DOI:10.16799/j.cnki.csdqyfh.260743

基于水量平衡与Stacking融合的泵站日进水流量预测

李翊君,刘亚珲
[上海市政工程设计研究总院(集团)有限公司,上海市 200092]

摘　要: 为实现排水系统的精细化优化调度,针对部分排水泵站缺乏可靠进水流量监测数据的实际问题,提出一种基于水量平衡与Stacking融合的泵站日进水流量预测方法。首先,基于InfoWorks构建泵站前池及上游管网仿真模型,建立液位—体积函数关系,结合出水流量实测数据与水量平衡原理反演得到泵站日进水流量,构建建模数据集;其次,以随机森林、XGBoost与LightGBM为基模型,采用Stacking融合策略构建集成预测模型,实现多模型预测结果的有效整合。以华东某泵站实际运行数据为例开展验证,结果表明:融合模型在测试集上的均方根误差(E_{RMS})为3 523.63,较最优单一模型降低14.2%;平均绝对百分比误差(E_{MAP})为14.22%,降低22.2%;决定系数(R^2)达到0.841。研究结果表明,所提方法在监测信息不完备条件下能够有效提高日尺度进水流量预测精度,为排水系统优化调度提供可靠数据支撑。

关键词: 排水泵站;日进水流量;水量平衡;Stacking融合;随机森林;XGBoost;LightGBM
中图分类号: TH-86　　**文献标志码:** A　　**文章编号:** 1009-7716(2026)11-0023-06

Daily Inflow Prediction of Pumping Stations Based on Water Balance and Stacking Fusion

LI Yijun, LIU Yahui
[Shanghai Municipal Engineering Design Institute (Group) Co., Ltd., Shanghai 200092, China]

Abstract: To achieve refined optimal operation of drainage systems, a daily inflow predication method for pumping stations based on water balance and Stacking fusion is proposed for the practical problem that some drainage pumping stations lack reliable real-time inflow monitoring data. Firstly, the simulation model of the front tank of the pumping station and the upstream pipeline network is constructed based on InfoWorks. A liquid level-volume functional relationship is derived. Combined with measured effluent flow data and the water balance principle, the daily inflow volume of the pumping station is back-calculated to construct the modeling dataset. Secondly, Random Forest (RF), XGBoost and LightGBM are adopted as base model, and an integrated prediction model is built with the Stacking fusion strategy to effectively integrate the prediction results of multiple models. Validation is carried out by using field operational data of an actual pumping station in East China. The results demonstrate that the E_{RMS} of the fused model on the test set reaches 3, 523. 63, 14. 2% lower than the best single model. The mean absolute percentage error (E_{MAP}) is 14. 22%, a decrease of 22. 2%. The coefficient of determination (R^2) reaches 0. 841. The study result verifies that the proposed approach can significantly improve the accuracy of daily-scale inflow predication under insufficient monitoring data, offering solid data support for refined optimal operation of drainage systems.

Keywords: drainage pumping station; daily-scale inflow; water balance; Stacking fusion; random forest; XGBoost; LightGBM

0　引　言

“十五五”阶段,我国城市基础设施建设聚焦提质增效与安全韧性提升,国家排水防涝专项规划明确要求强化厂站网一体化调度,推进排水管理精细化发展。上海十五五水务规划聚焦超大城市治理需求,加快排水系统数字化、智能化转型,搭建数据驱动的决策运行体系,完善泵站监测体系,优化智能调度能力。在此背景下,搭建高精度泵站进水流量预测模型,可为排水系统精细化管控与一体化智能调度提供核心技术支撑,助力城市排水安全韧性建设。

收稿日期:2026-07-06
作者简介:李翊君(1979—),男,硕士,教授级高级工程师,从事市政工程电气及自动化系统、数字化转型及人工智能算法应用的相关设计和研究工作。

泵站进水流量是排水系统调度控制的关键输入参数，其预测精度直接影响着调度策略的合理性。然而在实际运行中，部分泵站由于建设年代较早或改造受限，进、出水端均未配置可靠流量计，仅可获取前池液位及泵组启停状态等运行信息，出水流量需依据泵组铭牌参数进行近似推算。监测条件的不完备导致进水流量难以直接获取，进而制约预测模型的构建与调度决策的精细化实施。因此，在监测信息受限条件下构建可靠的日尺度进水流量预测方法，已成为亟待解决的技术问题[1]。

