

融合机理启发式时间特征工程的城市内涝水位预测研究

金家明^{1,2}, 蔡海捷³, 张典^{3*}

¹浙江省建设厅建筑工程科创中心, 城市地下生命线安全工程技术科创中心, 浙江 杭州

²浙江建设职业技术学院建筑设备学院, 浙江 杭州

³预泓科技(上海)有限公司, 上海

收稿日期: 2026年4月13日; 录用日期: 2026年5月15日; 发布日期: 2026年5月27日

摘要

随着全球气候变化的加剧及城市化进程的迅猛推进, 城市内涝已成为制约我国中心城区可持续发展的核心瓶颈之一。传统基于物理机制的水文学模型(如SWMM)虽然在机理描述上具有显著优势, 但在实时预警场景中往往面临计算效率低、参数获取难及模型维护成本高等现实挑战。针对这一痛点, 研究提出了一种融合机理启发式时间特征工程的异构数理模型预测框架。该框架的核心创新在于将水文物理循环机制转化为可量化的时间特征空间, 包括: 利用二十四节气标识捕捉地球公转驱动的季节性降雨背景、采用三角函数变换映射日内排水周期, 以及通过防泄露滚动统计(Shift-Rolling)和多步滞后构造长短期历史记忆。以某典型山前滨河城市为研究对象, 在中心城区关键水位站进行了多模型验证。实验对比了包括集成学习(LightGBM、随机森林)、支持向量机(SVM)及深度时序网络(LSTM、CNLSTM、Transformer)在内的异构模型库。结果表明, 基于机理启发式特征工程的LightGBM模型在测试集上取得了0.9887的纳什效率系数(NSE), 其预测精度和计算实时性显著优于传统物理模型。研究证实, 引入蕴含物理规律的时间特征能显著增强数理模型的泛化能力与稳健性, 为智慧排水系统的动态风险评估与科学防涝决策提供了高效的技术支撑。

关键词

城市内涝, 水位预测, 深度学习, 机理启发式特征工程, 智慧排水系统

Research on Urban Flooding Water Level Prediction Integrating Mechanism-Heuristic Temporal Feature Engineering

Jiaming Jin^{1,2}, Haijie Cai³, Dian Zhang^{3*}

*通讯作者。

文章引用: 金家明, 蔡海捷, 张典. 融合机理启发式时间特征工程的城市内涝水位预测研究[J]. 环境保护前沿, 2026, 16(5): 900-910. DOI: 10.12677/aep.2026.165089

¹Urban Underground Lifeline Safety Engineering Technology Science and Innovation Center, Zhejiang Provincial Department of Construction Science and Innovation Center for Construction Engineering, Hangzhou Zhejiang

²School of Building Equipment, Zhejiang College of Construction, Hangzhou Zhejiang

³Yuhong Technology (Shanghai) Co., Ltd., Shanghai

Received: April 13, 2026; accepted: May 15, 2026; published: May 27, 2026

Abstract

With the exacerbation of global climate change and the rapid advancement of urbanization, urban waterlogging has become a major bottleneck restricting the sustainable development of central urban areas in China. Although traditional physics-based hydrological models (e.g., SWMM) possess significant advantages in mechanistic representation, they frequently face practical challenges in real-time early warning scenarios, such as low computational efficiency, difficulties in parameter acquisition, and high model maintenance costs. To address these limitations, this study proposes a heterogeneous predictive modeling framework integrating mechanism-heuristic temporal feature engineering. The core innovation of this framework lies in translating physical hydrological cycle mechanisms into a quantifiable temporal feature space. Specifically, this includes: utilizing the Twenty-Four Solar Terms to capture the seasonal rainfall background driven by the Earth's revolution; employing trigonometric transformations to map intra-day drainage cycles; and constructing long- and short-term historical memory via data leakage-free shift-rolling statistics and multi-step lags. Taking a typical piedmont riverine city as the case study, multi-model validation was conducted at key water level stations within the central urban area. The experiments compared a diverse library of heterogeneous models, including ensemble learning algorithms (LightGBM, Random Forest), Support Vector Machines (SVM), and deep time-series networks (LSTM, CNN-LSTM, Transformer). The results indicate that the LightGBM model, enhanced by mechanism-heuristic feature engineering, achieved a Nash-Sutcliffe Efficiency (NSE) coefficient of 0.9887 on the test set. Its prediction accuracy and real-time computational efficiency significantly outperformed traditional physics-based models. This study confirms that incorporating temporal features embedded with physical principles can significantly enhance the generalization capability and robustness of data-driven models, providing highly efficient technical support for dynamic risk assessment and scientific waterlogging mitigation decisions in smart drainage systems.

