

机器学习在给排水管网中的应用

朱远建^{1,2}, 黄扬³, 梁一为^{2,4}, 岑敬明^{1*}, 李文丽¹, 陈祈安⁵, 朱健全¹, 侯辉^{6*}

¹广西贵港北控水务有限公司, 广西 贵港

²广西南宁北控水务有限公司, 广西 南宁

³桂林理工大学环境科学与工程学院, 广西 桂林

⁴广西慧水科技有限公司, 广西 南宁

⁵桂林理工大学土木工程学院, 广西 桂林

⁶桂林理工大学图书馆, 广西 桂林

收稿日期: 2026年5月12日; 录用日期: 2026年6月22日; 发布日期: 2026年6月30日

摘要

随着城市化进程的持续加速, 给排水管网作为城市生命线工程的核心组成部分, 其安全、高效、稳定运行直接关系到居民日常生活质量、城市生态环境可持续性以及城市整体韧性。传统水力建模方法在处理大规模、强非线性的管网运行问题时, 普遍存在参数标定耗时久、计算成本高昂、对突发故障响应滞后等突出不足, 难以满足现代城市智慧管网的运维需求。近年来, 以深度学习、图神经网络为代表的机器学习技术快速发展, 凭借其强大的数据挖掘、特征学习和复杂模式拟合能力, 为给排水管网的漏损检测、爆管识别、水质预警、需水量预测以及城市内涝预报等关键运维任务提供了全新的解决思路与技术路径。本文系统梳理近五年机器学习在给排水管网领域的研究进展, 从方法层面全面回顾传统机器学习、深度学习、图神经网络与物理信息神经网络的发展脉络及核心优势, 从应用层面重点探讨其在供水管网漏损识别与定位、污染事件检测、需水量预测, 以及排水管网管道缺陷识别、内涝预测等核心场景中的最新研究成果与实践应用。最后, 深入分析现有研究方法面临的数据稀缺、模型可解释性不足与跨场景泛化能力薄弱等现实挑战, 并对物理信息图神经网络与数字孪生融合等未来发展前景进行展望, 为推动机器学习技术在城市给排水管网领域的深度应用与产业化落地提供参考。

关键词

机器学习, 图神经网络, 供水排水管网, 漏损检测, 物理信息神经网络

The Application of Machine Learning in Water Supply and Drainage Networks

Yuanjian Zhu^{1,2}, Yang Huang³, Yiwei Liang^{2,4}, Jingming Cen^{1*}, Wenli Li¹, Qi'an Chen⁵, Jianquan Zhu¹, Hui Hou^{6*}

¹Guangxi Guigang BEWG Water Co., Ltd., Guigang Guangxi

*通讯作者。

文章引用: 朱远建, 黄扬, 梁一为, 岑敬明, 李文丽, 陈祈安, 朱健全, 侯辉. 机器学习在给排水管网中的应用[J]. 软件工程与应用, 2026, 15(3): 479-493. DOI: 10.12677/sea.2026.153045

²Guangxi Nanning BEWG Water Co., Ltd., Nanning Guangxi

³College of Environmental Science and Engineering, Guilin University of Technology, Guilin Guangxi

⁴Guangxi Huishui Technology Co., Ltd., Nanning Guangxi

⁵College of Civil Engineering, Guilin University of Technology, Guilin Guangxi

⁶Library of Guilin University of Technology, Guilin Guangxi

Received: May 12, 2026; accepted: June 22, 2026; published: June 30, 2026

Abstract

With the accelerating urbanization process, water supply and drainage networks—as critical components of urban infrastructure—play a pivotal role in ensuring safe, efficient, and stable operations that directly impact residents' quality of life, urban ecological sustainability, and overall urban resilience. Traditional hydraulic modeling methods exhibit significant limitations when addressing large-scale, highly nonlinear network operations, including time-consuming parameter calibration, high computational costs, and delayed responses to sudden failures, making them inadequate for modern smart urban pipeline management requirements. In recent years, rapid advancements in machine learning technologies—particularly deep learning and graph neural networks—have leveraged their robust data mining, feature learning, and complex pattern recognition capabilities to provide innovative solutions for critical operations tasks such as leakage detection, pipe rupture identification, water quality monitoring, water demand forecasting, and urban flooding prediction. This paper systematically reviews five years of research progress in machine learning applications for water supply and drainage networks, comprehensively examining the developmental trajectories and core strengths of traditional machine learning, deep learning, graph neural networks, and physical information neural networks at the methodological level, while focusing on cutting-edge research achievements and practical implementations in key scenarios—including leakage identification and localization in water supply networks, pollution event detection, water demand forecasting, pipeline defect detection, and flood prediction. Finally, this study conducts an in-depth analysis of the practical challenges faced by existing research methodologies—such as data scarcity, insufficient model interpretability, and weak cross-scenario generalization capabilities—and outlines future prospects for integrating physical information graph neural networks with digital twins. These insights provide valuable references for advancing the deep application and industrial implementation of machine learning technologies in urban water supply and drainage network systems.

Keywords

Machine Learning, Graph Neural Networks, Water Supply and Drainage Pipeline Networks, Leakage Detection, Physical Information Neural Networks

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

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



Open Access

1. 引言

供水与排水管网是支撑现代城市正常运行的“血管”系统，具有规模庞大、拓扑结构复杂、深埋地下、运维难度极高的特点[1][2]，如图1所示。全球供水管网的非收益水量平均占比约为25%，部分发展中国家这一比例甚至超过40%，造成巨大经济损失和水资源浪费[3][4]；与此同时，在全球气候变化背景

下, 极端降雨天气频发, 老旧排水系统易引发城市内涝和合流制溢流, 严重影响城市正常秩序与居民生命财产安全[5] [6]。



Figure 1. Water supply and drainage networks: the “blood vessel” system of modern cities

图 1. 供水与排水管网：现代城市的“血管”系统

传统管理模式主要依赖 EPANET、SWMM 等经典水力模型以及现场人工巡检[7] [8]。尽管这些方法物理意义明确, 但在面对大规模复杂管网时, 存在参数标定耗时费力、计算量大、反应滞后等明显短板, 已难以适配现代城市管网智慧化运维的需求[9] [10]。随着物联网传感器、地理信息系统、SCADA 系统与智能水表的广泛普及, 给排水管网积累了海量的运行监测数据, 为数据驱动的机器学习方法提供了充足的数据支撑[11] [12]。机器学习能够从海量历史数据中自动挖掘隐藏的特征与运行规律, 无需依赖复杂的物理模型假设, 在图像识别、自然语言处理等多个领域已取得突破性成果[13], 近年来也逐渐被广泛应用于水务领域, 在漏损识别、需水预测、水质预警、管道缺陷检测等关键任务中展现出独特优势[14]-[16]。其中, 图神经网络 GNN 天然契合管网的图结构特性, 能够有效捕捉管网节点与管段之间的关联关系[17] [18]; 物理信息神经网络则将水力学方程等物理规律嵌入模型损失函数, 在数据稀疏的场景下表现出独特的适配性[19] [20]。

本文从方法与应用两个维度系统梳理近五年研究进展, 结合工程实践需求进行综合评判, 并提出针对性发展路径, 为相关领域的研究与实践提供参考。

2. 给排水管网中机器学习方法概述

机器学习在管网领域的应用经历了从传统浅层模型到深度学习, 再到图结构感知与物理约束融合的演进过程。不同方法在机制、适用场景与工程适配性上各具特点, 共同推动管网运维从经验驱动向数据及物理协同驱动转型。表 1 系统比较了各类方法的机制、适用场景及优缺点。

Table 1. Comparison of machine learning methods applied to water supply and drainage networks

表 1. 机器学习方法在给排水管网中的应用比较

方法类型	核心机制	适用场景	优势	局限
传统机器学习	基于统计学习与集成树模型, 通过特征工程捕捉数据模式	小样本、高维数据场景; 漏损识别、管道失效风险预测	样本需求低、可解释性较强、训练速度快	特征工程依赖人工、难以捕捉复杂非线性动态

