

DOI: 10. 20040/j. cnki. 1000-7709. 2023. 20230176

基于多层长短期记忆神经网络的用水量预测

王健, 刘丽, 查淳膺, 陈国炜

(合肥工业大学土木与水利工程学院, 安徽 合肥 230009)

摘要: 及时准确的居民用水量预测对供水系统的设计和运行管理至关重要。长短期记忆神经网络(LSTM)是一种有效的基于数据驱动的用水量预测模型,但其通常依赖于大量的参数设置。因此,在LSTM模型基础上,通过叠加时间分布模块,提出多层长短期记忆神经网络模型(MLSTM)。与LSTM模型对比分析表明,MLSTM模型具有较低复杂度和更高的预测精度,尤其对于高峰期用水量预测(M_{MAPE} 值降低约60%),且受外部环境条件(如天气)的影响较小。

关键词: 居民用水量;长短期记忆神经网络;时间分布模块;多层长短期记忆神经网络;预测精度

中图分类号: TU991.31;TV213.9

文献标志码: A

文章编号: 1000-7709(2023)12-0024-04

1 引言

城市用水量预测是给水系统规划、运行和管理中的关键问题^[1]。其中给水系统的规划设计依赖于对该区域长期用水量的预测,一旦给水系统建成,通常面临水泵调度方案制定、缓解高峰期的用水压力、降低管网的漏损率及降低能量消耗等运行管理问题^[1]。准确实时的用水量预测可有效提高给水系统实时水力水质模型的准确性和可靠性,并为后续运行管理提供重要支撑^[2]。近年来,随着人工智能的发展,深度学习方法在用水量预测领域得到广泛应用。LI M等^[3]发现相较于时间序列和其他机器学习模型,长短期记忆神经网络(LSTM)在预测突变数据点以及具有较高不确定性数据方面具有显著优势;DU B等^[4]将LSTM模型结合小波变化与主成分分析预测用水量,并与其他基础深度学习模型进行性能比较,发现该模型优于其他模型,尤其在捕获峰值和平均预测精度方面。尽管LSTM模型在用水量预测方面取得良好效果,但其需要大量参数才能达到较高的预测精度。鉴此,本文在LSTM模型基础上添加时间分布(Time-Distributed)类全连接层模块以减少模型的参数,提高模型精度,并与传统LSTM模型进行性能比较,分析其不同情景下的预测性能,旨在为供水系统用水量预测提供

新思路。

2 材料和方法

2.1 多层长短期记忆神经网络

LSTM模型是循环神经网络(RNN)的一种^[3],由一系列重复的网络模块组成(图1(a)),其架构的核心思想是单元状态 c ,用以存储信息,存储单元中的信息通过门机制选择性地控制信息流^[4]。LSTM的优势在于可有效处理短期和长期时间序列内的相关性,进而有助于其对未来用水量的准确预测^[5]。




图1 模型结构图

Fig. 1 Layout of the model

基于深度学习建模方法在数据进入LSTM模型^[6]前添加Time-Distributed模块,即输入数据(二维矩阵)被传递到“Time-Distributed”模块的3个完全连接的层,其中层1、2的激活函数使每个层的输出可以加速收敛,而输出层3需要放大器功能,其结构见图1(b);其次,数据被传递到

收稿日期: 2023-02-12, 修回日期: 2023-03-21

基金项目: 安徽省自然科学基金联合基金项目(2208085US13)

作者简介: 王健(1998-),男,硕士研究生,研究方向为给排水系统优化调度理论与技术,E-mail: 1220928835@qq.com

通讯作者: 刘丽(1972-),女,博士、教授、硕导,研究方向为给排水系统安全理论与技术,E-mail: lliu@hfut.edu.cn

LSTM 模块,其中一个 LSTM 层作为输出层。其中,MLSTM 各层单元数及激活函数等按文献[7]进行选择,而传统 LSTM 模型则参考文献[3]用于验证的 LSTM 结构,见表 1。

