

基于 EMD 和 ELM 的工厂化育苗水温组合预测模型

徐龙琴¹ 张 军² 李乾川³ 刘双印¹ 李道亮⁴

(1. 广东海洋大学信息学院, 湛江 524025; 2. 中航飞机汉中零组件制造有限公司, 汉中 723213;
3. 加州大学洛杉矶分校文理学院, 洛杉矶 90024; 4. 中国农业大学中欧农业信息技术研究中心, 北京 100083)

摘要: 针对南美白对虾工厂化育苗水温时序数据存在非线性、非平稳等特点,采用传统单项预测方法预测精度低、鲁棒性差等问题,提出基于经验模态分解(EMD)、相空间重构和极限学习机(ELM)的非线性组合预测模型。在建模过程中,采用 EMD 方法将工厂化育苗水温原始时序数据多尺度分解为一系列固有模态分量(IMF),并对各分量进行相空间重构,在相空间中对 ELM 训练建模,分别对各 IMF 序列进行预测,将各分量预测结果进行叠加重构得到原始水温序列的预测值。将该模型应用于广东省湛江市南美白对虾工厂化育苗水温预测中,结果表明,该模型取得了较好预测效果。与 BP 神经网络、标准 LSSVR 和标准 ELM 等单项预测模型对比分析,模型评价指标 MAPE、RMSE 和 MAE 分别为 0.015 8、0.032 9 和 0.096 2,均表明提出的组合模型具有较高预测精度和泛化性能,为南美白对虾工厂化育苗水温调控管理提供了一种有效的技术支持。

关键词: 南美白对虾; 工厂化养殖; 水温; 组合预测; 极限学习机; 经验模态分解

中图分类号: TP391 **文献标识码:** A **文章编号:** 1000-1298(2016)04-0265-07

Combined Prediction Model of Water Temperature in Industrialized Cultivation Based on Empirical Mode Decomposition and Extreme Learning Machine

Xu Longqin¹ Zhang Jun² Li Qianchuan³ Liu Shuangyin¹ Li Daoliang⁴

(1. College of Information, Guangdong Ocean University, Zhanjiang 524025, China
2. AVIC Aircraft Aerostructure Manufacturing (Hanzhong) Co., Ltd., Hanzhong 723213, China
3. College of Letters and Science, University of California, Los Angeles 90024, USA
4. Beijing ERC for Internet of Things in Agriculture, China Agricultural University, Beijing 100083, China)

Abstract: Since the sequence data of water temperature in industrialized *Litopenaeus vannamei* breeding is somehow non-linear, unsteady, and such problems like lower precision in the predicting results, low robustness will appear when utilizing the traditional single item predicting method, a combined non-linear prediction model based on empirical mode decomposition (EMD), phase space reconstruction and extreme learning machine (ELM) was proposed. In modeling, the EMD method was adopted to decompose the original time sequence data of water temperature in industrialized *Litopenaeus vannamei* breeding into a series of intrinsic mode function (IMF), and reconstruct the phase space of each component, set models of ELM training in phase space, predict each IMF sequence, and then combine and reconstruct the predicted values of each component to get the predicted value of original water temperature sequence. EMD – ELM was tested and compared with other algorithms by applying it to predict water temperature in industrialized *Litopenaeus vannamei* breeding pond of Zhanjiang City. The

收稿日期: 2015-11-01 修回日期: 2015-12-06

基金项目: 国家自然科学基金项目(61471133、61571444、61473331)、“十二五”国家科技支撑计划项目(2012BAD35B07)、广东省科技计划项目(2013B090500127、2013B021600014、2015A070709015、2015A020209171)、广东省自然科学基金项目(S2013010014629、2014A030307049)和广东海洋大学创新强校工程项目(GDOU2014050227)

作者简介: 徐龙琴(1977—),女,副教授,主要从事事智能计算、智能信息系统和农业信息化技术研究, E-mail: xlqlw@126.com

通信作者: 刘双印(1977—),男,教授,博士,主要从事事智能计算、智能信息处理和农业信息化技术研究, E-mail: hdlisylq@126.com

experimental results showed that the proposed combination prediction model of EMD – ELM had better prediction effect than the standard extreme learning machine (ELM), least squares support vector regression (LSSVR) and BP neural network methods. And the relative mean absolute percentage error (MAPE), root mean square error (RMSE) and mean absolute error (MAE) between the EMD – ELM and standard LSSVR models were 62.82%、45.62% and 42.77%, respectively, under the same experimental conditions. The relative MAPE, RMSE and MAE between the EMD – ELM and standard ELM models were 34.44%、28.94% and 25.37%, respectively. The relative MAPE, RMSE and MAE between the EMD – ELM and BPNN models were 77.0%、60.83% and 54.77%, respectively. It was obvious that the EMD – ELM had high forecast accuracy and generalization ability. The research results provided a new effective technical support for water temperature management and control in the industrialized cultivation of *Litopenaeus vannamei*.

