

DOI: 10.13382/j.jemi.B2104643

基于 TentFWA-GD 的 RBF 神经网络 COD 在线软测量方法*

陈如清 于志恒

(嘉兴南湖学院机电工程学院 嘉兴 314001)

摘要:针对污水处理过程 COD 难以实时准确测量的问题,提出了基于 TentFWA-GD 的 RBF 神经网络软测量方法。为解决现有 RBF 神经网络用于复杂工业过程软测量建模时存在网络参数难以确定及训练过程易陷入局部极值等问题,进一步提高 RBF 神经网络模型的预测精度与泛化能力,引入了 Tent 混沌映射对烟花算法 (fireworks algorithm, FWA) 进行改进,利用混沌运动的全局遍历性维持 FWA 的种群多样性并避免算法早熟收敛;将 TentFWA 算法与 GD 方法有机融合提出一种改进的 RBF 神经网络组合训练方法以改善网络的学习能力。将基于 TentFWA-GD 的 RBF 神经网络用于构建 4 个 Benchmark 函数拟合模型和农村生活污水处理过程 COD 在线软测量模型。仿真与应用结果表明,相对于其他神经网络模型,该模型具有较低的函数逼近误差和较高的 COD 预测精度。其中 COD 软测量模型训练结果的均方误差和平均绝对误差分别为 0.18 和 0.25,测试结果的两种误差分别为 0.23 和 0.36。

关键词:农村生活污水处理;COD 软测量;RBF 神经网络;烟花算法;Tent 混沌映射

中图分类号: TP183 **文献标识码:** A **国家标准学科分类代码:** 510.8040

COD on-line soft measurement based on TentFWA-GD RBF neural network

Chen Ruqing Yu Zhiheng

(College of Mechanical and Electrical Engineering, Jiaxing Nanhu University, Jiaxing 314001, China)

Abstract: With the goal to realize the real-time accurate measurement of chemical oxygen demand (COD) in wastewater treatment process, a soft-measurement method based on TentFWA-GD RBF neural network (NN) was proposed. To solve the problems of network parameters settings and local optima existing in RBF NN based soft sensor modeling for complex industrial processes, as well as improve the model's prediction precision and generalization ability, tent chaotic mapping was introduced in fireworks algorithm (FWA) to keep the population diversity and avoid the premature convergence by making use of the global ergodicity of chaos movement. Then a novel training method for RBF NN was proposed by combining the improved TentFWA with gradient descent (GD) method to enhance the learning ability. The TentFWA-GD RBF NN was applied to construct the fitting models of four Benchmark functions and the COD soft sensor model of rural domestic sewage treatment process. Simulation and application results showed that the model had lower function approximate error and higher COD prediction precision as compared with other neural network models. In COD soft sensor modeling, the mean square error and mean absolute error of the training results were 0.18 and 0.25, which of the test results were 0.23 and 0.36, respectively.

Keywords: rural domestic sewage treatment; soft sensor of chemical oxygen demand; RBF neural network; fireworks algorithm; Tent chaotic mapping

0 引言

随着我国农村经济的发展、生活的改善和人口的增加,农村污水排放量呈现快速增长态势,农村生活污水是农村面源污染的重要来源。农村生活污水处理过程中,化学需氧量(chemical oxygen demand, COD)既是描述水中有机物含量的一项重要参数,也是衡量水体污染程度的一项主要指标^[1]。COD 等水质参数的及时准确测量对于污水处理系统的优化控制和污水处理质量的整体提升均具有重要意义^[2]。

传统 COD 检测方法主要有重铬酸钾法、微波密封消解法和分光光度法等,诸类离线检测方法具有重现性好和检测精度高等优点,但也存在消解时间长、操作过程繁琐和二次污染较严重等缺陷,难以实现 COD 等水质参数的及时检测及污水处理过程的实时控制^[3-4]。近年来,基于 BP 神经网络、模糊神经网络、深度神经网络和 RBF 神经网络等人工神经网络污水水质参数软测量方法受到国内外学者广泛关注^[5],如文献[6-7]利用改良的粒子群算法或 FWA 优化神经网络并建立了相应的软测量模型,用于预测污水 COD 浓度等水质参数;李东等^[8]基于现有 co-training 模型,将协同训练算法与 BP 神经网络结合提出了 co-training BP 模型和异构自适应 co-training RPLS-RBP 混合回归模型,以 BSM1 仿真平台和实际污水处理厂为应用对象评估软测量模型的预测性能。为提高现有模糊神经网络的收敛速度和泛化性能,韩红桂等^[9]采用混合梯度下降算法训练模糊神经网络,用于非线性系统建模及污水处理过程重要指标预测;丁海旭等^[10]提出一种改进的自组织递归模糊神经网络并建立了 BOD 浓度软测量模型。为实现化工厂污水处理过程多变量的同步实时预测,文献[11-12]提出了基于改进深层神经网络的多输出自适应软测量方法;文献[13]提出了一种基于流形学习算法和深度神经网络的软测量方法,用于预测污水处理过程的总凯氏氮浓度。其他如文献[14]结合卷积神经网络和递归神经网络,提出了面向污水处理的数据驱动预测控制方法与系统框架,并进行了实验验证^[14];文献[15]基于小波神经网络和自适应加权融合算法,提出了一种改进的自适应估计方法并建立了集成软测量模型,以克服污水处理过程工况条件复杂多变对 COD 测量精度的影响;文献[16]提出了一种基于循环神经网络的半监督动态软测量模型。基于神经网络的软测量技术在理论研究和实际应用中均取得了较好成效。