表 1 MLSTM 与 LSTM 参数对比

Tab. 1 Comparison between MLSTM and LSTM parameters

模型	层	神经元类型	神经元数量	参数个数	激活函数
LSTM	1	LSTM	128	70 656	Sigmoid
	输出	Dense	1	129	Sigmoid
MLSTM	1	Time-Distributed	50	500	ReLU
	2	Time-Distributed	10	510	ReLU
	3	Time-Distributed	1	11	Linear
	4	LSTM	32	4 352	Sigmoid Tanh
输出	LSTM	1	136	Sigmoid Linear	

2.2 数据及预处理

研究数据为 A、B 两个小区的用水量及环境云采集的天气数据(降雨量、气温和相对湿度),采集时间间隔为 1 h,从 2020 年 6 月 25 日至 2021 年 6 月 24 日,共 8 759 条,其中缺少 2020 年 12 月至 2021 年 2 月的天气数据,剔除信息不完整数据后,提取下半年用水量数据,共计 4 088 条,结果见图 2。其中 A、B 小区用水量均值分别为

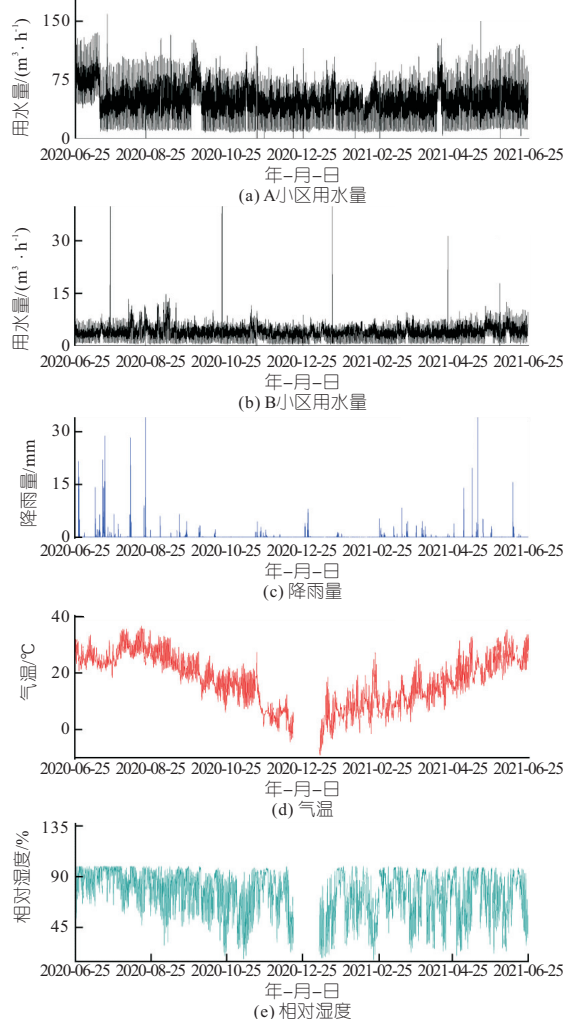


图 2 用水量和气候数据

Fig. 2 Water demand and climate data

45.90、3.89 m³/h,最小值分别为 13.24、0.91 m³/h,最大值分别为 93.00、7.08 m³/h。小区用水量呈明显的周期性变化,居民在 1 d 内存在两个用水高峰期,1 周循环变化。由降雨量图(图 2)可知,当地全年降雨大部分集中于 6 月份,其余气温与相对湿度数据见图 2。

