

袁卓异,李勇刚. 基于集成 LSTM 的泵站供水流量智能预测方法[J]. 湖南科技大学学报(自然科学版), 2023, 38(1):68-75. doi:10.13582/j.cnki.1672-9102.2023.01.009

YUAN Z Y, LI Y G. Intelligent Prediction Method of Water Supply Flow in Pump Station Based on Integrated LSTM [J]. Journal of Hunan University of Science and Technology (Natural Science Edition), 2023, 38(1):68-75. doi:10.13582/j.cnki.1672-9102.2023.01.009

基于集成 LSTM 的泵站供水流量智能预测方法

袁卓异¹, 李勇刚^{2*}

(1. 湖南华博信息技术有限公司, 湖南长沙 410035; 2. 中南大学 自动化学院, 湖南长沙 410083)

摘要: 城市二次加压供水泵站的供水流量预测是实现清水池补水、蓄水的依据,也是保证居民用水安全的前提。针对泵站供水流量受线性、非线性和时变等多种因素影响,导致传统模型的预测效果较差的问题,提出了一种基于长短时记忆网络与整合移动平均自回归模型相结合(LSTM-ARIMA)的方法,建立泵站供水流量集成预测模型。首先将获取到的供水流量数据按照时间日期进行打标签及预处理;然后将处理后的数据分别放入 LSTM 模型和 ARIMA 模型中进行训练与测试,通过统计分析 2 个模型的历史预测准确次数来确定它们各自的基本权重,并在预测过程中自适应修正权重;最后,基于对应权重将 2 个模型集成,得到最终的供水流量预测结果。某供水泵站的现场数据验证表明:本文方法所得结果与其他 2 种方法所得的预测结果在均方根误差(RMSE)上分别降低了 51.24% 和 66.52%,在平均绝对误差(MAE)上分别降低了 49.84% 和 67.02%,验证了模型的有效性。

关键词: LSTM; ARIMA; 供水流量预测; 集成模型

中图分类号: TP277 **文献标志码:** A **文章编号:** 1672-9102(2023)01-0068-08

Intelligent Prediction Method of Water Supply Flow in Pump Station Based on Integrated LSTM

YUAN Zhuoyi¹, LI Yonggang²

(1. Hunan Huabo Information Technology Co., Ltd., Changsha 410035, China;

2. School of Automation, Central South University, Changsha 410083, China)

Abstract: The prediction of water supply flow of urban secondary pressurized water supply pump station is the basis to realize water replenishment and storage of clear water pool, and also the premise to ensure water safety of residents. Aiming at the problem that the water supply flow of pumping stations is affected by linear, nonlinear and time-varying factors, which leads to the poor prediction effect of traditional models, a method based on the combination of deep learning long and short-term memory network and integrated moving average autoregressive model (LSTM-ARIMA) is proposed to establish an integrated prediction model of water supply flow of pumping stations. Firstly, the water supply flow data obtained are labeled and preprocessed according to the time and date. Then, the processed data are put into LSTM model and ARIMA model respectively for training and testing. The basic weights of the two models are determined by statistical analysis of the historical prediction accuracy times of the two models, and the weights are modified adaptively in the prediction process. Finally, the two models are

收稿日期: 2022-09-30

基金项目: 国家自然科学基金资助重大项目(61890932)

* 通信作者, E-mail: liyonggang@csu.edu.cn

integrated based on the corresponding weights to obtain the final water supply flow prediction results. The field data of a water supply pump station is used to verify the effectiveness of the proposed method. The results obtained by the proposed method are compared with the prediction results obtained by the other two methods. The results show that the RMSE is reduced by 51.24% and 66.52% respectively, and the MAE is reduced by 49.84% and 67.02% respectively, which verifies the effectiveness of the model.

