

耦合无迹卡尔曼滤波的城市排水系统 实时控制方法研究

陈 阳¹, 王珠桥¹, 郭宇超²

(1. 广州珠科院工程勘察设计有限公司, 广州 510630; 2. 达拉特旗水利事业发展中心, 内蒙古 鄂尔多斯 014399)

摘 要: 模型预测控制 (MPC) 已越来越多地应用于城市排水系统中闸泵的协同调控, 以最大化利用现有调蓄能力以缓解内涝风险。然而, 利用观测数据提升模型预测性能的研究仍然有限。在此背景下, 如何对城市排水系统状态进行精准预测, 得到可靠的排水系统控制策略以减轻极端降雨事件的负面影响显得至关重要。提出一种新型模型预测控制框架, 即无迹卡尔曼滤波的模型预测控制 (UKF-MPC) 方法, 该框架耦合了无迹卡尔曼滤波 (UKF) 和模型预测控制 (MPC) 方法, 通过动态误差校正机制提升预测的整体精度, 并在福州市斗门区域进行应用研究。结果表明, UKF-MPC 通过动态融合观测信息与模型预测输出, 相对性能指数 (RIP) 的均值达 36.4%。与传统 MPC 方法相比, UKF-MPC 所得控制策略在不确定环境下具有更好的适用性与稳健性。

关键词: 模型预测控制; 无迹卡尔曼滤波; 城市内涝; 数据同化

中图分类号: TU992

文献标志码: A

文章编号: 1001-5485(2026)06-0198-08

Real-time Control Method for Urban Drainage Systems Based on Coupled Unscented Kalman Filter

CHEN Yang¹, WANG Zhu-qiao¹, GUO Yu-chao²

(1. Guangzhou Zhuke Institute of Engineering Survey and Design Co., Ltd., Guangzhou 510630, China;

2. Dalate Banner Water Utilities Development Centre, Ordos 014399, China)

Abstract: [Objective] Model Predictive Control (MPC) has been increasingly applied to the coordinated regulation of sluices and pumps in urban drainage systems to maximize the utilization of existing storage capacity and mitigate waterlogging risks. However, research on leveraging observational data to improve model prediction performance remains limited. This study focuses on measurement uncertainty in real-time control of urban drainage systems and proposes an Unscented Kalman Filter-based Model Predictive Control (UKF-MPC) method to enhance system adaptability under complex conditions. [Methods] By integrating model predictions with sensor observations, the proposed method incorporates data assimilation into the error feedback strategy and state update of the MPC prediction model, establishing a real-time data-driven MPC framework. The approach was validated in the Doumen area of Fuzhou City. [Results] (1) UKF-MPC significantly improved flow prediction accuracy by dynamically fusing observational information with model outputs, increasing the Nash-Sutcliffe Efficiency (NSE) from 0.39–0.58 to 0.56–0.79, with a mean Relative Improvement Percentage (RIP) of 36.4%. (2) Through data assimilation, the method upgraded traditional error feedback to state-space correction. Under 50-year and 100-year return period storm scenarios, UKF-MPC consistently generated more robust control strategies, enhancing system adaptability in complex environments and providing a framework capable of real-time system state perception and dynamic control optimization. [Conclusions] Compared with conventional MPC, the control strategies derived from UKF-MPC exhibit superior applicability and robustness under uncertain conditions. Future research will quantitatively analyze the influence of UKF parameter settings on correction performance and conduct systematic validation across multiple watersheds and diverse rainfall events using richer observational data, to further clarify the applicability boundaries

and parameter sensitivity mechanisms of UKF-MPC. On this basis, further exploration will focus on incorporating state covariance information directly into the optimization problem to develop a risk-aware model predictive control method.

Key words: model predictive control; unscented Kalman filter; urban waterlogging; data assimilation

0 引言

在全球气候变化与快速城市化进程交织的背景下,极端降雨事件频发、强度增大,城市内涝风险日益加剧,严重威胁人民生命财产安全和城市正常运行^[1-2]。构建宜居、韧性与智慧的城市,提升城市排水系统应急管理水平成为了迫切需求。然而,城市排水系统是一个高度复杂、时变且充满不确定性的系统,为其制定高效控制策略一直是领域内的巨大挑战^[3-4]。

近年来,模型预测控制(Model Predictive Control, MPC)因其能够处理多变量约束、进行误差反馈并结合滚动优化机制等优势,被逐步应用于排水系统闸、泵的协同调控中,以最大程度地利用现有调蓄空间,减轻内涝风险^[5-6]。经典的 MPC 框架包含 3 个核心组成部分:预测模型、滚动优化策略和误差反馈策略^[7]。其中,误差反馈环节是 MPC 区别于传统优化算法的关键模块,通过实时观测值与模型预测值之间的偏差,对后续预测进行校正,从而赋予控制器应对不确定性的能力^[8-9]。然而,误差反馈机制多依赖于预测误差法(Prediction Error Method, PEM),如自回归模型、移动平均模型和自回归-移动平均模型等,对于系统存在的多重不确定性处理能力有限^[10],直接导致传统 MPC 在复杂现实环境下的控制性能受到影响。为降低不确定性对控制策略的负面影响,诸多学者对模型参数、降雨预报精度及其预见期等不确定性对排水系统的影响进行了深入研究,提出了多种应对策略,如通过最小化合流制溢流(Combined Sewer Overflow, CSO)预期风险削减溢流体积^[11]、采用机会约束随机模型预测控制或开发鲁棒模型预测控制降低不确定性的影响^[4,12]等,但是目前在如何充分利用观测数据以提高模型预测效果方面的研究成果仍较少。

