

doi:10.6041/j.issn.1000-1298.2017.S0.033

融合 ARIMA 模型和 GAWNN 的溶解氧含量预测方法

吴静¹ 李振波^{1,2} 朱玲¹ 李晨¹

(1. 中国农业大学信息与电气工程学院, 北京 100083; 2. 中国农业大学农业部农业信息获取技术重点实验室, 北京 100083)

摘要: 针对河流污染治理、水源管理, 提出了融合差分自回归滑动平均 ARIMA 模型和遗传算法优化的波神经网络相结合的河流水质预测方法。将采集的河流水质参数时间序列数据, 分解为线性与非线性序列, 线性数据使用 ARIMA 模型预测, 使用最小二乘法完成了 ARIMA 模型参数估计。对于经过 ARIMA 模型处理的非线性残差数据、预测值与原始溶解氧序列之间的线性与非线性关系, 采用波神经网络(WNN)获得预测值, 并采用遗传算法的选择、交叉、变异等操作优化网络参数, 比传统 WNN 模型预测精度显著提高。ARIMA 模型、波神经网络、遗传算法优化波神经网络(GAWNN)和未经遗传算法优化的组合模型预测平均绝对误差分别为 0.29%、0.39%、0.26%、0.24%, 提出的组合模型预测结果平均绝对误差约 0.19% 且为最小。结果表明, 该组合模型优于单个模型和传统组合模型的预测结果。

关键词: 水质预测; 差分自回归滑动平均模型; 遗传算法; 波神经网络

中图分类号: TP391 **文献标识码:** A **文章编号:** 1000-1298(2017)S0-0205-06

Hybrid Model of ARIMA Model and GAWNN for Dissolved Oxygen Content Prediction

WU Jing¹ LI Zhenbo^{1,2} ZHU Ling¹ LI Chen¹

(1. College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China

2. Key Laboratory of Agricultural Information Acquisition, Ministry of Agriculture, China Agricultural University, Beijing 100083, China)

Abstract: In view of the river pollution control and water management, this study put forward a hybrid model of autoregressive moving average (ARIMA) model and wavelet neural network combined with genetic algorithm, to predict the river water quality. For time series data of water quality parameters, it includes linear and nonlinear sequences. So using the least square method to estimate the ARIMA model parameters, ARIMA model was used to predict linear data. For the nonlinear relationship among the residual error data, prediction result, and original data, using genetic algorithm to optimize wavelet neural network (WNN) parameters, including selection, crossover and mutation operation, WNN was applied to obtain predicted data, which increased the traditional WNN prediction precision significantly. Experimental results show that the mean absolute error of ARIMA model, wavelet neural network, genetic algorithm optimized wavelet neural network (GAWNN), or the hybrid model without genetic algorithm optimized model prediction results are 0.29%, 0.39%, 0.26% and 0.24% respectively. The mean absolute error of the combined model prediction is about 0.19%, which is the minimum, indicating that the prediction result is better than that of single model and the hybrid model without genetic algorithm optimized.

Key words: water quality prediction; autoregressive integrated moving average model; genetic algorithm; wavelet neural network

引言

河流水质变化预测是实现水资源管理、水污染

治理的前提工作。使用历史数据, 可通过不同的预测方法挖掘水质指标之间的非线性关系或待预测水质指标本身随时间的变化规律。河流流域水质受人

收稿日期: 2017-06-03 修回日期: 2017-11-21

基金项目: 国家国际科技合作专项(2015DFA00530)、山东省重点研发计划项目(2016CYJS03A02)和国家自然科学基金项目(61471133)

作者简介: 吴静(1993—), 女, 硕士生, 主要从事计算机视觉和物联网技术研究, E-mail: 306930180@qq.com

通信作者: 李振波(1978—), 男, 副教授, 博士生导师, 主要从事智能信息处理研究, E-mail: zhenboli@126.com

类活动和水文气象条件的双重影响,需要及时地监测河流流域的水量与水质状况,预测后续水质变化。河流流域水质的影响因子为 pH 值、溶解氧 (DO)、电导率 (EC)、浊度 (TU)、氨氮 ($\text{NH}_3\text{-N}$)、化学需氧量 (COD)、高锰酸盐等水质参数,对其中溶解氧、氨氮、高锰酸盐的预测,对河流不同流域的污染治理、水源管理具有预警作用。利用采集的时间序列水质数据,分析监测数据,利用模型预测后续水质变化是十分有必要的。目前预测方法主要分为两大类^[1]:一是传统的预测方法,把经典数学作为理论基础,包括时间序列预测法、回归分析法、马尔科夫模型、水质模拟预测法等;二是基于人工智能的预测方法,包括灰色模型、神经网络预测法、支持向量机回归预测法等。