Keywords: LSTM; ARIMA; prediction of water supply flow; integrated model

随着城市化的不断发展,人们对生产和生活用水的需求不断增大,导致供水泵站的一次供水管网局部供水压力不稳定,部分区域往往存在用水高峰期供水压力不足,用户在该时段用水体验变差、加压泵站可供水量受限的问题^[1].针对这一问题,供水泵站通常会建造一定容量的清水池来适应外管网的用水需求变化,主要在用户用水高峰期对外管网补水、用水低谷期清水池自蓄水的方式满足外管网的用水需求.但通过清水池补蓄水存在 2 个问题:首先,清水池在供水过程中需经常调节水位,以避免部分清水长期滞留造成细菌、微生物等有害物质滋生的问题;其次,清水池池底随着使用时间的增长会沉淀部分杂质,当清水池水位低于某一固定值时,供水浊度会急剧上升.以上 2 个问题都将导致泵站供水质量不满足城市供水水质标准要求.因此,为了满足用户对用水量和用水水质的要求,有效预测泵站的供水量,提前准备相应的清水池蓄水量,对实现居民用水量稳定的前提下保证用水安全有着十分重要的现实意义.

泵站供水量与城市生活需水量息息相关.近年来,有大量的学者在城市生活需水量预测方面进行了研究,早期的预测方法主要有系统动力学^[2-4]、线性回归^[5-6]和时间序列分析^[7-9]等,这些方法在本质上是捕捉对象的线性关系,但由于需水量会受到节假日、天气、工业生产等多种非线性和时变因素的影响,使得这些方法在模拟需水量的随机波动方面受到限制^[10-12].随着计算机技术的发展,基于机器学习的模型预测受到了人们的广泛关注.其中,人工神经网络可以通过分析历史数据的变化规律从而建立非线性映射模型^[13-14],将节假日等敏感因素与需水量的变化有机结合,已被广泛应用于城市生活需水量的预测.赵宏等^[15]针对城市用水量数据具有非线性、时变等特点,提出一种基于径向基函数神经网络的用水量短期预测模型;王圃等^[16]通过离散小波变化对城市日供水量的时间序列进行空间重构后,采用 BP (Back Propagation) 神经网络模型进行预测,相比于单一 BP 神经网络可以更好地反映序列变化特性;Salloom T 等^[17]通过 SPNN 和 DCGRU 这 2 种神经网络模型对需水量进行预测,并将 PID 控制方法思想应用于每个时间步的预测当中,从而提高预测结果的准确性.

基于循环神经网络(RNN)模型改进的 LSTM 模型因其在时间序列数据方面具有高效的处理特性,也逐渐受到人们重视.郭冠呈等^[18]提出一种基于双向长短时记忆的循环神经网络模型,用于常州市某独立计量区域的入口水量预测,通过实例验证所提模型的有效性和稳定性;Zhang 等^[19]基于经验模态分解方法进行数据预处理,通过建立 LSTM 模型进行城市供水水质预测,提高水质检测的准确性;Cen 等^[20]基于 LSTM 模型,结合先验知识数据转移的方法实现原油价格的预测;李刚^[21]等通过对城市供水系统的历史流量进行分析,采用季节性 ARIMA 方法对区域性加压泵站运行方式建立了预测模型;Zhu H^[22]等提出一种基于长期、短期记忆网络的工程中常用的自回旋积分运动平均模型相结合的电凝反应器的去除速率的预测方法.

因此,利用 LSTM 模型进行供水流量的预测具有准确度高、实时性强的优点.由于供水流量随时间的变化具有明显的发展趋势,且单一的 LSTM 模型预测容易忽略序列本身存在的线性关系,故而本文采用在时间序列预测方面具有较高稳定性的 ARIMA 模型进行辅助补偿,通过 LSTM 模型和 ARIMA 模型的加权集成,有助于进一步提升供水预测模型的有效性,实现城市供水泵站的供水流量有效预测.

1 LSTM 和 ARIMA 模型理论

1.1 LSTM 模型

长短期记忆人工神经网络(Long Short-Term Memory, LSTM)是一种特殊形式的循环神经网络(Recurrent Neural Network, RNN).LSTM 的优点主要体现于通过增加 3 种门限(即输入门、遗忘门和输出门)和 1 个存储历史记忆的细胞单元,调节自循环过程中不同时刻各连接节点之间的权重系数,避免网络

训练过程中出现梯度膨胀或梯度消失的问题^[23].LSTM 基本结构如图 1 所示.




