



文章栏目: 水污染防治

DOI 10.12030/j.cjee.201906005

中图分类号 X506

文献标识码 A

王飞, 卿晓霞, 温馨. 基于多级神经网络模型的厌氧氨氧化系统参数预测[J]. 环境工程学报, 2020, 14(3): 681-690.

WANG Fei, QING Xiaoxia, WEN Xin. Parameter prediction of anaerobic ammonium oxidation system based on multi-level neural network model[J]. Chinese Journal of Environmental Engineering, 2020, 14(3): 681-690.

# 基于多级神经网络模型的厌氧氨氧化系统参数预测

王飞<sup>1</sup>, 卿晓霞<sup>1,\*</sup>, 温馨<sup>2</sup>

1. 重庆大学环境与生态学院, 重庆 400045

2. 重庆科技学院建筑工程学院, 重庆 401331

第一作者: 王飞(1995—), 男, 硕士研究生。研究方向: 水处理自动控制。E-mail: wangfe186@126.com

\*通信作者: 卿晓霞(1963—), 女, 博士, 教授。研究方向: 水处理自动控制。E-mail: qxx118@126.com

**摘要** 厌氧氨氧化菌生长条件复杂、影响因素多, 其工艺系统运行控制复杂, 为解决上述问题, 研究构建了 1 个多级神经网络预测模型, 以提高 SBBR 单级自养脱氮厌氧氨氧化系统出水总氮去除率预测精度, 并确定了系统工程应用的关键控制参数。一级神经网络模型通过灰色关联度分析, 对影响出水总氮去除率的关键性指标进行预测; 二级神经网络模型基于一级模型增加数据维度, 并通过改进粒子群算法优化网络、借鉴遗传算法变异的思想扩大搜索范围, 提高了出水总氮去除率的预测精度。多级神经网络模型预测结果表明, 其总氮去除率平均相对误差为 0.54%, 相对误差为 5.76%, 均方根误差为 1.132 1, 预测数据基本上与实际值相符; 与其他预测模型相比较, 该模型表现出较优的预测精度。进一步分析发现, 通过控制工艺系统的曝气量调节出水亚氮浓度, 是保证工艺反应的稳定和实现厌氧氨氧化工艺工程应用的有效控制方式。

**关键词** 人工神经网络; 模拟预测; 改进粒子群算法; 厌氧氨氧化

厌氧氨氧化反应是厌氧氨氧化菌在厌氧或缺氧条件下, 利用  $\text{CO}_2$  或  $\text{H}_2\text{CO}_3$  等无机碳源, 以  $\text{NO}_2^-$  为电子受体, 直接将  $\text{NH}_4^+$  还原为  $\text{N}_2$  排放到大气中的新型脱氮工艺<sup>[1]</sup>, 具有工艺流程短、脱氮效率高、需氧量少、几乎不产生污泥、不产生二次污染等优点<sup>[2-3]</sup>。在当今许多污水处理系统工艺复杂、能耗高、产泥量大的背景下, 实现厌氧氨氧化工艺的工程应用显得尤为重要。然而, 由于厌氧氨氧化过程苛刻的工艺条件和复杂的影响因素<sup>[4]</sup>, 使其对工艺过程控制的要求高, 且难以确定关键运行控制参数。通过建立厌氧氨氧化工艺系统水质预测模型, 可以掌握该工艺系统的运行规律, 反映其运行状态, 对明确厌氧氨氧化工艺过程的关键控制参数, 实现工艺过程的工程应用具有重要意义。

与所有污水处理工艺一样, 厌氧氨氧化属于复杂的生化反应过程, 具有非线性、时变性和大时滞的特点<sup>[5]</sup>, 难以建立精确的数学模型。目前, 用于水质预测的数学模型主要有多元线性回归模

收稿日期: 2019-06-01; 录用日期: 2019-09-05

基金项目: 国家重点研发计划项目(2017YFC0404704); 重庆市技术创新与应用示范专项重点研发项目(cstc2018jszx-zdyfxmX0010)

型、灰色预测模型、支持向量机、神经网络模型等。多元线性回归模型因其算法精度低、智能化程度弱,达不到很好的预测效果<sup>[6]</sup>;灰色预测模型因其不考虑系统的内在机理,在作较长时间预测时往往精度不高<sup>[7]</sup>;虽然支持向量机模型算法在处理小样本预测方面较有优势,但基于小样本的学习随机性较强,易忽略数据样本的关键信息,且模型运行时间较神经网络长<sup>[8]</sup>。有研究<sup>[9-11]</sup>表明,BP神经网络是解决非线性、大时变系统的分析、预测及建模问题的有效工具,具有智能化程度高、仿真能力强的优势,但也存在易收敛至局部极值点的缺陷,须辅助其他优化模型以改善其性能。常用的解决方法是对神经网络模型各层之间的权重和阈值进行优化,如BAGHERI等<sup>[12]</sup>利用遗传算法(genetic algorithm, GA)优化人工神经网络,对神经网络的权值、阈值所组成的种群随机搜索并进行选择、交叉、变异等数值计算,成功实现了对活性污泥膨胀的预测。但GA计算复杂,容易陷入“早熟”,近年来,粒子群算法(particle swarm optimization, PSO)因其算法简单、参数少、求解速度快、通用性强等优点而备受人们关注。粒子群中的每一个粒子都代表一个问题的可能解,通过粒子个体的简单行为、群体内的信息交互可实现问题的求解,常用于智能系统模型的优化。但PSO也存在着搜索精度较低、后期迭代效率不高等不足<sup>[13]</sup>。

