

DOI: 10.13382/j.jemi.2017.09.021

# 基于约束多目标骨干粒子群的 污水处理过程优化控制<sup>\*</sup>

周红标

(淮阴工学院 自动化学院 淮安 223003)

**摘要:**为了取得污水处理过程能耗和出水水质这对冲突目标之间的最佳平衡,提出一种基于约束多目标骨干粒子群的污水处理过程智能优化控制方法。首先,利用数据驱动的思想建立能耗和出水水质的模糊神经网络预测模型;其次,利用带自适应扰动的约束多目标骨干粒子群优化算法对溶解氧和硝态氮浓度的设定值进行动态寻优,并利用模糊隶属函数法设计智能决策系统用于从Pareto最优解集中确定最优设定值;最后,利用模糊逻辑控制器实现底层跟踪控制。基于国际基准平台BSM1实验结果表明,建立的数据驱动模型能够有效辨识污水处理过程;同时,所提的多目标优化控制方法在保证出水水质参数达标前提下,能够有效地降低污水处理过程的能耗。

**关键词:**污水处理过程;数据驱动;优化控制;多目标优化;骨干粒子群

中图分类号: TP273 文献标识码: A 国家标准学科分类代码: 510.8010

## Optimal control for wastewater treatment process based on constrained bare-bones multi-objective particle swarm optimization algorithm

Zhou Hongbiao

(Faculty of Automation, Huaiyin Institute of Technology, Huai'an 223003, China)

**Abstract:** To achieve an optimal balance between energy consumption (EC) and effluent quality (EQ) of a wastewater treatment process (WWTP), an intelligent optimal control strategy is proposed based on constrained bare-bones multi-objective particle swarm optimization algorithm (CBBMOPSO). First, a data-driven-based fuzzy neural network prediction model of EC and EQ is constructed utilizing the process date measured from WWTP. Then, the proposed CBBMOPSO with adaptive disturbance is used for dynamically optimizing the set-points of dissolved oxygen  $S_o$  concentration and nitrate nitrogen  $S_{NO}$  level. Furthermore, an intelligent decision-making system based on fuzzy membership function is designed to identify the optimal setting value from the Pareto optimal set. Finally, the optimization set-points of  $S_o$  and  $S_{NO}$  are tracked by a fuzzy logic controller to realize multi-objective optimal control of the WWTP. The experimental results based on the international benchmark simulation model No. 1 (BSM1) demonstrate that the proposed CBBMOPSO method can significantly reduce the energy consumption on the premise of assuring water quality.

**Keywords:** wastewater treatment process; data driven; optimal control; multi-objective optimization; bare-bones particle swarm

## 0 引言

水污染问题是世界上最令人头疼的问题之一,而且在未来几十年还会继续恶化<sup>[1]</sup>。目前,生物处理法是污

水处理厂最广泛采用的净水方法,特别是活性污泥法是去除污水中污染物的最有效方法<sup>[2]</sup>。该方法的重要举措就是通过鼓风机向曝气池中充入适当氧气以保持好氧区的溶解氧  $S_o$  浓度以及通过回流泵回流污水以保持缺氧区的硝态氮  $S_{NO}$  浓度,这需要大量的电力能量供给。随着

公众对环境关注度的提高,出水水质参数的相关标准也越来越严格,污水处理厂在“提标改造”过程中不得不使  $S_o$  和  $S_{NO}$  维持于一个较高的运行水平。但是,好氧区  $S_o$  浓度过高,有可能破坏反硝化所需的缺氧环境,增大缺氧区可快速降解有机碳的消耗,从而影响污水处理效果。同样,合适的缺氧区  $S_{NO}$  浓度才能保证反硝化反应的顺利进行,从而提高脱氮去除率。因此,根据入水情况对  $S_o$  和  $S_{NO}$  设定值进行动态寻优,实现以节能降耗为目的的优化控制是提高污水处理效果和降低运行成本的一种可行办法<sup>[3]</sup>。

污水处理过程(wastewater treatment processes, WWTPs)的优化问题主要包含以下几个方面<sup>[4]</sup>:1)建立模拟污水处理生化反应过程和污染物浓度变化的数学模型,包括关键水质参数的软测量模型<sup>[5]</sup>;2)选择优化目标,比如减少能耗;3)选择能够影响优化目标的控制参数,比如溶解氧浓度直接关系到曝气能耗的大小,而曝气能耗占总能耗的 60% 以上<sup>[6]</sup>;4)考虑优化问题的约束条件,比如在国家标准(GB18918-2002)中出水水质参数  $BOD$  的一级 A 标准要求小于 10 mg/L;5)利用优化算法寻找优化问题的最优解。此外,由于污水处理过程连续运行,还需考虑优化问题的动态特性,常用控制向量参数化(control vector parameterization, CVP)<sup>[7]</sup>方法进行处理。CVP 方法主要是将时间域分割成有限的时间间隔,在每个时间间隔内将优化问题当作静态问题,比如说将 1 d 的污水处理过程按每 2 h 分割成 12 份,从而可以获得 12 个溶解氧优化设定值。

在过去的十几年里,污水处理过程单目标优化方法已取得丰硕的成果<sup>[8-10]</sup>。单目标优化方法主要关注能耗指标,容易导致出水水质参数超标,增加运行成本。因此,为了处理能耗和出水水质这对相互竞争的目标,多目标优化方法引起了学者的广泛关注<sup>[11-13]</sup>。Machado 等人<sup>[11]</sup>采用相对增益矩阵优化出水水质和操作成本构成的目标函数,Qiao 等人<sup>[12]</sup>采用自适应动态规划设计数据驱动的自适应优化控制(DDAOC)算法优化能耗和出水水质加权和构成的目标函数,Zhang 等人<sup>[13]</sup>采用遗传算法独立地优化操作成本和出水水质。然而,上述多目标方法主要是利用加权法将多目标优化问题转化为单目标优化问题,普遍存在权值系数难以确定的缺陷,而且没有考虑不同目标函数之间的依赖关系。由于污水处理生化反应过程的相互影响,能耗和出水水质呈现相互冲突的特性,利用多目标优化方法同时优化这两个目标有利于得到更多更富竞争力的 Pareto 解<sup>[14-18]</sup>。Hakanen 等人<sup>[15]</sup>采用集成 NSGA-II 交互式多目标优化工具箱 IND-NIMBUS 同时优化曝气能耗和出水总氮等多个目标,Sweetapple 等人<sup>[16]</sup>采用 NSGA-II 同时优化温室气体排放量、生产成本和出水污染物浓度,Hreiz 等人<sup>[17]</sup>采用

NSGA-II 同时优化出水水质和运行成本,Chen 等人<sup>[18]</sup>采用 NSGA-II 同时优化出水水质和操作成本,Qiao 等人<sup>[19]</sup>采用 NSGA-II 和神经网络相结合的方法(DMOOC)同时优化能耗和出水水质。上述基于 NSGA-II 的方法在降低能耗的同时取得了较好的出水水质,节约了操作成本,也减少了污染物的排放。

不同于 NSGA-II 中遗传算法的进化思想,粒子群优化算法(particle swarm optimization, PSO)<sup>[20]</sup>通过模拟鸟类觅食等复杂群体行为进行决策空间寻优,具有概念简明、实现方便和收敛速度快等优点。作为一种基于种群的多目标启发式优化技术,多目标粒子群优化算法(multi-objective particle swarm optimization, MOPSO)具有对优化问题 Pareto 前沿形状和连续性不敏感,一次迭代可获得多个 Pareto 解的特点<sup>[21]</sup>,在优化问题中得到了成功应用<sup>[22-23]</sup>。然而,传统 PSO 算法需要较高的技巧设计惯性权重和学习因子的自适应取值策略来调控算法的全局探索和局部开发能力,限制其在实际工程中的应用。Kennedy<sup>[24]</sup>于 2003 年提出的骨干粒子群算法(bare-bones particle swarm optimization, BBPSO)采用关于粒子个体引导者和全局引导者的高斯采样完成粒子位置的更新,并且取消了速度更新公式<sup>[24-25]</sup>,避免了 PSO 算法飞行参数需要调整的缺陷,更加适合于解决污水处理过程多目标优化问题。