城市排水系统实时控制中不确定性主要包括了模型输入不确定性、模型结构不确定性、参数不确定性及量测不确定性。本研究聚焦于量测不确定性,即传感器设备固有的噪声和误差,直接测量数据作为模型初始状态,可能会引入震荡和不稳定的控制行为。因此,本文提出一种基于无迹卡尔曼滤波的模型预测控制(Unscented Kalman Filter-Model Pre-

dictive Control, UKF-MPC)方法,通过融合模型预测数据与传感器观测数据,并将其应用于 MPC 的误差反馈策略与预测模型状态更新中,以增强城市排水系统在复杂环境下的适应性。

1 基于实时数据同化的模型预测控制方法

本研究的控制对象为研究区内调蓄池配套的 5 台水泵。通过优化水泵的启停时序,实现对调蓄池排水过程的动态调控,从而降低区域内涝风险。为实现上述目标,提出了一种基于无迹卡尔曼滤波的模型预测控制方法,包含 5 个部分:

(1) 预测模型,旨在预测未来系统状态。

(2) 滚动优化,一种在连续时间窗口内进行迭代优化的方法,通过在每个时间步长重新计算决策方案来生成基于当前状态和未来预测的最优控制策略。

(3) 优化模型,用于优化闸泵等控制工程的动作。

(4) 误差反馈,通过计算本次滚动优化中的预测误差并将其作用于下一次滚动优化中以减小预测误差。

(5) UKF,通过传感器数据(观测状态)实时校正模型预测的偏差,校正后的状态作为模型初始状态并用于误差反馈模块,使 MPC 能够基于更接近现实的状态进行未来控制动作的优化,从而降低排水系统控制策略失控风险。

UKF-MPC 流程如图 1 所示。




图1 UKF-MPC 流程示意图

Fig.1 Flowchart of UKF-MPC

1.1 预测模型

在城市排水系统的实时控制中,调控策略的有

效性高度依赖于对未来系统状态的准确预测。因此,本文采用基于水箱水平衡模型(the Water Tank-Water Balance Model, TWBM)作为城市排水系统预测模型,模型结构如图 2 所示。降雨首先进入第一层水箱,即溢流层。假定降雨只能通过检查井流入排水系统,检查井充满后则无法继续流入。其目的是模拟由于排水管网充满,无法通过排水系统排出而积聚在地面的积水。第二层和第三层水箱为排水层,旨在模拟通过流域内排水系统下游排水口流出过程。水箱的蓄水量由上层水箱的入流量和本层水箱底孔和侧孔的出流量决定。水箱的排水过程由第二层和第三层水箱侧孔的排水过程决定。第一层水箱代表整个地表空间,其剩余水量代表溢流量,第二层和第三层水箱代表整个排水系统内部空间,剩余总水量代表排水系统的储水量。TWBM 在满足精度的同时具有更高的计算效率,模型结构采用的模型验证及详细原理见以往研究成果^[5]。




图 2 水箱模型结构

Fig.2 Tank model structure

在 UKF-MPC 框架中,预测模型输出包括以下 2 种:

(1) 研究区溢流量。即第一层水箱的溢流累积过程,表征无法经管网系统排出而漫溢至地表的涝水量,是评估区域内涝风险的核心指标,直接用于优化模型的目标函数中。

(2) 下游排口出流流量。即第二层和第三层水箱的侧孔出流总量,反映排水系统向受纳水体(洋下河)的排水能力,用于判断排河条件、计算调蓄池入流过程,并为水泵启停控制提供边界输入。

1.2 优化模型

在本文所提的模型预测控制框架中,优化模型的决策变量为调蓄池配套水泵的启停状态。研究区

调蓄池共配备 5 台水泵,单台水泵额定流量为 $0.58 \text{ m}^3/\text{s}$,决策变量定义为一个五维离散向量,在每一优化时步中,通过差分进化算法对水泵的组合启停状态进行寻优,以实现综合效益最优。

1.2.1 目标函数

研究区内调蓄池的主要功能是存储无法及时排出的涝水。本文对模型预测控制中的优化模型制定了以下优化目标,以降低区域溢流风险,实现综合效益最优:

(1) 调蓄池的峰值水位最小,旨在充分利用调蓄池的调蓄空间,即

$$J_1 = \min(h_{\text{peak_level}}) \quad (1)$$

式中: J_1 为最小的调蓄池峰值水位; $h_{\text{peak_level}}$ 为 t 时刻调蓄池峰值水位。

(2) 调度末时刻的水位不超过目标水位,确保调度结束后为下一场降雨预留充足调蓄空间,即

$$J_2 = \min(h_{\text{end_level}}) \quad (2)$$

式中: J_2 为最小的调度期结束时刻调蓄池水位; $h_{\text{end_level}}$ 为调度期结束时刻调蓄池水位。

(3) 研究区溢流量最小,以反映内涝风险的控制效果,即

$$J_3 = \min\left(\sum_{t=0}^n v_{\text{flood}}\right) \quad (3)$$

式中: J_3 为最小的调度期内研究区域总溢流量; v_{flood} 为调度期内研究区域总溢流量。

(4) 能耗最低,通过减少不必要的启泵次数,降低运行成本,即

$$J_4 = \min\left(\sum_{t=1}^T N_t\right) \quad (4)$$

式中: J_4 为最低能耗; N_t 为 t 时刻运行的水泵数量,以水泵运行数量及时间代表能耗。

1.2.2 约束条件

(1) 水位约束:

$$h_{\min} < h < h_{\max} \quad (5)$$

式中: h 为调蓄池水位; $h_{\min}$ 和 $h_{\max}$ 为调蓄池下限和上限水位。 $h_{\min} = -22.8 \text{ m}$, $h_{\max} = -8.15 \text{ m}$ 。

(2) 流量约束:

$$Q_n^{\min} < Q_{n,t} < Q_n^{\max} \quad (6)$$

式中: $Q_{n,t}$ 为第 n 台水泵 t 时刻的流量; $Q_n^{\min}$ 和 $Q_n^{\max}$ 为第 n 台水泵的下限和上限流量,取 $Q_n^{\min} = 0 \text{ m}^3/\text{s}$ 和 $Q_n^{\max} = 0.58 \text{ m}^3/\text{s}$ 。

1.2.3 优化求解器

本文通过构建惩罚函数方式将多目标转化为单目标问题,并利用差分进化(Differential Evolution, DE)算法^[13-14]进行求解。具体表述如下:

$$\min J = \min \{ \alpha_1 (J_1 - J_1^{\text{obj}}) + \alpha_2 (J_2 - J_2^{\text{obj}}) + \alpha_3 J_3 + \alpha_4 J_4 \} \quad (7)$$

式中: J 为总目标函数值; J_1^{obj} 、 J_2^{obj} 分别为 J_1 、 J_2 的期望目标值; α_1 、 α_2 、 α_3 、 α_4 为判别目标重要性的权重, 这些权重是为了明确 J_1 、 J_2 、 J_3 、 J_4 的优先级, α_1 、 α_2 、 α_3 、 α_4 分别为 1 000、10、1 000、100。

1.3 滚动优化策略

优化模型中每次求解优化问题后所得的最优控制动作序列并不会完全执行, 而是仅执行第一个时间步长的决策, 随后在下一个时间步长进行新一轮的优化求解。这个过程通常被称为滚动时域优化 (Receding Horizon Approach, RHA)。

MPC 采用了时间向前滚动式有限时域优化策略。这种策略不同于传统优化调度中使用固定全局优化目标并一次性执行的方式。MPC 的优化过程是在线、反复进行的, 滚动时域优化机制确保了在每次优化中能够利用误差反馈策略降低预测误差, 从而更加准确地调整控制策略。此外, 该机制还充分利用了水情监测信息, 实时指导调度决策的执行。

1.4 基于 UKF 的预测模型初始状态更新

UKF 通过确定性采样策略实现不确定性的表征与传播, 在预测步, 上一时刻的后验协方差通过非线性状态转移函数传播生成预测状态的 Sigma 点集及其协方差, 本质上是将输入不确定性向前传播至下一时刻。在更新步, 预测协方差与观测协方差共同决定卡尔曼增益, 实现了量测信息对模型预测的加权融合, 从而降低状态估计的不确定性, 同时将其作为预测模型的新状态以提高预测精度。

1.4.1 无迹卡尔曼滤波原理

无迹卡尔曼滤波是一种非线性状态估计方法^[15], 可在不需要线性化的情况下有效处理非线性问题。UKF 算法具体步骤如下^[16]:

UKF 中状态方程和观测方程分别为:

$$\mathbf{x}_{k+1} = f(\mathbf{x}_k, u_k, \theta) + w_k \quad (8)$$

$$\mathbf{y}_k = h(\mathbf{x}_k, u_k, \theta) + v_k \quad (9)$$

式中: $f(\mathbf{x}_k, u_k, \theta)$ 为预测模型内部蓄水量变化响应函数; $\mathbf{y}_k$ 为第 k 步观测流量; $h(\mathbf{x}_k, u_k, \theta)$ 为预测模型的响应函数; $\mathbf{x}_k$ 、 $\mathbf{x}_{k+1}$ 均为预测模型内部状态, 如水箱蓄水量; u_k 为预测模型输入, 如降雨; θ 为预测模型参数; w_k 和 v_k 为过程噪声和测量噪声协方差。