在监测信息不完备条件下，监督学习模型的构建首先面临的是训练样本标签缺失问题。针对进水流量无法直接测量的实际情况，有必要通过机理约束对历史运行数据进行反演，构建可用于模型训练的目标变量。水量平衡理论为此提供了可行路径。通过建立泵站控制区域的体积守恒关系，结合前池液位变化及基于泵组运行状态推算的出水流量，可在日尺度上反演得到进水总量，从而形成监督学习所需的训练数据集。该过程实现了由运行信息到目标变量的机理反演，为后续数据驱动模型训练奠定基础。

在流量预测领域，传统时间序列模型如ARIMA等方法在早期研究中得到应用，但其对平稳性要求较高，难以刻画复杂非线性关系[2]。随着机器学习方法的发展，随机森林、XGBoost、LightGBM等模型被广泛用于供排水系统流量预测[3-6]。相关研究表明，集成学习模型在非线性建模和特征适应性方面具有较好表现[7]。此外，多模型融合策略（如Stacking）通过整合不同模型的预测结果，可在一定程度上降低偏差与方差，提高预测稳定性[8]。然而，现有研究多建立在监测数据完整可靠的前提下，针对进水流量缺失场景的研究相对较少，尤其缺乏将水力机理模型与机器学习融合的系统方法。

针对上述问题，本文提出一种基于水量平衡与Stacking融合的排水泵站日尺度进水流量预测方法。InfoWorks作为排水管网领域主流的水力仿真模拟软件，可精准实现水系构筑物与管网系统的数字化建模及水力演算。首先依托InfoWorks构建泵站前池及上游管网仿真模型，建立液位-体积函数关系，在水量平衡约束下反演形成日尺度进水流量训练数据；其次构建以随机森林、XGBoost和LightGBM为基模型的Stacking融合预测框架，实现多模型协同优化。该方法实现了机理反演与数据驱动预测的有机耦合，在监测信息不完备条件下提高了日尺度进水流量预测精度，可为排水系统精细化优化调度提供技术支撑。

1　基于水量平衡的日尺度进水流量反演方法

在城市排水系统的高效运行管理中，准确掌握泵站的来水流量至关重要，这是实现精细化调度的基础，也是调度预案制定的关键数据。然而，在华东某地区的泵站实际运行场景下，泵站进水及出水端缺乏流量计，仅设置了前池液位计。因泵站上游管网与前池具备调蓄蓄水能力，水位变化无法直接对等反映实时来水量，仅依靠现有液位监测数据难以精准反演泵站进水流量，这一难题制约了排水调度工作的开展，而基于水量平衡原理的流量推算方法，为解决该问题提供了可靠技术路径。

1.1　日尺度水量平衡方程建立

针对该泵站无可靠进水流量直接监测数据的问题，本文以前池及其上游汇水管网作为控制体，在日尺度上建立水量平衡关系。考虑城市合流制管网中可能存在地下水入渗、旱天非降雨入流、管道外渗漏失、蒸发以及溢流等水量交换过程，控制体在单日时间步长内的完整水量平衡可表示为：

$$W_{in} = W_{out} + \Delta V + W_e + W_I + W_o + \varepsilon \quad (1)$$

式中：W_{in}为控制体日进水总量，包括上游汇水区生活污水、降雨径流以及地下水入渗、旱天非降雨入流等进入管网并最终汇入泵站的水量；W_{out}为泵站日出水总量；ΔV为前池及上游管网日内始末蓄水体积变化量，$\Delta V = V_{end} - V_{start}$，其中$V_{start}$、$V_{end}$分别为日内初始与结束时刻前池及上游管网的水体体积；W_e为蒸发损失量；W_I为管道外渗漏失量；W_o为溢流或旁路排放量；ε为由流量估算、液位测量及液位-体积关系拟合等引起的综合误差项。

在本文研究对象中，地下水入渗及旱天非降雨入流作为泵站实际进水组成部分，随泵站出水过程和管网蓄水变化共同反映在反演得到的W_{in}中，因此本文并未将其从进水总量中剔除。为获得可用于监督学习建模的日尺度目标变量，需进一步判断蒸发、管道外渗漏失及溢流项对水量平衡的影响。研究期内控制体主要由封闭管道和泵站前池组成，开敞水面面积相对于日输送水量较小，日蒸发损失可按$W_e = E \cdot A$估算，其中E为日蒸发深度，A为有效开敞水面面积。与泵站日进水量相比，W_e/W_{in}占比极低。管道外渗漏失主要与管材、接口状态、地下水位及管内