本文在分析污水处理过程控制变量、操作变量、优化目标和出水水质性能指标的基础上,采用模糊神经网络(fuzzy neural network, FNN)建立随入水条件改变而动态调整的能耗和水质模型。针对在满足出水水质参数达标的约束条件下,尽量减少能耗和罚款的多目标优化问题,结合含约束 Pareto 支配关系处理机制,提出带自适应扰动的约束多目标骨干粒子群优化算法(constrained bare-bones multi-objective particle swarm optimization, CBBMOPSO)实现对  $S_o$  和  $S_{NO}$  设定值的多目标优化。采用模糊隶属函数法设计智能决策系统确定最优的折衷解作为每个优化周期内控制变量的设定值,底层采用模糊逻辑控制器(fuzzy logic controller, FLC)实现优化设定值的精确跟踪。所有实验均采用国际基准仿真平台(Benchmark Simulation Model No. 1, BSM1)进行仿真测试。

## 1 多目标优化问题

### 1.1 基准仿真模型

为了合理评价污水处理过程不同控制策略,国际水质协会(IWAQ)和欧盟科学技术与合作组织(COST)合作开发了活性污泥污水处理基准仿真模型 BSM1,其总体布局如图 1 所示<sup>[26]</sup>。BSM1 采用典型的前置反硝化脱氮

A/O工艺,由生化反应池和二沉池组成。生化反应池包含五个单元,前两个单元是缺氧区,主要完成反硝化反应,后3个单元是好氧区,主要完成硝化反应<sup>[27]</sup>。生化反应池好氧区第3和第4单元的氧气转换系数要求保持在恒定值240 d<sup>-1</sup>,由于入水流量和组分浓度呈现强非线性关系, $S_o$ 和 $S_{NO}$ 控制器的目标就是分别通过调节第5单元的曝气量 $K_{La5}$ 和内回流量 $Q_a$ 来控制第5单元的溶

解氧浓度( $S_{O,5}$ )和第2单元的硝态氮浓度( $S_{NO,2}$ )达到并跟踪优化设定值。BSM1模型根据某实际污水处理厂连续两周的运行操作数据,设计了晴好天气、阴雨天气和暴雨天气3种不同工况下入水流量和组分浓度的数据文件,采样间隔为15 min<sup>[26]</sup>。图2所示为晴好天气下入水流量和入水 $S_s$ 、 $X_{B,H}$ 、 $S_{NH}$ 浓度,反映了污水处理过程大时变、高  
度非线性、强耦合和不确定性干扰严重的特点<sup>[26-27]</sup>。

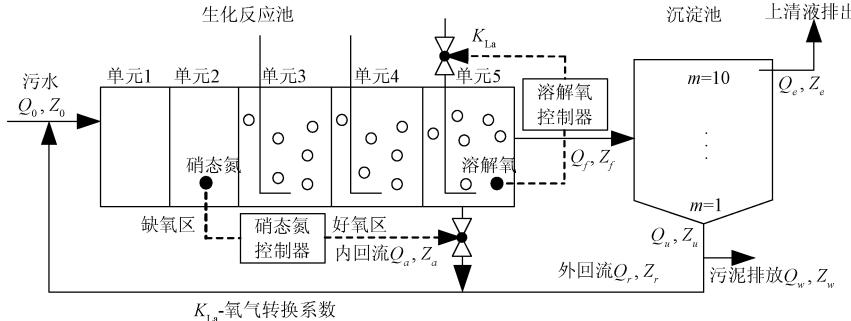
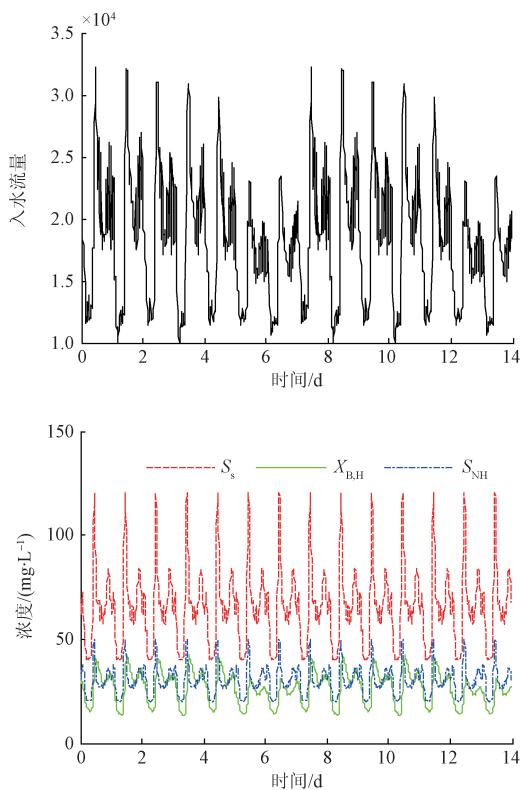


图1 BSM1布局

Fig. 1 Layout of BSM1

图2 晴好天气下入水流量和入水 $S_s$ 、 $X_{B,H}$ 、 $S_{NH}$ 浓度Fig. 2 The influent flow rate and  $S_s$ ,  $X_{B,H}$ ,  $S_{NH}$  concentration in dry weather

## 1.2 多目标优化问题

污水处理过程约束多目标优化问题的实质是通过对

$S_{O,5}$ 和 $S_{NO,2}$ 两个控制变量设定值的优化来处理能耗(EC)和水质(EQ)这两个相互竞争的目标函数,在保证平均出水水质参数达标的前提下,取得EC和EQ之间的最佳平衡。

由于曝气能耗(AE)和泵送能耗(PE)占总能耗的70%以上<sup>[26]</sup>,因此优化问题的EC指标定义为AE和PE之和,即:

$$EC = AE + PE \quad (1)$$

按照BSM1定义,AE和PE的公式为<sup>[25]</sup>:

$$AE = \frac{S_{O,sat}}{T \times 1.8 \times 1000} \int_{kT}^{(k+1)T} \sum_{i=1}^5 V_i \cdot K_{La i}(t) dt \quad (2)$$

$$PE = \frac{1}{1000 T} \int_{kT}^{(k+1)T} (4Q_a(t) + 8Q_r(t) + 50Q_w(t)) dt \quad (3)$$

式中: $V_i$ 和 $K_{La i}$ 分别为第*i*个单元的体积和氧气转换系数, $S_{O,sat}$ 为溶解氧饱和浓度, $T$ 为优化周期, $Q_a$ 、 $Q_r$ 和 $Q_w$ 分别为内回流量、污泥回流量和污泥排放量。

EQ表示向受纳水体排放出水污染物所需支付的罚款,按照BSM1定义,EQ的公式为<sup>[26]</sup>:

$$EQ = \frac{1}{1000 T} \int_{t_0}^t (2SS(t) + COD(t) + 3S_{NKj}(t) + 10S_{NO}(t) + 2BOD_5(t)) Q_e(t) dt \quad (4)$$