1.4.1.1 预测

(1) 以对称采样策略生成 Sigma 点及相应的权重。

$$\mathbf{X}_{0,k} = \mathbf{x}_k \quad (10)$$

$$\mathbf{X}_{i,k} = \mathbf{x}_k + [\sqrt{(n+\gamma) \mathbf{P}_k}]_i, \quad i = 1, 2, \dots, n \quad (11)$$

$$\mathbf{X}_{i,k} = \mathbf{x}_k - [\sqrt{(n+\gamma) \mathbf{P}_k}]_i, \quad i = n+1, n+2, \dots, 2n \quad (12)$$

$$\omega_0^m = \frac{\gamma}{n+\gamma} \quad (13)$$

$$\omega_0^c = \frac{\gamma}{n+\gamma} + 1 - \alpha^2 + \beta \quad (14)$$

$$\omega_i^m = \omega_i^c = \frac{1}{2(n+\gamma)}, \quad i = 1, 2, \dots, n \quad (15)$$

式中: $\mathbf{X}_{0,k}$ 为初始状态均值; $\mathbf{X}_{i,k}$ 为第 i 个状态均值; ω_i^m 和 ω_i^c 为 Sigma 点的均值与协方差的权重; n 为状态向量的维数; ω_0^c 为协方差的初始权重; ω_0^m 为均值的初始权重; $\gamma = \alpha^2(n+k) - n$ 为比例参数, α 为很小的正数, 一般取值 $10^{-4} \leq \alpha \leq 1$; $\mathbf{P}_k$ 为状态协方差矩阵; $[\sqrt{(n+\gamma) \mathbf{P}_k}]_i$ 为矩阵 $(n+\gamma) \mathbf{P}_k$ 进行 Cholesky 分解得到下三角矩阵中的第 i 列向量。

(2) 计算第 $k+1$ 步的预测 Sigma 点 $\mathbf{X}_{i,k+1}^-$ 。

$$\mathbf{X}_{i,k+1}^- = \mathbf{X}_{i,k}^- \quad (16)$$

式中 $\mathbf{X}_{i,k}^-$ 为第 k 步的预测 Sigma 点。

(3) 计算第 $k+1$ 步的系统状态均值 $\hat{\mathbf{x}}_{k+1}^-$ 和协方差 $\mathbf{P}_{k+1}^-$, 即:

$$\hat{\mathbf{x}}_{k+1}^- = \sum_{i=0}^{2n} \omega_i^m \mathbf{X}_{i,k+1}^- \quad (17)$$

$$\mathbf{P}_{k+1}^- = \sum_{i=0}^{2n} \omega_i^c (\mathbf{X}_{i,k+1}^- - \hat{\mathbf{x}}_{k+1}^-) (\mathbf{X}_{i,k+1}^- - \hat{\mathbf{x}}_{k+1}^-)^T + \mathbf{Q}_k \quad (18)$$

式中: $\hat{\mathbf{x}}_{k+1}^-$ 为第 $k+1$ 步状态预测均值; $\mathbf{Q}_k$ 为系统过程噪声协方差。

1.4.1.2 更新

(1) 计算观测向量 Sigma 点 $\mathbf{Y}_{i,k+1}^-$ 。

$$\mathbf{Y}_{i,k+1}^- = h(\mathbf{X}_{i,k+1}^-) \quad (19)$$

式中 $h(\cdot)$ 为预测模型的响应函数。

(2) 计算第 $k+1$ 步观测流量的均值 $\hat{\mathbf{y}}_{k+1}^-$ 和协方差 $\mathbf{P}_{k+1}^+$ 。

$$\hat{\mathbf{y}}_{k+1}^- = \sum_{i=0}^{2n} \omega_i^m \mathbf{Y}_{i,k+1}^- \quad (20)$$

$$\mathbf{P}_{k+1}^+ = \sum_{i=0}^{2n} \omega_i^c (\mathbf{Y}_{i,k+1}^- - \hat{\mathbf{y}}_{k+1}^-) (\mathbf{Y}_{i,k+1}^- - \hat{\mathbf{y}}_{k+1}^-)^T + \mathbf{R}_{k+1} \quad (21)$$

式中: $\mathbf{Y}_{i,k+1}^-$ 为观测向量 Sigma 点; $\mathbf{R}_{k+1}$ 为测量噪声协方差矩阵; $\hat{\mathbf{y}}_{k+1}^-$ 为第 $k+1$ 步观测流量的均值。

(3) 更新第 $k+1$ 步系统状态估计的均值 $\hat{\mathbf{x}}_{k+1}^-$ 和协方差 $\mathbf{P}_{k+1}$ 。

$$\hat{\mathbf{x}}_{k+1}^- = \hat{\mathbf{x}}_{k+1}^- + \mathbf{K}_{k+1} (\mathbf{y}_{k+1}^- - \hat{\mathbf{y}}_{k+1}^-) \quad (22)$$

$$\mathbf{P}_{k+1} = \mathbf{P}_{k+1}^- + \mathbf{K}_{k+1} (\mathbf{P}_{yy,k+1}^- - \mathbf{K}_{k+1}^T) \quad (23)$$