外水头差有关，本研究对象运行期内未出现持续异常液位衰减或旱天出水量突变现象，且经运行记录核查无溢流或旁路排放事件。

因此，在研究期内无溢流记录、蒸发损失及外渗漏失相对于日进水量占比较小的条件下，式（1）中 W_e、W_I 和 W_o 可并入 ε。若忽略高阶小量并将 ε 作为反演误差处理，则日尺度水量平衡可简化为：

$$W_{in} \approx W_{out} + \Delta V \tag{2}$$

1.2　出水流量估算方法

由于泵站未配置出水流量计，出水流量通过泵组运行状态估算。设第 i 台泵组铭牌流量为 q_i，运行状态为 $s_i(t)$（运行时取 1，停止时取 0），则瞬时出水流量可以表示为：

$$q_{out}(t) = \sum_{i=1}^{n} s_i(t) \cdot q_i \tag{3}$$

日出水总量通过离散积分计算：

$$W_{out} = \sum_{k=1}^{N} q_{out}(t_k) \cdot \Delta t \tag{4}$$

式中：N 为单日采样次数；Δt 为采样时间间隔。

1.3　液位-体积函数构建方法

为准确计算控制体体积变化量，依托 InfoWorks 构建泵站前池及上游管网仿真模型。通过改变前池液位边界条件，在-5.5~6 m 区间内按 0.1 m 步长进行模拟，获得液位-体积对应关系样本。

采用分段线性拟合建立函数关系：

$$V = f(H) \tag{5}$$

式中：V 为对应控制体体积；H 为前池液位，$f(H)$ 的表达式如式（6）所示。

$$f(H) = \begin{cases} 113H + 615.85 & H \in [-5.4, -4.3) \\ 964.8H^2 + 8447.3H + 18620.2 & H \in [-4.3, -3.3) \\ -662.9H^2 - 2787.7H - 735.6 & H \in [-3.3, -2.3) \\ 1127.5H + 4764.9 & \text{H} \in [-2.3, -1.3) \\ 543.3H^2 + 1562H + 4418.3 & H \in [-1.3, 0.8) \\ -319.2H^2 + 1933.8H + 4791.2 & H \in [0.8, 3) \\ 120H + 7374.7 & H \in [3, 4.7) \\ 3.5H + 7927.8 & H \in [4.7, 6) \end{cases} \tag{6}$$

该分段函数的拟合曲线如图 1 所示。

基于日内初始时刻的液位 h_{start} 和结束时刻的液位 h_{end}，通过已建立的液位-体积函数来计算体积变化量：

$$\Delta V = f(h_{end}) - f(h_{start}) \tag{7}$$

结合计算得到的出水总量 Q_{out} 与体积变化量 ΔV，根据水量平衡方程可最终推算出日进水流量。

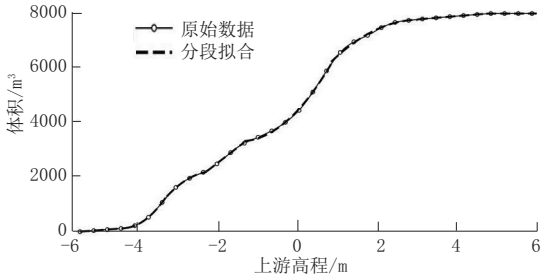


图 1　液位-体积函数关系

2　算法原理介绍

泵站日尺度进水流量受降雨过程、居民生活习惯、管网蓄水效应及泵组运行状态等多因素耦合影响，呈现明显非线性特征。为刻画复杂映射关系，本文选取 3 类基于决策树的集成学习模型作为基础模型：随机森林、XGBoost 与 LightGBM。

2.1　单一预测模型原理

随机森林基于集成学习思想，通过 bootstrap 抽样从原始数据中生成多个子样本集，每个子样本集独立构建决策树；在树节点分裂时，随机选择部分特征，采用 Gini 不纯度等指标确定最优分裂点；对于回归任务，最终预测结果为所有决策树输出的平均值。其优势在于通过多树集成有效降低过拟合风险，适用于泵站流量预测中存在复杂噪声的数据场景；能直接处理高维输入特征，无需进行特征降维；可通过特征重要性评分来量化各影响因素对泵站来水量的贡献度，为排水系统调度提供解释性支持。