续表

深度学习	多层非线性变换与注意力机制, 自动学习时序或图像特征	时序预测、图像缺陷分类; 需水量预测、CCTV 缺陷识别	表征能力强、端到端学习	数据需求大、“黑箱”特性明显、长时序受限
图神经网络	邻域消息传递与拓扑聚合, 显式建模节点和边的关系	图结构数据; 全节点压力重建、需水预测、异常检测	天然适配管网拓扑、空间关联捕捉强	计算复杂度高、大规模图扩展性仍需优化
物理信息神经网络	将质量守恒、动量守恒等水力方程嵌入损失函数	数据稀疏场景; 状态估计、漏损反演	物理一致性强、外推能力优	方程形式依赖先验知识、训练稳定性要求高

传统机器学习在小样本场景中表现稳定。Mounce 等[21]较早将 SVM 应用于供水管网的异常流量检测, 建立了基于在线监测的爆管识别系统。随机森林、梯度提升树等模型由于具备较强的特征筛选能力和良好的可解释性, 在管网状态评估、压力预测中也有广泛应用[22]-[24]。Lučin 等[25]和 Snider 等[26]分别用随机森林和梯度提升树开展漏损定位与管道失效风险预测, 验证了集成学习在工程中的实用性。但这类方法高度依赖人工特征工程, 难以有效捕捉管网复杂的时空非线性动态, 在实际大规模部署中泛化能力受限。

深度学习方法凭借其多层非线性变换的优势, 能够有效学习数据中的复杂模式, 对图像、时序等高维数据具有强大的表征能力[27], 逐渐成为管网研究的主流方法。卷积神经网络(CNN)适合处理具有局部相关性的输入数据, 在排水管道 CCTV 影像缺陷分类中表现突出, 有效解决了人工判读效率低、主观性强的问题[28] [29]; 循环神经网络(RNN)及其改进型长短期记忆网络(LSTM)、门控循环单元(GRU), 擅长建模时序数据的时间依赖关系[30] [31], 在管网流量、压力、需水量等时序预测任务中应用广泛, 能够精准捕捉数据的时间变化规律[32] [33]; Transformer 模型借助自注意力机制, 突破了循环神经网络的序列长度瓶颈, 在长时序预测场景中预测精度更高[34], Cody 等[35]将自编码器与水声谱图结合, 实现了小漏点的早期精准识别, 进一步拓展了深度学习在管网漏损检测中的应用边界。然而, 深度学习“黑箱”特性明显, 且在数据不足或分布偏移时易过拟合, 对物理一致性关注不足, 限制了其在真实老旧管网中的直接应用。

图神经网络的出现, 为解决管网图结构数据的处理难题提供了有效途径。供水与排水管网本质上属于典型的图结构, 节点对应水池、用户、检查井等设施, 边对应管段, 普通卷积神经网络无法直接处理这种非欧氏数据, 而图神经网络通过邻域信息聚合的方式, 能够在节点和边级别开展高效学习, 充分捕捉管网的拓扑关联关系[36] [37]。各类图神经网络模型不断迭代优化, 分别引入采样、注意力机制等改进策略, 进一步增强了模型在大规模管网图上的可扩展性。在水务领域, 图神经网络已被广泛应用于管网全节点压力重建、网络物理攻击检测、需水量预测等任务, Kipf 和 Welling [38]提出的 GCN 为后续工作奠定了基础, GraphSAGE 和 GAT 分别引入采样和注意力机制, 进一步增强了模型在大规模图上的可扩展性[39] [40]。在水务领域, Hajgató 等[41]将 GCN 用于由有限压力测点重建管网全节点压力, 效果显著优于传统插值方法。Tsiami 与 Makropoulos [42]将时空图卷积网络应用于网络物理攻击检测, 展示了 GNN 在异常事件识别上的潜力。Zanfei 等[43]提出图卷积递归网络(GCRN)用于需水预测, 并把管网拓扑信息显式注入预测过程。这些研究表明, GNN 的消息传递机制天然模拟了管网中水力波的传播与节点耦合, 是传统时序模型的重要补充, 但在工程部署中仍需解决计算效率与大规模图训练难题。

物理信息神经网络(PINN)为数据稀疏场景下的管网建模提供了全新思路, 该方法通过将偏微分方程等物理规律作为软约束加入模型损失函数, 使神经网络在学习过程中始终保证物理一致性, 有效解决了

传统数据驱动模型缺乏物理合理性的问题。在管网领域, PINN 可以将连续性方程、动量方程等水力约束注入网络, 从而在传感器稀疏的情况下进行状态估计与漏损反演[44][45]。Cuomo 等[46]总结了 PINN 在科学机器学习中的进展。Willard 等[47]则在更广义的尺度上, 讨论了机器学习与科学知识结合的研究路径。与纯数据驱动方法相比, PINN 在外推能力和可靠性上具有明显优势, 尤其适合老旧管网数据不足的实际工况, 是实现“数据高效、物理可信”混合建模的关键路径。综上, 各类方法从统计学习到深度表征, 再到拓扑感知与物理约束融合, 逐步形成更具工程适配性的技术体系, 未来混合模型将成为工程适配性的核心方向。

3. 机器学习在供水管网中的应用

供水管网的安全稳定运行直接关系到居民用水安全与城市正常运转, 机器学习技术在供水管网中的应用主要集中在漏损检测与定位、爆管事件识别、水质监测与污染事件识别、需水量预测等核心场景, 有效解决了传统运维模式的诸多痛点, 如图 2 所示。

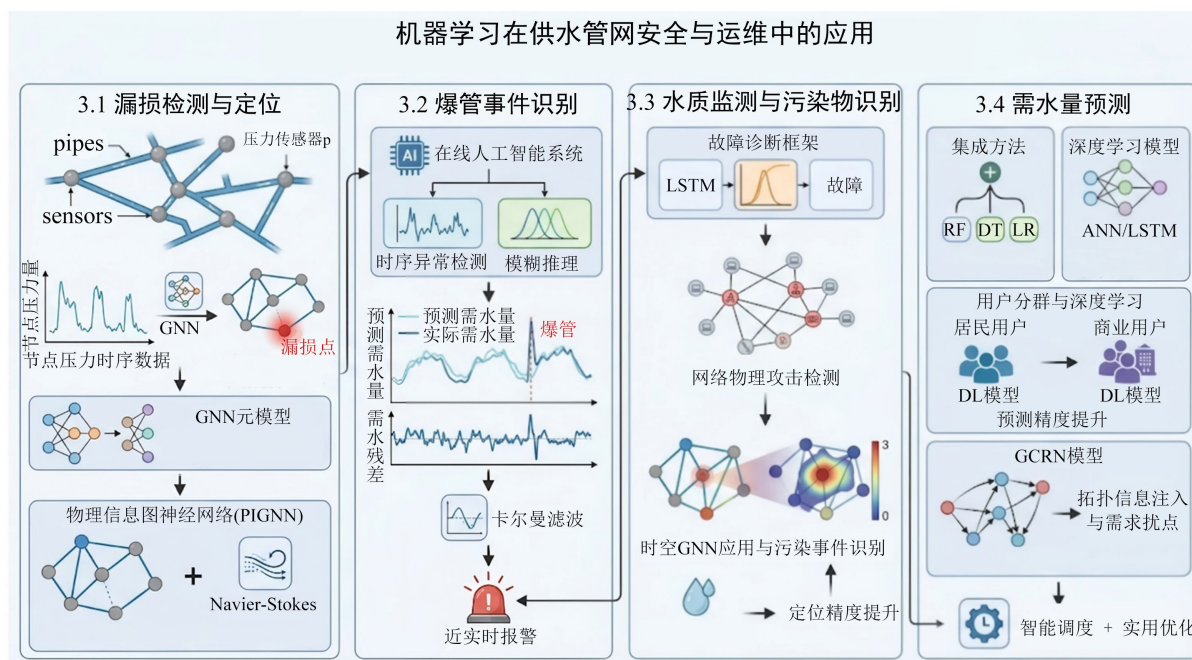


Figure 2. Application of machine learning in the safety and operation and maintenance of water supply networks