式中: $\mathbf{K}_{k+1}$ 为卡尔曼滤波的增益矩阵; $\mathbf{y}_{k+1}^-$ 为观测流量; $\mathbf{P}_{yy,k+1}^-$ 为观测向量协方差矩阵。

$\mathbf{K}_{k+1}$ 、 $\mathbf{P}_{xy,k+1}^-$ 可分别表示为:

$$\mathbf{K}_{k+1} = \mathbf{P}_{xy,k+1}^- (\mathbf{P}_{yy,k+1}^-)^{-1}, \quad (24)$$

$$\mathbf{P}_{xy,k+1}^- = \sum_{i=0}^{2n} \omega_i^c (\mathbf{X}_{i,k+1}^- - \hat{\mathbf{x}}_{k+1}^-) (\mathbf{Y}_{i,k+1}^- - \hat{\mathbf{y}}_{k+1}^-)^T. \quad (25)$$

式中 $\mathbf{P}_{xy,k+1}^-$ 为状态和观测向量的交互协方差矩阵。

1.4.2 预测模型状态更新

UKF-MPC 框架中, UKF 与 MPC 的耦合通过状态空间校正实现。在每个控制时域, UKF 利用实时观测数据更新系统状态, 输出后验状态均值和协方差矩阵, 其中, 状态均值作为当前时刻系统状态的最优估计, 并直接作为 TWBM 在本时域进行滚动预测的初始状态。协方差矩阵主要作用于 UKF 的内部增益计算, 通过调节模型预测与观测数据的权重, 确保了状态均值的估计精度, 即通过 UKF 提升状态估计的准确性, 从而间接增强 MPC 在复杂环境下的稳健性。

1.5 误差反馈策略

为了减少预测误差的影响, 误差反馈策略将每次滚动优化中第一个步长预测结果与实时监测数据进行比较, 将本次滚动优化计算得到的预测误差传递到下次滚动优化中, 以便采取相应的纠正措施, 进一步提高预报精度。误差反馈机制表述如下:

$$\beta = \frac{Q_t - Q_t^m}{Q_t^m}, \quad (26)$$

$$Q_{t+1}^c = (1 + \beta) Q_{t+1}^m. \quad (27)$$

式中: Q_t 为 t 时刻融合传感器观测数据与模型预测后的入流; Q_t^m 为 t 时刻的预测入流; Q_{t+1}^m 为 $t+1$ 时刻的预测入流; Q_{t+1}^c 为 $t+1$ 时刻的修正入流。

2 案例研究与应用

2.1 研究区域概况及 MPC 参数设置

研究区是位于福州市面积为 3.64 km^2 的城市排水片区, 包括雨水排水系统和调蓄池。排水管网包括 1 335 条管道、1 324 个检查井, 斗门调蓄池总容积 16 万 m^3 , 配备 5 台流量为 $2 100 \text{ m}^3/\text{h}$ 的排水泵, 主要用于雨水收集和管理。在降雨过程中, 研究区的雨水通过检查井经排水管道流入洋下河。在强降雨或台风期间洋下河水位超过警戒水位时, 河水顶托导致斗门地区排水困难, 容易出现大面积内涝, 此时关闭洋下河沿线排口, 启用调蓄池将研究区的涝

水储存起来, 缓解该地区的排涝压力。当洋下河水位降低后, 开启洋下河沿线排口, 同时开启调蓄池水泵排水, 为下一次降雨腾出调蓄空间。

本研究基于 JAVA 语言实现了 UKF-MPC 算法; 差分进化算法中种群规模取值为 100, 交叉概率为 0.4, 变异概率为 0.1, 迭代次数 1 000; UKF 中 $a = 0.001$, $\beta = 2$, $k = 3 - n$ ($n = 1$), 过程噪声协方差矩阵通过降雨事件率定确定, 测量噪声协方差矩阵基于传感器标定误差并采用自适应缩放策略动态计算确定; 硬件环境采用 Intel Core i5-13400F CPU (2.50 GHz)、32 GB RAM、512 GB NVMe SSD + 4 TB HDD 存储及 NVIDIA GeForce GTX 1660 SUPER (6 GB) 显卡。

2.2 预测模型验证

本文采用的预测模型, 其拓扑结构、模型参数及率定过程已在先前研究中^[5]详细阐述并验证。鉴于本文沿用相同的模型结构与区域数据, 故直接采用已率定参数集。模型精度验证采用的降雨事件见表 1 及验证结果见表 2。

表 1 降雨事件信息

Table 1 Investigated storm events

序号	降雨事件发生时间	降雨历时/h	降雨量/mm
1	2021-08-01	73.6	287.2
2	2022-05-26	9.8	32.4
3	2022-06-02	7.4	41.4
4	2022-06-06	7.6	72.7
5	2022-06-09	8.8	67.9
6	2021-05-24	5.7	43.3
7	2021-05-30	6.8	33.6

