 56(1): e2019WR025326. DOI: [10.1029/2019WR025326](https://doi.org/10.1029/2019WR025326).
- [30] FANG K, SHEN C. Near-Real-Time forecast of satellite-based soil moisture using long short-term memory with an adaptive data integration kernel[J]. *Journal of Hydrometeorology, Boston MA, USA: American Meteorological Society*, 2020, 21(3): 399-413. DOI: [10.1175/JHM-D-19-0169.1](https://doi.org/10.1175/JHM-D-19-0169.1).
- [31] 芮孝芳. 数值天气预报的成功经验对洪水预报的启示[J]. *水利水电科技进展*, 2019, 39(1): 1-6. (RUI X F. Inspirations of successful experience of numerical weather prediction to flood forecasting[J]. *Advances in Science and Technology of Water Resources*, 2019, 39(1): 1-6. (in Chinese)) DOI: [10.3880/j.issn.1006-7647.2019.01.001](https://doi.org/10.3880/j.issn.1006-7647.2019.01.001).
- [32] KRATZERT F, KLOTZ D, HOCHREITER S, et al. A note on leveraging synergy in multiple meteorological data sets with deep learning for rainfall-runoff modeling[J]. *Hydrology and Earth System Sciences*, 2021, 25(5): 2685-2703. DOI: [10.5194/hess-25-2685-2021](https://doi.org/10.5194/hess-25-2685-2021).
- [33] WANG C, TANG G, GENTINE P. PrecipGAN: merging microwave and infrared data for satellite precipitation estimation using generative adversarial network[J]. *Geophysical Research Letters*, 2021, 48(5): e2020GL092032. DOI: [10.1029/2020GL092032](https://doi.org/10.1029/2020GL092032).
- [34] ANDERSON S, RADIĆ V. Evaluation and interpretation of convolutional long short-term memory networks for regional hydrological modelling[J]. *Hydrology and Earth System Sciences*, 2022, 26(3): 795-825. DOI: [10.5194/hess-26-795-2022](https://doi.org/10.5194/hess-26-795-2022).
- [35] WUNSCH A, LIESCH T, CINKUS G, et al. Karst spring discharge modeling based on deep learning using spatially distributed input data[J]. *Hydrology and Earth System Sciences*, 2022, 26(9): 2405-2430. DOI: [10.5194/hess-26-2405-2022](https://doi.org/10.5194/hess-26-2405-2022).
- [36] FANG K, KIFER D, LAWSON K, et al. The data synergy effects of time-series deep learning models in hydrology[J]. *Water Resources Research*, 2022, 58(4): e2021WR029583. DOI: [10.1029/2021WR029583](https://doi.org/10.1029/2021WR029583).
- [37] HRACHOWITZ M, SAVENIJE H H G, BLÖSCHL G, et al. A decade of predictions in ungauged basins (PUB): A review[J]. *Hydrological Sciences Journal, Taylor & Francis*, 2013, 58(6): 1198-1255. DOI: [10.1080/02626667.2013.803183](https://doi.org/10.1080/02626667.2013.803183).
- [38] KRATZERT F, KLOTZ D, HERRNEGGER M, et al. Toward improved predictions in ungauged basins: Exploiting the power of machine learning[J]. *Water Resources Research*, 2019, 55(12): 11344-11354. DOI: [10.1029/2019WR026065](https://doi.org/10.1029/2019WR026065).
- [39] MA K, FENG D, LAWSON K, et al. Transferring hydrologic data across continents-leveraging data-rich regions to improve hydrologic prediction in data-sparse regions[J]. *Water Resources Research*, 2021, 57(5): e2020WR028600. DOI: [10.1029/2020WR028600](https://doi.org/10.1029/2020WR028600).
- [40] GRILL G, LEHNER B, THIEME M, et al. Mapping the world's free-flowing rivers[J]. *Nature*, 2019, 569(7755): 215-221. DOI: [10.1038/s41586-019-1111-9](https://doi.org/10.1038/s41586-019-1111-9).
