

基于EMD-LSTM模型的右江水库日入库流量预测

潘志浩¹, 陈森林^{1,2}, 梁斌¹, 谭安琪¹, 黄馗³, 毛玉鑫⁴

¹武汉大学水利水电学院, 湖北 武汉

²武汉大学水资源与水电工程科学国家重点实验室, 湖北 武汉

³广西电网电力调度控制中心, 广西 南宁

⁴中国长江电力股份有限公司, 湖北 宜昌

收稿日期: 2021年12月9日; 录用日期: 2022年1月29日; 发布日期: 2022年2月22日

摘要

入库流量预测可为水电站水库防汛抗旱、水位控制等提供必要依据。然而传统物理建模方法预测入库流量对数据资料要求较高, 在资料相对匮乏地区难以应用。针对入库流量序列非线性非平稳以及原始数据包含噪声等问题, 将经验模态分解(empirical mode decomposition, EMD)良好的滤波特性和长短期记忆(long-short-term memory, LSTM)神经网络强大的非线性映射能力相结合, 用于右江水库日入库流量预测。首先采用EMD方法对入库流量序列进行分解, 然后对分解的各分量分别建立LSTM进行预测, 最后加和重构得到预测结果, 同时采用单一LSTM作为对比。在右江水库日入库流量预测中, EMD-LSTM预测结果平均绝对误差(MAE)为 $29.46 \text{ m}^3/\text{s}$, 平均相对误差(MAPE)为11.06%, 确定性系数(DC)为0.95, 各评价指标均优于单一LSTM, 表明EMD-LSTM在右江水库日入库流量预测中具有很好的适用性, 明显提高了日入库流量预测精度, 对今后右江水库安全经济运行具有重要指导意义。

关键词

入库流量, 经验模态分解, 长短期记忆网络

Inflow Prediction of Youjiang Reservoir Based on EMD-LSTM Model

Zhihao Pan¹, Senlin Chen^{1,2}, Bin Liang¹, Anqi Tan¹, Kui Huang³, Yuxin Mao⁴

¹School of Water Resources and Hydropower Engineering, Wuhan University, Wuhan Hubei

²State Key Laboratory of Water Resources and Hydropower Engineering Science, Wuhan University, Wuhan Hubei

³Power Dispatching Control Center, Guangxi Power Grid, Nanning Guangxi

⁴China Yangtze Power Co., Ltd., Yichang Hubei

Received: Dec. 9th, 2021; accepted: Jan. 29th, 2022; published: Feb. 22nd, 2022

作者简介: 潘志浩(1998-), 男, 山东德州人, 硕士研究生, 主要从事水文水资源研究, Email: 707462595@qq.com

文章引用: 潘志浩, 陈森林, 梁斌, 谭安琪, 黄馗, 毛玉鑫. 基于 EMD-LSTM 模型的右江水库日入库流量预测[J]. 水资源研究, 2022, 11(1): 20-29. DOI: 10.12677/jwrr.2022.111002

Abstract

The prediction of inflow can provide necessary basis for flood prevention, drought relief and water level control in hydropower reservoirs. However, traditional prediction methods based on physical models have a high demand for data and are difficult to apply when data is relatively scarce. The inflow series has characteristics of nonlinearity and nonstationary. And the original data contains some noise. To solve these problems, empirical mode decomposition (EMD) and long-short-term memory (LSTM) neural network were combined to predict Youjiang Reservoir daily inflow, which made full use of the good filtering property of EMD and the powerful nonlinear mapping ability of LSTM. Firstly, the EMD was applied to decompose the inflow series, then the LSTM was built separately for each component from EMD for prediction, and finally each prediction result was superposed to obtain the final prediction result. Meanwhile, a single LSTM was used as comparison. The results indicated that the EMD-LSTM model exhibited better than the single LSTM in terms of the average absolute error ($MAE = 29.46 \text{ m}^3/\text{s}$), the average relative error ($MAPE = 11.06\%$) and the coefficient of certainty ($DC = 0.95$). Based on the above results, EMD-LSTM has good applicability and obviously improves the prediction accuracy, which is of great significance to guide the safe and economic operation in the future.

Keywords

Reservoir Inflow, Empirical Mode Decomposition, Long-Short-Term Memory Network

Copyright © 2022 by author(s) and Wuhan University.

