

基于知识的污水生化处理过程智能优化方法

乔俊飞^{1,2} 韩改堂^{1,2} 周红标^{1,2}

摘要 针对污水处理过程控制能耗过大和水质超标严重等问题, 本文提出一种基于知识的污水生化处理过程智能优化控制方法. 该方法通过记忆多目标智能优化算法的动态处理信息, 建立环境变量参数与最优解之间的知识模型. 优化算法利用知识库中非支配解的引导, 结合定向局部区域寻优以及随机全局寻优策略, 提高了算法的收敛性, 获取了更高质量的解. 最后基于国际通用平台 BSM1 进行实验验证. 结果表明, 与其他优化算法相比, 该方法能够在保证出水水质的前提下产生更少的能量消耗.

关键词 污水处理过程, 能耗, 多目标优化, 知识引导

引用格式 乔俊飞, 韩改堂, 周红标. 基于知识的污水生化处理过程智能优化方法. 自动化学报, 2017, 43(6): 1038–1046

DOI 10.16383/j.aas.2017.c170088

Knowledge-based Intelligent Optimal Control for Wastewater Biochemical Treatment Process

QIAO Jun-Fei^{1,2} HAN Gai-Tang^{1,2} ZHOU Hong-Biao^{1,2}

Abstract In order to solve the problems of excessive energy consumption and serious water quality in wastewater treatment process, a wastewater treatment process intelligent optimization control method based on knowledge is proposed. Knowledge model of environment variable parameters and optimal solutions are built by memorizing the dynamic processing information of the multi-objective intelligent optimization algorithm. The optimization algorithm is guided by the non-dominated solution in the knowledge base, and combines the oriented local area search and the stochastic global search strategy to improve the convergence of the algorithm and obtains a higher quality solution. Finally, experiment verification is performed on the international common simulation platform BSM1. Results show that the proposed method can reduce energy consumption under the premise of ensuring the quality of the effluent.

Key words Wastewater treatment process, energy consumption, multi-objective optimization, knowledge guidance

Citation Qiao Jun-Fei, Han Gai-Tang, Zhou Hong-Biao. Knowledge-based intelligent optimal control for wastewater biochemical treatment process. *Acta Automatica Sinica*, 2017, 43(6): 1038–1046

水污染是世界上最令人头疼的问题之一, 在未来的几十年将呈现继续恶化的趋势^[1]. 目前, 生物处理法是污水处理厂采用最广泛的净水方法. 其中, 活性污泥法是去除有机污染物最有效的方法之一^[2]. 该方法的重要举措之一就是通过对鼓风机向曝气池中充入适当氧气以保持好氧区中溶解氧 (Dissolved oxygen, SO) 浓度以及通过回流泵回流污水以保持

缺氧区的硝态氮 (Nitrate nitrogen, SNO) 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 SO 和 SNO 维持于一个较高的运行水平, 以便得到满意的出水水质. 然而, 好氧区 SO 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 SNO 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, 根据污水处理工况的变化对 SO 和 SNO 设定值进行动态寻优, 是提升污水处理除氮效果和降低运营成本的一种可行办法^[3].

在实际污水处理厂中, 底层跟踪控制处理过程多采用开关控制和 PID 控制等传统控制方法^[4–6]. Carlsson 等^[4] 设计 PI、PD 和 PID 等多种控制策略并集成到 BSM1 中作为控制性能比较的基准控制器. Wahab 等^[5] 针对硝化反硝化污水处理过程具有的强非线性和不确定干扰等特点, 设计了自整定多变量 PID 控制器, 结果显示闭环控制性能得到极大

收稿日期 2017-02-20 录用日期 2017-03-30
Manuscript received February 20, 2017; accepted March 30, 2017

国家自然科学基金 (61533002), 国家杰出青年科学基金项目 (61225016) 资助

Supported by National Natural Science Foundation of China (61533002) and National Natural Science Funds for Distinguished Young Scholar (61225016)

本文责任编辑 郭戈
Recommended by Associate Editor GUO Ge

1. 北京工业大学信息学部 北京 100124 2. 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 100124 2. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing 100124

