数据和知识驱动的城市污水处理过程多目标优化控制

韩红桂 [1] 张琳琳 [1] 伍小龙 [1] 乔俊飞 [1]

摘 要 城市污水处理过程优化控制是降低能耗的有效手段, 然而, 如何提高出水水质的同时降低能耗依然是当前城市污水处理过程面临的挑战. 围绕上述挑战, 文中提出了一种数据和知识驱动的多目标优化控制 (Data-knowledge driven multiobjective optimal control, DK-MOC) 方法. 首先, 建立了出水水质、能耗以及系统运行状态的表达关系, 获得了运行过程优化目标模型. 其次, 提出了一种基于知识迁徙学习的动态多目标粒子群优化算法, 实现了控制变量优化设定值的自适应求解. 最后, 将提出的 DK-MOC 应用于城市污水处理过程基准仿真模型 1 (Benchmark simulation model No. 1, BSM1). 结果表明该方法能够实时获取控制变量的优化设定值, 提高了出水水质, 并且有效降低了运行能耗.

关键词 城市污水处理过程, 数据和知识驱动方法, 多目标优化控制, 知识迁徙学习, 动态多目标粒子群优化

引用格式 韩红桂, 张琳琳, 伍小龙, 乔俊飞. 数据和知识驱动的城市污水处理过程多目标优化控制. 自动化学报, 2021, **47**(11): 2538−2546

DOI 10.16383/j.aas.c210098

Data-knowledge Driven Multiobjective Optimal Control for Municipal Wastewater Treatment Process

HAN Hong-Gui[1] ZHANG Lin-Lin[1] WU Xiao-Long[1] QIAO Jun-Fei[1]

Abstract The optimal control is an effective method to reduce energy consumption for municipal wastewater treatment process. However, it is still a challenge to improve the effluent qualities and reduce energy consumption simultaneously for the municipal wastewater treatment process. To solve this problem, a data-knowledge driven multiobjective optimal control (DK-MOC) method is proposed in this paper. First, the expression relationship among effluent qualities, energy consumption and system operation state is established to obtain the operational optimal objective model. Second, a dynamic multiobjective particle swarm optimization algorithm, based on knowledge transfer learning method, is proposed to obtain the optimal set-points of control variables adaptively. Finally, the proposed DK-MOC method is applied to the benchmark simulation model No. 1 (BSM1) of the municipal wastewater treatment process. The results demonstrate that this proposed method can obtain the optimal set-points of control variables online, which not only improve the effluent qualities, but also reduce the operation energy consumption effectively.

Key words Municipal wastewater treatment process, data-knowledge driven method, multiobjective optimal control, knowledge transfer learning method, dynamic multiobjective particle swarm optimization

Citation Han Hong-Gui, Zhang Lin-Lin, Wu Xiao-Long, Qiao Jun-Fei. Data-knowledge driven multiobjective optimal control for municipal wastewater treatment process. *Acta Automatica Sinica*, 2021, **47**(11): 2538−2546

城市污水处理过程通过微生物吸附、分解以及氧化等过程, 将污水中的污染物去除, 是维持水资源可持续利用的重要手段[1−3]. 近年来, 随着城市污水排放量不断增加和国家排放标准的日趋严格, 城市污水处理厂规模不断增容, 导致城市污水处理过程运行能耗逐渐增大, 且出水水质不稳定[4−6]. 因此, 如何降低运行能耗和提高出水水质是城市污水处理过程亟待解决的问题.

为了降低城市污水处理过程运行能耗, Sun 等提出了基于活性污泥 2d 模型的优化控制策略, 该优化控制策略建立了能耗与化学需氧量 (Chemical oxygen demand, COD)、生化需氧量 (Biochemical oxygen demand, BOD)、氨氮、总氮等状态变量的关系, 利用氨氮偏差计算溶解氧浓度的优化设定

收稿日期 2021-02-10 录用日期 2021-05-28
Manuscript received February 10, 2021; accepted May 28, 2021
国家重点研发项目 (2018YFC1900800-5), 国家自然科学基金 (61890930-5, 61903010, 62021003), 北京市卓越青年科学家计划项目 (BJJWZYJH01201910005020), 北京市自然科学基金 (KZ202110005009) 资助
Supported by National Key Research and Development Project (2018YFC1900800-5), National Natural Science Foundation of China (61890930-5, 61903010, 62021003), Beijing Outstanding Young Scientist Program (BJJWZYJH01201910005020), and Beijing Natural Science Foundation (KZ202110005009)
本文责任编委 王卓
Recommended by Associate Editor WANG Zhuo
1. 北京工业大学信息学部, 计算智能与智能系统北京市重点实验室 北京 100124
1. Faculty of Information Technology, Beijing University of Technology, Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing 100124

值[7]. 应用结果表明, 该优化控制策略能够有效降低能耗. De Gussem 等提出了一种能耗实时优化控制策略, 该优化控制策略采用活性污泥能耗模型实现能耗与城市污水处理过程运行状态之间的关系描述, 并基于计算流体力学完成曝气池中叶轮开闭数量优化[8]. 应用效果表明, 该优化控制策略可以在不影响有机物去除效率的情况下降低能耗. 上述优化控制策略构建了基于机理分析的能耗目标模型描述城市污水处理过程运行能耗与运行状态变量的关系. 然而, 由于城市污水处理过程入水流量、入水水质等动态变化, 模型精度难以保证, 影响优化控制效果[9−11]. 因此, 基于数据驱动优化目标模型的优化控制方法获得了一些学者的关注, Zeng 等提出了基于混合整数非线性规划模型的优化控制方法, 该优化控制方法完成了泵送能耗与泵送速度、操作时间的动态关系表达, 并采用贪婪类电磁机制算法获取最优的泵送速度和操作时间[12]. 仿真结果表明, 该优化控制方法可以显著地降低城市污水处理过程泵送能耗. Filipe 等提出了能耗优化控制策略, 该优化控制策略采用梯度增强树建立了泵送能耗与运行状态变量之间的动态关系, 并基于深度强化学习实现控制变量优化设定值的求解[13]. 仿真结果表明, 该优化控制策略可以有效节约城市污水处理过程泵送能耗. 然而, 城市污水处理过程出水水质也是一个重要的运行指标, 如何降低城市污水处理过程能耗的同时提高出水水质是亟待解决的问题[14−16].

