

DOI: 10.13382/j.jemi.B2104122

基于 FOA-GRNN 模型的太湖水质预测研究*

陶志勇 曹琦 徐光宪

(辽宁工程技术大学电子与信息工程学院 葫芦岛 125105)

摘要: 由于水环境较为复杂,传统水质预测方法难以建立理想的非线性系统。为了提高水质预测精度,提出一种利用果蝇算法(fruit fly optimization algorithm, FOA)改进广义神经网络(general regression neural network, GRNN)的水质预测模型。利用果蝇优化算法具有的全局寻优特性可以对关键参数进行寻优的特点,结合广义神经网络的高精度逼近能力,建立了 FOA-GRNN 水质预测模型。选取太湖水域 0 号观测站采集到的溶解氧、温度、总氮、总磷等 4 项数据,使用线性插值法、平滑法与归一法对数据进行预处理并实验仿真。仿真结果表明,FOA-GRNN 的预测结果接近真实值,其 4 项预测指标的均方根误差分别为 0.164 83、0.250 39、0.126 59、0.111 19,达到理想结果,具有稳定性强、精度高的优点,在水质预测方面有很大的实际应用价值。

关键词: 广义神经网络;果蝇优化算法;数据预处理;水质预测

中图分类号: TP391;TN919 **文献标识码:** A **国家标准学科分类代码:** 510.3050

Research on taihu lake water quality prediction based on FOA-GRNN model

Tao Zhiyong Cao Qi Xu Guangxian

(School of Electronic and Information Engineering, Liaoning Technical University, Huludao 125105, China)

Abstract: Due to the complexity of the water system, it is difficult to establish an ideal nonlinear system with traditional water quality prediction methods. In order to improve the accuracy of water quality prediction, this paper proposes a water quality prediction model that uses the fruit fly optimization algorithm (FOA) to improve the general regression neural network (GRNN). Using the global optimization feature of the fruit fly optimization algorithm that can optimize the key parameters, combined with the high-precision approximation ability of the generalized neural network, the FOA-GRNN water quality prediction model is established. Four items of data including oxygen content, temperature, total nitrogen, and total phosphorus collected from observation station No. 0 in Taihu Lake are selected, and the data are preprocessed and simulated by linear interpolation and normalization. The simulation results show that, compared with the GRNN model and the BP model, the prediction results of FOA-GRNN are closer to the true value. The root mean square errors of the four prediction indicators are 0.164 83, 0.250 39, 0.126 59, and 0.111 19, respectively, which are all lower than the GRNN model and the BP model have the advantages of strong stability and high accuracy, and have great practical application value in water quality prediction.

Keywords: generalized neural network; fruit fly optimization algorithm; data preprocessing; water quality prediction

0 引言

淡水是人类赖以生存的基础,是人类生命的源泉。随着社会经济的快速发展,有限的淡水资源被不断消耗,由于过去人们环保意识较差、各方面监管不足,大量工

业、生活废水未经有效处理便排入到地表水体当中,对水体的整体生态环境、生态多样性、服务功能造成了严重的破坏^[1]。有统计表明,太湖水域自 20 世纪 80 年代以来便频发藻华,严重危害了长江三角洲地区的生态环境,上百种植物、鱼类、浮游生物消失在了藻华之中^[2],因此治理和保护水环境势在必行。水质预测可以准确的描述水

环境各数据的变化,对于未来一段时间内水体质量和污染物的发展趋势提供准确的趋势预测,为水污染的防治提供科学决策的依据。意义。

现阶段,水质预测常用的方法主要分为灰度预测模型、混沌理论、时间序列模型、支持向量机(SVM)、人工神经网络等五类。灰度模型是从灰色系统中抽象出来的模型,适用于短期水质预测^[3]。刘东君等^[4]基于调和平均加权法对灰度模型进行加权优化,一定程度上提高了预测精度,缺点是工作量偏大、无法对周期性数据样本进行预测。朱广利等^[5]把相空间重构思想应用到混沌理论中,提出了加权动态局域预测模型并成功运用于洛河流域溶解氧预测,取得了一定的成果,但是该模型对数据样本数量需求较大,不适用于长期预测。张丽梅等^[6]分别采用细分外推法和多参考数据加权的模糊预测法对时间序列进行优化,预测结果显示细分外推法优化的时间序列模型可以达到更好的预测结果,此方法过于依赖参数选取,波动较大。张秀菊^[7]分析了支持向量回归理论和方法并建立支持向量机水质预测模型,预测结果一般。由于水环境是一个复杂多变的动态系统,许多水质参数无法精确测定且难以用数学建模的方式来进行精准描述。人工神经网络则可以很好的解决上述问题。