厌氧氨氧化工艺的优势在于其较高的脱氮效率,总氮去除率是评判工艺水平和运行水平的重要指标之一<sup>[14]</sup>。为确定厌氧氨氧化工艺工程应用的关键运行控制参数,本研究以SBBR单级自养脱氮厌氧氨氧化工艺系统为研究对象,以出水总氮去除率为目标,建立了基于BP神经网络的多级预测模型。其中:一级模型通过灰色关联度分析,对影响出水总氮去除率的关键性指标进行了预测;二级模型在基于一级模型上增加数据维度,并通过改进粒子群算法优化人工神经网络、借鉴遗传算法变异的思想扩大搜索范围,提高出水总氮去除率的预测精度。通过模型预测和结果分析,明确了厌氧氨氧化工艺系统运行的关键控制参数,为工艺过程的优化与进一步工程应用提供参考。

## 1 材料与方法

### 1.1 实验装置

实验采用的工艺装置由SBBR及其附属的水箱、蠕动泵、空气泵、转子流量计及在线检测仪表组成,如图1所示。其中,SBBR是由树脂不透光材料制成的圆柱形反应器,内径20 cm、高度50 cm,有效容积为10 L,内填充组合材料,以适应微生物的附着和生长,填充比为50%。

### 1.2 人工合成污水

实验采用人工合成污水,通过向自来水中投加适量 $\text{NH}_4\text{HCO}_3$ 以配制不同氨氮浓度的进水。水中其他组分如下:葡萄糖适量; $\text{KH}_2\text{PO}_4$ 为 $25\text{ mg}\cdot\text{L}^{-1}$ ; $\text{FeSO}_4$ 为 $6.25\text{ mg}\cdot\text{L}^{-1}$ ; $\text{MgSO}_4\cdot 7\text{H}_2\text{O}$ 为 $100\text{ mg}\cdot\text{L}^{-1}$ ; $\text{CaCl}_2$ 为 $150\text{ mg}\cdot\text{L}^{-1}$ ; $\text{EDTA}$ 为 $25\text{ mg}\cdot\text{L}^{-1}$ ;pH为 $7.8\pm 0.2$ 。考虑到微生物生长需要,配水中添加了微量元素。

### 1.3 实验方法及构建过程

接种污泥采用污水厂脱水剩余污泥,通过设置不同的换水比0.5、0.25、0.12,实现反应器在不同进水氮负荷(分别为 $0.2$ 、 $0.1$ 、 $0.05\text{ kg}\cdot(\text{m}^3\cdot\text{d})^{-1}$ )条件下的构建与运行。反应器通过蠕动泵控制

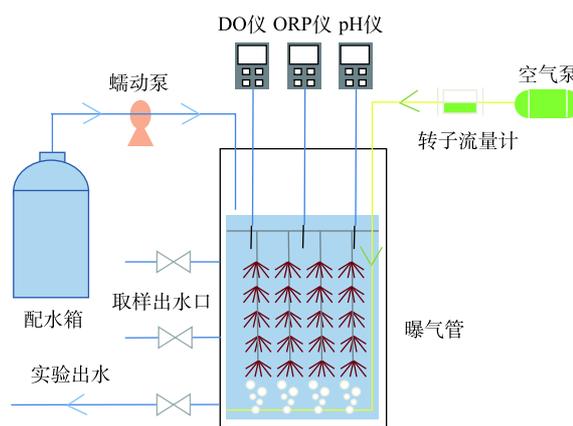


图1 实验装置示意图

Fig. 1 Schematic diagram of experimental device

进水，电磁阀控制出水，通过空气泵及转子流量计调节系统中的溶解氧含量，并配备加热棒以维持反应器温度。反应周期为12 h，采用序批式运行方式，具体运行工况为进水→曝气→排水。实验过程中，每天收集反应器进、出水水样，并测定水质指标。反应器配备DO仪、pH仪及ORP仪，随时监测运行状况。在系统构建过程中，前5~7 d为适应期，污泥中的微生物逐渐恢复活性；之后系统内出现亚氮积累现象，氨氮去除率上升，而总氮去除率保持稳定，即系统发生了短程硝化作用；通过调节曝气量控制出水，60 d后，亚氮积累现象消失，出水亚氮浓度明显下降，总氮去除率升高，推测此时系统内总氮的损失原因在于厌氧氨氧化菌的富集；68 d后，系统出水趋于稳定，硝氮为主要的出水氮形态；90 d后，系统稳定运行。研究采用16S rRNA序列分析测试方法对所构建的系统中微生物群落特征进行了探讨分析。16S rRNA分析测试按样品的选取、Illumina平台测序、样品的检测分析3个步骤进行，分析结果显示，在属水平上样品中存在优势微生物主要包括：*Anaerolineaceae\_uncultured*、*Haliangium*、*Bacillus*、*Bdellovibrio*、*Caldilineaceae\_uncultured*、*Ignavibacterium*、*Lactococcus*、*Nitrosomonas*、TK10\_norank、*Candidatus Brocadia*，分别占样品总序列数的7.4%、0.4%、0.6%、0.2%、1.0%、4.3%、3.6%、5.2%、3.2%和22.3%。系统中*Nitrosomonas*属于亚硝化菌，负责将氨氮转化为亚氮供厌氧氨氧化菌等利用；分析表明，厌氧氨氧化菌*Candidatus Brocadia*属在系统中占绝对优势，表明系统构建成功。