Keywords

Urban Flooding, Water Level Forecasting, Deep Learning, Mechanism-Heuristic Feature Engineering, Smart Drainage System

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

在过去的几十年里,中国经历了史无前例的城镇化进程,深刻改变了原有土地利用方式。大量自然透水表面被混凝土和沥青等不透水表面取代,从根本上改变了城市的水文循环特征[1]。降雨产生的径流系数显著增大,汇流时间缩短,导致城市中心城区在遭遇极端短时强降雨时极易发生严重的内涝灾害[2]。

为了应对这一复杂挑战,现代城市管理部门开始寻求建设“智慧排水系统”,力求实现对城市水系统的动态感知与智能调度。其中,水位预测模型是整套系统的“神经中枢”,其准确性与实时性直接决定了应急预案启动的及时[3]。传统工程领域,普遍依靠物理机制模型(如 SWMM 或 MIKE+)通过数值求解圣维南方程组来模拟地表径流与管网流动[3]。然而,物理模型在应用于实时预报时存在天然局限:首先,其准确度高度依赖于高精度的地形数据(DEM)及精细的管网拓扑参数,而这些数据在老旧城区往往存在缺失或更新滞后的问题[3];其次,物理过程的数值模拟涉及复杂的偏微分方程求解,耗时巨大,难以满足毫秒级的实时滚动预警需求。

近年来,数据驱动的数据模型因其强大的非线性映射能力和极快的推理速度,逐渐成为水文预报领域的创新方向。在具体应用层面,国内水务领域已开展了多项针对性尝试。例如,在郑州市的内涝预测研究中,研究者通过集成 Transformer 的全局特征提取能力与 LSTM 的时序建模能力,并结合麻雀搜索算法(SSA)优化超参数,在极端降雨情境下取得了优异的预警效果[4]。针对南昌乌沙河流域,研究人员采用了物理机制与机器学习耦合的代理模型方案,利用 XGBoost 算法对复杂管网系统进行快速降阶模拟,实现了预测效率与精度的平衡[5]。在深圳,基于 Lasso 特征降维与 GBDT 算法的轻量化框架被应用于实时内涝热点识别,成功在海量多源变量中提取关键 determinants [3]。此外,针对海绵城市建设中的排水需求,基于粒子群算法优化的 LSTM (PSO-LSTM)模型也被用于新型排水廊道系统的液位波动预测[6]。

本研究的关注区域位于华北典型山前城市,地势南高北低,南部山区径流与北部“地上悬河”压力构成了显著的“南洪北涝”风险。研究点位紧邻泉群补给的中心内湖,湖底为火成岩不透水层,排水受北侧调控设施控制。气候属暖温带季风区,年均降水量约 614.0~670.47 mm,且 70%集中于 6~9 月。这种“山-泉-湖-河”复合水系结构使中心城区在汛期面临极高的内涝风险,对水位预测的精度与适应性提出了更苛刻的要求。

针对上述区域水文特征,本研究的创新点在于构建了一个“机理启发式”的特征工程框架。不仅利用了原始的降雨量和历史水位数据,还构造了能够反映地球公转规律的二十四节气特征,以及反映日内循环的三角函数变换特征。在模型体系方面,本研究涵盖了从经典树模型到现代注意力机制的异构模型库,旨在探索不同算法在中心城区特定水利条件下的性能边界,并通过梯度裁剪与早停等防御性策略,确保预警系统的生产环境稳定性[7]。

2. 建模方法

本章将详细阐述水位预测模型的构建流程,从底层的数据对齐到高层的模型优化,形成一套标准化的水文数理建模方案。整体架构如图 1 所示。

本项目的研究数据来源于某城市中心城区的自动化监测网络,涵盖了高频率的水位传感器数据及同步的气象站降雨记录。研究中并没有直接将原始降雨数据输入模型,而是从基础、周期、气象、滞后和统计五个维度挖掘多维度特征。

2.1. 基础与周期特征的三角变换

为了捕捉水位变化的日内循环特征(如人为排水规律或潮汐影响),提取了时间戳中的“小时”信息。传统的分类变量或线性编码无法表达 23 点到 0 点之间的连续性,因此引入了正弦(Sin)与余弦(Cos)变换[8],计算方法见公式(1)~(2):

