

DOI:10.3876/j.issn.1000-1980.2025.05.001

# 物理引导数据驱动方法研究综述及其在水文模型构建中的应用与展望

冯 钧<sup>1,2</sup>, 邵萍萍<sup>3</sup>, 张继茹<sup>1,2</sup>, 刘学毅<sup>1,2</sup>

(1. 水利部水利大数据重点实验室, 河海大学, 江苏 南京 211100; 2. 河海大学计算机与软件学院, 江苏 南京 211100;  
3. 江苏信息职业技术学院物联网工程学院(信息学院), 江苏 无锡 214153)

**摘要:** 为探索物理机理模型与数据驱动模型的融合方法, 分析了现有物理引导融合驱动方法的实现方式, 对基于理论引导数据科学(TGDS)的物理引导融合驱动方法在不同领域的研究现状进行了分类与总结, 并提出了物理引导反馈融合驱动方法和物理引导编码融合驱动方法这种新的分类方式, 结合水文建模领域的特点, 详细阐述了物理引导融合驱动方法在水文模型构建中的挑战, 并对未来的研究方向进行了展望。认为基于TGDS的物理引导融合驱动方法, 能够增强预测结果的物理一致性, 减少预测误差的累积, 提高模型的可解释性, 同时能为洪水预报水文模型的改进提供可行路径, 既能减少机理模型因概化过程带来的预测精度不高的问题, 又能有效改善由于数据驱动模型对样本的过度依赖导致的可解释性低的问题; 但该方法在应用中面临着计算能力有限、提取多源数据特征不够准确、参数调整不够灵活的问题, 因此在未来研究中可以结合可微分建模或者采用大模型结合领域知识图谱的方法, 进一步探索洪水时序预测建模研究, 以更好地应对复杂环境下的洪水预报需求。

**关键词:** 物理引导数据驱动; 融合驱动; 洪水预报; 人工智能

**中图分类号:** P333 **文献标志码:** A **文章编号:** 1000-1980(2025)05-0001-09

## Research review of physics-guided data-driven methods and their application and prospects in hydrological model development

FENG Jun<sup>1,2</sup>, SHAO Pingping<sup>3</sup>, ZHANG Jiru<sup>1,2</sup>, LIU Xueyi<sup>1,2</sup>

(1. Key Laboratory of Water Big Data Technology of Ministry of Water Resources, Hohai University, Nanjing 211100, China;  
2. College of Computer Science and Software Engineering, Hohai University, Nanjing 211100, China  
3. The Internet of Things Engineering College (Information Security College), Jiangsu Vocational College of Information Technology, Wuxi 214153, China)

**Abstract:** To explore the fusion methods of physical mechanism models and data-driven models, the implementation pathway of existing physics-guided fusion driving methods was analyzed. The research status of physics-guided fusion driving methods based on theory-guided data science (TGDS) in different fields was classified and summarized, and new classification methods, such as the physics-guided feedback fusion driving method and the physics-guided coding fusion driving method, were proposed. According to the characteristics of the hydrological modeling field, the challenges of the physics-guided fusion driving method in hydrological model construction were elaborated in detail. And the future research directions have been prospectively discussed. It was believed that the physics-guided fusion driving method based on TGDS could enhance the physical consistency of prediction results, reduce the accumulation of prediction errors, and improve the interpretability of the model, providing a feasible path for improving flood

**基金项目:** 国家重点研发计划项目(2023YFC3209203); 国家自然科学基金项目(62306007); 江苏省水利科技项目(2022002, 2023044); 水利部重大科技项目(SKS-2022132)

**作者简介:** 冯钧(1969—), 女, 教授, 博士, 主要从事数据管理、领域知识工程、水利大数据应用研究。E-mail: fengjun@hhu.edu.cn

**通信作者:** 邵萍萍(1987—), 女, 讲师, 博士, 主要从事时序预测、理论指导数据科学与洪水预报研究。E-mail: 200207060003@hhu.edu.cn

**引用本文:** 冯钧, 邵萍萍, 张继茹, 等. 物理引导数据驱动方法研究综述及其在水文模型构建中的应用与展望[J]. 河海大学学报(自然科学版), 2025, 53(5): 1-9.

FENG Jun, SHAO Pingping, ZHANG Jiru, et al. Research review of physics-guided data-driven methods and their application and prospects in hydrological model development[J]. Journal of Hohai University(Natural Sciences), 2025, 53(5): 1-9.

forecasting-oriented hydrological models. It could not only improve the low prediction accuracy caused by the generalization process of the mechanism model but also effectively improve the interpretability problem caused by the excessive dependence of data-driven models on samples. However, this method faces the problems of limited computing power, inaccurate extraction of multi-source data features, and inflexible parameter adjustment in its application. Therefore, in future research, differentiable modelling (DM) can be combined, or large models combined with domain knowledge graphs can be used to further explore the modeling of flood time series prediction, so as to better meet the needs of flood forecasting in complex environments.