- [41] 孙志禹, 陈永柏, 李翀, 等. 中国水库温室气体研究(2009—2019): 回顾与展望[J]. *水利学报*, 2020, 51(3): 253-267. (SUN Z Y, CHEN Y B, LI C, et al. Research of reservoir greenhouse gas emissions in China (2009-2019): Review and outlook[J]. *Journal of Hydraulic Engineering*, 2020, 51(3): 253-267. (in Chinese)) DOI: [10.13243/j.cnki.slxb.20190478](https://doi.org/10.13243/j.cnki.slxb.20190478).
- [42] OUYANG W, LAWSON K, FENG D, et al. Continental-scale streamflow modeling of basins with reservoirs: Towards a coherent deep-learning-based strategy[J]. *Journal of Hydrology*, 2021, 599: 126455. DOI: [10.1016/j.jhydrol.2021.126455](https://doi.org/10.1016/j.jhydrol.2021.126455).
- [43] HANASAKI N, KANAE S, OKI T. A reservoir operation scheme for global river routing models[J]. *Journal of Hydrology*, 2006, 327(1): 22-41. DOI: [10.1016/j.jhydrol.2005.11.011](https://doi.org/10.1016/j.jhydrol.2005.11.011).
- [44] YASSIN F, RAZAVI S, ELSHAMY M, et al. Representation and improved parameterization of reservoir operation in hydrological and land-surface models[J]. *Hydrology and Earth System Sciences*, 2019, 23(9): 3735-3764. DOI: [10.5194/hess-23-3735-2019](https://doi.org/10.5194/hess-23-3735-2019).
- [45] ZHANG D, LIN J, PENG Q, et al. Modeling and simulating of reservoir operation using the artificial neural network, support vector regression, deep learning algorithm[J]. *Journal of Hydrology*, 2018, 565: 720-736. DOI: [10.1016/j.jhydrol.2018.08.050](https://doi.org/10.1016/j.jhydrol.2018.08.050).
- [46] YANG S, YANG D, CHEN J, et al. Real-time reservoir operation using recurrent neural networks and inflow forecast from a distributed hydrological model[J]. *Journal of Hydrology*, 2019, 579: 124229. DOI: [10.1016/j.jhydrol.2019.124229](https://doi.org/10.1016/j.jhydrol.2019.124229).
- [47] TURNER S W D, DOERING K, VOISIN N. Data-

- driven reservoir simulation in a large-scale hydrological and water resource model[J]. *Water Resources Research*, 2020, 56(10): e2020WR027902. DOI: 10.1029/2020WR027902.
- [48] BEVEN K. Deep learning, hydrological processes and the uniqueness of place[J]. *Hydrological Processes*, 2020, 34(16): 3608-3613. DOI: 10.1002/hyp.13805.
- [49] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep learning[M]. MIT press, 2016.
- [50] FANG K, KIFER D, LAWSON K, et al. Evaluating the potential and challenges of an uncertainty quantification method for long short-term memory models for soil moisture predictions[J]. *Water Resources Research*, John Wiley & Sons, Ltd, 2020, 56(12): e2020WR028095. DOI: 10.1029/2020WR028095.
- [51] KLOTZ D, KRATZERT F, GAUCH M, et al. Uncertainty estimation with deep learning for rainfall-runoff modelling[J]. *Hydrology and Earth System Sciences Discussions*, 2021, 2021: 1-32. DOI: 10.5194/hess-2021-154.
- [52] BISHOP C M. Mixture density networks[R]. Birmingham: Aston University, 1994. DOI: 10.1109/IJCNN.2000.860813
- [53] LAIO F, TAMEA S. Verification tools for probabilistic forecasts of continuous hydrological variables[J]. *Hydrology and Earth System Sciences*, 2007, 11(4): 1267-1277. DOI: 10.5194/hess-11-1267-2007.
- [54] KRAPU C, BORSUK M, KUMAR M. Gradient-based inverse estimation for a rainfall-runoff model[J]. *Water Resources Research*, 2019, 55(8): 6625-6639. DOI: 10.1029/2018WR024461.
- [55] SAMEK W, WIEGAND T, MÜLLER K-R. Explainable artificial intelligence: understanding, visualizing and interpreting deep learning models[J]. *ITU Journal: ICT Discoveries*, 2017(1). DOI: 10.48550/arXiv.1708.08296.
- [56] 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. DOI: 10.1038/s41586-019-0912-1.