XGBoost 基于梯度提升框架，以加法模型的形式迭代构建决策树，每棵新树拟合前序模型的残差；通过在目标函数中引入树复杂度惩罚项实现正则化机制，有效抑制过拟合；同时借助预排序技术实现特征分裂的并行计算，提升训练效率。其优势体现在对非线性关系的捕捉能力强，可精准拟合泵站流量与多影响因素的复杂映射关系；对缺失值具有自适应性，适用于泵站监测数据中可能存在的信息不全问题；预测精度高，能为排水系统精细化调度提供可靠的流量预判依据[9]。

LightGBM 采用基于直方图的决策树算法，将连续特征离散化为有限数量的 bins 以减少计算量；通过 GOSS 采样保留梯度较大的样本、EFB（Exclusive Feature Bundling）技术捆绑互斥特征，在降低模型复杂度的同时保持预测精度；以叶子生长策略构建树结构，进一步提升训练速度。其优势为训练效率高、内存占用低，可快速处理泵站长期积累的大规模历

史运行数据；对高维稀疏特征适应性强，能有效整合排水系统中多源异构信息（如时段、季节、设备状态等）；适用于需要高频更新预测模型的泵站实时调度场景。

2.2　Stacking融合策略原理

单一模型在复杂场景下可能存在偏差或方差问题[10]。为提高预测稳定性与泛化能力，本文采用Stacking融合策略构建集成预测模型。

Stacking融合的基本框架由基模型和元模型2层组成。基模型负责提供多样化的预测结果，选择随机森林、XGBoost、LightGBM作为基模型，因其在泵站流量预测场景中各具优势，且模型原理的差异能够确保预测误差的互补性。元模型以基模型的预测结果为输入，学习最优整合策略。对于回归任务，选择线性回归作为元模型，其简单性可避免过拟合，同时能够保证对基模型输出的线性加权优化，适配泵站流量预测的连续值输出需求。为避免基模型的预测结果与训练数据过拟合，采用K折交叉验证生成元特征：将训练集分为K折，每次用K−1折训练基模型，对剩余1折进行预测，最终拼接K次预测结果作为元模型的训练数据，确保元模型能够学习到泛化能力强的整合规则，提升对泵站未来流量的预测可靠性。

Stacking融合的实现流程分为训练阶段和预测阶段。训练阶段，对每个基模型执行K折交叉验证，得到训练集的K折预测结果，拼接形成元特征矩阵；以元特征矩阵为输入、真实泵站流量为标签，训练元模型。预测阶段，用全部训练数据重新训练各基模型，对测试集进行预测，生成测试集的元特征矩阵；将测试集元特征输入元模型，输出最终的融合预测结果，为排水系统调度预案制定提供决策支持。模型结构如图2所示。

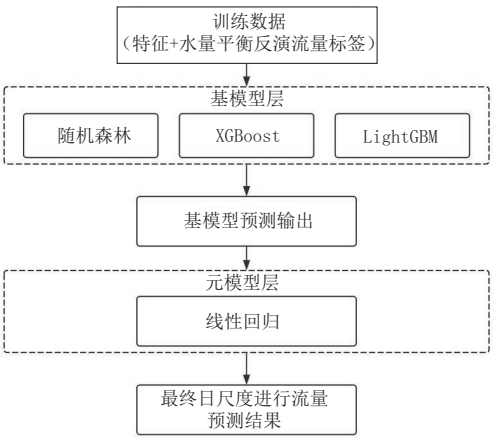


图2　模型结构图

Stacking提升预测性能与鲁棒性的机理主要体现在两个方面：一是整合不同模型的优势，弥补单一模型缺陷，通过元模型学习权重分配，在泵站流量预测中充分发挥各基模型的优势，规避单一模型在极端工况（如暴雨导致的流量突增）下的预测偏差；二是降低预测结果的方差与偏差，多模型融合通过平均效应降低预测方差，元模型对系统性误差的拟合能够减少偏差，使融合结果更稳定，适用于排水系统调度中对流量预测精度和可靠性要求较高的场景，为InforWorks仿真提供更精准的输入数据。