**Key words:** physics-guided data driving; fusion driving; flood forecasting; artificial intelligence

洪水危害巨大,研究切实有效的洪水预报方法对洪水控制和灾害应急处理具有重要意义。作为防洪减灾中最重要的非工程措施,洪水预报的准确性直接关系到防灾减灾的成效,有效的洪水预报能够显著降低洪涝灾害对社会经济和人民生命财产安全造成的威胁<sup>[1]</sup>。洪水始于降雨,经过地表径流、土壤水、地下径流与蒸散发之间的相互转化,最终形成流域出口的径流。这个降雨-径流的全过程构成了一个具有时空多尺度动态结构的复杂系统。在目前的洪水预报研究中,物理机理方法已被证明能够实现有效的洪水推演与评估<sup>[2]</sup>。该方法基于水文学和数学原理,通过适当概化径流形成过程<sup>[3]</sup>构建水文物理模型,其优势在于模型参数具有明确物理意义,可通过测量或计算获得,能在确定条件下模拟洪水演进过程并揭示显性规律,适合全局性问题的分析。然而,该方法也存在一定的局限性:模型严格依照物理定律推导求解,参数需要人工率定,计算复杂度与效率难以平衡。由于数据集、参数和模型结构的差异导致预测不确定性增加,这些因素都制约了该方法在洪水预报中的应用。随着人工智能的快速发展,数据驱动方法在洪水预报领域展现出巨大潜力<sup>[4-5]</sup>,该方法通过复杂模式识别和非线性动力学模拟,从海量数据中提取有价值信息,其中最具代表性<sup>[6]</sup>的为深度学习模型。针对洪水时序数据具有的不确定性、非线性和非平稳性特点,该模型能有效捕捉其中的复杂非线性关系,优势在于能在开放条件和未知环境中挖掘隐式规律,更好地拟合径流时序数据<sup>[7-8]</sup>。数据驱动方法也存在着明显的不足:模型性能高度依赖数据样本的质量和规模,而洪水数据获取难度较大、成本偏高。此外,这类方法本质上属于黑盒模型,仅利用观测数据进行训练,训练过程没有洪水物理规律的引导,容易导致收敛缓慢、欠拟合甚至训练失败,有时甚至会产生违背洪水过程物理规律的输出结果。

为了更好地解决上述问题,一种理论引导数据科学(theory-guided data science, TGDS)<sup>[9]</sup>的融合驱动方法正日益受到广泛关注。该方法通过结合物理机理方法与数据驱动方法,利用领域知识和专家经验引导数据驱动模型,使其拟合过程更符合物理规律,从而提升模型的鲁棒性和物理一致性。目前,关于 TGDS 研究,学者们提出了不同的分类方式:Faroughi 等<sup>[10]</sup>将 TGDS 研究分为物理引导神经网络(physics-guided neural network, PGNN)、物理知情神经网络(physics-informed neural network, PINN)、物理编码神经网络(physics-encoded neural network, PENN)等类别;Chen 等<sup>[11]</sup>从软约束(通过损失函数将物理规律引入模型)和硬约束(将物理机理嵌入到数据驱动模型中)两种角度研究 TGDS 的实现方式;Huang 等<sup>[12]</sup>以 PINN 为例,从损失函数设计、参数初始化等关键环节深入分析了 PINN 的不同适用场景。由于 TGDS 方法能够确保模型的物理一致性,模型预测精度和可解释能力通常优于单一数据驱动模型,因此该方法不仅在洪水预报领域展现出巨大潜力,还在水文模拟、故障诊断、智能交通、电力系统分析等多个领域得到了广泛应用<sup>[13]</sup>。

水文建模领域经历了较长时间的发展,积累了丰富的知识与研究成果,主要包括物理规律、物理定律、先验知识以及经验等,被称为物理机理(或物理知识)。物理机理方法提供观测空间以外的可解释性和概括性规律,这与数据驱动方法从数据中提取隐式规律形成互补,将这些物理知识融合到数据驱动模型中,提出了物理引导融合驱动方法<sup>[14]</sup>,进而实现水文物理机理方法与数据驱动方法的有效融合,帮助模型输出更合理的预测结果。本文以 TGDS 为技术支撑,通过将洪水预报领域内的物理知识引入数据驱动模型中,形成物理引导融合驱动方法<sup>[15]</sup>来支撑水文模型构建与洪水预报研究:①对现有的物理引导融合驱动的 3 种实现方式进行概念描述与特点分析;②对 TGDS 为技术支撑的物理引导融合驱动方法在不同领域的研究现状进行了分类与总结,提出了物理引导反馈融合驱动方法和物理引导编码融合驱动方法这种新的分类方式;③对物理引导融合驱动方法在水文模型构建中的挑战进行了详细阐述,并展望了未来的研究方向。

## 1 物理引导融合驱动方法研究

现有的物理引导数据驱动的实现方式或者说物理机理模型与深度学习方法融合方式主要分为 3 类<sup>[16]</sup>。第一类以物理机理模型为主模型,引入数据驱动方法进行优化,考虑到物理机理模型是对实际物理过程进行

概化,可能会出现与实际环境不匹配的问题,学者们主要从 2 个方面进行改进:数据驱动方法实时校正物理机理模型的参数<sup>[17]</sup>、数据驱动方法辅助选取物理机理模型<sup>[18]</sup>。第二类主要为物理机理和数据驱动模型混合建模,主要包括:混合模块建模简化物理机理模型结构关系<sup>[19]</sup>、混合特征提取建模复杂非线性关系<sup>[20]</sup>。

第三类以数据驱动模型为主模型,引入物理机理进行部分修正。洪水预报领域的数据集往往存在多源、多尺度和高维异构的情况,不同时空尺度上的多种气候和洪水过程中的变量,在时空分辨率上通常不一致<sup>[21]</sup>,第一类融合方法不能很好地捕捉其中的非线性关系。洪水过程固有的随机性、非线性和非平稳性会导致预测结果的不确定性,第二类融合方法受限于建模复杂度、计算效率及预测精度的平衡限制,往往不能取得较高的精度,第三类融合方法可以更好地解决上述问题。洪水预报研究中存在着数据稀疏的问题,低质量的标记数据也会引入数据噪声的问题<sup>[22]</sup>,这在一定程度上影响了模型预测的准确性,通过引入物理机理到数据驱动模型中,可实现对数据驱动输出结果的校正,提升模型的可解释性。