与 BP 网络相比,RBF 网络具有拓扑结构紧凑及非线性逼近能力较强等优势,适用于函数逼近、非线性优化及预测建模等领域。但实际用于污水处理等复杂非线性过程的软测量建模时,由于网络目标函数通常为含有多

极点的复杂非线性曲面,存在网络模型的学习与映射能力不强、训练过程易陷入局部极值及网络参数(如基函数的中心、方差(宽度)和隐含层至输出层的连接权值等)难以确定等问题。针对这类问题,本文有机融合 FWA 优化算法、Tent 混沌映射和 GD 迭代方法,提出了一种改良的 RBF 神经网络组合训练方法并建立了农村生活污水处理过程 COD 浓度软测量模型,以提高现有 RBF 神经网络模型的预测精度和泛化性能,仿真与应用结果验证了该模型的有效性。

1 RBF 神经网络 COD 软测量模型

将 RBF 网络用于软测量建模,就是利用 RBF 神经网络构造采用常规传感器即可直接测量的辅助变量与难以直接测量的主导变量之间的网络模型,实现对主导变量的预测。如图 1 所示,RBF 网络的拓扑结构通常由输入层、隐含层和输出层构成。输入层和输出层节点分别对应软测量模型的各个辅助变量和主导变量。

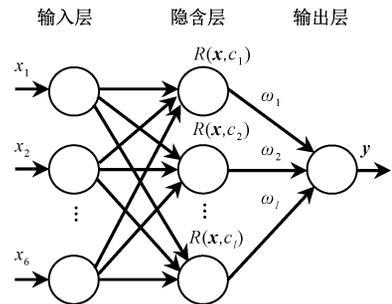


图 1 RBF 神经网络软测量模型

Fig. 1 RBF NN based soft sensor model

根据农村生活污水处理过程分析和现场运行经验,本文选取进水流量 Q 、进水悬浮固体浓度 SS 、进水总磷 TP 、进水总氮 TN 、进水温度 T 和溶解氧浓度 DO 等 6 个过程参数作为辅助变量,对应网络的 6 个输入层节点;COD 浓度预测值为软测量模型的主导变量,对应网络的 1 个输出层节点;隐含层节点数为 l 。隐含层节点数的选取与网络的输入输出维度相关,且每个模型均不相同,目前尚无统一的设置依据。参照现有文献隐含层节点数量的确定方法,可设定 $l = 2m + 1$,其中 m 为输入层节点个数。

设输入向量 $x = \{x_1, x_2, \dots, x_6\}$,输出向量为 y 。输入层将输入向量非线性映射至隐含层的输入,隐含层的输出通过权重矩阵线性映射到输出层的输入。使用高斯径向基函数作为隐含层激活函数,即:

$$R(x, c_j) = \exp\left(-\frac{\|x - c_j\|^2}{2\delta_j^2}\right) \quad (1)$$

对应输入向量 x ,RBF 网络的输出 $y(x)$ 为:

$$y(x) = \sum_{j=1}^l \omega_j R(x, c_j) \quad (2)$$

式中: $c = \{c_1, c_2, \dots, c_l\}$ 和 $\delta = \{\delta_1, \delta_2, \dots, \delta_l\}$ 分别为隐含层 RBF 激活函数的中心矢量和基宽向量, $\omega = \{\omega_1, \omega_2, \dots, \omega_l\}$ 为隐含层至输出层的连接权值。研究表明, c, δ 和 ω 是 RBF 神经网络软测量模型的重要参数, 运用相关学习算法确定参数值是网络训练的主要任务。本文融合 FWA 算法、Tent 混沌映射与 GD 迭代方法, 提出一种 TentFWA-GD 算法并将其用于 RBF 神经网络训练, 以获取最优的参数值 c^* 、 δ^* 和 ω^* 。

2 FWA 基本原理及早熟收敛分析

2.1 FWA 算法流程

类似于其他群智能优化算法, FWA 采用迭代搜索策略, 每次迭代过程中依次执行爆炸算子、高斯变异、映射规则和选择策略等 4 项操作, 直至达到预设的算法终止条件, 即达到最大迭代次数或满足优化问题的精度要求^[17]。常用于训练神经网络, 优化网络结构参数及改善网络性能。

基本 FWA 的实现流程可分为如下几个步骤:

1) 初始烟花种群的生成。即在解空间随机产生一定规模的烟花成员构成初始种群, 各烟花成员可视为解空间的候选解;

2) 利用适应度函数评价各烟花成员的适应度值, 根据适应度值及相关规则计算各烟花成员产生的火花数量和爆炸半径;

3) 产生爆炸火花, 并通过高斯变异操作生成一定数量的变异火花;

4) 评价烟花、爆炸火花及变异火花等全体成员的适应度值。适应度值最优个体优先作为下一代烟花成员, 采用“轮盘赌方式”选择其余烟花成员;

5) 计算全体成员的最优解, 并判定是否满足结束要求。若满足则算法停止搜索, 否则继续迭代搜索。

FWA 算法运行过程中, 各烟花成员产生火花数量 S_i 的计算公式为:

$$S_i = M \times \frac{y_{\max} - f(x_i) + \varepsilon}{\sum_{i=1}^N (y_{\max} - f(x_i)) + \varepsilon} \quad (3)$$

$$S_i = \begin{cases} \text{round}(a * M), S_i < aM \\ \text{round}(b * M), S_i > bM, a < b < 1 \\ \text{round}(S_i), \text{其他} \end{cases} \quad (4)$$

