

DOI:10.19853/j.zgjsps.1000-4602.2023.01.016

面向实时控制的排水系统深度LSTM神经网络模型

杨萌祺¹, 徐智伟¹, 王一茗¹, 曾思育^{1,2}, 杜鹏飞¹, 董欣^{1,2}

(1. 清华大学 环境学院, 北京 100084; 2. 环境模拟与污染控制国家重点联合实验室, 北京 100084)

摘要: 如何得到兼顾运算时间和预测效果的排水系统预测模型是排水系统实时控制领域亟需解决的问题。针对这一难点,以非线性映射能力较强且运算速度较快的长短时记忆(LSTM)神经网络为基础,构建了面向实时控制的排水系统深度LSTM神经网络模型,并以苏州市福星片区为案例区域,验证该模型的预测效果和计算效率。结果显示,该模型对18个泵站站前液位预测结果的纳什效率系数均在0.5以上,且在不同降雨情景下均能得到较好的拟合结果;与机理模型相比,该模型能节约99.7%的计算时间,可显著提高排水系统预测模型的实时性。

关键词: 城市排水系统; 实时控制; 长短时记忆(LSTM)神经网络; 深度学习; 泵站站前液位

中图分类号: TU992 文献标识码: A 文章编号: 1000-4602(2023)01-0105-06

Deep LSTM Neural Network Model for Real-time Control of Urban Drainage System

YANG Meng-qi¹, XU Zhi-wei¹, WANG Yi-ming¹, ZENG Si-yu^{1,2}, DU Peng-fei¹,
DONG Xin^{1,2}

(1. School of Environment, Tsinghua University, Beijing 100084, China; 2. State Key Joint Laboratory of Environment Simulation and Pollution Control, Beijing 100084, China)

Abstract: An urgent problem in the context of real-time control of drainage system is to establish a predicting model which balances operation time and prediction effect. To solve this problem, a deep long short term memory (LSTM) neural network model for real-time control of urban drainage system was constructed, which had strong nonlinear mapping ability and fast operation speed. The prediction performance and operation efficiency of the model were verified in Fuxing area of Suzhou City. The Nash-Sutcliffe efficiency coefficient of the prediction results of the water level in front of 18 pumping stations was above 0.5, and good fitting results were obtained under different rainfall scenarios. Compared with the mechanism model, the proposed model saved 99.7% of the operation time and significantly improved the real-time performance of the drainage system prediction model.

Key words: urban drainage system; real-time control; long short term memory (LSTM) neural network; deep learning; water level in front of pumping station

基金项目: 国家自然科学基金资助项目(51778327)

通信作者: 董欣 E-mail: dongxin@tsinghua.edu.cn

随着城市点源污染逐步得到控制,雨季溢流污染成为城市水环境的重要污染源。排水系统实时控制技术是一种成本效益比较高的溢流控制方式,这种技术旨在通过优化排水系统中泵站、调蓄池和闸门等控制设施的操作,充分利用现有城市排水系统的调蓄能力,在不新增基础设施的前提下实现削减排水系统溢流量、提升系统效能等目标^[1-2]。模型预测控制方法是系统实时控制的有效方法之一^[3-4],已被广泛应用于先进制造、能源、环境等许多领域的过程控制问题中。模型预测控制方法使用模型预测不同控制措施下未来一段时间的系统状态,从中比选出最佳的控制措施并根据新的数据定期更新策略,具有滚动优化和反馈校正的特点。因此,建立优秀的系统状态预测模型是模型预测控制方法的关键和基础^[5]。

常用的城市排水系统状态预测模型主要可分为机理模型与水箱模型两大类。经过率定后的机理模型准确度较高,以机理模型为基础的模型预测控制方法生成的控制策略的效果较好。然而,机理模型的运算速度往往较慢,计算时间较长,在现有条件下仅适用于生成面积较小、管网结构较为简单的片区的优化控制策略^[6-7]。线性水箱模型的运算速度较快,可以在较短时间内预测系统状态,但该模型对控制方程的简化可能导致模型失真,进而严重影响控制效果。因此,如何兼顾排水系统状态预测模型的计算时间和控制效果成为现阶段城市排水系统实时控制领域亟需解决的问题之一。