3　实验分析

本实验以华东某地区泵站为研究对象，基于多维度监测数据构建预测模型并开展对比验证。实验数据涵盖泵站运行状态与环境参数，其中运行数据包括泵站的液位（m）监测、出水瞬时流量（m^3/s）数据；环境参数则为附近雨水泵站测量的日内累计降雨量（mm）。数据集时间跨度为2024年4月1日至2025年3月31日，时间分辨率为5 min，覆盖平水期、丰水期。通过基于水量平衡原理拟合的泵站来水流量方法，得到365条泵站日进水流量有效样本。其中前90%作为训练集用于模型参数学习，后10%作为测试集。

3.1　评价指标确定

实验选取均方根误差（E_{RMS}）、决定系数（R^2）、平均绝对百分比误差（E_{MAP}）作为模型性能的核心评价指标，从不同维度全面衡量模型的预测精度[11-12]。

平均绝对百分比误差E_{MAP}以百分比形式表示预测误差，能直观反映预测值相对于真实值的偏离程度。计算公式为：

$$E_{MAP}=\frac{100\%}{n}\sum_{i=1}^{n}\left|\frac{\hat{y}_i-y_i}{y_i}\right| \tag{8}$$

均方根误差E_{RMS}直接反映预测值与真实值的平均偏离程度，单位与目标变量一致，物理意义明确。计算公式为：

$$E_{RMS}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}\left(\hat{y}_i-y_i\right)^2} \tag{9}$$

决定系数R^2反映模型相对于“均值预测”的改进程度。计算公式为：

$$R^2=1-\frac{\sum_{i=1}^{n}\left(y_i-\hat{y}_i\right)^2}{\sum_{i=1}^{n}\left(y_i-\bar{y}_i\right)^2} \tag{10}$$

上述式中：n为样本个数；$\hat{y}_i$为第i个样本对应的预测

值；y_i 为第 i 个样本对应的真实值；$\bar{y}_i$ 为样本的平均值。

3.2　单一预测模型构建

实验中构建了 3 类单一预测模型（XGBoost、LightGBM、随机森林）及 Stacking 融合模型。对于各单一模型，采用贝叶斯优化算法对其关键参数进行调优，通过早停机制监控验证集损失以避免过拟合。Stacking 融合模型以 XGBoost、LightGBM、随机森林作为基模型，采用 5 折交叉验证生成次级训练数据，选用线性回归作为元模型，通过最小化均方根误差 E_{RMS} 训练系数，实现对基模型预测结果的加权整合。

各单一模型在泵站数据测试集上的性能指标如表 1 所示。

表 1　单一模型在泵站测试集上的性能指标

模型名称	E_{MAP}	E_{RMS}	R^2
XGBoost	0.217 0	5 382.9	0.723 5
LightGBM	0.208 0	4 856.7	0.774 9
随机森林	0.182 7	4 107.3	0.839 0

由表 1 可知：在 3 类单一模型中，随机森林的综合性能最优，表明该模型对泵站日进水流量的整体变化趋势和细节波动具有较强的捕捉能力；LightGBM 的性能次之，各项指标均优于 XGBoost，体现了其在处理类别特征和大规模数据上的优势；XGBoost 的性能相对较差，其决定系数仅为 0.723 5，说明其在该数据集上对流量规律的拟合程度有待提高。