近些年来,许多学者使用多种方法组成的混合模型做预测,说明结合不同的模型可以改善单一模型预测性能。CHEN 等^[2]构造了组合模型,合并季节性自回归综合移动平均 (SARIMA) 和支持向量机,用于季节性时间序列模型预测。其中差分自回归滑动平均 (ARIMA) 时间序列预测模型与神经网络的混合模型也出现不少。TSENG 等^[3]提议使用结合了季节性 ARIMA (SARIMA) 模型和反向传播神经网络的 SARIMABP 混合模型来预测季节性时间序列数据。ZHOU 等^[4]提出了一种基于灰色和 Box-Jenkins 自回归移动平均模型的混合建模和预测方法。MEHDI 等^[5]使用 ARIMA 与 ANN 的混合模型来对时间序列数据进行预测。

文献[6-8]研究了基于 ARIMA 和 ANN 预测方法,实验结果证明了混合模型预测的有效性。JIANG 等^[9]提出一种基于小波神经网络的遗传算法 (GAWNN) 模型预测土地位移的方法,与基于反向传播神经网络的遗传算法 (GABPNN) 相比,对我国的三峡库区白水山滑坡的位移预测,结果显示 GAWNN 的精度更高,说明经过遗传算法优化人工神经网络更适合水质参数预测,可提高水质预测的预测精度。DENG 等^[10]为了获得比传统 ARIMA-ANN 模型更通用、更精确的预测模型水质混合预测模型,提出了一个新的混合模型 ARIMA 和径向基函数神经网络,实验结果表明,该方法模型是一种有效水质预测方法。随后,DENG 等^[11]提出了一种新的水质时间序列数据分析框架,可以挖掘水质历史数据的隐藏和有价值的知识,对我国长江上游 5 个监测站收集的氧时间序列数据进行了分析,发现了水质在主流和支流的关系以及主要的变化模式。

因此,本文以水质溶解氧时序数据为研究对象,为获得比传统 ARIMA 和 ANN 模型更通用、更精确

的水质混合预测模型,提出一种基于 ARIMA 模型和小波神经网络的水质预测方法,并结合遗传算法对小波神经网络进行优化,最后与单独的 ARIMA 模型和小波神经网络,以及 ARIMA 结合未经遗传算法优化的小波神经网络 3 种预测模型进行对比分析。

1 方法与算法

1.1 差分自回归滑动平均 ARIMA 模型

差分自回归滑动平均模型 (Autoregressive integrated moving average model, ARIMA) 记为 $\text{ARIMA}(p, d, q)$, AR 是自回归, p 为自回归项, MA 为移动平均, q 为移动平均项数, d 为将时间序列变成平稳时间序列时所处理的差分次数。

建立 ARIMA 时间序列模型包括 4 个步骤^[12]:

(1) 数据的平稳性处理

ARIMA 模型建模时,首先采用 ADF (Augmented dickey-fuller) 单位根检验来判断数据的平稳性。采取差分的形式处理非平稳数据。时间序列数据被平稳化处理后, $\text{ARIMA}(p, d, q)$ 模型就转化为 $\text{ARMA}(p, q)$ 模型。序列能通过 d 次差分后变成平稳序列则建立 $\text{ARIMA}(p, d, p)$ 模型

$$w_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \cdots + \phi_p w_{t-p} + \delta + u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \cdots + \theta_q u_{t-q} \quad (1)$$

式中 w_t ——样本时间序列数据

ϕ_i, θ_i ——模型参数, $i = 1, 2, \dots, q$

δ ——常数,表示序列数据无 0 均值化

u_t ——白噪声序列,其服从独立正态分布 $N(0, \sigma^2)$

(2) 模型识别

在时间序列分析中,采用自相关函数 (ACF)、偏自相关函数 (PACF) 来判别 $\text{ARMA}(p, q)$ 模型的系数和阶数。自相关函数 (ACF) 描述时间序列观测值与其过去的观测值之间的线性相关性。偏自相关函数 (PACF) 描述在给定中间观测值的条件下时间序列观测值与其过去的观测值之间的线性相关性。

(3) 参数估计

时间序列分析模型的阶数确定后,用最小二乘法对 ARIMA 模型进行参数估计。

(4) 模型验证

模型建立完成后,其误差符合平均值为零且方差为常数的正态分布,则认为所建模型是合理的。

1.2 优化的小波神经网络

1.2.1 小波神经网络

小波神经网络 (WNN) 以误差反传神经网络拓扑结构为基础,与 BP 神经网络类似。在小波神经网络中,信号向前传播的同时,误差反向传播,不同

的是小波神经网络隐含层节点的传递函数为小波基函数^[13,14-15]。WNN 包括 3 部分,即输入层、输出层和隐含层,WNN 拓扑结构如图 1 所示。本文小波神经网络采用了单隐层结构,隐层节点根据处理的信号性质选择了 Morlet 小波函数作为传递函数。