时间序列数据在训练 MLSTM 神经网络前需要进行预处理,将其转换成具有输入和输出分量的样本,使问题从无监督转化为有监督^[6]。根据文献[3]的结论,将输入时间分为 3 个时段,即当天、前一天和前天。如表 2 所示,为了预测当天的用水量(Q_t⁰)数据,输入是当天前 3 个时间步的用水需求(Q_{t-1}⁰、Q_{t-2}⁰、Q_{t-3}⁰),前一天以时间 t 为中心的 3 个连续时间步长的用水需求(Q_{t-1}⁻¹、Q_t⁻¹、Q_{t+1}⁻¹),以及前天以时间 t 为中心的 3 个连续时间步长的用水需求(Q_{t-1}⁻²、Q_t⁻²、Q_{t+1}⁻²)。以类似的方式,确定 LSTM 模型的输入、输出分量的样本。

表 2 LSTM 与 MLSTM 模型的输入

Tab. 2 Inputs for LSTM and MLSTM

模型	输入和输出
LSTM	$Q_t^0 = f(Q_{t-1}^{-2}, Q_t^{-2}, Q_{t+1}^{-2}, Q_{t-1}^{-1}, Q_t^{-1}, Q_{t+1}^{-1}, Q_{t-1}^0, Q_t^0, Q_{t-2}^0, Q_{t-3}^0)$
MLSTM	$Q_t^0 = f(Q_{t-1}^{-2}, Q_t^{-2}, Q_{t+1}^{-2}, Q_{t-1}^{-1}, Q_t^{-1}, Q_{t+1}^{-1}, Q_{t-1}^0, Q_t^0, Q_{t-2}^0, Q_{t-3}^0)$

2.3 模型评价指标

拟利用模型均方根误差(R_{RMSE})、平均绝对百分比误差(M_{MAPE})和拟合优度 R² 三个指标评价模型的拟合结果。计算公式分别为:

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (1)$$

$$E_{MAPE} = \frac{1}{N} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (2)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (3)$$

式中, Y_i 为 i 时刻的实际值; \hat{Y}_i 为模型给出的 i 时刻的预测值; N 为观测个数; \bar{Y} 为时间序列平均值。

其中, R_{RMSE}、M_{MAPE} 值越小表明模型预测精度越高;而 R² 取值为(-∞, 1],若 R² = 1,则预测效果非常好;R² 越大表明预测精度越高;若预测方法 R² > 0.5,则该方法有效。

3 基于多层长短期记忆神经网络的用水量预测

3.1 MLSTM 与 LSTM 模型的预测结果对比

为充分发挥模型预测性能,通过敏感性分析确定 MLSTM 模型学习率为 0.001,损失函数为均方误差,批次为 48,迭代次数为 250。为防止模型过拟合,采用 Adam 优化器,在梯度多次不再下降时乘以因子 0.5,并按照 90%训练集,10%验证集的比例进行用水量预测,LSTM 使用相同设置,以对比两模型性能。同时,为消除试验误差,每组试验运行 5 次,比较其平均值。

A、B 小区用水量的 MLSTM 与 LSTM 模型预测结果对比见图 3。由图 3 可知,两模型均能捕捉用水量的变化趋势。由图 3(a)可知,LSTM 模型在 A 小区用水量高峰的预测中出现偏差,而 MLSTM 对用水高峰的捕捉相对精准;图 3(b)也得出相同结论,但在 B 小区用水量预测中,两模型预测效果明显劣于 A 小区。两模型的预测精度指标值见表 3,MLSTM 预测结果中 M_{MAPE} 在 A、B 两小区分别为 6.530%、17.821%,明显优于 LSTM 模型;尤其在高峰期时段,B 小区 MLSTM 与 LSTM 预测指标 M_{MAPE} 分别为 6.340%、20.270%,相差近 2 倍,对于 R_{RMSE} 、 R^2 指标,MLSTM 在 A、B 小区用水高峰均表现出更好的预测性能,而 LSTM 在 A 小区用水高峰 R^2 呈负数,表示该模型不可用。原因在于 B 小区用水量较低,居民用水随机性高,虽然 LSTM 通过门机制可以很好地捕捉这些数据中的短期依赖,但 MLSTM 通过 Time-Distributed 模块可以将一个