人工神经网络模型是一种具有强大的输入输出拟合能力的机器学习算法,能够有效处理非线性复杂过程。人工神经网络模型的运算速度较快,若以之为基础的排水系统状态预测模型能够满足排水系统控制对模型准确度的要求,则可以在一定程度上解决现有机理模型运算时间过长的问题,提高模型预测控制方法在排水系统实时控制领域的实用性。在这类模型中,长短时记忆(LSTM)神经网络模型能够学习时间序列间长期尺度依赖关系的能力^[8],被广泛用于降雨^[8]、径流^[9]、地质灾害^[10]等的预测研究中,但以LSTM神经网络模型为基础的排水系统状态预测研究尚不多见。为此,笔者以苏州市中心城区某片区为例,构建了面向排水系统实时控制的深度LSTM神经网络模型,并对LSTM神经网络的预测效果和运算时间进行了分析,检验了该方

法的可靠性。

1 深度LSTM神经网络模型的构建

1.1 研究区域概况

研究区域为苏州市中心城区福星污水处理厂服务区域(简称福星片区)。福星片区面积为46.1 km²,污水管线总长约600 km,常住人口约38万人,年平均降雨量约为1 150 mm,研究区域以泵站为节点可划分为18个泵站片区(石路泵站数据缺失),各泵站片区间的连接关系如图1所示。污水排入市政管道后汇集到相应泵站,经多级提升汇集到设计规模为18×10⁴ m³/d的福星污水处理厂。在此前的研究中,已有研究者使用暴雨洪水管理模型(SWMM)评估了该片区的调控潜力。研究结果显示,在多年平均降雨情景下,管网整体的剩余调控空间占总存储空间的30%以上。因此,有必要在该区域构建能够兼顾预测效果和运算时间的排水系统模型,从而支持对该区域排水系统进行实时控制。

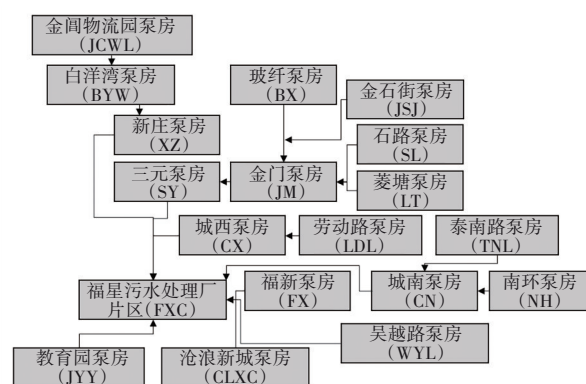


图1 研究区内泵站片区间的连接关系

Fig.1 Connection between pumping stations in study area

1.2 模型构建

本研究所构建的深度LSTM神经网络模型结构如图2所示。该模型以排水系统状态矩阵 $s(t)$ 为输入数据,通过3个LSTM神经网络层与两个Dense层对输入数据进行处理,最终输出下一时间节点的泵站前液位预测值 $L_{\text{pump},pre}$ 。




图2 深度LSTM神经网络模型结构

Fig.2 Structure of deep LSTM neural network model

输入数据包含当前时间节点前1 h的降雨量序列、污水管网泵站启停状态序列和站前液位序列等排水系统状态数据。考虑到监测数据的采集频率,本研究中的时间间隔步长固定为5 min。因此排水系统状态矩阵 $s(t)$ 定义为各变量当前时间点前12个时间节点(即前1 h)的状态序列构成的矩阵,如式(1)所示。

$$s(t) = \begin{bmatrix} R(k), Q_{\text{pump},1}(k), \dots, Q_{\text{pump},18}(k), \\ L_{\text{pump},1}(k), \dots, L_{\text{pump},18}(k) \end{bmatrix}^T \quad (1)$$

式中: $R(k)$ 为研究区的降雨量序列; $Q_{\text{pump},1}(k), \dots, Q_{\text{pump},18}(k)$ 分别为研究区18个泵站的启停状态序列; $L_{\text{pump},1}(k), \dots, L_{\text{pump},18}(k)$ 分别为研究区18个泵站的站前液位序列。

LSTM层与Dense层起到数据处理的作用。主要的超参数为LSTM层输出向量长度及Dense层神经元数量,参考现有研究常用的神经网络模型超参数初值设置方法,3个LSTM神经网络层输出向量长度均设为50,第1个Dense层神经元数量为38,第2个Dense层神经元数量为1。

第1个LSTM层以排水系统状态矩阵 $s(t)$ 为输入,输出长度为50的向量;后两个LSTM层分别以前一层的输出向量为输入,处理数据并输出相同长度的向量。单个LSTM层内部结构如图3所示,其内部包含输入门层、遗忘门层、输出门层和单元状态层。预测过程中,LSTM层整合新的输入数据 x_t 、上一时间节点的单元状态 C_{t-1} 和输出 y_{t-1} ,以式(2)所示的方式处理数据并产生新的单元状态 C_t 和输出 y_t 。 y_t 与 C_t 的传递以及各门层之间的交互使LSTM能够学习长时序依赖信息,从而能够充分挖掘降雨量、泵站启停状态、泵站液位和历史时刻系统状态中包含的信息。