目前,第三类融合方法中比较常用的是 TGDS,该方法旨在利用领域的科学知识,提高数据驱动模型的有效性,其中物理一致性是 TGDS 研究理论体系的重要组成部分,它通过将领域的物理知识融合到数据驱动模型中,引导数据驱动模型向符合领域先验知识与物理规律的方向训练与拟合,辅助构建可以进行科学解释的数据驱动模型,减少数据驱动模型对数据样本的依赖,更好地实现物理一致性。在数据驱动模型中引入物理一致性的方式很多,考虑到模型训练的准确性和模型构建的复杂性,一些学者试图将物理一致性纳入现有的数据科学模型学习框架中,而另一些学者则是通过不同方式将数据驱动模型与物理机理模型相结合:Luo 等<sup>[23]</sup>考虑到 Navier-Stokes 方程源于动量守恒,提出了一种编码非线性参数偏微分方程 (partial differential equation, PDE) 建模框架,通过结合物理原理指导模型优化,结合偏微分方程的第一原则和守恒性来降低相关参数的估计误差;Pathak 等<sup>[24]</sup>提出将约束与网络输出进行解耦,这种算法的约束结构简单,更新的网络参数也符合一定的置信概率区间;Karpatne 等<sup>[9]</sup>认为构建物理一致性模型的主要方法包括物理上一致的解作为初始点,结合物理先验和相关性制定概率空间的边界,将科学知识作为约束条件优化模型,在目标函数中编码科学知识正则项。本文从物理机理和数据驱动模型的融合方式及模型融合物理一致性的程度方面提出了 TGDS 研究现状的新分类:物理引导反馈融合驱动方法和物理引导编码融合驱动方法,如图 1 所示。物理引导反馈融合驱动方法主要是通过引入物理约束到损失函数中引导模型实现物理一致性,物理引导编码融合驱动模型则是将物理机理嵌入到数据驱动框架中实现模型的物理一致性;前者适用于数据资源较丰富,对计算实时性要求较高的业务场景,后者适用于数据样本受限,但是对预测精度有一定要求的时序数据处理业务场景。对于每一类模型,本文将具体阐述物理机理与数据驱动方法的结合方式和相应优势,并给出相关分析与展望。




图 1 物理机理模型、数据驱动模型与 TGDS 关系示意图

Fig. 1 Schematic diagram of relationship between physical mechanism models, data-driven models, and TGDS

1.1 物理引导反馈融合驱动方法

物理引导反馈融合驱动方法基于输入和输出之间的映射关系,结合复杂的动力学系统从数据集中获取不同的属性特征,通过引入物理约束到损失函数中,引导模型在训练过程中向着符合物理规律的方向进行,

进而使得整个模型的构建过程符合基本的物理规律和原则。在水文建模领域,该方法取得了有效的研究推广;Wang 等<sup>[25]</sup>采用 TGDS 神经网络 TgNN 研究地下水流;Raissi 等<sup>[26]</sup>详细讨论了结合 TGDS 的深度学习算法在水资源管理等方面的研究现状;He 等<sup>[27]</sup>结合生成对抗网络与 TGDS 构建高质量模型 TgGAN 来求解动态 PDE,用于解决具有非均匀模型参数的动态地下流问题。目前,物理引导反馈融合驱动方法主要包括两种网络构建方式:PGNN 和 PINN。

### 1.1.1 模型构建

PGNN 将输入与输出之间的物理约束条件转换成损失函数约束项,在训练时对违反物理认知的输出做出惩罚,从而引导神经网络学习对应的物理知识,使整个模型构建过程符合物理规律<sup>[28]</sup>。在 PGNN 的技术体系中,物理规律可以通过添加动力学方程的方式融合到模型中,使整个训练过程在物理规律的指导下进行有效的拟合。这种方法的优点在于训练方法相对简单,因此 Huang 等<sup>[29]</sup>采用 PGNN 加速了计算流体力学的迭代过程;Faroughi 等<sup>[30-31]</sup>考虑了训练数据背后的物理原理,并加速了模拟过程。需要注意的是,PGNN 需要依赖大量的数据集来训练,对数据集的质量要求较高,同时计算成本也相对较高,模型鲁棒性较低,模型的通用性也较低。

PINN 通过引入物理知识的正则项和边界约束构建模型的损失函数,使模型的训练和输出遵守物理规律,同时采用自动微分方法求解 PDE,通过最小化损失函数近似求解<sup>[26]</sup>。各个领域的学者对 PINN 进行了大量的研究<sup>[32-34]</sup>;Chen 等<sup>[35]</sup>进一步开发了基于 TGDS 框架的软约束模型 TgDLF,以解决实际场景中知识驱动与数据驱动融合的问题;考虑到 PINN 的初始化问题,Jia 等<sup>[36]</sup>利用合成数据对网络进行预训练,然后采用相对较少的真实数据样本对模型进行微调,进而有效模拟湖泊的温度变化规律;为了有效降低神经网络参数冗余问题,Daw 等<sup>[37]</sup>将物理规律约束融合到神经网络中,成功预测了空间湖泊温度,有效提升了模型的可解释性;Sun 等<sup>[38]</sup>将模型权重设置为地震波传播控制方程的参数,物理约束得到了有效集成;Yao 等<sup>[39]</sup>将物理模型和深度学习神经网络的输出进行了有效优化结合,充分抓取了较长时间尺度物理特征及短期随机隐式特征。总之,与 PGNN 相比,PINN 可在高非线性、有限数据集和随机噪声环境中提供较好的预测精度。但是 PINN 的收敛性还需要进一步证明,损失函数中多个正则项权重需要进一步优化,边界条件和初始条件的优化也需要进一步提升。此外该类模型的物理约束均为软约束,并不能保证整个过程都严格符合物理规律。