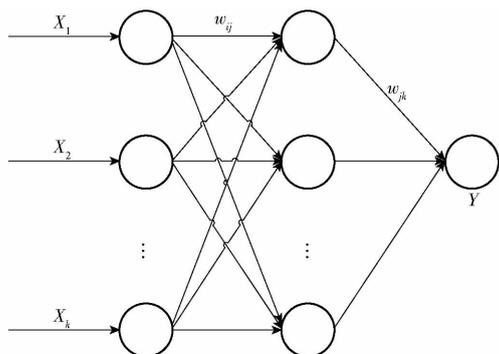


图 1 小波神经网络拓扑结构

Fig. 1 Wavelet neural network topology

X_1, X_2, \dots, X_k 是 WNN 的输入参数; Y 是预测的输出值; w_{ij} 和 w_{jk} 为网络连接权重值。当输入水质参数样本序列为 $x_i (i = 1, 2, \dots, k)$ 时,隐含层输出为

$$h_j = M_j \left(\frac{\sum_{i=1}^k w_{ij} x_i - b_j}{a_j} \right) \quad (j = 1, 2, \dots, m) \quad (2)$$

式中 h_j ——隐含层第 j 个节点的输出
 w_{ij} ——输入层和隐含层的连接权重值
 a_j ——小波基函数 M_j 的伸缩因子
 b_j —— h_j 的平移因子
 M_j ——小波基函数

文中采用的小波基函数是 Morlet 母小波基函数,公式为^[16]

$$y = \cos(1.75x) e^{-\frac{x^2}{2}} \quad (3)$$

小波神经网络输出层计算公式为

$$y_k = \sum_{i=1}^m w_{ik} h_i \quad (k = 1, 2, \dots, n) \quad (4)$$

式中 w_{ik} ——隐含层到输出层的网络连接权重值
 h_i ——第 i 个隐含层节点的输出
 m ——隐含层节点个数
 n ——输出层节点个数^[17]

1.2.2 遗传算法优化的的小波神经网络

遗传算法 (Genetic algorithm) 是模拟达尔文生物进化论的自然选择和遗传学机理的生物进化过程的计算模型^[18-21]。本文采用遗传算法优化的 WNN 网络,其优化网络模型流程图如图 2 所示,具体步骤如下:

(1) 初始化种群和编码网络参数。随机选择 P 个染色体 $P_i (i = 1, 2, \dots, n)$, 对网络参数进行初始

化编码。初始化交叉规模,选择概率 P_s , 交叉概率 P_c , 突变概率 P_m , 初始种群数,设置遗传代数。

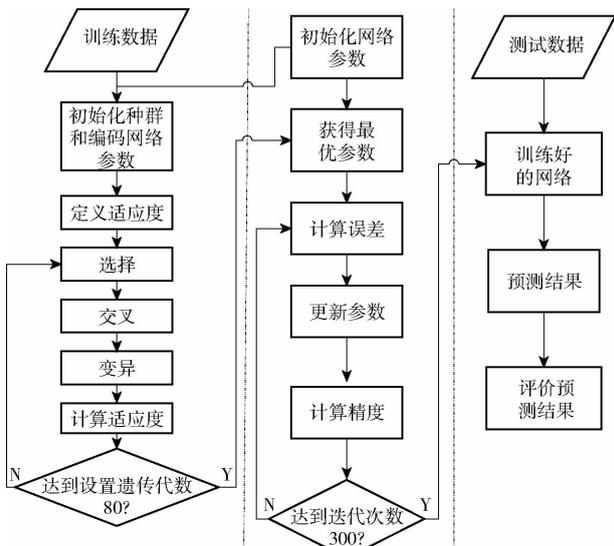


图 2 遗传算法优化的的小波神经网络流程图

Fig. 2 Wavelet neural network optimized by genetic algorithm flowchart

(2) 计算适应度值,根据训练的结果确定每个个体的适应度值。适应度值通过适应度函数计算

$$V = \frac{1}{\frac{1}{L} \sum_{i=1}^L (\hat{y}_i - y_i)^2} \quad (5)$$

式中 \hat{y}_i ——第 i 个输出节点的期望输出值

y_i ——第 i 个节点的实际输出值

V ——适应度值,根据适应度函数计算 V , 保存最大的个体

L ——训练样本长度

(3) 选择、交叉和变异操作^[19]。选择操作是为了得到更优异的下一代,所以将个体适应度最大值直接遗传给后代,同时还应保证种群多样性,从而避免陷入局部最优。本文采用适应度比例方法,个体的选择概率和其适应度值成比例,适应值高的个体在子代中复制自身的个体数目多,保证适应度最大的个体被保留。其中第 n 个个体根据其适应度 $V_n (V_i (i = 1, 2, \dots, L)$ 为每个个体适应度) 被选中的概率 P_s 计算