$$H_{sin} = \sin\left(\frac{2\pi \cdot t}{24}\right) \quad (1)$$

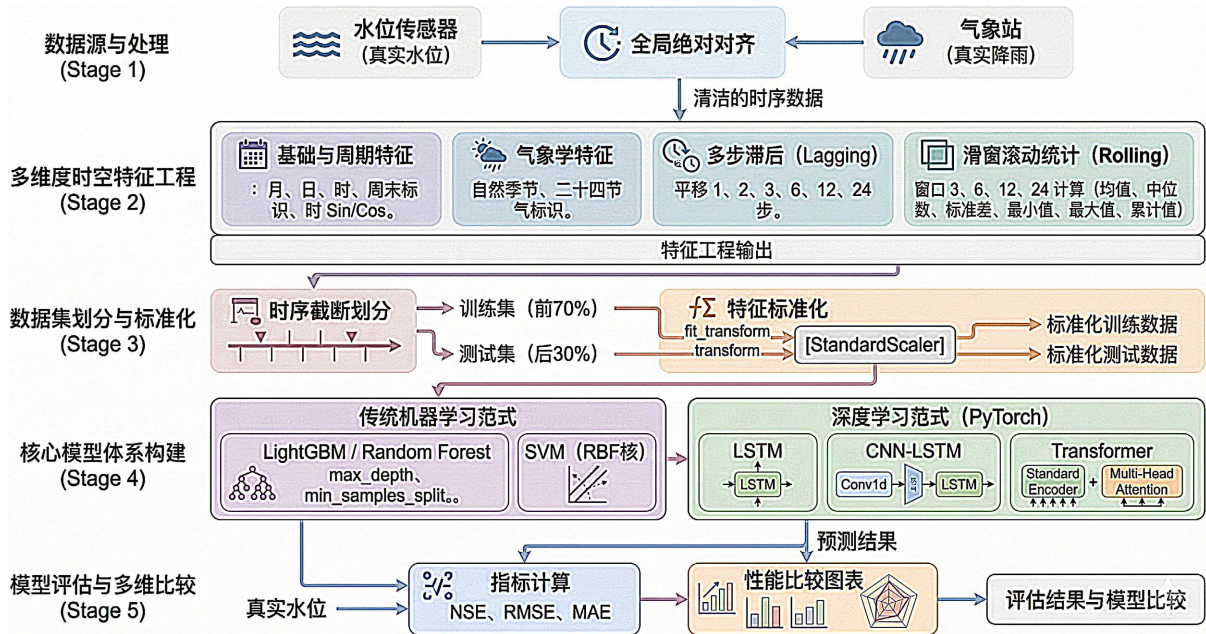


Figure 1. Framework diagram of technical process
图 1. 技术流程架构图

$$H_{\cos} = \cos\left(\frac{2\pi \cdot t}{24}\right) \quad (2)$$

通过这种映射，模型可以在连续的单位圆上理解时间的周期性。同时，系统还提取了月份、日期及周末标识，以捕捉潜在的节假日排水差异。

2.2. 气象学特征映射

城市水位的季节性波动与太阳直射点的周期性移动高度相关。本研究创新性地引入了中国传统的“二十四节气”作为特征变量。由于二十四节气反映了精细的气候转换节点(如“惊蛰”代表雷雨增多，“大暑”代表强降水频发)，它比普通的月份指标更能反映东亚季风气候下的降雨分布规律。通过计算当前日期与二十四节气天文节点的“宽容度窗口”距离，构造了连续的节气标识符，增强了模型对极端天气演变季节性规律的感知能力[9]。

2.3. 多步滞后与长期记忆构造

降雨对水位的影响具有明显的滞后效应(Lagging Effect)，这种效应取决于流域的汇流面积和排水管网的排涝能力。为了捕捉从短期冲击到中长期背景水位的变化，对特征执行了 1、2、3、6、12、24 步的时序平移[10]。这使得模型在决策时刻能够“回顾”过去一整天的环境演变路径。

2.4. 滑窗滚动统计

为了表征序列的趋势性(如降雨强度的累积效应)，系统计算了窗口大小为 1、2、3、6、12、24 的滚动统计量，包括均值、中位数、标准差、极值及累计值。

2.5. 数据集划分

本项目将前 70% 的数据时序作为训练集，后 30% 的数据作为测试集。这种做法拒绝了样本间的随机

打乱，确保模型利用历史数据预测未来。

2.6. 异构模型体系构建

实验构建了一个跨越传统机器学习与尖端神经网络的庞大模型库，以寻找预测性能的最佳平衡点。

2.6.1. 传统机器学习范式

1) LightGBM (轻量级梯度提升机): 采用基于直方图的算法和叶子生长策略(Leaf-wise)。它在处理具有大量非线性突变特征的水位数据时具有极高的速度优势。通过限制 `max_depth`，有效地控制了复杂模型的过拟合风险。

2) 随机森林(Random Forest): 作为集成学习的经典代表，它通过构建多棵决策树并取平均值来提高预测的稳健性。

3) 支持向量机(SVM): 利用 RBF 核将低维非线性问题映射到高维空间，旨在寻找能够最大化水位变化间隔的决策面。

2.6.2. 深度学习范式

1) LSTM (长短期记忆网络): 通过遗忘门、输入门和输出门的精妙设计，LSTM 能够有效缓解传统循环神经网络中的梯度消失问题，是捕获水文长程依赖关系的最佳工具。

2) CNNLSTM (时空联合架构): 首先利用一维卷积核(Conv1d)在局部时间窗内扫描，提取降雨强度的瞬时梯度和高频波动特征，随后将这些特征序列输入 LSTM 进行宏观时序汇聚。

3) Transformer (注意力机制网络): 完全摒弃了递归结构，依靠多头注意力机制(Multi-Head Attention)计算序列中任意两点之间的关联。它能够突破传统 RNN 的序列处理瓶颈，实现全局上下文的捕捉。

2.7. 模型评估

本项目采用了一套多维度的评估指标，包含 NSE (纳什效率系数)、RMSE (均方根误差)以及 MAE (平均绝对误差) [6] [11]。公式及定义见表 1:

Table 1. Definition and statistical significance of evaluation metrics

表 1. 评估指标定义及统计学意义

指标名称	数学公式	水文学意义
NSE	$1 - \frac{\sum (y_{obs} - y_{sim})^2}{\sum (y_{obs} - \bar{y}_{obs})^2}$	衡量模型预测值与实测值拟合程度的公认指标。1 为完美拟合；0 代表预测水平与平均值持平；负值代表模型不可靠。
RMSE	$\sqrt{\frac{1}{n} \sum (y_{obs} - y_{sim})^2}$	评估预测值与真实值之间的偏离程度，对极端水位(离群点)较为敏感。
MAE	$\frac{1}{n} \sum y_{obs} - y_{sim} $	反映预测误差的平均水平，能更直观地表现预测水位的物理偏差。

3. 评估结果与分析

3.1. 异构模型库性能总表

表 2 和表 3 分别汇总了各模型在训练集与测试集上的表现数据，整体模型训练测试效果较好，无过拟合现象。其中，各模型的关键参数如表 4 所示。

Table 2. Comparison of training and evaluation results for water level prediction models**表 2.** 水位预测模型训练评估结果对比

模型名	TRAIN_NSE	TRAIN_RMSE	TRAIN_MAE
CNNLSTM	0.9829	0.08096	0.0327
LSTM	0.9940	0.0482	0.0109
LightGBM	0.9974	0.0314	0.0063
RandomForest	0.9962	0.0381	0.0054
SVM	0.9847	0.0769	0.0676
Transformer	0.9917	0.0566	0.0241

Table 3. Comparison of testing and evaluation results for water level prediction models**表 3.** 水位预测模型测试评估结果对比

模型名	TEST_NSE	TEST_RMSE	TEST_MAE
CNNLSTM	0.9514	0.1367	0.0443
LSTM	0.9542	0.1327	0.0383
LightGBM	0.9887	0.0659	0.0285
RandomForest	0.9787	0.0906	0.0211
SVM	0.8910	0.2048	0.1842
Transformer	0.9506	0.1380	0.0465

Table 4. Key parameters of water level prediction model**表 4.** 水位预测模型关键参数

模型名	模型关键参数
CNN-LSTM	cnn_channels:32, kernel_size:4, lstm_hidden:64, cnn_dropout:0.2, lstm_dropout:0.2, learning_rate:0.001, optimizer:Adam, weight_decay:0.05
LSTM	lstm_hidden_size:64, lstm_num_layers:1, lstm_dropout:0.4, learning_rate:0.001, optimizer:AdamW, weight_decay:0.1
LightGBM	n_estimators:250, learning_rate:0.02, num_leaves:64, max_depth:6, reg_alpha:0.1
RandomForest	n_estimators:500, max_depth:6, min_samples_split:8, min_samples_leaf:8, max_features:sqrt
SVM	C:1, kernel:rbf, gamma:scale
Transformer	trans_dim_model:32, trans_num_heads:4, trans_num_layers:1, dropout:0.5, learning_rate:5e-05, optimizer:AdamW, weight_decay:0.3

在多模型评估对比中, LightGBM 算法表现出最优的拟合精度。实验数据表明, 该模型在测试集上的纳什效率系数达到 0.9887, 均方根误差降至 0.0658。结果反映出梯度提升决策树架构在处理降雨驱动序列时具备显著优势, 能够有效应对城市感知数据中普遍存在的非线性特征与瞬时突变。

在时序依赖关系的捕捉能力方面, LSTM 网络展现了稳健的建模性能, 其测试集纳什效率系数为 0.9542。尽管其对极端值的捕捉精度略低于集成学习模型, 但在提取长程时间相关性方面表现出较强的鲁棒性。相比之下, 传统支持向量机模型的预测效能相对有限, 测试集纳什效率系数仅为 0.8910。这表明该算法在处理智慧城市监测领域中大规模、非平稳的高维时序数据时, 其特征表征深度与泛化性能仍存在一定的局限性。

3.2. 可视化诊断：全景响应与拟合评估

3.2.1. 时序拟合曲线图和散点图

图 2 展示了各模型测试集的时序拟合曲线，以及训练集/测试集的预测值与实测值围绕对角线(预测值 = 实测值)的集中程度，用于评估模型在不同水位波动情况的泛化程度和不同水位区间的偏差分布。

从时序演化趋势看，各模型响应特征差异显著。LightGBM 与随机森林对瞬时峰值的捕捉能力较强，在相位与振幅上与观测值高度契合。相比之下，SVM 在初期存在系统性偏差，低观测值下的高位“超调”现象是导致其 NSE 下降的主因。而在平稳期，以 LSTM 和 Transformer 为代表的递归神经网络拟合稳定性最优。散点图量化结果显示，大部分模型散点紧贴 1:1 理想线，其中 LightGBM 在全量程内均无明显偏移。除 SVM 外，其余模型训练与测试集分布高度重合，样本外推能力稳健。局部误差分析证实，SVM 在低值区的模拟值异常集聚于高位区间，定量反映了其初期预测的严重失准。

3.2.2. 特征重要性排序图(top30)

图 3 展示了 LightGBM 模型对参与训练的特征进行特征重要性评估的前 30 个重要特征排序情况。对 LightGBM 模型的特征贡献度分析表明，模型呈现出显著的非均匀贡献分布。少数核心特征占据了绝大部分的解释权重，前五个特征的累计重要性接近 60%。