图3 LSTM神经网络层内部结构

Fig.3 Structure of the LSTM layer

$$\begin{aligned} f_t &= \sigma(W_f \cdot [y_{t-1}, x_t] + b_f) \\ i_t &= \sigma(W_i \cdot [y_{t-1}, x_t] + b_i) \\ c_t &= \tanh(W_c \cdot [y_{t-1}, x_t] + b_c) \\ C_t &= f_t \otimes C_{t-1} + i_t \otimes c_t \\ o_t &= \sigma(W_o \cdot [y_{t-1}, x_t] + b_o) \\ y_t &= o_t \otimes \tanh(C_t) \end{aligned} \quad (2)$$

式中: x_t 和 y_t 分别为LSTM神经网络层 t 时刻的输入和输出; i_t, f_t, o_t 和 c_t 分别为LSTM神经网络内部4个门层的输出; σ 和 \tanh 分别为Sigmoid和tansig激活函数; W 和 b 分别为不同门层的权重和偏置值。

Dense层为线性全连接层,以式(3)所示的方式进一步选择和压缩LSTM层的输出,最终输出下一时间节点各泵站站前液位的预测值。第1个Dense层将LSTM层输出的50维向量压缩为38维,第2个Dense层将38维向量压缩为1维,输出节点泵站站前液位的预测值 $L_{\text{pump},\text{pre}}$ 。模型中的Dense层能帮助模型确定隐藏状态中的变化因素,提高对输入历史数据的总结能力。

$$y_{t,\text{Dense}} = W \cdot x_{t,\text{Dense}} + b \quad (3)$$

式中: $x_{t,\text{Dense}}$ 和 $y_{t,\text{Dense}}$ 分别为Dense神经网络层 t 时刻的输入和输出; W 和 b 分别为权重和偏置值。

深度LSTM神经网络模型的主要参数是各层神经网络层中的权重和偏置值。如式(2)所示,每一个LSTM层中包含4组权重和偏置值;如式(3)所示,每一个Dense层包含1组权重和偏置值。在模型结构确定后,需要通过模型训练与测试过程调整模型参数,从而构建起泵站站前液位预测值 $L_{\text{pump},\text{pre}}$ 与排水系统状态 $s(t)$ 之间的非线性映射关系。

2 模型训练与测试

本研究使用苏州市中心城区福新片区2019年4月1日—6月30日逐5 min降雨监测数据、泵站流量和站前液位监测数据进行模型的训练与测试。其中,4月1日—6月11日的20 727组数据用于训练,占总数据量的80%;6月12日—30日的5 194组数据构成测试集,占总数据量的20%。

模型训练是通过调整参数使模型输出接近训练样本中实测数据的过程。本研究以均方误差(MSE)作为训练过程中的目标损失函数,表征模型预测结果与期望输出之间的误差大小;以自适应矩估计(Adam)算法对权重 W 和偏置值 b 等模型参数进行迭代优化,当数据集上的目标损失函数趋于收

敛时结束训练。模型训练过程中的超参数参考文献中常用的参数值进行设置:学习率为 1.0×10^{-3} ,批处理量为64,最大迭代次数为50。利用训练集数据对案例区域深度LSTM神经网络模型进行训练,训练过程中目标损失函数的变化见图4。在训练过程中,深度LSTM神经网络模型预测结果的损失函数随训练代数的增加而不断降低,在50代左右趋于收敛,得到经过训练的深度LSTM神经网络模型。




图4 损失函数随迭代次数的变化曲线

Fig.4 Loss function-epoch curve

经过训练的深度LSTM神经网络模型对案例区域排水系统内全部18个泵站站前液位的预测结果与监测结果都有较好的拟合效果。以福星泵站为例,深度LSTM神经网络模型对福星泵站站前液位的预测结果如图5所示,在训练集和测试集上的纳什效率系数(NSE)分别为0.94和0.98,平均相对误差分别为1.1%和1.5%,能够较为准确地反映该泵站的液位变化情况。




图5 深度LSTM神经网络模型对福星泵站站前液位的模拟结果

Fig.5 Forecasts of water level in Fuxing pump station by the deep LSTM neural network model