人工神经网络属于“黑箱模型”,具有非线性逼近能力优秀、自学习性能较强、鲁棒性高等优点,因此对于解决非线性问题有着更好的适用性^[8]。Kim等^[9]采用聚类算法与人工神经网络相结合的方法,把训练数据集不平衡对神经网络拓扑结构训练所造成的影响降到最低;Shi等^[10]采用水质时间序列进行小波降噪然后优化人工神经网络的方法,取得了理想的预测结果。当前应用最广泛的 BP 神经网络(back propagation neural network, BPNN)存在学习速度不快、易陷入局部最优且预测精度不高的缺点,而广义回归神经网络模型(general regression neural network, GRNN)具有柔性的网络结构、强大的非线性映射能力、良好的容错能力等优点,被广泛应用于建立预测模型且取得了较为精准的预测结果^[11-12]。因此,本文尝试在水质预测领域引入广义神经网络,采用果蝇优化算法(fruit fly optimization algorithm, FOA)针对广义神经网络模型进行改进,首先提出 FOA-GRNN 水质预测模型。以太湖流域为研究对象,选取溶解氧、温度、总氮、总磷等四项数据为研究实例进行仿真,并与未改进的广义回归神经网络模型与传统的 BP 神经网络模型仿真结果作对比分析,论证了 FOA-GRNN 模型在水质预测方面的优越性,为管控水环境提供科学的决策依据。

1 FOA-GRNN 水质预测模型

本文的 FOA-GRNN 水质预测模型结构如图 1 所示。

整个模型由 3 部分组成。首先,对于输入的水数据集进行预处理。采用线性插值法填充缺失数据与平滑法处理骤变数据后,再做归一化处理。其次,由于 GRNN 性能主要受光滑因子 σ 影响,故用果蝇优化算法优化广义回归神经网络的主要思想就是利用果蝇寻觅食物以及通过视觉聚集群体位置的特性,来寻得 Spread 的最优值,即把 GRNN 模型预测过程中所得到的均方根误差(RMSE)调整到最小。最后,寻得最优光滑因子后,将此光滑因子输入到 GRNN 中并建立水质预测模型。

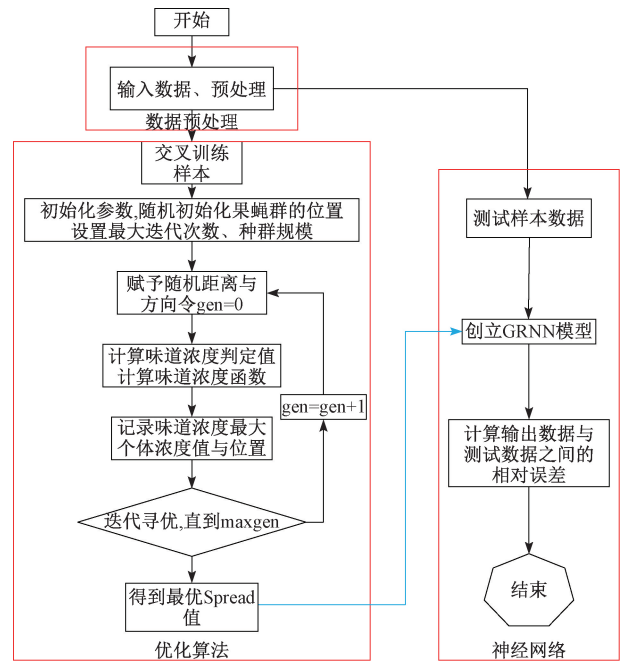


图 1 FOA-GRNN 流程

Fig. 1 FOA-GRNN flow chart

本文是将 GRNN 的均方根误差函数作为果蝇预测中的适应度函数,先计算果蝇个体与原点之间的距离 D_i 并取倒数,得到果蝇群味道浓度判定值 σ 。再将味道浓度判定值 σ 代入 GRNN 的 Spread 中,利用 MATLAB 神经网络的工具箱 newgrnn 函数来计算出最优值。

$$\sigma = \frac{1}{D_i} \quad (1)$$

$$RMSE = \sqrt{\frac{\sum_1^M (\hat{y}_1 - y_i)^2}{M}} \quad (2)$$

具体步骤如下:

- 1) 选取数据,对各项数据进行归一化处理以同等比例划分训练集与测试集;
- 2) 设置种群初始位置为 $[0, 1]$, 最大迭代次数为 100, 种群规模为 10;
- 3) 计算果蝇个体与原点之间的距离并取倒数,作为其对应的光滑因子;

4) 选取 GRNN 的均方根误差函数作为适应度函数并代入步骤 3 中的光滑因子, 计算并找出浓度值 $Smell$ 最小的个体, 记录最优浓度 $bestSmell$ 并保留其位置;

5) 迭代寻优, 重复步骤 2) ~ 4), 直到最大迭代次数, 输出此时的最优光滑因子;

6) 将步骤 5) 中输出的最优光滑因子输入到 GRNN 中建立预测模型。

1.1 数据预处理

由于在水质数据采集的过程中干扰因素众多, 导致采集到的数据会存在噪音多、不一致、缺失较多等缺点, 如果直接将未经处理的数据运用实验仿真, 会导致众参数的变化规律难以被发掘, 影响模型的预测精度, 故需要进行数据预处理。数据预处理的目的是填充缺失值、识别离群点、光滑数据噪音。

如果缺失数据较少, 对整体数据影响不大, 此时可以忽略缺失值, 或者针对少量缺失值进行人工填写。但是上述两种方法仅限于缺失值占比较小, 不适用于数据缺失较多的情况。当缺失值占整体数据比重较大时, 通常采用如下 3 种处理方式: 1) 对缺失值进行等值替换, 操作简单, 但可靠性欠佳; 2) 使用线性插值、平滑方法等多种方法取得均值填充缺失值, 这种方法最大的优点是填充的数据在一定程度上保留了数据的典型趋势; 3) 使用回归、决策树等算法计算缺失的数据, 较为复杂。

首先是针对缺失数据的处理。针对前后时间间隔较大的缺失数据, 本文采用不同监测站同一时期且刻度相同位置的数据对其进行修复。对于时间跨度很小的缺失数据, 则采用线性插值法对其进行补充, 公式如下:

$$X_{k+i} = X_k + i(X_{k+j} - X_k)/j, 0 < i < j \quad (3)$$

式中: X_k 、 X_{k+i} 和 X_{k+j} 是水质参数分别在 k 、 $k+i$ 和 $k+j$ 时刻的取值。

由于监测是连续的, 因此监测到的水文数据具有时序性和延续性的特点, 在正常情况下相邻的水文数据不会发生骤变, 因此应当将数值大于样本均方误差两倍的跳变数据做平滑处理, 公式如下:

$$X_k = (X_{k-1} + X_{k+1})/2 \quad (4)$$

初始数据类型较为复杂且跨度较大, 为保证预测的准确性, 本文将处理过的数据再做归一化处理, 公式如下:

$$X_0 = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (5)$$

式中: X_0 为归一化后的数据; x 为样本初始数据; x_{\max} 为样本数据中的最大值; x_{\min} 为样本数据中的最小值。

1.2 优化算法

果蝇优化算法^[13]是潘文超^[14]在 2011 年 6 月提出的一种全局优化算法。FOA 算法与遗传算法、蚁群算法、粒

子群算法等相似, 都是通过模拟自然界中的生物行为来进行寻优的。其优点是参数少, 具有更快的收敛速度以及更好的收敛能力, 因此被广泛应用于神经网络、数据挖掘、支持向量机参数优化等各个科学和工程领域。