图 1 LSTM 基本结构

图 1 中: x_t 为当前细胞的输入; h_{t-1} 为前一时刻细胞的输出; c_t 为细胞的状态; f_t, i_t 和 o_t 分别为遗忘门、输入门和输出门.

1.1.1 遗忘门

遗忘门可以决定前一时刻细胞状态 (c_{t-1}) 中的信息可以保留多少,当 f_t 的值越大,表示该位置保留的历史信息越多,反之,则越少.其计算公式为

$$f_t = \sigma(w_f x_t + u_f h_{t-1} + b_f). \quad (1)$$

式中: w_f 为输入节点与输入层之间的权值; u_f 为输入节点与隐藏层之间的权值; b_f 为输入层的偏置项; σ 为激活函数.

通过使用激活函数将细胞的输出转为非线性,以增加网络的非线性特征.本文将 σ 取为 Sigmoid 函数:

$$\sigma(x) = \frac{1}{1 + e^{-x}}. \quad (2)$$

1.1.2 输入门

与传统的 RNN 相比,LSTM 的一个显著特征在于可以通过输入层控制当前层的哪些信息作为细胞的更新信息.其计算公式为^[25]:

$$i_t = \sigma(w_i x_t + u_i h_{t-1} + b_i); \quad (3)$$

$$\tilde{c}_t = \tanh(w_c x_t + u_c h_{t-1} + b_c). \quad (4)$$

式中: \tilde{c}_t 为细胞的更新信息.

根据 LSTM 基本结构图(图 1)可知:在已知细胞的更新信息后,需要开始对细胞的状态进行更新,计算公式为

$$c_t = f_t \otimes c_{t-1} + i_t \otimes \tilde{c}_t. \quad (5)$$

1.1.3 输出门

图 1 中, o_t 为输出门,但该输出门的直接输出不是最终输出值,要得到细胞的最终输出,还需通过一个 sigmoid 激活函数来确定要传递的细胞状态信息的比例,然后通过一个 tanh 激活函数将更新好的细胞状态信息进行处理,从而得到相同的动态范围值,最后将该值与 Sigmoid 激活函数的输出值进行合成,得到一个 LSTM 单元的最终输出,计算公式分别为

$$o_t = \sigma(w_o x_t + u_o h_{t-1} + b_o); \quad (6)$$

$$h_t = o_t \otimes \tanh(c_t). \quad (7)$$

LSTM 网络基于反向传播算法与梯度下降结合的方式进行训练,通过将每个时刻的误差项逐层向上传递以更新网络层权重,从而使损失函数最小化.为了更好地评价预测性能,本文采用平均相对误差(MRE)、均方根误差(RMSE)和平均绝对误差(MAE)作为评价指标,以反映预测值与实际值之间的偏离情况,它们的计算公式如式(8)~式(10)所示^[23].

1) 平均相对误差(MRE)

$$\text{MRE} = \frac{1}{N} \sum_{t=1}^N \frac{|\hat{y}_t - y_t|}{y_t}. \quad (8)$$

2) 均方根误差 (RMSE)

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2}. \quad (9)$$

3) 平均绝对误差 (MAE)

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i). \quad (10)$$

式中: N 为样本数据量; \hat{y}_i 为 t 时刻的预测值; y_i 为 t 时刻的实际值; \bar{y}_i 为实际值的平均值.

1.2 ARIMA 模型

整合移动平均自回归模型 (Autoregressive Integrated Moving Average Model, ARIMA) 可通过对历史时间序列的统计分析和曲线拟合推断出该序列的发展趋势^[24], 因而在工程上常被用于时间序列数据的预测. ARIMA 模型主要由自回归模型 (AR) 和移动 s 平均模型 (MR) 以及差分法组成^[25] 数学表达式为

$$\hat{y}_i = \varphi_1 y_{i-1} + \varphi_2 y_{i-2} + \cdots + \varphi_p y_{i-p} + \varepsilon_i - u_1 \varepsilon_{i-1} - u_2 \varepsilon_{i-2} - \cdots - u_q \varepsilon_{i-q}. \quad (11)$$

式中: \hat{y}_i 为 t 时刻的 ARIMA 模型输出; y 为历史样本数据; ε 为零均值白噪声时间序列; φ 为自回归系数; u 为移动平均系数; p 为自回归模型阶数; q 为移动平均模型阶数.