式中: M 为调节爆炸火花数的系数, ε 为避免分母为 0 的微量, y_{\max} 为种群中适应度值最差的个体, a, b 为限制火花数量 S_i 范围的两个常数, round 为根据四舍五入原则的取整函数。

爆炸幅度 R_i 的计算公式为:

$$R_i = R \times \frac{f(x_i) - y_{\min} + \varepsilon}{\sum_{i=1}^N f(x_i) - y_{\min} + \varepsilon} \quad (5)$$

式中: 常数 R 为调节爆炸半径的系数, y_{\min} 为种群中适应度值最优的个体。

除适应度值最优个体外, 其余下一代烟花成员采用“轮盘赌方式”产生, 成员 x_i 选择概率 $p(x_i)$ 的计算公式为:

$$p(x_i) = \frac{R(x_i)}{\sum_{x_j \in K} R(x_j)} \quad (6)$$

$$R(x_i) = \sum_{x_j \in K} d(x_i - x_j) = \sum_{x_j \in K} \|x_i - x_j\|$$

式中: $R(x_i)$ 为当前个体 x_i 与群体中其他个体之间的距离之和。为维持群体的多样性, 处于较低密度区域的个体被选中概率更高。

2.2 FWA 算法早熟收敛分析

种群多样性直接影响到 FWA 算法的全局优化性能, 多样性好的群体易克服早熟收敛问题而找到全局最优解。FWA 算法搜索过程中, 随着迭代次数的增加各烟花成员在解空间位置的差异度将逐步缩小, 形成烟花成员的聚集现象。此时适应度值最佳个体若不是优化问题的理论最优解, 则认为烟花群体陷入局部最优或 FWA 算法出现早熟收敛。

采用适应度方差法进行 FWA 算法的收敛性分析, 迭代过程中通过分析烟花成员适应度值的整体变化情况, 作为 FWA 种群陷入局部最优的判断依据。设 N 为烟花群体规模, $f(x_i)$ 和 f_{avg} 分别为第 i 个成员的适应度值及当前群体的平均适应度值, 当前群体适应度值方差 σ^2 可定义为:

$$\sigma^2 = \sum_{i=1}^N \frac{(f(x_i) - f_{\text{avg}})^2}{N} \quad (7)$$

群体适应度值方差 σ^2 反映了烟花群体中烟花成员的聚集程度, 数值越小表示烟花成员在解空间的分布越集中, 可作为 FWA 种群多样性的衡量指标。FWA 算法搜索过程中, 各烟花成员的适应度值随着迭代次数的增加而逐步接近, σ^2 的数值也随之减小。当 σ^2 小于某一阈值 C 且全局最优解未满足算法终止条件, 则判断 FWA 算法早熟收敛。此时应克服算法的早熟问题, 引导 FWA 群体逃离局部最优区域。

3 混合 TentFWA-GD 训练算法

3.1 Tent 混沌映射

Tent 映射 (又称帐篷映射) 是一种常用的分段线性混沌映射, 与 Logistic 等其他形式混沌映射对比, 具有功

率谱密度均匀、迭代速度快及相关特性好等特点,适用于处理大数量级的数据序列。Tent 映射及 Lyapunov 指数 λ 数学表达式分别为:

$$z_{n+1} = a - 1 - a |z_n|, 1 < a \leq 2 \quad (8)$$

$$\lambda = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=0}^{n-1} \ln \left| \frac{dx_{n+1}}{dx_n} \right| = \ln \alpha \quad (9)$$

当系统参数 $a=2$ 时, $\lambda_{\max} = \ln 2$, 映射表达式为:

$$z_{n+1} = \begin{cases} 2z_n, & 0 \leq z_n \leq 0.5 \\ 2(1 - z_n), & 0.5 < z_n < 1 \end{cases} \quad (10)$$

3.2 TentFWA-GD 算法原理

GD 方法是神经网络模型最常用的训练方法,具有原理简单及易于实现等特点,且当目标函数为凸函数时可得到全局最优解。但用于 RBF 神经网络训练时,由于网络目标函数误差曲面极其复杂,存在网络收敛速度慢、易陷入局部极小和网络初始值设置值敏感等不足。FWA 优化算法用于 RBF 神经网络训练,具有搜索范围广、运行效率高及鲁棒性能好等优点,但也存在局部搜索能力不强及计算精度不高等缺点。为充分发挥这两种方法的优势并克服其存在的不足,本文引入 Tent 混沌映射改进 FWA 算法以防止发生早熟收敛;将改进 TentFWA 与 GD 方法有机融合,提出一种改进的 RBF 神经网络组合训练方法以提高网络学习能力与泛化能力。

TentFWA-GD 训练算法的基本原理为:RBF 神经网络训练过程采用全局粗略搜索与局部精细探索相结合的寻优机制。第 1 阶段由 FWA 算法进行一定搜索并采用适应度方差法判断是否陷入局部最优;第 2 阶段当 FWA 算法陷入局部最优解时,一方面利用 Tent 混沌映射引导烟花种群逃离局部最优区而继续全局搜索;另一方面结合 GD 方法训练 RBF 神经网络,以加强烟花种群的局部探索能力并提高群体最优解的精度。因此,改进的 TentFWA-GD 训练方法可根据实际收敛情况实现全局搜索和局部搜索的自动切换,有效提高了 RBF 神经网络的学习速度和泛化能力。