$$P_s = \frac{V_n}{\sum_{i=1}^L V_i} \quad (6)$$

交叉是随机将个体基因位置互换,从而得出新个体,其中第 i 个染色体 a_i 和第 j 个染色体 a_j 的第 k 个基因的交叉操作方法为

$$\begin{cases} a_{ij} = a_{ij}(1-b) + a_{kj}b \\ a_{kj} = a_{kj}(1-b) + a_{ij}b \end{cases} \quad (7)$$

其中 b 为 $[0, 1]$ 区间的随机数,当生成随机数符合

$b \leq P_c$ 时按式(7)进行操作,设置 P_c 。

变异是为了产生更优秀的个体,在个体中随机挑选基因,对基因进行变异操作,其中第 i 个个体的第 j 个基因 a_{ij} 进行变异的操作方法为

$$a_{ij, \text{new}} = \begin{cases} a_{ij} + (a_{\max} - a_{ij}) [1 - r^{(1-g/G_{\max})^2}] & (r \geq 0.5) \\ a_{ij} - (a_{ij} - a_{\min}) [1 - r^{(1-g/G_{\max})^2}] & (r < 0.5) \end{cases} \quad (8)$$

式中 $a_{ij, \text{new}}$ ——变异生成的新个体

a_{\max} ——基因 a_{ij} 上界

a_{\min} ——基因 a_{ij} 下界

g ——当前迭代次数

G_{\max} ——最大进化次数

r —— $[0, 1]$ 区间的随机数

设置变异概率 P_m , 当生成随机数符合 $r \leq P_m$ 时按式(8)进行变异操作。

(4) 将种群遗传代数超过预定值作为终止条件, 并将得到的最优编码个体进行解码, 转换为优化的小波网络连接权值和伸缩平移尺度, 否则返回步骤(2)。

(5) 用遗传算法完成对小波神经网络权值 w_{ij} 、 w_{jk} 和小波伸缩与平移因子 a_j 、 b_j 优化完成后, 再利用均方误差方法调整网络参数使得误差函数 F 达到最小值, 获得误差函数 F 的梯度, 然后利用梯度值进行误差的反向传播。以网络参数 w_{ij} 和 a_j 为例, 调整公式

$$F = \frac{1}{L} \sum_{i=1}^L (\hat{y}_i - y_i)^2 \quad (9)$$

$$w_{ij, \text{new}} = w_{ij, \text{old}} + \eta \frac{\nabla F}{\nabla w_{ij, \text{old}}} \quad (10)$$

$$a_{j, \text{new}} = a_{j, \text{old}} + \eta \frac{\nabla F}{\nabla a_{j, \text{old}}} \quad (11)$$

式中 $w_{ij, \text{old}}$ 、 $w_{ij, \text{new}}$ ——调整前与调整后的输入层结点与隐含层结点之间的权值

$a_{j, \text{new}}$ 、 $a_{j, \text{old}}$ ——调整前和调整后的平衡因子

η ——网络学习速率

1.3 ARIMA 和 GAWNN 组合模型

实际的时间序列往往既有线性特征, 又有非线性特征, 单独使用 ARIMA 或 WNN 都不能很好地反映出时间序列的线性与非线性双重特征^[16]。为更好表征其中线性和非线性关系, 相比单独的 ARIMA 模型和传统神经网络模型, 验证 ARIMA 与 GAWNN 组合模型预测的有效性, 本文以水质参数溶解氧时间序列数据为研究对象, 使用遗传算法对小波神经网络进行优化, 包含 ARIMA 模型建模和小波神经网络建模两个阶段:

(1) 将溶解氧时间序列输入 ARIMA 模型中, 根

据 ADF 检测数据平稳性, 进行 d 次差分, 观测自相关和偏相关图, 识别模型。设 ARIMA 模型预测结果为 \hat{L}_t , 原时间序列 y_t 和预测结果 \hat{L}_t 的残差为 e_t , 即

$$e_t = y_t - \hat{L}_t \quad (12)$$

原时间序列中的非线性关系隐含在残差序列 $\{e_t\}$ 中, 即

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \varepsilon_t \quad (13)$$

式中 ε_t ——随机误差

ARIMA 建模步骤: ①把溶解氧时序数据分为训练集和测试集。对训练集数据进行归一化处理, 将数据转换到 $[0, 1]$ 区间, 公式为

$$x_i = \frac{X_i - \bar{X}_i}{S_i} \quad (14)$$

式中 X_i ——原始溶解氧时间序列数据

\bar{X}_i ——溶解氧数据平均值

S_i ——标准偏差

②差分溶解氧时序数据, 然后使用 AR、MA 和 ARMA 不同模型计算 AIC 值, 选用 AIC 值最小的模型。③采用自相关函数 (ACF)、偏自相关函数 (PACF) 来判别 ARMA (p, q) 模型的系数 p 和阶数 q 。④使用最小二乘法对模型参数值进行参数估计。⑤预测误差是否是平均值为零且方差为常数的正态分布, 即服从零均值、方差不变的正态分布, 最后训练数据反归一化, 获得残差序列数据和预测数据, 模型建立完成。