### 1.1.2 局限性分析

物理引导反馈融合驱动方法计算结构相对简单,并且能够提取非线性物理现象所映射的输入输出相关性,但是也存在一定的不足之处。

PGNN 输出结果的可解释性相对较低,此外当模型面对训练样本存在的稀疏性、噪声及缺失值的问题时,模型的鲁棒性往往相对较低。物理过程可能存在随机性也会导致模型的拟合过程具有一定的不确定性,模型的输入输出之间误差累积,会影响模型在学习底层物理关系时的泛化性。

PINN 在建模物理过程的动态特征时具有一定的优势,但是在非线性 PDE 构建过程中,收敛性需要进一步验证,同时 PINN 在全局最小值求解方面存在不足。在模型的训练过程和超参数优化时,PINN 损失函数中的不同损失项在训练过程中会互相“竞争”,进而影响训练过程的稳定性。当面对高维问题时,PINN 可能导致不连续的求解方案,进而提升计算成本。对于新的物理规律,PINN 需要额外训练一个神经网络,并调整相应的参数和权重,这在一定程度上限制了 PINN 的外推,相应的 PDE 参数、边界和初始条件的最优化问题也需要进一步分析。此外,现有的物理引导反馈融合驱动方法无法确保在每个点都不违反物理约束。

## 1.2 物理引导编码融合驱动方法

物理引导编码融合驱动方法是将物理知识编码到数据驱动模型中,对数据混沌性和数据漂移问题具有一定的优势。编码式融合驱动方式中的物理知识被硬编码到了神经网络中,部分研究人员通过施加物理先验知识的期望、方差、偏导数等不同形式,从而有效量化神经网络的误差曲线以及权重鲁棒性评估曲线。本文主要考虑了编码式融合驱动方法的 2 种主要形式:PENN 和神经网络常微分方程(neural ordinary differential equations,NeuralODE)。

### 1.2.1 模型构建

硬约束方法中的 PENN 通过编码领域先验知识和物理规律,将这些物理信息直接嵌入到神经网络架构中,对神经网络的偏差和权重进行鲁棒曲线估计和不确定性量化,进而提升模型的预测性能,Rao 等<sup>[40]</sup>在无

法采用 PDE 进行显式表征或者数据样本受到限制的场景中,提出将非线性系统的控制经验硬编码到循环卷积神经网络中,与物理引导反馈融合驱动模型相比,展现了较好的鲁棒性。此外,Rao 等<sup>[41]</sup>在复杂数据环境中,采用物理编码方式下的神经网络,有效建模时空 PDE。Ren 等<sup>[42]</sup>基于物理硬编码式神经网络和 PINN,构建了混合模型 PhyCRNet,能够有效应对低维度参数的时空变化,进而在低维空间中抓取数据时空特征,同时模型有效融合了可以显式表示时序推演特征的自回归网络,具有业务外推能力。

NeuralODE 则是另一类硬约束预测建模方法,通过学习训练数据中非线性变换的结构,将其编码到网络层中,确保了神经网络优化方程的可微性,神经网络的隐藏层通过使用可微函数,进而参数化隐藏状态导数,将离散序列转化为连续的非线性函数<sup>[43]</sup>,优点是利用一个较“浅”的网络来建模一个相对复杂的物理模型,无需构建更深的网络,进而降低模型计算成本。Ma 等<sup>[44]</sup>采用了伴随灵敏度方法计算梯度,用较小的计算内存控制误差,使模型具有更好的敏感度分析能力。Poli 等<sup>[45]</sup>优化了模型的实用性能,同时 Inners 等<sup>[46-47]</sup>将可微编程和通用微分方程的求解能力进行了有效融合优化。Lai 等<sup>[48]</sup>将 NeuralODE 有效集成到 PINN 中,用以降低物理建模与数据驱动结合过程中的偏差,改善了波动性较大的问题。Roehrl 等<sup>[49]</sup>结合正向模型,有效验证了 PINODE 在建模物理模型不确定性方面的优势。Dulny 等<sup>[50]</sup>将常微分方程 (ordinary differential equation, ODE) 系统建模复杂 PDE 与 NeuralODE 结合,可以有效提取 PDE 动力学物理特征。

1.2.2 局限性分析

物理引导编码融合驱动模型在融合复杂物理过程建模方面取得了一定的进展,但是在模型训练和建模过程中的不确定性量化方面仍有不足,其在收敛速度和样本敏感性方面也存在一定的局限性。在建模动态物理过程时,相对复杂的计算结构,也限制了该类融合驱动方法的推广,因此现有的硬约束方法需要做进一步的改进与优化。

2 物理引导融合驱动方法在水文模型构建中的应用与展望

学者们在基于物理机理构建洪水预报模型时,需要考虑变量的时变特征提取、非线性特征以及复杂现象模拟的计算复杂度等问题,数据驱动方法主要从输入输出数据中提取特征及隐式规律,它的非线性建模能力可以很好地解决上述问题。然而单一的数据驱动方法主要依赖于数据样本的数量与质量,训练过程不依赖物理规律,可能出现不符合科学常识的预测结果,因此需要领域先验知识与物理规则引导数据驱动模型向符合物理规律的方向拟合,确保输出结果的物理一致性,从而提升模型的可解释性。因此,在实际问题研究中,采用物理引导融合驱动方法,将有助于提升模型的整体性能。本节聚焦于物理引导融合驱动方法在水文模型构建中的一些主要困难与挑战,并回顾相关研究团队为解决这些问题所采取的措施,同时结合具体研究对该领域未来的发展方向进行展望。

