



改进EEMD-GRU混合模型在径流预报中的应用

刘扬, 王立虎, 杨礼波, 刘雪梅

引用本文:

刘扬,王立虎,杨礼波,刘雪梅. 改进EEMD-GRU混合模型在径流预报中的应用[J]. 智能系统学报, 2022, 17(3): 480–487.

LIU Yang,WANG Lihu,YANG Libo,LIU Xuemei. Application of improved EMD-GRU hybrid model in runoff forecasting[J]. *CAAI Transactions on Intelligent Systems*, 2022, 17(3): 480–487.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202105010>

您可能感兴趣的其他文章

深度学习的双人交互行为识别与预测算法研究

Human interaction recognition and prediction algorithm based on deep learning

智能系统学报. 2020, 15(3): 484–490 <https://dx.doi.org/10.11992/tis.201812029>

一种高效的稀疏卷积神经网络加速器的设计与实现

Design and implementation of an efficient accelerator for sparse convolutional neural network

智能系统学报. 2020, 15(2): 323–333 <https://dx.doi.org/10.11992/tis.201902007>

基于知识图谱和用户长短期偏好的个性化景点推荐

Personalized attraction recommendation based on the knowledge graph and users' long-term and short-term preferences

智能系统学报. 2020, 15(5): 990–997 <https://dx.doi.org/10.11992/tis.201904064>

一种改进的深度学习的道路交通标识识别算法

An improved deep learning algorithm for road traffic identification

智能系统学报. 2020, 15(6): 1121–1130 <https://dx.doi.org/10.11992/tis.201811009>

基于改进卷积神经网络的多标记分类算法

A multi-label classification algorithm based on an improved convolutional neural network

智能系统学报. 2019, 14(3): 566–574 <https://dx.doi.org/10.11992/tis.201804056>

基于递归神经网络的风暴潮增水预测

Prediction of storm surge based on recurrent neural network

智能系统学报. 2017, 12(5): 640–644 <https://dx.doi.org/10.11992/tis.201706015>



微信公众平台



期刊网址

DOI: 10.11992/tis.202105010

网络出版地址: <https://kns.cnki.net/kcms/detail/23.1538.TP.20220106.1206.002.html>

改进 EEMD-GRU 混合模型在径流预报中的应用

刘扬, 王立虎, 杨礼波, 刘雪梅

(华北水利水电大学 信息工程学院, 河南 郑州 450046)

摘要:为解决径流预测模型存在的预测精确度低、稳定性差、延时高等问题,结合门控制循环单元神经网络(gated recurrent unit, GRU),集合经验模态分解(ensemble empirical mode decomposition, EEMD)的各自优点,提出一种基于改进 EEMD 方法的深度学习模型(EEMD-GRU)。该模型首先以智能算法对径流信号进行边界拓延,以解决 EEMD 边界效应。然后利用改进 EEMD 方法将径流信号分解为若干稳态分量,将各分量作为 GRU 模型的输入并对其进行预测。实验结果表明,与结合了经验模态分解的支持向量回归模型相比,并行 EEMD-GRU 径流预测模型的预测精准度、可信度和效率分别提高 82.50%、144.67% 和 95.49%。基于 EEMD-GRU 的最优运算结果表明,该方法可进一步减少区域防洪的经济损失,提高灾害监管的工作效率。

关键词:径流预报;集合经验模态分解;深度学习;门控制循环单元神经网络;并行计算;混合模型;时序预测;工程应用

中图分类号: TP183;TV124 文献标志码: A 文章编号: 1673-4785(2022)03-0480-08

中文引用格式: 刘扬, 王立虎, 杨礼波, 等. 改进 EEMD-GRU 混合模型在径流预报中的应用 [J]. 智能系统学报, 2022, 17(3): 480-487.

英文引用格式: LIU Yang, WANG Lihu, YANG Libo, et al. Application of improved EMD-GRU hybrid model in runoff forecasting[J]. CAAI transactions on intelligent systems, 2022, 17(3): 480-487.

Application of improved EMD-GRU hybrid model in runoff forecasting

LIU Yang, WANG Lihu, YANG Libo, LIU Xuemei

(School of Information Engineering, North China University of Water Resources and Electric Power, Zhengzhou 450046, China)

Abstract: Runoff prediction models suffer from low prediction accuracy, poor stability, and high delay. Combined with the advantages of gate control recurrent unit (GRU) neural network and ensemble empirical mode decomposition (EEMD), we propose a deep learning model based on the improved EEMD method (EEMD-GRU) to solve the aforementioned problems of runoff models. Our model initially uses an intelligent algorithm to extend the boundary of the runoff signal to solve the EEMD boundary effect. Subsequently, the improved EEMD method is used to decompose the runoff signals into numerous steady-state components. Each component is then used as the input in the GRU model and is predicted. The experimental results show that the prediction accuracy, credibility, and efficiency of the parallel EEMD-GRU runoff prediction model improve by 82.50%, 144.67%, and 95.49%, respectively, in comparison to the support vector regression model combined with empirical mode decomposition. The optimal calculation results based on EEMD-GRU show that this method can further reduce the economic loss of regional flood control and improve the efficiency of disaster supervision.

Keywords: runoff prediction; ensemble empirical mode decomposition; deep learning; gated recurrent unit; parallel computing; hybrid model; time series prediction; engineering application

河川径流作为水循环的关键节点,对其进行精确预报具有重要意义。变化环境下径流的波动

系数不断加大,极端气候背景下的径流趋势呈现更大的波动性,给径流的准确预报提出了更高的要求。如何根据不同流域,提出更加稳定、高效的预报模型,具有重要的理论意义和应用价值。

收稿日期: 2021-05-06. 网络出版日期: 2022-01-06.