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

入库流量预测可为水电站水库防汛抗旱、优化调度、水位控制[1]提供必要依据，在水库安全经济运行和水资源开发利用[2]等方面发挥重要作用。入库流量预测方法主要分为过程驱动模型方法和数据驱动模型方法两大类。过程驱动模型主要是基于对产汇流过程模拟建立的物理模型，然而物理模型大多结构复杂，且模型所需已知信息较多，包括水文、气象以及流域下垫面等信息，对资料匮乏的地区，建立物理模型较为困难。数据驱动模型则不需要考虑径流形成机制，只需建立输入、输出之间最优数学关系，其中基于时间序列自身的建模及预测作为一种重要手段在学术界和实际应用领域极为普遍[3]。传统的时间序列预测方法通常假设数据是由线性过程产生的，由此基于线性关系建立符合假设条件的统计模型[4]。然而，入库流量由于受到内部和外部众多不确定性因素影响[5]，具有非线性、时变性、动态性[6]，难以满足传统时间序列模型的假设条件。

随着大数据和人工智能时代的到来，以人工神经网络为核心的人工智能大数据技术在各个领域得以应用[7]。近年来，以 BP 神经网络为代表的数据驱动预测模型具有强大的非线性映射能力[8]，逐渐被应用到时间序列预测分析中。在众多神经网络中，长短期记忆(long-short-term memory, LSTM)神经网络对时间序列预测具有显著优势，在水文时间序列预测方面具有较好表现[9]。Kratzert 等[10]利用大量流量数据集训练 LSTM 模型，通过 LSTM 预测结果与实际流量进行对比，得出 LSTM 可以用于流域流量预测的结论。殷兆凯等[11]采用 LSTM 建立了流域降雨径流模型，将流域降雨、气象及水文数据作为输入，并与新安江模型对比，得出在预见期 0~2 d 时 LSTM 预报精度最高。秦鹏等[12]提出一种新的耦合模型 GAN-LSTM，该模型在缺失数据条件下的预报性能显著优于其他同类型模型。石晴宜等[13]建立基于小波分析的 LSTM 水质单因子预测方法，将其用于淮河入洪泽湖的水

质预测，大幅度提升了水质预测精度。

由于入库流量序列是含有多种频率和趋势成分的非线性非平稳序列[14]，加之单一神经网络模型在训练过程中易受噪声信号干扰[15]，在一定程度上增加了直接预测难度，很难达到预测精度要求。因此，本文采用经验模态分解(Empirical Mode Decomposition, EMD)对原时间序列进行分解，以降低其复杂程度，对分解后的各分量采用 LSTM 模型分别进行滑动预测，最终将各分量预测结果进行加和重构获得入库流量的预测结果，并与单一 LSTM 模型进行对比分析。

2. 研究流域及数据

2.1. 研究流域

右江水库，又名百色水利枢纽工程，位于珠江流域右江上游河段，地处云贵高原东麓，地势西高东低，南北高中部低，为典型的河谷型丘陵地貌。右江水库坝址以上集雨面积为 $19,600 \text{ km}^2$ ，占右江流域面积的 47.5%。流域年平均降雨量位于 1000~1700 mm 之间，降雨年内分配不均，汛期降雨量占全年的 80%左右，暴雨天气系统主要受副热带高压、热带低压、台风、东风波及西南低涡等影响。右江水库是一座以防洪为主，兼有发电、灌溉、航运、供水等综合效益的大型水利枢纽，水库总库容 56.6亿 m^3 ，防洪库容 16.4亿 m^3 ，调节库容 26.2亿 m^3 ，死库容 21.8亿 m^3 ，多年平均径流量 $263 \text{ m}^3/\text{s}$ ，年径流量 82.9亿 m^3 ，为不完全多年调节水库。右江水库控制流域如图 1 所示。