- [57] 芮孝芳. 数据密集范式与水文学的未来[J]. *水利水电科技进展*, 2018, 38(6): 1-7. (RUI X F. Hydrology future and data-intensive paradigm[J]. *Advances in Science and Technology of Water Resources*, 2018, 38(6): 1-7. (in Chinese)) DOI: 10.3880/j.issn.1006-7647.2018.06.001.
- [58] MORRIS M D. Factorial sampling plans for preliminary computational experiments[J]. *Technometrics*, Taylor & Francis, 1991, 33(2): 161-174. DOI: 10.1080/00401706.1991.10484804.
- [59] BACH S, BINDER A, MONTAVON G, et al. On pixel-wise explanations for non-linear classifier decisions by layer-wise relevance propagation[J]. *PLOS ONE*, Public Library of Science, 2015, 10(7): 1-46. DOI: 10.1371/journal.pone.0130140.
- [60] LUNDBERG S M, LEE S I. A unified approach to interpreting model predictions[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc. , 2017: 4768-4777.
- [61] DIKSHIT A, PRADHAN B. Interpretable and explainable AI (XAI) model for spatial drought prediction[J]. *Science of The Total Environment*, 2021, 801: 149797. DOI: 10.1016/j.scitotenv.2021.149797.
- [62] LIN Y, WANG D, WANG G, et al. A hybrid deep learning algorithm and its application to streamflow prediction[J]. *Journal of Hydrology*, 2021, 601: 126636. DOI: 10.1016/j.jhydrol.2021.126636.
- [63] HU X, SHI L, LIN G, et al. Comparison of physical-based, data-driven and hybrid modeling approaches for evapotranspiration estimation[J]. *Journal of Hydrology*, 2021, 601: 126592. DOI: 10.1016/j.jhydrol.2021.126592.
- [64] WANG R, KIM J H, LI M H. Predicting stream water quality under different urban development pattern scenarios with an interpretable machine learning approach[J]. *Science of The Total Environment*, 2021, 761: 144057. DOI: 10.1016/j.scitotenv.2020.144057.
- [65] RIBEIRO M T, SINGH S, GUESTRIN C. "Why should I trust you?": Explaining the predictions of any classifier[C]// Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, NY, USA: Association for Computing Machinery, 2016: 1135-1144. DOI: 10.1145/2939672.2939778
- [66] WORLAND SCOTT C, STEINSCHNEIDER S, ASQUITH W, et al. Prediction and inference of flow duration curves using multioutput neural networks[J]. *Water Resources Research*, 2019, 55(8): 6850-6868. DOI: 10.1029/2018WR024463.
- [67] PAN B, HSU K, AGHAKOUCHAK A, et al. Improving precipitation estimation using convolutional neural network[J]. *Water Resources Research*, 2019, 55(3): 2301-2321. DOI: 10.1029/2018WR024090.

- [68] SCHMIDT L, HEBE F, ATTINGER S, et al. Challenges in applying machine learning models for hydrological inference: A case study for flooding events across Germany[J]. *Water Resources Research*, 2020, 56(5): e2019WR025924. DOI: 10.1029/2019WR025924.
- [69] BREIMAN L. Random forests[J]. *Machine Learning*, 2001, 45(1): 5-32. DOI: 10.1023/A:1010933404324.
- [70] YOKOO K, ISHIDA K, ERCAN A, et al. Capabilities of deep learning models on learning physical relationships: Case of rainfall-runoff modeling with LSTM[J]. *Science of The Total Environment*, 2022, 802: 149876. DOI: 10.1016/j.scitotenv.2021.149876.
- [71] 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. DOI: 10.1109/TKDE.2017.2720168.
- [72] 夏军. 水文尺度问题[J]. *水利学报*, 1993(5): 32-37. (XIA J. Hydrological scale problem[J]. *Journal of Hydraulic Engineering*, 1993(5): 32-37. (in Chinese)) DOI: 10.3321/j.issn:0559-9350.1993.05.004.
- [73] TSAI W P, FENG D, PAN M, et al. From calibration to parameter learning: harnessing the scaling effects of big data in geoscientific modeling[J]. *Nature Communications*, 2021, 12(1): 5988. DOI: 10.1038/s41467-021-26107-z.
- [74] ZHAO W L, GENTINE P, REICHSTEIN M, et al. Physics-constrained machine learning of evapotranspiration[J]. *Geophysical Research Letters*, 2019, 46(24): 14496-14507. DOI: 10.1029/2019GL085291.