表 2 预测模型精度验证

Table 2 Validation of prediction model accuracy

类型	降雨事件发生时间	水量误差	NSE
排口出流	2021-08-01	0.013 4	0.967 9
	2022-05-26	0.064 4	0.812 5
	2022-06-02	0.048 5	0.921 2
	2022-06-06	0.009 3	0.895 2
	2022-06-09	0.024 3	0.965 7
	2021-05-24	0.065 3	0.792 7
	2021-05-30	0.091 2	0.882 0
区域溢流	2021-08-01	0.085 9	0.644 9
	2022-05-26	0.143 5	0.680 0
	2022-06-02	0.009 4	0.790 5
	2022-06-06	0.195 2	0.766 2
	2022-06-09	0.199 4	0.701 5
	2021-05-24	0.005 8	0.623 4
	2021-05-30	0.138 2	0.655 2

注: NSE 为纳什效率系数 (Nash-Sutcliffe Efficiency Coefficient)。

2.3 不确定性条件下城市排水系统控制策略研究

2.3.1 案例设置

(1) 方案 1。方案 1 设置 2 个场景 (表 3), 采用 SWMM 计算研究区排口总出流量作为真实流量过程, 并在其基础上随机生成 1 000 组含噪声的流量数据 (相对误差在 $-20\% \sim 20\%$ 以内); 场景 1 采用

TWBM 计算 100 a 一遇降雨下流量过程;场景 2 采用 TWBM 计算 100 a 一遇降雨下流量过程,并采用基于 UKF 的误差反馈策略对预报结果进行修正。通过场景 1 与场景 2 结果对比,分析所提策略对模型预报精度的提升效果。

表 3 方案 1 场景设置

Table 3 Setup of scenario 1

场景	模型输入	模型	修正方法
场景 1	100 a 一遇降雨	TWBM	
场景 2	100 a 一遇降雨观测流量(含噪声)	TWBM	UKF

(2)方案 2。方案 2 设置 2 个场景(表 4),场景 1 采用传统 MPC 方法得到控制策略,场景 2 采用 UKF-MPC 得到控制策略,通过对比分析场景 1 和场景 2 控制策略风险,分析 UKF-MPC 较传统 MPC 在应对模型预测不确定性的能力提升效果。

表 4 方案 2 场景设置

Table 4 Setup of scenario 2

场景	模型输入	调控方法	求解器
场景 1	50、100 a 一遇降雨、观测流量(含噪声)	传统 MPC	DE
场景 2	50、100 a 一遇降雨、观测流量(含噪声)	UKF-MPC	DE

2.3.2 随机模拟流量

为模拟真实工况下传感器观测数据存在的量测不确定性,本研究采用 SWMM 计算研究区排水系统在 100 a 一遇降雨下的研究区排口总出流量作为“真实流量”。在此基础上,通过叠加随机噪声生成含噪声的“观测流量”序列,用于模拟实际工程中流量监测设备的测量值。该含噪声观测数据作为 UKF 数据同化模块的输入,用于测试所提方法在量测不确定性条件下的状态校正效果。

本研究在 SWMM 计算流量的基础上随机生成 1 000 组流量序列数据(图 3(a)),平均相对误差为 7.3%~18.9%。为减少计算负担,采用同步向后消去策略(the Simultaneous Backward Reduction)^[4]将随机场景缩减为 10 组(图 3(b)),平均相对误差在 7.9%~18.1%。所得到的场景子集在概率测度上最接近初始分布。随后将数据集输入方案 1 中分别进行计算运行,并对基于 UKF 的误差反馈策略的修正效果进行分析。

2.3.3 考虑模型预测不确定性的预测结果分析

2.3.3.1 预测精度评估指标

为系统评估预报精度的提升效果,采用相对性能指数(Relative Improvement Performance, RIP)作为对预测值修正效果的评价指标,该指标旨在量化在其可改进空间内所实现的预报精度提升比例,计算式如下:




图 3 随机模拟流量结果(含噪声)

Fig.3 Simulated flow results from random realizations (with noise)

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_i^o - Q_i^m)^2}{\sum_{i=1}^n (Q_i^o - Q_i')^2}, \quad (28)$$

$$RIP = \frac{NSE_b - NSE_a}{1 - NSE_a} \times 100\% \quad (29)$$

式中: Q_i^o 和 Q_i^m 分别为真实流量和预测流量; Q_i' 为流量平均值; NSE_a 为观测数据(含噪声)的纳什效率系数; NSE_b 为修正后预测结果的纳什效率系数。

2.3.3.2 结果分析

为定量分析所提方法对预测的修正效果,对修正前后共 10 组预测序列进行对比分析,结果见表 5。

表 5 预测结果

Table 5 Prediction results

事件编号	NSE		RIP/%	平均相对误差(修正前)/%
	修正前	修正后		
1	0.54	0.79	54.3	9.10
2	0.58	0.69	26.2	16.30
3	0.52	0.57	10.4	18.10
4	0.53	0.68	31.9	15.90
5	0.40	0.69	48.3	12.30
6	0.43	0.77	59.6	7.90
7	0.49	0.58	17.6	17.50
8	0.44	0.69	44.6	13.50
9	0.39	0.56	27.9	16.10
10	0.46	0.69	42.6	12.70