提高. Harja 等^[6] 针对污水处理过程溶解氧控制设计了分数阶 PI 控制器, 结果显示所设计控制器能够有效抑制参数变化带来的控制品质变差的影响, 具有较强的鲁棒性. 虽然传统控制方法结构简单易实现, 但其初始设置的参数并不能随时间和工况的变化而动态改变, 粗放型的控制过程使得跟踪误差较大, 并不能很好地控制污水处理过程中包含的非线性动态反应. 此外, 在实际污水处理运行过程中, 其底层设定值往往由厂内专家通过观察以及经验决定, 由于不能实时监督, 导致设定值不能随时间和工况的变化而改变, 因此往往导致能耗过高或者出水水质较差的现象.

针对这一问题, 当前一些优化控制技术被应用在污水处理过程中^[7-13]. Ostace 等^[7] 采用模式搜索算法 (Pattern search, PS) 优化溶解氧设定值, 结果显示总成本下降 7%. Qiao 等^[8] 针对溶解氧和硝态氮的优化控制, 采用数据驱动的自适应优化控制器 (Data driven adaptive optimization control, DDAOC) 优化能耗和出水水质加权和构成的目标函数, 结果显示能耗降低 8.5%. 韩广等^[9] 采用 Hopfield 神经网络结合拉格朗日乘子法设计污水处理过程优化控制方案, 结果显示总能耗降低 5.3%. Santín 等^[10] 采用模型预测控制 (Model predictive control, MPC)、前馈控制 (Feedforward control, FF) 和模糊控制器构建两层控制器优化溶解氧设定值, 结果显示晴天天气下总能耗下降 6.9%. Zhang 等^[11] 采用遗传算法独立地优化操作成本和出水水质, 结果显示在保证出水水质参数达标的同时, 有效地降低了操作成本. Sweetapple 等^[12] 针对温室气体排放量、生产成本和出水污染物浓度的多目标优化问题, 采用非支配排序遗传算法 NSGA-II 对其进行同时优化以获取污水处理过程最佳的操作参数, 结果显示在保证出水水质的前提下, 温室气体排放量和生产成本是一对相互竞争的目标. Hreiz 等^[13] 针对某小型污水处理厂能耗过高的问题, 采用精英多目标遗传算法同时优化出水水质和操作成本, 取得了两者之间的最佳平衡. Qiao 等^[14] 采用模糊神经网络建立能耗和出水水质数据驱动模型, 并利用 NSGA-II 构建动态多目标优化控制方法 (Dynamic multi-objective optimization control, DMOOC) 对其同时进行优化, 结果显示能耗降低了 4.94%. 文献 [7-8] 为单目标方法, 主要是对溶解氧进行优化控制, 优化目标以能耗为主. 文献 [9-11] 利用权值系数将多目标优化问题转化为单目标优化问题, 并没有考虑不同目标函数之间的依赖关系. 文献 [12-14] 考虑到污水处理生化反应过程之间相互影响, 能耗和出水水质等多目标之间呈现相互冲突的特性, 利用多目标优化算法同时优化多个目标, 能

够得到更富竞争力的折衷解.

然而, 以上多目标智能优化方法很少应用历史最优解的信息, 对于处理环境相同且最优解决方案变化很小的情况, 在新的搜索周期进行完全随机初始化策略会造成昂贵的计算成本^[15]. 因此, 如何在处理新的优化周期时有效应用过去最优解的信息成为当前多目标优化算法的重要课题之一^[16]. 污水处理过程作为非线性动态系统, 在相似的处理环境 (入水流量、污染物浓度) 下具有相近的解决方案, 因此应用知识指导优化算法的搜索将能够得到更精确的优化解.

基于以上多目标优化算法以及污水处理过程特性的分析, 本文提出一种基于知识的多目标粒子群 (Knowledge-based multi-objective particle swarm optimization, KBMOPSO) 优化算法, 用于实现污水生化处理过程的智能优化控制. 该方法将入水流量 (Q_0)、入水氨氮 ($S_{NH,in}$) 和入水总氮 ($S_{tot,in}$) 作为工况识别参考变量, 与最优解建立联系形成知识模型, 用于引导 KBMOPSO 的搜索过程. 实验结果验证了所提方法的有效性, 为污水处理厂提供了切实有效的优化控制方案.

