

DOI: 10.11830/ISSN.1000-5013.202001027



# 结合时间序列分解和神经网络的 河流溶解氧预测

卢毅敏<sup>1,2,3</sup>, 张红<sup>1,2,3</sup>

(1. 福州大学 空间数据挖掘与信息共享教育部重点实验室, 福建 福州 350108;  
2. 福州大学 地理空间信息技术国家地方联合工程研究中心, 福建 福州 350108;  
3. 数字中国研究院(福建), 福建 福州 350003)

**摘要:** 为克服小流域数据资料少,河流溶解氧的非平稳特性及动态变化造成的预测困难,提出结合具有自适应噪声的完整集成经验模态分解(CEEMDAN)和 Elman 动态神经网络的预测方法. 使用 CEEMDAN 方法对原始溶解氧时序数据进行平稳化处理及降噪,提取溶解氧随时间变化的波动特征、周期特征,以及长期趋势,通过计算样本熵(SE)值,将相似的特征序列合并,以减小误差累积,对合并后的新序列分别采用布谷鸟搜索(CS)算法优化的 Elman 模型进行预测,将各预测值叠加,得到最终预测结果. 实验结果表明:CEEMDAN-SE-CS-Elman 方法平均绝对误差( $E_{MA}$ )为 0.14;平均绝对百分误差( $E_{MPA}$ )为 2.07%;均方根误差( $E_{RMS}$ )为 0.24;可决系数( $R^2$ )达到 0.951 6,精度较其他时间序列预测模型有所提高.

**关键词:** 河流溶解氧; 预测模型; CEEMDAN; 样本熵; 布谷鸟搜索算法; Elman 神经网络

**中图分类号:** TP 183; X 832      **文献标志码:** A      **文章编号:** 1000-5013(2020)05-0659-08

## Prediction of River Dissolved Oxygen Combined Times Series Decomposition and Neural Network

LU Yimin<sup>1,2,3</sup>, ZHANG Hong<sup>1,2,3</sup>

(1. Key Lab of Spatial Data Mining and Information Sharing of Ministry of Education,  
Fuzhou University, Fuzhou 350108, China;  
2. National Engineering Research Center of Geospatial Information Technology,  
Fuzhou University, Fuzhou 350108, China;  
3. Academy of Digital China (Fujian), Fuzhou 350003, China)

**Abstract:** In order to overcome the difficulties of prediction caused by the unstable characteristics and dynamic changes of river dissolved oxygen in small watershed with few data, a prediction method was proposed based on complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) and Elman dynamic neural network. The CEEMDAN method was used to stabilize and reduce the noise of the original dissolved oxygen time series data. The fluctuation characteristics, periodic characteristics and long-term trend of dissolved oxygen with time change were extracted. By calculating the sample entropy (SE) value, several sequences with similar feature were combined to reduce the error accumulation. The Elman model optimized by

the cuckoo search (CS) algorithm was adopted to predict the new recombined sequences respectively, and the final prediction result was obtained by superposing the prediction results of each sequence. The experimental results showed that the mean absolute error ( $E_{MA}$ ) of CEEMDAN-SE-CS-Elman method was 0.14, the mean absolute percentage error ( $E_{MPA}$ ) was 2.07%, the root mean square error ( $E_{RMS}$ ) was 0.24, and the coefficient of determination ( $R^2$ ) reached 0.9516. The prediction accuracy was improved compared with other time series forecasting models.

**Keywords:** river dissolved oxygen; forecasting models; CEEMDAN; sample entropy; cuckoo search algorithm; Elman neural network

河流中的溶解氧(DO)是反映水质状况及自净能力的重要指标<sup>[1]</sup>. 高质量浓度溶解氧有利于降解河流中各类污染物,并有效控制底泥释放氮、磷和有机物,当河流复氧速度远低于耗氧速度时,低质量浓度溶解氧将导致需氧生物死亡及水质恶化<sup>[2]</sup>. 因此,针对河流溶解氧预测的研究具有重要意义,为水质管理和污染预警提供决策支持.