式中: $SS$ 、 $COD$ 、 $S_{NKj}$ 、 $S_{NO}$ 和 $BOD_5$ 分别为固体悬浮物浓度、化学需氧量、硝态氮浓度、凯氏氮浓度和5日生化需氧量, $Q_e$ 是上清液排出量。

多目标优化问题的约束条件为平均出水水质参数需要符合BSM1基准中给出的达标限值范围,具体为<sup>[26]</sup>:

$$S_{NH} \leq 4 \text{ mg/L}, N_{tot} \leq 18 \text{ mg/L}$$

$$\begin{aligned} & BOD_5 \leq 10 \text{ mg/L}, COD \leq 100 \text{ mg/L}, \\ & SS \leq 30 \text{ mg/L} \end{aligned} \quad (5)$$

式中:出水总氮  $N_{\text{tot}}$  是出水硝态氮  $S_{\text{NO}_3}$  和出水凯氏氮  $S_{\text{NKj}}$  之和。

综上所述,污水处理过程约束多目标优化问题描述如下:

$$\begin{aligned} \min F(\mathbf{x}) &= \{f_{\text{EC}}(\mathbf{x}), f_{\text{EQ}}(\mathbf{x})\} \\ \text{s. t. } \begin{cases} g_1(\mathbf{x}) = f_1(\mathbf{x}) - 4 \leq 0 \\ g_2(\mathbf{x}) = f_2(\mathbf{x}) - 18 \leq 0 \\ g_3(\mathbf{x}) = f_3(\mathbf{x}) - 10 \leq 0 \\ g_4(\mathbf{x}) = f_4(\mathbf{x}) - 100 \leq 0 \\ g_5(\mathbf{x}) = f_5(\mathbf{x}) - 30 \leq 0 \\ x_1^l \leq x_1(k) \leq x_1^u \\ x_2^l \leq x_2(k) \leq x_2^u \end{cases} \end{aligned} \quad (6)$$

式中: $\mathbf{x} = [x_1, x_2] = [S_{0,sp}, S_{NO,sp}]$  为优化向量; $f_j(\mathbf{x})$  为 5 种出水水质参数与优化向量之间的关系, $j = 1, 2, \dots, 5$ ; $x_1^l$  和  $x_2^l$  是第  $i$  个优化变量的上下限, $i = 1, 2$ 。

## 2 多目标优化控制

由式(1)~(4)可以发现,EC 主要与操作变量  $K_{La5}$  和  $Q_a$  相关,EQ 主要与出水水质参数相关。但是,EC、EQ 与  $S_{0,5}$ 、 $S_{NO,2}$  这两个优化变量之间并没有明确的数学关系,同时构成约束条件的关键出水水质参数也不能在线测量。因此,本文首先利用数据驱动思想构建 EC、EQ 和出水水质参数的 FNN 预测模型。然后,利用 CBBMOPSO 算法对  $S_{0,5}$  和  $S_{NO,2}$  进行动态寻优,进一步利用 FLC 跟踪优化设定值,实现污水处理过程的多目标优化控制。优化控制整体框架如图 3 所示。

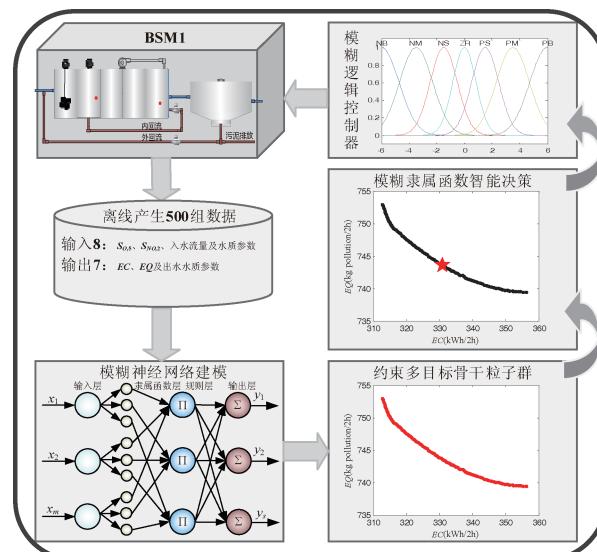


图 3 多目标优化控制结构

Fig. 3 Structure of multi-objective optimal control

### 2.1 模糊神经网络建模

采用 S 型 FNN 建立 EC、EQ 和出水水质参数的预测模型<sup>[28]</sup>, 实现如下的 MIMO 非线性映射:

$$f_k(\mathbf{X}) = \sum_{j=1}^n w_{jk} \varphi_j = \frac{\sum_{j=1}^n w_{jk} \exp\left(-\frac{\|\mathbf{X} - \mathbf{c}_j\|^2}{\delta_j^2}\right)}{\sum_{j=1}^n \exp\left(-\frac{\|\mathbf{X} - \mathbf{c}_j\|^2}{\delta_j^2}\right)} \quad (7)$$

式中: $\mathbf{X} = [x_1, x_2, \dots, x_m]$  为 FNN 的输入向量, $m$  为输入变量数; $\mathbf{c}_j = [c_{1j}, c_{2j}, \dots, c_{mj}]$  和  $\delta_j = [\delta_{1j}, \delta_{2j}, \dots, \delta_{mj}]$  分别为规则层第  $j$  个神经元对应的隶属函数层神经元的高斯函数中心和宽度; $\varphi_j$  是规则层第  $j$  个神经元归一化后的输出; $w_{jk}$  为规则层第  $j$  个神经元与输出层第  $k$  个神经元之间的连接权; $j = 1, 2, \dots, n, n$  为规则层神经元数; $k = 1, 2, \dots, s, s$  为输出变量数。

FNN 的参数学习采用梯度下降算法, 定义目标函数为:

$$E(t) = \frac{1}{2} e_m(t)^2 = \frac{1}{2} (y_d(t) - y(t))^2 \quad (8)$$

式中: $y_d$  是网络期望输出, $y$  为网络实际输出。令  $\boldsymbol{\Theta} = [\mathbf{w}, \mathbf{c}, \boldsymbol{\delta}]^T$  表示参数向量, 则参数更新公式为:

$$\boldsymbol{\Theta}(t+1) = \boldsymbol{\Theta}(t) - \eta \frac{\partial E(t)}{\partial \boldsymbol{\Theta}(t)} \quad (9)$$

式中: $\eta$  为 FNN 参数学习率。实现该算法的函数命名为 FNN\_modeling。

### 2.2 CBBMOPSO 算法

#### 2.2.1 含约束支配关系

考虑粒子  $\mathbf{x}$ , 定义其约束违背程度为:

$$cv(\mathbf{x}) = \sum_{j=1}^J \max(g_j(\mathbf{x}), 0) + \sum_{j=J+1}^K \max(|h_j(\mathbf{x})| - \delta, 0) \quad (10)$$

式中: $g_j(\mathbf{x})$  为粒子  $\mathbf{x}$  的  $J$  个不等式约束条件, $j = 1, 2, \dots, J$ ; $h_j(\mathbf{x})$  为粒子  $\mathbf{x}$  的  $K - J$  个等式约束条件, $j = J + 1, J + 2, \dots, K$ ; $cv(\mathbf{x})$  为粒子  $\mathbf{x}$  的约束违背程度。

结合粒子的多个目标函数值, 对于给定粒子  $\mathbf{x}_1$  和  $\mathbf{x}_2$ , 当解  $\mathbf{x}_1$  优于解  $\mathbf{x}_2$  时, 称  $\mathbf{x}_1$  含约束支配  $\mathbf{x}_2$ , 如果满足如下条件之一<sup>[29]</sup>:1) 两个解均为可行解, 且解  $\mathbf{x}_1$  支配解  $\mathbf{x}_2$ ; 2) 解  $\mathbf{x}_1$  为可行解, 解  $\mathbf{x}_2$  在不可行区域; 3) 解  $\mathbf{x}_1$  和  $\mathbf{x}_2$  均在不可行区域, 且解  $\mathbf{x}_1$  违反约束值较小。实现获取粒子群中非支配解的函数命名为 Non\_dominated。

