

DOI: 10.19797/j.cnki.1000-0852.20200490

改进VMD-QR-ELM混合模型在径流预报中的应用

刘扬, 王立虎, 杜帅兵, 赵丽, Muhammad Abdullah Shakir

(华北水利水电大学 信息工程学院, 河南 郑州 450046)

摘要:以黄河流域石嘴山水文站2002—2019年径流数据为研究对象,根据其数据分布特征构建基于并行VMD-QR-ELM模型的径流预测方法。实验结果表明,基于并行VMD-QR-ELM的径流预测方法相比于传统极限学习模型(ELM),精准度提高73.28%,可信度提高38.78%,相对于串行模型其效率提高87.5%。

关键词:变分模态分解;正交三角分解;径流预测;并行计算;极限学习

中图分类号:TV124;P338 **文献标识码:**A **文章编号:**1000-0852(2022)06-0031-04

0 引言

径流作为水循环的关键环节,对其进行准确、高效、稳定的预测具有重要意义。如今,变化环境下径流的波动系数不断加大,径流预报工作面临前所未有的新挑战。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。机理驱动模型如利用坡度,土壤湿度和暴风雨持续时间三种指标建立方程,改进SCS-CN模型,进行区域径流预报^[1];通过Eck-hardt递归数字滤波法对春汛来水进行预报^[2]。数据驱动模型如利用GRU和LSTM网络进行短期径流预测^[3];或者利用人工神经网络对降雨径流进行预报^[4]。然而,机理驱动模型往往存在外部干扰因素众多,机理认识不深刻等问题。以统计科学为基础的数据驱动模型,因时序数据的非平稳性,易变性和数据采集设备的误差,往往会导致模型精度低,泛化能力差。

极限学习机(ELM)由Huang等人于2004年提出^[5],目的是提高反向传播算法的学习效率,同时简化算法学习参数。极限学习已经被广泛应用于时间序列预测,实践证明相对于人工神经网络,极限学习具有更高的效率和精度。变分模态分解(VMD)是一种自适应、完全非递归的信号处理方法。文献[6]将VMD和梯度增强回归神经网络(GBRT)进行融合,构建

VMD-GBRT混合模型,并将其应用于月径流量预测,实验表明,其所构建的VMD-GBRT模型相比于EEMD-GBRT模型具有更低的误差和更高的确定系数。文献[7]将VMD与核极限学习(KELM)相结合,构建VMD-KELM模型并应用于时序预测,结果表明,VMD-KELM模型具有更高的预测精度,然而,VMD在分解过程中往往会出现端点效应,导致分解信号失去物理意义。

综上所述,文章首先以极值拓延法改进变分模态分解(VMD)端点效应,然后以QR分解重定义ELM隐藏层输出,构建一种基于QR分解的ELM模型QR-ELM。进而将改进后的VMD与QR-ELM进行融合,构建VMD-QR-ELM预测模型,最后为提高模型工作效率,将并行计算思想引入VMD-QR-ELM模型,构建并行VMD-QR-ELM模型。文章将黄河流域径流数据为研究对象,根据其数据分布特征构建基于并行VMD-QR-ELM模型的径流预测方法,为短期防洪减灾和长期水资源分配提供决策支持。

1 径流预报方法构建

1.1 研究对象

预报对象为黄河流域干流石嘴山水文站洪峰流量。历史径流资料采用水利部所提供的石嘴山水文站2002—2019年日尺度径流数据。石嘴山水文站位

收稿日期:2020-11-24

网络首发日期:2022-11-25

网络首发地址:<https://kns.cnki.net/kcms/detail/11.1814.P.20221124.2056.012.html>

作者简介:刘扬(1979—),女,河南郑州人,副教授,硕导,博士,主要从事深度学习,数据挖掘,水利大数据分析等方面的研究。E-mail: ly_research@126.com;15838080515@126.com