Key words: *Litopenaeus vannamei*; industrialized cultivation; water temperature; combined prediction; extreme learning machine; empirical mode decomposition

引言

南美白对虾工厂化养殖过程中,水温是影响对虾育苗、成虾健康生长最直接、最关键的水质参数之一,水温过高或过低都会严重威胁对虾正常生长^[1-2]。而养殖水温易受气温、水生物活动等多因素交叉影响,具有非平稳、非线性、大时滞等特征,使得单项预测方法存在预测精度低、泛化性能差等缺陷,难以满足工厂化对虾养殖水质精准调控管理实际需要^[3-4]。

为准确预测水温时空变化,近年来国内外学者进行了大量研究,其预测方法主要分两大类:①基于热量平衡方程和能量转换方程的机理模型法^[5-6],该方法虽对河流和水库的水温预测取得了较好效果,但该方法过程复杂、参数众多,需要复杂详尽的观测信息作为支撑,很难在水产养殖领域实施。②基于数据驱动的非机理模型,主要通过大量历史数据建模,拟合出水温变化规律。该类模型主要包括时间序列法、灰色理论、神经网络、支持向量机等方法。其中:时间序列法简便直观,但对非线性、非平稳水质参数预测效果不理想^[7];灰色理论计算简便,但预测精度易受历史数据波动影响^[8];神经网络具有自主学习和非线性拟合能力,但存在欠学习和过学习、易陷入局部最优等问题^[9-12];支持向量机(SVM)具有较好泛化能力和非线性拟合能力,可解决易陷入局部最优、维数灾难和小样本等问题,但SVM计算复杂,且影响该模型性能的正则化参数和核函数参数难以确定^[13-16]。而极限学习机(ELM)是一种性能优异的新型单隐层前馈神经网络^[17],该算法不必多次迭代优化就可获得适宜神经网络权重,能极大地提高ELM学习速度和泛化能力,规避一般神经网络存在的缺陷,与SVM相比,预测性能

类似,但参数优化和收敛速度方面ELM更具优势,ELM已在模式分类^[18-19]、预测^[20-22]等领域得到了广泛应用。然而,上述常用单项预测方法均直接在原始时序数据上建模,则会把养殖水温时序数据中不同尺度特征信息同质化,且难充分挖掘和利用各时频特征信息,尤其是养殖水温非平稳性和多尺度性势必影响上述方法预测性能,故降低水温非平稳性和降噪尤为重要。

常用降低养殖水温时序数据非平稳性主要方法有小波分析(Wavelet analysis,WA)和经验模态分解(Empirical mode decomposition,EMD)。小波分析虽能提取不同尺度上细节信息,但存在不能据时序信号自身特性实现自适应多分辨率分析,需要选取小波基、且分解尺度需事先确定不得调整等不足^[23]。而EMD在进行非平稳性时序数据分解时,无需设定先验基函数,能自适应地把局部时间内包含的多个模态的非线性和非平稳时序数据,分解成有限个彼此影响小、不同尺度的基本模态分量,从而降低系统间特征信息干扰或耦合,与WA相比,EMD具更强局部表现能力,更能准确地刻画系统原有物理特性,在预测^[24]和故障诊断^[25]等领域得到广泛应用。

在借鉴前人研究成果基础上^[24-25],本文将EMD和ELM结合,提出基于EMD和ELM的工厂化育苗水温组合预测模型。建模中利用EMD将非平稳工厂化育苗水温时序数据多尺度分解成一系列具有不同特征尺度的IMF分量,并对不同尺度IMF分量采用CAO方法重构相空间,在相空间中分别采用极限学习机进行训练建模预测,最后对各IMF分量预测结果叠加重构得到工厂化养苗水温最终的预测结果。将该模型应用于广东省湛江市南美白对虾工厂化育苗水温预测中。

1 材料与方法

1.1 试验区域

本研究区域湛江市位于东经 110°4′、北纬 21°12′, 广东省西南部, 中国大陆最南端雷州半岛上, 东濒南海, 西临北部湾, 属热带亚热带季风性气候。全市对虾养殖达 92 300 hm², 产量占全国产量的 15% 左右, 选择该试验区域的广东省南美白对虾种苗良种场, 每个育苗池塘 15 m², 共有 11 条车间 140 个育苗池塘。在育苗车间中安装有换水泵、增氧设备、温度调控设备、灯光控制设备、在线监测育苗水质参数的多种水质传感器和水产养植物联网平台。

1.2 数据采集系统架构

以广东省湛江市南美白对虾工厂化育苗良种场某养殖池塘水质为研究对象, 采用中国农业大学和广东海洋大学联合研制的水产养植物联网平台采集育苗池塘水质参数数据, 其系统拓扑结构图如图 1 所示。该系统主要由环境数据感知层、网络传输层、信息智能处理和应用服务层组成, 分别实现育苗水质数据在线采集、信息可靠传输、智能信息处理与业务逻辑计算、水质调控决策等功能^[16]。




