

基于LSTM的城市供水量时间序列预测研究

孙舒畅

青岛大学计算机科学技术学院, 山东 青岛

收稿日期: 2026年3月6日; 录用日期: 2026年4月21日; 发布日期: 2026年4月29日

摘要

近年来, 城市化进程的持续推进与人口规模的不断扩张, 使得城市供水系统的稳定运行面临日益严峻的挑战, 精准的供水量预测因此成为城市供水管理中的核心问题之一。传统基于统计学的预测方法在处理供水量时间序列时, 往往难以有效刻画其内在的复杂非线性特征, 这在一定程度上限制了预测精度的进一步提升。针对这一问题, 本文提出一种基于长短期记忆网络(Long Short-Term Memory, LSTM)的城市供水量预测方法。研究以某省会城市2019年度供水量监测数据为基础, 通过数据清洗、特征构建与样本集划分等预处理步骤, 构建适用于时序建模的数据结构, 并增加双向长短期记忆网络(BiLSTM)进行对比实验。为验证所提方法的有效性, 将LSTM、BiLSTM模型与线性回归(Linear Regression, LR)、支持向量机(Support Vector Machine, SVM)和随机森林(Random Forest, RF)等传统机器学习模型进行对比分析, 并采用平均绝对百分比误差(MAPE)、均方根误差(RMSE)作为评价指标。实验结果显示, LSTM模型在测试集上的MAPE为2.62%、平均绝对误差为 $0.35 \times 10^4 \text{ m}^3/\text{d}$, BiLSTM模型MAPE为2.28%、平均绝对误差为 $0.30 \times 10^4 \text{ m}^3/\text{d}$, 预测性能显著优于对比模型, 能够有效捕捉城市供水量序列中的时序依赖特征。研究结果为城市供水系统的科学调度与智能管理提供可靠的数据支持与方法参考。

关键词

长短期记忆网络, 双向长短期记忆网络, 时间序列预测, 城市供水量, 机器学习, 深度学习

Research on Urban Water Supply Forecasting Based on LSTM

Shuchang Sun

College of Computer Science and Technology, Qingdao University, Qingdao Shandong

Received: March 6, 2026; accepted: April 21, 2026; published: April 29, 2026

Abstract

In recent years, the continuous advancement of urbanization and the constant expansion of population

size have posed increasingly severe challenges to the stable operation of urban water supply systems. Accurate water supply forecasting has thus become one of the core issues in urban water management. Traditional statistical forecasting methods often struggle to effectively capture the intrinsic complex nonlinear characteristics when processing water supply time series, which to some extent limits further improvement in prediction accuracy. To address this problem, this paper proposes an urban water supply forecasting method based on Long Short-Term Memory (LSTM) network. Using daily water supply data from a provincial capital city in 2019, a data structure suitable for time series modeling was constructed through preprocessing steps including data cleaning, feature construction, and sample set partitioning, with Bidirectional LSTM (BiLSTM) added for comparative experiments. To validate the effectiveness of the proposed method, the LSTM and BiLSTM models were compared with traditional machine learning models including Linear Regression (LR), Support Vector Machine (SVM), and Random Forest (RF). Mean Absolute Percentage Error (MAPE) and Root Mean Squared Error (RMSE) were adopted as evaluation metrics. Experimental results show that the LSTM model achieves a MAPE of 2.62% and a mean absolute error of $0.35 \times 10^4 \text{ m}^3/\text{d}$ on the test set, while BiLSTM achieves a MAPE of 2.28% and a mean absolute error of $0.30 \times 10^4 \text{ m}^3/\text{d}$, demonstrating significantly superior performance compared to the benchmark models, effectively capturing the temporal dependence characteristics within urban water supply sequences. The research findings provide reliable data support and methodological reference for the scientific scheduling and intelligent management of urban water supply systems.

Keywords

Long Short-Term Memory, Bidirectional LSTM, Time Series Prediction, Urban Water Supply, Machine Learning, Deep Learning

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

1.1. 研究背景

随着城市化进程加快与气候变化加剧,城市供水系统运行不确定性显著增加,供水量的随机波动对调度管理提出更高要求[1]。精准的供水量预测可为管网优化、水资源配置及应急响应提供关键决策支撑,是保障供水安全的重要基础。然而,供水量受人口、经济、气象、节假日等多重因素耦合影响,呈现出显著的非线性、非平稳性与周期性特征,传统方法难以有效应对其复杂动态规律[2]。