数据经预处理后, 利用果蝇算法对 GRNN 光滑因子进行寻优, 步骤归纳如下^[15-17]。

1) 随机初始化果蝇群的位置。

$$Initx_axis \quad (6)$$

$$Inity_axis \quad (7)$$

2) 赋予个体随机的觅食距离与方向并记录。

$$x_i = x_axis + Random \quad Vaule \quad (8)$$

$$y_i = y_axis + Random \quad Vaule \quad (9)$$

3) 由于无法确定果蝇食物的位置, 转为估

计果蝇个体与原点之间的距离 D_i 。取果蝇群味道浓度判定值 σ 为距离 D_i 的倒数。

$$D_i = \sqrt{X_i^2 + Y_i^2} \quad (10)$$

$$\sigma = \frac{1}{D_i} \quad (11)$$

4) 调用 GNRR 测试数据的 RMSE 作为味道浓度函数 (Fitness function), 其中 σ 为步骤 3) 中所求得的味道浓度判定值。

5) 找出果蝇群中味道浓度最大的果蝇个体, 并记录其位置。

$$[bestSmell \quad bestIndex] = \max(Smell) \quad (12)$$

6) 储存最高的气味浓度及其位置坐标值。同时, 果蝇利用视觉飞向该位置, 新聚集位置形成。

$$Smellbest = bestSmell \quad (13)$$

$$x_axis = x(bestIndex) \quad (14)$$

$$y_axis = y(bestIndex) \quad (15)$$

7) 迭代寻优开始, 重复上述步骤 2) ~ 6), 记录最优气味浓度值及其坐标, 直到达到最大迭代次数为止。此时的即为最优光滑因子。

1.3 GRNN

GRNN^[18-20]是美国学者 Specht 在 1991 年提出的一种高度并行的径向基函数网络。得益于 GRNN 强大的非线性映射能力, 即使样本数量较少, 其仍然可以在样本中找到关系, 从而使网络的输出收敛到最佳值; 此外, 由于其良好的容错能力和鲁棒性, 广义回归神经网络具有更好的逼近能力和比 BP 更快的学习速度, 因此 GRNN 非常适合解决非线性问题。GRNN 由一个径向基网络层和一个线性网络层组成, 包括输入层、隐含层和输出层 4 层结构, 其结构如图 2 所示。

本文网络计算过程如下。

1) X_i 是经预处理后的水质数据, 每个神经元都通过输入将数据直接采样到模式层, 无需计算。




图 2 广义回归神经网络结构示意图

Fig. 2 Schematic diagram of generalized regression neural network structure

2) 隐含层第 i 个神经元输出为:

$$P_i = \exp \left[- \frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right] \quad (16)$$

式中: X 是该层的网络输入变量; X_i 是第 i 个神经元所对应的训练样本; σ 是果蝇寻优得到的最优光滑因子, 决定隐含层中基函数的形状。

3) 求和层中有两种类型的神经元, 其公式如下:

$$S_{Dj} = \sum_{i=1}^n P_i \quad (17)$$

$$S_{Nj} = \sum_{i=1}^n y_{ij} P_i \quad (18)$$

式中: S_{Dj} 为所有求和层神经元的总和, 且求和层与神经元之间的连接权值为 1; S_{Nj} 代表所有模型层神经元的总和, 但是求和层与神经元之间的连接权重不再为 1, 而是隐含层第 i 个训练样本与求和层第 i 个元素。

4) 将式(2)和(3)相除可以得到每个神经元的计算:

$$y_i = \frac{S_{Nj}}{S_{Dj}} = \frac{\sum_{i=1}^n y_{ij} P_i}{\sum_{i=1}^n P_i} \quad (19)$$

此时 y_i 便是经过 GRNN 计算后的最终输出结果果。

2 实验仿真与比较

2.1 数据来源

太湖 (119°52'–120°36'E, 30°55'–31°32'N) 位于长江三角洲, 为我国五大淡水湖之一。本文所用数据集来源于中国科学院太湖湖泊生态系统研究站 (以下简称太湖站)《2007—2015 年太湖水体理化监测数据集》^[17]。太湖站共有 8 个长期观测站点, 观测站点位置如图 3 所示。

本文选取太湖站 0 号观测站 (120°22'217"E, 31°53'983"N)2007 年 1 月~2015 年 12 月共计 108 组数据^[19], 数据采样频率为每月中旬采样一次。采用前 90




图 3 太湖站位置以及站点分布

Fig. 3 Location of Taihu station and station distribution map

组数据进行训练网络, 后 18 组作为测试数据。

选取指标包括溶解氧、温度、总磷及总氮 4 项。

2.2 模型评价标准

为了可以直观的评价各预测模型的优劣, 需对预测结果做具体的量化。本文选取 RMSE 作为评价指标对各模型的预测结果做量化分析评价。RMSE 的计算结果与模型预测能力成反比。具体公式如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{i0})^2} \quad (20)$$