图 1 系统拓扑结构图

Fig. 1 Topology structure diagram of system

1.3 方法

1.3.1 经验模态分解

经验模态分解 (EMD) 无需采用信号的先验知识, 可自适应地把非平稳和非线性信号分解为一系列具有不同特征尺度的本征模态分量和剩余分量, 能较好地捕捉不同尺度下的特征信息^[26]。

给定的南美白对虾工厂化养殖水温时序样本数据 $\{x(t) | t = 1, 2, \dots, N\}$, EMD 分解的具体步骤如下:

(1) 计算 $x(t)$ 的局部极大值和局部极小值。

(2) 通过三次样条插值法分别连接局部极小值和局部极大值, 组成上下包络线 $x_{\max}(t)$ 和 $x_{\min}(t)$,

计算每个时刻上下包络序列的均值

$$m_1(t) = \frac{x_{\min}(t) + x_{\max}(t)}{2} \quad (1)$$

(3) 计算 $x(t)$ 与 $m_1(t)$ 之差

$$h_1(t) = x(t) - m_1(t) \quad (2)$$

得到一个移除低频的新数据序列, 如果 $h_1(t)$ 满足 IMF 的 2 个条件, 则记 $c_1(t) = h_1(t)$, $c_1(t)$ 为原始序列 $x(t)$ 的第 1 个 IMF 分量, 它表征原始序列 $x(t)$ 高频成分。如果 $h_1(t)$ 不满足 IMF 的 2 个条件, 则将 $h_1(t)$ 看作新的信号 $x(t)$, 重复上述步骤, 直到 $h_1(t)$ 是一个 IMF 为止^[27]。

(4) 从原始 $x(t)$ 中减去 $c_1(t)$, 得到移除最高频成分的差值数据序列 $r_1(t) = x(t) - c_1(t)$, 再把 $r_1(t)$ 看作新的信号, 重复上述步骤, 依次提取后续 IMF 分量 $c_2(t), c_3(t), \dots, c_n(t)$ 和剩余分量 $r_n(t)$, 其原始时序 $x(t)$ 可以表示 IMF 和剩余分量 r_n 之和, 即

$$x(t) = \sum_{i=1}^n c_i(t) + r_n \quad (3)$$

式中 n ——IMF 的数量

1.3.2 相空间重构

Takens 定理已证明选取合适的延迟时间和嵌入维数, 可使重构后的相空间能够较好地表达系统状态随时间序列演化轨迹^[28]。设工厂化养殖育苗水温时序数据 $\{x(i) | i = 1, 2, \dots, N\}$, 若延迟时间为 τ , 嵌入维数 m , 则水温时序数据相空间重构为

$$X(i) = (x(i), x(i + \tau), \dots, x(i + (m - 1)\tau)) \quad (4)$$

式中, $i = 1, 2, \dots, Z, Z = N - (m - 1)\tau$ 。由此可知, 获取适宜的延迟时间 τ 和嵌入维数 m 是相空间重构的关键。重构相空间已有许多成熟的方法, 选择适宜于非线性系统的互信息法提取时序空间的非线性相关性^[28], 通过计算时序的互信息值, 提取第一次达到极小值点所对应的时间作为最佳延迟时间; 采用能够避免假临近现象的 CAO 方法^[29]确定重构相空间中的最小嵌入维数。

1.3.3 极限学习机

极限学习机 (ELM) 是一种新型的单隐含层前馈神经网络, 与传统的 RBF 神经网络、支持向量机 (SVM) 和 BP 神经网络相比, ELM 算法整个参数优化过程无需迭代, 只需设置隐含层神经元格式, 并通过求解线性方程组, 即可获得网络权值的全局最优解^[17-22, 30-31]。

给定 N 个不同的南美白对虾工厂化育苗水体水温时序训练样本 $\{(x_i, y_i) | x_i \in \mathbf{R}^n; y_i \in \mathbf{R}^m\} (i = 1, 2, \dots, N)$, 含有 L 个节点隐含层节点且激励函数为 $f(x)$ 的极限学习机数学模型表示为^[17, 30]

$$y_j = \sum_{i=1}^N \beta_i f(w_i x_j + b_i) \quad (j=1,2,\cdots,N) \quad (5)$$

式中 w_i ——连接第 i 个隐含层结点和输入节点的权重向量

β_i ——连接第 i 个隐含层结点和输入输出神经元的权重向量

b_i ——第 i 个隐层节点的偏置

y_j ——第 j 个节点的输出值

若 ELM 神经网络的训练过程能零误差逼近 N 个训练样本,则存在 $\hat{w}_i$ 、 $\hat{\beta}_i$ 和 $\hat{b}_i$ 使

$$t_j = \sum_{i=1}^L \hat{\beta}_i f(\hat{w}_i x_j + \hat{b}_i) \quad (j=1,2,\cdots,N) \quad (6)$$