基于机理模型的河流溶解氧预测方法需要大量的基础资料作为支撑<sup>[3]</sup>,而小流域资料贫乏,随着机器学习与智能传感器技术的快速发展,基于数据驱动的非机理组合预测模型逐渐兴起<sup>[4-7]</sup>. 但河流的动态性、不确定性,以及繁杂性使得河流溶解氧随着时间随机变化,呈现非线性、非平稳性特征<sup>[8]</sup>,预测精度难以提高. 文献[9-10]采用小波分解法进行平稳化处理及降噪,并取得较好的预测效果,但这些方法未对 DO 序列的不同时频特征进行深入挖掘,并且小波基函数依赖于人为选择,给预测结果带来一定主观影响. 经验模态分解(EMD)法很好地解决了这个问题<sup>[11]</sup>,仅根据数据自身极值特点进行分解,而具有自适应噪声的完整集成经验模态分解(CEEMDAN)法解决了 EMD 模态混叠问题<sup>[12]</sup>,以及集合经验模态分解(EEMD)存在大量集成平均计算次数的问题<sup>[13]</sup>. 因此,本文提出一种结合 CEEMDAN 分解和 Elman 动态神经网络的河流溶解氧预测模型.

# 1 研究方法

## 1.1 CEEMDAN 分解法

DO 时序数据具有明显的非线性和非平稳性特征,任一时间可具有多种波动模式,为了提取 DO 时序数据潜在的变化特性、周期特征,以及长期趋势,实现对 DO 序列时频特征的充分挖掘、平稳化处理及降噪,引入 CEEMDAN 分解法,使噪声残留引起的重构误差在分解阶段叠加抵消.

进行  $I$  次实验,通过对每次分解后的余量序列添加白噪声,并进行 EMD 分解,可得第  $k$  个模态分量 IMF  $k(t)$  及第  $k$  个余量  $R^k(t)$  为

$$\text{IMF } k(t) = \frac{1}{I} \sum_{i=1}^I E(r^{k-1}(t) + \epsilon^{k-1} E^{k-1}(w_i(t))),$$

(1)

$$R^k(t) = r^{k-1}(t) - \text{IMF } k(t).$$

(2)

式(1),(2)中: $I$  为 500; $\epsilon^{k-1}$  取值为  $\epsilon^0 [\text{std}((r^{k-1}(t))/\text{std}(E^{k-1}(w_i(t))))]$ , $\epsilon^0$  取 0.2,  $\text{std}(\cdot)$  为标准差算子,能使每个分解过程具有适当的信噪比; $E(\cdot)$  为分解算子.

当余量序列  $R^k(t)$  的极值点个数小于 2 时,结束分解,共得到  $k$  个代表 DO 序列不同时频特征的模态分量,以及代表 DO 序列长期趋势的最终余量  $R(t)$ . 原始 DO 时序数据  $S(t)$  可表示为

$$S(t) = \sum_{k=1}^K \text{IMF } k + R(t).$$

(3)

## 1.2 样本熵

若对分解后的每个 DO 时频特征都进行建模,会带来预测误差累积;若仅根据频率特征将各特征重组为高频、中频、低频 3 组,会丢失部分隐含的 DO 时序变化信息. 样本熵(SE)是通过计算时间序列的复杂度来衡量信号产生新模式的概率,抗噪能力强,采用较少的数据段即可得到稳定的熵值,可充分挖掘水环境系统复杂性<sup>[14]</sup>. 因此,文中以 SE 衡量 DO 各时频特征的自相似性,熵值越大,时频特征越复杂,特征序列的自相似性越小,所包含的特征信息与变化细节越重要,对 DO 预测结果影响越大,建模时

越应当保留. 将各 DO 时频特征依序分别组成维数为  $m$  和  $m+1$  的向量序列  $S_m = \{s_1, s_2, \dots, s_{t-m}\}$  和  $S_{m+1} = \{s_1, s_2, \dots, s_{t-m}\}$ , 其中,  $s_i = \{u_i, u_{i+1}, \dots, u_{i+m-1}\}$  ( $i=1, 2, \dots, t-m$ ) 为 IMF  $k(t)$  中第  $i$  个数据开始, 连续  $m+1$  个数据组成的向量,  $m$  取 4.

样本熵定义为

$$SE(m, r) = \lim_{t \rightarrow \infty} \left[ -\ln \frac{B^{m+1}(r)}{B^m(r)} \right]. \tag{4}$$

各时频特征的样本熵值计算式为

$$SE(m, r, t) = -\ln \frac{B^{m+1}(r)}{B^m(r)}. \tag{5}$$

式(4), (5)中:  $r$  取  $0.1 \sim 0.2 \text{std}(\text{IMF } k(t))$  具有较合理的统计特性, 文中取  $0.15 \text{std}(\text{IMF } k(t))$ ;  $B^m(r)$ ,  $B^{m+1}(r)$  分别为向量  $S_j$  与模板向量  $S_i$  的匹配概率.