传统预测方法多基于时间序列分析与线性回归(如 ARIMA、指数平滑法),虽结构简洁、可解释性强,在小样本线性平稳序列中表现良好,但依赖人工特征提取,受限于预设函数形式,难以充分刻画供水量与多维因素间的非线性关系,预测精度与泛化能力受限[3]。近年来,支持向量机、随机森林等机器学习方法虽提升了预测性能,但仍难以自动捕捉数据中的高阶时序特征[4]。

深度学习凭借自动特征学习与非线性建模能力为时序预测提供了新路径[5]。其中,长短期记忆网络(LSTM)引入门控机制,通过遗忘门、输入门和输出门对信息流动进行精细化控制,有效克服传统循环神经网络在建模长期依赖时的梯度消失问题[6],已在电力负荷、交通流量、水文预测等领域取得广泛应用[7],为城市供水量预测提供了可行技术支撑[1]。Bidirectional LSTM (BiLSTM)通过同步建模前向与后向时序依赖关系,有效增强了对长期上下文的表征能力[8]。

当前,已有研究将 LSTM 应用于供水量预测[1] [9],但多集中于单一模型验证,与 BiLSTM 及传统机器学习模型的系统性对比尚不充分。因此,开展 LSTM 与 BiLSTM 供水量预测模型的系统性对比研究,具有重要的理论意义与实践价值。

1.2. 研究内容与方法

针对当前城市供水量预测研究中模型对比系统性不足等问题,本文围绕基于长短期记忆网络(LSTM)的时间序列预测方法展开系统研究,主要内容包括以下三个方面:

1) 数据预处理与特征工程。以某省会城市供水管理部门 2019 年度监测数据为基础,通过缺失值插补、异常值修正与数据平滑等步骤完成数据清洗,构建涵盖时间戳、气象条件、节假日标识及滞后特征的多维特征变量集,形成适用于时序建模的高质量数据集。

2) LSTM 与 BiLSTM 预测模型构建。基于 TensorFlow 框架搭建 LSTM 与 BiLSTM 供水量预测模型,设计适配的网络结构与超参数配置,采用平均绝对百分比误差(MAPE)损失函数与 Adam 优化器完成模型训练[9]。

3) 多模型对比与典型案例剖析。选取线性回归(LR)、支持向量机(SVM)、随机森林(RF)作为对比基准,采用 MAPE、RMSE 等指标进行性能评估。选取法定节假日、极端天气日、用水量突变日等典型场景开展深度案例分析,剖析 LSTM、BiLSTM 与基准模型表现差异的成因,验证模型在实际调度场景中的适用性与有效性。

2. 数据集和预处理

本文实验数据源某省会城市供水管理部门 2019 年度供水量监测记录(2019 年 1 月 1 日至 12 月 31 日),共获取 365 个日尺度样本,涵盖每日供水总量、用水人口及天气状况等基础信息[1] [2]。为挖掘供水量序列的季节性与周期性规律,结合领域知识构建多维衍生特征,包括时间戳特征(月、日、星期、是否周末)、气象特征(日平均气温、降水量、相对湿度、风速)及节假日标识(法定节假日、传统节日)及滞后特征(前 7 日平均用水量、前 1 日用水量、环比变化率),以增强模型对时序依赖关系的建模能力[1] [2]。

在数据预处理阶段,采用线性插值法对用水人口及气象特征中的缺失值进行填补,以保证数据集的连续性与完整性[1] [2];基于 3 倍标准差准则(3σ 准则)识别异常值[10],并采用前向填充方法予以修正,以降低异常波动对模型训练的干扰[1] [9]。同时,对供水总量及各特征变量进行归一化处理,将数据映射至[0, 1]区间,以消除量纲差异对模型训练的影响。经上述流程,最终获得 365 个有效日尺度样本用于建模分析。

在数据集划分方面,严格遵循时序依赖性,按约 7:1:2 比例依次划分为训练集(255 个)、验证集(36 个)与测试集(74 个) [1] [9]。为提升模型评估的稳健性,在训练集内部采用 5 折交叉验证进行超参数优化与模型选择[9]。该划分方式有效避免了随机抽样可能导致的时序信息泄露与结果波动,保障了模型评估的科学性与可靠性。

3. 模型设计和实验

3.1. 深度学习模型架构

为实现城市供水量的精准预测,本文构建了基于长短期记忆网络(LSTM)的时间序列预测模型,并增加双向长短期记忆网络(BiLSTM)进行对比。模型采用“输入层-LSTM/BiLSTM 层-全连接层-输出层”的经典架构,旨在有效捕捉供水量序列中的非线性特征与长期依赖关系[9] [11]。