图 2. 机器学习在供水管网安全与运维中的应用

3.1. 漏损检测与定位

漏损是供水管网最严重的运行问题之一, 也是相关研究的热点方向, 早期 Romano 等[48]便提出了基于统计过程控制与神经网络结合的爆管检测方法, 为后续研究奠定了基础。部分学者系统综述了数据驱动的爆管检测方法, 将其归纳为信号处理、机器学习与混合方法三类, 并进一步比较了基于模型与数据驱动的漏损检测与定位方法, 指出二者的互补性。在 2020 年举办的“漏损检测与隔离方法之战”(BattLeDIM)国际竞赛中, Saldarriaga 等[49]组织了基于真实管网 L-Town 的标准评测, 为不同算法的横向对比提供了公平平台。近年来, 随着深度学习与图神经网络的发展, 漏损检测与定位技术得到显著提升, Fan 等[50]采用机器学习模型对节点压力时序数据建模, 在合成数据上漏损识别准确率较高。Daniel 等[51]提出顺序压力驱动算法, 将数据驱动识别和模型定位结合起来。Xing 与 Sela [52]使用 GNN 进行管

网状态估计, 实验显示半监督学习方式可以在标注样本极少时仍保持良好性能。Kerimov 等[53]针对 GNN 元模型在水力系统中的迁移性能进行了系统评测。Zhou 等[54]采用深度学习方法定位水网爆管, 并验证了模型在多种工况下的鲁棒性。物理信息方法在漏损检测领域的应用也受到广泛关注, Ashraf 等[55]提出基于物理信息图神经网络的供水管网状态估计框架, 能利用稀疏压力测量推断管网运行状态。Sun 等[56]则在更基础的层面研究了物理约束下的深度学习, 为流体场代理模型提供了思路。Garzón 等[57]综述了机器学习代理模型在城市水网中的研究进展, 指出代理模型在快速分析大规模管网情景方面的优势。

这些成果验证了混合方法在快速分析大规模情景、降低部署成本方面的优势(代表性研究的横向对比与评述详见表 2), 但实际工程中仍面临域偏移, 即合成数据和真实老旧管网对比问题, 因此迁移性能有待进一步验证。

Table 2. Comparison and critical review of representative studies on leakage detection and localization

表 2. 代表性漏损检测与定位研究对比与评述

参考文献	所用模型	数据集	关键性能指标	主要创新点	作者评述与局限性
Romano 等[48]	ANN + 统计过程控制 (SPC)	英国某供水公司 DMA 区域 SCADA 在线压力流量数据	爆管事件检测率高, 误报率低于传统阈值法	首次将 ANN 与 SPC 相结合, 实现近实时报警框架	依赖人工设置控制限, 对噪声敏感; 模型尚未显式考虑管网拓扑关系
Cody 等[35]	深度自编码器 + 水声谱图	实验室管段水声采集数据	小漏点早期识别敏感度优于传统声学方法	将无监督深度表征学习用于声学漏损检测	实验环境理想, 实际管网背景噪声干扰下泛化性能仍需验证
Zhou 等[54]	深度全连接神经网络	C-Town 基准管网、EPANET 仿真生成多工况数据	节点级定位准确率显著优于多元回归基线	系统验证了不同需求模式、漏损强度下的鲁棒性	完全依赖合成数据, 真实管网中传感器布设稀疏将明显削弱性能
Fan 等[50]	传统 ML 模型对比	合成管网压力时序数据	多模型对比, 集成方法准确率较高	构建了从特征提取到分类的快速检测流程	未涉及真实管网验证; 特征工程依赖经验, 迁移成本高
Daniel 等[51]	数据驱动识别 + 模型驱动定位的顺序压力估计	BattLeDIM L-Town 基准管网	在 L-Town 基准上识别与定位综合表现较优	实现数据驱动和水力模型的双阶段耦合	对水力模型校准精度依赖较强, 在严重老化管网中存在风险
Xing 与 Sela [52]	半监督图神经网络 (GNN)	C-Town 等基准管网仿真数据	标注样本占比 < 10% 时仍保持较高估计精度	首次系统验证半监督 GNN 在管网状态估计中的可行性	图结构假设静态, 实际管网阀门切换导致拓扑动态变化时性能下降
Kerimov 等[53]	多种 GNN 元模型	多个 WDS 基准管网的跨管网迁移测试	GNN 元模型在大多数指标上优于全连接基线	首次系统评测 GNN 元模型在不同水力系统间的迁移性能	跨管网迁移仍存在显著性能衰减, 提示需引入域自适应机制
Ashraf 等[55]	物理信息图神经网络 (PI-GNN)	合成 WDS 数据 + 稀疏压力测点	在测点稀疏条件下状态估计误差低于纯 GNN	将水力守恒约束嵌入 GNN 损失函数, 实现物理一致性	训练对超参数敏感; 实际管网中物理方程参数本身不确定, 影响约束效果

3.2. 爆管事件识别

爆管事件具有突发性、隐蔽性强的特点, 一旦发生会造成严重的水资源浪费与财产损失, 机器学习方法为爆管事件的快速识别提供了有效支撑。Mounce 等[58]开发了在线人工智能系统, 结合时序异常检测和模糊推理, 对管网传感数据中的爆管事件实现近实时报警。Bakker 等[59]基于自适应预测模型对短期需水进行实时预报, 并将残差用于异常识别。Ye 与 Fenner [60]把卡尔曼滤波用于水力测量数据处理, 提升了爆管检测的灵敏度。机器学习将响应时间从小时级缩短至分钟级, 但多数研究仍停留在检测层面,

未来需与决策模块结合，形成感知、预警、处置三者的闭环。

3.3. 水质监测与污染事件识别

水质安全关乎公众健康，机器学习技术在水质监测与污染事件识别中发挥了重要作用。Eliades 与 Polycarpou [61]较早提出面向水系统的故障诊断与安全框架。Taormina 与 Galelli [62]首次将深度学习应用于网络物理攻击的检测和定位，为水务领域的安全研究开辟了方向。近年来，结合 GNN 的污染事件识别方法不断涌现，能够同时学习时间和空间相关性，定位精度较传统方法有明显提升[63]。相比传统方法，污染事件定位精度得到明显提升，但在真实污染事件样本极少的情况下，需加强自监督预训练与少样本学习策略。

3.4. 需水量预测

精确的需水量预测是供水管网调度优化、资源合理配置的前提，直接影响管网运行效率与供水可靠性。部分学者比较了多种机器学习方法在短期需水预测中的表现，结果显示集成方法效果稳定，且采用深度学习方法对短期需水进行预测，在多个数据集上优于传统时间序列模型。Pesantez 等[64]则比较了聚类与深度学习模型在城市需水预测中的差异，指出用户分群有助于提升精度。Zanfei 等[65]提出 GCRN，把管网拓扑信息注入预测模型，在意大利一座中型城市的实证中取得了最优表现。这些成果为智能调度提供了支撑，但外部扰动，例如节假日、气象、突发事件等建模仍需加强，以提高长时序预测的鲁棒性。

4. 机器学习在排水管网中的应用

排水管网承担着城市污水排放、雨水疏导的重要功能，长期运行易出现各类问题，机器学习技术在排水管网中的应用主要集中在管道缺陷识别、城市内涝预测、流量预测与运维优化等场景，有效提升了排水管网的运维效率与韧性，如图 3 所示。值得注意的是，供水管网的机器学习应用以时序异常检测和图结构建模为主，而排水管网则侧重图像识别与洪水仿真代理模型，二者技术路径存在明显分野，这反映了供水侧“稳态水力过程”与排水侧“动态水文过程”的本质差异。未来需探索跨系统一体化建模，实现城市水循环全链条智能管理。