ARIMA 模型的具体步骤: 首先, 需要对时间序列数据进行平稳性检验, 以确定差分项 d 的取值; 然后, 通过自相关图 (ACF) 和偏自相关图 (PACF) 分析确定模型的 p 阶数和 q 阶数; 最后, 将时间序列数据放入模型中进行训练和测试, 得到最终的预测结果.

2 供水流量集成预测模型

泵站给用户供水过程中, 不同时间段的用水需求会有所不同, 因此, 供水流量会随时间的变化而改变. LSTM 网络通过使用 3 种门对存储单元的状态进行调节, 这种网络结构可以高效地处理与时间存在依赖关系的时序数据, 因此, 采用具有高效处理特性的长短期记忆网络 (LSTM) 对自来水泵站的供水流量进行预测. 同时, 由于供水流量的变化会随时间发展呈现出一种特定趋势, 因此本文利用稳定性较高的 ARIMA 模型进行辅助补偿. 系统研究方案为首先分别采用 LSTM 模型和 ARIMA 模型对供水流量进行预测, 通过统计分析它们的历史预测值与实际工业数据之间的误差, 确定 LSTM 模型和 ARIMA 模型各自所占权重, 最后将这 2 个模型分别与对应的权重相乘后相加, 得到最终的供水流量预测值.

2.1 数据预处理

由于供水流量数据较大, 导致不同时间段的供水流量相差较大, 使得模型在训练过程中存在困难. 为了允许模型变量能够在不同量化尺度下进行比较, 同时提高模型训练效果, 需要将获取到的原始数据进行归一化预处理, 使归一化后的数据处于 0~1 的范围. 归一化处理公式为

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}}. \quad (12)$$

式中: x 为供水流量; x_{\min} 为供水流量的最小值; x_{\max} 为供水流量的最大值.

2.2 基于 LSTM-ARIMA 的供水流量集成预测模型

根据供水泵站的供水经验可知, 每日的不同时间段供水流量有所不同, 同时, 平常日 (周一—周五) 和周末 (周六—周日) 的供水流量也会存在一定差别, 因此, 为了提高 LSTM 模型的学习效率, 将获取到的供水流量数据按照时间和日期打标签, 并将该标签与对应的流量数据共同作为 LSTM 模型的输入变量. 将各变量的数据集按照设定好的比例划分为训练集和测试集, 通过测试全连接层层数与迭代次数等, 训练和测试网络模型, 得到本文的 LSTM 模型整体结构如图 2 所示.

同时, 将历史的供水流量数据放入 ARIMA 模型中进行训练. 在建立 ARIMA 模型的时候, 需要保证时间序列数据是稳定的, 如果不稳定则需要通过差分化将其转换成稳定的序列, 才能对数据进行较准确的预




图 2 LSTM 模型结构

测.本文根据 ADF 检验原理判断确定得到 ARIMA 模型的参数 d 为 0,同时通过对时间序列的自相关图(ACF)和偏自相关图(PACF)分析,确定模型的 p, q 阶分别为 3 和 0.

在分别得到 LSTM 模型和 ARIMA 模型的历史预测值后,计算其与对应的实际值之间的偏差,对于偏差较小的预测值则为对应的模型累计一次准确次数,最终按照不同模型准确次数的得分计算 2 种模型的权重大小.若 2 种模型在某一时刻的预测偏差相等,则该时刻的数据点直接被忽略(即 2 种模型的准确次数不予累计),具体判断过程如图 3 所示.