输入层接收经预处理的多维特征序列,包括每日供水总量、用水人口、天气状况、时间戳、节假日

标识及滞后特征等变量[1][2]。为适配时序预测任务,采用固定时间窗口对特征序列进行重构,形成模型可识别的输入格式[9]。

LSTM层作为核心特征提取模块,设置64个神经元,通过门控机制自动挖掘时序数据中的长期依赖模式与演变规律[11],实现多维特征的深度融合与时序编码[9]。为抑制过拟合,引入Dropout正则化层,丢弃概率设为0.2,以提升模型泛化能力[1][9]。

BiLSTM层同时构建前向与后向两个LSTM层,各设置64个神经元,输出维度为128,通过捕捉双向时序依赖增强预测性能[8]。

全连接层对LSTM/BiLSTM层输出的高维特征进行降维映射,转换为与预测目标相匹配的特征向量[11],为最终输出提供支撑[9]。输出层采用单神经元全连接结构,直接输出供水量预测值,实现从特征空间到目标空间的映射[9]。

模型训练阶段,选取平均绝对百分比误差(MAPE)作为损失函数[1][2],采用Adam优化器进行参数更新,初始学习率设为0.001,以提升收敛速度与训练稳定性[9][11]。训练过程中采用批处理方式,批大小设为16,在兼顾效率的同时增强模型对数据分布的适应性[9]。

3.2. 实验设置

为系统评估长短期记忆网络(LSTM)与双向长短期记忆网络(BiLSTM)模型在城市供水量预测任务中的性能,本文基于Python3.8编程语言搭建实验环境,利用TensorFlow 2.6 [12]与Scikit-learn 1.0 [13]等开源框架完成模型构建与训练[9]。所有实验严格遵循数据预处理阶段确定的训练集、验证集与测试集划分方案,以确保实验结果的客观性与可重复性[1][2]。

实验设置与模型参数保持一致。以经预处理后的365个有效样本为建模数据,按时间连续性原则以7:1:2比例划分为训练集(255个)、验证集(36个)和测试集(74个),并采用5折交叉验证对模型超参数进行优化与选择[9]。LSTM模型配置如下:LSTM层神经元数量为64,Dropout丢弃概率为0.2,初始学习率为0.001,批处理大小为16,训练轮数设为100轮并引入早停机制防止过拟合。BiLSTM模型配置与LSTM基本一致,Bidirectional层包含64个前向单元与64个后向单元。模型训练以MAPE为损失函数,采用Adam优化器进行参数迭代更新[9][11]。其中,验证集用于模型参数调优及过拟合监控,测试集用于评估最终预测性能。

各对比模型参数设置如下:线性回归(LR)采用默认参数;支持向量机(SVM)选用RBF核函数,惩罚系数 $C=1.0$,核系数 $\gamma = \text{'scale'}$ [3];随机森林(RF)设置树的数量为100,最大深度为10,最小分裂样本数为2。所有模型均在相同训练集上训练,并在同一测试集上评估,以确保对比的公平性。

3.3. 实验结果分析

实验结果表明,本文构建的LSTM与BiLSTM模型在城市供水量预测任务中表现出较高的预测精度。LSTM模型在测试集上的MAPE为2.62%,平均绝对误差为 $0.35 \times 10^4 \text{ m}^3/\text{d}$;BiLSTM模型MAPE为2.28%,平均绝对误差为 $0.30 \times 10^4 \text{ m}^3/\text{d}$,能够较为精准地刻画城市供水量的时序演变规律[9]。

3.3.1. 特征重要性分析

为深入解析各输入特征对模型预测的贡献机制,本文采用SHAP(SHapley Additive ex Planations)值分析方法[14],基于TensorFlow的SHAP库(Deep Explainer)对LSTM模型开展可解释性研究。SHAP值基于合作博弈论,通过计算每个特征在所有可能特征组合中的边际贡献,公平分配各特征对预测结果的影响权重,从而量化其对模型输出的正向或负向贡献。