各单一模型预测结果与真实值的对比见图 3 至图 5。

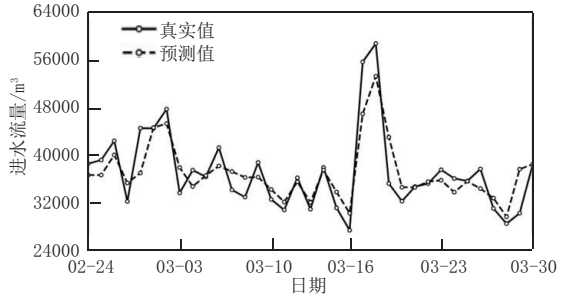


图 3　XGBoost 预测结果与真实值对比

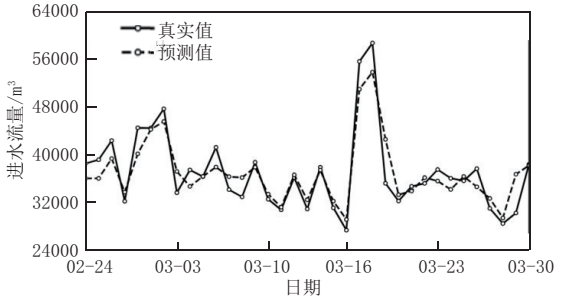


图 4　LightGBM 预测结果与真实值对比

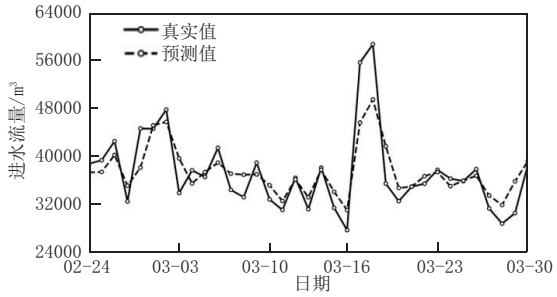


图 5　随机森林预测结果与真实值对比

3.3　基于 Stacking 融合模型构建

基于 Stacking 融合模型在泵站测试集上的性能指标见表 2；融合模型预测结果与真实值的对比见图 6。为更直观地比较各模型的性能，将所有模型的关键指标汇总于表 2。

表 2　Stacking 融合模型在泵站测试集上的性能指标

模型名称	E_{MAP}	E_{RMS}	R^2
XGBoost	0.217 0	5 382.9	0.723 5
LightGBM	0.208 0	4 856.7	0.774 9
随机森林	0.182 7	4 107.3	0.839 0
Stacking 融合模型	0.142 2	3 523.6	0.841 1

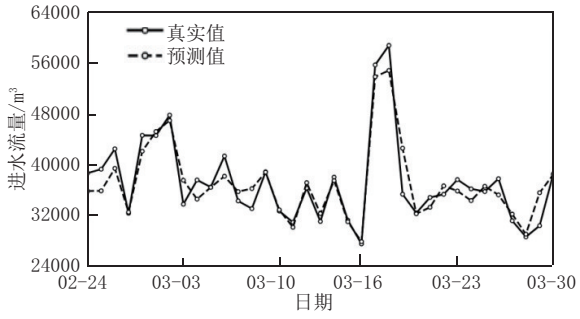


图 6　融合模型预测结果与真实值对比

对比表 1 与表 2 可以发现，Stacking 融合模型的各项性能指标均优于单一模型。与最优单一模型相比，其 E_{RMS} 值降至 3 523.6，降低了 14.2%；E_{MAP} 值降至 0.142 2，降低了 22.2%；R^2 达到 0.841 1，提升了 0.25%。这表明融合模型通过整合各单一模型的优势，有效提升了预测精度。

从预测结果的可视化来看，Stacking 融合模型的预测曲线与真实值曲线的贴合程度更高，尤其是在极端降雨导致的流量突增和异常数据点处，该模型的拟合精度明显优于单一模型。这说明 Stacking 策略能够有效降低预测偏差与方差，提高模型对复杂工况的适应能力。融合模型的稳定性也得到了增强，在不同流量区间的预测误差分布更为均匀。

综上所述，针对泵站日进水流量预测问题，Stacking 融合模型能够显著提升预测精度与鲁棒性，为排水系统的优化调度提供更为可靠的决策依据。

4　结　语

（1）针对排水泵站进水流量缺乏直接监测数据的实际问题，提出了一种基于水量平衡与Stacking融合的日尺度进水流量预测方法。在监测信息不完备条件下，首先依托InfoWorks构建泵站前池及上游管网仿真模型，建立液位-体积函数关系，在水量守恒约束下反演形成日尺度进水流量训练数据；在此基础上构建以随机森林、XGBoost和LightGBM为基模型的Stacking融合预测框架，实现机理反演与数据驱动预测的有机结合。

（2）实验结果表明，相较于最优单一模型，融合模型在测试集上的E_{RMS}降低14.2%，E_{MAP}降低22.2%，R^2达到0.841 1，预测误差分布更加集中，在高流量波动阶段表现出更好的稳定性。研究结果表明，在缺乏直接流量监测条件下，通过水量平衡反演构建训练数据并结合集成学习方法，可有效提高日尺度进水流量预测精度，为排水系统精细化优化调度提供数据支持。

参考文献：

[1] 魏红霞.基于机器学习的城市积水风险预测研究[J].城市道桥与防洪，2025(11)：175-179.

[2] 杨钰雪.智慧化城市短期供水量预测与梯级泵站优化调度研究[D].重庆：重庆大学，2022.