于宁夏与内蒙古毗邻的石嘴山市,是黄河流域重要的报汛站之一,集水面积为309 146 km²(见图1)。

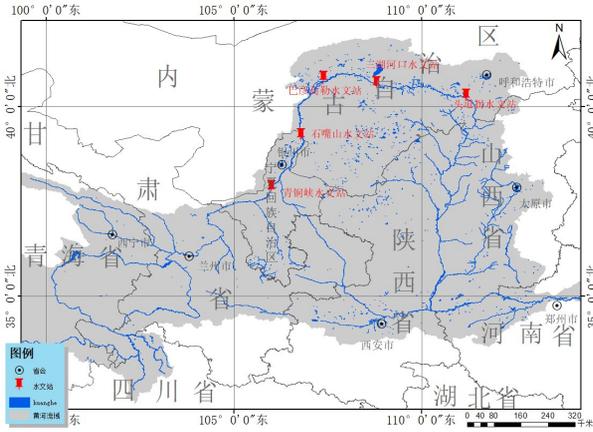


图1 石嘴山水文站地理位置

Fig.1 The location of Shizuishan hydrological station

1.2 改进方案

由于VMD分解过程中采用信号截断以及Hilbert变换,导致其产生端点效应,降低了分解精度^[8]。解决模态分解边界效应的方法一般是对信号进行边界拖延^[9]。皮尔逊相关系数是采用两个随机变量的相关程度来表示,其相关程度越高,皮尔逊相关系数越大,越能够表明其统计相关。文章利用皮尔逊相关系数作为波形匹配函数对原始信号进行边界拖延,具体步骤如下。

(1)对于给定原始径流信号 f_{Runoff} ,首先获取径流信号的所有局部极值点,并设 M_{max} 为极大值集合、 E_{min} 为极小值集合。

(2)定义 $f_{Runoff}(t)$ 最左端相邻极值分别为 E_0 和 M_0 (设 E_0 为极小值, M_0 为极大值),左端点定义为 $f_{Runoff}(0)$, $f_{Runoff}(0)$ 与 M_0 之间的波形定义为 W_0 ,长度为 l 。

(3)以 M_{max} 中除点 M_0 以外的每个极大值 M_i 为参考点,定义 W_i 为以 M_i 为终点,长度为 l 的子波。以皮尔逊相关系数 M_p 计算子波 W_i 与 W_0 的匹配程度。定义为公式(1):

$$M_p(W_i, W_0) = \frac{\sum_{i=1}^N (W_i - \bar{W}_i)(W_0 - \bar{W}_0)}{\sqrt{\sum_{i=1}^N (W_i - \bar{W}_i)^2 \sum_{i=1}^N (W_0 - \bar{W}_0)^2}} \quad (1)$$

(4)记, $M_{pmax} = \max\{M_{pW_0W_1}, M_{pW_0W_2}, \dots, M_{pW_0W_i}, \dots, M_{pW_0W_n}\}$ 假设 $M_{pmax} = M_{pW_0W_i}$,则拓延 W_i 前若干子信号至 $f_{Runoff}(t)$ 左端。

(5)利用同样原理拓延原始径流信号的右边界。

1.3 改进VMD-QR-ELM模型构建

改进VMD-QR-ELM首先以极值拓延法解决VMD端点效应,然后以改进的VMD方法将原始径流信号分解为若干本征模态分量(IMF),以完成非稳态时序信号向稳态时序信号的转变^[10]。然后以QR分解替代传

统的奇异值分解(SVD)方案,对极限学习机的输出进行整体优化,并提高传统ELM模型的运算效率^[11-13]。其基本实现如下。

设 f_{Runoff} 为原始径流信号,将变分模态分解问题描述为利用中心频率求 K 个有限带宽的模态函数 $u_k(t)$, $k=1, 2, \dots, k$,从而使每个模态分量的带宽估计之和最小。所有IMF分量的和等于原始信号 f_{Runoff} ,具体表达式如下:

$$\min_{\{u_k, \omega_k\}} \left\{ \sum_{k=1}^K \left\| \frac{\partial \left[\delta(t) + \frac{j}{\pi t} \right] \otimes u_k(t) e^{-j\omega_k t}}{\partial t} \right\|_2^2 \right\}, s.t. \left\{ \sum_{k=1}^K u_k = f_{Runoff} \right\} \quad (2)$$