特征贡献度分析显示，模型决策受时序自回归特征主导。一阶滞后特征 `water_level_lag_1` 贡献率达 26.1%，揭示了目标变量强烈的记忆效应与物理系统的演化连续性；`lag_2` 与 `lag_24` 则验证了多尺度相关性及日循环规律。极值与波动率指标对脉冲信号捕捉至关重要，`water_level_roll_3_max` (10.4%)解释了模型拟合突发波动的机理，而 `roll_3_std` 的入选反映了变化速率在识别系统突变中的统计意义。外部驱动中，月份特征 `month` (8.9%)捕捉了季节性基流差异，提升了长序列预测的稳健性。降雨特征中，`Rainfall_roll_24_std` 贡献高于均值，体现了系统对降雨强度的瞬时响应特征。此外，通过三角函数编码 `hour_cos` 与 `hour_sin` 保证了日内时序的连续性，有效消除了零点数值突变的影响，优化了对昼夜波动的模拟效果。

3.2.3. SHAP 蜂群图

结合 SHAP 的蜂群图进一步分析特征对模型预测的影响作用，如图 4 所示。从整体分布来看，模型表现出明显的非线性响应和长尾效应，即极少数极端特征值对模型输出产生了巨大的推动作用，这与时序数据中的脉冲式波动特征高度吻合。

在特征影响方向分析中，`water_level_roll_3_max` 表现出明确的正向触发机制。当该特征取高值时，SHAP 值显著大于 0.8，表明近 3 小时内的水位峰值对预测具有强烈的正向拉升作用。这种非对称分布特性不仅提升了模型捕捉瞬时洪峰的灵敏度，也保障了平稳期的监测稳定性。一阶滞后特征 `water_level_lag_1` 呈现持续的线性增强效应，构成了模型预测的逻辑基准；而 `water_level_lag_2` 在低值时的负向修正作用，则反映了系统的均值回归特性，有效防止了预测轨迹偏离。此外，环境因子与降水特征具备显著的边际效应。月份特征依据季节周期对预测值进行双向平移修正；降水波动特征 `Rainfall_roll_6_std` 虽总体权重居中，但其高值点对输出具有明显的滞后触发作用，体现了系统对剧烈降水脉冲的响应逻辑。

3.2.4. 可视化结果分析

实验结果表明，各模型性能的差异主要源于算法机理、特征表征能力以及计算效率要求的深度耦合。LightGBM 模型在测试集纳什效率系数达到 0.9887，均方根误差指标亦展现出优于深度学习模型的稳健性。这一性能优势首先可归因于底层算法构建原理的差异。LightGBM 依托基于直方图算法的决策树构建策略，通过贪婪搜索在特征空间中快速建立局部非线性决策边界，对于捕捉降雨驱动下的水位突发脉冲