基于 TentFWA-GD 的 RBF 神经网络训练过程,具体流程如下:

1) 根据预设参数在解空间进行烟花种群的随机初始化。其中烟花成员的维数为 RBF 神经网络待优化参数 c 、 δ 和 ω 的维数之和,适应度函数为神经网络的均方误差;

2) 基于 FWA 算法优化 RBF 网络参数。包括:计算烟花种群各成员的信息(位置和适应度值)、群体最优成员的信息(群体最优位置和适应度值)及群体适应度值方差 σ^2 ;判断 FWA 是否陷入局部极值, $\sigma^2 \leq C$ 且群体适应度值未达到设定值则进入步骤 3), 否则返回步骤 2);

3) 采用 GD 方法进一步优化 RBF 网络参数。包括:以当前群体最优烟花成员的位置作为当前 RBF 网络的

初始参数值,调用 GD 算法调整网络参数;对于每个烟花成员,按照概率 P_m 在混沌搜索空间进行 Tent 混沌映射;计算种群各成员的信息、群体最优成员的信息及群体适应度值方差;

4) 训练过程达到最大迭代次数或网络误差满足精度要求时算法停止搜索,否则转步骤 2) 继续迭代。

综上所述, TentFWA-GD 混合算法融合了 FWA 算法、Tent 混沌映射和 GD 迭代方法。FWA 算法和 Tent 混沌映射方法较传统神经网络算法步骤简单,训练速度较快。算法的复杂度方面, TentFWA-GD 算法与 FWA-GD、PSO-GD 和 GA-GD 等算法复杂度的相当;算法的收敛性方面,引入 Tent 混沌映射机制使烟花群体具备更强的全局搜索能力,引入 GD 算法则进一步增强了烟花群体的局部搜索能力。改进方法具有收敛速度更快及收敛精度更高等优点。

3.3 算法性能测试

为检验改进算法的全局搜索性能和寻优精度,建立基于 TentFWA-GD 算法的 RBF 神经网络函数拟合模型,并以 4 个常用 Benchmark 函数为测试对象进行函数模拟和误差分析。仿真过程中,还构建了基本 BP 神经网络(训练函数为 trainbp)、GA-BP 神经网络、PSO-BP 神经网络、基本 RBF 神经网络(训练函数为 solverb)和基于 FWA-GD 算法的 RBF 神经网络等 5 种函数拟合模型,分别进行 100 次函数拟合实验,以形成对比。4 个复杂函数的具体描述如表 1 所示。

表 1 测试 Benchmark 函数集

Table 1 Test Benchmark functions

函数	范围
$f_1 = 100 \times (x_1^2 - x_2)^2 + (1 - x_1)^2$	$x_i \in [-10, 10], i = 1, 2$
$f_2 = x_1^2 + x_2^3 - x_1 x_2 x_3 + x_3 - \sin x_2^2 - \cos(x_1, x_2^2)$	$x_i \in [-2\pi, 2\pi], i = 1, 2, 3$
$f_3 = x_1^{x_2^3} + x_3^{x_4^{x_5}}$	$x_i \in [0, 2], i = 1, 2, \dots, 5$
$f_4 = \sum_{i=1}^8 x_i^i$	$x_i \in [-1, 1], i = 1, 2, \dots, 8$

参数设置如下:神经网络结构分别为 2-5-1、3-7-1、5-11-1、8-17-1(根据 4 个函数的自变量和因变量的个数,并参照本文第 1 节的方法确定隐层节点数 l);解空间维数(即 RBF 神经网络 c 、 δ 和 ω 的数目) $D = l + l + l = 3l$,神经网络最大训练次数为 1 000,训练目标为 10^{-6} ;神经网络样本集的生成:对于 4 个待拟合函数,分别在自变量取值范围内随机生成规模为 200 的样本集,训练和测试样本数量分别为 150 和 50,各智能优化算法的群体规模均为 40;FWA 参数初始化:爆炸半径调节系数 R 为 240,爆炸火花数调节系数 M 为 200,爆炸火花数限制系数 a 和 b

分别为 1 和 20, 变异火花数量为 45; TentFWA-GD 算法的混沌变换概率 P_m 为 0.2, 群体适应度值方差的阈值 C 为 0.01; GA 参数初始化: 交叉概率为 0.56; 变异概率为 0.01; PSO 参数初始化: $c_1 = c_2 = 2.0$; $\omega_{\max} = 0.56$, $\omega_{\min} =$

0.06。表 2 为 6 种函数拟合模型的拟合结果, 数据为 100 次实验的平均值, ER1 为训练均方误差、ER2 为检验均方误差、ER3 为训练平均绝对误差, ER4 为检验平均绝对误差。

表 2 6 种神经网络模型函数拟合结果对比 (100 次实验)