完成训练后需要对模型进行测试,以确定模拟效果是否满足实际应用要求。当模型无法满足要求时,需要通过调整模型结构超参数与训练超参数,重新训练模型。本研究以NSE作为测试指标,以经过训练的深度LSTM神经网络模型在训练集和测试集上的NSE均大于0.5为测试标准,测试结果如图6所示。可知,在训练集和测试集上,深度LSTM神经网络模型对18个泵站站前液位的模拟结果均满足要求,因此认为该模型能够有效预测案例区域排水系统在未来一段时间内的系统状态。




图6 深度LSTM神经网络模型在训练集和测试集上的纳什效率系数

Fig.6 NSE of deep LSTM neural network model on training set and testing set

3 模型性能评估

为确保模型在不同降雨情景下均能准确预测排水系统状态,本研究以4种量化指标评估深度LSTM神经网络模型在不同降雨情景下的预测效

果。所选的3场降雨如图7所示。4月21日降雨事件的峰值降雨强度为0.92 mm/h,作为小雨情景;5月25日降雨事件的峰值降雨强度为4.88 mm/h,作为中雨情景;6月17日—19日降雨事件的峰值降雨强度为11.08 mm/h,作为大雨情景。所选4种量化指标分别为NSE、均方根误差(RMSE)、平均绝对误差(MAE)和平均绝对百分比误差(MAPE)。NSE是水文领域最常用的评价模型预测值与实测值整体拟合情况的目标函数,对峰值敏感,越接近1,模型效果越好;RMSE、MAE和MAPE是常用的预测评价指标,能够表征预测结果与实测值之间的差异,越接近0,模型效果越好。

3种降雨情景下深度LSTM神经网络模型的模拟结果见图7。模型在小雨和中雨情景下的预测效果较好,能够准确预测泵站站前液位的峰值和谷值;大雨情景下,深度LSTM神经网络模型低估了降雨后期的液位,拟合效果稍劣于其他两场降雨。3种降雨情景下模型模拟结果的4种量化指标值见图8,模型模拟结果的NSE均在0.9以上,其余3项指标均接近0,这表明模型预测值和实测值的拟合度较好,能够满足实时控制对模型精度的要求。


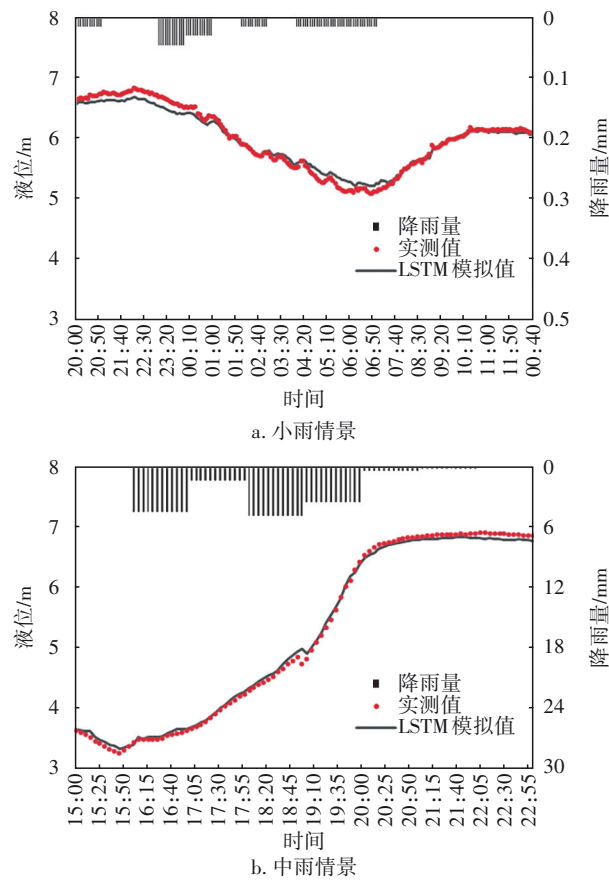


图7 深度LSTM神经网络模型在不同降雨情景下的模拟结果
Fig.7 Simulation results of deep LSTM neural network model under different rainfall scenarios




图8 不同降雨情景下深度LSTM神经网络模型模拟结果的量化指标值

Fig.8 Quantitative indicator values of deep LSTM neural network model under different rainfall scenarios

为了进一步表征深度LSTM神经网络模型在实时性方面的性能,本研究将其与传统机理模型进行了比较。案例区域排水系统的机理模型采用SWMM构建,为了保证模拟精度与深度LSTM神经网络模型具有可比性,该机理模型包含了5 032个汇水区、5 033根管段和1个出水口。两个模型同时在配置相同的PC机上运行[处理器为Intel(R) Core(TM) i7-8700 CPU @ 3.20 GHz,内存为16.0 GB],模拟大雨条件下系统在雨中和雨后共36 h的状态。机理模型完成模拟需要260 min左右,而深度LSTM神经网络模型仅需要25 s左右。由此可见,本研究