式中: N 代表测试样本的数目; y_{i0} 代表 i 时刻的预测值; y_{i1} 代表 i 时刻的真实值。

2.3 异常数据处理

本文采用线性插值法与平滑公式来处理采集到的水质数据, 以剔除异常数据。处理前与处理后的数据对比如图 4~7 所示。可以看出, 经过预处理的水质数据曲线更加平滑, 数据波动更小, 有利于提升预测精度。

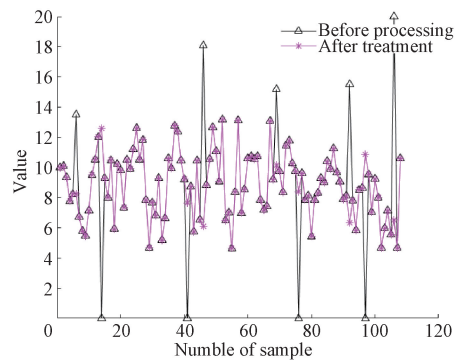


图 4 含氧量数据预处理对比

Fig. 4 Comparison of oxygen content data preprocessing

2.4 仿真结果分析

设置果蝇群体初始位置为 $[0, 1]$, 最大迭代次数为 100, 种群规模为 10, 建立 FAO-GRNN 预测模型。经归一化处理过后的 90 组数据作为训练样本, 18 组数据作为




图 5 温度数据预处理对比

Fig. 5 Temperature data preprocessing comparison chart

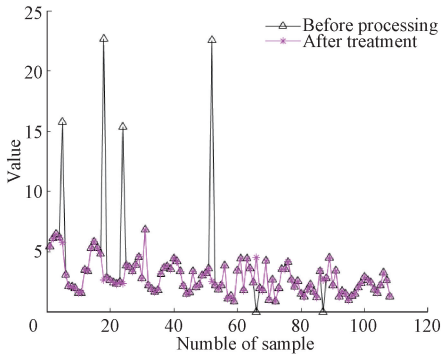


图 6 总氮数据预处理对比

Fig. 6 Comparison of total nitrogen data preprocessing

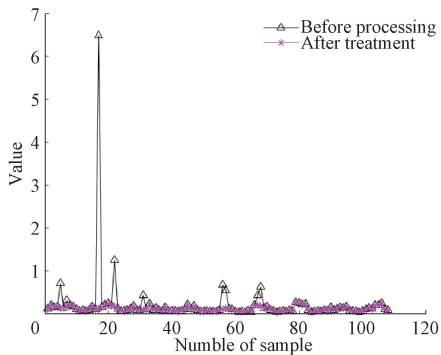


图 7 总磷数据预处理对比

Fig. 7 Comparison of total phosphorus data preprocessing

测试样本。为体现 FAO-GRNN 模型预测优越性,引入未改进的 GRNN 模型以及传统的 BP 模型,对比结果如图 8~11 所示。

从 4 组预测结果可以看出,3 种预测模型均可以对水文数据进行预测,但 GRNN 模型、BP 模型预测结果存在不同程度的波动导致稳定性较差,且预测精度均不如 FOA-GRNN 模型。