为了同时优化能耗和出水水质, Vega 等提出了实时优化控制策略, 该优化控制策略采用实时优化算法实现溶解氧和硝态氮浓度优化设定值的求解[17]. 仿真结果表明, 该优化控制策略能够在降低能耗成本的同时提高出水水质. Zhang 等提出了基于城市污水处理过程动态特征的优化控制方法, 该优化控制方法采用动态遗传算法求解水力停留时间、内循环比等控制变量的优化设定值, 并利用反向传播算法获取能耗和出水水质的权重系数[18]. 仿真结果表明, 该优化控制方法能够有效降低城市污水处理过程能耗并提高出水水质. 上述两种优化控制策略主要通过引入权重系数, 将多目标优化问题转化为单目标优化问题对控制变量设定值进行求解. 然而, 由于城市污水处理过程运行状态难以确定, 导致权重系数难以准确获取[19−20]. 因此, De Faria 等提出了基于档案多目标进化算法的优化控制策略, 该优化控制策略能够通过 Pareto 支配关系平衡能耗成本、出水水质和生命周期影响, 获得合适的溶解氧浓度、外部碳源等控制变量优化设定值[21]. 仿真结果表明, 该优化控制策略有效降低了能耗成本, 提高了出水水质. Qiao 等提出了基于自适应多目标差分进化算法的优化控制策略, 该优化控制策略能够获取合适的溶解氧和硝态氮浓度的优化设定值, 实现了城市污水处理过程能耗和出水水质同时优化[22]. 另外, 一些学者提出了基于多目标优化算法的优化控制方法同时优化了能耗和出水水质[23−25]. 然而, 城市污水处理过程优化目标模型是时变的, 如何获得有效的控制变量优化设定值依然是城市污水处理过程面临的挑战性问题[26].

城市污水处理过程优化控制方法主要包括以下三个过程: 首先, 建立运行过程目标模型, 描述运行目标与系统状态变量的动态特征; 其次, 设计优化方法, 获取控制变量优化设定值; 最后, 利用控制器跟踪设定值, 实现城市污水处理过程优化控制[27−29]. 文中提出了一种数据和知识驱动的多目标优化控制 (Data-knowledge driven multiobjective optimal control, DK-MOC) 方法, 主要贡献如下:

1) 设计基于自适应模糊神经网络 (Adaptive fuzzy neural network, AFNN) 的数据驱动优化目标模型, 描述能耗、出水水质以及相关状态变量的动态关系.

2) 提出基于知识迁徙学习的动态多目标粒子群优化算法, 将目标变化前具有较好分布性的解应用于目标变化后控制变量设定值的求解过程, 并检测种群进化状态调整种群进化方向, 提高种群的搜索性能, 获取有效的控制变量优化设定值.

1　城市污水处理过程能耗分析

城市污水处理过程能耗主要包括泵送能耗和曝气能耗, 其中, 泵送能耗主要指内回流、外回流和污泥排放所产生的能耗, 与泵送能耗有关的主要状态变量有入水流量、硝态氮浓度、混合固体悬浮物浓度; 曝气能耗主要指控制生化反应池中的曝气过程产生的能耗, 与曝气能耗有关的主要状态变量有入水流量、溶解氧浓度、硝态氮浓度、氨氮浓度、混合固体悬浮物浓度. 为了实现对能耗的定量描述, 文中给出基于城市污水处理过程基准仿真模型 1 (Benchmark simulation model No. 1, BSM1) 的曝气能耗计算方式[30]:

$$\mathrm{AE}(t)=\frac{S_{O,sat}}{1\,800\tau}\int_{t}^{t+\tau}\sum_{i=1}^{5}V_i\times K_La_i(t)\mathrm{d}t \tag{1}$$

式中, AE(t) 为 t 时刻曝气能耗, τ 为计算间隔, $S_{O,sat}$ 为溶解氧饱和浓度, V_i 为第 i 个反应池的体积, $K_La_i(t)$ 为 t 时刻氧传递系数, 溶解氧浓度可通过调整氧传递系数进行调节. 泵送能耗的计算方式为

$$\mathrm{PE}(t)=\frac{1}{\tau}\int_{t}^{t+\tau}(0.004\times Q_a(t)+0.05\times Q_w(t)+0.008\times Q_r(t))\mathrm{d}t \tag{2}$$

式中, $\mathrm{PE}(t)$ 为 t 时刻泵送能耗, $Q_a(t)$ 为 t 时刻的内回流量, 硝态氮浓度可通过调整内回流量进行调节, $Q_r(t)$ 为 t 时刻的外回流量, $Q_w(t)$ 为 t 时刻的污泥排放量.

城市污水处理过程的能耗和出水水质是相互冲突的目标, 同时受多个变量共同影响. 为了提高城市污水处理过程出水水质, 城市污水处理厂通常采用增加曝气量, 延长曝气时间, 调节内外回流等方式调节生化反应过程. 然而, 曝气量和回流流量的增加会导致能耗提高. 目前, 高能耗已成为制约城市污水处理厂发展的瓶颈问题, 给国家能源和资源节约产生了严峻挑战. 为此, 城市污水处理多目标优化控制得到了广泛的研究, 成为提高出水水质, 降低能耗, 促进可持续发展的重要技术手段. 然而, 在城市污水处理过程中, 能耗和出水水质受入水水质、入水流量等多个变量的影响, 具有动态时变特性. 在动态时变环境下, 如何获取合适的控制变量设定值是城市污水处理过程优化控制面临的挑战性问题.

2 数据和知识驱动的城市污水处理过程多目标优化控制

文中提出了 DK-MOC 方法, 主要包括以下部分: 首先, 建立数据驱动的优化目标模型, 实现能耗、出水水质和运行状态变量之间动态关系的准确描述. 其次, 设计基于知识迁徙学习的动态多目标粒子群优化算法求解控制变量优化设定值. 最后, 采用比例积分微分 (Proportional integral differential, PID) 控制器跟踪优化设定值. DK-MOC 流程如图 1 所示.

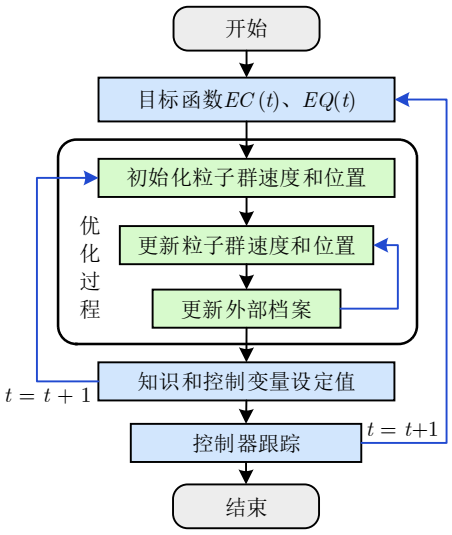

图 1 DK-MOC 的流程图

Fig. 1 The flow chart of DK-MOC

2.1 运行过程目标模型构建

为了描述城市污水处理过程优化目标与系统运行状态变量之间的动态关系, 文中建立了基于 AFNN 的出水水质和能耗优化目标模型:

$$\min F(t)=[EQ(t),EC(t)]^{\mathrm{T}} \tag{3}$$

式中, $F(t)$ 表示运行目标函数, $EQ(t)$ 为出水水质模型, $EC(t)$ 为能耗模型.