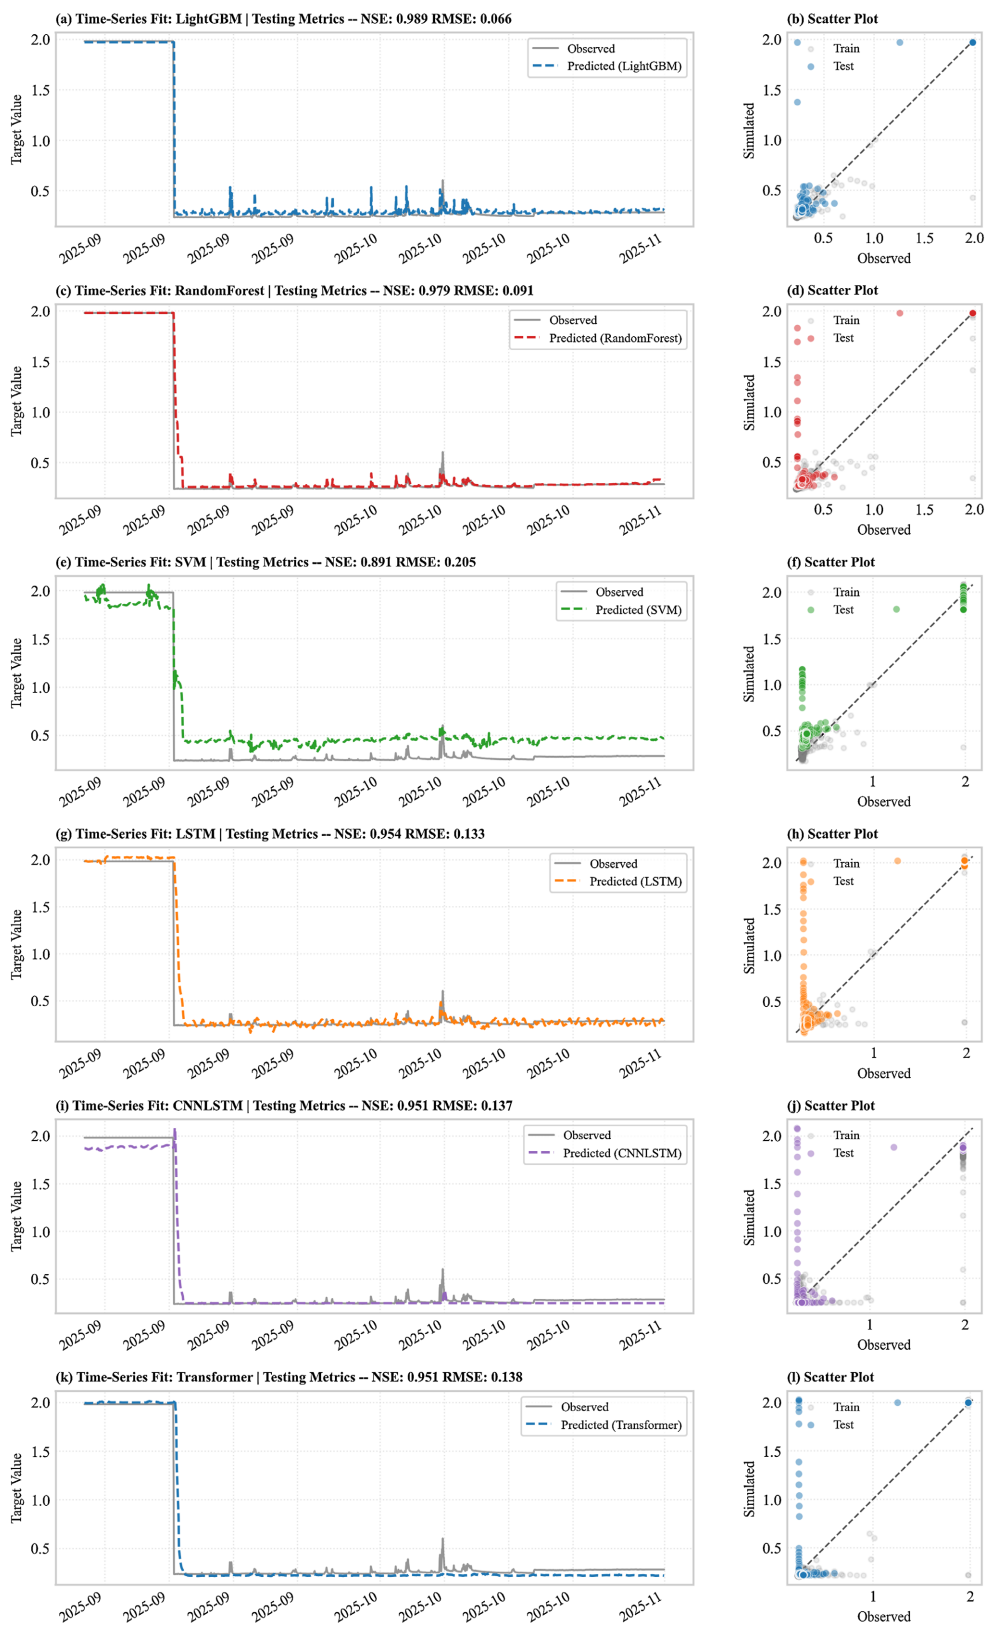


Figure 2. Fitted curve plot and scatter plot
图 2. 拟合曲线图和散点图

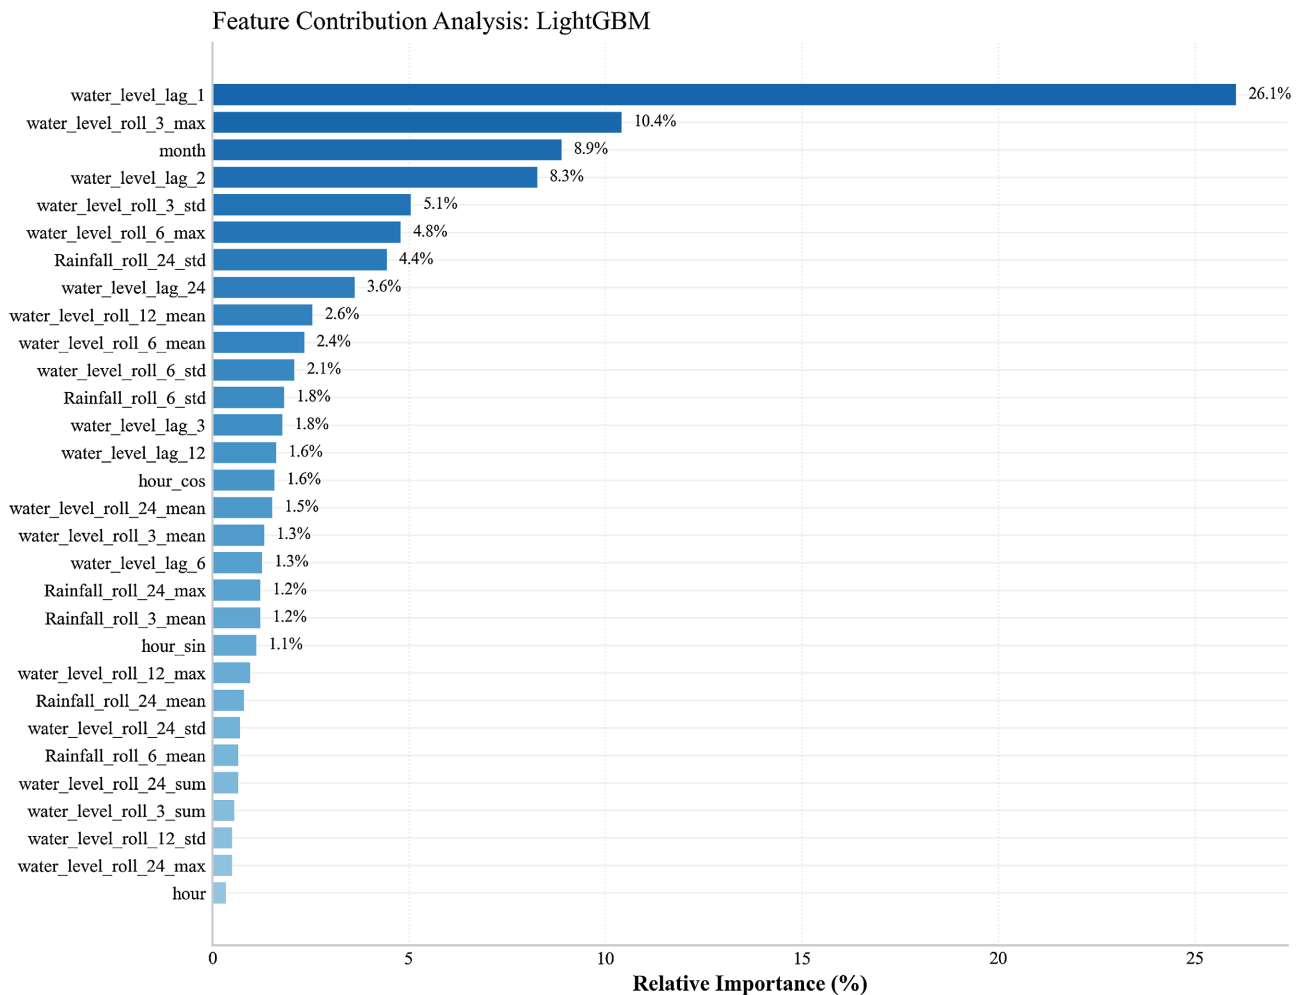


Figure 3. Ranking of feature importance in LightGBM

图 3. LightGBM 特征重要性排序

信号具有更强的灵敏度。相比之下，以 LSTM 和 Transformer 为代表的深度学习模型虽具备强大的自动特征表征潜力，但其依赖梯度的反向传播机制在处理含有剧烈噪声与脉冲特征的非平稳时序数据时，易受局部扰动影响，且受限于当前感知数据规模，其泛化深度受到制约。

性能差异的深层逻辑进一步指向数据特性与样本规模的限制。从学习理论视角分析，深度学习模型的性能优势通常建立在大规模数据集之上，而现阶段城市基础设施监测数据呈现出明显的中小规模时序特征。在现有样本尺度下，深度学习模型的高维参数空间难以得到充分训练，导致其特征提取潜力被抑制，极易产生过拟合现象。与之形成鲜明对比，以 LightGBM 为代表的集成学习模型具备更强的归纳偏置，通过树结构的迭代累加，能够更高效地在有限样本中提取鲁棒的决策规则。