由表 5 可知,经修正后,各序列预测性能均得到不同程度改善。NSE 方面,修正前各序列 NSE 分布于 0.39~0.58 之间,修正后提升至 0.56~0.79。其中,第 6 组序列提升最明显, NSE 由 0.43 增至 0.77; RIP 为 10.4%~59.6%,均值为 36.4%。从修正前的预测结果来看, RIP 与平均相对误差总体上呈负相关关系(表 5), UKF 在总量预测较准的基础上,改善了过程拟合度(NSE),提升整体预报精度。结合初始 NSE 和平均误差联合分析可知,所提方法的适用性与预测误差的组成密切相关,总体上所提方法适用于平均误差较小但过程拟合不佳的情况(事件 5、事件 6、事件 8、事件 10),在平均误差较大但过程拟合度较好的情况提升效果明显下降(事件 2、事件 3、事

件7、事件9)。值得注意的是,上述规律中存在个别偏离整体趋势的特殊事件(事件1、事件4),可能是由于不同事件的 UKF 最优参数存在差异,导致个别序列的修正效果出现波动。

综上所述,UKF-MPC 修正效果受初始平均误差、NSE 和 UKF 参数等多重因素共同影响,所提方法在平均误差较小但过程拟合不佳的情况下可以发挥最大效果。

2.3.4 考虑模型预测不确定性的控制策略风险分析

流量预测精度对比如表6所示,由表6可知,UKF-MPC 在 50 a 一遇和 100 a 一遇设计暴雨下的流量预测 NSE 分别为0.73和0.71,显著高于传统 MPC 的0.43和0.48,表明其预测过程与真实流量拟合度更优。从总洪量预测相对误差看,传统 MPC 分别为-13.9%和-14.2%,呈现显著的系统性低估;UKF-MPC 分别为-7.1%和-7.9%,相对误差绝对值减小约 50%,虽仍存在轻度低估,但已大幅度减小了预测相对误差,为后续控制策略提供了更可靠的预测输入。

表6 流量预测精度对比

Table 6 Comparison of prediction accuracy

设计降雨	模型方法	NSE	总洪量相对误差/%
50 a 一遇	UKF-MPC	0.73	-7.1
	传统 MPC	0.43	-13.9
100 a 一遇	UKF-MPC	0.71	-7.9
	传统 MPC	0.48	-14.2

预测精度的不同直接导致了控制策略效果出现明显差异。由表6和图4可知,100 a 一遇暴雨场景下由于 UKF-MPC 预测流量与真实过程更接近,预测总洪量比传统 MPC 高 6%,因此采取预排措施,所以 UKF-MPC 策略下启泵时间较传统 MPC 提前 20 min,峰值水位、能耗、区域溢流分别增加 0.56 m、12.4%、14.1%,更能体现真实情况。50 a 一遇暴雨场景中 UKF-MPC 策略启泵时间提前 20 min,峰值水位、能耗、区域溢流分别增加 0.31 m、9.6%、10.7%,规律与 100 a 一遇场景一致,调蓄池水位及泵站启闭过程见图4。

从调度效果上看,UKF-MPC 策略反而是不利的,但结合预测误差分析可知,传统 MPC 的预测结果存在更严重的系统性低估,基于偏小的入流预测作出了偏乐观的决策(启泵偏晚、预排不足),可能导致真实洪峰来临时调蓄能力不足,溢流风险增大。综上所述,与 UKF-MPC 相比,虽然传统 MPC 所得控制策略的结果更为乐观,但可能误导调度人员的判断,使城市洪涝风险增大。而 UKF-MPC 基于更高精度的预测生成的策略更为审慎稳健,有效降低了城市洪涝风险。




图4 控制策略效果

Fig.4 Performances of control strategies

3 结论与展望

3.1 结论

本文提出了一种耦合无迹卡尔曼滤波与模型预测控制(UKF-MPC)的城市排水系统实时控制方法并进行了验证。主要结论如下:

(1)提出的耦合无迹卡尔曼滤波与模型预测控制(UKF-MPC)的城市排水系统运行调控方法,通过数据同化实现了从传统误差反馈向状态空间校正的升级,增强了系统在复杂环境下的适应能力。

(2)研究表明,该方法显著提升了流量预测精度,NSE 由0.39~0.58提升至0.56~0.79,RIP 均值达36.4%。

(3)在 50 a 一遇和 100 a 一遇暴雨情景下,

UKF-MPC 均能生成更稳健的控制策略,为城市排水系统提供了一种可实时感知系统状态、动态优化控制策略的框架。

3.2 展望

当前研究仍存在以下有待深化的方向:

(1)未定量分析 UKF 参数设置对校正效果的影响。

(2)当前 UKF-MPC 框架通过提升状态估计的准确性,间接增强了 MPC 在复杂环境下的稳健性,但状态协方差信息尚未被直接应用于优化决策。

(3)目前仅在单一区域以设计暴雨进行验证,案例类型单一。因此未来将结合更丰富的实测数据,开展多流域、多类型降雨事件的系统验证,进一步厘清 UKF-MPC 的适用边界与参数敏感机制,以增强结论的普适性与可靠性。在此基础上,将探索如何将状态协方差信息直接纳入优化问题,构建能够自主规避风险的模型预测控制方法。