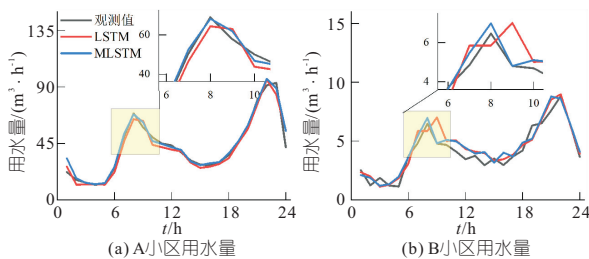


图 3 MLSTM 与 LSTM 预测结果对比

Fig. 3 Comparison between MLSTM and LSTM prediction results

表 3 LSTM 与 MLSTM 预测精度指标对比

Tab. 3 Comparison of accuracy measures between LSTM and MLSTM prediction

用水类型	模型	$R_{RMSE}/(m^3 \cdot h^{-1})$	$M_{MAPE}/\%$	R^2
A	LSTM	4.570	9.220	0.959
	MLSTM	3.983	6.530	0.969
B	LSTM	0.776	18.988	0.846
	MLSTM	0.657	17.821	0.890
A(高峰期)	LSTM	4.771	9.830	0.889
	MLSTM	2.514	4.440	0.969
B(高峰期)	LSTM	1.172	20.270	-0.741
	MLSTM	0.405	6.340	0.792

全连接层应用于 LSTM 层的每个时间步骤上,加强了其数据捕捉能力,使其在某些局部时段表现更好。

3.2 基于 MLSTM 模型的连续预测结果

给水系统中水泵的运行调度方案通常依赖于用户用水量的连续预测分析^[3]。为了探究 MLSTM 在动态预测用水量方面的性能,使用训练好的模型对 A 小区用水量进行连续预测,即将模型输出的预测值作为新的模型输入进行连续预测。A 小区连续预测多个用水数据的结果见图 4。由图 4 可看出,两模型均能捕捉用水量变化模式,但 MLSTM 在 8、22 h 两用水高峰处用水量数据捕捉具有明显优势。两模型连续预测结果指标对比见表 4,MLSTM、LSTM 在连续预测中 R_{RMSE} 分别为 4.996、5.319 m^3/h ,对于 M_{MAPE} 、 R^2 指标 MLSTM 也表现更佳。究其原因,在连续预测过程中,由于预测值与观测值的偏差导致预测误差不断积累,使模型预测效果变差,但由于 MLSTM 的模型参数少于传统 LSTM 模型,导致其在连续预测中,模型的输入被取代时修改的参数更少,从而降低了累积误差。




图 4 MLSTM 与 LSTM 连续预测结果对比

Fig. 4 Comparison of continuous prediction results between MLSTM and LSTM

表 4 LSTM 与 MLSTM 模型连续预测结果指标对比
Tab. 4 Accuracy measures comparison of continuous prediction between LSTM and MLSTM

模型	$R_{RMSE}/(m^3 \cdot h^{-1})$	$M_{MAPE}/\%$	R^2
LSTM	5.319	13.212	0.945
MLSTM	4.996	10.736	0.952

3.3 天气参数对 MLSTM 模型预测结果的影响

用水量预测通常需要考虑温度、湿度与降雨量等因素^[8]。为此,将气候因素等外部参数作为 MLSTM 模型的协变量,开发 MLSTM 多变量用水量预测模型以探究外部参数对 MLSTM 模型预测性能的影响。即为预测当天的用水量 Q_t^0 ,在输入变量不变的情况下,分别添加前一时刻天气数据(R_{t-1}^0 、 T_{t-1}^0 、 H_{t-1}^0)。MLSTM 模型在添加不同气候参数后预测和观测结果见图 5。由图 5 可看出,模型能精准地捕捉用水量变化模式,但添