## 2 人工神经网络多级预测模型

近年来，人工神经网络因其较强的自适应性和学习能力，广泛应用于复杂系统的建模和智能模拟。通常，为降低人工神经网络模型的复杂度，提高运算速度，人们通常须采用聚类分析<sup>[15]</sup>、主成分分析<sup>[16]</sup>、灰色关联分析<sup>[17]</sup>等数学方法对数据进行降维处理。然而，对厌氧氨氧化工艺而言，由于Anammox生长条件复杂、影响因素众多，盲目地数据降维必然造成有效信息的缺失，不可避免会导致模型精度的降低。为尽可能保持信息的全面性，本研究通过大量实验计算，提出适当增加数据维度以捕获工艺系统关键信息的模型构建新思路，并通过改进算法进一步优化人工神经网络的结构参数，以提高预测精度。为此，本研究提出一种厌氧氨氧化系统出水总氮去除率多级预测模型，第1级模型采用BP神经网络对影响工艺过程的关键参数进行预测，增加二级模型的输入数据维度，以保证厌氧氨氧化反应信息的全面性；第2级预测模型基于改进的粒子群算法优化神经网络，克服BP神经网络易收敛至局部极值点的缺陷，以提高出水总氮去除率的预测精度。

### 2.1 数据采集与处理

实验装置构建完成后，反应器稳定运行。通过改变进水条件进行实验和数据采集，每组数据包含温度、溶解氧、进水氨氮、出水氨氮、出水亚氮、出水硝氮等6个参数，并计算总氮去除率。剔除异常数据后部分实验数据如表1所示。为避免各维数据之间数量级差异带来的误差，数据采集完成后需要对实验数据进行归一化处理。

### 2.2 一级预测模型

1) 预测变量的选取。为确定预测变量，首先计算各影响因素对出水总氮去除率的灰色关联度<sup>[18]</sup>。灰色关联度分析方法根据序列曲线几何形状的相似度来判断其关联程度的大小，曲线越相似，相应序列的关联度就越大，反之则越小。首先，对数据进行处理，设处理后的参考序列 $X_0=\{x_0(k),k=1,2,\dots,n\}$ ，比较序列 $X_i=\{x_i(k),k=1,2,\dots,n\}$ ，一般选择因变量为参考序列，自变量为比较序列；按式(1)计算 $X_0$ 与 $X_i$ 在 $k$ 点的关联系数值。

$$\eta_i(k) = \frac{\min_i \min_k |x_i(k) - x_0(k)| + \rho \max_i \max_k |x_i(k) - x_0(k)|}{|x_i(k) - x_0(k)| + \rho \max_i \max_k |x_i(k) - x_0(k)|} \quad (1)$$

表1 部分实验数据  
Table 1 Partial experimental data

序号	进水氨氮/(mg·L <sup>-1</sup> )	溶解氧/(mg·L <sup>-1</sup> )	温度/°C	出水氨氮/(mg·L <sup>-1</sup> )	出水硝氮/(mg·L <sup>-1</sup> )	出水亚氮/(mg·L <sup>-1</sup> )	总氮去除率/%
1	200	0.98	31	18.83	26.75	0.24	77.09
2	200	0.48	30.9	21.25	26.00	0.31	76.22
3	200	0.77	31.2	1.61	43.66	0.24	77.24
4	200	0.89	30.8	34.70	14.87	0.29	75.07
5	200	0.54	31.1	41.96	15.62	0.29	71.06
6	200	1.11	29.2	23.13	16.91	0.18	79.89
7	185	0.7	30.5	33.89	11.88	0.26	75.12
8	173	0.56	32.1	18.56	32.64	0.21	70.29
9	173	0.88	32.3	6.19	33.28	0.23	77.06
10	100	1.4	30.8	4.84	22.79	0.16	72.21
11	100	1.05	30.3	9.15	20.22	0.16	70.55
12	185	1.09	31.1	25.29	8.35	0.28	81.67
13	173	0.77	32.3	9.15	35.10	0.26	74.28
14	100	1.6	29.5	0.00	22.47	0.11	77.42
15	86	1.35	31.7	12.37	4.28	0.16	80.45

式中： $\eta_i(k)$ 为比较序列与参考序列在 $k$ 点的关联系数值； $\rho$ 为分辨系数， $\rho$ 越小，分辨力越大，本研究取值为0.2； $\min_k |x_i(k) - x_0(k)|$ 为对于第 $i$ 项影响因素 $|x_i(k) - x_0(k)|$ 的最小值； $\max_k |x_i(k) - x_0(k)|$ 为对于第 $i$ 项影响因素 $|x_i(k) - x_0(k)|$ 的最大值。

最后，通过求比较序列与参考序列的关联系数的均值，来定量描述两者的关联度，如式(2)所示。

$$\lambda_i = \frac{1}{n} \sum_{k=1}^n \eta_i(k) \quad (2)$$

式中： $\lambda_i$ 为比较序列与参考序列之间的关联度值， $n$ 为影响因素数量。

比较序列与参考序列的关联度计算结果如下：进水氨氮为0.3565，溶解氧为0.4749，温度为0.4729，出水氨氮为0.4344，出水硝氮为0.4770，出水亚氮为0.4778。出水亚氮浓度是关联度最大的因素，是厌氧氨氧化反应的关键性指标。如果预测模型存在易被忽略的环境因素将使得模型存在系统性误差。出水亚氮浓度带有反应过程环境因素的影响成分<sup>[19]</sup>，将其作为出水总氮去除率预测模型的输入变量可避免此类误差的产生。

DECANETE等<sup>[20]</sup>和LACKNER等<sup>[21]</sup>的研究结果也表明，亚氮是厌氧氨氧化工艺必要的底物，但其过高的浓度也会对反应产生消极影响。为此，研究将出水亚氮浓度作为一级预测模型的预测变量。