将熵值近似的分量进行合并, 得到  $n$  个新的重组序列  $X_t = \{x_1, x_2, \dots, x_t\}$  ( $t=1, 2, \dots, T$ ).

1.3 CS 优化的 Elman 神经网络

DO 时序数据具有延续性及自相关性, 历史时序数据对未来指标值的变化具有很大影响. Elman 动态神经网络作为时间序列预测模型的一种, 承接层可以记忆一定程度的 DO 历史数据, 并与当前时刻 DO 值共同成为隐含层的当前输入. 这可以表达历史 DO 数据与未来 DO 数据间的时间延迟, 捕捉 DO 数据的时间变化特征, 具有适应时变特性的能力<sup>[15-17]</sup>. 新兴的布谷鸟搜索(CS)算法只有两个参数(待优化的初始权值与阈值组数  $n=25$ , 新解的概率  $p=0.25$ ), 通用性好, 搜索速率快, 不易陷入局部最小值, 能有效克服神经网络存在的问题<sup>[18-19]</sup>, 并消除预测过程中随机因素的干扰, 提高预测精度. 将误差值定义为适应度值  $fit$ , 依据莱维(Levy)飞行原理寻找新解, 采用偏好随机游动法替换该解, 即

$$x_i^{t+1} = x_i^t + \alpha \otimes \text{levy}(\lambda), \quad x_i^{t+1} = x_i^t + (R x_i^{t,p} - x_i^{t,q}). \tag{6}$$

式(6)中:  $\alpha > 0$  为步长缩放因子;  $\otimes$  为逐点乘积运算;  $\text{levy}(\lambda)$  为随机搜索路径, 可以产生随机步长;  $R$  为  $(0, 1)$  的随机数;  $x_i^{t,p}$ ,  $x_i^{t,q}$  表示  $t$  代的两个随机解. 最终得到最小适应度值  $fit_{\min}$  及最优解  $x_{\text{best}}$ .

1.4 组合预测模型的构建

基于 CEEMDAN 分解、SE 和 CS-Elman 动态神经网络构建的河流溶解氧预测方法流程图, 如图 1 所示. 首先, 使用 CEEMDAN 方法分解原始 DO 时序数据, 实现对非线性、非平稳性 DO 序列的平稳化处理及降噪, 充分挖掘 DO 时序信号中不同时间尺度的特征信息及噪声, 提取 DO 时序随时间变化的波

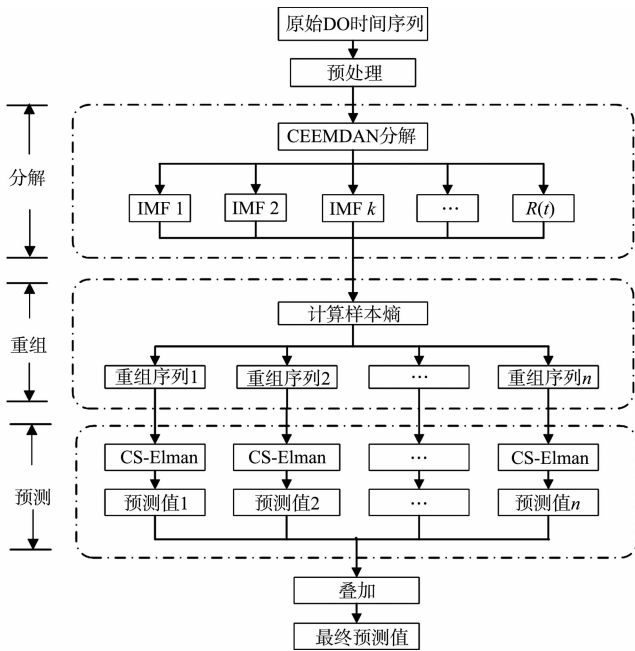


图 1 河流溶解氧预测方法流程图

Fig. 1 Flow chart of dissolved oxygen prediction in rivers

动特征、周期特征及长期趋势,然后,通过计算样本熵值衡量各时频特征的自相似性,将熵值近似的特征重新组合为新序列,以减小计算量和误差累积.同时,保留对 DO 预测结果具有重要影响的特征信息与变化细节.最后,对新序列分别构建 CS 优化的 Elman 预测模型,将预测值叠加,得到最终预测结果.