#### 2.2.2 外部档案维护

类似于大多数的 MOPSO 算法, 本文也采用容量固定的外部档案来保存算法获得的非支配解。自拥挤距离法<sup>[29]</sup>是目前应用较为广泛的方法之一, 能够在一定程度上保持了解的多样性。文献[29]采用的拥挤距离法一次性删除拥挤距离较小的多余非支配解, 容易引起非支

配解多样性的退化。本文采用动态拥挤距离法来评价外部储备集中元素的分布密度,实现外部档案的维护,算法伪代码如图4所示,实现动态拥挤距离法的函数命名为Control\_archive。

假设外部储备集为 $A$ ,产生的新种群为 $S$ ,其中 $A$ 和 $S$ 为输入, $N_a$ 为外部档案的最大容量。在算法2中,Non-dominated( $S_i, A_j$ )用于评价 $S_i$ 和 $A_j$ 之间带约束Pareto支配关系。当 $S_i$ 带约束支配 $A_j$ 时,该函数返回1;否则,当 $A_j$ 带约束支配 $S_i$ 或 $S_i$ 和 $A_j$ 互不支配时,返回-1;最终,算法2将返回更新后的外部储备集 $A$ 。

```

function Control_archive(A,S)
1   for i = 1 to |S|
2     for j = 1 to |A|
3       flag = Non_dominated(Si,Aj);
4       if flag == 1
5         mark Aj as a dominated solution;
6       else if flag == -1
7         mark Si as a dominated solution; break;
8       end if
9     end for
10    delete the marked dominated solutions from A;
11    if Si is not marked as a dominated solution
12      add Si to A;
13      if |A| > Na
14        compute the crowding distance value;
15        delete the one with the worst fitness value;
16      end if
17    end if
18  end for
19  return A;

```

图4 外部档案维护伪代码

Fig. 4 The pseudo-code of outside files maintenance

### 2.2.3 个体引导者选择

粒子的个体引导者 $pbest$ 是当前粒子从初始时刻到目前为止发现的最好位置。采用约束Pareto支配关系来确定个体引导者,其基本思想如下:当粒子发现的新解被旧解约束支配时,则个体引导者不变;当粒子发现的新解约束支配旧解时,则将新解作为个体引导者;而当新解和旧解互不约束支配时,则随机选择一个解作为个体引导者。对某个粒子来说,该方法仅需保存一个个体引导者,算法简单高效。具体更新公式如(11),实现 $pbest$ 选择的函数命名为Select\_pbest。

$$\begin{cases} pbest_i(t+1) = \\ pbest_i(t), F(pbest_i(t)) < F(x_i(t+1)) \\ x_i(t+1), F(x_i(t+1)) < F(pbest_i(t)) \\ random, \text{其他} \end{cases} \quad (11)$$

### 2.2.4 全局引导者选择

粒子全局引导者是当前粒子邻域内所有粒子从初始

时刻到目前为止发现的最好位置,引导着种群的进化方向。对于多目标问题,全局引导者是一组Pareto最优解集,需要为每个粒子从外部档案中选择一个 $gbest$ 。本文采用规模为2的锦标赛选择法选择全局引导者,实现 $gbest$ 选择的函数命名为Select\_gbest。

### 2.2.5 粒子位置更新

通过改进Zhang等人<sup>[25]</sup>提出的方法,设计了具有自适应能力的粒子位置更新公式:

$$\begin{cases} x_{ij}(t+1) = \\ \mu_{ij}(t) + \sigma_{ij}(t)N(0,1), U(0,1) < 0.5 \\ gbest_{ij}(t), \text{其他} \end{cases} \quad (12)$$

$$\mu_{ij}(t) = (r_1 pbest_{ij}(t) + (1 - r_1) gbest_{ij}(t)) \quad (13)$$

$$\sigma_{ij}(t) = |pbest_{ij}(t) - gbest_{ij}(t)| + \Delta \quad (14)$$

$$\Delta = r_2 \sqrt{1 - t/T_{\max}}^{-dis} \quad (15)$$

$$dis = \|pbest_i(t) - gbest_i(t)\|_2 \quad (16)$$

式中: $r_1$ 和 $r_2$ 为 $[0,1]$ 上均匀分布的随机数;高斯采样中心 $\mu_{ij}$ 为 $pbest_{ij}$ 和 $gbest_{ij}$ 之间的随机权重和,这能够进一步扩大粒子的搜索范围;高斯采样的宽度 $\sigma_{ij}$ 为 $pbest_{ij}$ 和 $gbest_{ij}$ 之间的距离加上自适应扰动 $\Delta$ ; $T_{\max}$ 为最大迭代次数; $\Delta$ 与 $pbest_i$ 和 $gbest_i$ 之间欧氏距离以及迭代次数有关,当 $pbest_i$ 接近 $gbest_i$ 时, $\Delta$ 增大;当 $pbest_i$ 远离 $gbest_i$ 时, $\Delta$ 减小;随着迭代次数增加, $\Delta$ 最终趋于0。自适应 $\Delta$ 的引入有助于平衡粒子的探索和开发能力,降低算法陷入局部Pareto前沿的可能性。实现粒子位置更新的函数命名为Up\_particle。

### 2.2.6 变异操作

MOPSO的快速收敛特性使得算法可能会过早地收敛到局部Pareto前沿,因此本文引入时变变异算法,通过变异参数 $\alpha$ 同时调整变异概率和变异范围<sup>[22,25]</sup>,有效地平衡了粒子群算法的探索和开发能力。算法伪代码如图5所示,实现变异操作的函数命名为Mutation。其中, $\alpha$ 为变异参数, $N$ 为粒子群规模, $T_{\max}$ 为算法最大迭代次数, $k$ 为决策变量维数, $r_3 \sim U(0,1)$ , $u_{.j}$ 和 $l_{.j}$ 分别为决策变量上下限

```

function Mutation
1   pm = e(-α × t/Tmax)
2   for i = 1 to N
3     if pm > r3
4       j = random(1, k);
5       range = (u.j - l.j) × pm;
6       xij = xij + N(0,1) × range;
7       end if
8       if xij > u.j then xij = u.j;
9       if xij < l.j then xij = l.j;
10      end for

```

图5 时变变异伪代码

Fig. 5 The pseudo-code of mutation operator

### 2.3 智能决策

面对包含众多等同优秀解的 Pareto 解集,需要从中选取一个偏好解,以确定当前优化周期内  $S_{0,5}$  和  $S_{NO,2}$  的底层控制设定值。本文采用模糊隶属函数法<sup>[25]</sup>设计了智能决策系统。对于第  $i$  个目标函数  $F_i$ ,外部储备集中非支配解  $\mathbf{x}_k$  的满意度定义为:

$$\mu_i^k = \begin{cases} 1, & F_i(\mathbf{x}_k) \leq F_i^{\min} \\ \frac{F_i^{\max} - F_i(\mathbf{x}_k)}{F_i^{\max} - F_i^{\min}}, & F_i^{\min} < F_i(\mathbf{x}_k) < F_i^{\max} \\ 0, & F_i(\mathbf{x}_k) \geq F_i^{\max} \end{cases} \quad (17)$$