成立^[17,30]。

式(6)可简化为矩阵形式^[24]

$$T = H\beta \quad (7)$$

其中^[17,24,30]

$$H = \begin{bmatrix} f(w_1 x_1 + b_1) & \cdots & f(w_L x_1 + b_L) \\ \vdots & & \vdots \\ f(w_1 x_N + b_1) & \cdots & f(w_L x_N + b_L) \end{bmatrix}_{N \times L}$$
$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m} \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m}$$

式中 H ——隐含层输出矩阵

HUANG 等证明了当激励函数 $f(x)$ 无限可微时,ELM 网络参数不必全部调整,其输入连接权重参数 w 和隐含层节点偏置 b 可以随机选择,且训练过程保持不变^[26]。通过求解式(7)的最小二乘解,可得到隐含层结点和输入输出神经元的权重向量 β ,即

$$\min_{\beta} \| H\beta - T \|$$
$$\hat{\beta} = H^+ T \quad (8)$$

式中 H^+ 为隐含层输出矩阵 H 的 Moore-Penrose 广义逆,由上述可知,与传统梯度算法相比,ELM 在训练过程中不必调整 w_i 和 b_i ,只需计算出 β ,即可获得一个全局最优解,较好地规避了传统梯度算法存在的问题。

2 基于 EMD-ELM 的南美白对虾工厂化养殖水温组合预测模型

将经验模态分解和极限学习机有机结合,提出了基于 EMD-ELM 的南美白对虾工厂化养殖水温组合预测模型。在建模过程中,首先采用 EMD 对非平稳和非线性的南美白对虾工厂化养殖水温时序数据进行自适应地多尺度分解,得到一组不同频度的本模特征 IMF 分量和剩余分量;然后运用 CAO 方法

对不同尺度序列进行相空间重构,并在相空间中分别采用极限学习机进行建模预测;最后将各分量预测结果进行叠加重构得到工厂化养殖水温最终的预测结果。其水温组合预测流程图如图 2 所示,基于 EMD-ELM 的水温组合预测步骤如下:




图 2 基于 EMD-ELM 的养殖水温组合预测流程图

Fig. 2 Flowchart of water temperature combined forecasting based on EMD-ELM

(1) 原始养殖水温时序数据分解。采用 EMD 分解流程中式(1)~(3)多尺度分解南美白对虾工厂化养殖池塘水温时序数据,获得 n 个不同波动频率的本征模态分量 ($IMF_1 \sim IMF_n$) 和 1 个剩余分量 r_n 。

(2) IMF 和 r_n 相空间重构。分别通过 CAO 方法和互信息法确定各个 IMF 和 r_n 的嵌入维数 m 和延迟时间 τ 。

(3) ELM 网络输入输出相空间域的向量选择。根据 1.3.3 节极限学习机拟合原理,在相空间域中确定各个 IMF 分量和剩余分量 r_n 的 ELM 网络输入和输出变量。对于一个确定的 m 和 τ 的分量序列,其 ELM 网络输入输出样本结构可表示为

$$X = \begin{bmatrix} x(1) & x(1+\tau) & \cdots & x(1+(m-1)\tau) \\ x(2) & x(2+\tau) & \cdots & x(2+(m-1)\tau) \\ \vdots & \vdots & & \vdots \\ x(M) & x(M+\tau) & \cdots & x(M+(m-1)\tau) \end{bmatrix}$$
$$Y = \begin{bmatrix} x(2+(m-1)\tau) \\ x(3+(m-1)\tau) \\ \vdots \\ x(M+1+(m-1)\tau) \end{bmatrix}$$

(4) 各分量的极限学习机训练与预测。采用极限学习机分别对各个 IMF 分量和 r_n 分量构建拟合预测模型,获得各分量的预测结果。

(5) 最终预测结果输出。把各分量预测结果叠加重构,得到工厂化养殖池塘水温的最终预测结果。

(6) 组合模型预测性能评价。采用平均绝对百分比误差 MAPE、均方根误差 RMSE 和平均绝对误差 MAE 等评价指标对基于 EMD-ELM 组合模型预测性能进行评价,各评价指标表达式分别为

$$M_{APE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

(9)

$$R_{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}$$

(10)

$$M_{AE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$

(11)

式中 $y_i, \hat{y}_i$ ——实际值和预测值
 N ——测试样本集数量

3 实验与结果分析

3.1 南美白对虾工厂化养殖水温数据源

以湛江市南美白对虾工厂化养殖某池塘水温为研究对象,采用 1.2 节的水产养殖物联网平台,每隔 30 min 对南美白对虾工厂化养殖水温时序数据采样一次,将获取的数据作为验证组合预测模型的样本集。采样时间为 2015 年 5 月 27—5 月 31 日,共采集 240 个样本,将前 3 d 的 192 个样本作为训练集,最后 1 d 的 48 个样本作为测试集,对下一时刻的养殖水温进行组合预测。其工厂化养殖水温原始数据如图 3 所示。由图 3 可知,南美白对虾工厂化养殖水温时序数据具有较强的非线性和周期性。