2 实验分析

2.1 数据预处理

以福建省的晋江流域为研究区域,该流域位于北纬  $24^{\circ}49'36''\sim 25^{\circ}35'13''$ ,东经  $117^{\circ}41'13''\sim 118^{\circ}41'49''$ ,流域总面积为  $5\,629\text{ km}^2$ ,河长为  $182\text{ km}$ ,河道平均坡降为  $1.9\%$ ,是福建省第 3 大河流,泉州市境内第一大河流,也是福建省经济最发达地区之一.晋江流域水资源是泉州市重要的饮用水源地,其水质优劣与泉州市经济发展和人民生活水平密切相关.

实验数据来源于福建省环保厅地表水质自动监测站点.晋江流域共有泉州石碇、安溪南英和南安秋阳 3 个地表水质监测站点,选取各站点 2017 年 3 月 27 日至 2019 年 1 月 2 日的 DO 监测数据作为研究数据.每日自 00:00 开始监测,每间隔 4 h 采样一次.由于监测设备故障、网络传输错误等问题,建模前必须对原始 DO 监测数据进行预处理.首先,依据 GB 3838—2002《地表水环境质量标准》和箱线图剔除异常值;其次,考虑到实验数据集缺失值很少,且 DO 数据一般短时间内波动较小,所以使用中值插补法对缺失值进行插补;最后,计算日均值,分别得到的 647 条日监测数据构成完整的 DO 时间序列  $S(t)=\{s_1,s_2,\cdots,s_t\}$ .

2.2 河流溶解氧质量浓度预测

DO 时间序列 CEEMDAN 分解结果,如图 2 所示.由图 2 可知:原始 DO 时序数据表现出明显的随机性和非线性,IMF 1~IMF 3 时频特征起伏变化明显,表明 DO 质量浓度受到随机影响;IMF 4~IMF 8 时频特征具有明显的周期特征,可知 DO 时间序列具有季节性变化;余量时频特征较为平缓,表明 DO 时间序列的长期趋势,各 IMF 分量迭代次数逐渐降低至 0,重构后相对百分比误差达到  $10^{-13}$  数量级,表明 DO 原始数据得到完全分解.




图 2 DO 时间序列 CEEMDAN 分解结果

Fig. 2 CEEMDAN decomposition results of DO time series

计算各 IMF 分量样本熵,如表 1 所示.表 1 中: $\Delta$  为差值.由表 1 可知:各分量的样本熵值整体表现为递减趋势,说明各分量随着波动频率降低,序列的复杂程度越小,随机性也越小;IMF 1 熵值最大,和相邻分量 IMF 2 的样本熵差值为 0.230,在所有相邻样本熵差值中为第 2 大,说明 IMF 1 与 IMF 2 之间

的相似性较小,两者所包含的特征信息与变化细节的差异较大,所以 IMF 1 对 DO 预测结果影响较大,建模时将 IMF 1 单独作为一个新的重组序列;IMF 2~IMF 4 熵值较大,且 IMF 2 与 IMF 3,IMF 3 与 IMF 4 之间的样本熵差值在所有差值中较大,说明 IMF 2~IMF 4 所包含的特征信息与变化细节对预测结果均有一定影响,也分别单独作为一个新的重组序列;IMF 5~IMF 7 熵值较小,序列的复杂程度较低,且 IMF 4 与 IMF 5 之间的样本熵差值在所有差值中最大,IMF 5 与 IMF 6,IMF 6 与 IMF 7 之间的样本熵差值最小,说明 IMF 4 与 IMF 5 所包含的特征信息的相似性很小,不应叠加,而 IMF 5~IMF 7 这 3 个分量具有一定的相似性,所以将这 3 个分量叠加作为一个新的重组序列;同理将余量与 IMF 8 叠加作为一个新的重组序列。