$$EQ(t)=\boldsymbol{\varphi}(t)\boldsymbol{w}^{1\mathrm{T}}(t) \tag{4}$$

$$EC(t)=\boldsymbol{\varphi}(t)\boldsymbol{w}^{2\mathrm{T}}(t) \tag{5}$$

式中, $\boldsymbol{\varphi}(t)=[\varphi_1(t),\cdots,\varphi_{10}(t)]$ 为模糊神经网络归一化层输出向量, $\boldsymbol{w}^q(t)=[w_1{}^q(t),\cdots,w_{10}{}^q(t)]$ 为模糊神经网路归一化层与第 q 个输出连接的权重向量, 当 $q=1$ 时, 输出为出水水质, 当 $q=2$ 时, 输出为能耗. 归一化层的输出为

$$\varphi_l(t)=\phi_l(t)\Big/\sum_{j=1}^{10}\phi_j(t) \tag{6}$$

式中, $l=1,\cdots,10$ 为归一化层神经元数量. $\phi_j(t)$ 为模糊规则层第 j 个神经元的输出.

$$\phi_j(t)=\prod_{i=1}^{4}\mathrm{e}^{-\frac{(s_i(t)-\mu_{ij}(t))^2}{2(\sigma_{ij}(t))^2}} \tag{7}$$

式中, $s_i(t)$ 为输入层第 i 个输入, $\boldsymbol{\mu}_j(t)=[\mu_{1j}(t),\cdots,\mu_{ij}(t),\cdots,\mu_{4j}(t)]$ 为模糊规则层的中心向量, $\boldsymbol{\sigma}_j(t)=[\sigma_{1j}(t),\cdots,\sigma_{ij}(t),\cdots,\sigma_{4j}(t)]$ 为模糊规则层宽度向量, 输入向量通过主成分分析和指标可操作性确定, 表示为

$$\boldsymbol{s}(t)=[S_O(t),S_{NO}(t),S_{NH}(t),MLSS(t)] \tag{8}$$

式中, $\boldsymbol{s}(t)$ 为 t 时刻模糊神经网络的输入向量, $S_O(t)$ 为 t 时刻溶解氧浓度, $S_{NO}(t)$ 为 t 时刻硝态氮浓度, $S_{NH}(t)$ 为 t 时刻氨氮浓度, $MLSS(t)$ 为 t 时刻混合固体悬浮物浓度.

为了提高模糊神经网络的自适应能力, 其参数更新规则为

$$\boldsymbol{\Theta}(t+1)=\boldsymbol{\Theta}(t)+(\boldsymbol{\Phi}(t)+\chi(t)\times\boldsymbol{I})^{-1}\times\boldsymbol{\Lambda}(t) \tag{9}$$

式中, $\boldsymbol{\Theta}(t)=[\boldsymbol{w}^1(t),\ \boldsymbol{w}^2(t),\ \boldsymbol{\mu}_1(t),\cdots,\ \boldsymbol{\mu}_{10}(t),\ \boldsymbol{\sigma}_1(t),\cdots,\ \boldsymbol{\sigma}_{10}(t)]^{\mathrm{T}}$ 为参数矩阵, $\boldsymbol{\Phi}(t)$ 为拟海瑟矩阵, $\boldsymbol{\Lambda}(t)$ 为梯度向量, $\boldsymbol{I}$ 为单位矩阵, $\chi(t)$ 为自适应

参数, 更新方式为

$$\chi(t)=\chi(t-1)\cdot\frac{\delta^{\min}(t)+\chi(t-1)}{\delta^{\max}(t)+1} \tag{10}$$

$\delta^{\min}(t)$ 和 $\delta^{\max}(t)$ 分别为拟海瑟矩阵 $\boldsymbol{\Phi}(t)$ 的最小和最大特征值, 自适应参数 $\chi(t)$ 满足 $0<\chi(t)<1$. 拟海瑟矩阵 $\boldsymbol{\Phi}(t)$ 和梯度向量 $\boldsymbol{\Lambda}(t)$ 的计算方式为

$$\boldsymbol{\Phi}(t)=\sum_{q=1}^{2}\boldsymbol{J}_q^{\mathrm{T}}(t)\boldsymbol{J}_q(t) \tag{11}$$

$$\boldsymbol{\Lambda}(t)=\sum_{q=1}^{2}\boldsymbol{J}_q^{\mathrm{T}}(t)e_q(t) \tag{12}$$

式中, $e_q(t)$ 为输出层第 q 个神经元的误差, $\boldsymbol{J}_q(t)$ 为雅克比矩阵.

AFNN 充分考虑了城市污水处理过程动态以及易受扰动特性, 描述了出水水质、能耗以及运行状态变量之间的动态关系, 基于模糊规则增加了模型的抗干扰能力. 另外, 模型的参数更新规则能够提高模型的自适应能力, 提高模型精度.

2.2　控制变量优化设定值求解

为了降低能耗, 提高出水水质, 文中提出了基于知识迁徙学习的动态多目标优化算法, 获取控制变量溶解氧和硝态氮浓度的优化设定值. 在优化过程中, 知识的表示形式为

$$\boldsymbol{A}(t)=[\boldsymbol{a}_1^*(t-1),\boldsymbol{a}_2^*(t-1),\cdots,\boldsymbol{a}_H^*(t-1)] \tag{13}$$

式中, $\boldsymbol{A}(t)$ 为 t 时刻种群初始化过程获得的知识, $\boldsymbol{a}_h^*(t-1)$ 为在 $t-1$ 时刻转移的作为知识的第 h 个粒子位置信息, 即控制变量溶解氧和硝态氮浓度的优化值, $h=1,2,\cdots,H$, H 为所转移的知识量.

在新优化周期开始, 种群中 H 个粒子采用 $\boldsymbol{A}(t)$ 进行初始化, $\boldsymbol{A}(t)$ 包括 $t-1$ 代中 Pareto 前沿上的边缘粒子和具有较强收敛性的粒子 Knee points 的位置信息, 剩余粒子采用如下公式分别生成

$$\boldsymbol{x}_i(0)=\boldsymbol{x}_{\min}+(\boldsymbol{x}_{\max}-\boldsymbol{x}_{\min})\circ\boldsymbol{r}_{1\times 2} \tag{14}$$

式中, $\boldsymbol{x}_i(0)$ 为第 i 个粒子的初始位置向量, $i\in[H+1,N]$, N 为种群规模, $\boldsymbol{x}_{\max}=[S_{O,\max},S_{NO,\max}]$ 和 $\boldsymbol{x}_{\min}=[S_{O,\min},S_{NO,\min}]$ 分别为溶解氧和硝态氮浓度的上界和下界, $\boldsymbol{r}_{1\times 2}$ 为分布于 $[0,1]$ 的 1×2 维随机向量.