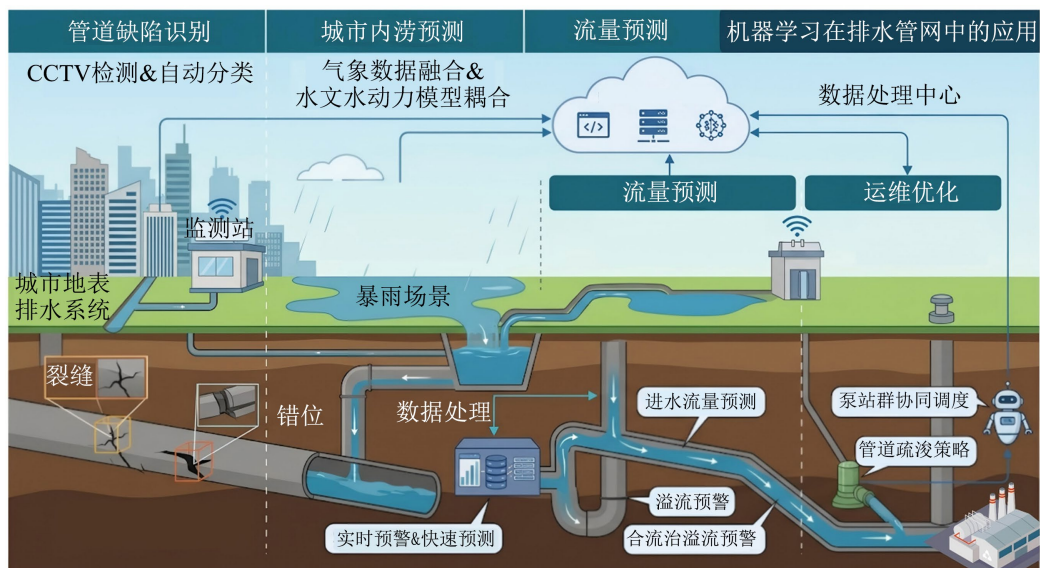


Figure 3. Application of machine learning in drainage networks

图 3. 机器学习在排水管网中的应用

4.1. 管道缺陷识别

排水管道长期受污水腐蚀, 容易出现破裂、错位、根系侵入等缺陷。传统 CCTV 人工判读, 效率低、主观性强。Hawari 等[66]系统综述了机器学习在排水管状态评估中的进展。Cheng 与 Wang [67]使用深度学习实现了管道缺陷的端到端检测; Yin 等[68]结合目标检测和迁移学习, 在小样本场景下取得了不错的效果。Wang 与 Cheng [69]进一步把条件随机场与 CNN 结合, 实现了像素级缺陷分割, 提供了缺陷面积的定量信息。这些方法为修复决策提供了定量依据, 但小样本场景下的泛化能力仍有待提升, 若结合领域自适应技术, 可实现大幅度的效率和精准度提升。

4.2. 城市内涝预测

气候变化加剧了城市内涝风险。传统 SWMM 等水文水动力模型计算量大, 难以满足实时预报需求, 机器学习技术凭借其快速预测的优势, 成为城市内涝预测的重要工具。Mosavi 等[70]系统综述了机器学习在洪水预测中的应用。Berkhahn 等[71]将神经网络与水动力模型耦合, 实现对城市内涝水深的快速预测。Guo 等[72]采用 CNN 对降雨和内涝水深之间建立端到端映射, 预测速度比 SWMM 快多个数量级。Chang 等[73]基于 RNN 对实时水位进行多步预测, 为内涝预警提供了支撑。机器学习的运用不仅大幅提升了内涝预测的速度, 还保证了预测精度, 为城市内涝预警、应急处置提供了及时有效的支撑, 有效降低了内涝灾害造成的损失, 但极端工况下的外推能力不足, 需与物理水动力模型形成混合预报系统。代表性研究的横向对比与评述详见表 3 所示。

Table 3. Comparison and critical review of representative studies on urban flood prediction

表 3. 代表性城市内涝预测研究对比与评述

参考文献	所用模型	数据集	关键性能指标	主要创新点	作者评述与局限性
Chang 等[73]	RNN 多步水位预测	中国某城市实测水位与降雨时序数据	1~3 步未来水位预测 R ² 较高	实现实时多步水位滚动预测, 支撑内涝预警	对极端罕见暴雨外推能力有限, 预测视野受序列长度制约
Berkhahn 等[71]	集成 ANN + 水动力模型耦合	德国某城市内涝实测与水动力仿真混合数据	实时内涝水深预测精度接近水动力模型, 但速度提升明显	首次提出 ANN 与水动力模型集成的实时预报架构	训练样本需要水动力模型预先生成, 场景外推依然受限于训练分布
Guo 等[72]	CNN 端到端降雨 - 内涝映射	葡萄牙某城市 SWMM 仿真生成的降雨 - 淹没图像对	预测速度较 SWMM 加速若干数量级, 空间精度可接受	首次将图像式 CNN 用于内涝场快速推断	完全数据驱动, 缺乏物理一致性约束; 实际地表条件变化下需重新训练
Mosavi 等[70]	多种 ML 模型综述对比	公开洪水数据集汇总	综述类	系统梳理 ML 在洪水预测中的应用范式与挑战	聚焦流域尺度, 城市内涝特有的管网和地表耦合机制讨论不足
Mounce 等[75]	ANN + 雷达降雨数据	英国某合流制溢流井实测水位与雷达降雨数据	CSO 井水位多步预测 RMSE 优于自回归基线	将高分辨率雷达降雨作为外源驱动注入预测模型	雷达数据获取成本较高; 单点预测难以反映全网协同响应

4.3. 流量预测与运维优化

排水流量预测是合流制溢流控制和泵站调度优化的基础。Wei 与 Kusiak [74]采用机器学习模型对污水处理厂进水流量进行小时级预测, 并与季节性模型做了系统比较。Mounce 等[75]使用神经网络结合雷达降雨数据, 对合流制溢流井水位进行预测。这类方法的共同特点是把环境变量, 如降雨、气温等, 作为外源输入, 显著提升预测精度, 推动了排水管网运维的精细化、智能化发展。这类方法为泵站调度提

供了科学依据，但单点预测难以支撑全网协同优化，未来需引入多智能体强化学习，进一步强化预测。

5. 面向工程实际部署的挑战与对策

尽管机器学习模型在仿真与试点研究中取得了优异表现，但从科研原型走向供排水公司大规模生产环境的过程中，仍面临数据、技术与管理三个维度的深层挑战[76]。

5.1. 数据获取与治理

实际管网监测数据通常分散在 SCADA、GIS、营业收费、客服报修等多个独立系统中，字段标准不统一，时间戳精度参差，缺失与异常普遍存在；不同水务公司之间的数据更因涉及供水安全、客户隐私与商业利益而难以共享，形成显著的数据孤岛。针对这一困境，联邦学习(Federated Learning)提供了“数据不动模型动”的分布式训练范式，可在不汇集原始数据的前提下协同训练全局模型；差分隐私与同态加密技术则可进一步降低参与方对隐私泄露的顾虑[77]。在单一水务公司内部，数据治理(Data Governance)体系的建设同样关键，包括统一字段编码、建立数据质量评价指标、引入主动学习以高效标注稀缺故障样本等。

5.2. 模型集成与运维

一是与既有运维系统的集成，即 SCADA、GIS、水力模型与机器学习模块之间普遍存在接口不统一、数据延迟不一致等问题，需要通过中间件与标准化 API 进行解耦；二是边缘计算适配，即在 DMA 计量分区、泵站、管网末端等现场部署场景下，算力与功耗受限，大型深度学习模型难以直接落地，需借助模型剪枝、量化、知识蒸馏等模型压缩技术，以及 TinyML 等轻量化推理框架[78]；三是模型全生命周期管理(MLOps)，管网数据随季节、用水模式、管网改造而漂移，模型上线后必须建立持续监控、自动再训练与版本回滚机制，以避免一次训练、长期失效的问题。