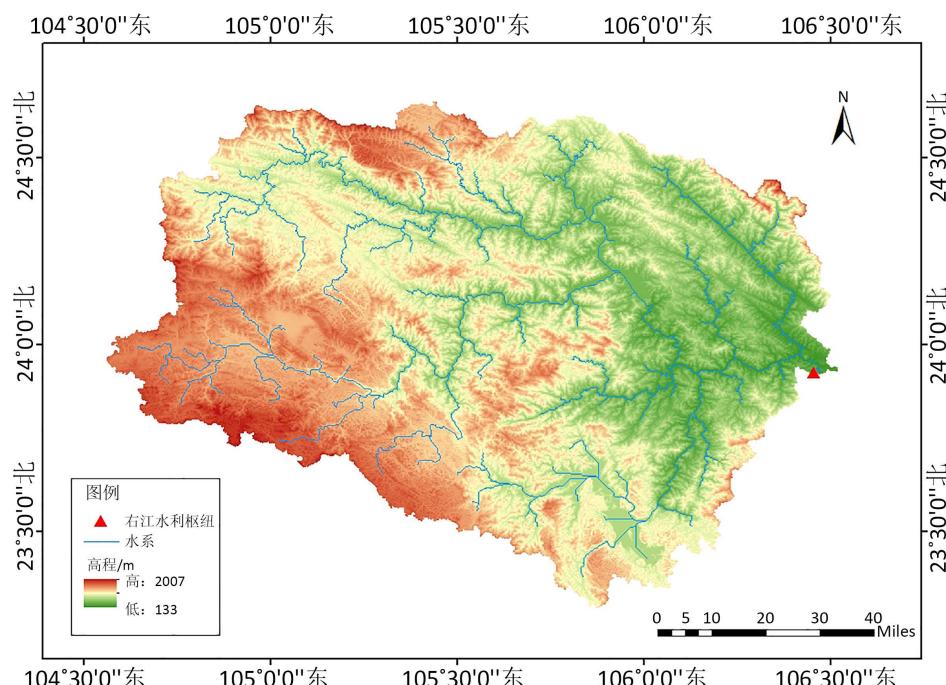


Figure 1. The map of Youjiang Reservoir basin

图 1. 右江水库流域图

2.2. 数据

本文数据采用右江水库 2017 年 1 月 1 日至 2019 年 12 月 31 日入库流量日尺度数据，其过程线如图 2 所示，从图中可以看出，右江水库 2017~2019 年入库流量序列波动性较大，复杂程度较高，呈现出较强的非线性和非平稳性，且整体呈现出减少趋势。

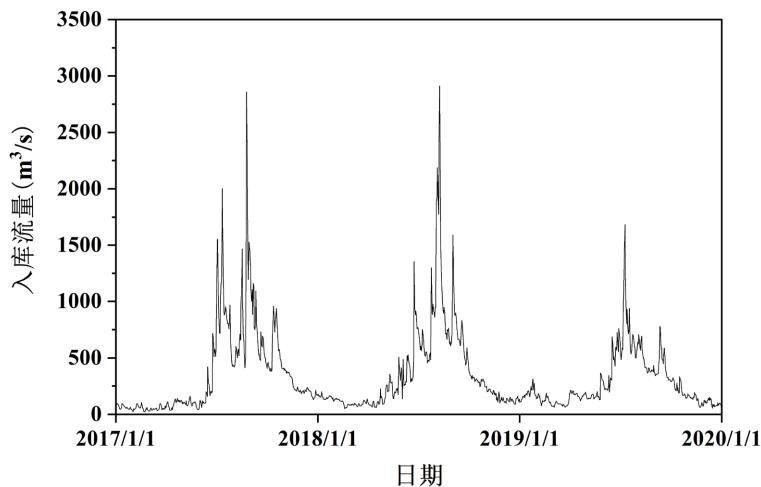


Figure 2. The daily inflow process of Youjiang Reservoir from 2017 to 2019
图 2. 右江水库 2017~2019 年逐日入库流量过程线

3. 研究方法

3.1. EMD

EMD [16]是一种基于数据本身时间尺度特征的自适应时频信号分解算法，该算法不需要任何先验假设[17]和预先设置任何基函数[18]，在非线性、非平稳时间序列的处理中具有良好效果。EMD 算法可以将复杂时间序列分解为有限个本征模函数(intrinsic mode function, IMF)和一个趋势项(trend)，分解得到的各 IMF 分量包含了原数据在不同时间尺度上的波动信息[19]。EMD 分解过程如下：

- 1) 首先计算出时间序列 $\{x_t\}$ 的局部极大值、极小值，采用三次样条插值函数拟合所有极值点得到上包络线 $\{u_t\}$ 和下包络线 $\{l_t\}$ ；
- 2) 计算上包络线和下包络线的均值 m_t ：

$$m_t = \frac{u_t + l_t}{2} \quad (1)$$

- 3) 将 m_t 从 x_t 中剔除后，得到中间信号 ε_t ：

$$\varepsilon_t = x_t - m_t \quad (2)$$

- 4) 判断 ε_t 是否满足 IMF 分量的两个条件：①信号中零点数和极值点数相等或至多相差 1；②极大值和极小值包络线的均值相等且为 0。若满足，则 ε_t 作为一个 IMF 分量，否则将 $\{\varepsilon_t\}$ 作为一个新的输入序列，重复 Step 1~4 直到为止 ε_t 满足 IMF 分量条件为止；

- 5) 将每次得到的 IMF 分量从原时间序列中剔除，重复上述步骤，直到最后余量信号 r_t 为单调序列或者足够小时，EMD 分解结束。通过以上步骤，原时间序列分解成一系列 IMF_i ($i = 1, 2, \dots, n$) 和 r_t 。

$$x_t = \sum_{i=1}^n IMF_i + r_t \quad (3)$$

3.2. LSTM

为了解决循环神经网络(RNN)存在长期依赖记忆丢失、梯度消失等问题，Hochreiter 等[20]在 RNN 的基础上提出了带有记忆单元的 LSTM 模型。LSTM 模型同样由输入层、隐藏层和输出层组成，不同的是 LSTM 模型在隐藏层中引入了记忆细胞单元代替了传统 RNN 中的细胞单元，每个记忆细胞单元组成包括一个状态单元和 3