本研究设计的结构化特征工程是实现模型性能跨越的核心因素。在实际感知环境下，模型难以仅凭原始序列自动挖掘出长程季节先验与短期极值扰动间的物理关联。通过引入防泄露滚动统计与二十四节气三角变换，本研究将水文物理规律显式化，有效地弥补了小样本背景下表征学习的缺失。这些结构化特征直接映射了排水系统的响应机理，显著降低了算法的学习代价。相比之下，深度学习模型尝试通过隐藏层权重拟合复杂的移动平均或极值检测逻辑，其学习效率在感知维度受限且含有测量误差的环境下表现出明显的瓶颈，拟合精度难以超越经过物理机理干预的集成学习算法。




Figure 4. Beeswarm plot of SHAP values for LightGBM

图 4. LightGBM SHAP 蜂群图

在计算开销与部署时效维度，LightGBM 表现出显著的轻量化优势。得益于带深度限制的叶子生长策略，该模型在保障预报精度的同时，实现了毫秒级推理时效，与智慧城市实时预警的高时效需求高度契合。综上所述，LightGBM 通过融合结构化机理特征与高效树集成架构，在预测精度、泛化稳健性及计算效率间实现了最优平衡，为复杂动态环境下的实时防灾减灾提供了坚实的算法支撑。

4. 总结

针对城市中心城区内涝防治的技术瓶颈，本研究构建并验证了一套基于异构数据驱动架构的水位预测体系。研究确立了全局绝对对齐的数据治理协议，并提出了融入水文机理特征的启发式特征工程。实验证实，该体系在预测精度与实时响应时效上均表现出显著优势，为复杂动态环境下的城市水位预报提