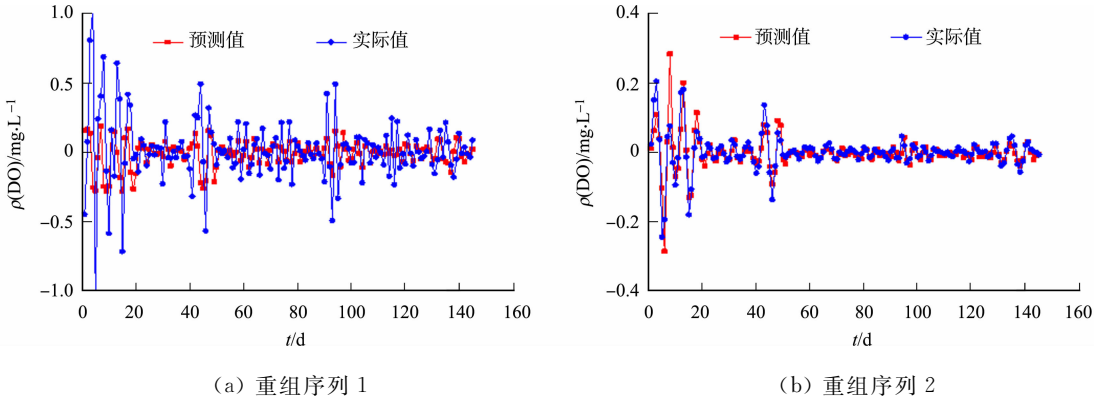
根据文献[20]计算各重组序列的平均周期,各重组序列的分量组成及其平均周期结果,各 IMF 分量重组结果,如表 2 所示.表 2 中: $T$  为平均周期.由表 2 可知:各重组序列的平均周期呈现递增趋势;重组序列 1~3 为分解出的高频率序列部分,平均周期分别为 6.55,8.44,12.27 d,表明短期内 DO 影响因子随机作用引起的 DO 质量浓度波动情况;重组序列 4,5 为分解出的中频率序列部分,平均周期分别为 23.28,51.92 d,表明河流 DO 质量浓度的月变化、季节性变化;重组序列 6 为分解出的低频部分,平均周期为 337.50 d,表明从长期看,晋江流域 DO 的周期性是按年度变化的。

表 2 各 IMF 分量重组结果  
Tab.2 Results of recombined of IMF components

参数	重组序列 1	重组序列 2	重组序列 3	重组序列 4	重组序列 5	重组序列 6
组成分量	IMF 1	IMF 2	IMF 3	IMF 4	IMF 5+IMF 6+IMF 7	IMF 8+余量
$t/d$	6.55	8.44	12.27	23.28	51.92	337.50

通过计算时间序列的自相关系数确定模型结构,当滞后阶数为  $N$  时,时间序列自相关系数较小,可以认为前  $N-1$  天的 DO 质量浓度对第  $N$  天的 DO 质量浓度影响最大,确定 Elman 模型输入神经元个数为  $N-1$ ,输出神经元个数为 1.对于重组序列  $X_i$ ,循环将连续  $N$  天的数据分为一组,用前  $N-1$  天的 DO 数据预测第  $N$  天的 DO 质量浓度,即前  $N-1$  天的 DO 时序数据作为输入,第  $N$  天的数据作为输出,得到样本  $P=\{p_1, p_2, \cdots, p_{T-N+1}\}$ ,其中,  $p_i=[x_i, x_{i+1}, \cdots, x_{i+N-1}]^T (i=1, 2, \cdots, T-N+1)$ ,共  $T-N$  组,将前  $3(T-N+1)/4$  组作为训练数据,后  $(T-N+1)/4$  组作为测试数据.  $N$  为 3,共得到 645 组实验数据,将前 500 组作为模型的训练数据,后 145 组作为测试数据。

将训练样本  $P=\{p_1, p_2, \cdots, p_{T-N+1}\}$  归一化,并输入 CS-Elman 模型,将最优初始权值和阈值  $x_{best}$  赋予 Elman 神经网络,使用误差反向传播和梯度下降法对各个隐含层神经元的权值系数进行修正,直到训练误差小于阈值.为保证模型高效、稳定运行,将 Elman 神经网络的学习速率设为 0.1,训练目标最小误差设为 0.000 1,隐含层输出采用激活函数 tansig 处理,模型训练结束后,将测试样本的 DO 数据输入到训练好的模型中进行预测,经过线性传递函数 purelin 处理并反归一化,得到各重组特征序列的预测结果,如图 3 所示.由图 3 可知:随着 DO 数据波动趋于平稳,预测值与实际值越相吻合。