式中: $\{u_k\} = \{u_1, u_2, \dots, u_k\}$ 代表分解得到的 k 个IMF分量; $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_k\}$ 代表分量的中心频率; \otimes 为卷积计算, K 为模态函数的总数, $\delta(t)$ 为狄拉克分布, $e^{-j\omega_k t}$ 为复平面上模态函数中心频率的向量描述, k 是模态函数的中心频率, ∂_t 为对时间 t 求偏导^[14]。

对于任意 n 个训练样本 $u_k(t)$, m 个隐层节点,激活函数为 $g(x)$ 的ELM模型可以定义为公式(3):

$$\sum_{i=1}^m \beta_i g(w_i g(t)_j + b_i) = Q_j, j=1, 2, \dots, n \quad (3)$$

式中: w_i 为连接第 i 个隐藏层节点和输入节点的权重; b_i 是第 i 个隐藏层节点的偏差; Q_j 为模型的输出。 $w_i u_k(t)_j$ 为 w_i 和 $u_k(t)_j$ 的内积。该方程可重写如下^[15-18]:

$$H\beta = T \quad (4)$$

在标准ELM算法中,通常利用奇异值分解(SVD)方法得到隐藏层输出。对于任意 $m \times n$ 阶矩阵 H ,SVD分解可定义为公式(5):

$$H = U \Sigma V^T \quad (5)$$

式中: U 和 V 是正交酉矩阵,其中 $\Sigma = \begin{pmatrix} \Delta & 0 \\ 0 & 0 \end{pmatrix}$, Δ 为可逆对角矩阵。

文章在得到ELM模型的隐藏层输出过程中,以QR分解方法重定义 H^* 解决方案。QR分解的基本形式可以定义如下:

$$A = QR \quad (6)$$

其中: Q 是正交矩阵, R 是上三角矩阵。因此QR-ELM定义如下:

$$H^* T = R_{i+1}^{-1} Q_{i+1}^T T = \begin{bmatrix} R_i^{-1} & -R_i^{-1} r_{i+1} & r_{i+1, i+1}^{-1} \\ 0 & r_{i+1, i+1} & \end{bmatrix} \begin{bmatrix} Q_i^T \\ Q_{i+1}^T \end{bmatrix} T = \begin{bmatrix} f_i - R_i^{-1} r_{i+1} f_{i+1}^T \\ f_{i+1}^T \end{bmatrix} \quad (7)$$

Gram-Schmidt正交化实现QR分解,同基于Jacobi旋转的SVD分解相比,QR分解在解决增量学习方面

有较强优势^[9]。

1.4 基于并行VMD-QR-ELM的径流预测方法

文章将VMD与QR-ELM极限学习机相融合,提出一种新的基于增强极限学习机的预测模型(VMD-QR-ELM模型)。模型中,为解决径流监测序列的不稳定性,首先利用VMD模型将原始径流信号分解为若干个稳态IMF分量;然后以IMF分量作为QR-ELM模型的输入,对其进行预测。最后为满足径流预测的实时性要求,文章将并行计算方法引入径流预测方法的构建中,提出并行VMD-QR-ELM方法,其基本实现流程见图2。

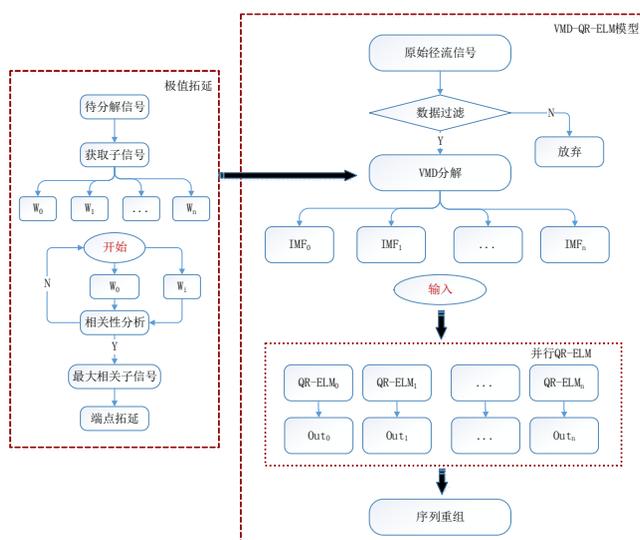


图2 并行VMD-QR-ELM结构流程

Fig.2 Structure flow of parallel VMD-QR-ELM

以石嘴山水文站为例:

(1) 实时采集水文站径流数据,通过数据清洗技术,对空数据,非数值型数据等进行过滤。

(2) 将过滤后的数据进行VMD分解,分解为若干个IMF分量,然后利用交叉验证方法,将各分量拆分为训练集和测试集合,测试集占比为0.35。

(3) 采用模型计算流水线和集中调度的动态任务分配方案作为QR-ELM并行策略,将被分解的IMF训练集和测试集并行输入QR-ELM模型。

(4) 利用并行QR-ELM模型分别预测石嘴山水文站未来2天、5天、21天、31径流数据,以此获得未来径流变化趋势。

1.5 评估标准

文章选用纳什指数(E_{ns}),平均绝对误差(MAE),相对误差(RE)和运行时间(Run Time)作为评估标准,以评估VMD-QR-ELM模型的可信度,精准度和执行

效率。其中, E_{ns} 用于评估预测模型的可信度, E_{ns} 取值为负无穷至1, E_{ns} 接近1,表示模式质量好, E_{ns} 远小于0,表示模型是不可信的。相对误差(RE)和平均绝对误差(MAE)分别评估实时误差与整体误差。运行时间用以评估模型效率。

2 结果和分析

文章选取石嘴山水文站径流数据,训练集划定为2002年至2014年,验证集为2014年2019年,以传统ELM为对比模型,对文章提出的并行VMD-QR-ELM模型进行验证。基于并行VMD-QR-ELM的洪水预测方法及ELM方法以验证数据作为输入分别对未来2天、5天、21天、31天径流深度进行预测的误差如图3所示。

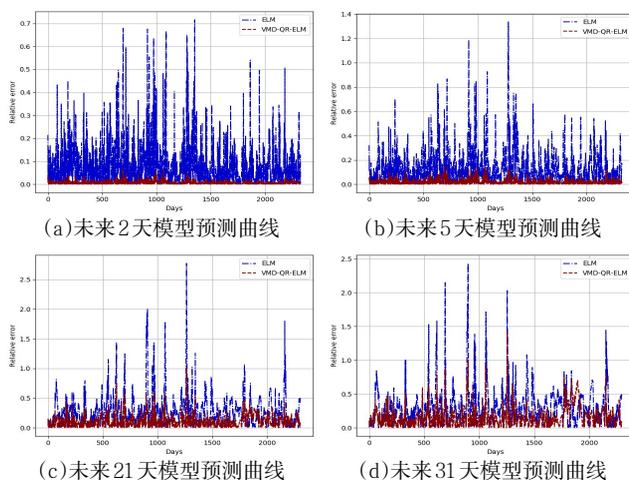


图3 不同时间预测实时误差

Fig.3 The real-time error of prediction at different times

从图3可以看到,当预见期为未来2天和5天时,VMD-QR-ELM的误差水平相对于ELM具有更高的优势,并且,调整输入步长,VMD-QR-ELM具有误差水平更加稳定。

综合图4、表1可以看到预见期为未来2天,预见期为未来2天、5天、21天和31天时,VMD-QR-ELM方法相对于ELM方法, E_{ns} 分别提高4.3%,11.8%,55.8%和83.2%,MAE分别降低93.0%,86.4%,62.6%和51.1%。由表2可以看到文章所提出的基于并行VMD-QR-ELM的预测方法相对于串行VMD-QR-ELM方法,其效率提高87.5%,相对于ELM效率提高32.7%。文章所提出的VMD-QR-ELM模型相对于传统ELM模型具有更高的精度和可信度,但是文章所引入的VMD分解方法在一定程度上增加了模型的运算消耗,导致模型的效率降低。