Table 2 Comparison of function fitting results between six neural network models

神经网络类型	f_1				f_2			
	ER1	ER2	ER3	ER4	ER1	ER2	ER3	ER4
BP	9.792×10^{-5}	4.554×10^{-2}	8.621×10^{-2}	6.399×10^{-1}	3.610×10^{-4}	1.472×10^{-1}	1.590×10^{-2}	3.883×10^{-1}
GA-BP	7.218×10^{-5}	8.337×10^{-3}	1.402×10^{-2}	1.026×10^{-1}	9.102×10^{-5}	6.159×10^{-2}	1.014×10^{-2}	1.735×10^{-1}
PSO-BP	6.965×10^{-5}	7.671×10^{-3}	1.321×10^{-2}	9.872×10^{-2}	9.616×10^{-5}	6.833×10^{-2}	1.323×10^{-2}	2.006×10^{-1}
RBF	7.730×10^{-5}	8.395×10^{-3}	1.392×10^{-2}	1.855×10^{-1}	1.204×10^{-4}	7.021×10^{-2}	1.471×10^{-2}	2.314×10^{-1}
FWA-GD RBF	2.032×10^{-5}	5.764×10^{-4}	3.212×10^{-3}	9.872×10^{-2}	5.943×10^{-5}	8.319×10^{-4}	4.932×10^{-3}	5.303×10^{-2}
TentFWA-GD RBF	1.314×10^{-6}	4.113×10^{-5}	8.123×10^{-4}	1.512×10^{-2}	3.394×10^{-6}	9.659×10^{-5}	2.319×10^{-3}	1.530×10^{-2}
神经网络类型	f_3				f_4			
	ER1	ER2	ER3	ER4	ER1	ER2	ER3	ER4
BP	1.150×10^{-2}	2.124×10^{-1}	7.662×10^{-2}	4.080×10^{-1}	1.194×10^{-2}	1.441×10^{-2}	9.001×10^{-2}	1.011×10^{-1}
GA-BP	6.757×10^{-3}	1.180×10^{-2}	4.858×10^{-2}	6.047×10^{-2}	9.870×10^{-3}	1.183×10^{-2}	7.540×10^{-2}	8.972×10^{-2}
PSO-BP	5.873×10^{-3}	1.025×10^{-2}	4.222×10^{-2}	5.255×10^{-2}	1.026×10^{-2}	1.238×10^{-2}	7.889×10^{-2}	9.891×10^{-2}
RBF	9.612×10^{-3}	1.678×10^{-2}	6.910×10^{-2}	8.601×10^{-2}	1.176×10^{-2}	1.352×10^{-2}	9.184×10^{-2}	1.093×10^{-1}
FWA-GD RBF	5.783×10^{-3}	8.204×10^{-3}	4.531×10^{-2}	5.762×10^{-2}	7.012×10^{-3}	8.503×10^{-3}	7.223×10^{-2}	9.705×10^{-2}
TentFWA-GD RBF	3.659×10^{-3}	7.532×10^{-3}	2.616×10^{-2}	4.069×10^{-2}	5.127×10^{-3}	6.684×10^{-3}	5.275×10^{-2}	8.012×10^{-2}

由表 2 的拟合结果可知, 基于 RBF 神经网络函数拟合模型, 其拟合精度整体优于 BP 神经网络函数拟合模型, 训练误差和检验误差均有较大程度下降。说明 RBF 网络具有更好的全局逼近能力, 能较好解决 BP 网络的局部最优问题; 参照现有文献, 采用智能优化策略优化 BP 神经网络模型和 RBF 神经网络模型的参数, 有效避免了网络参数选择的盲目性和随意性, 相应拟合模型的训练误差和检验误差较基本模型有一定程度下降。而采用 FWA-GD 算法和改进的 TentFWA-GD 算法优化 RBF 网络参数, 则进一步提高了模型的函数拟合精度; 将 TentFWA-GD 混合算法用于训练 RBF 网络、优化网络参数并获取最佳网络结构, 能有效提升网络的学习效果, 所构建的函数拟合模型训练误差和检验误差最低, 学习能力和拟合性能最优。

此外, 表 2 的测试结果也说明, 本文提出的 TentFWA-GD 算法, 由于采用适应度方差法判断 FWA 算法早熟收敛并利用 Tent 混沌映射引导烟花成员逃离局部最优解, 与其他智能优化策略相比, 在处理复杂函数拟合问题时具有更好的寻优精度、寻优率和鲁棒性。适用于求解多峰及复杂高维空间的全局优化问题。

4 基于 TentFWA-GD 的 RBF 神经网络 COD 软测量建模

4.1 样本数据准备

现有污水处理过程是一个多变量、非线性和大滞后

的复杂生化反应系统, 过程建模较为困难。某农村生活污水处理厂, 采用改良智能型 SBR 污水处理工艺。采用 4 组 SBR 反应池交替运行以实现污水连续处理, 对污水水质或水量突变冲击负荷的适应能力较强; 运用耦合强化污染物去除单元, 确保出水水质符合排放标准。该 SBR 工艺的主要流程包括流入、反应、沉淀、排放和闲置等 5 个反应工序。COD 浓度是污水处理过程的一项重要指标, 在线监测具有重要意义。现有水质监测设备多采用常规化学法 (如重铬酸盐法检测 COD 等), 存在设备价格昂贵、化学试剂消耗量大、保养运维费用高及对检测人员技能要求高等不足, 难以满足农村生活污水监测的实际需求。从工程应用角度出发, 将本文所设计的基于 TentFWA-GD 算法的 RBF 神经网络应用于污水处理过程关键参数的实时预测, 建立了污水曝气过程 COD 浓度的软测量模型。