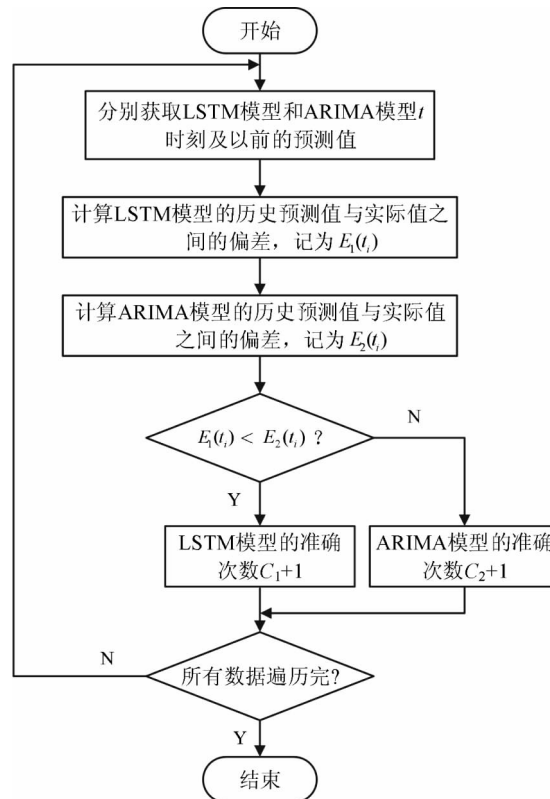


图3 LSTM模型和ARIMA模型预测值的准确次数判断

将 LSTM 模型和 ARIMA 模型累计的准确次数分别除以 t 时刻及以前的历史数据长度,得到的值作为 2 个模型所占的基本权重比.通过 LSTM 模型和 ARIMA 模型分别预测 $t+1$ 时刻的供水流量,将这 2 个模型得到的预测值分别乘以对应的权重后相加,得到供水流量的集成预测值,其计算公式^[20]为

$$\hat{y}(t+1) = \omega_1 \hat{y}_{\text{LSTM}}(t+1) + \omega_2 \hat{y}_{\text{ARIMA}}(t+1). \quad (13)$$

式中: $\hat{y}(t+1)$ 为 $t+1$ 时刻供水流量的集成预测值; $\hat{y}_{\text{LSTM}}(t+1)$ 为 $t+1$ 时刻 LSTM 模型得到的供水流量预测值; $\hat{y}_{\text{ARIMA}}(t+1)$ 为 $t+1$ 时刻 ARIMA 模型得到的供水流量预测值; ω_1 和 ω_2 为 LSTM 模型和 ARIMA 模型所占的基本权重,由于该基本权重是基于历史的预测结果统计分析得来,缺乏对实时数据的适应性,为此,本文在实时预测过程中根据前一时刻的预测误差对比,自适应修正对应模型的权重大小.

3 实例验证与分析

为了验证本文所提预测方法的有效性,以湖南某区域供水泵站为研究对象,选取 2021 年 11 月和 12 月的供水流量数据用于实例验证和分析(共 8 784 组数据,其中每组数据采集的时间间隔为 10 min/次).按照设定好的比例划分训练数据集用于 LSTM 模型和 ARIMA 模型的训练,最后利用 144 组数据进行模型测试和验证.将本文方法得到的预测结果分别与 LSTM 模型和 ARIMA 模型的预测结果进行比较,对比结果分别如图 4 和图 5 所示.




图 4 本文方法与单一 LSTM 模型的平常日供水流量预测结果对比




图 5 本文方法与单一 ARIMA 模型的平常日供水流量预测结果对比

从图 4 和图 5 可以看出:通过本文方法得到的供水流量的预测值相较于单一的 LSTM 模型和 ARIMA 模型的预测值更接近于实际工业数据.为了更好地对本文方法、LSTM 模型和 ARIMA 模型的预测效果进行对比分析,采用平均相对误差(MRE)、均方根误差(RMSE)和平均绝对误差(MAE)作为预测性能的评价指标,对多模型性能进行比较分析.得出的预测误差如图 6 所示,它们的对比结果如表 1 所示.