供了可靠的技术支撑。

本研究揭示了数据驱动范式在智慧排水领域的应用价值。与高度依赖排水管网物理属性刻画的传统机理模型相比,数据驱动模型采用结果导向的学习范式,通过对历史实测数据的反演学习,将管网阻力、渗漏及淤积等复杂物理属性隐式编码于模型参数中。这种建模方式有效缓解了物理建模中因下垫面环境剧烈波动导致的参数不确定性问题,展现出极强的技术适应性,特别适用于监测数据较为密集的中心城区。

机理启发式的特征设计被证实是提升模型泛化能力的科学途径。通过引入二十四节气变量,模型成功获取了地表辐射能量变化与季节性季风方向的先验背景。这种将水文气候常识转化为数理特征的策略,使算法能够根据季节周期自动调节对降雨波动的响应敏感度,有效地弥补了小样本背景下表征学习的不足。目前,相关算法已成功集成至城市智慧排水监测预警平台,作为风险评估与工程调度的核心组件投入运行,为超大城市内涝灾害的精细化治理提供了量化依据与技术范式。

尽管本研究在拟合精度与推理稳健性上取得了预期成果,但在极端灾害预测与空间关联性挖掘方面仍具提升空间。由于历史数据中超常规暴雨样本较为稀缺,模型在应对极端长尾事件时的外推能力仍需进一步验证。未来研究将探索引入物理信息神经网络以强化物理约束,并计划利用图卷积神经网络构建管网拓扑模型,以捕获水位在空间上的传导规律。随着感知网络的深度加密与数模耦合技术的成熟,该研究框架有望在韧性城市建设与智慧水务决策中发挥更广泛的示范作用。

参考文献

- [1] Wang, Q., Tang, M. and Shi, P. (2025) Depth Prediction of Urban Waterlogging Based on BiTCN-GRU Modeling. *PLOS One*, **20**, e0321637. <https://doi.org/10.1371/journal.pone.0321637>
- [2] Fu, S., Schultz, D.M., Lyu, H., Zheng, Z. and Zhang, C. (2025) Creating a National Urban Flood Dataset for China from News Texts (2000-2022) at the County Level. *Hydrology and Earth System Sciences*, **29**, 767-783. <https://doi.org/10.5194/hess-29-767-2025>
- [3] Deng, Y. and Lu, X. (2026) Explainable Machine Learning-Based Urban Waterlogging Prediction Framework. *Urban Science*, **10**, Article 156. <https://doi.org/10.3390/urbansci10030156>
- [4] Fan, Z., Zhang, J., Chen, Y. and Xu, H. (2025) Urban Flood Prediction Model Based on Transformer-LSTM-Sparrow Search Algorithm. *Water*, **17**, Article 1404. <https://doi.org/10.3390/w17091404>
- [5] Hu, Y., Tang, M., Ma, S., Zhu, Z., Zhou, Q., Xie, Q., et al. (2025) A Rapid Prediction Method for Key Information of the Urban Flood Control Engineering System Based on Machine Learning: An Empirical Study of the Wusha River Basin. *Water*, **17**, Article 784. <https://doi.org/10.3390/w17060784>
- [6] Santiago-Collazo, F., Bayer, L., Vilorio, O., Cardenas, L. and Bilskie, M. (2023) SWMM Model Limitations Report. University of Georgia's College of Engineering. <https://www.thempc.org/docs/lit/CoreMpo/Studies/Ufm/2023/FMT-2023-08-31-SWMM-LimitationsReport.pdf>
- [7] Zhang, T., Zhu, T., Gao, K., Zhou, W. and Yu, P.S. (2023) Balancing Learning Model Privacy, Fairness, and Accuracy with Early Stopping Criteria. *IEEE Transactions on Neural Networks and Learning Systems*, **34**, 5557-5569. <https://doi.org/10.1109/tnnls.2021.3129592>
- [8] Zhu, Z., Wu, G., Gu, Y., Huang, J., Chen, Z. and Lu, H. (2024) Time-Varying Discrete Cosine Transform Based on Shaping Regularization and Its Application in Seismic Data Analysis. *Journal of Geophysics and Engineering*, **21**, 496-506. <https://doi.org/10.1093/jge/gxae016>
- [9] Li, J.F., Lu, Z.Y., Xu, C., and Zhang, W.X. (2024) Analysis of Geographical Origin of Solar Terms Based on the STTMD Method. *Scientific Reports*, **14**, Article No. 22708. <https://doi.org/10.1038/s41598-024-73740-x>
- [10] Álvarez-Estrella, J., Muñoz, P., Bendix, J., Contreras, P. and Céleri, R. (2024) Enhancing Peak Runoff Forecasting through Feature Engineering Applied to X-Band Radar Data. *Water*, **16**, Article 968. <https://doi.org/10.3390/w16070968>
- [11] Hodson, T.O. (2022) Root-Mean-Square Error (RMSE) or Mean Absolute Error (MAE): When to Use Them or Not. *Geoscientific Model Development*, **15**, 5481-5487. <https://doi.org/10.5194/gmd-15-5481-2022>