利用现场 DCS 系统采集污水处理过程各项原始参数信息, 组建水质指标模型数据库。综合现场经验和 PCA 分析, 确定进水流量 Q 、进水悬浮固体浓度 SS 、进水总氮 TN 、进水总磷 TP 、进水温度 T 和溶解氧浓度 DO 等 6 项过程参数与 COD 浓度的关联性最大。定义软测量模型的输入辅助变量 $X = [x_1, x_2, \dots, x_6]$, 对应进水流量 Q 等 6 个参数, 输出主导变量 Y , 对应出水 COD 浓度, 建立 RBF 神经网络软测量模型。部分样本数据如表 3 所示。对实测的水质指标数据进行预处理。首先, 利用莱特检验法判别和剔除水质指标模型数据库中的异常值; 其次, 考虑到不同水质指标具有不同的量纲和单位, 为消除量

纲影响,将数据进行归一化处理并映射至 $[0, 1]$ 区间范围。

表 3 部分样本数据

Table 3 Partial of the sample data

Q/m^3	SS/ ($mg \cdot L^{-1}$)	TP/ ($mg \cdot L^{-1}$)	TN/ ($mg \cdot L^{-1}$)	$T/^\circ C$	DO/ ($mg \cdot L^{-1}$)	COD/ ($mg \cdot L^{-1}$)
28 316	317.57	2.60	28.03	22.77	2.93	22.97
31 429	268.18	2.51	34.51	19.53	4.86	17.10
35 071	315.74	3.39	17.41	17.41	1.92	14.78
28 214	303.60	3.09	20.95	16.39	1.52	10.73
25 968	160.60	2.02	18.72	19.03	2.23	18.52
33 198	190.86	3.24	21.45	14.37	0.71	20.54
33 523	374.44	2.66	16.90	21.05	4.45	16.19
30 526	213.53	2.52	40.08	23.17	2.83	8.91
30 736	293.48	2.34	17.61	24.39	1.11	17.61
30 912	425.04	2.72	13.05	19.33	1.52	26.92

4.2 COD 软测量建模与校正

利用嵌入式智能仪表(下位机)和水质参数检测模块等硬件实验平台,进行 COD 浓度在线软测量,其实现过程描述如下:

1) 辅助变量选择。综合现场经验和 PCA 分析,选取进水流量 Q 等 6 个过程参数作为 COD 软测量的辅助变量,构建基于 TentFWA-GD 算法的 RBF 神经网络软测量模型;

2) 软测量程序编写。基于 RBF 神经网络结构及改进训练算法编写软测量程序,保存至嵌入式智能仪表处理系统;

3) 软测量建模。从水质指标模型数据库中随机选取 200 组数据用于训练软测量模型,神经网络进行自适应调整直至训练精度达到设定值;另选取未参与训练的 50 组数据用于测试软测量模型;保存神经网络结构和最优参数,用于 COD 在线测量;

4) COD 在线软测量。将训练好的嵌入式智能仪表作为下位机接入污水处理过程,利用现场 DCS 系统等实时获取进水流量 Q 等 6 个过程参数,新的现场数据经预处理后输入软测量模型;基于软测量程序嵌入式智能仪表及时计算 COD 浓度值;依据设置的采样时间间隔,重复 4);

5) 输出 COD 实时预测结果。

此外,将 COD 浓度在线软测量模型用于污水处理过程的实时控制,考虑到过程对象的时变性,实际工况和参数会发生不同程度变化而产生一定偏差,导致软测量模型的估计偏差增大甚至失真。为适应过程操作特性变化和生产工况变迁,需对所构建的软测量模型进行校正。校正方法主要有定时校正和满足一定条件的校正两种。结合现场实际情况,本文采取第 2 种方式。即将软测量模型的预测值和相应的取样分析数据进行比较,若预测

精度小于某一阈值(如绝对误差小于 0.50),则仍采用该软测量模型;否则,利用累积的新样本数据参照上述建模方法进行校正,以得到适应新工况的 COD 软测量模型。

4.3 COD 软测量模型性能测试

构建 RBF 神经网络污水曝气过程 COD 浓度在线软测量模型,其中 3 层网络拓扑结构为 6-13-1(隐层节点数 $l=2 \times 6 + 1 = 13$),待优化网络参数 c, δ 和 ω 个数为 39,训练方法为 TentFWA-GD 算法。并与基本 BP 神经网络、GA-BP 神经网络、PSO-BP 神经网络、基本 RBF 神经网络和基于 FWA-GD 算法的 RBF 神经网络等模型进行对比。建模过程主要参数为:BP 和 RBF 两类神经网络结构均为 6-13-1,最大训练次数为 5 000,各智能优化算法的群体规模为 40;FWA 参数:爆炸半径调节系数 R 为 200,爆炸火花数调节系数 M 为 150,爆炸火花数限制系数 a 和 b 分别为 1 和 20,变异火花数为 45;GA 参数:交叉概率为 0.56;变异概率为 0.01;PSO 参数: $c_1 = c_2 = 2.0$; $\omega_{\max} = 0.56$, $\omega_{\min} = 0.06$;TentFWA-GD 算法的混沌变换概率 P_m 为 0.2,群体适应度值方差的阈值 C 为 0.015。

将预处理后的样本作为神经网络模型的训练数据,训练结束后保存最优 c^* 、 δ^* 和 ω^* 值用于模型在线预测 COD 浓度。表 4 为 6 种神经网络模型的训练与预测结果,ER1 和 ER3 分别表示训练过程的均方误差和平均绝对误差,ER2 和 ER4 分别表示测试过程的均方误差和平均绝对误差。图 2 和 3 分别为基于 TentFWA-GD 算法的 RBF 神经网络软测量模型的训练效果和预测结果。