基金项目: 河南省水利科技攻关项目(GG202042).

通信作者: 刘扬. E-mail: ly_research@126.com.

目前, 以物理认识为基础的机理驱动模型和以统计科学为基础的数据驱动模型在径流预报领域取得了一定的进展。以气象数据作为输入, 利用半分布式水文模型对径流进行预测, 并以异常相关系数作为评估指标, 实验结果表明, 确定性预测精度较高^[1]。将分布式水文模型和气象遥相关分析相结合, 采用水文模型提供初始条件, 利用遥相关指数确定气象输入, 开展流域水库入库径流的长期预测^[2]。然而, 机理驱动模型往往存在可解释性差, 主观干扰因素众多等问题。数据驱动模型可以有效缓解机理模型带来的不足^[3-6]。例如, 以支持向量回归(support vector regression, SVR)模型预测集水区洪水发生概率, 结果表明, SVR 模型对于提前 1~3 h 的预测具有令人满意的预测性能^[7]。利用自适应神经模糊推理系统(adaptive neuro-fuzzy inference system, ANFIS)对区域径流进行预测。结果表明, ANFIS 模型的平均绝对误差优于其他模型^[8]。然而, 以统计科学为基础的数据模型往往存在预测精度低, 可解释性差等问题。混合模型可有效缓解数据模型的不足。结合人工神经网络(artificial neural network, ANN)模型和 Muskingum-Cunge 方法, 进而构建一种基于 BR-ANN 的洪水预报模型。研究区的验证对比结果表明, BR-ANN 模型具有优越的综合预测能力^[9]。将 SWAT 模型与 ANN 模型结合并用于区域径流预测, 结果表明 SWAT-ANN 的预测精度优于 SWAT 模型^[10]。结合经验模式分解(empirical mode decomposition, EMD)算法与长短时记忆神经网络(long short-term memory networks, LSTM), 进而构建 EMD-LSTM 模型。并使用均方根误差(root mean square error, RMSE)、决定系数、Willmott 一致性指数(Willmott index, WI)和 Legates-McCabe 指数(Legates McCabe index, LMI)作为评估标准, 结果表明该方法在特大洪水年预测可靠性较高^[11]。然而, EMD 方法在分解过程中往往存在模态混叠和端点效应^[12-14]。

针对以上问题, 本文结合改进集合经验模态分解(ensemble empirical mode decomposition, EEMD)与门控循环单元神经网络(gated recurrent unit, GRU)构建一种基于改进 EEMD 的神经网络模型(EEMD-GRU)。该模型将改进 EEMD 方法和 GRU 模型进行融合, 同时引入并行计算思想, 实现对径流的精确、高效、稳定预测。经验证, 相比于结合了 EMD 的 SVR 模型, 并行 EEMD-GRU 模

型表现出更加高效、可靠的性能。

1 相关理论

1.1 GRU 深度学习

GRU 基于循环神经网络。同循环神经网络相比, GRU 具有计算效率高, 逻辑简单等优势^[15]。其基本结构如图 1 所示。

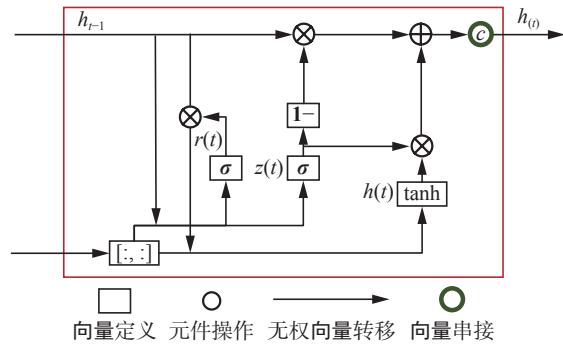


图 1 GRU 神经元结构

Fig. 1 GRU neuron structure

GRU 的提出是为了克服 RNN 无法很好地处理远距离依赖的问题, 在保持了 LSTM 效果的同时使结构更加简单。GRU 仅保留了重置门和更新门, 即图中 $r(t)$ 和 $z(t)$, 其中重置门输出矩阵 r , 可定义为

$$r_t = \sigma(w_r \cdot [h_{t-1}, x_t])$$

式中: w_r 为重置门的权重矩阵; σ 为 sigmoid 函数; h_{t-1} 为 $t-1$ 时刻的隐含状态; x_t 为 t 时刻输入数据。更新门输出矩阵 z , 可定义为

$$z_t = \sigma(w_z \cdot [h_{t-1}, x_t])$$

式中: w_z 为更新门的权重矩阵; 则 GRU 网络的输出可定义为

$$\hat{y}_t = \sigma(w_o h_t + c)$$

式中: w_o 为输出权重矩阵; c 为输出偏置^[16-18]。

1.2 集合经验模态分解

EEMD 在经验模态分解的基础上, 通过引入白噪声, 有效消除了模态混叠现象, 使得 EEMD 的分解结果更加具有物理意义^[19-24], 集合经验模态分解的基本原理可以描述如下:

1) 将正态分布的白噪声信号 $n_i(t)$ 加到原始信号 $x(t)$ 得到信号 $x_i(t)$, 定义为

$$x_i(t) = x(t) + n_i(t)$$

2) 将加入白噪声的信号作为一个整体, 然后进行经验模态分解(EMD), 得到各 IMF 分量, 定义为

$$x_i(t) = \sum_{j=1}^n c_{ij}(t) + r_i(t)$$

式中: $c_{ij}(t)$ 为第 i 次加入白噪声后分解得到的第 j 个 IMF 分量; $r_i(t)$ 是分解后的剩余分量; n 为

IMF 分量的个数。

3) 重复 1)~2), 对各阶分量取平均, 得到最终 IMF 分量 $c_j(t)$ 为

$$c_j(t) = \frac{1}{w} \sum_{i=1}^w x_{ij}(t)$$

式中 w 为添加白噪声的次数, 即总体平均数。

EEMD 的提出是解决 EMD 分解过程中出现的模态混叠现象, 使得在模态分解过程中可以很好地避免 IMF 分量不精确等问题^[25-26]。

2 径流预报方法构建

2.1 基于智能算法的端点效应改进方案

解决集合经验模态分解边界效应的方法一般是对信号进行边界拖延。本文利用极限学习算法作为模态分解端点效应的解决方案, 具体步骤

如下:

1) 以右边界为例, 选取合适的拓延步长, 作为原始信号的拓延信号序列长度;

2) 将原始信号划分为测试集、训练集, 进而构建极限学习预测模型;

3) 将原始信号右端点利用预测模型进行预测, 预测信号与原始信号合并;

4) 利用相同的原理拓延原始信号的左边界。

2.2 并行 EEMD-GRU 径流预测方法

综合实时采集技术, 以黄河流域部分干流共 32 个水文站的实际水文数据作为数据支撑, 进行数据清洗、分解、预测、重构等一系列操作, 最终获得高精度径流预测值, 进而为水库的安全运行和区域防洪减灾提供决策支持。图 2 给出了并行 EEMD-GRU 的数据流程图, 其基本实现如下。

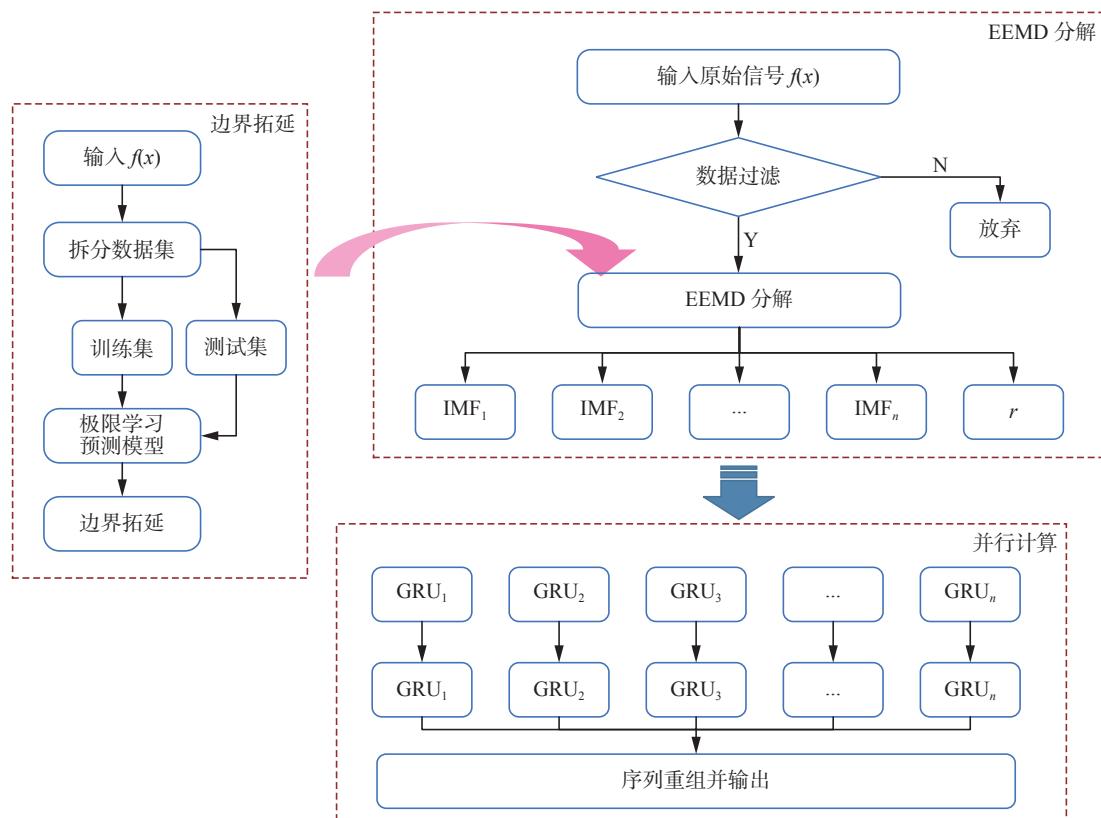


图 2 并行 EEMD-GRU 流程
Fig. 2 Parallel EEMD-GRU flow

1) 以黄河流域部分干流为实验对象, 实时采集水文站径流数据 $f(t)$, 通过数据清洗技术, 对空数据、非数值型数据等非法数据进行过滤, 然后对其进行归一化, 其中归一化方程可定义为

$$\mathbf{x}^* = \frac{x - \min(x)}{\max(x) - \min(x)}$$

式中: $\max(x)$ 为样本数据的最大值; $\min(x)$ 为样本数据的最小值。

2) 基于带外误差理论, 以目标站点为基准,

将目标预测站上下游水文站径流数据作为特征 \mathbf{x}^* , 对目标预测站进行特征选择。首先, 将径流样本通过重复抽样的方式构建样本, 训练模型, 然后利用剩余样本对模型进行评估, 并计算样本误差, 记作 E_1 , 最后将剩余样本加入噪声, 计算剩余样本的误差, 记作 E_2 , 特征 $f_i(\mathbf{x}^*)$ 的重要性可定义为

$$f_i(\mathbf{x}^*) = \sum_{i=1}^N \frac{E_{2i} - E_{1i}}{N}$$

$f_i(\mathbf{x}^*)$ 值越大, 表明特征 \mathbf{x}^* 的重要程度越高。

3) 将归一化并经过特征选择的数据首先进行边界拓延, 然后进行 EEMD 分解, 分解为若干本征模态分量, 并将各分量分别拆分为训练集和测试集;