图 3 育苗水温原始数据变化曲线

Fig.3 Variation curve of the original water temperature data

3.2 基于 EMD 的养殖水温多尺度分解及相空间重构

根据第 2 节的 EMD-ELM 组合预测方法中的步骤,对 240 个工厂化养殖原始水温时序数据进行多尺度分解,得到 6 个 IMF 分量和 1 个剩余分量,其原始数据经 EMD 分解得到各分量序列如图 4 所示。

由图 4 可以看出养殖水温时序数据呈现出明显的多尺度特征,6 个本征模态分量由高到低,各自描述这原始水温时序数据不同的波动尺度信息,剩余分量比较平稳,刻画了水温总体变化特征。

对 EMD 分解后的各个 IMF 分量和 r_n 分量分别采用 Cao 方法和互信息法进行相空间重构计算,不同尺度分量相空间重构的最佳嵌入维数 m 和延迟时间 τ 如表 1 所示。




图 4 基于 EMD 的原始水温多尺度分解

Fig.4 Multi-scale decomposition of original water temperature based on EMD

表 1 各分量相空间重构结果

Tab.1 Results of phase space reconstruction for each subsequence

分量	嵌入维数 m	延迟时间 τ	隐含层神经元个数
IMF ₁	5	4	18
IMF ₂	3	5	14
IMF ₃	6	7	21
IMF ₄	4	6	15
IMF ₅	5	6	17
IMF ₆	7	3	20
r_n	6	8	19

3.3 预测结果分析

在相空间重构结果的基础上,采用极限学习机分别对各个 IMF 分量和 r_n 分量建模预测,得到各个分量极限学习机网络隐含层神经元个数见表 1,各个 IMF 分量和剩余分量 r_n 的 ELM 预测结果如表 2 所示。

表 2 各分量预测结果分析

Tab.2 Precision analysis of forecast results for each subsequence

分量	MAPE	RMSE	MAE
IMF ₁	0.018 7	0.043 7	0.145 5
IMF ₂	0.015 2	0.030 5	0.097 9
IMF ₃	0.008 1	0.022 8	0.095 8
IMF ₄	0.007 6	0.015 8	0.083 0
IMF ₅	0.006 3	0.008 9	0.035 2
IMF ₆	0.004 9	0.005 4	0.034 1
r_n	0.003 7	0.004 8	0.021 3

从表 2 可知,ELM 模型对高频的分量预测性能较差,随着各分量的频率降低,ELM 预测精度逐步提高,从而说明 ELM 模型在中低频分量和剩余分量上表现出更好的预测性能。

为进一步验证本文组合模型的预测性能,分别采用 BPNN、标准 LSSVR、标准 ELM 和 EMD-ELM 模型对同样的南美白对虾工厂化养殖水温时序数据进行预测。其中 BP 神经网络结构采用 3-4-1 结构,学习因子 $\varphi=0.8$,最大误差 $\varepsilon=0.0001$,激励函数为 sigmoid 函数;标准 LSSVR 模型采用交叉验证法获得其正则化参数 $\Psi=92.37$ 及 RBF 核函数参数 $\sigma=1.451$;标准 ELM 隐含层神经元个数为 8,嵌入维数 $m=5$,延迟时间 $\tau=7$ 。4 种模型预测曲线对比如图 5 所示,其预测精度统计结果如表 3 所示。




图 5 4 种模型的水温预测结果

Fig. 5 Water temperature forecasting results for four models

表 3 不同模型预测结果分析

Tab.3 Precision analysis of forecast results for each model

模型	MAPE	RMSE	MAE
BPNN	0.068 7	0.084 0	0.212 7
标准 LSSVR	0.042 5	0.060 5	0.168 1
标准 ELM	0.024 1	0.046 3	0.128 9
EMD-ELM	0.015 8	0.032 9	0.096 2

从图 5 可以看出,BP 神经网络、标准 LSSVR 和标准 ELM 预测模型的单项预测误差较大,尤其 BP 神经网络在拐点附近偏离实测值最大;本文提出的基于 EMD-ELM 的组合预测能够较好地拟合养殖水温非线性变化曲线,取得较好的预测效果。