(2) 遗传算法优化的小波神经网络 (GAWNN) 模型对残差序列 $\{e_t\}$ 以及原始溶解氧序列 y_t 和 ARIMA 的预测值 \hat{L}_t 3 个输入序列进行预测, 设 ARIMA 和 GAWNN 模型进行组合预测的结果为 \hat{y}_t , 则

$$\hat{y}_t = f(y_t, e_t, \hat{L}_t) \quad (15)$$

小波神经网络建模步骤: ①经过 ARIMA 模型预测后的残差序列数据、预测数据和原始溶解氧时间序列数据数据进行归一化处理, 并作为小波神经的输入。②使用遗传算法对小波的伸缩因子、平移因子、连接权值进行优化, 获得最优网络参数。③对小波神经网络学习率以及动量因子赋予初始值, 利用均方误差法对伸缩因子、平移因子、连接权值再次进行优化。调整网络参数使得误差函数达到最小值, 使用误差函数梯度值进行误差的反向传播。④若误差函数小于预先设定的某个精度值, 或者达到最大迭代次数, 则计算隐层及输出层的输出, 停止网络学习过程, 否则返回步骤③。⑤使用平均绝对误差 (MAE)、均方根误差 (RMSE)、均方误差 (MSE) 评价模型预测性能, 保存网络参数, 获得网络模型。⑥利用测试集验证组合模型预测, 获得预测结果。

2 试验结果与分析

试验采用 7 d 溶解氧时间序列数据,有 5 496 条数据,每隔 2 min 采集一次,组合模型选用前 6 d 的时序数据作为训练集,第 7 天的数据作为测试集。经过训练集试验,ARIMA 模型最优为 ARIMA(7, 1, 0),并用此模型预测第 7 天的溶解氧时序数据,获

得残差序列和预测数据。对于小波神经网络部分,选用经过 ARIMA 模型的残差序列、预测数据和原始溶解氧时序数据作为网络输入,隐层节点数目最优为 10 个(表 1),迭代次数 300 次,输出值为最终预测值。遗传算法初始种群为 30,选择操作采用适应度比例决定,交叉概率 0.6,变异概率 0.09,最大迭代次数设置为 80。

表 1 GAWNN 模型精度
Tab.1 Model accuracy of GAWNN

精度	6	7	8	9	10	11	12	13
MAE	0.004 8	0.004 6	0.004 5	0.003 2	0.001 9	0.002 5	0.003 5	0.003 8
RMSE	0.070 0	0.054 3	0.065 9	0.051 1	0.022 3	0.034 4	0.044 5	0.054 8
MSE	0.004 9	0.003 0	0.004 3	0.002 61	0.000 5	0.001 8	0.001 9	0.003 1

为了比较单个模型和组合模型预测精度,以及使用遗传算法优化小波神经和传统小波神经网络的差别,本文单个神经网络模型训练数据以前 6 d 溶解氧数据作为唯一的输入,隐层节点数目设置为 10,输出为溶解氧预测值。以经过 ARIMA 模型的残差序列、预测数据和原始溶解氧时序数据作为 GAWNN 的 3 个输入的训练过程,选定学习率为 0.02,在遗传算法优化的小波神经网络训练过程中,隐含层节点数目分别以 6 到 13 个节点测试,网络精度变化如表 1 所示。当隐含层节点数目为 10 时,GAWNN 拟合与预测效果最好,精度大幅度提高,这说明所建立小波神经网络预测模型隐含层节点数目 10 是适合的,并且拥有较好的收敛速度和精度。

小波神经网络训练过程中,传统小波神经网络(WNN)预测结果误差如图 3a 所示,使用遗传算法优化的小波神经网络(GAWNN)预测结果误差如图 3b 所示。从图 3a 中看出,WNN 网络在训练过程中,训练误差具有变化大、易波动等特点,使用遗传