根据图 6 和表 1 可以更加清楚地看到,本文所提方法的预测结果相比于单一的 LSTM 模型和 ARIMA 模型结果的相对误差更小, RMSE 分别降低了 33.5 和 70.3.同时,从 MAE 的对比可以看出:本文方法与工业数据的拟合程度更高,说明本文方法能够提升预测的准确度.




图 6 平常日供水流量预测误差对比

表 1 平常日供水流量在不同方法的预测结果对比

方法	MRE/%	RMSE	MAE
LSTM 模型	4.5	114.8	89.6
ARIMA 模型	6.2	151.6	120.1
本文方法	3.1	81.3	58.1

上述实例验证预测的是平常日(周一—周五)的居民供水流量,由于周末(周六—周日)的供水流量随时间变化情况与平常日的有所不同,为了进一步验证本文方法的可靠性,采用周末的 144 组供水流量数据进行测试分析,得到本文方法和单一 LSTM 模型、ARIMA 模型的预测效果对比分别如图 7 和图 8 所示,它

们的预测误差对比如图9所示,预测效果分析具体如表2所示.




图7 本文方法与单一 LSTM 模型的周末供水流量预测结果对比

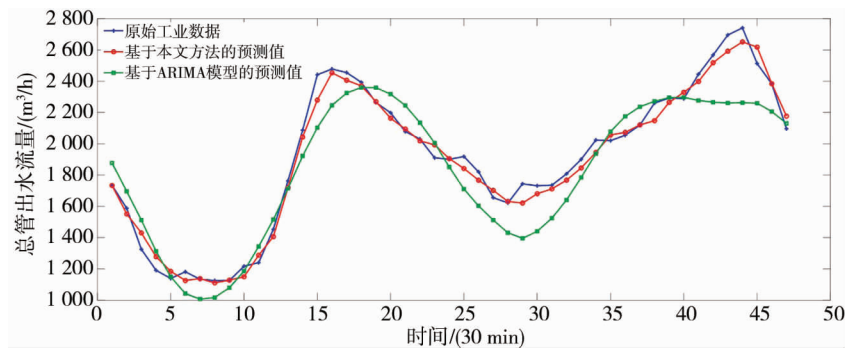


图8 本文方法与单一 ARIMA 模型的周末供水流量预测结果对比




图9 周末供水流量预测误差结果对比

表2 周末供水流量在不同方法的预测结果对比

方法	MRE/%	RMSE	MAE
LSTM 模型	4.96	124.7	94.7
ARIMA 模型	7.53	181.6	144.03
本文方法	2.58	60.8	47.5

从图7和图8可以看出:本文方法在预测周末供水流量方面也具有较高的准确性.同时,根据图9和表2可知:相对单一 LSTM 模型和 ARIMA 模型而言,本文方法的总体误差最小,MAE 最低.因此,应用本文方法能够实现供水泵站供水流量较为准确的预测.

4 结论

- 1) 本文融合了 LSTM 模型和 ARIMA 模型的优点,建立城市二次加压泵站的供水流量集成预测模型.
- 2) 本文所提出方法得到的预测值相较于 LSTM 方法和 ARIMA 方法,在 MRE 上分别降低了 47.98% 和 65.74%,在 RMSE 上分别降低了 51.24% 和 66.52%,在 MAE 上分别降低了 49.84% 和 67.02%,供水流量预

测值与实际值更为接近,具有较高的准确性,为供水泵站水位的控制奠定了基础。

参考文献:

- [1] 孙立生.无负压供水技术在二次供水系统中的应用[J].中国新技术新产品,2018(13):79-80.
- [2] 罗小鹏.基于水系连通的郑州市水资源优化配置研究[D].郑州:华北水利水电大学,2020.
- [3] 陈颖杰,金保明,金君良,等.变化环境下考虑物理机制的 SD 需水预测研究[J].水利水运工程学报,2021(3):84-95.
- [4] 秦欢欢,赖冬蓉,万卫,等.基于系统动力学的北京市需水量预测及缺水分析[J].科学技术与工程,2018,18(21):175-182.
- [5] GAO C, LV K, WU T, et al. Method for Determining Starting Point of Rolling Bearing Life Prediction Based on Linear Regression[J]. Electronics, 2019, 8(9):923.
- [6] ADJENUGHWURE K, PAPAPOPOULOS B. Constructing fuzzy-statistical prediction intervals from crisp linear regression models[C]//CENTRAL EUROPEAN SYMPOSIUM ON THERMOPHYSICS 2019 (CEST), 2019, 2116(1): 440007.
- [7] ZHAO L. Prediction model of ecological environmental water demand based on big data analysis[J]. Environmental Technology & Innovation, 2021, 21: 101196.
- [8] LIU Z, ZHU Z, GAO J, et al. Forecast Methods for Time Series Data: A Survey[J]. IEEE Access, 2021, 9: 91896-91912.
- [9] MCALINN K, WEST M. Dynamic Bayesian predictive synthesis in time series forecasting[J]. Journal of Econometrics, 2019, 210(1): 155-169.
- [10] 韩宏泉,吴珊,侯本伟.采用核极限学习机的短期需水量预测模型[J].哈尔滨工业大学学报,2022,54(2):17-24.
- [11] LAN Y, WANG J, BAI M, et al. A hybrid model based on stacking and multi-correction mechanisms for urban water demand prediction[J]. IFAC-PapersOnLine, 2020, 53(2): 16685-16690.
- [12] DU B, HUANG S, GUO J, et al. Interval forecasting for urban water demand using PSO optimized KDE distribution and LSTM neural networks[J]. Applied Soft Computing, 2022, 122: 108875.
- [13] 蔡逢煌.二次供水系统用水模型与管网状态预测[J].厦门大学学报(自然科学版),2001(s1):94-97.
- [14] ZHU H, HUANG Z, LU B, et al. Bearing remaining useful life prediction of fatigue degradation process based on dynamic feature construction[J]. International Journal of Fatigue, 2022, 164: 107169.
- [15] 赵宏.基于 RBF 网络的城市供水短期负荷预测[C]//Proceedings of 2011 International Conference on Fuzzy Systems and Neural Computing(FSNC 2011 V4), 2011: 42-45.
- [16] 王圃,唐鹏飞,白云,等.基于多分辨 BP 神经网络的城市日供水量预测模型[J].中国给水排水,2018,34(11):51-55.
- [17] SALLOOM T, KAYNAK O, YU X, et al. Proportional integral derivative booster for neural networks-based time-series prediction: Case of water demand prediction[J]. Engineering Applications of Artificial Intelligence, 2022, 108: 104570.
- [18] 郭冠呈,刘书明,李俊禹,等.基于双向长短时神经网络的水量预测方法研究[J].给水排水,2018,54(3):123-126.
- [19] ZHANG Y, LI C, JIANG Y, et al. Accurate prediction of water quality in urban drainage network with integrated EMD-LSTM model[J]. Journal of Cleaner Production, 2022, 354: 131724.
- [20] CEN Z, WANG J. Crude oil price prediction model with long short term memory deep learning based on prior knowledge data transfer[J]. Energy, 2019, 169: 160-171.
- [21] 李刚,刘晓峰,雷楚武,等.城市供水系统中区域性加压泵站运行方式研究[J].城镇供水,2018(6):41-46.
- [22] ZHU H, WANG Q, ZHANG F, et al. A prediction method of electrocoagulation reactor removal rate based on Long Term and Short Term Memory-Autoregressive Integrated Moving Average Model[J]. Process Safety and Environmental Protection, 2021, 152: 462-470.
- [23] 李占利,邢金莎,靳红梅,等.基于 EMD 和时序注意力机制的明渠流量预测模型[J].高技术通讯,2022,32(2): 122-130.
- [24] 郑浩然,潘雨青,李世伟,等.基于季节性 ARIMA 模型的小区供水预测[J].计算机应用与软件,2018,35(1):118-122.
- [25] BIN SHAARI M A, SAMSUDIN R, BIN SHABRI ILMAN A. Comparison of drought forecasting using ARIMA and empirical wavelet Transform-ARIMA[C]//IRICT 2017: Recent Trends in Information and Communication Technology, 2017: 449-458.