从表 3 可以看出,本文提出的 EMD-ELM 组合模型预测精度与其他方法相比有很大的改进,普遍优于传统的 BP 神经网络和标准 LSSVR 标准;同时

也优于没有经过多尺度分解而直接采用 ELM 建模预测的模型性能。在同种条件下,EMD-ELM 与 BP 神经网络相比,评价指标 MAPE、RMSE、MAE 分别降低了 77.0%、60.83% 和 54.77%;EMD-ELM 与标准 LSSVR 相比,评价指标 MAPE、RMSE、MAE 分别降低了 62.82%、45.62% 和 42.77%;EMD-ELM 与标准 ELM 相比,评价指标 MAPE、RMSE、MAE 分别降低了 34.44%、28.94% 和 25.37%。由图 5 和表 3 分析可知:EMD 能够对非线性水温序列中的非平稳振荡特征进行提取与表达,降低了不同尺度下特征信息干扰和非平稳性,有效提高了组合模型的预测精度。采用相空间重构将不同尺度下水温序列预测问题转化为相空间中毗邻节点的函数构建问题,较好地解决了组合模型网络结构嵌入维数和时间延迟参数确定问题,为构建高性能的组合预测模型奠定了基础。将能够进行多尺度特征提取的 EMD 与具有学习速度快和泛化性能好特点的 ELM 方法有机结合,分别对 EMD 挖掘的不同尺度下的水温特征信息进行建模预测与重构,不仅取得较好的预测性能,还克服了传统单项预测模型直接采用原始水温时序数据预测存在的预测精度低,难以满足工厂化养殖水质调控等问题。本文提出的基于 EMD-ELM 的组合模型是一种适宜的工厂化养殖水质预测方法,为水产养殖水质调控管理提供了技术支持。

4 结束语

针对传统水质单项预测方法直接对具有非平稳、大时滞、非线性和多尺度特征的工厂化养殖水温预测,存在预测精度低、鲁棒性差等问题,提出了基于 EMD-ELM 的水温组合预测模型,并应用与广东省湛江市南美白对虾工厂化养殖水温预测中,并与其他模型对比分析,结果表明,基于 EMD-ELM 组合预测模型具有较高的预测精度和泛化性能,能够为南美白对虾工厂化养殖水质调控提供决策依据,也为非线性、作用机理复杂系统建模提供一条新途径。

参 考 文 献

1 岑伯明,胡洲,陈汉春. 凡纳滨对虾养殖池塘水温预测模型研究[J]. 宁波大学学报:理工版,2012,25(1):7-12.
CEN Boming, HU Zhou, CHEN Hanchun. Analysis on temperature characteristics of the *litopenaeus vannamei* culture ponds and water temperature prediction [J]. Journal of Ningbo University: Natural Science & Engineering Edition, 2012,25(1):7-12. (in Chinese)

2 祁真. 对虾生态工程化养殖系统水环境变化及影响因子研究[D]. 杭州:浙江大学,2004.
QI Zhen. Study on water environment variation and influencing factor of shrimp ecological engineering cultivation system [D]. Hangzhou: Zhejiang University, 2004. (in Chinese)

3 马真. 凡纳滨对虾集约化养殖水质预警模型的研究[D]. 青岛:中国海洋大学,2010.
MA Zhen. Study on pre-alarming water quality system for intensively cultured *Litopenaeus vannamei* [D]. Qingdao: Ocean