2) BP神经网络模型。BP神经网络是一种多层前馈网络，由输入层、隐含层和输出层组成。BP神经网络的主要特点是信号前向传递，误差反向传播，并以均方误差最小化为目标，通过不断修改网络的权值和阈值达到拟合非线性、不确定性数学模型的目的，被证明是解决非线性、大时变系统的分析、预测、控制与建模问题的有效工具。本研究设计的一级预测模型拓扑结构为3-11-1。其输入变量为进水氨氮、溶解氧、温度，输出变量为出水亚氮浓度。通过试凑法确定隐含层神经元个数为11。

### 2.3 二级预测模型

二级预测模型仍采用 BP 神经网络，输入变量升维为 4 个，即进水氨氮、溶解氧含量、温度以及一级预测模型的输出变量出水亚氮，输出变量为出水总氮去除率。同样采用试凑法确定隐含层神经元个数为 11 个，构成拓扑结构为 4-11-1 的神经网络。多级神经网络模型结构如图 2 所示。

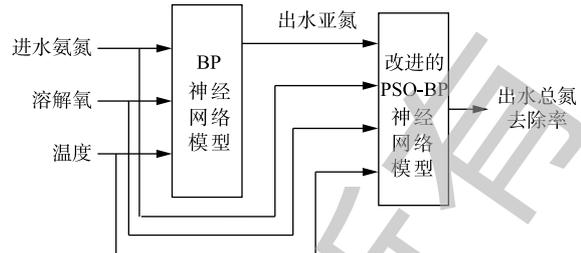


图 2 多级神经网络模型结构图

Fig. 2 Multilevel neural network model structure

由于二级预测模型是对系统总氮去除率进行预测，提高预测精度是二级预测模型设计应考虑的关键要素。为避免 BP 网络易收敛至局部极值造成的预测误差，研究了采用改进的 PSO 算法改善网络的性能。

1) PSO 算法及改进。假设在一个  $Z$  维的搜索空间中，有  $n$  个粒子组成的种群  $X=(X_1, X_2, \dots, X_n)$ ，其中第  $i$  个粒子在  $Z$  维搜索空间中的位置表示为一个  $Z$  维的向量  $X_i=[x_{i1}, x_{i2}, \dots, x_{iZ}]^T$ ，同时也是问题的一个潜在解；速度表示为  $V_i=[V_{i1}, V_{i2}, \dots, V_{iZ}]^T$ ，决定了粒子的搜索距离和方向。根据目标函数可计算出每个粒子的位置  $X_i$  对应的适应度值，其个体极值为  $P_i=[P_{i1}, P_{i2}, \dots, P_{iZ}]^T$ ，种群的全局极值为  $P_g=[P_{g1}, P_{g2}, \dots, P_{gZ}]^T$ 。

PSO 算法<sup>[22]</sup>在每一次迭代过程中，粒子通过个体极值和全局极值更新自身的速度和位置，如式 (3) 和式 (4) 所示。

$$V_{iz}^{k+1} = \omega V_{iz}^k + c_1 r_1 (P_{iz}^k - X_{iz}^k) + c_2 r_2 (P_{gz}^k - X_{iz}^k) \quad (3)$$

$$X_{iz}^{k+1} = X_{iz}^k + V_{iz}^{k+1} \quad (4)$$

式中： $\omega$  为惯性权重； $c_1$  和  $c_2$  为非负的常数，称为学习因子； $r_1$  和  $r_2$  为分布于  $[0,1]$  之间的随机数； $V_{iz}^k$  为迭代  $k$  次时粒子的速度； $X_{iz}^k$  为迭代  $k$  次时粒子的位置。为了防止盲目搜索，一般建议限制其位置和速度分别在  $[-X_{\max}, X_{\max}]$ 、 $[-V_{\max}, V_{\max}]$  区间内。

有研究<sup>[22]</sup>发现，通过不断更新 PSO 算法的惯性权重因子、学习因子，以确定其合理值，这样有助于促进粒子的收敛性。为了平衡 PSO 算法的全局搜索能力和局部改良能力，本研究采用非线性的动态惯性权重，如式 (5) 所示。

$$\omega = \begin{cases} \omega_{\min} + \frac{(\omega_{\max} - \omega_{\min}) \cdot (\theta - \theta_{\min})}{\theta_a - \theta_{\min}}, & \theta \leq \theta_a \\ \omega_{\max}, & \theta > \theta_a \end{cases} \quad (5)$$

式中： $\omega_{\max}$ 、 $\omega_{\min}$  分别为惯性权重因子  $\omega$  的最大值和最小值； $\theta$  为粒子的当前适应度值； $\theta_{\min}$  为当前所有粒子的适应度最小值，即此刻的全局最优值； $\theta_a$  为当前所有粒子的适应度平均值。

在优化过程中，采用异步变化的方式确定学习因子。在优化初始阶段，通过参数设定，使得粒子具有较大的自我学习能力和较小的社会学习能力，加强全局搜索能力；在优化后期，粒子具有较大的社会学习能力和较小的自我学习能力，有利于收敛至全局最优解，其更新公式如式 (6) 和式 (7) 所示。

$$c_1 = c_{1,\text{ini}} + \frac{c_{1,\text{fin}} - c_{1,\text{ini}}}{t_{\max}} \cdot t \quad (6)$$

$$c_2 = c_{2,\text{ini}} + \frac{c_{2,\text{fin}} - c_{2,\text{ini}}}{t_{\max}} \cdot t \quad (7)$$