算法优化后的 WNN 训练误差变化曲线平滑下降,而且收敛速度更快。

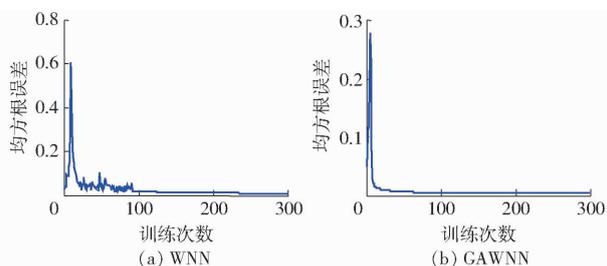


图 3 WNN 和 GAWNN 误差训练图

Fig.3 Training error graph of WNN and GAWNN

单独使用 ARIMA、WNN 模型、GAWNN 模型对溶解氧时间序列预测结果分别如图 4a ~ 4c 所示。两个组合模型 (ARIMA + WNN 和 ARIMA + GAWNN) 的预测结果如图 4d、4e 所示。本文使用预测结果的平均绝对误差、均方根误差和均方误差 3 个指标来评价每个模型的预测性能,误差越小,模型性能越好,模型精度如表 2 所示。

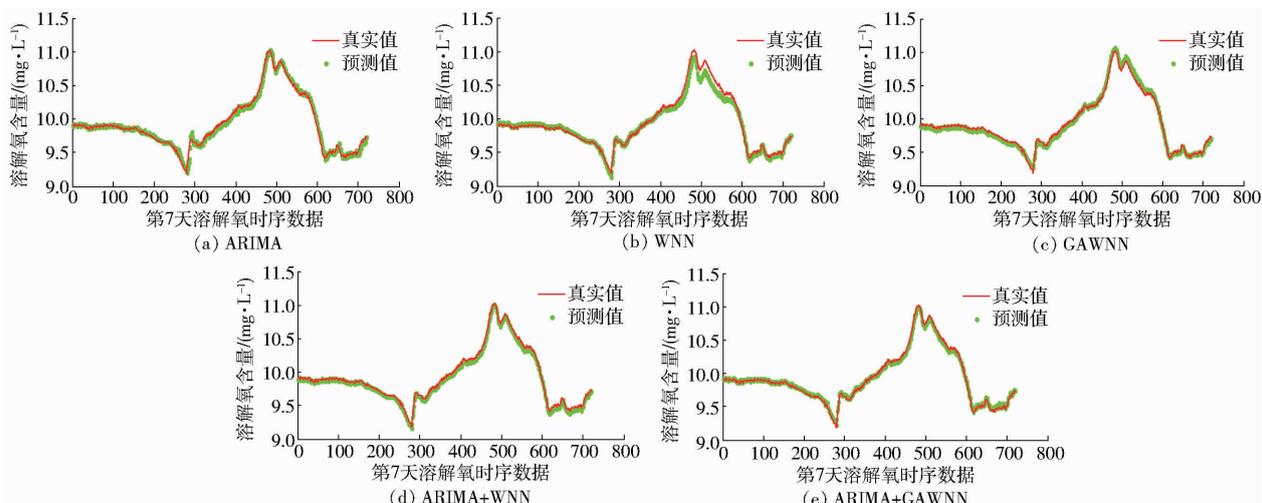


图 4 不同模型预测结果

Fig.4 Prediction result of different model

表2 模型精度
Tab.2 Model accuracy %

精度	ARIMA	WNN	GAWNN	ARIMA + WNN	ARIMA + GAWNN
MAE	0.29	0.39	0.26	0.24	0.19
RMSE	4.04	5.98	3.29	2.64	2.23
MSE	0.16	0.36	0.10	0.07	0.05

从表2可知,本文采用的ARIMA+GAWNN组合模型预测结果平均绝对误差、均方根误差、均方误差分别为0.19%、2.23%、0.05%,比单独的ARIMA模型、WNN和GAWNN预测结果都更精确;ARIMA模型和未经遗传算法优化的WNN组合模型平均绝对误差、均方根误差、均方误差分别为0.24%、2.64%、0.07%,误差结果均小于单独ARIMA模型和WNN。其中使用遗传算法优化的WNN预测效果优于WNN的预测效果。

针对河流污染治理和水源管理,本文使用

ARIMA模型与遗传算法优化的小波神经网络相结合的方法对水质参数溶解氧时间序列数据进行预测,为组合模型预测提供理论依据,本方法可扩展到其他水质参数时间序列数据的预测,例如氨氮浓度、总磷、总碳等。

3 结论

(1)遗传算法优化的小波神经网络比小波神经网络收敛更快,预测结果更准确;采用遗传算法优化小波神经网络能较好地克服梯度下降法参数初始值敏感和误差波动,获得全局最优的网络参数。