- University of China, 2010. (in Chinese)
- 4 张志成,汪卫明. 山区水库水温预测及影响因素[J]. 武汉大学学报:工学版,2013,46(5):610-614.
ZHANG Zhicheng, WANG Weiming. Prediction of mountain reservoir water temperatures and influential factor analysis[J]. Engineering Journal of Wuhan University, 2013,46(5):610-614. (in Chinese)
- 5 DIAO Wei, CHENG Yongguang, ZHANG Chunze, et al. Three-dimensional prediction of reservoir water temperature by the lattice Boltzmann method: Validation [J]. Journal of Hydrodynamics, 2015,27(2):248-256.
- 6 任华堂,夏建新,陶亚. 阿海水库水温数值预测研究[J]. 长江流域资源与环境,2010,19(7):814-820.
REN Huatang, XIA Jianxin, TAO Ya. On temperature numerical prediction in Ahai reservoir [J]. Resources and Environment in the Yangtze Basin, 2010,19(7):814-820. (in Chinese)
- 7 刘付程,刘吉堂,苏伟,等. 基于季节 ARIMA 模型的近海表层水温时间序列模拟与预测[J]. 淮海工学院学报:自然科学版,2009,18(4):77-80.
- 8 黄景锐,胡安众,张焕楚,等. 基于非等间距序列 GM(1,1)模型的地下水温度预测[J]. 水文地质工程地质,2013,40(1):48-52.
HUANG Jingrui, HU Anzhong, ZHANG Huanchu, et al. Prediction of shallow groundwater temperature based on GM(1,1) model for non-equidistant sequence [J]. Hydrogeology & Engineering Geology, 2013,40(1):48-52. (in Chinese)
- 9 ADAM P Piotrowski, MACIEJ J Napiorkowski, JAROSLAW J Napiorkowski, et al. Comparing various artificial neural network types for water temperature prediction in rivers [J]. Journal of Hydrology, 2015, 529(1):302-315.
- 10 张丽丽,王相友,张海鹏. 山药切片红外干燥温度神经网络预测[J]. 农业机械学报,2014,45(11):246-249.
ZHANG Lili, WANG Xiangyou, ZHANG Haipeng. Temperature prediction of yam under infrared drying based on neural networks [J]. Transactions of the Chinese Society for Agricultural Machinery, 2014,45(11):246-249. (in Chinese)
- 11 XU Longqin, LIU Shuangyin. Study of short-term water quality prediction model based on wavelet neural network [J]. Mathematical and Computer Modelling, 2013, 58(3-4):807-813.
- 12 刘雪,李亚妹,刘娇,等. 基于 BP 神经网络的鲜鸡蛋货架期预测模型[J]. 农业机械学报,2015,46(10):328-334.
LIU Xue, LI Yamei, LIU Jiao, et al. BP neural network based prediction model for fresh egg's shelf life [J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(10):328-334. (in Chinese)
- 13 LIU Shuangyin, TAI Haijiang, DING Qisheng, et al. A hybrid approach of support vector regression with genetic algorithm optimization for aquaculture water quality prediction [J]. Mathematical and Computer Modelling, 2013, 58(3-4):458-465.
- 14 刘伟,王建平,刘长虹,等. 基于粒子群寻优的支持向量机番茄红素含量预测[J]. 农业机械学报,2012,43(4):143-147.
LIU Wei, WANG Jianping, LIU Changhong, et al. Lycopene content prediction based on support vector machine with particle swarm optimization [J]. Transactions of the Chinese Society for Agricultural Machinery, 2012,43(4):143-147. (in Chinese)
- 15 任顺,于海业,周丽娜. 基于支持向量机的叶绿素荧光预测光能利用效率研究[J]. 农业机械学报,2015,46(4):273-276.
REN Shun, YU Haiye, ZHOU Li'na. Predicting light use efficiency with chlorophyll fluorescence spectra based on SVM [J]. Transactions of the Chinese Society for Agricultural Machinery, 2015,46(4):273-276. (in Chinese)
- 16 刘双印,徐龙琴,李振波,等. 基于 PCA-MCAFA-LSSVM 的养殖水质 pH 值预测模型[J]. 农业机械学报,2014,45(5):239-246.
LIU Shuangyin, XU Longqin, LI Zhenbo, et al. Forecasting model for based pH value of aquaculture water quality on PCA-MCAFA-LSSVM [J]. Transactions of the Chinese Society for Agricultural Machinery, 2014,45(5):239-246. (in Chinese)
- 17 HUANG Guangbin, ZHU Qinyu, Siew Chee-Kheong. Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70(1/3):489-501.
- 18 陆慧娟,安春霖,马小平,等. 基于输出不一致测度的极限学习机集成的基因表达数据分类[J]. 计算机学报,2013,36(2):341-348.
LU Huijuan, AN Chunlin, MA Xiaoping, et al. Disagreement measure based ensemble of extreme learning machine for gene expression data classification [J]. Chinese Journal of Computers, 2013,36(2):341-348. (in Chinese)
- 19 MOHAPATRA P, CHAKRAVARTY S, DASH P K. An improved cuckoo search based extreme learning machine for medical data classification [J]. Swarm and Evolutionary Computation, 2015, 24:25-49.
- 20 KASRA Mohammadi, SHAHABODDIN Shamsheerband, SHERVIN Motamedi, et al. Extreme learning machine based prediction of daily dew point temperature [J]. Computers and Electronics in Agriculture, 2015, 117:214-225.
- 21 ARANILDO R Lima, ALEX J Cannon, William W Hsieh. Nonlinear regression in environmental sciences using extreme learning machines: a comparative evaluation [J]. Environmental Modelling & Software, 2015, 73:175-188.
- 22 刘念,张清鑫,李小芳. 基于核函数极限学习机的分布式光伏短期功率预测[J]. 农业工程学报,2014,30(4):152-159.
LIU Nian, ZHANG Qingxin, LI Xiaofang. Distributed photovoltaic short-term power output forecasting based on extreme learning machine with kernel [J]. Transactions of the CSAE, 2014, 30(4):152-159. (in Chinese)
- 23 LI Song, WANG Peng, GOEL Lalit. Short-term load forecasting by wavelet transform and evolutionary extreme learning machine [J]. Electric Power Systems Research, 2015, 122:96-103.
- 24 颜七笙,王士同,张延飞,等. 基于经验模式分解和极限学习机的铀资源价格预测方法[J]. 控制与决策,2014,29(7):1187-1192.
YAN Qisheng, WANG Shitong, ZHANG Yanfei, et al. Uranium resource price prediction based extreme learning machine on empirical mode decomposition [J]. Control and Decision, 2014, 29(7):1187-1192. (in Chinese)

International Journal of Fuels and Lubricants, 2010, 3(1):673 – 689.