5.3. 人机交互与信任建立

管网调度员、巡检工程师等一线运维人员是机器学习模型的实际使用者，其信任度是算法落地的关键。依托 SHAP、LIME、注意力可视化等可解释人工智能技术(XAI) [79]，能够直观展示模型决策逻辑；同时开放专家修正与反馈通道，将反馈内容用于模型迭代学习。配套建立运维人员培训机制与权责划分规范，厘清黑箱算法的责任界定问题，助力智能模型完成从辅助工具到决策伙伴的转变。

数据、技术与管理层面的问题环环相扣，单一环节的不足都会成为应用落地的阻碍。未来研究在精进算法的基础上，也要重视落地部署、日常维护与应用可信性，让技术真正做到可用、好用、敢用。

6. 挑战与展望

机器学习在给排水管网领域虽取得显著进展，但实际落地仍面临多重瓶颈。在数据层面，管网监测点分布稀疏、数据采样频率不一、缺失值较多的问题普遍存在，且历史故障样本极少，给监督学习模型的训练带来极大困难；同时，公开的真实管网数据匮乏，多数研究依赖合成数据或单一城市管网案例，模型的跨场景验证不足，难以适应不同城市、不同类型管网的复杂工况[50]。同时，供水与排水管网数据特征差异进一步加剧了这一问题：供水侧以稳态压力-流量时序为主，排水侧则包含动态降雨-地表径流图像或者水位数据，二者难以直接迁移。半监督学习、自监督学习和迁移学习等技术，是缓解数据稀缺问题、提升模型泛化能力的可行思路。

在模型层面，深度学习模型的“黑箱”特性导致其可解释性较差，难以让管网运维人员理解模型的决策逻辑，进而影响对模型的信任与应用。可解释人工智能方法(如 SHAP、LIME)的引入，能够有效提

升模型的透明度,帮助运维人员理解模型预测结果的产生原因[80][81];而物理信息神经网络通过显式融入物理规律,从根本上提升了模型的物理合理性与可信度,为解决模型可解释性问题提供了重要路径,是更具工程价值的路径。

在应用层面,多数研究仍停留在仿真实验或单一管网案例验证阶段,难以直接应用于不同规模、不同拓扑结构的管网;此外,供水-排水技术路径的割裂也制约了城市水务一体化管理。因此,建立标准化的开放测试基准与数据集,如 L-Town、C-Town、BattLeDIM 数据集,从而能够为不同算法的客观评估提供公平的平台,推动算法的优化与落地。

在上述挑战的牵引下,未来研究应在以下五个方向重点突破。每一方向不仅是宏观技术路线,更对应若干具体且亟待回答的科学问题,值得后续研究者深入探索。

其一,图神经网络与物理信息神经网络的深度融合。GNN 擅长建模管网的图结构与空间关联,PINN 则擅长引入水力守恒约束以提升物理一致性,二者的耦合有望兼顾数据驱动与物理可信两大优势。然而,如何在统一框架下同时刻画管网拓扑的不确定性(例如阀门开闭、管段连接变化)与水力参数的不确定性(例如粗糙度、节点需水量),从而提升模型在真实老旧管网中的可靠性,仍是亟待回答的关键问题;此外,物理约束与图结构消息传递之间的耦合权重应如何根据测点稀疏程度自适应调整,以兼顾估计精度与训练稳定性,也有待进一步研究。

其二,数字孪生平台与机器学习的深度融合[82]。数字孪生能够构建管网的高保真虚拟镜像,而机器学习则作为其核心推理引擎,可实现状态实时监测、故障预警与调度优化。未来研究需要回答的核心问题是在毫秒级实时性约束下,如何构建高精度水力模型与数据驱动代理模型相结合的多保真度数字孪生架构,在快速推断与精细仿真之间动态切换;以及虚拟传感如何与物理传感网络协同,在管网状态长期漂移下持续校正机器学习模型,避免一次训练、长期失效。

其三,大语言模型与基础模型在水务领域的应用探索[83]。基础模型的一模型多任务范式有望将分散的运维知识、传感数据与文档资料整合到统一表征中。值得研究的方向包括能否构建覆盖管网设计规范、运维 SOP、历史故障工单与多源传感时序的水务领域基础模型,实现跨任务的统一表征与少样本快速适配;以及大语言模型与水力计算工具、GIS 数据库之间的工具调用机制如何安全可控地集成,以避免生成式 AI 的幻觉导致错误的运维决策。

其四,强化学习与多智能体方法在协同调度中的应用[84]。泵站、阀门、水厂、用户共同构成耦合度极高的复杂系统,单点优化已难以应对全局协同需求。在“源-厂-网-户”全链条调度场景下,如何设计兼顾供水可靠性、能耗、水质安全等多目标的多智能体强化学习奖励函数,是该方向的核心挑战;另一个紧迫问题是,经仿真训练得到的策略如何安全地迁移到真实管网。现阶段,可借助安全强化学习(safe RL)与“影子模式”(shadow mode)逐步上线,以避免对生产系统造成干扰。

其五,标准化开放基准与供水排水一体化建模。客观、可复现的横向评估是推动算法走向工程落地的前提。现有 L-Town、C-Town、BattLeDIM 等基准如何进一步扩展为涵盖供水-排水耦合过程、降雨外源驱动以及设备故障注入的开放城市水循环基准,以及如何设计跨城市、跨气候带的迁移评测协议,以客观度量模型在分布偏移下的真实泛化能力,而非仅是单一管网上的过拟合表现,是值得社区共同推进的工作。

7. 结论

机器学习为给排水管网智慧化运维提供了强大技术支撑。从传统机器学习到深度学习、图神经网络和物理信息神经网络,方法演进显著提升了关键运维任务的效率与精度。然而,数据稀缺、可解释性不足、跨场景泛化能力薄弱以及供水-排水技术路径割裂仍是主要制约。未来,需进一步融合多源监测数

据、水力学物理先验知识和管网图结构信息，不断优化模型算法，构建透明、可迁移、面向实战的智能管网管理系统，推动城市供水与排水基础设施的智慧化、精细化发展，提升水资源利用效率与防灾减灾能力。