式中： $c_{1,\text{ini}}$ 、 $c_{2,\text{ini}}$  分别为  $c_1$ 、 $c_2$  的初始值，分别设定为 2.5、0.5； $c_{1,\text{fin}}$ 、 $c_{2,\text{fin}}$  分别为  $c_1$ 、 $c_2$  的迭代终值，分别设定为 0.5、2.5； $t$  为当前迭代次数； $t_{\max}$  为最大迭代次数。

标准的 PSO 算法收敛快, 具有很强的通用性, 但也存在易早熟收敛、搜索精度较低、后期迭代效率不高等缺点。为此, 本研究借鉴遗传算法变异的思想, 在标准 PSO 算法中, 引入自适应变异操作, 即在每一次迭代过程中对某些变量以一定的概率重新初始化, 既保证粒子有一定的变异率, 又使得其搜索范围不局限于逐渐变小的搜索空间内。

在每一次迭代寻优过程中, 都需要计算粒子的适应度值, 其适应度函数如式 (8) 所示。

$$\theta(i) = \sum_{j=1}^n \sum_{k=1}^m |y_{jk}(i) - o_{jk}(i)| \quad (8)$$

式中:  $\theta(i)$  为粒子的适应度值;  $y_{jk}(i)$  为训练输出期望值;  $o_{jk}(i)$  为训练输出值。

2) 改进的 PSO-BP 预测模型。首先, 随机初始化 BP 神经网络的输入层与隐含层连接权值、隐含层神经元阈值、隐含层与输出层连接权值以及输出层神经元阈值, 构成 PSO 算法中各微粒的位置和速度。其次, 采用改进的 PSO 算法优化微粒的位置和速度, 并将满足适应度函数要求的粒子作为最优解输出, 从而确定出一个结构、权值、阈值确定的神经网络。然后, 运用测量的历史数据训练神经网络, 使其误差达到性能要求。训练误差函数如式 (9) 所示。

$$E_{\text{mse}} = \frac{1}{N} \sum_{i=1}^N (u_i - v_i)^2 \quad (9)$$

式中:  $E_{\text{mse}}$  为模型训练误差;  $u_i$  为出水总氮去除率预测值;  $v_i$  为出水总氮去除率期望值;  $N$  为训练样本数量。

最后, 将一级预测模型的预测结果与进水氨氮、溶解氧浓度及温度共 3 个输入变量一同导入改进型 PSO-BP 神经网络进行计算。多级神经网络预测算法流程图如图 3 所示。

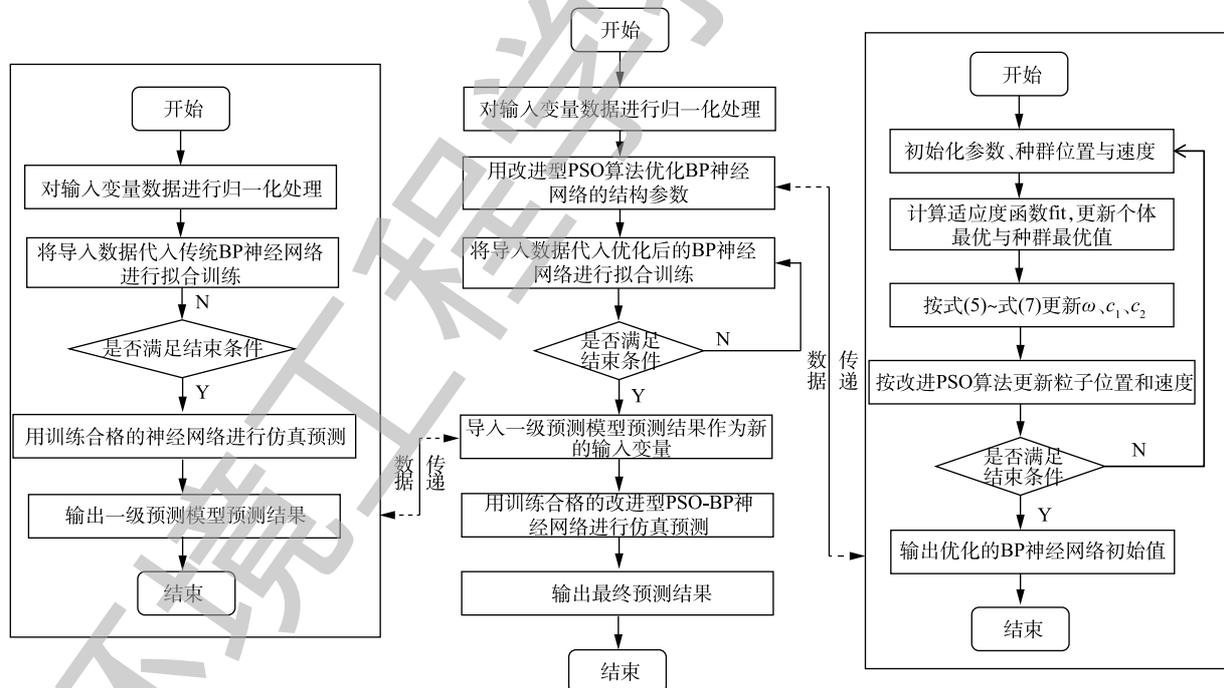


图 3 多级神经网络预测算法流程

Fig. 3 Flow chart of multi-Level neural network prediction algorithm

### 3 预测模拟

#### 3.1 模拟过程

选取实验过程获取的 100 组数据中的 85 组用于模型训练, 另外 15 组进行模型预测。模拟平台

基于 Matlab 2017a, 训练误差为 0.000 1。二级预测模型中人工神经网络的权值及阈值通过粒子群算法确定, 种群粒子数为 40, 每个粒子的维度为 67, 算法迭代进化次数为 100。