12 MEISAMI A M, MOHAMMADPOUR J, GRIGORIADIS K M. An adaptive control strategy for urea – SCR aftertreatment system [C]//Proceedings of the 2010 American Control Conference, 2010: 3027 – 3032.

13 CHEN P, WANG J, HUANG C C, et al. A robust ammonia coverage ratio control method for a two-cell selective catalytic reduction system in low temperature operations[C]//American Control Conference, 2014: 2606 – 2611.

14 赵靖华,陈志刚,胡云峰,等. 基于“三步法”的柴油机 Urea – SCR 系统控制设计[J]. 吉林大学学报:工学版,2015, 45(6): 1913 – 1923.

ZHAO J H, CHEN Z G, HU Y F, et al. Design of diesel engine’s urea – SCR system controller using triple-step method[J]. Journal of Jilin University: Engineering and Technology Edition,2015, 45(6): 1913 – 1923. (in Chinese)

15 NING J, YAN F. Compound control strategy based on active disturbance rejection for selected catalytic reduction systems[J]. Journal of Dynamic Systems, Measurement, and Control, 2015, 137(5): 051008.

16 MEISAMI A M, MOHAMMADPOUR J, GRIGORIADIS K M. PCA-based linear parameter varying control of SCR aftertreatment systems[C]//Proceedings of the 2011 American Control Conference, 2011: 1543 – 1548.

17 刘传宝,颜伏伍,胡杰,等. 柴油机 SCR 后处理系统控制策略[J]. 农业机械学报, 2013, 44(11): 6 – 11.

LIU C B, YAN F W, HU J, et al. SCR post-processing system control strategy of diesel engine[J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(11): 6 – 11. (in Chinese)

18 FLIESS M, LÉVINE J, MARTIN P, et al. Flatness and defect of non-linear systems; introductory theory and examples[J]. International Journal of Control, 1995, 61(6): 1327 – 1361.

19 SCHÄR C M. Control of a selective catalytic reduction process[D]. Zurich: Swiss Federal Institute of Technology,2003.

20 SCHÄR C M, ONDER C H, GEERING H P. Control of an SCR catalytic converter system for a mobile heavy-duty application [J]. IEEE Transactions on Control Systems Technology, 2006, 14(4): 641 – 653.

21 WILLI R. Low-temperature selective catalytic reduction of NO_x-catalytic behavior and kinetic modeling [D]. Zurich: ETH Zurich,1996.

22 HSIEH M. Control of diesel engine urea selective catalytic reduction systems[D]. Ohio: The Ohio State University, 2010.

23 ZHENG Q, CHEN Z, GAO Z. A practical approach to disturbance decoupling control[J]. Control Engineering Practice, 2009, 17(9): 1016 – 1025.

24 王萍,于鸿昶,刘奇芳,等. 主动队列管理的约束 H_{∞} 状态反馈控制方法[J]. 控制理论与应用,2013, 30(11): 1353 – 1359.

WANG P, YU H C, LIU Q F, et al. State-feedback constrained H-infinity control for active queue management[J]. Control Theory & Applications, 2013, 30(11): 1353 – 1359. (in Chinese)

25 PHILIPP O, HUBER M. Development and test of ECU functions for OBD with enDyna[C]. JSAE Paper 20045402,2004.

~~~~~

(上接第 271 页)

25 JAOUHER Ben Ali, NADER Fnaiech, LOTFI Saidi, et al. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals [J]. Applied Acoustics, 2015, 89: 16 – 27.

26 HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceedings of the Royal Society of London A, 1998, 454(1971): 903 – 995.

27 龚承柱,李兰兰,杨娟,等. 基于 EMD – PSR – LSSVM 的城市燃气管网短期负荷预测[J]. 系统工程理论与实践,2014, 34(11):3001 – 3008.

GONG Chengzhu, LI Lanlan, YANG Juan, et al. An integrated short-term load forecasting approach for urban gas pipeline network based on EMD, PSR and LSSVM [J]. Systems Engineering Theory & Practice, 2014, 34(11): 3001 – 3008. (in Chinese)

28 FRASER A M, SWINNEY H L. Independent coordinates for strange attractors from mutual information [J]. Physical Review A: General Physics, 1986, 33(2): 1134 – 1140.

29 CAO Liangyue. Practical method for determining the minimum embedding dimension of a scalar time series [J]. Physica D: Nonlinear Phenomena, 1997, 110(1 – 2): 43 – 50.

30 HUANG Guangbin, ZHANG Hongming, DING Xiaojian, et al. Extreme learning machine for regression and multiclass classification [J]. IEEE Transactions on Systems Man and Cybernetics Part B: Cybernetics, 2012, 42(2): 513 – 529.

31 WANG Yuguang, CAO Feilong, YUAN Yubo. A study on effectiveness of extreme learning machine [J]. Neurocomputing, 2011, 74(16): 2483 – 2490.