4) 对训练集与测试集进行数据划分, 将过去 5 d(通过实验分析, 将预测集序列长度设置为 5 模型效果最优)设置为输入变量, 分别对未来 1、4、6、16、21、31 d 进行预测;

5) 对预测分量进行重组, 由此得到输出序列。

3 结果和分析

本文选取黄河流域 2002—2019 年径流观测

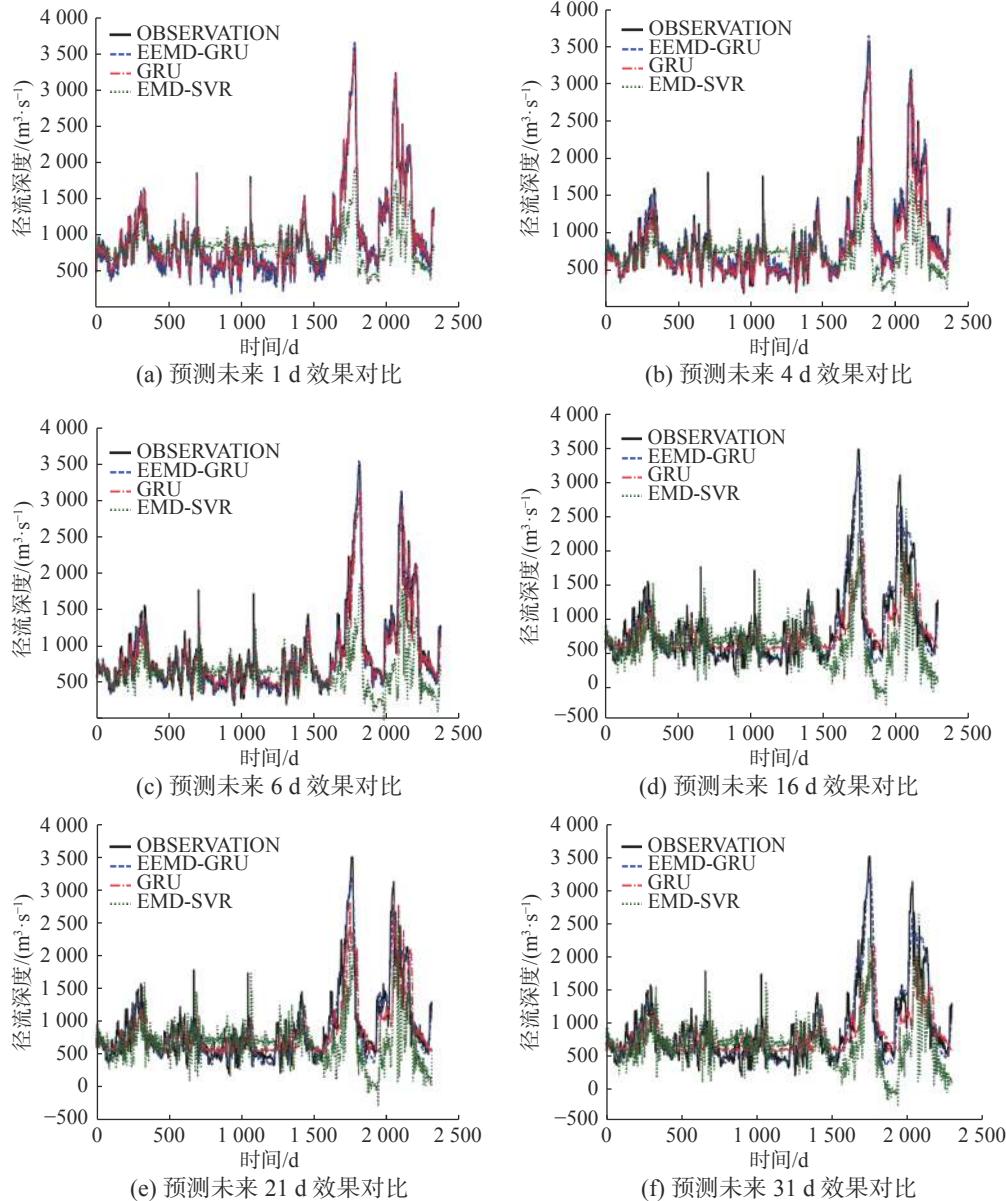


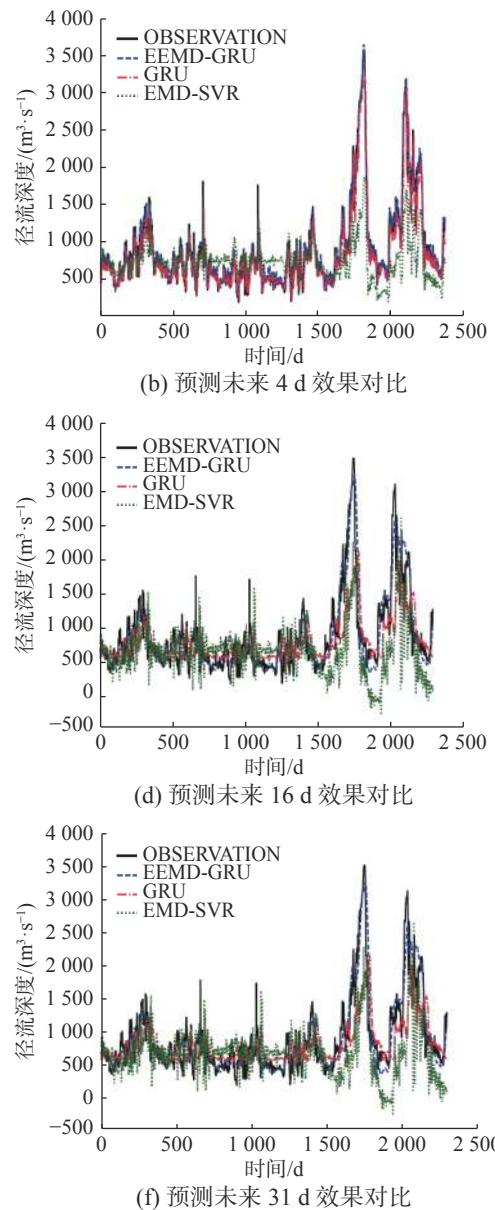
图 3 不同模型不同时间尺度下的预测曲线对比

Fig. 3 Comparison of prediction curves under different models and different time scales

根据图 3 可知, 在低延时的未来预测中, EEMD-GRU 与 GRU 表现能力相似, 但是随着预测天数的增加, EEMD-GRU 相对于 GRU 和 EMD-SVR 具

数据作为数据支撑, 以 EMD-SVR^[27] 和 GRU^[28] 作为对比模型, 以纳什指数 (E_{ns})、平均绝对误差、相关误差、运行时间 (run time) 作为评估标准, 实现对算法的可信度、稳定性、精准度和执行效率的全面评估。其中 E_{ns} 纳什效率系数用于评估预测模型的可信度与稳定性。 E_{ns} 取值为负无穷至 1, E_{ns} 接近 1, 表示模式质量好, 模型可信度高。相对误差和平均绝对误差分别评估实时误差与整体误差。