2.1 主要挑战

物理引导反馈融合驱动方法的预测精度与损失函数密切相关,考虑到实际水文模型构建和洪水预报过程中物理知识的多样性和复杂性,以及多维控制方程的非线性组合可能会进一步增加损失函数正则化机制的构建难度。模型的解空间可能是多个局部最优解耦合而成,导致全局最优解的计算复杂度显著增加,进而影响模型预测的不确定性。物理引导反馈融合驱动方法现有的点预测机制容易受到实际采集的数据样本中噪声、缺失值及稀疏性的影响,模型迭代过程中累积的误差,进一步降低预测输出的精度,增加了模型预测的不确定性。此外,现有物理引导反馈融合方法的数据驱动模型为判别模型<sup>[8]</sup>,缺乏对实测数据样本分布的理解,无法提供收敛保证,进一步影响了模型的预测精度并增加了预测输出的不确定性。

受降雨和其他气象的多方面因素联合作用,水文过程固有的随机性使得径流形成过程存在广泛的不确定性,进而导致的混沌性对输出结果的影响更为明显,洪水过程是一个高度非线性系统,径流过程中随机性和混沌性的影响,给预测模型的构建带来了一定的困难。Chen 等<sup>[11]</sup>通过投影将控制方程作为硬约束纳入神经网络方程来融合驱动预测,但是目前的物理引导编码融合驱动模型没有内置的不确定性量化,物理引导的约束空间无法有效编码混沌现象对径流预测结果的影响,从而影响模型的物理约束范围,进而降低了模型的精度。

水文时序数据中存在的分布漂移问题对预测结果有影响,而目前物理引导编码融合驱动模型未考虑数据分布漂移的问题,即使引入了领域的物理知识构建相应的物理约束,模型的性能仍可能会受到限制。目前,物理约束预测建模方法较少考虑复杂非线性偏微分方程参数估计误差阈值的控制,进一步影响了硬约

束模型的优化,以往的物理引导编码融合驱动方法,忽略了水文模型构建中动态特征与复杂非线性 PDE 参数估计误差阈值的控制,进而影响物理约束空间边界划定。以往硬约束构建时,在平衡洪水动态参数优化时,存在局部最优问题,进而降低了预测模型的鲁棒性。

2.2 研究展望

为了有效量化预测过程中的不确定性,学者们尝试将区间预测机制引入物理引导反馈融合驱动模型。Shao 等<sup>[6]</sup>将下上边界估计(lower upper bound estimation, LUBE)区间预测机制引入到物理引导反馈融合驱动模型中,提出了物理引导反馈融合驱动模型的不确定性预测方法,结合误差因子调节机制的 LUBE 区间预测方法来有效量化预测误差,并降低潜在因素对输出结果的不利影响。后处理机制<sup>[51]</sup>可以有效组合模型的多组输出序列,降低复合解空间优化复杂度对预测精度的不利影响。此外,为了降低判别模型对预测精度的影响,可以结合生成对抗网络(generative adversarial network, GAN)、去噪扩散概率模型(denoising diffusion probabilistic model, DDPM)<sup>[6]</sup>等生成模型技术构建物理引导反馈融合驱动模型,通过将洪水预报过程中的先验信息设置为张量辅助信息构建模型的初始条件,优化了模型初始化条件。学者们还通过注意力机制提取数据特征,作为模型的生成约束条件,将洪水特征有效地集成到生成模型中。然而,现有物理引导反馈融合驱动方法的通用性相对较低,考虑到洪水物理过程可能存在随机性,导致模型的拟合过程存在一定的不确定性,模型的输入输出之间误差累积,会影响模型在学习底层物理关系时的泛化性,损失函数中的不同损失项的权重分配也需要进一步研究。

为了有效应对随机性对洪水预报精度的影响,学者们尝试采用神经网络对物理建模中的随机项进行编码。Shao 等<sup>[52]</sup>在物理引导编码融合驱动模型的构建过程中,选择与物理过程相匹配的特征来使数据驱动模型产生具有实际物理意义的结果。为了考虑混沌过程中随机现象对预测结果的影响,物理引导编码融合驱动模型对随机过程进行编码,有效地描述了物理场中复杂的隐式随机过程。此外,水文建模领域中的圣维南方程,可以有效建模洪水的动态时空变化(包括水深、流速等关键参数的变化,由此推算流量的变化),辅助模型构建有效的约束超平面,对径流预测中的预测矩阵和物理机制约束矩阵进行分层建模和超平面投影,实现输出结果严格符合相应的物理规律这一目标。洪水预报领域相应的约束主要包括:水量平衡约束、最高最低水位约束、始末条件约束、防洪控制点流量约束以及其他水文和气象的过程性或实时性约束等,不同的约束对模型的物理引导也是不一致的。

在模型构建过程中,学者们采用不同的方法来降低融合驱动模型对数据样本的依赖,Sun 等<sup>[53]</sup>设计了一种结构化的网络模型增强初始和边界条件,并将控制方程并入了损失函数中来驱动训练过程,在流体建模过程中降低了对数据样本的依赖。Wang 等<sup>[54]</sup>提出了一种用于学习物理 PDE 的算子网络架构 DeepONets,其可以在数据样本支撑不足的情况下,快速建模 PDE 的解空间,与传统方法相比,速度提升了 3 个数量级。Luo 等<sup>[23]</sup>为了有效应对数据稀缺带来的不利影响,提出了一种编码非线性参数 PDE 建模框架,通过结合物理知识来指导模型优化,结合偏微分方程的第一原则和守恒性来降低相关参数的估计误差。此外,在物理引导编码融合驱动建模时,学者们可以通过物理定律对模型参数估计进行有效的误差控制,进而提高 PDE 项的微分精度。自适应机制可以有效应对水文建模与 PDE 求解过程中的全局优化问题,进而提高模型精度及鲁棒性,这也是未来一个重要的研究方向。