为了提高多目标粒子群优化算法的搜索能力, 文中基于历史信息的种群进化状态检测机制, 设计自适应进化方向选择策略, 平衡种群的探索和开发能力. 其中, 种群进化状态通过种群收敛性和种群多样性检测, 种群收敛性表示为

$$P_C(k)=\sum_{n=1}^{N}\sum_{u=k-k_0}^{k}\mathrm{e}^{\frac{\tilde{C}_n(k)}{k-u+1}} \tag{15}$$

式中, $P_C(k)$ 为第 k 代种群收敛性指标, k_0 表示历史迭代次数, $\tilde{C}_n(k)$ 为种群中第 n 个粒子在第 k 代的收敛性, 计算方式为

$$\tilde{C}_n(k)=EQ_n(k-1)-EQ_n(k)+EC_n(k-1)-EC_n(k) \tag{16}$$

$EQ_n(k)$ 和 $EC_n(k)$ 分别为第 n 个粒子在第 k 代的出水水质和能耗值. 种群多样性表示为

$$P_D(k)=\sum_{n=1}^{N}\sum_{u=k-k_0}^{k}\mathrm{e}^{\frac{\tilde{D}_n(k)}{k-u+1}} \tag{17}$$

式中, $P_D(k)$ 为第 k 代种群多样性指标, $\tilde{D}_n(k)$ 表示第 n 个粒子在第 k 代的多样性分布信息, 计算方式为

$$\tilde{D}_n(k)=\left(\sum_{i=1}^{N}|(EQ_n(k)-EQ_i(k)|+\sum_{i=1}^{N}|(EC_n(k)-EC_i(k)|\right)\Big/N \tag{18}$$

根据种群的收敛性和多样性, 文中将进化状态划分为 5 个阶段, 并设计自适应进化方向选择策略平衡种群的探索和开发能力, 自适应进化方向选择策略如下所示:

阶段 1. 当 $P_C(k)-P_C(k-1)>0$ 且 $P_D(k)-P_D(k-1)>0$ 时, 种群处于进化阶段, 速度和位置的更新公式为

$$v_{i,d}(k+1)=\omega v_{i,d}(k)+c_1r_1(p_{i,d}(k)-x_{i,d}(k))+c_2r_2(g_d(k)-x_{i,d}(k)) \tag{19}$$

$$x_{i,d}(k+1)=x_{i,d}(k)+v_{i,d}(k+1) \tag{20}$$

式中, $x_{i,d}(k)$ 为第 i 个粒子在第 k 代的第 d 维位置, $v_{i,d}(k)$ 为第 i 个粒子在第 k 代的第 d 维速度, $p_{i,d}(k)$ 为第 i 个粒子在第 k 代个体最优解的第 d 个维度, $g_d(k)$ 为种群在第 k 代全局最优解的第 d 个维度, w 为惯性权重, r_1 和 r_2 为区间 $[0,1]$ 的随机数, c_1 和 c_2 分别为自我认知参数和社会认知参数.

阶段 2. 当 $P_C(k)-P_C(k-1)<0$ 且 $P_D(k)-P_D(k-1)>0$ 时, 种群处于探索阶段, 速度和位置的更新公式为

$$v_{i,d}(k+1)=\omega v_{i,d}(k)+c_1r_1(p_{i,d}(k)-x_{i,d}(k))+c_2r_2(g_d(k)-x_{i,d}(k))+c_3r_3C_d(k) \tag{21}$$

$$x_{i,d}(k+1)=x_{i,d}(k)+v_{i,d}(k+1) \tag{22}$$

式中, r_3 为分布于区间 $[0,1]$ 的随机数, c_3 为收敛性方向飞行参数, $C_d(k)$ 为第 k 代收敛性方向的第 d

个维度, 表示为

$$C_d(k)=\frac{1}{k_0+1}(x_{l(k),d}(k)-x_{l(k),d}(k-k_0)) \tag{23}$$

$$l(k)=\underset{n\in[1,N]}{\operatorname{argmax}}\left(\sum_{u=k-k_0}^{k}\mathrm{e}^{\frac{\tilde{C}_n(k)}{k-u+1}}\right) \tag{24}$$

式中, $l(k)$ 表示在第 k 次迭代中具有最大收敛性的粒子编号.

阶段 3. 当 $P_C(k)-P_C(k-1)>0$ 且 $P_D(k)-P_D(k-1)<0$ 时, 种群处于开发阶段, 速度和位置的更新公式为

$$\begin{aligned}v_{i,d}(k+1)=&\omega v_{i,d}(k)+c_1r_1(p_{i,d}(k)-x_{i,d}(k))+\\&c_2r_2(g_d(k)-x_{i,d}(k))+c_4r_4D_d(k)\end{aligned} \tag{25}$$

$$x_{i,d}(k+1)=x_{i,d}(k)+v_{i,d}(k+1) \tag{26}$$

式中, r_4 为分布于区间 [0, 1] 的随机数, c_4 为多样性方向飞行参数, $D_d(k)$ 表示第 k 代多样性方向的第 d 个维度, 计算方式为

$$D_d(k)=\frac{1}{k_0+1}(x_{p(k),d}(k)-x_{p(k),d}(k-k_0)) \tag{27}$$

$$p(k)=\underset{n\in[1,N]}{\operatorname{argmax}}\left(\sum_{u=k-k_0}^{k}\mathrm{e}^{\frac{\tilde{D}_n(k)}{k-u+1}}\right) \tag{28}$$

式中, $p(k)$ 表示第 k 次迭代中种群多样性最大的粒子编号.

阶段 4. 当 $P_C(k)-P_C(k-1)<0$ 且 $P_D(k)-P_D(k-1)<0$ 时, 种群处于退化阶段, 速度和位置的更新公式为

$$\begin{aligned}v_{i,d}(k+1)=&\omega v_{i,d}(k)+c_1r_1(p_{i,d}(k)-x_{i,d}(k))+\\&c_2r_2(g_d(k)-x_{i,d}(k))+\\&0.5\times(c_3r_3C_d(k)+c_4r_4D_d(k))\end{aligned} \tag{29}$$

$$x_{i,d}(k+1)=x_{i,d}(k)+v_{i,d}(k+1) \tag{30}$$

阶段 5. 当 $P_C(k)-P_C(k-1)=0$ 或 $P_D(k)-P_D(k-1)=0$ 时, 种群处于停滞阶段, 速度和位置的更新公式为

$$\begin{aligned}v_{i,d}(k+1)=&\omega v_{i,d}(k)+c_1r_1(p_{i,d}(k)-x_{i,d}(k))+\\&c_2r_2(g_d(k)-x_{i,d}(k))\end{aligned} \tag{31}$$

$$x_{i,d}(k+1)=\begin{cases}x_{d,\min}+(x_{d,\max}-x_{d,\min})\times G(0,1),\\\qquad\qquad r_3\le p_b(k+1)\\x_{i,d}(k),\qquad r_3>p_b(k+1)\end{cases} \tag{32}$$

式中, $G(0, 1)$ 是一个服从均匀分布的随机值, $x_{d,\min}$ 和 $x_{d,\max}$ 是第 d 维的最小值和最大值, $p_b(k)$ 为突变率:

$$p_b(k)=0.5-0.5\times\frac{k}{K} \tag{33}$$

式中, K 为种群最大迭代次数.