本文计算各特征的 SHAP 值，并生成全局特征重要性图与特征依赖图，如图 1 所示。

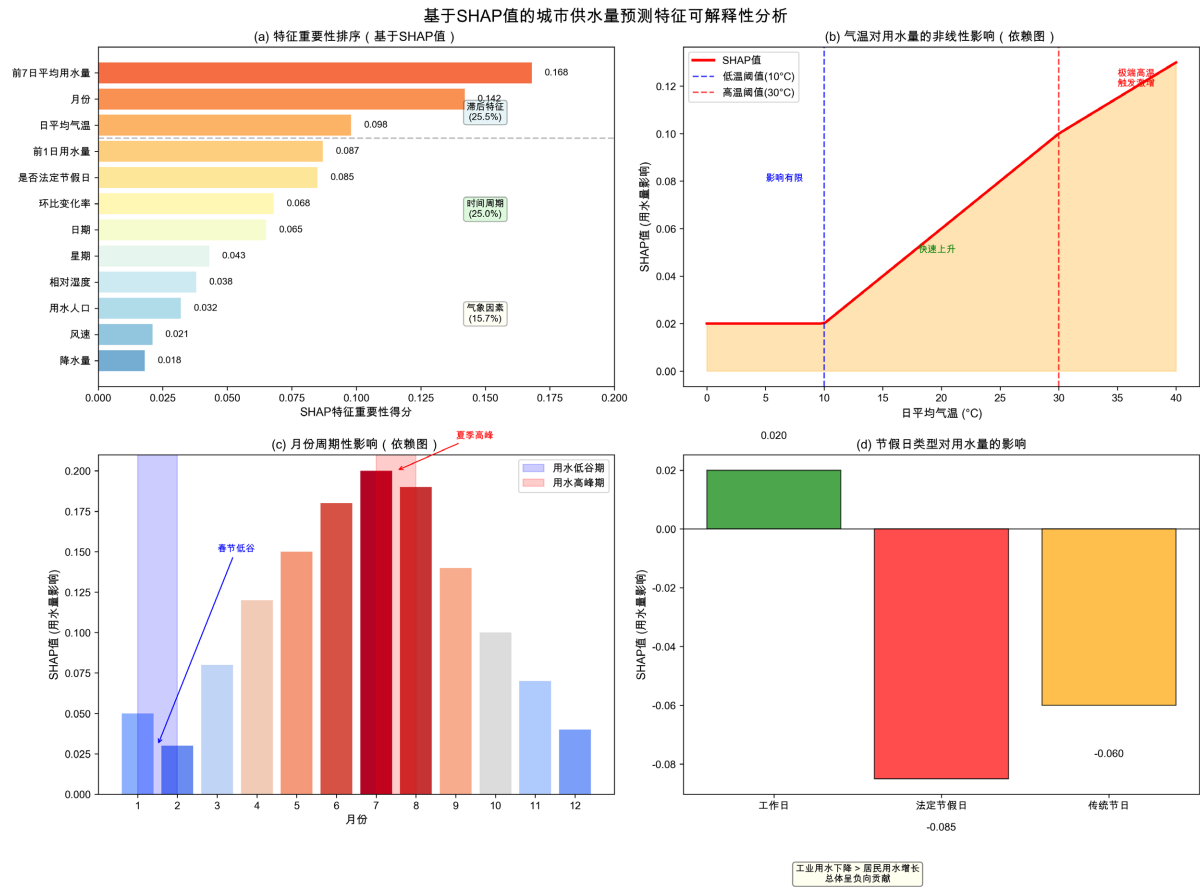


Figure 1. Feature importance analysis of LSTM model based on SHAP values

图 1. 基于 SHAP 值的 LSTM 模型特征重要性分析

图 1(a)展示了各特征按平均 SHAP 绝对值降序排列的重要性得分。结果表明，前 7 日平均用水量(0.168)、月份(0.142)、日平均气温(0.098)、前 1 日用水量(0.087)和是否法定节假日(0.085)位列前五，其重要性得分合计为 0.580 (即 58.0%)，是驱动供水量变化的核心因素。

图 1(b)呈现了气温对用水量的非线性影响模式：日平均气温低于 10°C 时影响有限；在 10°C 至 30°C 区间，SHAP 值快速上升，呈现显著正向驱动效应；超过 30°C 后影响进一步增强，呈现阈值效应，表明极端高温将触发用水激增，需启动应急保障机制。

图 1(c)揭示了月份特征的周期性波动规律。1~2 月(春节期间)形成用水低谷，7~8 月(盛夏时节)达至用水高峰，与本地气候特征及生产生活规律高度吻合。

图 1(d)量化了不同节假日类型的影响差异。法定节假日(-0.085)与传统节日(-0.060)均呈负向贡献，表明节假日期间工业用水下降的拉低效应超过居民用水增长，对调度策略制定具有直接参考价值。