并行 EEMD-GRU 方法及 EMD-SVR 方法分别对未来 1、4、6、16、21、31 d 径流深度进行预测, 结果如图 3 所示。



有较高的精确度。由于 EEMD 可有效提高 GRU 模型的鲁棒性。使得固定未来天数, 调整预测序列的特征和序列长度, EEMD-GRU 相比 GRU 模

型稳定性高。

根据图 4 可以了解到, EEMD-GRU 相对于 GRU 模型和 EMD-SVR 模型, 预测误差更小, 精

度更高, 且相对于其他模型更加稳定。由于 EMD 方法存在模态混叠和端点效应, EMD-SVR 模型预测精度最差。

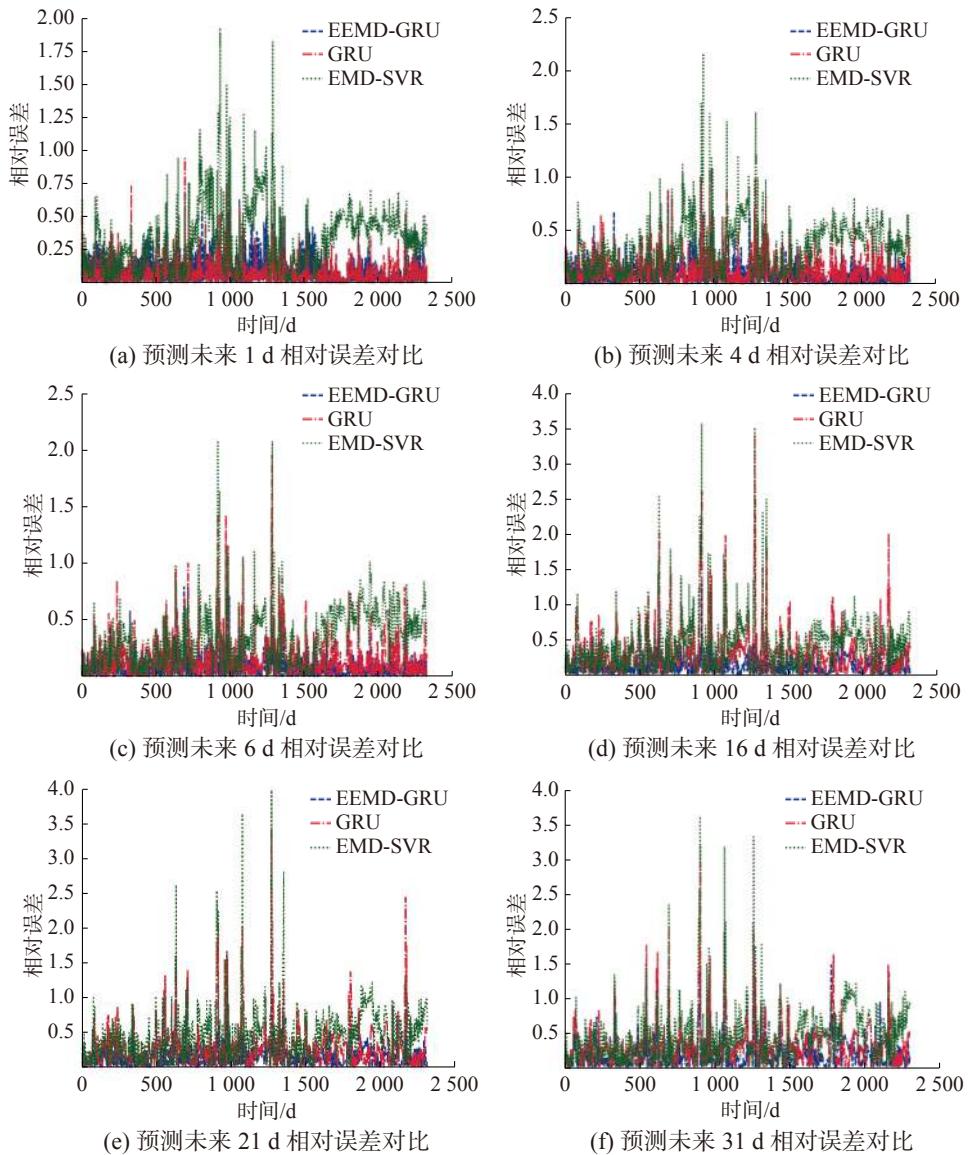


图 4 不同模型不同时间尺度下的相对误差对比

Fig. 4 Comparison of relative errors of different models and different time scales

综合表 1 与图 5, 由于 EEMD-GRU 引入了分解合成策略, 有效提高了模型的非稳态信号处理能力, 模型的预测精度提高, 可信度增强。算法的运行时间可以作为算法运行效率的一个衡量标准, EEMD-GRU 模型相对于 EMD-SVR 模型由于加入了并行计算的概念, 使得模型的整体预测效

率提高。

图 6 反应了各个算法在预测过程中的实时可信度表现。在中长期径流预测中, 预见期的增加, 序列的非稳态性增强, 对模型的鲁棒性要求更高。预见期为未来 16 d、31 d 时, EMD-SVR 和 GRU 模型相对于 EEMD-GRU 模型, 可信度较差。

表 1 不同模型不同时间尺度下指标数值对比

Table 1 Comparison of index values under different models and different time scales

预见期(未来)/d	模型	E_{ns}	平均绝对误差	运行时间/s
1	EEMD-GRU	0.986	53.275	0.062
	GRU	0.953	92.375	0.781
	EMD-SVR	0.403	304.371	1.374

续表 1

预见期(未来)/d	模型	E_{ns}	平均绝对误差	运行时间/s
4	EEMD-GRU	0.963	84.841	0.046
	GRU	0.882	138.948	1.062
	EMD-SVR	0.348	314.534	1.687
6	EEMD-GRU	0.961	85.480	0.046
	GRU	0.847	158.460	0.890
	EMD-SVR	0.230	336.510	1.453
16	EEMD-GRU	0.909	126.920	0.047
	GRU	0.651	242.192	0.828
	EMD-SVR	0.186	360.657	1.593
21	EEMD-GRU	0.895	137.606	0.047
	GRU	0.564	253.497	0.797
	EMD-SVR	0.082	389.773	1.671
31	EEMD-GRU	0.824	168.525	0.062
	GRU	0.419	287.513	0.797
	EMD-SVR	0.047	395.967	1.656