3 结 语

物理引导融合驱动方法在水文模型构建领域取得了一定的研究与发展,在进行水文模型构建时,可以根据不同的水利业务场景的业务需求,结合物理一致性选择不同物理约束,充分发挥训练后的反馈式与编码式融合驱动模式在不同洪水场景中的优势,提升整体模型的计算效率。此外,考虑到物理引导融合驱动方法的诸多局限性,在未来的工作中,学者可以结合微分建模(differentiable modelling, DM)<sup>[55]</sup>方法开展基于多个物理规律约束的水文模型构建的研究,与本文的物理引导融合驱动技术体系相比,两者都将物理规律与神经网络结合起来,但它们的方法、目的和理论有所不同。具体来说,物理引导融合驱动方法一般是通过正则化项或预训练方式引入物理约束,使神经网络方法以更少的训练数据获得更好的鲁棒性,而 DM 使用数值物理模型作为主干模型进行构建。物理引导融合驱动方法的目标是提升输出结果的物理一致性,而 DM 则是寻求更新知识或挖掘新规律。理论上,当物理引导融合驱动模型中引入物理规律时,通常被引入的规律是被视为

定理(尽管有时存有一定误差),但是在 DM 中并不要求物理规律或者知识是正确的。在未来的工作中可以基于 DM,并结合多个物理规律约束,进一步优化水文模型的构建过程。此外,面对更复杂得多源时空水文数据,需要进一步建模空天地一体化的时候,现有的物理引导融合驱动方法存在着计算能力有限、提取多源数据特征不够准确、参数优化不够灵活等缺点,而大模型结合知识图谱可以缓解上述问题。以 GPT-4<sup>[56]</sup>为代表的人工智能大语言模型可以提供强大的概念性方案,知识图谱<sup>[57]</sup>则具备确定性的领域内的先验知识和规则约束,强化学习<sup>[58]</sup>可通过与环境交互,在线自主学习优化控制策略,实现模型参数的实时动态调整。在未来的研究中,可以采用大模型结合知识图谱推演产汇流等洪水形成过程,并利用强化学习技术实现模拟环境和与真实水文场景的互动学习,进行参数的实时调整,更好地捕捉洪水过程中的多变量复杂非线性关系,提升模型预测精度,进一步研究物理引导融合驱动方法在水文预报业务中的应用与拓展。

## 参考文献:

- [1] 霍文博,朱跃龙,李致家,等.新安江模型和支持向量机模型实时洪水预报应用比较[J].河海大学学报(自然科学版),2018,46(4):283-289. (HUO Wenbo, ZHU Yuelong, LI Zhijia, et al. Comparison of Xin'anjiang model and Support Vector Machine model in the application of real-time flood forecasting[J]. Journal of Hohai University (Natural Sciences), 2018, 46(4):283-289. (in Chinese))
- [2] 张旭旻,瞿思敏,李倩,等.基于协整理论的淮河流域上游洪水预报实时校正方法[J].水资源保护,2022,38(6):88-95. (ZHANG Xumin, QU Simin, LI Qian, et al. Real-time correction method of flood forecasting for the upper Huaihe River Basin based on cointegration theory[J]. Water Resources Protection, 2022, 38(6):88-95. (in Chinese))
- [3] 张金存,芮孝芳.分布式水文模型构建理论与方法述评[J].水科学进展,2007,18(2):286-292. (ZHANG Jincun, RUI Xiaofang. Discussion of theory and methods for building a distributed hydrologic model[J]. Advances in Water Science, 2007, 18(2):286-292. (in Chinese))
- [4] 朱跃龙,赵群,余宇峰,等.基于时空特征挖掘的流量过程智能模拟方法[J].河海大学学报(自然科学版),2021,49(1):7-12. (ZHU Yuelong, ZHAO Qun, YU Yufeng, et al. Intelligent simulation method of runoff process based on spatiotemporal feature mining[J]. Journal of Hohai University (Natural Sciences), 2021, 49(1):7-12. (in Chinese))
- [5] 张珂,牛杰帆,李曦,等.洪水预报智能模型在中国半干旱半湿润区的应用对比[J].水资源保护,2021,37(1):28-35. (ZHANG Ke, NIU Jiefan, LI Xi, et al. Comparison of artificial intelligence flood forecasting models in China's semi-arid and semi-humid regions[J]. Water Resources Protection, 2021, 37(1):28-35. (in Chinese))
- [6] SHAO Pingping, FENG Jun, LU Jiamin, et al. Data-driven and knowledge-guided denoising diffusion model for flood forecasting[J]. Expert Systems with Applications, 2024, 244:122908.
- [7] 张力,王红瑞,郭琲楠,等.基于时序分解与机器学习的非平稳径流序列集成模型与应用[J].水科学进展,2023,34(1):42-52. (ZHANG Li, WANG Hongrui, GUO Beinan, et al. Integrated model and application of non-stationary runoff based on time series decomposition and machine learning[J]. Advances in Water Science, 2023, 34(1):42-52. (in Chinese))
- [8] SHAO Pingping, FENG Jun, WU Yirui, et al. Data-driven and knowledge-guided heterogeneous graphs and temporal convolution networks for flood forecasting[J]. Applied Sciences, 2023, 13(12):7191.
- [9] 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.
- [10] FAROUGHI S A, PAWAR N M, FERNANDES C, et al. Physics-guided, physics-informed, and physics-encoded neural networks and operators in scientific computing: fluid and solid mechanics[J]. Journal of Computing and Information Science in Engineering, 2024, 24(4):040802.
- [11] CHEN Yuntian, HUANG Dou, ZHANG Dongxiao, et al. Theory-guided hard constraint projection (HCP): a knowledge-based data-driven scientific machine learning method[J]. Journal of Computational Physics, 2021, 445:110624.
- [12] HUANG Bin, WANG Jianhui. Applications of physics-informed neural networks in power systems: a review[J]. IEEE Transactions on Power Systems, 2023, 38(1):572-588.
- [13] 李峰,王琦,胡健雄,等.数据与知识联合驱动方法研究进展及其在电力系统中应用展望[J].中国电机工程学报,2021,41(13):4377-4389. (LI Feng, WANG Qi, HU Jianxiong, et al. Combined data-driven and knowledge-driven methodology research advances and its applied prospect in power systems[J]. Proceedings of the CSEE, 2021, 41(13):4377-4389. (in Chinese))
- [14] 中华人民共和国中央人民政府.国务院印发《新一代人工智能发展规划》[EB/OL]. (2017-07-20). [https://www.gov.cn/xinwen/2017-07/20/content\\_5212064.htm](https://www.gov.cn/xinwen/2017-07/20/content_5212064.htm).