基于 Pareto 支配关系建立的外部档案采用拥挤距离维护并选择全局最优粒子. 城市污水处理过程水质达标即可排放, 因此, 在第 K 代外部档案中选择溶解氧和硝态氮浓度优化设定值时, 增加决策者偏好信息, 控制变量优化设定值选择对应能耗值最低的非支配解, t 时刻溶解氧和硝态氮的优化设定值为 $S_O^*(K)$ 和 $S_{NO}^*(K)$.

基于知识迁徙学习的动态多目标粒子群优化算法采用 t 时刻的最优粒子对 $t+1$ 时刻种群的位置进行初始化, 并利用历史信息来检测种群进化状态, 为种群提供不同的进化方向, 提高种群的搜索能力, 求解溶解氧和硝态氮浓度的优化设定值. 其中, T_{max} 为终止时间. 控制变量优化设定值的获取流程如图 2 所示.

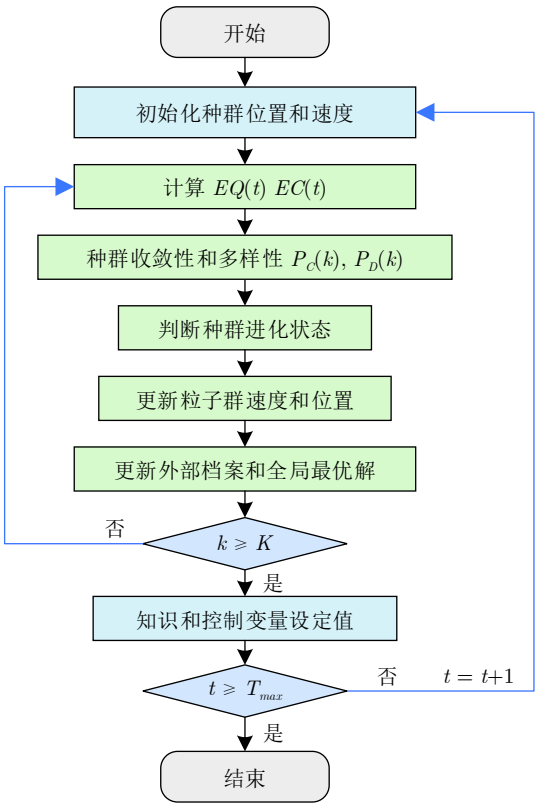

图 2 控制变量设定值求解步骤

Fig. 2 The solution procedure of set values of control variables

基于知识迁徙学习的动态多目标粒子群优化算法的计算复杂度分析如下: 假设粒子群规模为 N, 计算种群目标值的时间复杂度为 $\mathrm{O}(MN)$, 计算每个粒子收敛性的时间复杂度为 $\mathrm{O}(N)$, 计算每个粒子的多样性指标的时间复杂度为 $\mathrm{O}(MN^2)$, 计算种

群收敛性和多样性指标的时间复杂度均为 O(N), 粒子速度和位置更新的计算复杂度为 O(N), 外部档案更新的计算复杂度为 O(MN^2), 选择全局最优解的计算复杂度为 O(N), 因此, 基于知识迁徙学习的动态多目标粒子群优化算法的计算复杂度为 O(MN^2). 在城市污水处理过程中, 优化控制的周期一般为 2 小时, 因此, 多目标粒子群优化算法的计算复杂度是可以满足实际应用需求的.

3　实验结果及分析

文中从优化目标模型和优化控制性能两方面验证 DK-MOC 策略的有效性, 采用 BSM1 仿真平台作为公共验证平台, 该平台是国际水协会专家提出的基于生物脱氮策略的城市污水处理过程仿真平台, 主要用于城市污水处理过程控制策略的测试, 能够为不同优化控制策略提供相同的测试环境, 可以公平地比较不同策略的性能. 而且, 该平台可设置不同的实验环境, 文中设置了干旱和阴雨天气两种实验环境. 实验在 Windows10、CPU 1.80 GHz、MATLAB 2018 上运行. 为了保证评价结果的有效性, 所有的实验运行 30 次, 取平均值作为结果.

3.1　优化目标模型性能

AFNN 与自适应核函数 (Adaptive kernel function, AKF)[22, 25]、遗传算法−人工神经网络 (Genetic algorithm-artificial neural network, GA-ANN)[23] 以及最小二乘支持向量机 (Least squares support vector machine, LSSVM)[24] 进行比较, 所有模型的更新频率为 15 min, 训练过程中的迭代次数设置为 10 次. 均方根误差 (Root mean square error, RMSE) 和预测精度 (Prediction accuracy, PA) 用于评价模型的性能

$$\mathrm{RMSE}=\sqrt{\frac{\sum_{i=1}^{L}(y_i-\hat{y}_i)}{L}} \tag{34}$$

$$\mathrm{PA}=\left[1-\left|\frac{\sum_{i=1}^{L}(y_i-\hat{y}_i)}{\sum_{i=1}^{L}y_i}\right|\right]\times 100\ \% \tag{35}$$

式中, y_i 为第 i 次测试的实际值, $\hat{y}_i$ 为第 i 次测试时模型输出值, L 为测试总次数.

在干旱和阴雨天气下, RMSE 和 PA 如表 1 和表 2 所示, 可以看出, 在能耗和出水水质指标预测中, 与 AKF、GA-ANN 和 LSSVM 相比, AFNN 在干旱天气和阴雨天气下具有较低的 RMSE 和较高 PA, 说明 AFNN 能够更精确地构建能耗和出水水质模型. 另外, 图 3 ~ 4 给出了干旱天气下基于 AFNN 的能耗和出水水质建模结果. 由于每日出水水质和能耗值为每日采样多次的累加和, 因此, 图 3 和图 4 的出水水质和能耗在数值上相对图 5 和图 6 较小. 图 3 ~ 4 的建模结果表明, 所采用的 AFNN 可

表 1　干旱天气下能耗和出水水质的测量精度

Table 1　The measurement accuracy of energy consumption and effluent quality in dry weather

模型	*EC*		*EQ*	
	RMSE	PA	RMSE	PA
AKF	0.0082	98.71 %	0.0079	97.06 %
GA-ANN	0.0123	93.36 %	0.0124	95.52 %
LSSVM	0.0115	96.21 %	0.0139	94.31 %
AFNN	**0.0079**	**98.99 %**	**0.0070**	**98.73 %**

表 2　阴雨天气下能耗和出水水质的测量精度

Table 2　The measurement accuracy of energy consumption and effluent quality in rainy weather