- [75] BENNETT A, NIJSSEN B. Deep learned process parameterizations provide better representations of turbulent heat fluxes in hydrologic models[J]. *Water Resources Research*, 2021, 57(5): e2020WR029328. DOI: 10.1029/2020WR029328.
- [76] CLARK M P, NIJSSEN B, LUNDQUIST J D, et al. A unified approach for process-based hydrologic modeling: 1. modeling concept[J]. *Water Resources Research*, John Wiley & Sons, Ltd, 2015, 51(4): 2498-2514. DOI: 10.1002/2015WR017198.
- [77] SUN A Y, SCANLON B R, ZHANG Z, et al. Combining physically based modeling and deep learning for fusing grace satellite data: can we learn from mismatch?[J]. *Water Resources Research*, 2019, 55(2): 1179-1195. DOI: 10.1029/2018WR023333.
- [78] CHO K, KIM Y. Improving streamflow prediction in the WRF-Hydro model with LSTM networks[J]. *Journal of Hydrology*, 2022, 605: 127297. DOI: 10.1016/j.jhydrol.2021.127297.
- [79] HAN H, MORRISON R R. Improved runoff forecasting performance through error predictions using a deep-learning approach[J]. *Journal of Hydrology*, 2022, 608: 127653. DOI: 10.1016/j.jhydrol.2022.127653.
- [80] FRAME J M, KRATZERT F, RANEY II A, et al. Post-processing the National Water Model with long short-term memory networks for streamflow predictions and model diagnostics[J]. *Journal of the American Water Resources Association*, 2021, 57(6): 885-905. DOI: 10.1111/1752-1688.12964.
- [81] BOUCHER M A, QUILTY J, ADAMOWSKI J. Data assimilation for streamflow forecasting using extreme learning machines and multilayer perceptrons[J]. *Water Resources Research*, 2020, 56(6): e2019WR026226. DOI: 10.1029/2019WR026226.
- [82] WILLARD J, JIA X W, XU S M, et al. Integrating scientific knowledge with machine learning for engineering and environmental systems[J]. *arXiv*, 2003.04919, 2021. DOI: 10.48550/arXiv.2003.04919.
- [83] WANG N, ZHANG D, CHANG H, et al. Deep learning of subsurface flow via theory-guided neural network[J]. *Journal of Hydrology*, 2020, 584: 124700. DOI: 10.1016/j.jhydrol.2020.124700.
- [84] KARPATNE A, WATKINS W, READ J, et al. Physics-guided neural networks (PGNN): An application in lake temperature modeling[J]. *arXiv*, 1710.11431, 2017. DOI: 10.48550/arXiv.1710.11431.
- [85] XIE K, LIU P, ZHANG J, et al. Physics-guided deep learning for rainfall-runoff modeling by considering extreme events and monotonic relationships[J]. *Journal of Hydrology*, 2021, 603: 127043. DOI: 10.1016/j.jhydrol.2021.127043.
- [86] JIA X, WILLARD J, KARPATNE A, et al. Physics-guided machine learning for scientific discovery: An application in simulating lake temperature profiles[J]. *ACM/IMS Trans. Data Sci.*, New York, NY, USA: Association for Computing Machinery, 2021, 2(3). DOI: 10.1145/3447814.
- [87] YANG S, YANG D, CHEN J, et al. A physical process and machine learning combined hydrological model for daily streamflow simulations of large watersheds with limited observation data[J]. *Journal of Hydrology*, 2020, 590: 125206. DOI: 10.1016/j.jhydrol.2020.125206.

- [88] READ J S, JIA X, WILLARD J, et al. Process-guided deep learning predictions of lake water temperature[J]. *Water Resources Research*, 2019, 55(11): 9173-9190. DOI: [10.1029/2019WR024922](https://doi.org/10.1029/2019WR024922).
- [89] HOEDT P-J, KRATZERT F, KLOTZ D, et al. MC-LSTM: mass-conserving LSTM[J]. *arXiv*, 2101.05186, 2021. DOI: [10.48550/arXiv.2101.05186](https://doi.org/10.48550/arXiv.2101.05186).