个门结构(遗忘门、输入门、输出门)，其中状态单元用于记录当前时刻状态，门结构可以控制对输入数据信息有选择的记忆或忘记。LSTM 模型相关计算公式如式(4)所示。

$$\begin{cases} \mathbf{f}_t = \sigma[\mathbf{W}_f(\mathbf{h}_{t-1}, \mathbf{x}_t) + \mathbf{b}_f] \\ \mathbf{i}_t = \sigma[\mathbf{W}_i(\mathbf{h}_{t-1}, \mathbf{x}_t) + \mathbf{b}_i] \\ \tilde{\mathbf{C}}_t = \tanh[\mathbf{W}_c(\mathbf{h}_{t-1}, \mathbf{x}_t) + \mathbf{b}_c] \\ \mathbf{C}_t = \mathbf{f}_t \odot \mathbf{C}_{t-1} + \mathbf{i}_t \odot \tilde{\mathbf{C}}_t \\ \mathbf{o}_t = \sigma[\mathbf{W}_o(\mathbf{h}_{t-1}, \mathbf{x}_t) + \mathbf{b}_o] \\ \mathbf{h}_t = \mathbf{o}_t \odot \tanh(\mathbf{C}_t) \end{cases} \quad (4)$$

式中： \mathbf{f}_t 、 \mathbf{i}_t 、 \mathbf{o}_t 、 \mathbf{C}_t 分别为 t 时刻的遗忘门、 输入门、 输出门和记忆细胞单元状态； \mathbf{W} 、 \mathbf{b} 分别表示相应的权重矩阵和偏移向量； \mathbf{h}_t 、 \mathbf{h}_{t-1} 分别为前一时刻和当前时刻隐藏层状态； σ 为 sigmod 激活函数； $\tilde{\mathbf{C}}_t$ 为记忆更新变量； \tanh 为双曲正切激活函数。

3.3. EMD-LSTM 模型及评价指标

本文通过构建 EMD-LSTM 预测模型，即先将右江水库日入库流量序列进行 EMD 分解，对分解后的各 IMF_i 和趋势项分别采用 LSTM 模型进行预测，将预测结果加和重构得到右江水库日入库流量的预测结果，EMD-LSTM 预测流程图如图 3 所示，并与单一 LSTM 模型预测结果对比分析。

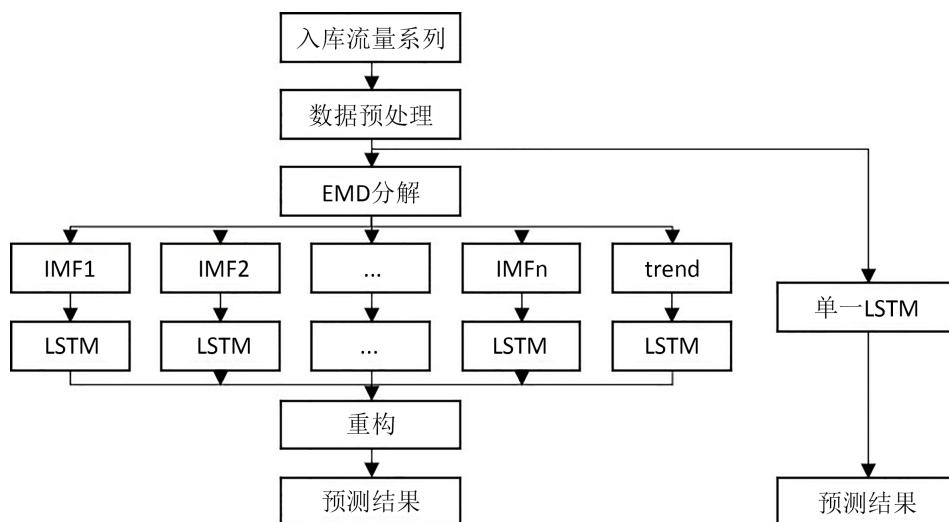


Figure 3. The flow chart of EMD-LSTM

图 3. EMD-LSTM 预测流程图

为了评价模型预测结果的可靠性和准确性，参考《水文预报规范》，采用平均绝对误差(MAE)、平均相对误差(MAPE)、确定性系数(DC)分别对单一 LSTM 和 EMD-LSTM 预测结果进行评价。

$$MAE = \frac{1}{T} \sum_{i=1}^n |\hat{Q}_i - Q_i| \quad (5)$$

$$MAPE = \frac{1}{T} \sum_{i=1}^n \frac{|\hat{Q}_i - Q_i|}{Q_i} \quad (6)$$

$$DC = 1 - \frac{\sum_{i=1}^n (\hat{Q}_i - Q_i)^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2} \quad (7)$$

式中: Q_i 为实测入库流量, m^3/s ; \hat{Q}_i 为模型预测的入库流量, m^3/s ; \bar{Q} 为实测入库流量平均值, m^3/s ; T 为时段数。