式中: $F_i^{\max}$  和  $F_i^{\min}$  分别是第  $i$  个目标函数  $F_i$  的最大值和最小值。归一化的非支配解  $\mathbf{x}_k$  的满意度为:

$$\mu^k = \frac{\sum_{i=1}^M \mu_i^k}{\sum_{k=1}^{|A_r|} \sum_{i=1}^M \mu_i^k} \quad (18)$$

式中: $M$  是目标个数,  $|A_r|$  是外部储备集元素个数。选取  $\mu^k$  的最大值对应的解为偏好解。实现智能决策的函数命名为 Decision\_maker。

### 2.4 模糊逻辑控制器

当 CBBMOPSO 算法产生  $S_{0,5}$  和  $S_{NO,2}$  优化设定值后,底层需要通过控制器跟踪设定值。BSM1 基准中底层采用 PID 控制,由于 PID 控制参数固定,跟踪效果不太理想。本文分别设计了  $S_{0,5}$  和  $S_{NO,2}$  两个二维模糊逻辑控制器,FLC 的输出为:

$$\Delta u(t) = -K_{\Delta u} \text{Fuzzy}(K_e e, K_{\Delta e} \Delta e) \quad (19)$$

式中: $K_e$ 、 $K_{\Delta e}$  和  $K_{\Delta u}$  分别是误差  $e$ 、误差变化量  $\Delta e$  和操作量变化量  $\Delta u$  的量化因子。FLC 输入输出量均模糊化成 7 个模糊子集,即:

$$\{NB, NM, NS, ZO, PS, PM, PB\} \quad (20)$$

其中, $NB$ 、 $NM$ 、 $NS$ 、 $ZO$ 、 $PS$ 、 $PM$  和  $PB$  分别为负大、负中、负小、零、正小、正中和正大。输入输出量的模糊论域  $E$ 、 $\Delta E$  和  $\Delta U$  的范围为  $[-6, 6]$ 。

FLC 选用高斯函数作为隶属度函数,并令离原点近的函数曲线较陡,离原点远的函数曲线较缓,这有利于提高跟踪速度和跟踪精度,  $E$ 、 $\Delta E$  和  $\Delta U$  的模糊隶属函数如图 6 所示。

根据污水处理过程专家控制经验,模糊规则的设计原则为偏差较大时以快速逼近设定值为原则进行调节,偏差较小时以确保控制精度为原则进行细调节。建立的规则表如表 1 所示。

模糊控制过程中,  $\Delta U$  的计算必须按照模糊规则进行模糊推理得到。经模糊推理后,FLC 的输出  $\Delta U$  还需乘以量化因子进行反模糊化处理以得到  $\Delta u$  的精确值。实现模糊控制的函数命名为 FLC\_tracking。

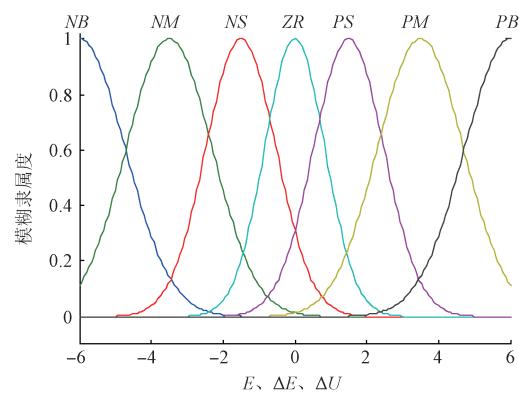


图 6 模糊隶属度函数曲线

Fig. 6 Curves of fuzzy membership function

表 1 模糊控制规则表

Table 1 Fuzzy control rules

$E$	$\Delta E$						
	NB	NM	NS	ZO	PS	PM	PB
NB	NB	NB	NB	NB	NM	NS	ZO
NM	NB	NB	NM	NM	NS	ZO	PS
NS	NB	NB	NM	NS	ZO	PM	PM
ZO	NM	NM	NS	NS	PS	PM	PM
PS	NM	NM	ZO	ZO	PM	PB	PB
PM	NS	ZO	PS	PM	PM	PB	PB
PB	ZO	PS	PM	PB	PB	PB	PB

### 2.5 算法实现

基于 CBBMOPSO-FLC 的污水处理过程动态多目标优化控制算法的总体流程如下。

1) 以优化周期为间隔,在优化变量的上下限内随机生成设定值,利用 BSM1 基准离线产生 500 组包含  $S_{0,5}$ 、 $S_{NO,2}$  和入水水质参数作为输入以及  $EC$ 、 $EQ$  和出水水质参数作为输出的建模数据,调用 FNN-modeling 函数建立  $EC$ 、 $EQ$  和出水水质参数预测模型。

2) 初始化参数。设定 FLC 的量化因子  $K_e$ 、 $K_{\Delta e}$  和  $K_{\Delta u}$ ;设定粒子群初始种群规模  $N$ ,最大外部档案容量  $N_a$ ,最大迭代次数  $T_{\max}$ ,变异参数  $\alpha$ 。

3) 在决策空间随机初始化所有粒子,调用 FNN-modeling 函数,对  $N$  个粒子分别计算  $M$  个目标函数值,形成初始种群  $P^{(0)}$ ;初始化粒子的个体引导者  $pbest$  为当前粒子位置,初始化外部档案  $A_r$  为空;令迭代次数  $t=0$ 。

4) 调用 Non-dominated 函数将粒子群中的非支配解加入外部档案  $A_r$ ,并调用 Control\_archive 函数对  $A_r$  进行维护,形成  $A_r^{(0)}$ 。调用 Select\_gbest 函数为每一个粒子从外部档案  $A_r^{(0)}$  中选出  $gbest$ 。

5) 令  $t=t+1$ ,开始进行循环迭代。

6) 调用 Up\_particle 函数更新粒子位置,调用

Mutation 函数实施变异操作, 调用 FNN\_modeling 函数评价新粒子的目标函数值, 形成种群  $P^{(t)}$ 。

7) 调用 Select\_pbest 函数更新个体引导者  $pbest$ ; 调用 Non-dominated 函数将粒子群  $P^{(t)}$  中的非支配解加入外部档案  $A_r^{(t-1)}$ , 然后调用 Control\_archive 函数对其进行进一步维护, 形成  $A_r^{(t)}$ ; 调用 Select\_gbest 函数更新全局引导者  $gbest$ 。

8) 若算法满足终止条件, 则跳出循环, 并输出外部档案  $A_r^{(t)}$  中的非支配解; 否则返回步骤 5) 继续循环迭代。

9) 调用 Decision\_maker 函数从非支配解中选取一个最偏好的解并赋值给  $[S_{O_{sp}}, S_{NO_{sp}}]$ 。

10) 调用 FLC\_tracking 函数对  $[S_{O_{sp}}, S_{NO_{sp}}]$  优化设定值进行跟踪控制并持续到当前优化周期结束。若 BSM1 连续 14 d 数据仿真完毕, 则结束; 否则, 返回步骤 3) 进行下一个优化周期的优化控制。

### 3 实验验证

#### 3.1 参数设置

所有实验均采用 MATLAB R2013b 编程环境, 运行算法的计算机采用四核配置, 主频为 2.9 GHz。控制器的采样周期对控制性能有着重要的影响, 本文控制器采样周期为 45 s, 优化周期为 2 h, 采用晴好天气数据进行仿真分析; FNN 的结构为 8-140-20-7, 参数学习率  $\eta = 0.01$ ; CBBMOPSO 算法中  $N = 50, N_a = 50, T_{\max} = 100, \alpha = 7; S_{O_{sp}}$  和  $S_{NO_{sp}}$  的优化设定范围为 0.4 ~ 3 mg/L 和 0.2 ~ 2 mg/L,  $S_{O_{sp}}$  模糊控制器的  $K_e, K_{\Delta e}$  和  $K_{\Delta u}$  分别为 24、16 和 10,  $S_{NO_{sp}}$  模糊控制器的  $K_e, K_{\Delta e}$  和  $K_{\Delta u}$  分别为 24、80 和 5 000。