由于曲线拟合的程度主要取决于人眼视觉的观察,受主观因素影响较大,因此本文分别从最大相对误差与均方根误差两个方面对 3 种预测模型做进一步量化。3

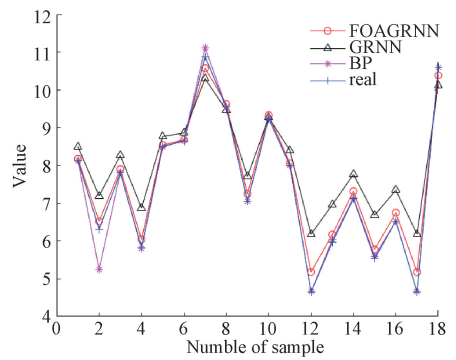


图 8 溶解氧的预测值与真实值的对比

Fig. 8 Comparison of the predicted value of oxygen content with the true value

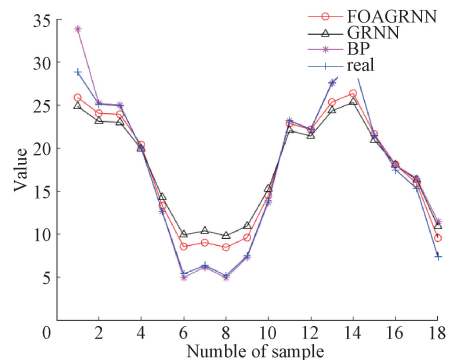


图 9 温度的预测值与真实值对比

Fig. 9 Comparison of the predicted value of the temperature with the true value

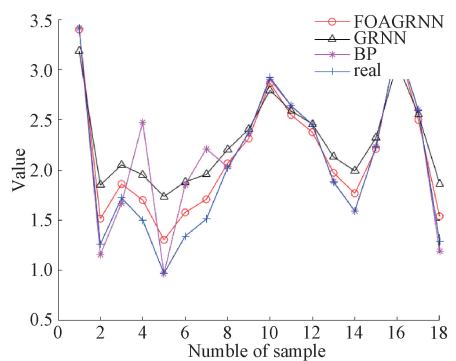


图 10 总氮的预测值与真实值对比

Fig. 10 Comparison of predicted value and true value of total nitrogen

个预测模型的最大相对误差如表 1 所示,均方根误差如表 2 所示。其中,最大相对误差代表预测误差的最大值,均方根误差描述的则是预测结果的离散程度,数值均是越小越好。




图 11 总磷的预测值与真实值对比

Fig. 11 Comparison of predicted value and true value of total phosphorus

表 1 最大相对误差比较

Table 1 Comparison of maximum relative error

神经网络结构	最大相对误差/%			
	溶解氧	温度	总氮	总磷
FOA-GRNN	0.366 9	0.433 5	0.344 2	0.086 1
GRNN	0.689 5	0.890 7	1.325 4	0.247 6
BP	0.652 4	0.978 4	0.649 8	4.346 1

表 2 均方根误差比较

Table 2 RMSE comparison

神经网络模型	RMSE			
	溶解氧	温度	总磷	总氮
FOA-GRNN	0.164 83	0.250 39	0.126 59	0.111 19
GRNN	0.317 06	0.367 59	0.290 06	0.275 4
BP	0.338 78	0.410 58	0.309 66	0.272 77

由表 1 可见,本文提出的 FOA-GRNN 模型对溶解氧、温度、总氮及总磷预测的相对误差的绝对值最大分别为 0.366 9%、0.433 5%、0.344 2%及 0.086 1%,未改进的 GRNN 模型对应的最大值分别为 0.689 5%、0.890 7%、1.325 4%及 0.247 6%,BP 模型对应的最大值分别为 0.652 4%、0.978 4%、0.649 8%及 4.346 1%。本文所提改进模型预测溶解氧数据的最大误差分别比 GRNN 模型和 BP 模型减少 46.79%、43.77%;预测温度数据的最大误差分别比 GRNN 模型和 BP 模型减少 51.33%、55.69%;预测总氮数据的最大误差分别比 GRNN 模型和 BP 模型减少 74.03%、47.03%;预测总磷数据的最大误差分别比 GRNN 模型和 BP 模型减少 16.15%、98.01%。由表 2 可知,对于 4 组预测数据,FAO-GRNN 模型均拥有更小的均方根误差值,预测精度显著提高。因此,FOA 对 GRNN 有很好的优化效果,本文所提 FOA-GRNN 模型对于水质预测的稳定性与精准度有显著提升,相比于 GRNN 模型及 BP 模型更适合承担水文数据预测的任务。

3 结 论

为提高传统水质预测模型的精度,本文提出了 FOA-GRNN 模型。由于广义神经网络模型的预测精度过于依赖光滑因子的选定,故引入果蝇优化算法来寻优最佳光滑因子,从而避免人工调整的误差,提升预测精度。以太湖 2007 年 1 月~2015 年 12 月 0 号观测站点所收集到的数据为例,选取溶解氧,温度,总磷以及总氮等 4 项指标进行实验仿真,并与未改进的 GRNN 模型、传统 BP 模型作对比。从仿真结果可以看出,与 GRNN 模型、BP 模型相比,FOA-GRNN 模型有着更稳定的预测曲线、更接近真实值的预测数据,预测精度最高且不需要人工调整参数,大幅降低了工作量与预测误差。后续将进一步加入其他优化模型及处理算法,达到更加准确的预测结果。