基金项目

本文受中央引导地方科技发展资金项目“桂科 ZY24212055”的资助支持。

参考文献

- [1] Wu, Z.Y., Sage, P. and Turtle, D. (2010) Pressure-Dependent Leak Detection Model and Its Application to a District Water System. *Journal of Water Resources Planning and Management*, **136**, 116-128. [https://doi.org/10.1061/\(asce\)0733-9496\(2010\)136:1\(116\)](https://doi.org/10.1061/(asce)0733-9496(2010)136:1(116))
- [2] Lambert, A. (1994) Accounting for Losses: The Bursts and Background Concept. *Water and Environment Journal*, **8**, 205-214. <https://doi.org/10.1111/j.1747-6593.1994.tb00913.x>
- [3] Kingdom, B., Liemberger, R. and Marin, P. (2006) The Challenge of Reducing Non-Revenue Water (NRW) in Developing Countries—How the Private Sector Can Help: A Look at Performance-Based Service Contracting. <https://econpapers.repec.org/paper/wbkwboper/17238.htm>
- [4] Liemberger, R. and Wyatt, A. (2018) Quantifying the Global Non-Revenue Water Problem. *Water Supply*, **19**, 831-837. <https://doi.org/10.2166/ws.2018.129>
- [5] Intergovernmental Panel on Climate Change (IPCC) (2023) Climate Change 2021—The Physical Science Basis: Working Group I Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press. <https://doi.org/10.1017/9781009157896>
- [6] Hammond, M.J., Chen, A.S., Djordjević, S., Butler, D. and Mark, O. (2015) Urban Flood Impact Assessment: A State-of-the-Art Review. *Urban Water Journal*, **12**, 14-29. <https://doi.org/10.1080/1573062x.2013.857421>
- [7] Rossman, L.A. (2013) Storm Water Management Model User's Manual Version 5.1. U.S. Environmental Protection Agency.
- [8] Rossman, L.A. (2000) EPANET 2 Users Manual. National Risk Management Research Laboratory, Office of Research and Development, U.S. Environmental Protection Agency.
- [9] Kapelan, Z.S., Savic, D.A. and Walters, G.A. (2007) Calibration of Water Distribution Hydraulic Models Using a Bayesian-Type Procedure. *Journal of Hydraulic Engineering*, **133**, 927-936. [https://doi.org/10.1061/\(asce\)0733-9429\(2007\)133:8\(927\)](https://doi.org/10.1061/(asce)0733-9429(2007)133:8(927))
- [10] Savic, D.A., Kapelan, Z.S. and Jonkergouw, P.M.R. (2009) Quo Vadis Water Distribution Model Calibration? *Urban Water Journal*, **6**, 3-22. <https://doi.org/10.1080/15730620802613380>
- [11] Boyle, T., Giurco, D., Mukheibir, P., Liu, A., Moy, C., White, S., *et al.* (2013) Intelligent Metering for Urban Water: A Review. *Water*, **5**, 1052-1081. <https://doi.org/10.3390/w5031052>
- [12] Stewart, R.A., Nguyen, K., Beal, C., Zhang, H., Sahin, O., Bertone, E., *et al.* (2018) Integrated Intelligent Water-Energy Metering Systems and Informatics: Visioning a Digital Multi-Utility Service Provider. *Environmental Modelling & Software*, **105**, 94-117. <https://doi.org/10.1016/j.envsoft.2018.03.006>
- [13] LeCun, Y., Bengio, Y. and Hinton, G. (2015) Deep Learning. *Nature*, **521**, 436-444. <https://doi.org/10.1038/nature14539>
- [14] Wu, Y. and Liu, S. (2017) A Review of Data-Driven Approaches for Burst Detection in Water Distribution Systems. *Urban Water Journal*, **14**, 972-983. <https://doi.org/10.1080/1573062x.2017.1279191>
- [15] Hu, Z., Chen, B., Chen, W., Tan, D. and Shen, D. (2021) Review of Model-Based and Data-Driven Approaches for Leak Detection and Location in Water Distribution Systems. *Water Supply*, **21**, 3282-3306. <https://doi.org/10.2166/ws.2021.101>
- [16] Adedeji, K.B., Hamam, Y., Abe, B.T. and Abu-Mahfouz, A.M. (2017) Towards Achieving a Reliable Leakage Detection and Localization Algorithm for Application in Water Piping Networks: An Overview. *IEEE Access*, **5**, 20272-20285. <https://doi.org/10.1109/access.2017.2752802>
- [17] Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C. and Yu, P.S. (2021) A Comprehensive Survey on Graph Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*, **32**, 4-24. <https://doi.org/10.1109/tnnls.2020.2978386>
- [18] Zhou, J., Cui, G., Hu, S., Zhang, Z., Yang, C., Liu, Z., *et al.* (2020) Graph Neural Networks: A Review of Methods and Applications. *AI Open*, **1**, 57-81. <https://doi.org/10.1016/j.aiopen.2021.01.001>
- [19] Raissi, M., Perdikaris, P. and Karniadakis, G.E. (2019) Physics-Informed Neural Networks: A Deep Learning

- Framework for Solving Forward and Inverse Problems Involving Nonlinear Partial Differential Equations. *Journal of Computational Physics*, **378**, 686-707. <https://doi.org/10.1016/j.jcp.2018.10.045>
- [20] Karniadakis, G.E., Kevrekidis, I.G., Lu, L., Perdikaris, P., Wang, S. and Yang, L. (2021) Physics-Informed Machine Learning. *Nature Reviews Physics*, **3**, 422-440. <https://doi.org/10.1038/s42254-021-00314-5>
- [21] Mounce, S.R., Mounce, R.B. and Boxall, J.B. (2011) Novelty Detection for Time Series Data Analysis in Water Distribution Systems Using Support Vector Machines. *Journal of Hydroinformatics*, **13**, 672-686. <https://doi.org/10.2166/hydro.2010.144>
- [22] Winkler, D., Haltmeier, M., Kleidorfer, M., Rauch, W. and Tscheikner-Gratl, F. (2018) Pipe Failure Modelling for Water Distribution Networks Using Boosted Decision Trees. *Structure and Infrastructure Engineering*, **14**, 1402-1411. <https://doi.org/10.1080/15732479.2018.1443145>
- [23] Chen, T. and Guestrin, C. (2016) XGBoost: A Scalable Tree Boosting System. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Association for Computing Machinery, 785-794. <https://doi.org/10.1145/2939672.2939785>
- [24] Breiman, L. (2001) Random Forests. *Machine Learning*, **45**, 5-32. <https://doi.org/10.1023/a:1010933404324>
- [25] Lučin, I., Lučin, B., Čarija, Z. and Sikirica, A. (2021) Data-Driven Leak Localization in Urban Water Distribution Networks Using Big Data for Random Forest Classifier. *Mathematics*, **9**, Article No. 672. <https://doi.org/10.3390/math9060672>
- [26] Snider, B. and McBean, E.A. (2020) Improving Urban Water Security through Pipe-Break Prediction Models: Machine Learning or Survival Analysis. *Journal of Environmental Engineering*, **146**, Article ID: 04019129. [https://doi.org/10.1061/\(asce\)je.1943-7870.0001657](https://doi.org/10.1061/(asce)je.1943-7870.0001657)
- [27] Heaton, J. (2018) Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep Learning. *Genetic Programming and Evolvable Machines*, **19**, 305-307. <https://doi.org/10.1007/s10710-017-9314-z>
- [28] Kumar, S.S., Abraham, D.M., Jahanshahi, M.R., Iseley, T. and Starr, J. (2018) Automated Defect Classification in Sewer Closed Circuit Television Inspections Using Deep Convolutional Neural Networks. *Automation in Construction*, **91**, 273-283. <https://doi.org/10.1016/j.autcon.2018.03.028>
- [29] Krizhevsky, A., Sutskever, I. and Hinton, G.E. (2012) ImageNet Classification with Deep Convolutional Neural Networks. *Proceedings of the 25th International Conference on Neural Information Processing Systems (NIPS'12)*, Lake Tahoe, 3-6 December 2012, 1097-1105.
- [30] Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., et al. (2014) Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, Doha, October 2014, 1724-1734. <https://doi.org/10.3115/v1/d14-1179>
- [31] Hochreiter, S. and Schmidhuber, J. (1997) Long Short-Term Memory. *Neural Computation*, **9**, 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [32] Antunes, A., Andrade-Campos, A., Sardinha-Lourenço, A. and Oliveira, M.S. (2018) Short-Term Water Demand Forecasting Using Machine Learning Techniques. *Journal of Hydroinformatics*, **20**, 1343-1366. <https://doi.org/10.2166/hydro.2018.163>
- [33] Guo, G., Liu, S., Wu, Y., Li, J., Zhou, R. and Zhu, X. (2018) Short-Term Water Demand Forecast Based on Deep Learning Method. *Journal of Water Resources Planning and Management*, **144**, Article ID: 04018076. [https://doi.org/10.1061/\(asce\)wr.1943-5452.0000992](https://doi.org/10.1061/(asce)wr.1943-5452.0000992)
- [34] Vaswani, A., et al. (2017) Attention Is All You Need. *Proceedings of the 31st International Conference on Neural Information Processing Systems*, Long Beach, 4-9 December 2017, 6000-6010.
- [35] Cody, R.A., Tolson, B.A. and Orchard, J. (2020) Detecting Leaks in Water Distribution Pipes Using a Deep Autoencoder and Hydroacoustic Spectrograms. *Journal of Computing in Civil Engineering*, **34**, Article ID: 04020001. [https://doi.org/10.1061/\(asce\)cp.1943-5487.0000881](https://doi.org/10.1061/(asce)cp.1943-5487.0000881)
- [36] Bronstein, M.M., Bruna, J., LeCun, Y., Szlam, A. and Vandergheynst, P. (2017) Geometric Deep Learning: Going Beyond Euclidean Data. *IEEE Signal Processing Magazine*, **34**, 18-42. <https://doi.org/10.1109/msp.2017.2693418>
- [37] Hamilton, W.L., Ying, R. and Leskovec, J. (2017) Inductive Representation Learning on Large Graphs. *Proceedings of the 31st International Conference on Neural Information Processing Systems*, Long Beach, 4-9 December 2017, 1025-1035.
- [38] Kipf, T.N. and Welling, M. (2016) Semi-Supervised Classification with Graph Convolutional Networks. *5th International Conference on Learning Representations*, Toulon, 24-26 April 2017. <https://mlanthology.org/iclr/2017/kipf2017iclr-semi/>
- [39] Velickovi, P., Cucurull, G., Casanova, A., et al. (2017) Graph Attention Networks. *6th International Conference on Learning Representations*, Vancouver, 30 April-3 May 2017. <https://mlanthology.org/iclr/2018/velickovic2018iclr-graph/>