1 问题描述

1.1 过程描述

当前污水处理厂多采用活性污泥法作为处理工艺, 其中包含的微生物反应使得处理过程具有非线性和大滞后特性, 其工艺布局如图 1 所示, 图 1 中参数定义在表 1 中给出. 污水处理过程由两部分组成, 第 1 部分为生化反应区, 主要通过微生物反应清除污水中含氮污染物; 第 2 部分为二层池, 主要通过物理沉降功能实现泥水分离.

1.2 问题分析

图 1 所示的污水处理过程在运营过程中存在两个重要的考察指标, 能耗和出水水质. 能耗主要包括曝气能耗和泵送能耗, 代表污水处理过程 90% 的电能消耗. 出水水质则直接反映了污水处理过程的好坏. 对于一个给定的污水处理过程存在如下特性: 1) 生化反应的存在以及入水流量和组分浓度的剧烈变化, 使得其精确控制极其困难; 2) 当出水指标超标时需要支付昂贵的罚款, 大大提高了污水处理厂的运营成本; 3) 由于入水的变化, 专家需时刻关注污染物的变化从而制定合适的控制变量设定值, 需要专家浪费大量的精力才能完成这项任务.

2 污水处理混合智能优化控制系统

为了解决污水处理过程中能耗过大和底层跟踪控制平稳性较差的问题, 本文提出一种基于 KBMO-




图 1 污水处理系统工艺布局图

Fig. 1 Wastewater treatment system process layout

表 1 参数描述

Table 1 Parameters description

符号	描述
$D_{o,set}$	溶解氧设定值
$S_{no,set}$	硝态氮设定值
CT	控制器
MI	测量设备
Z_0	入水组分
Z_a	内回流组分
Z_r	外回流组分
Z_w	污泥组分
Z_e	出水组分
Q_0	入水流量
Q_a	内回流
Q_r	外回流
Q_w	污泥流
Q_e	出水流量

PSO 的多目标优化控制方法, 其控制结构如图 2 所示. 此系统包含知识库、多目标优化模块和底层前馈神经网络 (Feedforward neural network, FNN) 控制器模块.

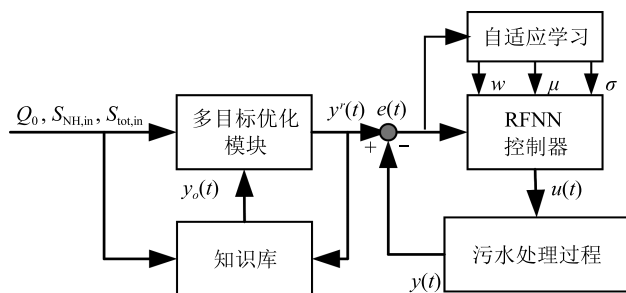


图 2 基于 KBMOPSO 的多目标优化控制方法

Fig. 2 Multiple objective optimization control system based on KBMOPSO

在图 2 中, y 和 y^r 分别代表控制变量实际输出以及控制变量设定值, C 表示知识库中的案例, e 为控制变量设定值与实际输出值之间的误差, w , μ 和 σ 分别代表 FNN 控制器的后件权值、隶属函数层神经元的中心以及宽度. 系统各模块描述如下:

1) 多目标优化模块. 通过分析污水处理过程特征, 以 Q_0 , $S_{NH,in}$, $S_{tot,in}$, $D_{o,set}$ 和 $S_{no,set}$ 作为相关变量, 建立能耗与出水水质模型, 此模型用于 KBMOPSO 适应度值计算, 通过 KBMOPSO 的智能搜索可以得到适应当前工况的溶解氧浓度和硝态氮浓度设定值.

2) 知识库. 知识库用于存储历史非支配解, 以 Q_0 , $S_{NH,in}$ 和 $S_{tot,in}$ 作为工况识别参考变量, 将参考变量与最优解建立关系形成知识模型存储在知识库中, 通过判定当前工况与知识库中历史非支配解对应工况的相似性, 进而在新的优化周期中应用历史非支配解初始化种群, 以引导 KBMOPSO 的搜索区域.