表 4 6 种模型的训练和预测结果对比

Table 4 Comparison of training and prediction results between six models

神经网络类型	训练结果		预测结果	
	ER1	ER3	ER2	ER4
BP	1.64	1.13	2.12	1.24
GA-BP	1.30	0.65	1.72	0.77
PSO-BP	1.22	0.62	1.63	0.70
RBF	1.49	0.76	1.99	0.90
FWA-GD RBF	0.42	0.40	0.56	0.53
TentFWA-GD RBF	0.18	0.25	0.23	0.36

表 4 的对比结果表明:与另外 5 种神经网络软测量模型相比,基于 TentFWA-GD 算法 RBF 神经网络模型的训练误差和泛化误差最小,表现出较强的全局逼近能力,与 3.3 节的算法性能测试结果一致,再次验证了本文所提出改进吐方法的有效性。从图 2 的训练结果可以看出,基于改进的组合训练方法训练 RBF 神经网络,参数优化过程采用全局粗略搜索与局部精细探索相结合的寻优机制,有效提升了训练效率和训练精度。训练样本的 COD 浓度实际值与软测量模型输出值之间的偏差较小(均方误差和平均绝对误差分别为 0.18 和 0.25),训练

过程满足要求。从图3的预测结果可以看出,测试样本的COD浓度测量精度较高(均方误差和平均绝对误差分别为0.23和0.36)。训练和测试结果表明,本文所构建的软测量模型具有良好的泛化性能,可较好地预测COD浓度。

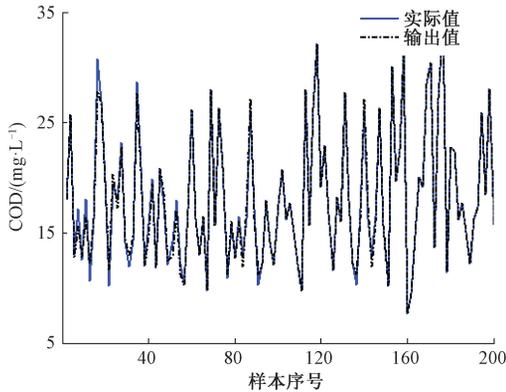


图2 TentFWA-GD RBF 软测量模型的训练结果
Fig. 2 Training result of TentFWA-GD RBF based soft sensor model

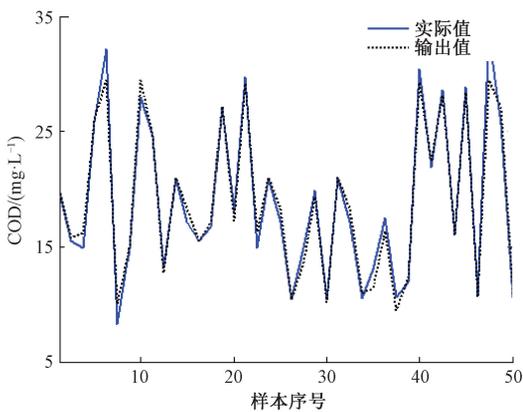


图3 TentFWA-GD RBF 软测量模型的预测结果
Fig. 3 Prediction result of TentFWA-GD RBF based soft sensor model

5 结论

农村生活污水处理中,COD 是评价水质优劣和水体污染程度的一项重要参数。为实现 COD 浓度的及时准确测量,本文基于 COD 传统测量方法及现有软测量方法,提出了一种基于 TentFWA-GD 的 RBF 神经网络训练方法并建立了 COD 在线软测量模型。

通过引入 Tent 混沌映射改进了 FWA 算法,利用混沌搜索的全局遍历性保持 FWA 算法的种群多样性并避免算法过早收敛,较大程度改善了常规 FWA 算法处理复杂优化问题的优化性能;将改进 TentFWA 算法与 GD 方

法有机融合,提出一种改进的 RBF 神经网络组合训练方法,实现了两者的优势互补。以 4 个常用 Benchmark 函数为对象进行函数模拟测试,仿真结果表明基于 TentFWA-GD 的 RBF 神经网络函数拟合模型具有学习能力强和拟合精度高等优点。最后将基于 TentFWA-GD 的 RBF 神经网络成功用于农村生活污水处理过程软测量建模,实时预测污水曝气过程 COD 浓度。应用结果表明基于改进 RBF 神经网络的软测量模型测量精度较高、泛化性能较好,为污水处理等复杂过程中关键变量的测量提供了一种可行的方法。