4. 研究结果

4.1. 数据预处理

为了避免入库流量数据差异过大导致模型收敛速度过慢甚至不收敛的情况、提高神经网络训练的精度和速度, 首先将入库流量数据进行归一化处理, 计算公式如式(8)所示。

$$Q'_t = \frac{Q_t - Q_{\min}}{Q_{\max} - Q_{\min}} \quad (8)$$

式中: Q'_t 为归一化之后的入库流量, 其大小位于 $[0, 1]$ 区间; Q_t 为时段 t 实测入库流量, m^3/s ; Q_{\max} 、 Q_{\min} 分别为入库流量系列中的最大值和最小值, m^3/s 。

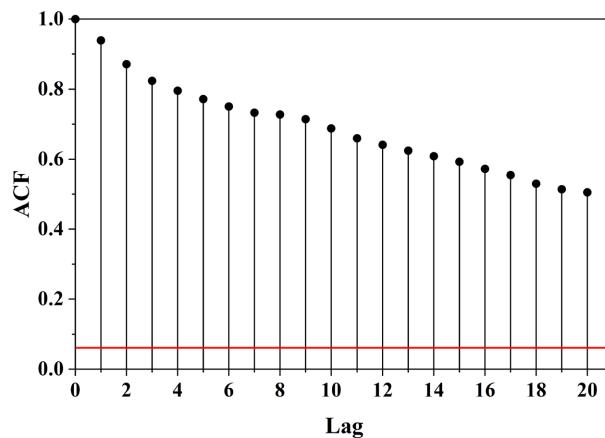


Figure 4. Autocorrelation coefficient graph of inflow series at Youjiang Reservoir

图 4. 右江水库入库流量系列自相关图

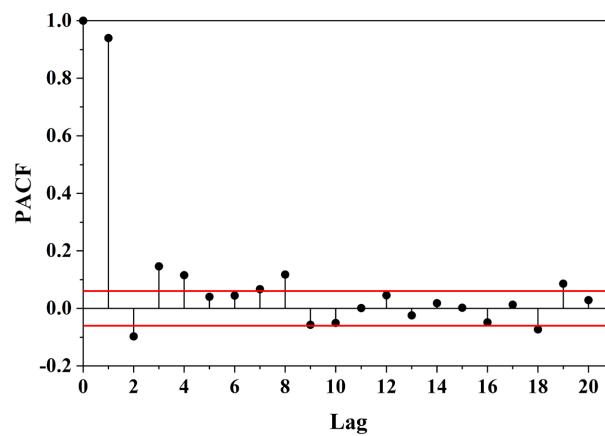


Figure 5. Partial autocorrelation coefficient graph of inflow series at Youjiang Reservoir

图 5. 右江水库入库流量系列偏相关图

在时间序列分析时，常采用自相关系数(autocorrelation coefficient, AC)和偏自相关系数(partial autocorrelation coefficient, PAC)找寻变量之间的相关程度。自相关系数用以描述数据系列自身不同时期的相关关系，即反映历史数据对现在影响的大小，而偏相关系数仅考虑滞后第 k 期对现在的影响。对右江水库日入库流量系列进行自相关和偏相关分析，并绘制自相关图、偏相关图分别如图 4、图 5 所示，可以看出，ACF 呈现出拖尾现象，PACF 在滞时大于 8 时基本落在 95% 的置信带内，所以可以认为右江水库入库流量与滞后 8 天内的入库流量相关性较大。因此确定滑动窗口长度为 8 天，即采用前 8 天的数据作为模型输入预测当前入库流量。

4.2. EMD-LSTM 模型构建及预测

对右江水库日入库流量系列进行 EMD 分解，得到 7 个 IMF 分量和 1 个趋势项，如图 6 所示，图中横坐标表示时间序列数(距资料系列开始日期的天数)，纵坐标表示分解的各本征模函数值。可以看出，分解之后入库流量各分量的非线性、非平稳性和复杂程度明显降低，分量 IMF1~IMF7 的频率依次降低，所包含原始序列的信息依次减少，趋势项表明右江水库入库流量呈现下降趋势。