#### 3.2 结果和分析

对于 500 组离线建模数据, 随机选取其中 450 组作为训练集, 剩余 50 组作为测试集, 利用 FNN 进行建模, 能耗指标 EC、出水水质指标 EQ 预测效果如图 7 所示。

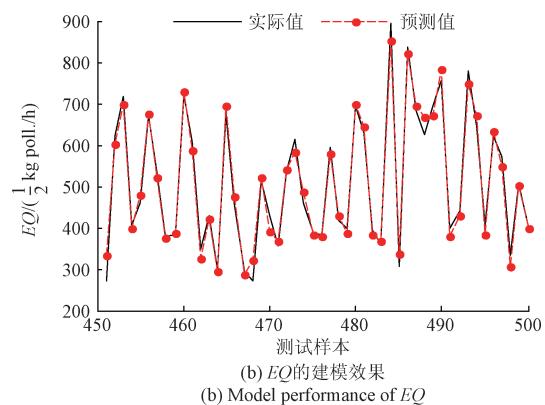
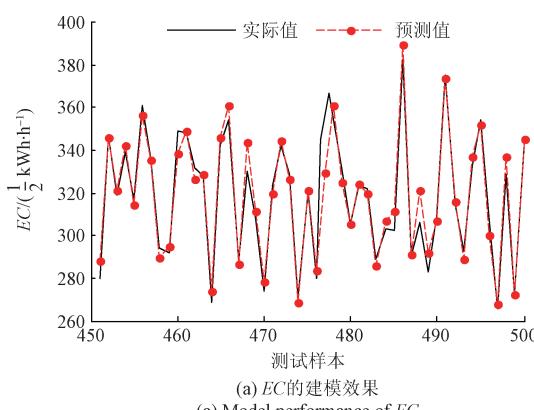


图 7 EC 和 EQ 的建模效果

Fig. 7 Modelling result of EC and EQ

可以看出, 预测模型的精度是令人满意的, 可以作为多目标算法的优化模型。由于 BOD、COD 和 TSS 一般不会超标, 故可以不建立其预测模型。

图 8 给出了优化算法在第 4 d 第 7 个优化周期初始时刻获得的 Pareto 最优解集及利用智能决策算法确定最优折衷解, 可以清晰地看出, 寻找到的非支配解分布均匀, 获取的优化设定值在保证出水水质参数达标前提下能最大程度降低能耗。

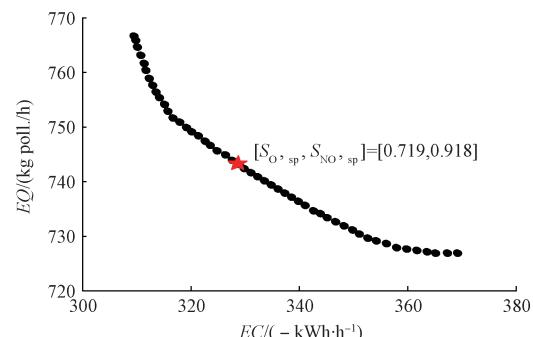
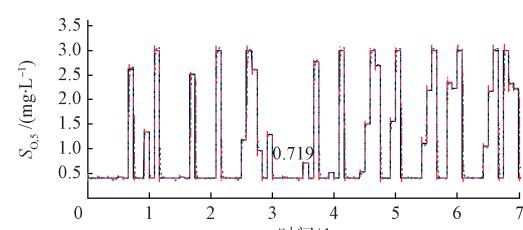


图 8 Pareto 最优解集及最优折衷解确定

Fig. 8 Pareto optimal solutions and identification of optimal compromise solution

图 9 给出了优化控制得到的  $S_{O_{sp}}$  和  $S_{NO_{sp}}$  以及底层跟踪控制效果, 图 10 给出了优化控制和 PID 恒定值控制下 5 种出水水质参数变化情况。



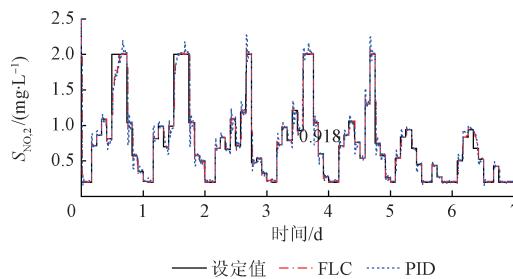


图 9 溶解氧和硝态氮优化设定值及跟踪效果

Fig. 9 Optimized set-value and tracking effect of  $S_O_2$  and  $S_{NO_2}$ 

由图 9 可以看出,在污水处理优化控制过程中,  $S_{O_2}$  和  $S_{NO_2}$  通过动态调整,使得 EC 和 EQ 这对相互冲突的目标达到最佳平衡,调整规律与图 2 所示的入水流量和水质参数的变化趋势基本吻合。相比 BSM1 模型自带的底层

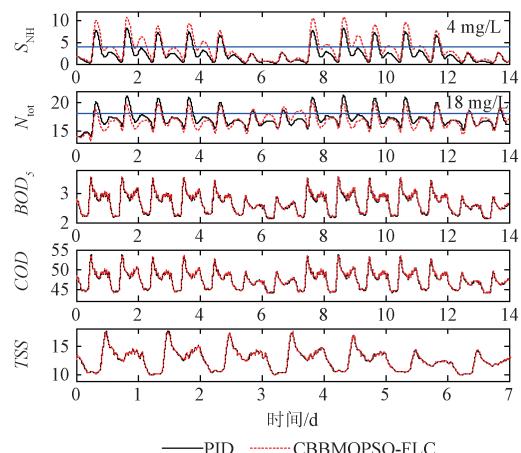


图 10 出水水质参数变化情况

Fig. 10 Change of effluent quality parameters

表 2 晴好天气工况下不同优化控制策略的能耗和出水水质比较

Table 2 Comparison of EC and EQ with different optimal control strategies in the dry weather

Weather	Method	AE		PE		EC		EQ	
		kWh · d <sup>-1</sup>	kWh · d <sup>-1</sup>	kWh · d <sup>-1</sup>	Up/Down	(kg poll./d)	Up/Down		
Dry	Open-Loop	3 341.26	388.15	3 729.41	—	6 590.53	—		
	PID	3 676.28	231.33	3 907.61	—	6 096.63	—		
	Hopfield <sup>[8]</sup>	3 435.11	267.22	3 702.33	↓ 5.30% *	—	—		
	DDAOC <sup>[12]</sup>	—	—	3 700.54	↓ 5.30% *	—	—		
	SOOC <sup>[19]</sup>	3 592.87	226.75	3 819.72	↓ 2.25%	6 205.84	↑ 1.79%		
	DMOOC <sup>[19]</sup>	3 577.80 *	233.84 *	3 705.63	↓ 5.14% *	6 466.75 *	↑ 6.07% *		
	CBBMOPSO-FLC	<b>3 406.71</b>	<b>249.60</b>	<b>3 656.31</b>	↓ 6.43%	<b>6 348.67</b>	↑ 4.13%		

注: \* 表示参考了原文给出的结果

表 3 晴好天气工况下不同优化控制策略的平均出水水质参数比较

Table 3 Comparison of average effluent parameters with different quality optimal control strategies in the dry weather