- [90] JIANG S, ZHENG Y, SOLOMATINE D. Improving AI system awareness of geoscience knowledge: symbiotic integration of physical approaches and deep learning[J]. *Geophysical Research Letters*, 2020, 47(13): e2020GL088229. DOI: [10.1029/2020GL088229](https://doi.org/10.1029/2020GL088229).
- [91] 陈军飞, 邓梦华, 王慧敏. 水利大数据研究综述[J]. *水科学进展*, 2017, 28(4): 622-631. (CHEN J F, DENG M H, WANG H M. A review of water resources big data[J]. *Advances in Water Science*, 2017, 28(4): 622-631. (in Chinese)) DOI: [10.14042/j.cnki.32.1309.2017.04.017](https://doi.org/10.14042/j.cnki.32.1309.2017.04.017).
- [92] LI X, CHENG G, WANG L, et al. Boosting geoscience data sharing in China[J]. *Nature Geoscience*, 2021, 14(8): 541-542. DOI: [10.1038/s41561-021-00808-y](https://doi.org/10.1038/s41561-021-00808-y).
- [93] 杨雅萍, 姜侯, 孙九林. 科学数据共享实践: 以国家地球系统科学数据中心为例[J]. *地球信息科学学报*, 2020, 22(6): 1358-1369. (YANG Y P, JIANG H, SUN J L. Practice of scientific data sharing: A case study of the national earth system science data center[J]. *Journal of Geo-Information Science*, 2020, 22(6): 1358-1369. (in Chinese)) DOI: [10.12082/dqxxkx.2020.200110](https://doi.org/10.12082/dqxxkx.2020.200110).
- [94] 李新, 南卓铜, 吴立宗, 等. 中国西部环境与生态科学数据中心: 面向西部环境与生态科学的数据集成与共享[J]. *地球科学进展*, 2008, 23(6): 628-637. (LI X, NAN Z T, WU L Z, et al. Environmental and ecological science data center for west China: integration and sharing of environmental and ecological data[J]. *Advances in Earth Science*, 2008, 23(6): 628-637. (in Chinese)) DOI: [10.3321/j.issn:1001-8166.2008.06.010](https://doi.org/10.3321/j.issn:1001-8166.2008.06.010).
- [95] HAO Z, JIN J, XIA R, et al. CCAM: China catchment attributes and meteorology dataset[J]. *Earth System Science Data*, 2021, 13(12): 5591-5616. DOI: [10.5194/essd-13-5591-2021](https://doi.org/10.5194/essd-13-5591-2021).
- [96] HORNER I, RENARD B, LE COZ J, et al. Impact of stage measurement errors on streamflow uncertainty[J]. *Water Resources Research*, 2018, 54(3): 1952-1976. DOI: [10.1002/2017WR022039](https://doi.org/10.1002/2017WR022039).
- [97] NEVO S, ELIDAN G, HASSIDIM A, et al. ML-based flood forecasting: Advances in scale, accuracy and reach[J]. *arxiv*, 2012, 00671, 2020, 2020. DOI: [10.48550/arXiv.2012.00671](https://doi.org/10.48550/arXiv.2012.00671).
- [98] DENG J, DONG W, SOCHER R, et al. ImageNet: A large-scale hierarchical image database[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. 2009: 248-255. DOI: [10.1109/CVPR.2009.5206848](https://doi.org/10.1109/CVPR.2009.5206848).
- [99] PUDASHINE J, GUYOT A, PETITJEAN F, et al. Deep learning for an improved prediction of rainfall retrievals from commercial microwave links[J]. *Water Resources Research*, 2020, 56(7): e2019WR026255. DOI: [10.1029/2019WR026255](https://doi.org/10.1029/2019WR026255).
- [100] GUPTA A, CHANG T, WALKER J, et al. Towards continuous streamflow monitoring with time-lapse cameras and deep learning[C]//ACM SIGCAS/SIGCHI Conference on Computing and Sustainable Societies (COMPASS), New York, NY, USA, 2022: 353-363. DOI: [10.1145/3530190.3534805](https://doi.org/10.1145/3530190.3534805).
- [101] ELTNER A, BRESSAN P O, AKIYAMA T, et al. Using deep learning for automatic water stage measurements[J]. *Water Resources Research*, 2021, 57(3): e2020WR027608. DOI: [10.1029/2020WR027608](https://doi.org/10.1029/2020WR027608).