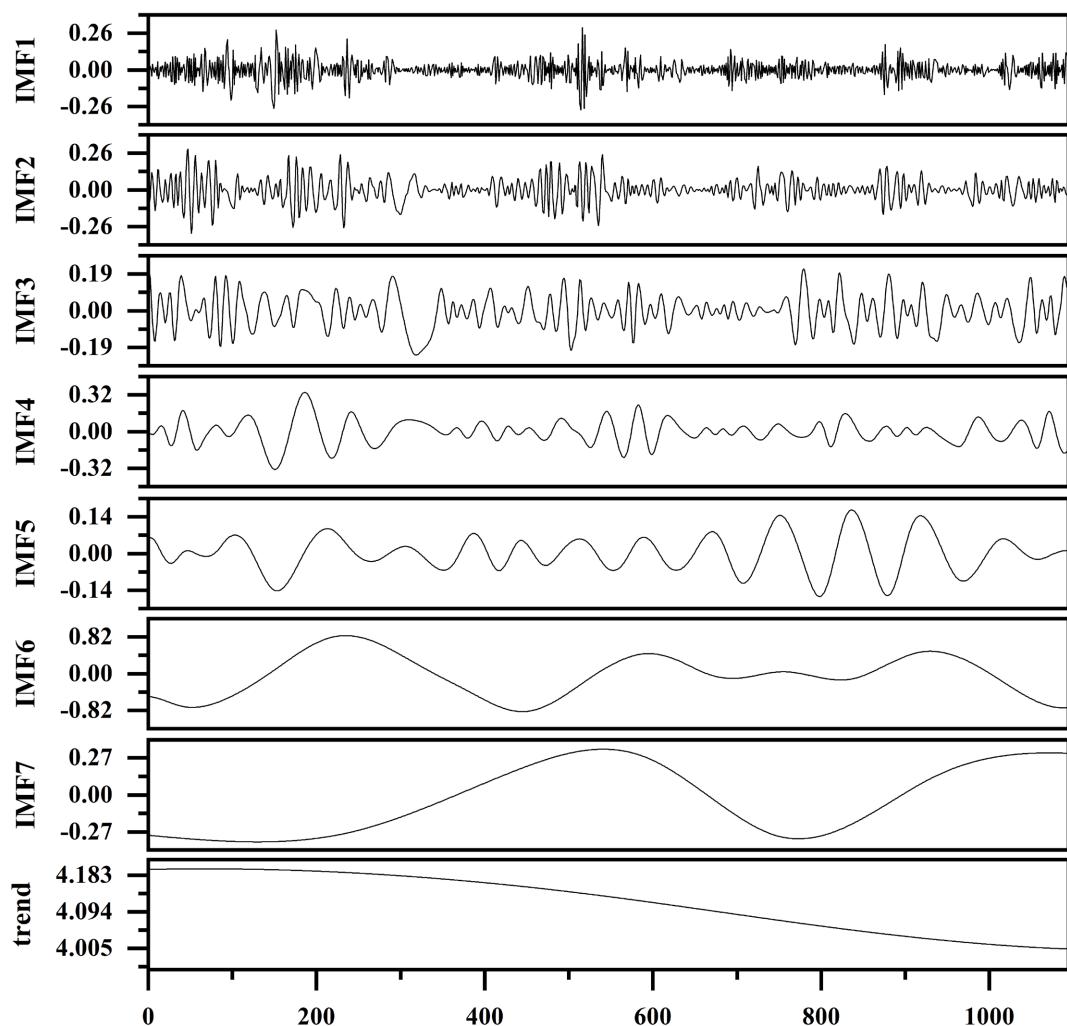


Figure 6. The decomposition result of inflow series by EMD at Youjiang Reservoir
图 6. 右江水库入库流量系列 EMD 分解结果

以右江水库 2017 年~2018 年共 760 天的实测日入库流量数据作为训练集，2019 年共 365 天的数据作为测试

集。数据预处理之后，将经过 EMD 分解得到的各 IMF 分量和趋势项分别建立 LSTM。采用滑动窗口方法进行预测，将前 8 天的入库流量数据作为输入，预测未来 1 天的入库流量，通过不断更新当天的实测入库流量数据实现向前滑动预测。LSTM 采用 Adam 算法训练内部参数，经调试，在隐含层神经元数为 20、训练次数为 500、学习速率为 0.005 时，LSTM 具有较好的预测性能。最终将各 IMF 分量和趋势项的预测结果相加重构，得到右江水库日入库流量的预测结果。同时采用单一 LSTM 在同样条件下对右江水库日入库流量进行预测，用于与 EMD-LSTM 对比分析，两者预测结果如图 6 所示，并对各模型预测精度进行评价，评价结果如表 1 所示。

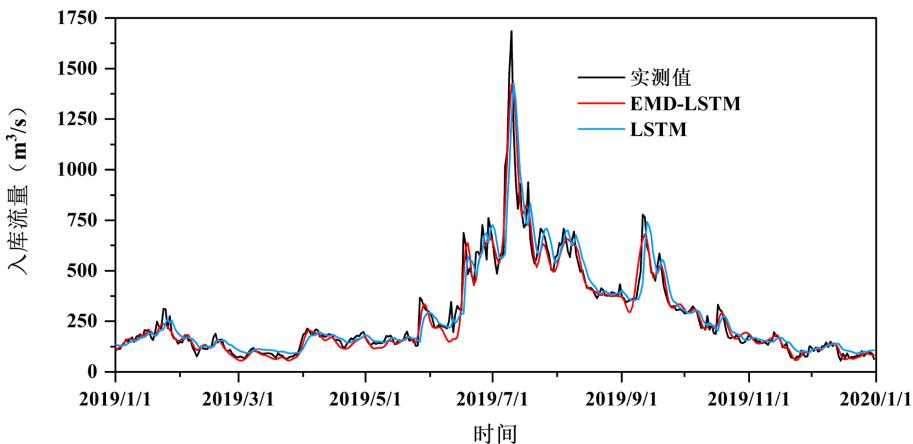


Figure 7. Comparison between prediction values of each model and original daily inflow of Youjiang Reservoir in 2019