[3] 陈成，王福鹏，闫钰，等.XGBoost结合建筑特征信息预测生活小区污水量[J].中国给水排水，2025，41(23)：77-83.

[4] 白云，陈国强.基于尺度特征融合的随机森林日供水量预测模型[J].长江科学院院报，2022，39(3)：33-37.

[5] 王伟杰，于洋，孙凌霄，等.基于XGBoost的干旱区典型绿洲主要作物需水量预测模型研究[J].干旱区地理，2025，48(12)：2087-2098.

[6] 贺波，马静，高赫余.基于多粒度特征和XGBoost模型的城市日供水量预测[J].长江科学院院报，2020，37(5)：43-49.

[7] 胡诗苑，高金良，钟丹，等.基于异常值识别的计量小区短期需水量预测[J].哈尔滨工业大学学报，2022，54(8)：43-51.

[8] 胡比澜，王洋洋，张永强.基于多模型Stacking融合的基坑测斜时序预测[J].浙江大学学报(工学版)，2025，59(4)：706-716.

[9] 李翊君，刘亚珲.集成学习与深度学习融合的污水厂出水水质预测研究[J].自动化仪表，2025，46(4)：101-106.

[10] 黄海东，刘世通，吴美琼.基于BiTCN和QRF的DMA用水量区间预测[J].中国给水排水，2026，42(5)：55-62.

[11] 俞焰，王莹璐，赵启涵.城市排水管网动态监测预警及冒溢预测[J].中国给水排水，2024，40(17)：123-130.

[12] 郭利进，刘文哲，刘彦宾.融合小波变换和改进麻雀算法的GRU水质预测研究[J].给水排水，2025，61(12)：144-151.

（上接第17页）

参考文献：

[1] 张义桐，郝增超，陈阳，等.全球多时间尺度复合高温干旱增加[J].中国科学：地球科学，2025，55(10)：3321-3332.

[2] 郝增超，陈阳.地球系统视角下的多圈层复合极端事件研究进展与展望[J].中国科学：地球科学，2024，54(2)：360-393.

[3] Zscheischler J, Westra S, Martius O, et al. A typology of compound weather and climate events[J]. Nature Reviews Earth & Environment, 2020, 1(7): 333-347.

[4] 王媛，苏布达，姜彤，等.气候与社会经济变化下抚河流域氮磷负荷变化[J].人民长江，2024，55(2)：65-76.

[5] Sun Y, Zhang X, Zwiers F W. Increasing compound heatwaves and floods in southern China: Patterns, causes, and societal impacts[J]. Journal of Climate, 2022, 35(12), 3899-3916.

[6] 王劲松，李耀辉，王润元，等.我国气象干旱研究进展评述[J].干旱气象，2012，30(4)：497-508..

[7] McKee T B, Doesken N J, Kleist J. The relationship of drought frequency and duration to time scales (Paper presented at the 8th Conference on Applied Climatology) [C]//Proceedings of the 8th Conference on Applied Climatology. Boston: American Meteorological Society, 1993: 179-184.

[8] 侯威，张存杰，高歌.基于气候系统内在层次性的气象干旱指数研究[J].气象，2012，38(6)：701-711.

[9] Shukla S, Wood A W. Use of a standardized runoff index for characterizing hydrologic drought[J]. Geophysical Research Letters, 2008, 35(2): L02405.

[10] 任立良，沈鸿仁，袁飞，等.变化环境下渭河流域水文干旱演变特征剖析[J].水科学进展，2016，27(4)：492-500.

[11] Palmer W C. Keeping track of crop moisture conditions, nationwide: The new Crop Moisture Index[J]. Weatherwise, 1968, 21(6): 156-161.

[12] 刘宪锋，朱秀芳，潘耀忠，等.农业干旱监测研究进展与展望(英文)[J].Journal of Geographical Sciences，2016，26(6)：750-767.

[13] Kogan F N. Application of vegetation index and brightness temperature for drought detection[J]. Advances in Space Research, 1995, 15(11): 91-100.

[14] Hao Z C, Hao F H, Singh V P, et al. A joint extreme index for compound droughts and hot extremes[J]. Stochastic Environmental Research and Risk Assessment, 2018, 32(10): 2827-2841.

[15] Peng S Z, Ding Y X, Liu W Z, et al. 1km monthly temperature and precipitation dataset for China from 1901 to 2017[J]. Earth System Science Data, 2019, 11(4): 1931-1946.