构建的深度LSTM神经网络模型可以节约99.7%的计算时间,具有非常明显的实时性优势,能够很好地支撑系统实时控制的需求。

4 结论

以运算速度快且非线性拟合能力强的LSTM神经网络为基础,构建了面向实时控制的城市排水系统深度LSTM神经网络模型,并以苏州市福星片区为案例区域,验证该模型的计算效果和效率。结果显示,深度LSTM神经网络模型能够较为准确地预测福星片区内18个泵站的站前液位,在测试集和训练集上,模拟结果的NSE均大于0.5。在不同的降雨条件下,4种预测评价指标值均显示模型的模拟结果与实测值具有较好的拟合度。与机理模型相比,深度LSTM神经网络模型能够减少99.7%的计算时间,显著提高了排水系统预测模型的实时性。

本研究开发了一种高效且具有较好计算效果的排水系统状态预测模型,一定程度上解决了排水系统实施控制领域模型预测效果与运算时间难以兼顾的问题,该模型可以耦合寻优算法,构建模型预测控制系统,从而支持实时控制技术在排水系统领域的实际应用。但是值得注意的是,深度LSTM神经网络的训练过程是基于有限训练集进行的。若预测情景与训练集中的数据差异较大,模型效果可能会大幅下降。未来可通过增加监测时间或增加典型降雨事件下的监测数据,来提升深度LSTM网络应对未知情景的泛化能力,并利用不同季节的监测数据对模型效果进行验证,检验该模型在其他季节的可靠性,扩展该模型在排水系统状态预测方面的应用范围。

参考文献:

- [1] 汤海,李田. 城市排水系统实时控制的现状与发展趋势[J]. 中国给水排水, 2009, 25(24): 11-14.
TANG Hai, LI Tian. Present situation and development trend of real time control of urban drainage system [J]. China Water & Wastewater, 2009, 25(24): 11-14 (in Chinese).
- [2] JAFARI F, MOUSAVI S J, YAZDI J, *et al.* Real-time operation of pumping systems for urban flood mitigation: single-period vs. multi-period optimization [J]. Water Resources Management, 2018, 32(14): 4643-4660.
- [3] PUIG V, CEMBRANO G, ROMERA J, *et al.* Predictive optimal control of sewer networks using CORAL tool: application to Riera Blanca catchment in Barcelona[J]. Water Science and Technology, 2009, 60(4): 869-878.
- [4] PLEAU M, COLAS H, LAVALLEE P, *et al.* Global optimal real-time control of the Quebec urban drainage system [J]. Environmental Modelling & Software, 2005, 20(4): 401-413.
- [5] 席裕庚,李德伟,林妹. 模型预测控制——现状与挑战[J]. 自动化学报, 2013, 39(3): 222-236.
XI Yugeng, LI Dewei, LIN Shu. Model predictive control—status and challenges [J]. Acta Automatica Sinica, 2013, 39(3): 222-236 (in Chinese).
- [6] LUND N S V, FALK A K V, BORUP M, *et al.* Model predictive control of urban drainage systems: a review and perspective towards smart real-time water management [J]. Critical Reviews in Environmental Science and Technology, 2018, 48(3): 279-339.
- [7] SADLER J M, GOODALL J L, BEHL M, *et al.* Leveraging open source software and parallel computing for model predictive control of urban drainage systems using EPA-SWMM5 [J]. Environmental Modelling & Software, 2019, 120: 104484.
- [8] ASANJAN A A, YANG T T, HSU K, *et al.* Short-term precipitation forecast based on the PERSIANN system and LSTM recurrent neural networks [J]. Journal of Geophysical Research: Atmospheres, 2018, 123(22): 12543-12563.
- [9] XIANG Z, YAN J, DEMIR I. A rainfall-runoff model with LSTM-based sequence-to-sequence learning [J]. Water Resources Research, 2020, 56:e2019WR025326.
- [10] XU S L, NIU R Q. Displacement prediction of Baijiabao landslide based on empirical mode decomposition and long short-term memory neural network in Three Gorges area, China [J]. Computers & Geosciences, 2018, 111: 87-96.

作者简介:杨萌祺(1996—),女,宁夏银川人,硕士研究生,主要研究方向为城市排水系统实时控制、入流入渗分析等。

E-mail: yangmq19@mails.tsinghua.edu.cn

收稿日期:2021-11-01

修回日期:2022-01-04

(编辑:刘贵春)