模型	*EC*		*EQ*	
	RMSE	PA	RMSE	PA
AKF	0.0093	96.60 %	0.0833	97.37 %
GA-ANN	0.0146	95.72 %	0.1002	94.32 %
LSSVM	0.0138	95.74 %	0.0940	96.76 %
AFNN	**0.0089**	**98.88 %**	**0.0776**	**98.89 %**

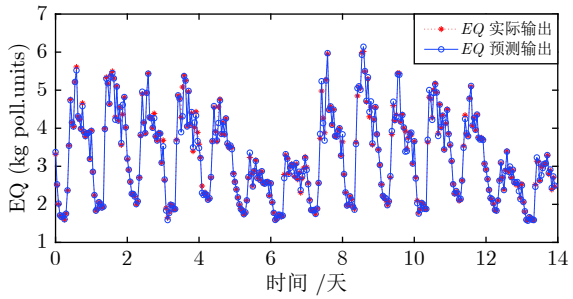

图 3　干旱天气下出水水质建模结果

Fig. 3　The modeling results of effluent quality in dry weather

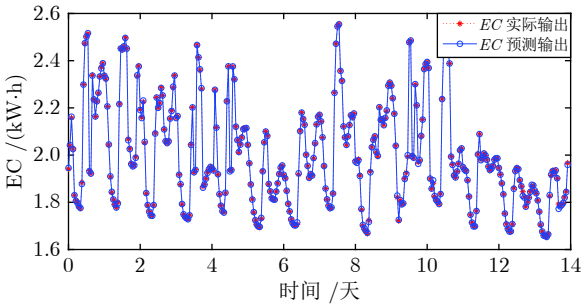

图 4　干旱天气下能耗建模结果

Fig. 4　The modeling results of energy consumption in dry weather

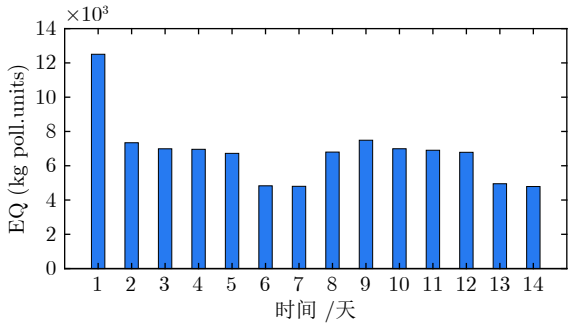

图 5 干旱天气下平均出水水质值

Fig. 5 Average values of effluent quality in dry weather

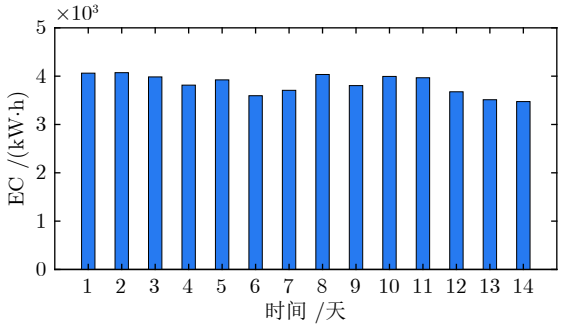

图 6 干旱天气下平均能耗值

Fig. 6 Average values of energy consumption in dry weather

以准确描述能耗和出水水质以及运行状态变量之间的动态关系.

3.2 优化控制性能

DK-MOC 主要包括 AFNN、基于知识迁徙学习的动态多目标粒子群优化算法和 PID 控制器. 为了验证基于知识迁徙学习的动态多目标粒子群优化算法与 PID 控制器共同构成的优化控制器的有效性, 文中利用文献 [23−25] 中提出的优化方法与 PID 控制器共同构建优化控制器, 建模方法都选择具有较高精度的 AFNN. 对比的优化方法主要包括非支配排序遗传算法 II (NSGAII)[23]、基于聚类的多目标粒子群优化 (Cluster-based multiobjective particle swarm optimization, CMOPSO)[24] 和自适应多目标粒子群优化 (Adaptive multiobjective particle swarm optimization, AMOPSO)[25]. 另外, 为了验证基于多目标优化方法和基于单目标优化方法的优化控制性能, 文中根据基于知识迁徙学习的动态多目标粒子群优化算法设计基于知识迁徙的动态单目标粒子群优化算法 (Knowledge transfer-based dynamic single objective particle swarm optimization, KT-DSOPSO), 其中, 出水水质作为约束, 能耗作为优化目标. 同时, 在所有的优化控制策略中, PID 控制器的参数设置: 溶解氧比例系数为 20, 硝态氮比例系数为 10 000, 溶解氧积分系数为 5, 硝态氮积分系数为 3 000, 溶解氧微分系数为 1, 硝态氮微分系数为 100. 在所有的优化算法中, 设置种群规模和外部档案最大尺寸为 40, 种群迭代次数均为 50. BSM1 中设置的总采样时间为 14 天, 优化周期为 2 小时, 在动态多目标粒子群优化算法中, 惯性权重 ω 为 0.7, c_1、c_2、c_3 和 c_4 分别为 2.5、2.5、0.5 和 0.5, k_0 为 4, H 为 8.

文中采用能耗和出水水质两个指标对优化控制策略的性能进行验证, 能耗值低说明优化控制过程中产生较少的能耗. 根据国际污水排放检测标准, 出水水质采用出水中氨氮、总氮、悬浮物、COD、BOD 的浓度计算, 浓度越低, 水质越好. 干旱天气下平均每天的出水水质和能耗表示如图 5 ~ 6 所示. 为了描述 DK-MOC 的优化控制性能, 图 7 ~ 8 给出了干旱天气下溶解氧和硝态氮浓度的优化设定值和跟踪值, 可以看出, 所提出的优化算法可以获得动态的控制变量优化设定值, 使用 PID 可以跟踪变化的优化设定值. 根据图 9 所示, 干旱天气下溶解氧和硝态氮的平均跟踪误差为 $S_O < 0.5$ mg·L^{-1}, $S_{NO} < 0.2$ mg·L^{-1}, 结果表明, 在 DK-MOC 策略中, PID 能较好地跟踪 S_O 和 S_{NO} 的优化设定值, 保证了跟踪控制的有效性.