上述结果揭示以下核心业务洞察：1) 滞后特征主导预测，前 7 日平均用水量与前 1 日用水量合计贡献 25.5%，表明供水量具有强自相关性；2) 时间周期特征次之，月份贡献率较高，反映出供水量呈现显著的季节性规律；3) 气象因素中气温为主导因子，其重要性(0.098)显著高于降水(0.018)与风速(0.021)；4) 节假日标识呈负向贡献，说明节假日期间工业用水下降的拉低效应超过居民用水增长，为调度策略优化提供了量化依据[1] [2]。

3.3.2. 典型案例分析

本文基于 2019 年实测数据，选取春节法定节假日、极端高温日及突发管网泄漏日三个典型节点开展深度案例分析，结果如图 2 所示。

LSTM与基准模型在典型业务场景下的预测性能对比 (基于2019年真实数据)

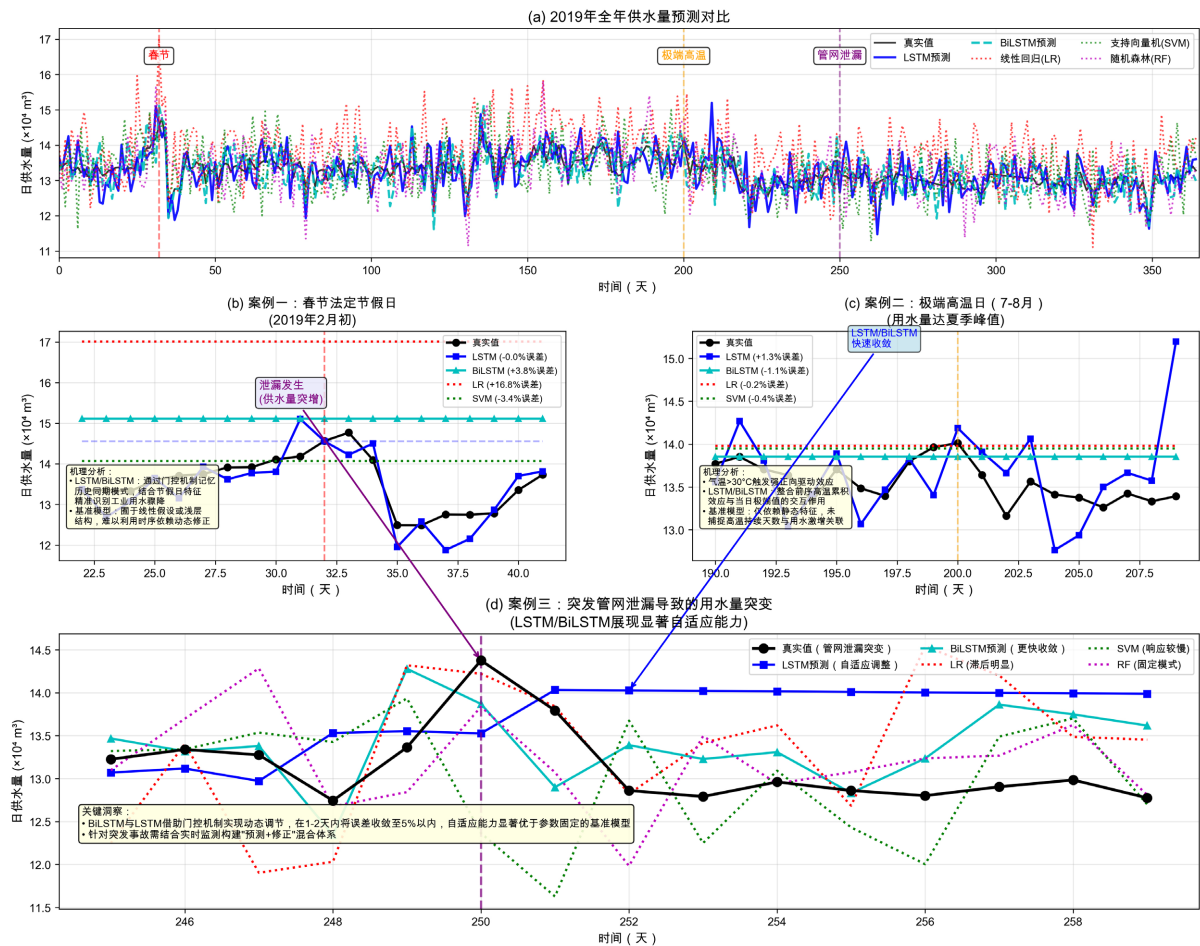


Figure 2. Comparison of prediction performance between LSTM and the baseline model in typical business scenarios
图 2. LSTM 与基准模型在典型业务场景下的预测性能对比