(2)神经网络预测模型隐含层数以及隐含层节点数目的确定可以通过定义所需要的层数节点数目进行训练,直到找到最佳隐含层数和隐层节点数目。

(3)组合模型可以很好地反映数据线性和非线性特征,优于使用单个模型预测的方法,具有良好的预测效果。

参 考 文 献

- 1 宋益春. 智能算法在水产养殖水质预测中的应用研究[D]. 无锡:江南大学, 2015.
- 2 CHEN K Y, WANG C H. A hybrid SARIMA and support vector machines in forecasting the production values of the machinery industry in Taiwan[J]. *Expert Systems with Applications*, 2007, 32: 254 - 264.
- 3 TSENG F M, YU H C, TZENG G H. Combining neural network model with seasonal time series ARIMA model[J]. *Technological Forecasting & Social Change*, 2002, 69(1): 71 - 87.
- 4 ZHOU Z J, HU C H. An effective hybrid approach based on grey and ARMA for forecasting gyro drift[J]. *Chaos, Solitons and Fractals*, 2008, 35(3): 525 - 529.
- 5 MEHDI K, MEHDI B. A novel hybridization of artificial neural networks and ARIMA models for time series forecasting[J]. *Applied Soft Computing*, 2011, 11(2): 2664 - 2675.
- 6 RATHNAYAKA R M K T, SENEVIRATNA D M K N, WEI Jianguo, et al. A hybrid statistical approach for stock market forecasting based on Artificial Neural Network and ARIMA time series models[C] // *IEEE Conference Publications. Behavioral, Economic and Socio-cultural Computing (BESC)*, 2015: 54 - 60.
- 7 ELJAZZAR M M, HEMAYED E E. Enhancing electric load forecasting of ARIMA and ANN using adaptive Fourier series[C] // *IEEE Conference Publications. 2017 IEEE 7th Annual Computing and Communication Workshop and Conference (CCWC)*, 2017: 1 - 7.
- 8 OZOZEN A, KAYAKUTLU G, KETTERER M, et al. A combined seasonal ARIMA and ANN model for improved results in electricity spot price forecasting: case study in Turkey[C] // *IEEE Conference Publications. Portland: Management of Engineering and Technology (PICMET)*, 2016: 2681 - 2690.
- 9 JIANG Ping, ZENG Zhigang, CHEN Jiejie, et al. Genetic algorithm based on wavelet neural network for the displacement prediction of landslide[C] // *IEEE Conference Publications. 2014 International Conference on Multisensor Fusion and Information Integration for Intelligent Systems (MFI)*, 2014: 1 - 5.
- 10 DENG Weihui, WANG Guoyin, ZHANG Xuerui, et al. Water quality prediction based on a novel hybrid model of ARIMA and RBF neural network[C] // *IEEE Conference Publications. 2014 IEEE 3rd International Conference on Cloud Computing and Intelligence Systems*, 2014: 33 - 40.
- 11 DENG Weihui, WANG Guoyin. A novel water quality data analysis framework based on time-series data mining[J]. *Journal of Environmental Management*, 2017, 196: 365 - 375.
- 12 WANG L, ZOU H, SU J, et al. An ARIMA-ANN hybrid model for time series forecasting[J]. *Systems Research and Behavioral Science*, 2013, 30(3): 244 - 259.
- 13 REN C X, WANG C B, YIN C C, et al. The prediction of short-term traffic flow based on the niche genetic algorithm and BP neural network[M]. Berlin: Springer, 2012: 775 - 781.
- 14 LI Peng, LIU Ming, ZHANG Xu, et al. Novel wavelet neural network algorithm for continuous and noninvasive dynamic estimation of blood pressure from photoplethysmography[J]. *Science China (Information Sciences)*, 2016, 59(4): 94 - 103.