参考文献(References):

- [1] 王 军,谭金凯. 气候变化背景下中国沿海地区灾害风险研究与应对思考[J]. 地理科学进展, 2021, 40(5): 870-882.(Wang Jun, Tan Jin-kai. Understanding the Climate Change and Disaster Risks in Coastal Areas of China to Develop Coping Strategies[J]. Progress in Geography, 2021, 40(5): 870-882.(in Chinese))
- [2] 王兆礼,孟德胜,廖耀星,等. 快速城市化对城市内涝特征的影响分析[J]. 水资源保护, 2025, 41(5): 41-51.(Wang Zhao-li, Meng De-sheng, Liao Yao-xing, et al. Analysis of Impact of Rapid Urbanization on Characteristics of Urban Waterlogging[J]. Water Resources Protection, 2025, 41(5): 41-51.(in Chinese))
- [3] Oh J, Bartos M. Model Predictive Control of Stormwater Basins Coupled with Real-time Data Assimilation Enhances Flood and Pollution Control under Uncertainty[J]. Water Research, 2023, 235: 119825.
- [4] Luo X, Liu P, Xia Q, et al. Machine Learning-based Surrogate Model Assisting Stochastic Model Predictive Control of Urban Drainage Systems[J]. Journal of Environmental Management, 2023, 346: 118974.
- [5] Chen Y, Wang C, Huang H, et al. Real-time Model Predictive Control of Urban Drainage System in Coastal Areas[J]. Journal of Hydrology, 2024, 628: 130570.
- [6] Xu W D, Burns M J, Cherqui F, et al. Enhancing Stormwater Control Measures Using Real-time Control Technology: A Review[J]. Urban Water Journal, 2021, 18(2): 101-114.
- [7] Ye S, Wang C, Wang Y, et al. Real-time Model Predictive Control Study of Run-of-river Hydropower Plants with Data-driven and Physics-based Coupled Model[J]. Journal of Hydrology, 2023, 617: 128942.
- [8] Magni L, Sepulchre R. Stability Margins of Nonlinear Receding-horizon Control Via Inverse Optimality[J]. Systems & Control Letters, 1997, 32(4): 241-245.
- [9] Nicolao G, Magni L, Scattolini R. On the Robustness of Receding-horizon Control with Terminal Constraints[J]. IEEE Transactions on Automatic Control, 1996, 41(3): 451-453.
- [10] Broersen P M T, Weerts A H. Automatic Error Correction of Rainfall-runoff Models in Flood Forecasting Systems[C]// IEEE. Proceedings of the 2005 IEEE Instrumentation and Measurement Technology Conference. Ottawa, Canada, May 16-19, 2005, New York: IEEE Press, 2005: 963-968.
- [11] Vezzaro L, Grum M. A Generalised Dynamic Overflow Risk Assessment (DORA) for Real Time Control of Urban Drainage Systems[J]. Journal of Hydrology, 2014, 515: 292-303.
- [12] Svensen J L, Sun C, Cembrano G, et al. Chance-constrained Stochastic MPC of Astlingen Urban Drainage Benchmark Network[J]. Control Engineering Practice, 2021, 115: 104900.
- [13] 叶洪涛,罗 飞,许玉格. 解决多目标优化问题的差分进化算法研究进展[J]. 控制理论与应用, 2013, 30(7): 922-928.(Ye Hong-tao, Luo Fei, Xu Yu-ge. Differential Evolution for Solving Multi-objective Optimization Problems: A Survey of the State-of-the-art[J]. Control Theory & Applications, 2013, 30(7): 922-928.(in Chinese))
- [14] 周新宇,蒋金峰,高卫峰,等. 动态精英学习的约束差分进化算法[J]. 模式识别与人工智能, 2025, 38(9): 820-836.(Zhou Xin-yu, Jiang Jin-feng, Gao Wei-feng, et al. Constrained Differential Evolution Algorithm with Dynamic Elite Learning[J]. Pattern Recognition and Artificial Intelligence, 2025, 38(9): 820-836.(in Chinese))
- [15] 刘建娟,李志伟,姬淼鑫,等. 多策略改进麻雀搜索算法优化无迹卡尔曼滤波方法[J]. 科学技术与工程, 2025, 25(1): 227-237.(Liu Jian-juan, Li Zhi-wei, Ji Miao-xin, et al. Multi-strategy Improvement of the Sparrow Search Algorithm for Optimizing the UKF Method[J]. Science Technology and Engineering, 2025, 25(1): 227-237.(in Chinese))
- [16] 左云龙,张晓锋,朱天高,等. 基于滤波平滑的迭代无迹卡尔曼滤波算法[J]. 海军工程大学学报, 2024, 36(5): 106-112.(Zuo Yun-long, Zhang Xiao-feng, Zhu Tian-gao, et al. Iterated Unscented Kalman Filter Algorithm Based on Filter Smoothing[J]. Journal of Naval University of Engineering, 2024, 36(5): 106-112.(in Chinese))