图 7. 右江水库 2019 年日入库流量实测值与各模型预测值对比

Table 1. Calculation results of each model evaluation standard

表 1. 各模型评价标准计算结果

数量	MAE (m^3/s)	MAPE (%)	DC
单一 LSTM	44.48	16.99	0.88
EMD-LSTM	29.46	11.06	0.95

根据图 7 可以看出，EMD-LSTM 模型和单一 LSTM 模型预测的入库流量与实测值变化趋势基本一致，均能较好追踪入库流量的动态变化，但在入库流量序列极值点处预测效果欠佳。由于右江水库日入库流量序列具有较强的非线性和非稳定性，单一 LSTM 模型预测性能劣于 EMD-LSTM 模型，同时受入库流量序列高一阶相关性的影响，单一 LSTM 模型预测结果明显滞后一个时段。相比单一 LSTM 模型，EMD-LSTM 模型预测结果的 MAE 降低 34%，MAPE 降低 35%，DC 从 0.88 提高到 0.95，说明 EMD 方法能有效滤除入库流量序列的噪声、降低原始序列的复杂程度，进而充分发挥 LSTM 模型的非线性处理能力，从而有效提高了右江水库日入库流量预测的精度和可靠性。

5. 结论

本文在对右江水库日入库流量预测过程中，首先采用 EMD 方法将原始日入库流量序列分解为有限个 IMF 分量和趋势项，降低原始序列的复杂程度，然后对这些分量分别采用 LSTM 进行预测，最后将每个分量的预测结果进行加和重构得到入库流量预测值。研究结果表明，相较于单一 LSTM，将 EMD 同 LSTM 相结合可以充分发挥两者优势，能够深入挖掘入库流量序列固有特性，有效避免单一 LSTM 在训练过程中受序列高一阶相关性导致滞后现象，进而提高入库流量预测的准确性。同时，与直接将原始数据序列输入模型进行预测相比，“分解 - 预测