- 7 MURPHY K, HERRY B, SULLIVAN T, et al. A low-cost autonomous optical sensor for water quality monitoring[J]. *Talanta*, 2015, 132:520 - 527.
- 8 纪莹蕾. 智能浊度传感器的研究与设计[D]. 合肥:中国科学技术大学,2014.
JI Yinglei. Research and design of intelligent turbidity sensor [D]. Hefei: University of Science and Technology of China, 2014. (in Chinese)
- 9 陈超. 面向鱼塘浊度检测的 WSN 节点关键技术研究[D]. 镇江:江苏大学,2014.
CHEN Chao. Key technologies of WSN node for fishpond turbidity detection [D]. Zhenjiang: Jiangsu University, 2014. (in Chinese)
- 10 JOHN F O, SMART C C. An inexpensive turbid meter for monitoring suspended sediment[J]. *Geomorphology*, 2005, 68(1 - 2):3 - 15.
- 11 GREGORY J. Monitoring particle aggregation processes[J]. *Advances in Colloid and Interface Science*, 2009,147 - 148:109 - 123.
- 12 吴刚,刘月明. 光纤水质传感器的研究现状和发展趋势[J]. *传感器与微系统*, 2013(12):3 - 8.
WU Gang, LIU Yueming. Research status and development trend of optical fiber water sensors[J]. *Sensors and Microsystems*, 2013(12):3 - 8. (in Chinese)
- 13 KUMAR A, SRIVASTAVA V, SINGH M K, et al. Current status of the IEEE 1451 standard-based sensor applications[J]. *IEEE Sensors Journal*, 2015, 15(5):2505 - 2513.
- 14 张瑞周,邵雪,鹿训练. 循环水浊度的控制方法[J]. *山东化工*,2016,45(13):199 - 200.
ZHANG Ruizhou, SHAO Xue, LU Xunlian. Turbidity control method in circulating water[J]. *Shandong Chemical Industry*, 2016,45(13):199 - 200. (in Chinese)
- 15 杨春曦,胡中功. 光纤传感器的应用及发展[J]. *武汉化工学院学报*, 2004(2):26 - 31.
YANG Chunxi, HU Zhonggong. Application and development of optical fiber sensor [J]. *Journal of Wuhan Institute of Chemical Technology*, 2004(2):26 - 31. (in Chinese)
- 16 DIAS PEREIAL M, POSTOLACHE O, SILVA GIRAO P, et al. SDI - 12 based turbidity measurement system with field calibration capability[C]//CCECE, Niagara Falls, 2004:1975 - 1979.
- 17 OCTAVIAN P, DIDAS PEREIRA J M, SILVA GIRAO P, et al. Smart flexible turbidity sensing based on embedded neural network[C]//IEEE SENSORS 2006, October 22 - 25:658 - 660.
- 18 OCTAVIAN P, SILVA GIRAO P, DIDAS PEREIRA J M, et al. Multibeamoptical system and neural processing for turbidity measurement[J]. *IEEE Sensors Journal*,2007,7(5):677 - 684.
- 19 ANTONIO G, MIGUEL A P, GUSTANO J G O, et al. A new design of low-cost four-beam turbidimete by using optical fibers [J]. *IEEE Transactions on Instrumentation and Measurement*, 2007, 56(3):907 - 911.
- 20 余名,唐云建. 浊度传感器的标定方法研究[J]. *自动化与仪器仪表*,2016(2):20 - 21.
YU Ming, TANG Yunjian. Study on calibration method of turbidity sensor [J]. *Automation and Instrumentation*, 2016(2):20 - 21. (in Chinese)

(上接第 210 页)

- 15 LI Baojian, CHENG Chuntian. Monthly discharge forecasting using wavelet neural networks with extreme learning machine[J]. *Science China (Technological Sciences)*,2014,57(12):2441 - 2452.
- 16 成云,成孝刚,谈苗苗,等. 基于 ARIMA 和小波神经网络组合模型的交通流预测[J]. *计算机技术与发展*,2017, 27(1):169 - 172.
CHEN Yun, CHEN Xiaogang, TAN Miaomiao, et al. Traffic flow prediction based on hybrid model of ARIMA and WNN [J]. *Computer Technology and Development*,2017, 27(1):169 - 172. (in Chinese)
- 17 JIA J. Financial time series prediction based on BP neural net-work[J]. *Applied Mechanics and Materials*,2014,631 - 632:31 - 34.
- 18 毛海颖,冯仲科,巩垠熙,等. 多光谱遥感技术结合遗传算法对永定河土壤归一化水体指数的研究[J]. *光谱学与光谱分析*,2014, 34(6):1649 - 1655.
MAO Haiying, FENG Zhongke, GONG Yinxi, et al. Researches of soil normalized difference water index (NDWI) of Yongding river based on multispectral remote sensing technology combined with genetic algorithm[J]. *Spectroscopy and Spectral Analysis* [J],2014, 34(6):1649 - 1655. (in Chinese)
- 19 胡瑾,何东健,任静,等. 基于遗传算法的番茄幼苗光合作用优化调控模型[J]. *农业工程学报*, 2014, 30(17):220 - 227.
HU Jin, HE Dongjian, REN Jing, et al. Optimal regulation model of tomato seedlings' photosynthesis based on genetic algorithm [J]. *Transactions of the CSAE*, 2014, 30(17):220 - 227. (in Chinese)
- 20 KONG Haipeng, LI Ni, SHEN Yuzhong. Adaptive double chain quantum genetic algorithm for constrained optimization problems [J]. *Chinese Journal of Aeronautics*,2015,28(1):214 - 228.
- 21 HUA Haiyan, LIN Shuwen. New knowledge-based genetic algorithm for excavator boom structural optimization[J]. *Chinese Journal of Mechanical Engineering*,2014,27(2):392 - 401.