改进的 PSO 算法粒子最优适应度曲线如图 4 所示, 由图 4 可知, 改进算法收敛速度较快, 优化精度高。网络性能评价函数包括平均绝对百分比误差  $E_{\text{mape}}$ 、均方根误差  $E_{\text{rmse}}$ 、最大绝对百分比误差  $E_{\text{re}}$ , 具体计算方法如式 (10)、式 (11) 和式 (12) 所示。

$$E_{\text{mape}} = \sum_{i=1}^N \left| \frac{u_i - v_i}{v_i} \right| \cdot \frac{1}{N} \times 100\% \quad (10)$$

$$E_{\text{rmse}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (u_i - v_i)^2} \quad (11)$$

$$E_{\text{re}} = \max_i |u_i - v_i| \quad (12)$$

### 3.2 结果与讨论

将进水氨氮浓度、溶解氧浓度、温度 3 个指标导入一级网络模型, 得到出水亚氮的预测结果 (如图 5 所示)。最大绝对误差为 0.039  $\text{mg} \cdot \text{L}^{-1}$ , 最大相对误差为 15.99%, 平均相对误差为 8.24%。

将一级模型预测的出水亚氮浓度同进水氨氮、溶解氧浓度及温度 3 个参数导入第 2 级预测模型, 对出水总氮去除率进行预测。为验证所提出的多级预测模型精度, 本研究将其预测结果与采用传统 BP 神经网络、遗传算法优化的 BP 神经网络 (GA-BP) 以及用标准粒子群算法优化的 BP 神经网络 (PSO-BP) 等 3 个模型的预测结果进行了对比, 结果如图 6 所示。

模型的预测性能误差按式 (8) 和式 (9) 计算, 得到各模型的性能误差计算结果 (如表 2 所示)。由表 2 可知, 多级预测模型出水总氮去除率的平均相对误差为 0.54%, 比传统 BP 神经网络模型、GA-BP 模型、PSO-BP 模型分别提高 6.33%、4.06% 和 3.89%; 预测出水总氮去除率的相对误差为 5.76%, 均方根误差为 1.132 1。预测数据基本与实际值相匹配, 说明该模型具有较优的预测精度。

分析发现, 本多级神经网络预测模型除采用改进的 PSO 算法和遗传算法变异的思想以提高第 2 级神经网络的算法精度外, 预测精度得以提高的另一个关键因素在于第 1 级预测模型对亚氮浓度的预测。对于单级自养脱氮系统的自动控制系统设计而言, 一方面对出水亚氮浓度的控制需要通过曝气量的控制来实现, 从氨氮到亚氮的过程, 须包含曝气的短程硝化过程, 故出水亚氮浓度很大程度上取决于系统曝气量的控制<sup>[23]</sup>; 另一方面, 系统中的溶解氧浓度影响厌氧氨氧化菌的生长<sup>[21]</sup>, 曝气量是此系统实现厌氧氨氧化工艺自动控制的关键控制参数。因此, 通过控制工艺系统的曝气量调节系统的出水亚氮浓度, 进而保证工艺反应的稳定进行, 是实现厌氧氨氧化工艺工程应用的有效控制方式。