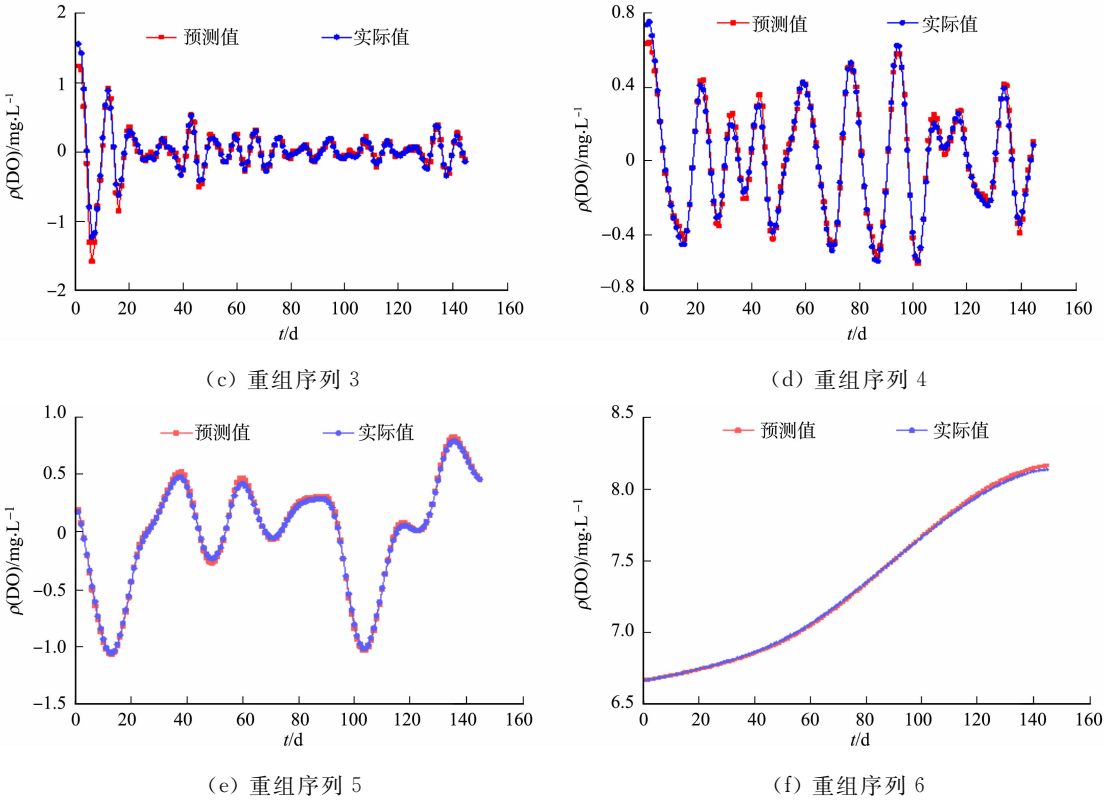


图 3 重组序列单步预测结果

Fig. 3 Single-step prediction results of recombined sequences

2.3 模型对比分析与精度评价

为评估文中模型(CEEMDAN-SE-CS-Elman)的有效性,将其与其他传统时间序列预测模型进行对比,结果如图 4 所示.由图 4 可知:文中模型的预测曲线更贴合真实曲线,预测精度更高.

精度评价结果,如表 3 所示.表 3 中: $E_{MA}$  为平均绝对误差; $E_{MPA}$  为平均绝对百分误差、 $E_{RMS}$  为均方根误差; $R^2$  为可决系数.由表 3 可知:相较于其他经典的时间序列预测模型(LSTM, ARIMA, Elman 动态神经网络预测),文中模型的精度更高,更适合作为晋江流域河流溶解氧预测的基准模型;相较于未分解的单一 Elman 模型,文中模型的  $E_{MA}$  提高 0.17,  $E_{MPA}$  提高 2.60%,  $E_{RMS}$  提高 0.26,  $R^2$  提高 0.197 5,说明采用分解法对溶解氧时序数据进行平稳化处理及降噪,提取溶解氧不同时频特征,能显著提高预测精度,且 CEEMDAN 分解比 EMD, EEMD 分解更有效;相较于 CEEMDAN-CS-Elman,文中 CEEMDAN-SE-CS-Elman 模型  $E_{MA}$  提高 0.04,  $E_{MPA}$  提高 0.49%,  $E_{RMS}$  提高 0.05,  $R^2$  提高 0.031 2,说明将样本熵值近似的溶解氧时频特征重组,能减小误差累积,保留重要信息,有效提高河流溶解氧预测精度;与采用遗传算法优化的 Elman 神经网络模型(CEEMDAN-SE-GA-Elman)进行对比,文