- [40] Defferrard, M., Bresson, X. and Vandergheynst, P. (2016) Convolutional Neural Networks on Graphs with Fast Localized Spectral Filtering. *The Fortieth Annual Conference on Neural Information Processing Systems*, Sydney, 6-12 December 2016. https://proceedings.neurips.cc/paper_files/paper/2016/file/04df4d434d481e5bb723be1b6df1ee65-Paper.pdf
- [41] Hajgat'o, G., Gyires-T'oth, B.A. and Pa'al, G. (2021) Reconstructing Nodal Pressures in Water Distribution Systems with Graph Neural Networks. <https://arxiv.org/abs/2104.13619>
- [42] Tsiami, L. and Makropoulos, C. (2021) Cyber-Physical Attack Detection in Water Distribution Systems with Temporal Graph Convolutional Neural Networks. *Water*, **13**, Article No. 1247. <https://doi.org/10.3390/w13091247>
- [43] Zanfei, A., Brentan, B.M., Menapace, A., Righetti, M. and Herrera, M. (2022) Graph Convolutional Recurrent Neural Networks for Water Demand Forecasting. *Water Resources Research*, **58**, e2022WR032299. <https://doi.org/10.1029/2022wr032299>
- [44] Cai, S., Mao, Z., Wang, Z., Yin, M. and Karniadakis, G.E. (2021) Physics-Informed Neural Networks (PINNs) for Fluid Mechanics: A Review. *Acta Mechanica Sinica*, **37**, 1727-1738. <https://doi.org/10.1007/s10409-021-01148-1>
- [45] Lu, L., Meng, X., Mao, Z., et al. (2019) DeepXDE: A Deep Learning Library for Solving Differential Equations. *SIAM Review*, **63**, 208-228.
- [46] Cuomo, S., Di Cola, V.S., Giampaolo, F., Rozza, G., Raissi, M. and Piccialli, F. (2022) Scientific Machine Learning through Physics-Informed Neural Networks: Where We Are and What's Next. *Journal of Scientific Computing*, **92**, Article No. 88. <https://doi.org/10.1007/s10915-022-01939-z>
- [47] Willard, J., Jia, X., Xu, S., Steinbach, M. and Kumar, V. (2022) Integrating Scientific Knowledge with Machine Learning for Engineering and Environmental Systems. *ACM Computing Surveys*, **55**, 1-37. <https://doi.org/10.1145/3514228>
- [48] Romano, M., Kapelan, Z. and Savić, D.A. (2014) Automated Detection of Pipe Bursts and Other Events in Water Distribution Systems. *Journal of Water Resources Planning and Management*, **140**, 457-467. [https://doi.org/10.1061/\(asce\)wr.1943-5452.0000339](https://doi.org/10.1061/(asce)wr.1943-5452.0000339)
- [49] Saldarriaga, J.G., Solarte, L., Salcedo, C., et al. (2020) Battle of the Leakage Detection and Isolation Methods: An Energy Method Analysis Using Genetic Algorithms. <https://api.semanticscholar.org/CorpusID:244969183>
- [50] Fan, X., Zhang, X. and Yu, X.B. (2021) Machine Learning Model and Strategy for Fast and Accurate Detection of Leaks in Water Supply Network. *Journal of Infrastructure Preservation and Resilience*, **2**, Article No. 10. <https://doi.org/10.1186/s43065-021-00021-6>
- [51] Daniel, I., Pesantez, J., Letzgus, S., Khaksar Fasaee, M.A., Alghamdi, F., Berglund, E., et al. (2022) A Sequential Pressure-Based Algorithm for Data-Driven Leakage Identification and Model-Based Localization in Water Distribution Networks. *Journal of Water Resources Planning and Management*, **148**, Article 04022025. [https://doi.org/10.1061/\(asce\)wr.1943-5452.0001535](https://doi.org/10.1061/(asce)wr.1943-5452.0001535)
- [52] Xing, L. and Sela, L. (2022) Graph Neural Networks for State Estimation in Water Distribution Systems: Application of Supervised and Semisupervised Learning. *Journal of Water Resources Planning and Management*, **148**, Article 04022018. [https://doi.org/10.1061/\(asce\)wr.1943-5452.0001550](https://doi.org/10.1061/(asce)wr.1943-5452.0001550)
- [53] Kerimov, B., Bentivoglio, R., Garzón, A., Isufi, E., Tscheikner-Gratl, F., Steffelbauer, D.B., et al. (2023) Assessing the Performances and Transferability of Graph Neural Network Metamodels for Water Distribution Systems. *Journal of Hydroinformatics*, **25**, 2223-2234. <https://doi.org/10.2166/hydro.2023.031>
- [54] Zhou, X., Tang, Z., Xu, W., Meng, F., Chu, X., Xin, K., et al. (2019) Deep Learning Identifies Accurate Burst Locations in Water Distribution Networks. *Water Research*, **166**, Article ID: 115058. <https://doi.org/10.1016/j.watres.2019.115058>
- [55] Ashraf, I., Strotherm, J., Hermes, L. and Hammer, B. (2024) Physics-Informed Graph Neural Networks for Water Distribution Systems. *Proceedings of the AAAI Conference on Artificial Intelligence*, **38**, 21905-21913. <https://doi.org/10.1609/aaai.v38i20.30192>
- [56] Sun, L., Gao, H., Pan, S. and Wang, J. (2020) Surrogate Modeling for Fluid Flows Based on Physics-Constrained Deep Learning without Simulation Data. *Computer Methods in Applied Mechanics and Engineering*, **361**, Article ID: 112732. <https://doi.org/10.1016/j.cma.2019.112732>
- [57] Garzón, A., Kapelan, Z., Langeveld, J. and Taormina, R. (2022) Machine Learning-Based Surrogate Modeling for Urban Water Networks: Review and Future Research Directions. *Water Resources Research*, **58**, e2021WR031808. <https://doi.org/10.1029/2021WR031808>
- [58] Mounce, S.R., Boxall, J.B. and Machell, J. (2010) Development and Verification of an Online Artificial Intelligence System for Detection of Bursts and Other Abnormal Flows. *Journal of Water Resources Planning and Management*, **136**, 309-318. [https://doi.org/10.1061/\(asce\)wr.1943-5452.0000030](https://doi.org/10.1061/(asce)wr.1943-5452.0000030)
- [59] Bakker, M., Vreeburg, J.H.G., van Schagen, K.M. and Rietveld, L.C. (2013) A Fully Adaptive Forecasting Model for Short-Term Drinking Water Demand. *Environmental Modelling & Software*, **48**, 141-151. <https://doi.org/10.1016/j.envsoft.2013.06.012>