- [102] SHEN C, CHEN X, LALOY E. Editorial: broadening the use of machine learning in hydrology[J]. *Frontiers in Water*, 2021, 3: 38. DOI: [10.3389/frwa.2021.681023](https://doi.org/10.3389/frwa.2021.681023).
- [103] ZHANG Y, CHIEW F H S, LIU C, et al. Can remotely sensed actual evapotranspiration facilitate hydrological prediction in ungauged regions without runoff calibration?[J]. *Water Resources Research*, 2020, 56(1): e2019WR026236. DOI: [10.1029/2019WR026236](https://doi.org/10.1029/2019WR026236).
- [104] MOSHE Z, METZGER A, ELIDAN G, et al. HydroNets: leveraging river structure for hydrologic modeling[J]. *arXiv*, 2007.00595, 2020. DOI: [10.48550/arXiv.2007.00595](https://doi.org/10.48550/arXiv.2007.00595).
- [105] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2017: 6000-6010.
- [106] ZHOU H Y, ZHANG S H, PENG J Q, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2021, 35(12): 11106-11115. DOI: [10.48550/arXiv.2012.07436](https://doi.org/10.48550/arXiv.2012.07436).
- [107] WU Z, PAN S, CHEN F, et al. A comprehensive

- survey on graph neural networks[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(1): 4-24. DOI: [10.1109/TNNLS.2020.2978386](https://doi.org/10.1109/TNNLS.2020.2978386).
- [108] RUBANOVA Y, CHEN R T Q, DUVENAUD D K. Latent ordinary differential equations for irregularly-sampled time series[C]//H WALLACH, H LAROCHELLE, A BEYGELZIMER, et al. *Advances in Neural Information Processing Systems*. Curran Associates, Inc. , 2019, 32.
- [109] RAVURI S, LENC K, WILLSON M, et al. Skilful precipitation nowcasting using deep generative models of radar[J]. *Nature*, 2021, 597(7878): 672-677. DOI: [10.1038/s41586-021-03854-z](https://doi.org/10.1038/s41586-021-03854-z).
- [110] RACKAUCKAS C, MA Y B, MARTENSEN J, et al. Universal differential equations for scientific machine learning[J]. *arXiv* , 2001.04385, 2020. DOI: [10.48550/arXiv.2001.04385](https://doi.org/10.48550/arXiv.2001.04385).
- [111] BANDAI T, GHEZZEHEI T A. Physics-informed neural networks with monotonicity constraints for Richardson-Richards equation: Estimation of constitutive relationships and soil water flux density from volumetric water content measurements[J]. *Water Resources Research*, 2021, 57(2): e2020WR027642. DOI: [10.1029/2020WR027642](https://doi.org/10.1029/2020WR027642).
- [112] GILADI N, BEN-HAIM Z, NEVO S, et al. Physics-aware downsampling with deep learning for scalable flood modeling[C]//A BEYGELZIMER, Y DAUPHIN, P LIANG, et al. *Advances in Neural Information Processing Systems*. 2021. DOI: [10.48550/arXiv.2106.07218](https://doi.org/10.48550/arXiv.2106.07218).

Review of deep learning for hydrological forecasting II: Research progress and prospect

OUYANG Wenyu, YE Lei, GU Xuezhi, LI Xiaoyang, ZHANG Chi
(*School of Hydraulic Engineering, Dalian University of Technology, Dalian 116024, China*)

Abstract: Many studies focus on the application of deep learning in data-driven hydrological models for hydrological forecasting. The recent research progress of deep learning models on hydrological forecasting are reviewed. Deep learning shows new features unseen in non-deep learning data-driven models. It can also help to address some old challenges in hydrological modeling, such as hydrological modeling under the impact of hydraulic projects and uncertainty analysis. Deep learning can be a tool for knowledge discovery. We also describe some studies for the integration of deep learning and domain knowledge in hydrology, including incorporating deep learning in physical mechanism models and physics-guided deep learning. We also highlight the challenges in applying deep learning to hydrological forecasting and propose potential opportunities. This review can provide a useful reference for further research on deep-learning-based hydrological forecasting.

Key words: deep learning; hydrological forecasting; physical mechanism; integrated modeling