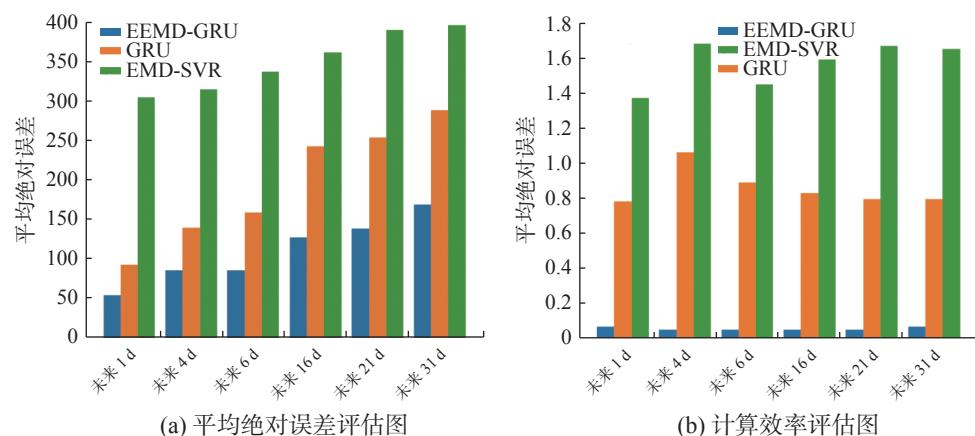
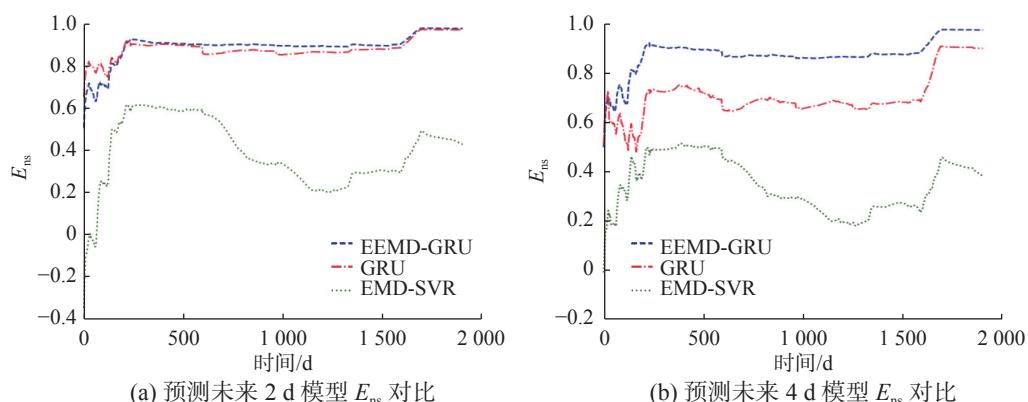
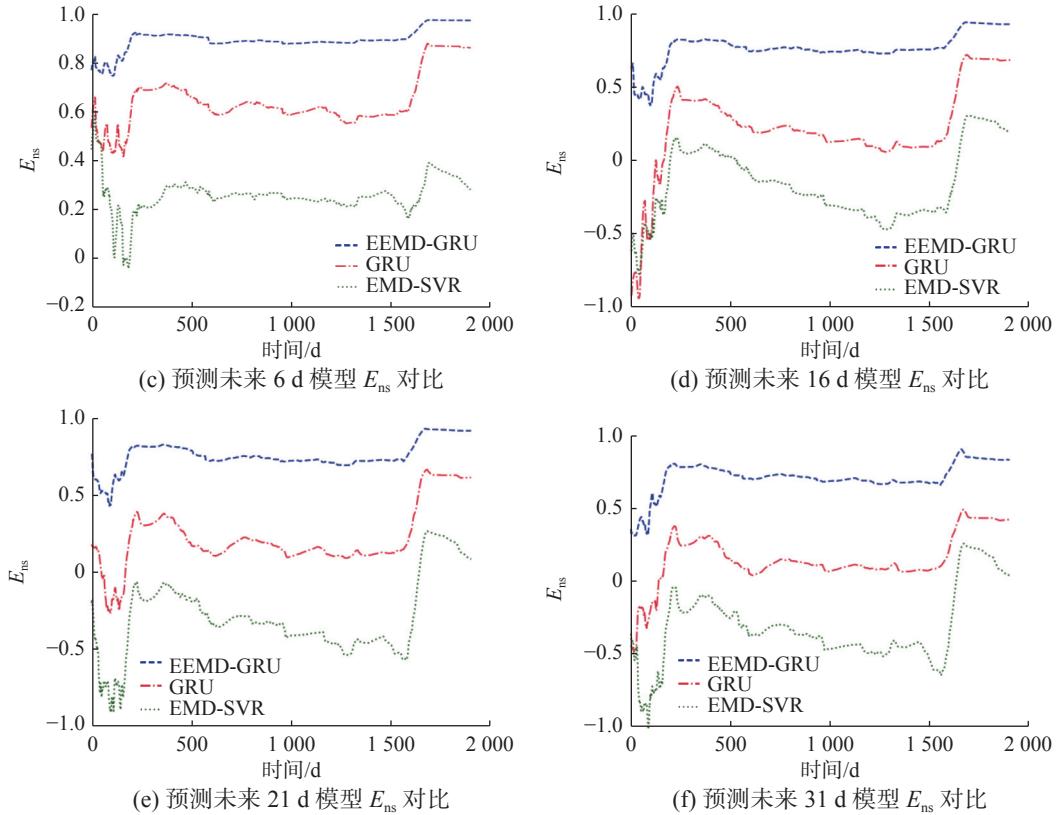


图 5 智能计算模型指标评估图

Fig. 5 Intelligent calculation model index evaluation chart



图 6 智能计算模型 E_{ns} 评估图Fig. 6 Intelligent calculation model E_{ns} evaluation chart

4 结束语

本文在模态分解方法与深度学习方法的思想上, 构造了并行 EEMD-GRU 径流预测方法, 主要结论有:

1) 本文所提出的并行 EEMD-GRU 模型对于不同预测步长, 预测时间均有较高的精度、可信度和预测效率, 预测模型具有一定的泛化性和鲁棒性, 通过与原生 GRU 模型和 EMD-SVR 模型的对比中发现, 所构建的混合模型精准度、可信度和效率高于其他模型。

2) 由于引入了 EEMD 分解算法, 使得混合模型整体计算性能有所下降, 虽然所引入的并行计算思想可以有效解决模型计算消耗, 但随之而来的的确是内存消耗问题, 希望在今后的研究中更加关注模型的高性能计算, 使得模型综合能力可以进一步提升。

参考文献:

- [1] LIU Lüliu, XIAO Chan, DU Liangmin, et al. Extended-range runoff forecasting using a one-way coupled climate-hydrological model: case studies of the Yiluo and Beijiang Rivers in China[J]. *Water*, 2019, 11(6): 1150.
- [2] WANG Jida, SHENG Yongwei, TONG T S D. Monitoring decadal lake dynamics across the Yangtze Basin downstream of Three Gorges Dam[J]. *Remote sensing of environment*, 2014, 152: 251–269.
- [3] LIANG Zhongmin, LI Yujie, HU Yiming, et al. A data-driven SVR model for long-term runoff prediction and uncertainty analysis based on the Bayesian framework[J]. *Theoretical and applied climatology*, 2018, 133(1/2): 137–149.