参考文献

- [1] NEWHART K B, HOLLOWAY R W, HERING A S. Data-driven performance analyses of wastewater treatment plants: A review [J]. *Water Research*, 2019, 157: 498-513.
- [2] RECIO G D, ADEKUNLE A, PERRIER M, et al. Wastewater treatment and online chemical oxygen demand estimation in a cascade of microbial fuel cells [J]. *Industrial & Engineering Chemistry Research*, 2017, 56(44): 12471-12478.
- [3] 潘碌亭, 谢欣珏, 王九成, 等. 脱氮除磷生物滤池填料制备及其对农村生活污水的处理效果[J]. *农业工程学报*, 2017, 33(9): 230-236.
PAN L T, XIE X J, WANG J CH, et al. Preparation of denitrification and dephosphorization biological fillers and its effect on treatment of rural domestic sewage [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2017, 33(9): 230-236.
- [4] 赵超, 戴坤成, 王贵评, 等. 基于 AWLS-SVM 的污水处理过程软测量建模[J]. *仪器仪表学报*, 2015, 36(8): 1792-1800.
ZHAO CH, DAI K CH, WANG G P, et al. Soft sensor modeling for wastewater treatment process based on adaptive weighted least squares support vector machines [J]. *Chinese Journal of Scientific Instrument*, 2015, 36(8): 1792-1800.
- [5] QIU Y, LIU Y, HUANG D. Data-driven soft-sensor design for biological wastewater treatment using deep neural networks and genetic algorithms [J]. *Journal of Chemical Engineering of Japan*, 2016, 49(10): 925-936.
- [6] 高峰, 冯民权, 滕素芬. 基于 PSO 优化 BP 神经网络的水质预测研究 [J]. *安全与环境学报*, 2015, 15(4): 338-341.
GAO F, FENG M Q, TENG S F. On the way for forecasting the water quality by BP neural network based on the PSO [J]. *Journal of Safety and Environment*,

- 2015, 15(4): 338-341.
- [7] 陈如清, 俞金寿. 基于改进 FWA-NN 的污水处理过程溶解氧浓度预测[J]. 中国环境科学, 2018, 38(10): 3739-3746.
CHEN R Q, YU J SH. Prediction of dissolved oxygen concentration in wastewater treatment process based on improved FWA-NN [J]. China Environmental Science, 2018, 38(10): 3739-3746.
- [8] 李东, 黄道平, 刘乙奇. 基于协同训练的半监督异构自适应软测量建模方法的研究[J]. 化工学报, 2020, 71(5): 2128-2138.
LI D, HUANG D P, LIU Y Q. Research on semi-supervised heterogeneous adaptive co-training soft-sensor model [J]. CIESC Journal, 2020, 71(5): 2128-2138.
- [9] 韩红桂, 林征来, 乔俊飞. 一种基于混合梯度下降算法的模糊神经网络设计及应用[J]. 控制与决策, 2017, 32(9): 1635-1641.
HAN H G, LIN ZH L, QIAO J F. Design and application of hybrid gradient descent-based fuzzy neural network [J]. Control and Decision, 2017, 32(9): 1635-1641.
- [10] 丁海旭, 李文静, 叶旭东, 等. 基于自组织递归模糊神经网络的 BOD 软测量[J]. 计算机与应用化学, 2019, 36(4): 331-336.
DING H X, LI W J, YE X D, et al. BOD soft-sensing based on self-organizing recurrent fuzzy neural network [J]. Computers and Applied Chemistry, 2019, 36(4): 331-336.
- [11] WANG X F, ZHANG X L. Soft-sensor modeling of chemical plant wastewater treatment process using improved deep neural network [J]. Fresenius Environmental Bulletin, 2020, 29(7): 5530-5539.
- [12] 邱禹, 刘乙奇, 吴菁, 等. 基于深度神经网络的多输出自适应软测量建模[J]. 化工学报, 2018, 69(7): 3101-3113.
QIU Y, LIU Y Q, WU J, et al. A self-adaptive multi-output soft sensor modeling based on deep neural network [J]. CIESC Journal, 2018, 69(7): 3101-3113.
- [13] YAN W W, XU R C, WANG K D, et al. Soft sensor modeling method based on semisupervised deep learning and its application to wastewater treatment plant [J]. Industrial & Engineering Chemistry Research, 2020, 59(10): 4589-4601.
- [14] GUO Z W, DU B X, WANG J H, et al. Data-driven prediction and control of wastewater treatment process through the combination of convolutional neural network and recurrent neural network [J]. RSC Advances, 2020, 10(23): 13410-13419.
- [15] CONG Q M, YU W. Integrated soft sensor with wavelet neural network and adaptive weighted fusion for water quality estimation in wastewater treatment process [J]. Measurement, 2018, 124: 436-446.
- [16] 邵伟明, 葛志强, 李浩, 等. 基于循环神经网络的半监督动态软测量建模方法[J]. 电子测量与仪器学报, 2019, 33(11): 7-13.
SHAO W M, GE ZH Q, LI H, et al. Semisupervised dynamic soft sensing approaches based on recurrent neural network [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(11): 7-13.
- [17] TAN Y, ZHU Y C. Fireworks algorithm for optimization [C]. Proceedings of 1st International Conference on Swarm Intelligence. Berlin, Germany: Springer, 2010: 355-364.

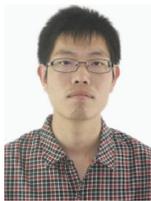
作者简介



陈如清, 2009 年于华东理工大学获得博士学位, 现为嘉兴南湖学院教授, 硕士生导师, 主要研究方向为复杂工业过程建模、智能控制技术。

E-mail: ruqing2002@163.com

Chen Ruqing received Ph. D. from East China University of Science and Technology in 2009. He is a professor and master supervisor at Jiaxing Nanhu University now. His main research interests include complex industrial process modeling and intelligent control technology.



于志恒(通信作者), 2015 年于江西理工大学获得硕士学位, 现为嘉兴南湖学院讲师/工程师。主要研究方向为柔性电子增材制造技术。

E-mail: yuzhiheng@jxnhu.edu.cn

Yu Zhiheng (Corresponding author) received M. Sc. from Jiangxi University of Science and Technology in 2015. He is a lecturer and engineer at Jiaxing Nanhu University now. His main research interest includes flexible electronic additive manufacturing technology.