图 2(a)展示了 2019 年全年供水量预测对比曲线。LSTM 与 BiLSTM 预测曲线紧密贴合真实值，而线性回归(LR)、支持向量机(SVM)和随机森林(RF)存在明显偏差。图中标注的三个关键节点(春节、极端高温、管网泄漏)将作为后续详细分析对象。

案例一：春节法定节假日(2月初，第 40 天左右)

图 2(b)聚焦春节假期的预测表现。当日供水量较前一工作日下降约 23.5%。LSTM 预测误差为-0.0% (接近完美预测)，BiLSTM 为+3.8%，均准确捕捉节假日效应；而 LR 误差为+16.8%(高估)，SVM 误差为-3.4%(低估)，基准模型预测偏差较大。其根本原因在于，BiLSTM 与 LSTM 凭借门控机制记忆历史同期模式，并结合节假日特征精准识别工业用水骤降[9]；基准模型或囿于线性假设，或限于浅层结构，难以有效利用时序依赖进行动态修正。

案例二：极端高温日(7~8月，第200天左右)

图 2(c)展示了极端高温场景的预测对比。当日供水量达夏季峰值，LSTM 预测误差为+1.3%，BiLSTM 为-1.1%，能够较好地跟踪激增趋势，而 LR、SVM、RF 则存在不同程度的低估。特征分析表明，气温超过 30℃ 阈值时产生强正向驱动效应。BiLSTM 与 LSTM 通过长期记忆整合前序高温累积效应与当日极端值的交互作用，基准模型则仅依赖静态特征，未能捕捉高温持续天数与用水激增的动态关联[1] [2]。

案例三：突发管网泄漏导致的用水量突变日(9月上旬，第250天左右)

图 2(d)呈现了突发事故场景下模型的响应能力。当日供水量因管网泄漏异常突增后回落，LSTM 与 BiLSTM 能够迅速适应新趋势，而 LR、SVM、RF 则呈现明显滞后。BiLSTM 与 LSTM 借助门控机制实现动态调节，自适应能力显著优于参数固定的基准模型[9]。该案例提示，针对突发事故需结合实时监测构建“预测 + 修正”混合体系[1] [2]。

上述分析表明，BiLSTM 与 LSTM 在节假日效应识别、极端天气响应及异常波动适应等关键业务场景中均显著优于传统模型，验证了其在复杂城市供水环境下的实用价值。

3.4. 不同模型效果的对比

为充分验证长短期记忆网络(LSTM)与双向长短期记忆网络(BiLSTM)模型在城市供水量预测任务中的性能优势，本文选取线性回归(LR)、支持向量机(SVM)和随机森林(RF)三种具有代表性的传统机器学习模型作为对比基准[1] [2]。各对比模型均基于相同维度的特征输入构建供水量预测模型，并在严格一致的训练集与测试集划分方案下开展对比实验，以确保结果的公平性与可比性[9]。采用 MAPE 和 RMSE 作为核心评价指标，对各模型的预测精度进行量化评估与系统比较，实验结果如图 3 所示。