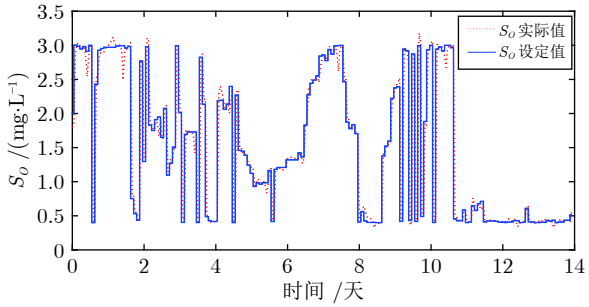

图 7 干旱天气下溶解氧浓度跟踪性能

Fig. 7 Tracking performance of S_O in dry weather

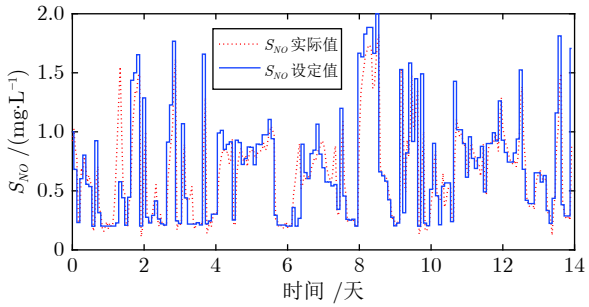

图 8 干旱天气下硝态氮浓度跟踪性能

Fig. 8 Tracking performance of S_{NO} in dry weather

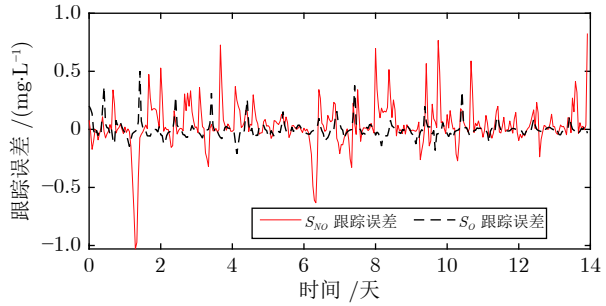

图 9　干旱天气下硝态氮和溶解氧浓度跟踪误差

Fig. 9　Tracking errors of S_{NO} and S_O in dry weather

为了精确描述 DK-MOC 性能, 表 3 给出了 DK-MOC 的出水水质的组分结果, S_{NH} 表示氨氮浓度, N_{tot} 表示总氮浓度, TSS 表示悬浮物浓度, 表 4 给出了不同优化控制策略在干旱和阴雨天气下的能耗和出水水质结果, 由表 3 ~ 4 可以看出, 在干旱天气下, DK-MOC 的 TSS、COD 和 BOD 浓度均远小于排放标准. 虽然 S_{NH}、N_{tot} 接近排放标准, 但所有的水质指标都达标, 且其总出水水质指标优于其他优化控制策略; 在阴雨天气下, DK-MOC 的 S_{NH} 浓度为 3.89 mg·L^{-1}, N_{tot} 浓度为 17.01 mg·L^{-1}, 水质指标均达标, 且运行能耗具有最小值. 另外, DK-MOC 与基于 KT-DSOPSO 的优化控制器对比, 可以看出, 所提出的基于知识迁徙学习的动态多目标粒子群优化方法可以权衡能耗和出水水质的关系. 结果表明, DK-MOC 可以通过获取动态优化设定值, 有效降低能耗, 提高出水水质.

表 3　DK-MOC 的出水水质结果

Table 3　Effluent quality results obtained by DK-MOC

水质指标	干旱天气	阴雨天气	排放标准
S_{NH} (mg·L^{-1})	3.44	3.89	<4
N_{tot} (mg·L^{-1})	17.41	17.01	<18
TSS (mg·L^{-1})	12.57	13.51	<30
COD (mg·L^{-1})	47.75	46.53	<100
BOD (mg·L^{-1})	2.71	2.93	<10

表 4　不同优化控制策略的比较结果

Table 4　Comparison results of different optimal control strategies

优化控制策略	干旱天气		阴雨天气	
	EC (kW·h)	*EQ* (kg poll. units)	*EC* (kW·h)	*EQ* (kg poll. units)
AFNN+NSGAII+PID	4015	8867	4969	9049
AFNN+CMOPSO+PID	4770	8915	4869	9293
AFNN+AMOPSO+PID	3848	7695	3870	**7944**
AFNN+KT-DSOPSO+PID	3727	9062	3892	9479
DK-MOC	**3641**	**7179**	**3821**	8106

4　结论

文中提出的 DK-MOC 方法主要包括以下优点:

1) 设计数据驱动的城市污水处理过程多目标优化模型, 实现运行状态变量与出水水质、能耗之间的动态关系的准确描述.

2) 提出了基于知识迁徙学习的动态多目标粒子群优化算法, 通过知识迁徙学习和自适应进化方向选择策略提高种群搜索性能, 从而获取有效的优化设定值.

BSM1 平台的测试效果显示: 与其他建模方式相比, AFNN 可以提高出水水质和能耗模型精度; 与一些优化控制策略相比, 所提出的 DK-MOC 方法可以获得有效的控制变量优化设定值, 提高了出水水质, 降低了能耗. 结果证明了 DK-MOC 方法的有效性.

References

1　Tang R, Wang Y, Yuan S, Wang W, Yue Z, Zhan X, et al. Organoarsenic feed additives in biological wastewater treatment processes: Removal, biotransformation, and associated impacts. *Journal of Hazardous Materials*, 2021, **406**: 124789

2　Iratni A, Chang N. Advances in control technologies for wastewater treatment processes: Status, challenges, and perspectives. *IEEE/CAA Journal of Automatica Sinica*, 2019, **6**(2): 337−363

3　Quan Lin-Min, Yang Cui-Li, Qiao Jun-Fei. Data-driven online self-organizing control for dissolved oxygen concentration, *Acta Automatica Sinica*, DOI: 10.16383/j.aas.c210041
(权利敏, 杨翠丽, 乔俊飞. 数据驱动的溶解氧浓度在线自组织控制方法. 自动化学报, DOI: 10.16383/j.aas.c210041)

4　Chistiakova T, Wigren T, Carlsson B. Combined *L*2 -stable feedback and feedforward aeration control in a wastewater treatment plant. *IEEE Transactions on Control Systems Technology*, 2020, **28**(3): 1017−1024

5　Ben-David E A, Habibi M, Haddad E, Hasanin M, Angel D L, Booth A M, et al. Microplastic distributions in a domestic wastewater treatment plant: Removal efficiency, seasonal variation and influence of sampling technique. *Science of The Total Environment*, 2021, **752**: 141880

6　Borzooei S, Amerlinck Y, Panepinto D, Abolfathi S, Nopens I, Nopens G, et al. Energy optimization of a wastewater treatment plant based on energy audit data: small investment with high return. *Environmental Science and Pollution Research*, 2020, **27**: 17972−17985

7　Sun J Y, Liang P, Yan X X, Zuo K C, Xiao K, Xia J L, et al. Reducing aeration energy consumption in a large-scale membrane bioreactor: Process simulation and engineering application. *Water Research*, 2016, **93**: 205−213

8　De Gussem K, Fenu A, Wambecq T, Weemaes M. Energy saving on wastewater treatment plants through improved online control: Case study wastewater treatment plant antwerp-south. *Water Science & Technology*, 2014, **69**(5): 1074−1079

9　Zonta Z J, Kocijan J, Flotats X, Vrečko D. Multi-criteria analyses of wastewater treatment bio-processes under an uncertainty and a multiplicity of steady states. *Water Research*, 2012, **46**(18): 6121−6131