- [15] 陈冲,朱啸宇,王芳,等.物理引导的深度学习研究综述:进展、挑战和展望[J]. 计算机科学与探索,2025,19(2):277-294. (CHEN Chong,ZHU Xiaoyu,WANG Fang,et al. Comprehensive review of physics-guided deep learning:advancements,challenges, and perspectives[J]. Journal of Frontiers of Computer Science and Technology,2025,19(2):277-294. (in Chinese))
- [16] 李鹏,黄文琦,王鑫,等.数据与知识联合驱动的人工智能方法在电力调度中的应用综述[J]. 电力系统自动化,2024,48(1):160-175. (LI Peng,HUANG Wenqi,WANG Xin,et al. Review on application of combined data-knowledge-driven artificial intelligence methods in power dispatching[J]. Automation of Electric Power Systems,2024,48(1):160-175. (in Chinese))
- [17] LI Yue,CHATTOPADHYAY P,XIONG Sihan,et al. Dynamic data-driven and model-based recursive analysis for estimation of battery state-of-charge[J]. Applied Energy,2016,184:266-275.
- [18] 黄天罡,薛禹胜,陈国平,等.暂态稳定算例的高效筛选[J]. 电力系统自动化,2018,42(8):83-91. (HUANG Tiangang,XUE Yusheng,CHEN Guoping,et al. An efficient stable case screening algorithm for transient stability assessment[J]. Automation of Electric Power Systems,2018,42(8):83-91. (in Chinese))
- [19] GASSEL S,NEUMANN T,WACKER M. Combining biomechanical and data-driven body surface models[C]//ACM SIGGRAPH 2017 Posters. Los Angeles:Association for Computing Machinery,2017:1-2.
- [20] LI Pai,GUAN Xiaohong,WU Jiang,et al. Modeling dynamic spatial correlations of geographically distributed wind farms and constructing ellipsoidal uncertainty sets for optimization-based generation scheduling[J]. IEEE Transactions on Sustainable Energy,2015,6(4):1594-1605.
- [21] 李雪梅,钟青祥,胡立春,等.大渡河流域电站智慧运行控制系统设计[J]. 南水北调与水利科技(中英文),2025,23(1):150-156. (LI Xuemei,ZHONG Qingxiang,HU Lichun,et al. Design of the intelligent operation control system for the Dadu River basin power stations[J]. South-to-North Water Transfers and Water Science & Technology,2025,23(1):150-156. (in Chinese))
- [22] 冯钧,吕志鹏,范振东,等.基于大语言模型辅助的防洪调度规则标签设计方法[J]. 水利学报,2024,55(8):920-930. (FENG Jun,LYU Zhipeng,FAN Zhendong,et al. Label design method for flood control scheduling rules assisted by LLM[J]. Journal of Hydraulic Engineering,2024,55(8):920-930. (in Chinese))
- [23] LUO Yingtao,LIU Qiang,CHEN Yuntian,et al. Physics-guided discovery of highly nonlinear parametric partial differential equations[C]//Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Long Beach:Association for Computing Machinery,2023:1595-1607.
- [24] PATHAK D,KRÄHENBUHL P,DARRELL T. Constrained convolutional neural networks for weakly supervised segmentation [C]//2015 IEEE International Conference on Computer Vision (ICCV). Santiago:IEEE,2015:1796-1804.
- [25] WANG Nanzhe,ZHANG Dongxiao,CHANG Haibin,et al. Deep learning of subsurface flow via theory-guided neural network[J]. Journal of Hydrology,2020,584:124700.
- [26] 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.
- [27] HE Tianhao,ZHANG Dongxiao. Deep learning of dynamic subsurface flow via theory-guided generative adversarial network[J]. Journal of Hydrology,2021,601:126626.
- [28] DAW A,KARPATNE A,WATKINS W D,et al. Physics-guided neural networks (PGNN): an application in lake temperature modeling[J]. Preprint ArXiv,2017,10:11431.
- [29] HUANG K,KRUGENER M,BROWN A,et al. Machine learning-based optimal mesh generation in computational fluid dynamics[J]. Preprint ArXiv,2021,2:12923.
- [30] FAROUGHI S A,RORIZ A I,FERNANDES C. A meta-model to predict the drag coefficient of a particle translating in viscoelastic fluids:a machine learning approach[J]. Polymers,2022,14(3):430.
- [31] ZAWAWI M H,SALEHA A,SALWA A,et al. A review:fundamentals of computational fluid dynamics (CFD)[C]//Proceedings of the 4th International Conference on Green Design and Manufacture 2018. Ho Chi Minh:AIP Publishing,2018:020252.
- [32] YANG Yibo,PERDIKARIS P. Adversarial uncertainty quantification in physics-informed neural networks [J]. Journal of Computational Physics,2019,394:136-152.
- [33] JAGTAP A D,KAWAGUCHI K,KARNIADAKIS G E. Adaptive activation functions accelerate convergence in deep and physics-informed neural networks[J]. Journal of Computational Physics,2020,404:109136.
- [34] YANG Liu,MENG Xuhui,KARNIADAKIS G E. B-PINNs:Bayesian physics-informed neural networks for forward and inverse PDE problems with noisy data[J]. Journal of Computational Physics,2021,425:109913.
- [35] CHEN Yuntian,ZHANG Dongxiao. Theory-guided deep-learning for electrical load forecasting (TgDLF) via ensemble long short-

term memory[J]. *Advances in Applied Energy*, 2021, 1:100004.