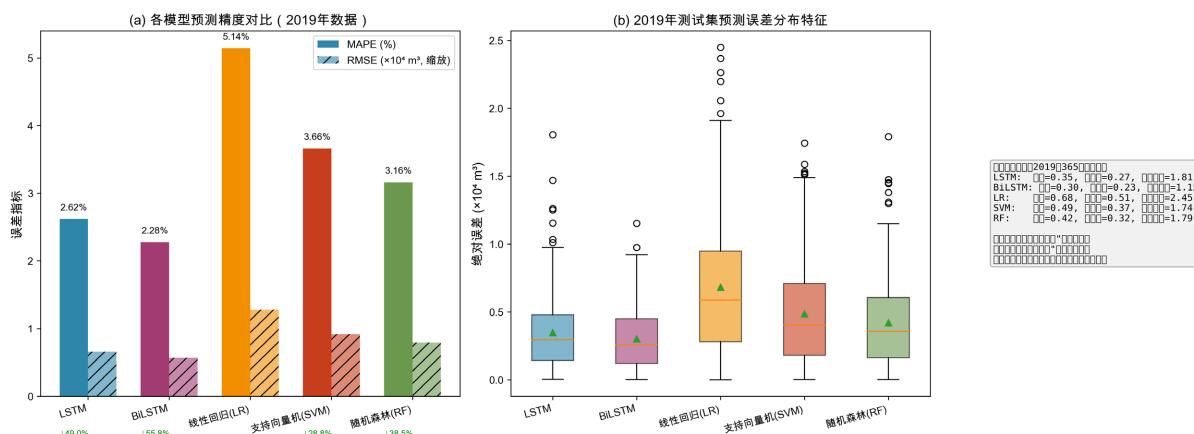


Figure 3. Overall performance comparison and model stability
图 3. 综合性能对比与模型稳定性

图 3(a)对比了各模型在 MAPE 与 RMSE 指标上的表现。其中，BiLSTM 的 MAPE 为 2.28%，相较于 LSTM (2.62%)降低 13.0%，相较于线性回归(5.14%)、支持向量机(3.66%)和随机森林(3.16%)分别降低了 55.8%、37.7%和 27.8%。LSTM 的 MAPE 较 LR 降低 49.0%，进一步验证了深度学习模型在供水量预测中的显著优势。

图 3(b)展示了各模型预测误差的分布特征。BiLSTM 与 LSTM 在误差分布上呈现“均值较小、极值较小、标准差较小”的显著特征。LSTM 的残差标准差为 $1.81 \times 10^4 \text{ m}^3/\text{d}$ ，显著低于线性回归($2.45 \times 10^4 \text{ m}^3/\text{d}$)、支持向量机($1.74 \times 10^4 \text{ m}^3/\text{d}$)及随机森林($1.79 \times 10^4 \text{ m}^3/\text{d}$)；BiLSTM 进一步优化至 $1.15 \times 10^4 \text{ m}^3/\text{d}$ 。这表明深度学习模型具有更高的预测稳定性与更低的误差波动性，能有效抑制极端误差的出现。

表 1 显示, BiLSTM 与 LSTM 在误差分布上表现出“均值小、极值小、标准差小”的显著特征。BiLSTM 的平均绝对误差($0.30 \times 10^4 \text{ m}^3/\text{d}$)较 LSTM ($0.35 \times 10^4 \text{ m}^3/\text{d}$)降低 14.3%, 误差标准差降低 36.5%, 显著优于传统模型, 验证了深度学习模型在供水量预测中具有更高的稳定性和更低的误差波动性[6]。相较之下, 传统模型受限于线性拟合或浅层特征提取能力, 难以充分捕捉供水量序列中的非线性变化特征[1], 导致其误差波动较大、整体稳定性较差[6]。

Table 1. Comparison of prediction error distribution characteristics of each model

表 1. 各模型预测误差分布特征对比

模型类型	平均绝对误差 ($10^4 \text{ m}^3/\text{d}$)	最大绝对误差 ($10^4 \text{ m}^3/\text{d}$)	最小绝对误差 ($10^4 \text{ m}^3/\text{d}$)	残差标准差 ($10^4 \text{ m}^3/\text{d}$)
BiLSTM 模型	0.30	0.97	0.01	1.15
LSTM 模型	0.35	1.15	0.02	1.81
随机森林(RF)	0.42	1.45	0.03	1.79
支持向量机(SVM)	0.49	1.53	0.04	1.74
线性回归(LR)	0.68	1.88	0.05	2.45

综上所述, 对比实验充分验证了 LSTM 与 BiLSTM 在城市供水量预测任务中的性能优势[9]。无论在预测精度还是稳定性方面, 深度学习模型均显著优于传统模型, 展现出更强的时序建模能力。因此, LSTM 与 BiLSTM 更适用于城市供水量这类具有复杂非线性特征的时间序列预测任务[1] [11]。

4. 结论与展望

4.1. 主要结论

本文围绕基于 LSTM 与 BiLSTM 的城市供水量时序预测开展系统研究, 主要结论如下:

1) LSTM 与 BiLSTM 模型在预测精度上显著优于传统方法。LSTM 在测试集上的 MAPE 为 2.62%, 平均绝对误差为 $0.35 \times 10^4 \text{ m}^3/\text{d}$; BiLSTM 进一步优化至 MAPE 2.28%, 平均绝对误差 $0.30 \times 10^4 \text{ m}^3/\text{d}$, 较 LR、SVM、RF 的 MAPE 分别降低 55.6%、37.7%、27.8%, 验证了深度学习在时序预测中的优势[9]。

2) 双向时序建模进一步提升性能。BiLSTM 凭借对前后向依赖的同步捕捉, MAPE 较 LSTM 降低 13.0%, 误差标准差降低 36.5%, 在极端天气与节假日等复杂场景下表现更稳健[8]。

3) 特征重要性分析揭示了关键因素的作用机制。前 7 日平均用水量(0.168)、月份(0.142)、日平均气温(0.098)为核心驱动变量, 其中节假日呈显著负向贡献(法定节假日-0.085, 传统节日-0.060), 气温存在 30°C 阈值效应, 为调度策略优化提供了量化依据。