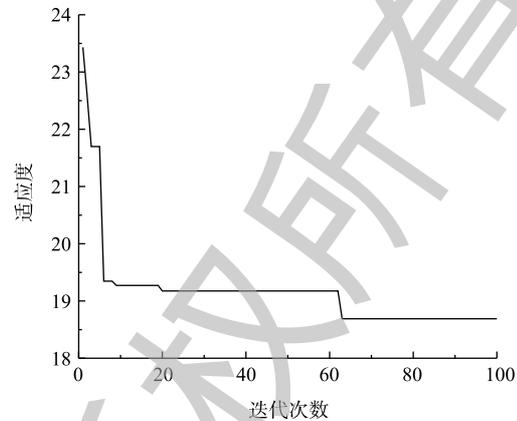


图 4 改进 PSO 算法最优适应度曲线

Fig. 4 Optimal fitness curve of improved PSO algorithm

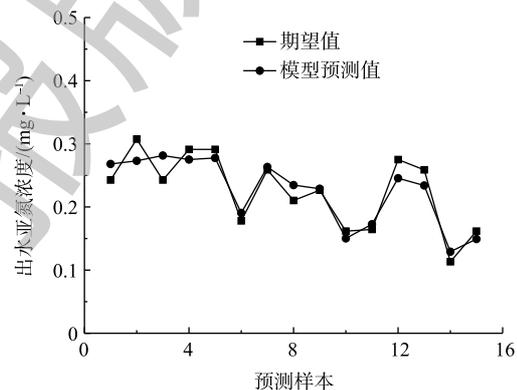


图 5 一级预测模型预测结果

Fig. 5 Prediction results based on the first-level prediction model

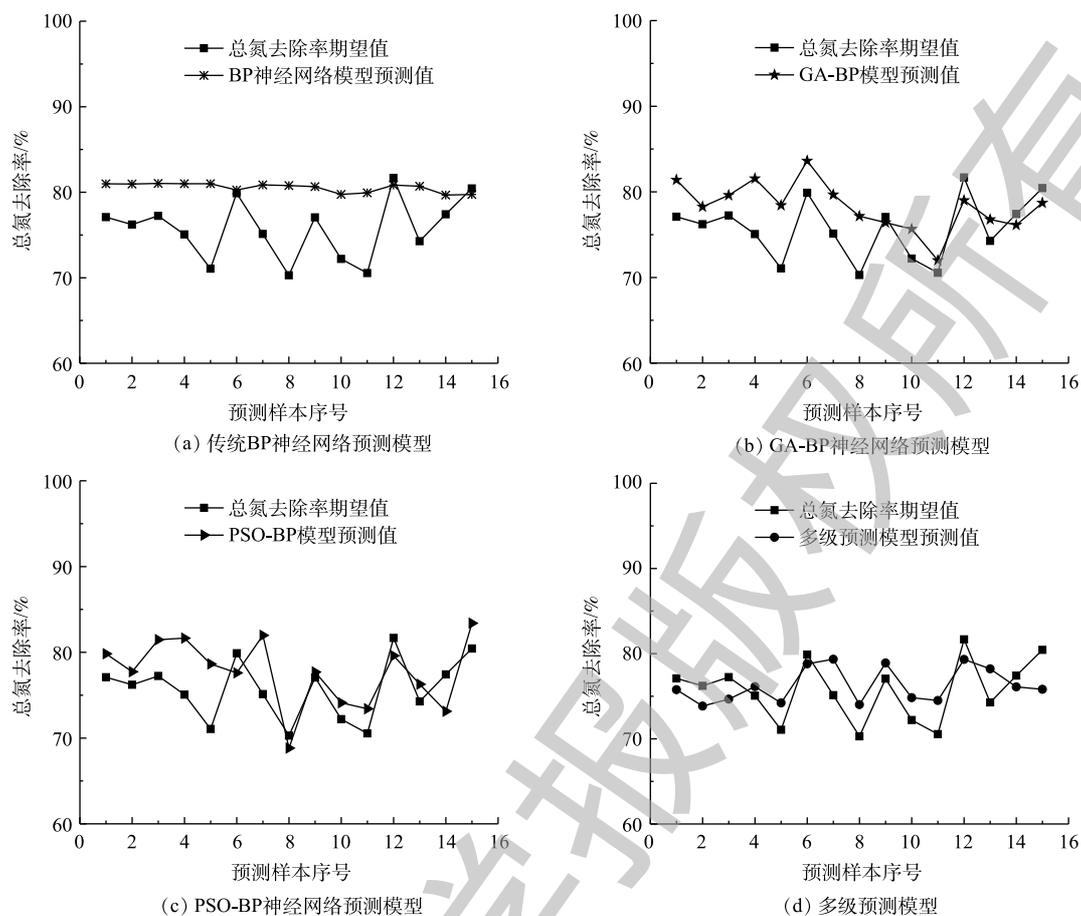


图6 各模型对总氮去除率预测结果

Fig. 6 TN removal rate prediction results of each model

#### 4 结论

1) 采用灰色关联度分析法得到出水亚氮浓度对出水总氮去除率的关联度为0.4778, 在各影响因素中最大, 提出构建多级预测模型, 一级预测模型采用BP神经网络对出水亚氮浓度进行预测, 增加二级预测模型的输入数据维度, 以捕获工艺系统的关键信息, 避免系统误差的产生; 二级预测模型对出水总氮去除率进行预测。

2) 二级预测模型采用改进的PSO算法, 通过不断更新PSO算法的惯性权重因子、学习因子优化神经网络以提高算法的精度, 并借鉴遗传算法中变异的思想扩大搜索范围。预测结果显示, 多级预测模型预测总氮去除率平均相对误差为0.54%, 比传统BP神经网络模型、GA-BP模型、PSO-BP模型分别提高6.33%、4.06%和3.89%; 相对误差为5.76%, 均方根误差为1.1321。预测数据基本上与实际值相匹配, 说明多级预测模型具有较优的预测精度。

3) 控制反应过程中亚氮浓度是提高厌氧氨氧化工艺总氮去除率的关键因素之一, 曝气量是厌氧氨氧化工艺的关键控制参数。因此通过控制工艺系统的曝气量调节出水亚氮浓度, 是保证工艺反应的稳定和实现厌氧氨氧化工艺工程应用的有效控制方式。

表2 各模型性能误差

Table 2 Performance error of each model

模型	$E_{\text{mape}}/\%$	$E_{\text{rmse}}$	$E_{\text{re}}/\%$
BP	6.87	5.970 1	14.94
GA-BP	4.60	3.991 4	10.37
PSO-BP	4.43	3.920 7	10.67
多级预测模型	0.54	1.132 1	5.76