Weather	Method	$S_{NH}$	$N_{tot}$	$BOD_5$	COD	TSS
Dry	Limit	4	18	10	100	30
	influent	30.14	51.47	70.57	167.3	198.57
	Open-loop	4.57	13.54	2.69	47.54	12.58
	PID	2.30	16.99	2.67	47.47	12.59
	Hopfield <sup>[8]</sup>	3.24	14.92	2.69	47.55	12.62
	DDAOC <sup>[12]</sup>	2.73	15.84	3.11	44.89	—
	SOOC <sup>[19]</sup>	3.05 *	16.31 *	—	—	—
	DMOOC <sup>[19]</sup>	3.19 *	17.33 *	—	—	—
	<b>CBBMOPSO - FLC</b>	<b>3.61</b>	<b>15.65</b>	<b>2.69</b>	<b>47.54</b>	<b>12.61</b>

注: \* 表示参考了原文给出的结果

PID 控制, FLC 的控制精度更高。由图 10 可以看出,相比于 PID 恒定值控制,优化控制方法下,  $N_{tot}$  浓度总体呈现下降趋势,而  $S_{NH}$  浓度在峰值处略有上升。从污水处理过程机理分析可知,  $N_{tot}$  和  $S_{NH}$  是一对具有相互竞争关系的出水水质参数,通过多目标优化算法能够取得这两者之间的最佳平衡。

表 2 和 3 分别给出了晴好天气下采用不同控制策略

时 AE、PE、EC、EQ 和 5 种平均出水水质参数的具体情况。其中,Open-Loop 表示开环控制,曝气量  $K_{LaS}$  和内回流量  $Q_a$  保持初始值;PID 为恒定值控制,即  $S_{O_2}$  和  $S_{NO_2}$  分别取 2 和 1 mg/L。

从表 2 可以看出,相比于 PID 恒定值控制,CBBMOPSO-FLC 优化控制方法下,总能耗 EC 下降了 6.43%,出水水质指标 EQ 上升了 4.13%,这表明多目标

表4 阴雨天气和暴雨天气工况下不同控制策略的能耗和出水水质比较

Table 4 Comparison of EC and EQ with different optimal control strategies in the rain and storm weather

Weather	Method	AE		PE		EC		EQ	
		kWh · d <sup>-1</sup>	kWh · d <sup>-1</sup>	kWh · d <sup>-1</sup>	Up/Down	(kg poll./d)	Up/Down		
Rain	Open-Loop	3 341.26	388.16	3 729.42	-	7 701.80	-		
	PID	3 664.92	253.09	3 918.01	-	7 112.12	-		
	SOOC <sup>[19]</sup>	3 572.91	257.98	3 830.89	↓ 2.20% *	7 215.23	↑ 1.45% *		
	DMOOC <sup>[19]</sup>	3 459.12	264.66	3 723.78	↓ 4.94% *	7 368.96	↑ 3.61% *		
	<b>CBBMOPSO-FLC</b>	<b>3 387.63</b>	<b>288.63</b>	<b>3 676.26</b>	<b>↓ 6.17%</b>	<b>7 461.33</b>	<b>↑ 4.91%</b>		
Storm	Open-Loop	3 341.26	388.16	3 729.42	-	7 244.26	-		
	PID	3 687.47	243.65	3 931.12	-	6 635.92	-		
	SOOC <sup>[19]</sup>	3 572.91	257.98	3 830.89	↓ 2.20% *	7 215.23	↑ 1.45% *		
	DMOOC <sup>[19]</sup>	3 425.43	268.88	3 694.32	↓ 5.99% *	7 055.32	↑ 6.32% *		
	<b>CBBMOPSO-FLC</b>	<b>3 354.61</b>	<b>279.71</b>	<b>3 634.32</b>	<b>↓ 7.55%</b>	<b>7 089.82</b>	<b>↑ 6.84%</b>		

注: \* 表示参考了原文给出的结果

优化控制能够实现节能降耗的目的。同时,结果也清晰地表明了污水处理过程 EC 和 EQ 是一对相互冲突的优化目标,即 EC 的下降必然引起 EQ 的上升;反之,想要取得较低的 EQ,则必然需要较大的 EC。此外,SOOC 方法节能效果有待进一步提高,DMOOC 方法的 EQ 明显增大。

从表3可以看出,CBBMOPSO-FLC 优化控制方法下,虽然  $S_{\text{NH}}$  有所上升,但是 5 种平均出水水质参数均在达标限值范围内,完全符合排放标准。需要指出的是,除了开环控制之外的所有控制方法均能够保证平均出水水质参数满足排放标准。从出水污染物去除率的角度分析,采用 CBBMOPSO-FLC 优化控制方法,相比入水水质参数,出水  $S_{\text{NH}}$ 、 $N_{\text{tot}}$ 、 $BOD_5$ 、 $COD$  和 TSS 的去除率分别达到了 88.20%、67.83%、96.19%、71.58% 和 93.65%。

为了进一步考察本文所提 CBBMOPSO-FLC 优化控制策略的有效性和对复杂工况的适应性,利用 BSM1 基准平台中的阴雨天气和暴雨天气两个入水文件进行实验验证。表4给出了阴雨天气和暴雨天气工况下不同优化控制策略的 EC 和 EQ 比较结果,表明本文优化控制方法在复杂天气条件下也取得不错的节能效果。

## 4 结 论

针对活性污泥法污水处理过程能耗和出水水质难以平衡的问题,提出了基于约束多目标骨干粒子群的智能优化控制方法。构建了以出水水质参数为约束,能耗和出水水质指标为优化目标的约束多目标优化模型,实现了对溶解氧和硝态氮设定值的在线动态优化。根据理论

分析和实验结果得出如下结论:

- 1) 利用数据驱动思想构建的能耗和出水水质模糊神经网络预测模型能够模拟真实的污水处理反应过程,模型精度达到作为优化目标的要求;
- 2) 根据约束 Pareto 支配关系,构建的带自适应扰动的约束多目标骨干粒子群算法寻优能力较强,克服了传统粒子群算法对惯性权重和学习因子敏感的不足,能够获得具有较好分布性的 Pareto 前沿,较为适合于实际工程应用;
- 3) 利用模糊隶属函数法设计的智能决策系统能够从 Pareto 前沿选取最偏好的折衷解,利用多变量模糊控制器对其进行跟踪控制,控制精度较高;
- 4) BSM1 的实验结果表明多目标优化控制方法在保证出水水质达标的同时,能够有效地降低能耗,为污水处理过程的优化控制提供了有价值的参考。

## 参 考 文 献

- [1] SHANNON M A, BOHN P W, ELIMELECH M, et al. Science and technology for water purification in the coming decades [J]. Nature, 2008, 452 (7185): 301-310.
- [2] HAMILTON R, BRAUN B, DARE R, et al. Control issues and challenges in wastewater treatment plants [J]. IEEE Control Systems, 2006, 26(4): 63-69.
- [3] ÅMAND L, CARLSSON B. Optimal aeration control in a nitrifying activated sludge process [J]. Water Research, 2012, 46(7): 2101-2110.
- [4] GUERRERO J, GUIASOLA A, VILANOVA R, et al. Improving the performance of a WWTP control system by model-based setpoint optimisation [J]. Environmental