图 4 DO 时间序列单步预测

Fig. 4 Single-step prediction of DO time series

表 3 不同预测模型精度评价

Tab. 3 Accuracy evaluation of different prediction models

预测模型	$E_{MA}$	$E_{MPA} / \%$	$E_{RMS}$	$R^2$
LSTM	0.35	5.30	0.53	0.659 9
ARIMA	0.31	4.68	0.50	0.765 4
Elman	0.31	4.67	0.50	0.754 1
EMD-SE-CS-Elman	0.27	3.40	0.39	0.866 1
EEMD-SE-CS-Elman	0.16	2.24	0.24	0.943 7
CEEMDAN-CS-Elman	0.18	2.56	0.29	0.920 4
CEEMDAN-SE-GA-Elman	0.16	2.37	0.26	0.935 2
CEEMDAN-SE-CS-Elman	0.14	2.07	0.24	0.951 6

与采用遗传算法优化的 Elman 神经网络模型(CEEMDAN-SE-GA-Elman)进行对比,文



中模型  $E_{MA}$  提高 0.02,  $E_{MPA}$  提高 0.30%,  $E_{RMS}$  提高 0.02,  $R^2$  提高 0.016 4, 证明 CS 优化算法的优越性, 能进一步提高河流溶解氧预测精度. 综合分析, 文中构建的模型较其他模型预测效果更好, 误差评价指标均为最优.

### 2.4 模型应用结果

为了验证文中模型的实用性, 分别对晋江流域安溪南英和南安秋阳站点同期 DO 时序数据进行预测, 预测的结果, 如图 5 所示. 由图 5 可知: 预测值与实际值拟合较好, 安溪南英站点  $E_{MA}$  为 0.20,  $E_{MPA}$  为 2.50%,  $E_{RMS}$  为 0.31,  $R^2$  为 0.928 1; 南安秋阳站点  $E_{MA}$  为 0.17,  $E_{MPA}$  为 2.39%,  $E_{RMS}$  为 0.25,  $R^2$  为 0.902 5.

实验结果表明: 文中模型具有一定的实用性, 但对于突变数据(如安溪南英站点第 133 d), 虽能准确预测变化趋势, 但存在一定预测误差, 在今后的建模中, 将针对研究提高突变数据的预测精度, 考虑加入其他 DO 影响因素, 使模型更加准确、稳定.




图 5 不同监测站点的预测结果  
Fig. 5 Prediction results of different monitoring sites

### 3 结论

针对小流域基础资料少和溶解氧指标值的随机波动性与非平稳性造成预测精度难以提高的问题, 提出了基于 CEEMDAN 分解、样本熵和 CS-Elman 动态神经网络的组合预测模型. 以福建省晋江流域溶解氧数据作为实例验证, 得到以下 2 个结论.

- 1) 设计 CEEMDAN 和样本熵相结合的溶解氧时间序列分解方法, 实现对溶解氧数据的平稳化处理及降噪, 充分挖掘溶解氧数据隐含的不同时间尺度特征, 相较于传统分解方法, 既保留了细节信息, 又减小误差累积, 有助于解读溶解氧指标随时间变化的内在机理.
- 2) 对提取的溶解氧时频特征, 分别构建 Elman 动态神经网络模型进行训练和预测, 采用全局搜索能力较强的 CS 算法优化模型, 进一步提高了河流溶解氧预测精度.

结果表明, 提出的 CEEMDAN-SE-CS-Elman 模型与其他时间序列预测模型相比,  $E_{MA}$ ,  $E_{MPA}$ ,  $E_{RMS}$  及  $R^2$  均有所提高, 可为数据驱动的小流域短时河流溶解氧预测提供新方法.

### 参考文献:

[1] NEMATİ S, FAZELİFARD M H, TERZİ Ö, *et al.* Estimation of dissolved oxygen using data-driven techniques in the Tai Po River, Hong Kong[J]. Environmental Earth Sciences, 2015, 74(5): 4065-4073. DOI: 10.1007/s12665-015-4450-3.

[2] 胡鹏, 杨庆, 杨泽凡, 等. 水体中溶解氧含量与其物理影响因素的实验研究[J]. 水利学报, 2019, 50(6): 679-686. DOI: 10.13243/j.cnki.slxb.20190108.

[3] 王思文, 齐少群, 于丹丹, 等. 基于 WASP 模型的水环境质量预测与评价研究: 以松花江哈尔滨江段为例[J]. 自然灾害学报, 2015, 24(1): 39-45. DOI: 10.13577/j.jnd.2015.0106.