- 重构”模式更适合处理非线性非平稳的时间序列，表明在模型预测之前对时间序列进行预处理是十分必要的。

致 谢

感谢广西电网有限责任公司为本研究提供基础数据与支持。

基金项目

国家自然科学基金资助项目(51779177); 广西电网公司科技项目资助(0400002020030103DD00134)。

参考文献

- [1] 唐海华, 陈森林, 赵云发, 等. 三峡水库入库流量计算方法研究[J]. 中国农村水利水电, 2008(4): 26-28.
TANG Haihua, CHEN Senlin, ZHAO Yunfa, *et al.* Study on calculation method of inflow of Three Gorges Reservoir. China Rural Water and Hydropower, 2008(4): 26-28. (in Chinese)
- [2] 郭华, 陈勇, 马耀光. 组合灰色预测模型在入库流量预测中的应用[J]. 干旱地区农业研究, 2012, 30(3): 96-100.
GUO Hua, CHEN Yong and MA Yaoguang. Application of combined grey forecasting model in the prediction of incoming flow. Agricultural Research in the Arid Areas, 2012, 30(3): 96-100. (in Chinese)
- [3] 于琼, 田宪. 基于组合模型的非线性时间序列预测算法[J]. 计算机工程与科学, 2021, 43(10): 1817-1825.
YU Qiong, TIAN Xian. A nonlinear time series prediction algorithm based on combination model. Computer Engineering & Science, 2021, 43(10): 1817-1825. (in Chinese)
- [4] KURT, S., TUNAY, K. B. STARMA models estimation with Kalman Filter: The case of regional bank deposits. Procedia Social and Behavioral Sciences, 2015, 195: 2537-2547. <https://doi.org/10.1016/j.sbspro.2015.06.441>
- [5] 田楚杰. 神经网络在时间序列与时空序列流量预测中的应用与研究[D]: [博士学位论文]. 北京: 北京邮电大学, 2021.
TIAN Chujie. Research of temporal flow prediction and spatial-temporal flow prediction based on neural networks. Ph.D. Thesis, Beijing: Beijing University of Posts and Telecommunications, 2021. (in Chinese)
- [6] 李强, 唐锋, 陈卓, 等. Elman 神经网络在水电站入库流量短期预测中的应用[J]. 华电技术, 2015, 37(7): 1-3+76.
LI Qiang, TANG Feng, CHEN Zhuo, *et al.* Application of Elman neural network in short-term reservoir inflow forecasting in hydropower station. Huadian Technology, 2015, 37(7): 1-3+76. (in Chinese)
- [7] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
ZHOU Feiyan, JIN Linpeng and DONG Jun. Review of convolutional neural network. Chinese Journal of Computers, 2017, 40(6): 1229-1251. (in Chinese)
- [8] 徐廷兵, 马光文, 黄炜斌, 等. 基于小波分析的 BP 网络预测模型及其在年径流预测中的应用[J]. 水电能源科学, 2012, 30(2): 17-19.
XU Tingbing, MA Guangwen, HUANG Weibin, *et al.* BP network prediction model and its application in annual runoff forecasting based on wavelet analysis. Water Resources and Power, 2012, 30(2): 17-19. (in Chinese)
- [9] HU, C., WU, Q., LI, H., *et al.* Deep learning with a long short-term memory networks approach for rainfall-runoff simulation. Water, 2018, 10(11): 1543. <https://doi.org/10.3390/w10111543>
- [10] KRATZERT, F., KLOTZ, D., BRENNER, C., *et al.* Rainfall-runoff modeling using long short-term memory (LSTM) networks. Hydrology and Earth System Sciences, 2018, 22(11): 6005-6022. <https://doi.org/10.5194/hess-22-6005-2018>
- [11] 殷兆凯, 廖卫红, 王若佳, 等. 基于长短时记忆神经网络(LSTM)的降雨径流模拟及预报[J]. 南水北调与水利科技, 2019, 17(6): 1-9+27.
YIN Zhaokai, LIAO Weihong, WANG Ruojia, *et al.* Rainfall-runoff modeling and forecasting based on long short-term memory (LSTM). South-to-North Water Transfers and Water Science & Technology, 2019, 17(6): 1-9+27. (in Chinese)
- [12] 秦鹏, 陈雨, 卢文龙. 缺失数据条件下基于 GAN 与 LSTM 的水文预报研究[J]. 人民黄河, 2021, 43(6): 16-20+27.
QIN Peng, CHEN Yu and LU Wenlong. Hydrological forecast based on GAN and LSTM under the condition of missing data. Yellow River, 2021, 43(6): 16-20+27. (in Chinese)
- [13] 石晴宜, 董增川, 罗赟, 等. 基于机器学习方法的洪泽湖入湖水质评价及预测研究[J/OL]. 中国农村水利水电, 1-14[2021-12-03]. <http://kns.cnki.net/kcms/detail/42.1419.TV.20210616.1626.024.html>
SHI Qingyi, DONG Zhengchuan, LUO Yun, *et al.* Evaluation and prediction of water quality of Hongze Lake based on machine learning method. China Rural Water and Hydropower, 1-14[2021-12-03]. <http://kns.cnki.net/kcms/detail/42.1419.TV.20210616.1626.024.html> (in Chinese)
- [14] TIAN, P., JIANZHONG, Z., CHU, Z., *et al.* Streamflow forecasting using empirical wavelet transform and artificial neural networks. Water, 2017, 9(6): 406. <https://doi.org/10.3390/w9060406>

- [15] 孙望良, 周建中, 彭利鸿, 等. DFA_VMD_LSTM 组合日径流预测模型研究[J]. 水电能源科学, 2021, 39(3): 12-15.
SUN Wangliang, ZHOU Jianzhong, PENG Lihong, et al. Study on DFA_VMD_LSTM hybrid daily runoff forecasting model. Water Resources and Power, 2021, 39(3): 12-15. (in Chinese)
- [16] HUANG, N. E., SHEN, Z., LONG, S. R., et al. The empirical mode decomposition method and the Hilbert spectrum for non-stationary time series analysis. Proceedings of the Royal Society of London. Series A, 1998, 454: 903-995.
<https://doi.org/10.1098/rspa.1998.0193>
- [17] 岳相臣. 经验模态分解算法应用研究[D]: [硕士学位论文]. 西安: 西安电子科技大学, 2013.
YUE Xiangchen. Research on empirical mode decomposition algorithm's application. Master's Thesis, Xi'an: Xi'an University, 2013. (in Chinese)
- [18] 王亦斌, 孙涛, 梁雪春, 等. 基于 EMD-LSTM 模型的河流水量水位预测[J]. 水利水电科技进展, 2020, 40(6): 40-47.
WANG Yibin, SUN Tao, LIANG Xuechun, et al. Prediction of river water flow and water level based on EMD-LSTM model. Advances in Science and Technology of Water Resources, 2020, 40(6): 40-47. (in Chinese)
- [19] 陈川, 陈冬林, 何李凯. 基于 BPNN-EMD-LSTM 组合模型的城市短期燃气负荷预测[J]. 安全与环境工程, 2019, 26(1): 149-154+169.
CHEN Chuan, CHEN Donglin and HE Likai. Short-term forecast of urban natural gas load based on BPNN-EMD-LSTM combined model. Safety and Environmental Engineering, 2019, 26(1): 149-154+169. (in Chinese)
- [20] HOCHREITER, S, SCHMIDHUBER, J. Long short-term memory. Neural Computation, 1997, 9(8): 1735-1780.
<https://doi.org/10.1162/neco.1997.9.8.1735>