- [60] Ye, G. and Fenner, R.A. (2011) Kalman Filtering of Hydraulic Measurements for Burst Detection in Water Distribution Systems. *Journal of Pipeline Systems Engineering and Practice*, **2**, 14-22. [https://doi.org/10.1061/\(asce\)jps.1949-1204.0000070](https://doi.org/10.1061/(asce)jps.1949-1204.0000070)
- [61] Eliades, D.G. and Polycarpou, M.M. (2010) A Fault Diagnosis and Security Framework for Water Systems. *IEEE Transactions on Control Systems Technology*, **18**, 1254-1265. <https://doi.org/10.1109/tcst.2009.2035515>
- [62] Taormina, R. and Galelli, S. (2018) Deep-Learning Approach to the Detection and Localization of Cyber-Physical Attacks on Water Distribution Systems. *Journal of Water Resources Planning and Management*, **144**. [https://doi.org/10.1061/\(asce\)jwr.1943-5452.0000983](https://doi.org/10.1061/(asce)jwr.1943-5452.0000983)
- [63] Lima, G.M., Brentan, B.M., Manzi, D. and Luvizotto, E. (2018) Metamodel for Nodal Pressure Estimation at near Real-Time in Water Distribution Systems Using Artificial Neural Networks. *Journal of Hydroinformatics*, **20**, 486-496. <https://doi.org/10.2166/hydro.2017.036>
- [64] Pesantez, J.E., Berglund, E.Z. and Kaza, N. (2020) Smart Meters Data for Modeling and Forecasting Water Demand at the User-Level. *Environmental Modelling & Software*, **125**, Article ID: 104633. <https://doi.org/10.1016/j.envsoft.2020.104633>
- [65] Zanfei, A., Menapace, A., Brentan, B.M., Righetti, M. and Herrera, M. (2022) Novel Approach for Burst Detection in Water Distribution Systems Based on Graph Neural Networks. *Sustainable Cities and Society*, **86**, Article ID: 104090. <https://doi.org/10.1016/j.scs.2022.104090>
- [66] Hawari, A., Alkadour, F., Elmasry, M. and Zayed, T. (2020) A State of the Art Review on Condition Assessment Models Developed for Sewer Pipelines. *Engineering Applications of Artificial Intelligence*, **93**, Article ID: 103721. <https://doi.org/10.1016/j.engappai.2020.103721>
- [67] Cheng, J.C.P. and Wang, M. (2018) Automated Detection of Sewer Pipe Defects in Closed-Circuit Television Images Using Deep Learning Techniques. *Automation in Construction*, **95**, 155-171. <https://doi.org/10.1016/j.autcon.2018.08.006>
- [68] Yin, X., Chen, Y., Bouferguene, A., Zaman, H., Al-Hussein, M. and Kurach, L. (2020) A Deep Learning-Based Framework for an Automated Defect Detection System for Sewer Pipes. *Automation in Construction*, **109**, Article ID: 102967. <https://doi.org/10.1016/j.autcon.2019.102967>
- [69] Wang, M. and Cheng, J.C.P. (2020) A Unified Convolutional Neural Network Integrated with Conditional Random Field for Pipe Defect Segmentation. *Computer-Aided Civil and Infrastructure Engineering*, **35**, 162-177. <https://doi.org/10.1111/mice.12481>
- [70] Mosavi, A., Öztürk, P. and Chau, K.-W. (2018) Flood Prediction Using Machine Learning Models: Literature Review. *Water*, **10**, Article No. 1536.
- [71] Berkhahn, S., Fuchs, L. and Neuweiler, I. (2019) An Ensemble Neural Network Model for Real-Time Prediction of Urban Floods. *Journal of Hydrology*, **575**, 743-754. <https://doi.org/10.1016/j.jhydrol.2019.05.066>
- [72] Guo, Z., Leitão, J.P., Simões, N.E. and Moosavi, V. (2020) Data-Driven Flood Emulation: Speeding up Urban Flood Predictions by Deep Convolutional Neural Networks. *Journal of Flood Risk Management*, **14**, e12684. <https://doi.org/10.1111/jfr3.12684>
- [73] Chang, F., Chen, P., Lu, Y., Huang, E. and Chang, K. (2014) Real-Time Multi-Step-Ahead Water Level Forecasting by Recurrent Neural Networks for Urban Flood Control. *Journal of Hydrology*, **517**, 836-846. <https://doi.org/10.1016/j.jhydrol.2014.06.013>
- [74] Wei, X. and Kusiak, A. (2015) Short-Term Prediction of Influent Flow in Wastewater Treatment Plant. *Stochastic Environmental Research and Risk Assessment*, **29**, 241-249. <https://doi.org/10.1007/s00477-014-0889-0>
- [75] Mounce, S.R., Shepherd, W., Sailor, G., Shucksmith, J. and Saul, A.J. (2014) Predicting Combined Sewer Overflows Chamber Depth Using Artificial Neural Networks with Rainfall Radar Data. *Water Science and Technology*, **69**, 1326-1333. <https://doi.org/10.2166/wst.2014.024>
- [76] Taloma, R.J.L., Cuomo, F., Comminiello, D. and Pisani, P. (2025) Machine Learning for Smart Water Distribution Systems: Exploring Applications, Challenges and Future Perspectives. *Artificial Intelligence Review*, **58**, Article No. 120. <https://doi.org/10.1007/s10462-024-11093-7>
- [77] Aziz, R., Banerjee, S., Bouzefrane, S. and Le Vinh, T. (2023) Exploring Homomorphic Encryption and Differential Privacy Techniques towards Secure Federated Learning Paradigm. *Future Internet*, **15**, Article No. 310. <https://doi.org/10.3390/fi15090310>
- [78] Jouini, O., Sethom, K., Namoun, A., Aljohani, N., Alanazi, M.H. and Alanazi, M.N. (2024) A Survey of Machine Learning in Edge Computing: Techniques, Frameworks, Applications, Issues, and Research Directions. *Technologies*, **12**, Article No. 81. <https://doi.org/10.3390/technologies12060081>
- [79] Brentan, B.M., Menapace, A., Oberascher, M., Herrera, M. and Sitzenfrei, R. (2025) Enhancing Explainable AI with Graph Signal Processing: Applications in Water Distribution Systems. *Water Research*, **285**, Article ID: 124022. <https://doi.org/10.1016/j.watres.2025.124022>

-
- [80] Lundberg, S.M. and Lee, S.I. (2017) A Unified Approach to Interpreting Model Predictions. In: Guyon, I., Luxburg, U.V., Bengio, S., *et al.*, Eds., *Advances in Neural Information Processing Systems* 30, Curran Associates, Inc., 4765-4774.
- [81] Ribeiro, M.T., Singh, S. and Guestrin, C. (2016) “Why Should I Trust You?” Explaining the Predictions of Any Classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco, 13-17 August 2016, 1135-1144. <https://doi.org/10.1145/2939672.2939778>
- [82] Fuertes, P.C., Alzamora, F.M., Carot, M.H. and Alonso Campos, J.C. (2020) Building and Exploiting a Digital Twin for the Management of Drinking Water Distribution Networks. *Urban Water Journal*, **17**, 704-713.
- [83] Bommasani, R., Hudson, D.A., Adeli, E., *et al.* (2021) On the Opportunities and Risks of Foundation Models. <https://arxiv.org/abs/2108.07258>
- [84] Hajgató, G., Paál, G. and Gyires-Tóth, B. (2020) Deep Reinforcement Learning for Real-Time Optimization of Pumps in Water Distribution Systems. *Journal of Water Resources Planning and Management*, **146**, Article ID: 04020079. [https://doi.org/10.1061/\(asce\)wr.1943-5452.0001287](https://doi.org/10.1061/(asce)wr.1943-5452.0001287)