- Modelling & Software, 2011, 26(4): 492-497.
- [5] 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.
- [6] CHACHUAT B, ROCHE N, LATIFI M A. Long-term optimal aeration strategies for small-size alternating activated sludge treatment plants [J]. Chemical Engineering and Processing: Process Intensification, 2005, 44(5): 591-604.
- [7] HREIZ R, LATIFI M A, ROCHE N. Optimal design and operation of activated sludge processes: State-of-the-art[J]. Chemical Engineering Journal, 2015, 281(12): 900-920.
- [8] 韩广, 乔俊飞, 韩红桂, 等. 基于 Hopfield 神经网络的污水处理过程优化控制 [J]. 控制与决策, 2014, 29(11):2085-2088.
- HAN G, QIAO J F, HAN H G, et al. Optimal control for wastewater treatment process based on Hopfield neural network [J]. Control and Decision, 2014, 29 (11): 2085-2088.
- [9] OSTACE G S, BAEZA J A, GUERRERO J, et al. Development and economic assessment of different WWTP control strategies for optimal simultaneous removal of carbon, nitrogen and phosphorus [J]. Computers & Chemical Engineering, 2013, 53 (4): 164-177.
- [10] SANTIN I, PEDRET C, VILANOVA R. Applying variable dissolved oxygen set point in a two level hierarchical control structure to a wastewater treatment process [J]. Journal of Process Control, 2015, 28(4): 40-55.
- [11] MACHADO V C, GABRIEL D, LAFUENTE J, et al. Cost and effluent quality controllers design based on the relative gain array for a nutrient removal WWTP [J]. Water Research, 2009, 43(20): 5129-5141.
- [12] QIAO J F, BO Y C, CHAI W, et al. Adaptive optimal control for a wastewater treatment plant based on a data-driven method [J]. Water Science and Technology, 2013, 67(10): 2314-2320.
- [13] ZHANG R, XIE W M, YU H Q, et al. Optimizing municipal wastewater treatment plants using an improved multi-objective optimization method [J]. Bioresource Technology, 2014, 157(4): 161-165.
- [14] DAI H, CHEN W, LU X. The application of multi-objective optimization method for activated sludge process: A review [J]. Water Science and Technology, 2016, 73(2): 223-235.
- [15] HAKANEN J, SAHLSTEDT K, MIETTINEN K. Wastewater treatment plant design and operation under multiple conflicting objective functions [J]. Environmental Modelling & Software, 2013, 46 (7): 240-249.
- [16] SWEETAPPLE C, FU G, BUTLER D. Multi-objective optimisation of wastewater treatment plant control to reduce greenhouse gas emissions [J]. Water Research, 2014, 55(5): 52-62.
- [17] HREIZ R, ROCHE N, BENYAHIA B, et al. Multi-objective optimal control of small-size wastewater treatment plants [J]. Chemical Engineering Research and Design, 2015, 102(10): 345-353.
- [18] CHEN W, LU X, YAO C. Optimal strategies evaluated by multi-objective optimization method for improving the performance of a novel cycle operating activated sludge process [J]. Chemical Engineering Journal, 2015, 260(1): 492-502.
- [19] QIAO J, ZHANG W. Dynamic multi-objective optimization control for wastewater treatment process [C]. Neural Computing and Applications, 2016: 1-11.
- [20] KENNEDY J, EBERHART R C. Particle swarm optimization [C]. IEEE International Conference on Neural Network, 1995: 1942-1948.
- [21] ZITZLER E, THIELE L, LAUMANNS M, et al. Performance assessment of multiobjective optimizers: An analysis and review [J]. IEEE Transactions on Evolutionary Computation, 2003, 7(2): 117-132.
- [22] COELLO C A C, PULIDO G T, LECHUGA M S. Handling multiple objectives with particle swarm optimization [J]. IEEE Transactions on Evolutionary Computation, 2004, 8(3): 256-279.
- [23] HU W, YEN G G. Adaptive multiobjective particle swarm optimization based on parallel cell coordinate system [J]. IEEE Transactions on Evolutionary Computation, 2015, 19(1): 1-18.
- [24] KENNEDY J. Bare bones particle swarms [C]. Swarm Intelligence Symposium, IEEE, 2003: 80-87.
- [25] ZHANG Y, GONG D W, DING Z. A bare-bones multi-objective particle swarm optimization algorithm for environmental/economic dispatch [J]. Information Sciences, 2012, 192 (6): 213-227.
- [26] JEPPSSON U, PONS M N. The COST benchmark simulation model-current state and future perspective [J]. Control Engineering Practice, 2004,

- 12(3): 299-304.
- [27] QIAO J F, HAN G, HAN H G. Neural network on-line modeling and controlling method for multi-variable control of wastewater treatment processes [J]. Asian Journal of Control, 2014, 16(4): 1213-1223.
- [28] HAN H G, QIAO J F. A self-organizing fuzzy neural network based on a growing-and-pruning algorithm [J]. IEEE Transactions on Fuzzy Systems, 2010, 18(6): 1129-1143.
- [29] DEB K, PRATAP A, AGARWAL S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II [J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182-197.

### 作者简介



周红标(通讯作者),2003年于淮阴工学院获得学士学位,2009年于兰州理工大学获得硕士学位,现为淮阴工学院讲师,主要研究方向为污水处理智能优化控制。

E-mail:hyitzhb@123.com

**Zhou Hongbiao** (Corresponding author)

received B. Sc. from Huaiyin Institute of Technology in 2003 and M. Sc. from Lanzhou University of Technology in 2009, respectively. Now he is lecturer in Huaiyin Institute of Technology. His main research interests include neural networks, multi-objective optimization, and optimal control for wastewater treatment process.

## NI宣布业界首款基于Thunderbolt™ 3的PXI系统远程控制解决方案

全新的PXI远程控制模块,让高性价比PXI控制器产品系列如虎添翼

NI(美国国家仪器公司,National Instruments,简称NI)近日宣布推出PXIE-8301远程控制模块,这是业界首款使用Thunderbolt™ 3技术,通过笔记本电脑控制PXI系统的解决方案。

PXIE-8301可通过2个Thunderbolt 3端口,提供PCI Express Gen 3连接功能,不仅提供最高性能,还可实现高达2.3 GB/s的持续数据吞吐量。工程师可使用第二个端口,以菊链方式连接额外的Thunderbolt 3或USB-C设备。PXIE-8301具有现代连接功能且性价比高,使得工程师能够以经济实惠的方式对PXI系统进行高性能控制,方便他们进行台式设备特性分析和验证或者开发可携式自动化测试系统。

“过去20年来,PXI平台已备受厂商与客户所青睐,并广泛应用于多种不同的领域,”NI杰出工程师兼PXI系统联盟(PXI Systems Alliance)主席Mark Wetzel表示,“基于Thunderbolt 3的远程控制模块的出现,不仅能展现PXI平台集成最新商用技术的能力,更能让PXI平台进一步覆盖高性能、低成本且超便携的应用领域。”

PXIE-8301进一步丰富了NI的高性价比PXI控制器系列,该系列最近还推出一款嵌入式PXI控制器PXIE-8821。PXIE-8821专为测试与测量应用而设计,搭载了2.6 GHz Intel Core i3-4110E双核心处理器,最高可提供2 GB/s系统带宽。由于嵌入式控制器具备工业评级性能、外形小巧与生命周期管理完善等优点,是在恶劣工作环境中长久部署PXI系统的理想选择。

远程控制模块与嵌入式控制器是NI平台与生态系统非常重要的一部分,旨在帮助工程师轻松构建更智能的测试系统。这些测试系统将受益于从直流到毫米波等不同工作频率范围的600多个PXI产品。它们采用PCI Express第三代总线接口,具有高吞吐量数据移动,同时具有纳秒级同步以及集成的定时和触发。NI平台受到一个由合作伙伴、附加IP和应用工程师组成的活跃生态系统的支持,可帮助工程师大幅降低测试成本,缩短上市时间以及确保测试装置能够适应未来需求,解决未来挑战。