10　Godini K, Azarian G, Kimiaei A, Dragoi E N, Curteanu S. Modeling of a real industrial wastewater treatment plant based on aerated lagoon using a neuro-evolutive technique. *Process Safety and Environmental Protection*, 2021, **148**: 114−124

11　Qiu Y, Li J, Huang X, Shi H. A feasible data-driven mining system to optimize wastewater treatment process design and opera-

tion. *Water*, 2018, **10**(10): 1342

12 Zeng Y, Zhang Z, Kusiak A, Tang F, Wei X. Optimizing wastewater pumping system with data-driven models and a greedy electromagnetism-like algorithm. *Stochastic Environmental Research and Risk Assessment*, 2016, **30**: 1263−1275

13 Filipe J, Bessa R J, Reis M, Alves R, Póvoa P. Data-driven predictive energy optimization in a wastewater pumping station. *Applied Energy*, 2019, **252**: 113423

14 Canete J F, Saz-Orozco P, Gabriel J G, Baratti R, Ruano A, Rivas-Blanco I. Control and soft sensing strategies for a wastewater treatment plant using a neuro-genetic approach. *Computers & Chemical Engineering*, 2021, **144**: 107146

15 Han H G, Zhang L, Liu H X, Qiao J F. Multiobjective design of fuzzy neural network controller for wastewater treatment process. *Applied Soft Computing*, 2018, **67**: 467−478

16 Li San-Yi, Qiao Jun-Fei, Li Wen-Jing, Gu Ke. Advanced decision and optimization control for wastewater treatment plants. *Acta Automatica Sinica*, 2018, **44**(12): 2198−2209
(栗三一, 乔俊飞, 李文静, 顾锞. 污水处理决策优化控制. 自动化学报, 2018, **44**(12): 2198−2209)

17 Vega P, Revollar S, Francisco M, Martín J M. Integration of set point optimization techniques into nonlinear MPC for improving the operation of WWTPs. *Computers and Chemical Engineering*, 2014, **68**: 78−95

18 Zhang R, Xie W M, Yu H Q, Li W W. Optimizing municipal wastewater treatment plants using an improved multi-objective optimization method. *Bioresource Technology*, 2014, **157**: 161−165

19 Mooselu M G, Nikoo M R, Latifi M, Sadegh M, Al-Wardy M, Al-Rawas G A. A multi-objective optimal allocation of treated wastewater in urban areas using leader-follower game. *Journal of Cleaner Production*, 2020, **267**: 122189

20 Tejaswini E S S, Panjwani S, Gara U B B, Ambati S R. Multi-objective optimization based controller design for improved wastewater treatment plant operation. *Environmental Technology & Innovation*, 2021, **23**: 101591

21 De Faria A B B, Ahmadi A, Tiruta-Barna L, Spérandio M. Feasibility of rigorous multi-objective optimization of wastewater management and treatment plants. *Chemical Engineering Research and Design*, 2016, **155**(Part B): 394−406

22 Qiao J F, Hou Y, Zhang L, Han H G. Adaptive fuzzy neural network control of wastewater treatment process with multiobjective operation. *Neurocomputing*, 2018, **275**: 383−393

23 Huang M, Han W, Wan J, Ma Y, Chen X. Multi-objective optimisation for design and operation of anaerobic digestion using GA-ANN and NSGA-II. *Journal of Chemical Technology & Biotechnology*, 2016, **91**(1): 226−233

24 Li Yong-Ming, Shi Xu-Dong, Xiong Wei-Li. Condition recognition based intelligent multi-objective optimal control for wastewater treatment. *CIESC Journal*, 2019, **70**(11): 4325−4336
(李永明, 史旭东, 熊伟丽. 基于工况识别的污水处理过程多目标优化控制. 化工学报, 2019, **70**(11): 4325−4336)

25 Han Hong-Gui, Zhang Lu, Lu Wei, Qiao Jun-Fei. Research on dynamic multiobjective intelligent optimal control for municipal wastewater treatment process. *Acta Automatica Sinica*, 2021, **47**(3): 620−629
(韩红桂, 张璐, 卢薇, 乔俊飞. 城市污水处理过程动态多目标智能优化控制研究. 自动化学报, 2021, **47**(3): 620−629)

26 Yang Cui-Li, Wu Zhan-Hong, Han Hong-Gui, Qiao Jun-Fei. Perspectives on optimal setting methods for municipal wastewater treatment processes. *Acta Automatica Sinica*, 2020, **46**(10): 2092−2108
(杨翠丽, 武战红, 韩红桂, 乔俊飞. 城市污水处理过程优化设定方法研究进展. 自动化学报, 2020, **46**(10): 2092−2108)

27 Newhart K B, Holloway R W, Hering A S, Cath T Y. Data-driven performance analyses of wastewater treatment plants: A review. *Water research*, 2019, **157**: 498−513

28 Han H G. Liu Z, Lu W, Hou Y, Qiao J F. Dynamic MOPSO-based optimal control for wastewater treatment process. *IEEE Transactions on Cybernetics*, 2021, **51**(5): 2518−2528.

29 Christine S, Fu G, Butler D. Multi-objective optimization of wastewater treatment plant control to reduce greenhouse gas emissions. *Water Research*, 2014, **55**: 52−62

30 Jeppsson U, Pons M N. The COST benchmark simulation model— Current state and future perspective. *Control Engineering Practice*, 2004, **12**(3): 299−304

韩红桂 北京工业大学信息学部教授. 主要研究方向为城市污水处理过程智能优化控制, 神经网络结构设计与优化. 本文通信作者.
E-mail: rechardhan@bjut.edu.cn
(**HAN Hong-Gui** Professor at the Faculty of Information Technology, Beijing University of Technology. His research interest covers intelligent optimal control of municipal wastewater treatment process, structure design and optimization of neural networks. Corresponding author of this paper.)

张琳琳 北京工业大学信息学部博士研究生. 主要研究方向为城市污水处理过程智能优化控制.
E-mail: zhangllsy@163.com
(**ZHANG Lin-Lin** Ph. D. candidate at the Faculty of Information Technology, Beijing University of Technology. Her main research interest is intelligent optimal control of municipal wastewater treatment process.)

伍小龙 北京工业大学信息学部讲师. 主要研究方向为城市污水处理过程智能特征建模与智能控制.
E-mail: lewis_wxl@sina.com
(**WU Xiao-Long** Lecturer at the Faculty of Information Technology, Beijing University of Technology. His research interest covers intelligent feature modeling and intelligent control of municipal wastewater treatment process.)

乔俊飞 北京工业大学信息学部教授. 主要研究方向为城市污水处理过程智能优化控制, 神经网络结构设计与优化.
E-mail: junfeq@bjut.edu.cn
(**QIAO Jun-Fei** Professor at the Faculty of Information Technology, Beijing University of Technology. His research interest covers intelligent optimal control of municipal wastewater treatment process, structure design and optimization of neural networks.)