图 5 具有不同气候参数的 MLSTM 预测结果对比

Fig. 5 Comparison of MLSTM prediction results among various climate parameters

加气候因素的 MLSTM 模型在 8 h 左右的第 1 个用水高峰出现预测偏差,导致模型预测精度下降。MLSTM 在添加不同气候参数后预测结果见表 5,四个 R_{RMSE} 指标分别为 3.983、3.774、4.146、4.421 m^3/h ,添加气候前后相差 0.5 m^3/h 左右, M_{MAPE} 、 R^2 两指标效果也呈现不同程度的变差。因为 MLSTM 模型的预测性能主要取决于其捕捉数据本身内在关系的强大能力,气候等数据对其预测效果影响有限,其不同于用水量的气候数据类型,甚至会导致模型性能下降。

表 5 MLSTM 添加不同气候参数后预测结果指标对比

Tab. 5 Accuracy measures comparison involving various climate parameters into MLSTM prediction

模型	$R_{RMSE}/(m^3 \cdot h^{-1})$	$M_{MAPE}/\%$	R^2
MLSTM	3.983	6.530	0.969
MLSTM(降雨量)	3.774	6.089	0.973
MLSTM(温度)	4.146	6.056	0.966
MLSTM(相对湿度)	4.421	6.797	0.962

4 结论

本文构建了基于 Time-Distributed 模块全连接层的 MLSTM 用水量预测模型,相较于 LSTM,该模型在用水峰值和连续预测上具有较高的短期依赖捕捉能力和预测精度,且受外

部参数影响较小。

参考文献:

- [1] ZUBAIDI S L, HASHIM K, ETHAIB S, et al. A novel methodology to predict monthly municipal water demand based on weather variables scenario [J]. Journal of King Saud University-engineering sciences, 34(3):163-169.
- [2] GUO G, LIU S, WU Y, et al. Short-term water demand forecast based on deep learning method[J]. Journal of water resources planning and management, 2018, 144(12):4018076.1-4018076. 11.
- [3] LI M, ZHENG F, TAO R, et al. Hourly and daily urban water demand predictions using a long short-term memory based model[J]. Journal of water resources planning and management, 2020, 146(9): 05020017.1-05020017. 11.
- [4] 李芬,杨程,赵晋斌,等. 基于天气类型聚类 and LSTM 的 PM2.5 短期预测模型[J]. 水电能源科学, 2021, 39(3):199-202,151.
- [5] DU B, ZHOU Q, GUO J, et al. Deep learning with long short-term memory neural networks combining wavelet transform and principal component analysis for daily urban water demand forecasting [J]. Expert systems with applications, 2021, 171(2):114571.
- [6] 李双宇,张明凯,刘艳臣,等. 基于 LSTM 模型的排水系统流量预测研究[J]. 中国给水排水, 2022, 38(5):59-64.
- [7] SALLOOM T, KAYNAK O, HE W. A novel deep neural network architecture for real-time water demand forecasting [J]. Journal of hydrology, 2021, 599:126353.
- [8] 李红冲,陈勋俊,刘国强,等. 城镇居民生活用水量预测及用水需求量影响因素分析[J]. 水电能源科学, 2022, 40(9):52-55.

Water Consumption Prediction Based on Multi-layer Long and Short Term Memory Neural Network

WANG Jian, LIU Li, ZHA Chun-ying, CHEN Guo-wei

(School of Civil and Hydraulic Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: Timely and accurate forecasting residential water consumption is critical to design and operational management of water supply systems. Long short-term memory (LSTM) is an effective data-driven prediction model for water consumption, but it usually relies on a large number of parameter settings. This paper proposed a multilayer long short-term memory neural network model (MLSTM), which was built on the LSTM model by superimposing a time distribution module. The results indicate that the MLSTM model has lower complexity and higher prediction accuracy than the LSTM model, especially for the prediction of peak water consumption with M_{MAPE} reduced by about 60%. Meanwhile, the MLSTM model is insignificantly affected by external environmental conditions (e. g., weather).

Key words: residential water consumption; long short-term memory; time distributed module; multilayer long short-term memory; prediction accuracy