- [4] SONG Peibing, LIU Weifeng, SUN Jiahui, et al. Annual runoff forecasting based on multi-model information fusion and residual error correction in the Ganjiang river basin[J]. *Water*, 2020, 12(8): 2086.
- [5] CHU Haibo, WEI Jiahua, LI Jiaye, et al. Improved medium-and long-term runoff forecasting using a multimodel approach in the Yellow River headwaters region based on large-scale and local-scale climate information[J]. *Water*, 2017, 9(8): 608.
- [6] 梁浩, 黄生志, 孟二浩, 等. 基于多种混合模型的径流预测研究 [J]. 水利学报, 2020, 51(1): 112–125.
- [7] LIANG Hao, HUANG Shengzhi, MENG Erhao, et al. Runoff prediction based on multiple hybrid models[J]. *Journal of hydraulic engineering*, 2020, 51(1): 112–125.
- [8] WU Jian, LIU Haixing, WEI Guozhen, et al. Flash flood forecasting using support vector regression model in a small mountainous catchment[J]. *Water*, 2019, 11(7): 1327.
- [9] KOVACEVIĆ M, IVANIŠEVIĆ N, DAŠIĆ T, et al. Application of artificial neural networks for hydrological modelling in karst[J]. *Grădevinar*, 2018, 70(1): 1–10.