[4] 笄英云, 汪晓东, 赵永刚, 等. 基于关联向量机回归的 DO 预测模型[J]. 环境科学学报, 2015, 35(11): 3730-3735. DOI: 10.13671/j.hjkxxb.2015.0424.

- [5] 张颖,高倩倩. 基于灰色模型和模糊神经网络的综合水质预测模型研究[J]. 环境工程学报,2015,9(2):537-545.
- [6] 宦娟,刘星桥. 基于 K-means 聚类 and ELM 神经网络的养殖水质溶解氧预测[J]. 农业工程学报,2016,32(17):174-181. DOI:10.11975/j.issn.1002-6819.2016.17.024.
- [7] 陈英义,程倩倩,方晓敏,等. 主成分分析和长短时记忆神经网络预测水产养殖水体溶解氧[J]. 农业工程学报,2018,34(17):183-191. DOI:10.11975/j.issn.1002-6819.2018.17.024.
- [8] 石子泊,邹志红. 基于小波变换的 ARIMA 模型在水质预测中的应用研究[J]. 环境工程学报,2014,8(10):4550-4554.
- [9] XU Mei,YAN Fu,LIU Zhenzhong,*et al.* Forecasting of water quality using grey GM(1,1)-wavelet-GARCH hybrid method in Songhua River Basin[J]. Transactions of the Chinese Society of Agricultural Engineering,2016,32(10):137-142. DOI:10.11975/j.issn.1002-6819.2016.10.019.
- [10] WU Jing,LI Zhenbo,ZHU Ling,*et al.* Hybrid model of ARIMA model and GAWNN for dissolved oxygen content prediction[J]. Transactions of the Chinese Society for Agricultural Machinery,2017(s1):204-210.
- [11] 李军,李佳,张世义,等. 采用 EEMD 算法与互信息法的机械故障诊断方法[J]. 华侨大学学报(自然科学版),2018,39(1):7-13. DOI:10.11830/ISSN.1000-5013.201706091.
- [12] 余成洲,李勇,白云. 基于集合经验模态分解和支持向量机的溶解氧预测[J]. 环境监测管理与技术,2018,30(3):27-31. DOI:10.3969/j.issn.1006-2009.2018.03.007.
- [13] BOUNY L E,KHALIL M,ADIB A. ECG signal filtering based on CEEMDAN with hybrid interval thresholding and higher order statistics to select relevant modes[J]. Multimedia Tools and Applications,2018,78(10):13067-13089. DOI:10.1007/s11042-018-6143-x.
- [14] 康艳,蔡焕杰,宋松柏. 水文系统复杂性模型研究及应用[J]. 水力发电学报,2013,32(1):5-10.
- [15] 施珮,袁永明,张红燕,等. GRNN 和 Elman 神经网络在水体溶解氧预测中的应用[J]. 江苏农业科学,2017,45(23):217-221. DOI:10.15889/j.issn.1002-1302.2017.23.061.
- [16] 严丽,王启志. GA-Elman 网络的网络控制系统预测[J]. 华侨大学学报(自然科学版),2014,35(6):620-624. DOI:10.11830/ISSN.1000-5013.2014.06.0620.
- [17] 李志新,赖志琴,龙云墨. 基于 GA-Elman 神经网络模型的年径流预测[J]. 水利水电技术,2018,49(8):71-77. DOI:10.13928/j.cnki.wrahe.2018.08.009.
- [18] WANG Zhilong,WANG Chen,WU Jie. Wind energy potential assessment and forecasting research based on the data pre-processing technique and swarm intelligent optimization algorithms[J]. Sustainability,2016,8(11):1191. DOI:10.3390/su8111191.
- [19] NAWI N M,KHAN A,REHMAN M Z,*et al.* Weight optimization in recurrent neural networks with hybrid meta-heuristic cuckoo search techniques for data classification[J]. Mathematical Problems in Engineering,2014,2015(4):1-12. DOI:10.1155/2015/868375.
- [20] 秦喜文,刘媛媛,王新民,等. 基于整体经验模态分解和支持向量回归的北京市 PM<sub>2.5</sub> 预测[J]. 吉林大学学报(地球科学版),2016,46(2):563-568. DOI:10.13278/j.cnki.jjuese.201602206.

(责任编辑: 陈志贤      英文审校: 吴逢铁)