参考文献

- [1] HARA J, MAMUN M, AN K G. Ecological river health assessments using chemical parameter model and the index of biological integrity model [J]. Water, 2019, 11(8) : 1729.
- [2] GUAN B H, AN S Q, GU B H. Assessment of ecosystem health during the past 40 years for Lake Taihu in the Yangtze River Delta, China [J]. Limnology, 2011, 12(1) : 47-53.
- [3] 郭兰兰,邹志红,安岩.基于残差修正的 GM(1,1)模型在水质预测中的应用研究 [J]. 数学的实践与认识, 2014, 44(19) : 176-181.
- [4] GUO L L, ZOU ZH H, AN Y. Research on application of modified GM (1, 1) model based on residual error in water quality prediction [J]. Mathematics Practice and Knowledge, 2014, 44(19) : 176-181.
- [5] 刘东君,邹志红.最优加权组合预测法在水质预测中的应用研究 [J]. 环境科学学报, 2012, 32 (12) : 3128-3132.
- [6] LIU D J, ZOU ZH H. Application of weighted combination model on forecasting water quality [J]. Journal of Environmental Science, 2012, 32(12) : 3128-3132.
- [5] 朱广利,秦玉芳.基于混沌理论的水质预测方法研究 [J]. 湖北农业科学, 2012, 51(17) : 3726-3729.
- [6] ZHU G L, QIN Y F. Water quality prediction method based on chaos theory [J]. Hubei Agricultural Sciences, 2012, 51(17) : 3726-3729.
- [6] 张丽梅,宛立,董建新.细分外推与模糊预测在近海水质非线性时序处理中的比较分析 [J]. 大连海洋大学

- 学报, 2015, 30(3): 324-329.
- ZANG L M, WAN L, DONG J X. Comparison of nonlinear times series of water quality analysis in coastal water by subdivision extrapolation and fuzzy forecasting[J]. Journal of Dalian Ocean University, 2015, 30(3): 324-329.
- [7] 张秀菊, 安焕, 赵文荣, 等. 基于支持向量机的水质预测应用实例[J]. 中国农村水利水电, 2015(1): 85-89.
- ZHANG X J, AN H, ZHAO W R, et al. Water quality prediction application example based on support vector machine [J]. China Rural Water and Hydropower, 2015(1): 85-89.
- [8] 惠高云, 谈立峰, 褚苏春, 等. 生活饮用水在线监测预警模型的研究进展[J]. 环境与健康杂志, 2018, 35(9): 841-845.
- HUI G Y, TAN L F, CHU S CH, et al. Online drinking water quality monitoring and early warning model: A review of recent studies[J]. Journal of Environment and Health, 2018, 35(9): 841-845.
- [9] KIM S E, SEO I W. Artificial neural network ensemble modeling with conjunctive data clustering for water quality prediction in rivers [J]. Journal of Hydro-environment Research, 2015, 9(3): 325-339.
- [10] SHI B, WANG P, JIANG J, et al. Applying high-frequency surrogate measurements and a wavelet-ANN model to provide early warnings of rapid surface water quality anomalies[J]. Science of the Total Environment, 2018, 610-611: 1390.
- [11] HUANG X, ZHAO H D. Projectile impact point prediction method based on GRNN [J]. Journal of Measurement Science and Instrumentation, 2016, 7(1): 7-12, 2.
- [12] ROOKI R. Application of general regression neural network (GRNN) for indirect measuring pressure loss of Herschel-Bulkley drilling fluids in oil drilling [J]. Measurement, 2016, 85: 184-191.
- [13] 赵新, 刘冬生. 基于改进果蝇算法优化 SVM 的模拟电路故障诊断及对比分析[J]. 电子测量与仪器学报, 2019, 33(3): 78-84.
- ZHAO X, LIU D SH. Analog circuit fault diagnosis and comparison analysis based on SVM optimized by improved fruit fly optimization algorithm[J]. Journal of Electronic Measurement and Instrument, 2019, 33(3): 78-84.
- [14] 潘文超. 应用果蝇优化算法优化广义回归神经网络进行企业经营绩效评估[J]. 太原理工大学学报(社会科学版), 2011, 29(4): 1-5.
- PAN W CH. Using fruit fly optimization algorithm optimized general regression neural network to construct the operating performance of enterprises model [J]. Journal of Taiyuan University of Technology (Social Science Edition), 2011, 29(4): 1-5.
- [15] 饶盛华, 张小平, 张铸, 等. 基于果蝇算法的开关磁阻电机多目标优化研究[J]. 电子测量与仪器学报, 2017, 31(7): 1152-1158.
- RAO SH H, ZHANG X P, ZHANG ZH, et al. Study on multi-objective optimization of SRM based on FOA[J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(7): 1152-1158.
- [16] 王菲, 冯早, 朱雪峰. 基于 FOA 优化的 CSSVM 管道堵塞状态识别研究[J]. 电子测量与仪器学报, 2020, 34(7): 168-176.
- WANG F, FENG Z, ZHU X F. Research on CSSVM pipeline blockage recognition based on FOA optimization[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(7): 168-176.
- [17] 肖晓晖. 基于改进果蝇优化算法优化 SVM 的模拟电路故障诊断[J]. 电子测量与仪器学报, 2019, 33(5): 57-64.
- XIAO X H. Fault diagnosis of analog circuits based on improved Drosophila optimization algorithm to optimize SVM [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(5): 57-64.
- [18] 李琳, 潘福臣, 房刚. 基于广义回归神经网络的线材温度预测分析[J]. 仪器仪表学报, 2006, 27(S1): 839-841.
- LI L, PAN F CH, FANG G. Performance prediction of wire temperature base on general regression neural network[J]. Chinese Journal of Scientific Instrument, 2006, 27(S1): 839-841.
- [19] 戴虹, 钱晋武, 张震, 等. GRNN 在肌电预测踝关节运动中的应用[J]. 仪器仪表学报, 2013, 34(4): 845-852.
- DAI H, QIAN J W, ZHANG ZH, et al. Application of GRNN in the prediction of ankle joint movement by electromyography [J]. Chinese Journal of Scientific Instrument, 2013, 34(4): 845-852.
- [20] 吴常铖, 宋爱国, 曾洪, 等. 基于 sEMG 和 GRNN 的手部输出力估计[J]. 仪器仪表学报, 2017, 38(1): 97-104.
- WU CH CH, SONG AI G, ZENG H, et al. Hand output