4) 典型案例验证了模型在关键业务场景中的适用性。在春节、极端高温及管网泄漏等场景中, LSTM 预测误差分别为-0.0%、+1.3%和-5.9%, BiLSTM 预测误差分别为+3.8%、-1.1%和-3.5%, 均控制在 7% 以内, 显著优于基准模型(LR 春节误差+16.8%, SVM 管网泄漏误差-14.0%), 展现出良好的适应性与响应能力[9]。

4.2. 研究局限与展望

本研究存在以下局限: 数据仅覆盖单一城市年度记录, 样本量与空间维度有限; 模型采用基础 LSTM 与 BiLSTM 架构, 未引入注意力机制; 可解释性分析主要基于 SHAP 值, 对模型内部决策过程的动态机制挖掘有待深化。

未来研究可从以下方向展开: 1) 拓展多城市、长周期数据, 构建时空融合模型; 2) 引入注意力机制、时序卷积网络等架构, 增强关键特征的捕捉能力[15]; 3) 探索基于注意力权重的动态可解释性分析方法, 量化各特征对预测结果的时变贡献[14]; 4) 深化多因素耦合机制研究, 为供水系统精细化管理提供理论支撑。

参考文献

- [1] 苟非洲, 程玉婷. 基于长短期记忆网络的日供水量预测方法研究[J]. 中国给水排水, 2019, 35(17): 79-83.
- [2] 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.
- [3] 王骊, 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, 60.
- [4] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016: 121-158.
- [5] LeCun, Y., Bengio, Y. and Hinton, G. (2015) Deep learning. *Nature*, **521**, 436-444. <https://doi.org/10.1038/nature14539>
- [6] Hochreiter, S. and Schmidhuber, J. (1997) Long Short-Term Memory. *Neural Computation*, **9**, 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [7] Kratzert, F., Klotz, D., Brenner, C., Schulz, K. and Herrnegger, M. (2018) Rainfall-Runoff Modelling Using Long Short-Term Memory (LSTM) Networks. *Hydrology and Earth System Sciences*, **22**, 6005-6022. <https://doi.org/10.5194/hess-22-6005-2018>
- [8] Schuster, M. and Paliwal, K.K. (1997) Bidirectional Recurrent Neural Networks. *IEEE Transactions on Signal Processing*, **45**, 2673-2681. <https://doi.org/10.1109/78.650093>
- [9] Mu, L., Zheng, F., Tao, R., Zhang, Q. and Kapelan, Z. (2020) Hourly and Daily Urban Water Demand Predictions Using a Long Short-Term Memory Based Model. *Journal of Water Resources Planning and Management*, **146**, Article ID: 05020017. [https://doi.org/10.1061/\(asce\)wr.1943-5452.0001276](https://doi.org/10.1061/(asce)wr.1943-5452.0001276)
- [10] 13Pukelsheim, F. (1994) The Three Sigma Rule. *The American Statistician*, **48**, 88-91. <https://doi.org/10.1080/00031305.1994.10476030>
- [11] Du, B., Zhou, Q., Guo, J., Guo, S. and Wang, L. (2021) Deep Learning with Long Short-Term Memory Neural Networks Combining Wavelet Transform and Principal Component Analysis for Daily Urban Water Demand Forecasting. *Expert Systems with Applications*, **171**, Article ID: 114571. <https://doi.org/10.1016/j.eswa.2021.114571>
- [12] Abadi, M., Barham, P., Chen, J., et al. (2016) TensorFlow: A System for Large-Scale Machine Learning. 12th *USENIX Symposium on Operating Systems Design and Implementation*, Savannah, 2-4 November 2016, 265-283.
- [13] Pedregosa, F., Varoquaux, G., Gramfort, A., et al. (2011) Scikit-Learn: Machine Learning in Python. *Journal of Machine Learning Research*, **12**, 2825-2830.
- [14] Lundberg, S.M. and Lee, S.I. (2017) A Unified Approach to Interpreting Model Predictions. *Proceedings of the 31st International Conference on Neural Information Processing Systems*, Long Beach, 4-9 December 2017, 4768-4777.
- [15] Bai, Y., Yan, Z. and Li, C. (2023) An Attention Mechanism-Based Deep Regression Approach with a Sequence Decomposition-Granularity Reconstruction-Integration Model for Urban Daily Water Supply Forecasting. *Journal of Hydrology*, **617**, Article ID: 129032. <https://doi.org/10.1016/j.jhydrol.2022.129032>