- [9] YUAN Ximin, ZHANG Xingyuan, TIAN Fuchang. Research and application of an intelligent networking model for flood forecasting in the arid mountainous basins[J]. *Journal of flood risk management*, 2020, 13(3): e12638.
- [10] LV Zhihua, ZUO Junjie, RODRIGUEZ D. Predicting of runoff using an optimized SWAT-ANN: a case study[J]. *Journal of hydrology: regional studies*, 2020, 29: 100688.
- [11] LIU Darong, JIANG Wenchao, MU Lin, et al. Streamflow prediction using deep learning neural network: case study of Yangtze River[J]. *IEEE access*, 2020, 8: 90069–90086.
- [12] TAO Xiong, BAO Yukun, HU Zhongyi. Does restraining end effect matter in EMD-based modeling framework for time series prediction? Some experimental evidences[J]. *Neurocomputing*, 2014, 123: 174–184.
- [13] 舒忠平, 杨智春. 抑制经验模分解边缘效应的极值点对称延拓法 [J]. *西北工业大学学报*, 2006, 24(5): 639–643.
SHU Zhongping, YANG Zhichun. A better method for effectively suppressing end effect of empirical mode decomposition (EMD)[J]. *Journal of Northwestern Polytechnical University*, 2006, 24(5): 639–643.
- [14] WU Fangji, QU Liangsheng. An improved method for restraining the end effect in empirical mode decomposition and its applications to the fault diagnosis of large rotating machinery[J]. *Journal of sound and vibration*, 2008, 314(3/4/5): 586–602.
- [15] JIN Xuebo, YANG Nianxiang, WANG Xiaoyi, et al. Hybrid deep learning predictor for smart agriculture sensing based on empirical mode decomposition and gated recurrent unit group model[J]. *Sensors*, 2020, 20(5): 1334.
- [16] GAO Wei, WAI R J. A novel fault identification method for photovoltaic array via convolutional neural network and residual gated recurrent unit[J]. *IEEE access*, 2020, 8: 159493–159510.
- [17] RADOJIČIĆ D, KREDATUS S. The impact of stock market price Fourier transform analysis on the Gated Recurrent Unit classifier model[J]. *Expert systems with applications*, 2020, 159: 113565.
- [18] XIAO Yi, LI Keying, HU Yi, et al. Combining STRIPAT model and gated recurrent unit for forecasting nature gas consumption of China[J]. *Mitigation and adaptation strategies for global change*, 2020, 25(7): 1325–1343.
- [19] XIE Ruimin, HAO Kuangrong, HUANG Biao, et al. Data-driven modeling based on two-stream λ gated recurrent unit network with soft sensor application[J]. *IEEE transactions on industrial electronics*, 2020, 67(8): 7034–7043.
- [20] YAN Ruiqing, LIU Wei, ZHU Meng, et al. Real-time abnormal light curve detection based on a gated recurrent unit network[J]. *Research in astronomy and astrophysics*, 2020, 20(1): 7.
- [21] DEVI A S, MARAGATHAM G, BOOPATHI K, et al. Hourly day-ahead wind power forecasting with the EEMD-CSO-LSTM-EFG deep learning technique[J]. *Soft computing*, 2020, 24(16): 12391–12411.
- [22] HASAN N. A methodological approach for predicting COVID-19 epidemic using EEMD-ANN hybrid model[J]. *Internet of things*, 2020, 11: 100228.
- [23] LIU Guancong, XIAO Xia, SONG Hang, et al. Precise detection of early breast tumor using a novel EEMD-based feature extraction approach by UWB microwave[J]. *Medical and biological engineering and computing*, 2021, 59(3): 721–731.
- [24] LIU Wei, LI Peiyao, WANG Keyu, et al. Coal-gangue interface detection based on ensemble empirical mode decomposition energy entropy[J]. *IEEE access*, 2021, 9: 54639–54648.
- [25] HABEN S, ARORA S, GIASEMIDIS G, et al. Review of low voltage load forecasting: methods, applications, and recommendations[J]. *Applied energy*, 2021, 304: 117798.
- [26] VALERO M, LI Fangyu, ZHAO Liang, et al. Vibration sensing-based human and infrastructure safety/health monitoring: a survey[J]. *Digital signal processing*, 2021, 114: 103037.
- [27] DUAN W Y, HAN Y, HUANG L M, et al. A hybrid EMD-SVR model for the short-term prediction of significant wave height[J]. *Ocean engineering*, 2016, 124: 54–73.
- [28] GAO Shuai, HUANG Yuefei, ZHANG Shuo, et al. Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation[J]. *Journal of hydrology*, 2020, 589: 125188.

作者简介:



刘扬, 副教授, 主要研究方向为智慧水利、机器学习、数据分析。参与水利重大科技、南水北调工程安全等项目 20 余项。发表学术论文 30 余篇。



王立虎, 硕士研究生, 主要研究方向为水利大数据、智能云计算、机器学习和深度学习。发表学术论文 6 篇。



杨礼波, 副教授, 主要研究方向为机器学习、模式识别、数据挖掘和信息管理。发表学术论文 10 余篇。