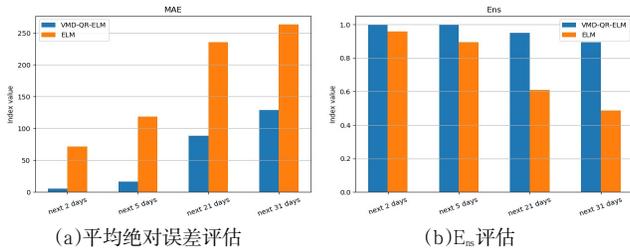


图4 智能计算模型性能评价
Fig.4 Performance evaluation of intelligent computing model

表1 评估指标对比

Table1 Comparison of evaluation index values

预测时间	模型	E_{ns}	MAE
未来2天	VMD-QR-ELM	0.999 811	5.307 721
	ELM	0.958 849	71.450 773
未来5天	VMD-QR-ELM	0.998 283	16.373 623
	ELM	0.893 084	118.481 497
未来21天	VMD-QR-ELM	0.949 139	88.224 304
	ELM	0.609 085	235.138 478
未来31天	VMD-QR-ELM	0.894 411	128.667 365
	ELM	0.487 594	263.176 038

表2 模型预测效率对比

Table2 Comparison of model prediction efficiency

模型	预处理时间/s	计算时间/s
并行VMD-QR-ELM	20.092	0.077
串行VMD-QR-ELM	20.092	0.616
QR-ELM	0	0.073
ELM	0	0.055

3 结论

以现有模态分解方法和深度学习方法为基础,结合并行计算思想构造一种基于并行VMD-QR-ELM的径流预测方法,主要结论如下:

(1)该方法对于不同预测步长,预测时间均有较高的精度,通过与极限学习模型的对比,所构建的混合模型VMD-QR-ELM相对于传统ELM模型其精准度提高73.28%。

(2)在模型可信度方面,本文所提出的VMD-QR-ELM模型相比于ELM模型提高38.78%。

(3)通过引入并行计算,进而构建并行VMD-QR-ELM方法,实验结果表明并行VMD-QR-ELM相对于串行VMD-QR-ELM方法运行效率提高87.5%。

(4)VMD-QR-ELM模型由于额外增加了数据分解的过程,使得模型性能降低,虽然本文所提出的并行VMD-QR-ELM相对于串行模型性能有所提高,但仍不能根本解决分解合成所带来的性能消耗。

参考文献:

- [1] SHI W , WANG N . An improved SCS- CN method incorporating slope, soil moisture, and storm duration factors for runoff prediction [J]. Water, 2020, 12(5):1335.
- [2] 李文龙, 次旦央宗, 王傲. 白山流域春季径流影响因素及作用机理识别[J]. 水利水电技术, 2019, 50(5).
- [3] GAO S , HUANG Y , ZHANG S , 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.
- [4] NOURANI V , KOMASI M , MANO A . A Multivariate ANN-Wavelet approach for rainfall - runoff modeling [J]. Water Resources Management, 2009, 23(14):2877.
- [5] HUANG G B , ZHU Q Y , SIEW C K . Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70(1/3): 489-501.
- [6] ZHANG D , CHEN S , LING L , et al. Forecasting agricultural commodity prices using model selection framework with time series features and forecast horizons[J]. IEEE Access, 2020, PP(99): 28197-28209.
- [7] HE X , LUO J , LI P , et al. A Hybrid Model Based on Variational Mode Decomposition and Gradient Boosting Regression Tree for Monthly Runoff Forecasting[J]. Water Resources Management, 2020, 34(4).
- [8] 姜婷,高舒芳.基于改进变分模态分解与双尺度分形维数的发动机故障诊断[J]. 车用发动机,2020(1):69-75.
- [9] TIAN Z , LI S , WANG Y . A prediction approach using ensemble empirical mode decomposition-permutation entropy and regularized extreme learning machine for short-term wind speed [J]. Wind Energy, 2020, 23(2).
- [10] TIAN Z , LI S , WANG Y . A prediction approach using ensemble empirical mode decomposition-permutation entropy and regularized extreme learning machine for short-term wind speed [J]. Wind Energy, 2020, 23(2).
- [11] GUO S S , XIE W , ZHU L F , et al. Adaptive Hybrid Soft-Sensor Model of Grinding Process Based on Regularized Extreme Learning Machine and Least Squares Support Vector Machine Optimized by Golden Sine Harris Hawk Optimization Algorithm [J]. Complexity, 2020, 2020.
- [12] WANG K , PEI H , CAO J , et al. Robust regularized extreme learning machine for regression with non-convex loss function via DC program[J]. Journal of the Franklin Institute, 2020.
- [13] WANG Q , DAI X , ZHOU D . Dynamic Correlation and Risk Conta-