## 参 考 文 献

- [1] JETTEN M S M, STROUS M, VAN DE PAS-SCHOONEN K T, et al. The anaerobic oxidation of ammonium[J]. *FEMS Microbiology Reviews*, 1998, 22(5): 421-437.
- [2] MA B, WANG S, CAO S, et al. Biological nitrogen removal from sewage via anammox: Recent advances[J]. *Bioresource Technology*, 2016, 200: 981-990.
- [3] CAO Y S, VAN LOOSDRECHT M C M, DAIGGER G T. Mainstream partial nitrification-anammox in municipal wastewater treatment: Status, bottlenecks, and further studies[J]. *Applied Microbiology and Biotechnology*, 2017, 101(4): 1365-1383.
- [4] 唐崇俭. 厌氧氨氧化工艺特性与控制技术的研究[D]. 杭州: 浙江大学, 2011.
- [5] PICOS-BENITEZ A R, LOPEZ-HINCAPIE J D, CHAVEZ-RAMIREZ A U, et al. Artificial intelligence based model for optimization of COD removal efficiency of an up-flow anaerobic sludge blanket reactor in the saline wastewater treatment[J]. *Water Science and Technology*, 2017, 75(6): 1351-1361.
- [6] SEEBOONRUANG U. A statistical assessment of the impact of land uses on surface water quality indexes[J]. *Journal of Environmental Management*, 2012, 101: 134-142.
- [7] 蒋白懿, 牟天蔚, 王玲萍. 灰色遗传神经网络模型对居民年需水量预测[J]. *给水排水*, 2018, 54(1): 137-142.
- [8] 黄辉, 马思佳, 王庆, 等. 多参数影响下污水总氮浓度预测最优方法研究[J]. *南京大学学报(自然科学)*, 2017, 53(6): 1194-1202.
- [9] ZHANG H G, CUI L L, ZHANG X, et al. Data-driven robust approximate optimal tracking control for unknown general nonlinear systems using adaptive dynamic programming Method[J]. *IEEE Transactions on Neural Networks*, 2011, 22(12): 2226-2236.
- [10] ZHAO Y, GUO L, LIANG J B, et al. Seasonal artificial neural network model for water quality prediction via a clustering analysis method in a wastewater treatment plant of China[J]. *Desalination and Water Treatment*, 2016, 57(8): 3452-3465.
- [11] YE J, ZHANG P, HOFFMANN E, et al. Comparison of response surface methodology and artificial neural network in optimization and prediction of acid activation of bauxsol for phosphorus adsorption[J]. *Water, Air & Soil Pollution*, 2014, 225(12): 2225.
- [12] BAGHERI M, MIRBAGHERI S A, BAGHERI Z, et al. Modeling and optimization of activated sludge bulking for a real wastewater treatment plant using hybrid artificial neural networks-genetic algorithm approach[J]. *Process Safety and Environmental Protection*, 2015, 95: 12-25.
- [13] 乔俊飞, 逢泽芳, 韩红桂. 基于改进粒子群算法的污水处理过程神经网络优化控制[J]. *智能系统学报*, 2012, 7(5): 429-436.
- [14] 李佟, 李军. 基于BP神经网络与马尔可夫链的污水处理厂脱氮效果模拟预测[J]. *环境科学学报*, 2016, 36(2): 576-581.
- [15] HU K, WAN J Q, MA Y W, et al. A fuzzy neural network model for monitoring A<sup>2</sup>/O process using on-line monitoring parameters[J]. *Journal of Environmental Science and Health*, 2012, 47(5): 744-754.

- [16] PLAZAS-NOSSA L, HOFER T, GRUBER G, et al. Forecasting of UV-Vis absorbance time series using artificial neural networks combined with principal component analysis[J]. *Water Science and Technology*, 2017, 75(4): 765-774.
- [17] 乔俊飞, 安茹, 韩红桂. 基于RBF神经网络的出水氨氮预测研究[J]. *控制工程*, 2016, 23(9): 1301-1305.
- [18] 刘思峰, 杨英杰, 吴利丰, 等. 灰色系统理论及其应用[M]. 7版. 北京: 科学出版社, 2014.
- [19] DU R, CAO S B, LI B K, et al. Performance and microbial community analysis of a novel DEAMOX based on partial-denitrification and anammox treating ammonia and nitrate wastewaters[J]. *Water Research*, 2017, 108: 46-56.
- [20] DECANETE J F, DEL SAZ-OROZCO P, BARATTI R, et al. Soft-sensing estimation of plant effluent concentrations in a biological wastewater treatment plant using an optimal neural network[J]. *Expert Systems with Applications*, 2016, 63: 8-19.
- [21] LACKNER S, GILBERT E M, VLAEMINCK S E, et al. Full-scale partial nitrification/anammox experiences: An application survey[J]. *Water Research*, 2014, 55: 292-303.
- [22] 严聪聪, 徐凯琳, 张建昆, 等. 基于改进的粒子群算法的活性污泥神经网络控制模型[J]. *给水排水*, 2018, 54(1): 130-136.
- [23] 王元月, 魏源送. 新型控制模式下短程硝化/厌氧氨氧化法处理污泥水[J]. *中国给水排水*, 2013, 29(17): 24-27.

(本文编辑: 曲娜, 郑晓梅, 张利田)

## Parameter prediction of anaerobic ammonium oxidation system based on multi-level neural network model

WANG Fei<sup>1</sup>, QING Xiaoxia<sup>1\*</sup>, WEN Xin<sup>2</sup>

1. College of Environment and Ecology, Chongqing University, Chongqing 400045, China

2. School of Civil Engineering and Architecture, Chongqing University of Science & Technology, Chongqing 401331, China

\*Corresponding author, E-mail: qxx118@126.com

**Abstract** Due to the complex growth conditions and multiple factors of anaerobic ammonium oxidizing (anammox) bacteria, the operation and control of the anammox process is very complex. In this study, a multi-level neural network prediction model was developed to improve the prediction accuracy of total nitrogen removal rate in the effluent of a single-stage SBBR autotrophic anammox system, and to determine the key control parameters for engineering applications of the system. The first-level artificial neural network model predicted the key indicators affecting the total nitrogen removal rate in the effluent through gray correlation analysis. The second-level artificial neural network model added the data dimension based on the first-level model, its artificial neural network was optimized with improving particle swarm optimization algorithm and its search range of particles was expanded by using the idea of genetic algorithm variation, then its prediction accuracy of total nitrogen removal rate was improved. The results showed that the predicted data basically matched with the actual value, the average relative error of total nitrogen removal rate was 0.54%, the relative error was 5.76%, and the root mean square error was 1.132 1. Compared with other predictive models, this model showed better prediction accuracy. Further analysis showed that it would be an effective control method to adjust the nitrous concentration in the effluent by controlling the aeration rate of the process system, which can ensure the stability of the process reaction and realize the engineering application of anammox process.

**Keywords** artificial neural networks; simulation prediction; improved particle swarm optimization; anammox