[36] JIA Xiaowei, WILLARD J, KARPATNE A, et al. Physics-guided machine learning for scientific discovery: an application in simulating lake temperature profiles[J]. *ACM/IMS Transactions on Data Science*, 2021, 2(3):20.

[37] DAW A, THOMAS R Q, CAREY C C, et al. Physics-guided architecture (PGA) of neural networks for quantifying uncertainty in lake temperature modeling[C]//*Proceedings of the 2020 Siam International Conference on Data Mining*. New York: Society for Industrial and Applied Mathematics, 2020:532-540.

[38] SUN Jian, NIU Zhan, INNANEN K A, et al. A theory-guided deep-learning formulation and optimization of seismic waveform inversion[J]. *Geophysics*, 2020, 85(2):R87-R99.

[39] YAO Kun, HERR J E, TOTH D W, et al. The TensorMol-0. 1 model chemistry: a neural network augmented with long-range physics[J]. *Chemical Science*, 2018, 9(8):2261-2269.

[40] RAO C, SUN H, LIU Y. Hard encoding of physics for learning spatiotemporal dynamics[J]. Preprint ArXiv, 2021, 5:00557.

[41] RAO C, REN P, LIU Y, et al. Discovering nonlinear PDEs from scarce data with physics-encoded learning[J]. Preprint ArXiv, 2022, 1:12354.

[42] REN Pu, RAO Chengping, LIU Yang, et al. PhyCRNet: physics-informed convolutional-recurrent network for solving spatiotemporal PDEs[J]. *Computer Methods in Applied Mechanics and Engineering*, 2022, 389:114399.

[43] CHEN R T Q, RUBANOVA Y, BETTENCOURT J, et al. Neural ordinary differential equations[J]. *Advances in Neural Information Processing System*, 2018, 31:1-11.

[44] MA Yingbo, DIXIT V, INNES M J, et al. A comparison of automatic differentiation and continuous sensitivity analysis for derivatives of differential equation solutions [C]//*2021 IEEE High Performance Extreme Computing Conference (HPEC)*. Waltham: IEEE, 2021:1-9.

[45] POLI M, MASSAROL S, YAMASHITA A, et al. Torchdyn: A neural differential equations library[J]. Preprint ArXiv, 2020, 9:09346.

[46] INNERS M, EDELMAN A, FISCHER K, et al. A differentiable programming system to bridge machine learning and scientific computing[J]. Preprint ArXiv, 2019, 7:07587.

[47] RACKAUCKAS C, INNES M, MA Y, et al. Diffeqflux. jl-A julia library for neural differential equations[J]. Preprint ArXiv, 2019, 2:02376.

[48] LAI Zhilu, MYLONAS C, NAGARAJAIAH S, et al. Structural identification with physics-informed neural ordinary differential equations[J]. *Journal of Sound and Vibration*, 2021, 508:116196.

[49] ROEHRL M A, RUNKLER T A, BRANDTSTETTER V, et al. Modeling system dynamics with physics-informed neural networks based on Lagrangian mechanics[J]. *IFAC-PapersOnLine*, 2020, 53(2):9195-9200.

[50] DULNY A, HOTH O A, KRAUSE A. NeuralPDE: modelling dynamical systems from data[C]//*Proceedings of the 45th German Conference on AI on KI 2022: Advances in Artificial Intelligence*. Trier: Springer, 2022:75-89.

[51] ASPERTI A, MERIZZI F, PAPARELLA A, et al. Precipitation nowcasting with generative diffusion models [J]. *Applied Intelligence*, 2024, 55(3), 187.

[52] SHAO Pingping, FENG Jun, LU Jiamin, et al. Data-driven and knowledge-guided denoising diffusion probabilistic model for runoff uncertainty prediction[J]. *Journal of Hydrology*, 2024, 638:131556.

[53] SUN Luning, GAO Han, PAN Shaowu, et al. Surrogate modeling for fluid flows based on physics-constrained deep learning without simulation data[J]. *Computer Methods in Applied Mechanics and Engineering*, 2020, 361:112732.

[54] WANG Sifan, WANG Hanwen, PERDIKARIS P. Learning the solution operator of parametric partial differential equations with physics-informed DeepONets[J]. *Science Advances*, 2021, 7(40):eabi8605.

[55] SHEN Chaopeng, APPLING A P, GENTINE P, et al. Differentiable modelling to unify machine learning and physical models for geosciences[J]. *Nature Reviews Earth & Environment*, 2023, 4(8):552-567.

[56] ACHIAM J, ADLER S, AGARWAL S, et al. Gpt-4 technical report[J]. Preprint ArXiv, 2023, 3:08774.

[57] 冯钧, 畅阳红, 陆佳民, 等. 基于大语言模型的水工程调度知识图谱的构建与应用[J]. *计算机科学与探索*, 2024, 18(6):1637-1647. (FENG JUN, CHANG Yanghong, LU Jiamin, et al. Construction and application of knowledge graph for water engineering scheduling based on large language model[J]. *Journal of Frontiers of Computer Science and Technology*, 2024, 18(6):1637-1647. (in Chinese))

[58] LIANG Yingyu. Introduction to reinforcement learning[M]. Singapore: Springer Singapore, 2020.