force estimation based on sEMG and GRNN[J]. Chinese Journal of Scientific Instrument, 2017, 38(1): 97-104.

[21] 闵岫, 钱荣树, 朱广伟, 等. 2007—2015 年太湖水体理化监测数据集[J]. 中国科学数据(中英文网络版), 2020, 5(1): 85-93.

MIN SH, QIAN R SH, ZHU G W, et al. A physical and chemical monitoring dataset of Taihu Lake from 2007 to 2015[J]. China Scientific Data (Chinese and English online version), 2020, 5(1): 85-93.

作者简介



陶志勇, 2000 年和 2005 年于辽宁工程技术大学分别获得学士学位、硕士学位, 2015 年于辽宁工程技术大学获得博士学位, 现为辽宁工程技术大学副教授, 主要研究方向为智能信息处理。

E-mail: xyzmail@126.com

Tao Zhiyong received his B. Sc. degree and M. Sc. degree from Liaoning Technical University in 2000 and 2005, and Ph. D. degree from Liaoning Technical University in 2015. Now he is an associate professor at Liaoning Technical University. His

main research interest includes intelligent information processing.



曹琦, 2018 年于山东建筑大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为智能信息处理。

E-mail: 372516932@qq.com

Cao Qi received her B. Sc. degree from Shandong Jianzhu University in 2018. Now she is a M. Sc. candidate at Liaoning Technical University. Her main research interest includes intelligent information processing.



徐光宪, 2000 年和 2005 年于辽宁工程技术大学分别获得学士学位、硕士学位, 2015 年于辽宁工程技术大学获得博士学位, 现为辽宁工程技术大学副教授, 主要研究方向为网络编码与信息处理。

E-mail: 5261009@qq.com

Xu Guangxian received his B. Sc. and M. Sc. degrees from Liaoning Technical University in 2000 and 2005, and Ph. D. from Liaoning Technical University in 2015. He is currently an associate professor at Liaoning Technical University. His main research interests include network coding and information processing.