3) 底层控制器. 采用 FNN 设计底层控制器, 此控制器充分利用神经网络的非线性自适应能力, 在设定值以及工况发生变化时, 迅速调整参数以映射系统变化的输入输出关系.

2.1 知识库的建立与应用

本文提出一种基于知识的 MOPSO 智能优化搜索算法, 如图 3 所示.

2.1.1 知识表达

知识表达的一般方法包括属性特征值描述方法^[17]、框架表示方法^[18]和面向对象的方法^[19]等. 由于属性特征值描述方法具有简单明了的特点, 本文选用其作为知识库中案例的表达形式, 如第 k 个案例形式可表达为

$$C_k : \langle X_k; Y_k \rangle, \quad k = 1, 2, \dots, n \quad (1)$$

其中, n 表示案例的总数目, X_k 和 Y_k 分别表示第 k 个案例的工况识别参考变量和解决方案 (历史最优解).

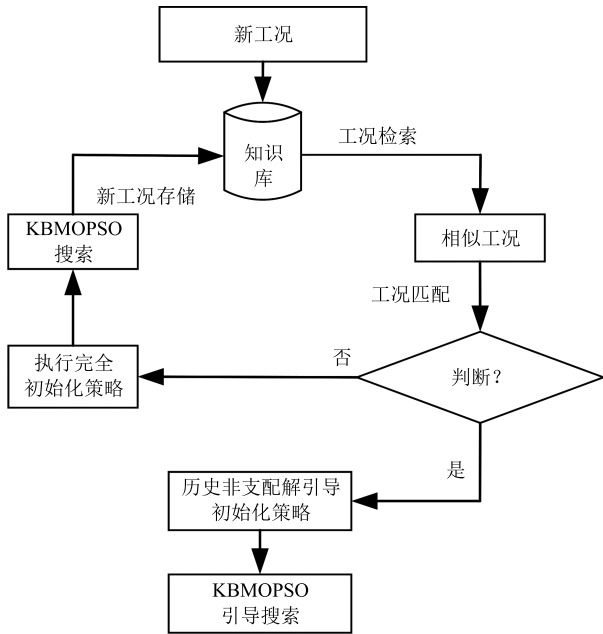


图3 KBMOPSO 程序流程图

Fig. 3 The program flow chart of KBMOPSO

2.1.2 工况检索和工况匹配

由于最近邻法简单实用, 本文利用其结构设计相似工况的搜索算法^[20-21]. 污水处理过程当前工况与知识库中第 k 个历史工况的检索方程可表示为

$$\begin{cases} s_k = 1 - \sum_{i=1}^3 w_i \text{sim}(x_i, x_{i,k}) \\ \text{sim}(x_i, x_{i,k}) = \frac{|x_i - x_{i,k}|}{\max(x_i, x_{i,k})} \end{cases} \quad (2)$$

其中, $\text{sim}(x_i, x_{i,k})$ 表示 X 和 X_k 之间的相似性, w_i 表示通过专家经验获得的第 i 个表达属性的权重值. 约束条件定义如下:

$$\sum_{i=1}^4 w_i = 1, \quad w_i \geq 0 \quad (3)$$

若满足条件

$$s_k \geq w_{th} \quad (4)$$

则第 k 个历史工况可视为匹配相似工况. 其中, w_{th} 是分析工况相似程度的阈值.

2.1.3 KBMOPSO 种群初始化

如果满足不等式 (4) 的案例数目是为 m , 种群大小为 N , 则 KBMOPSO 种群初始化为

步骤 1. 清除种群 P ;

步骤 2. 引用满足不等式 (4) 的历史非支配解作为 m 个种群初始解;

步骤 3. 随机初始化 $N - m$ 个解;

步骤 4. 初始化结束.

如果满足

$$\max_{k=1, \dots, n} (s_k) < w_{th} \quad (5)$$

表明没有符合条件的历史工况, 则 KBMOPSO 种群初始化为

步骤 1. 清除种群 P ;

步骤 2. 随机初始化 N 个解;

步骤 3. 初始化结束.

2.1.4 新工况存储

当式 (5) 满足条件时, 表明系统出现新的处理工况, 如图 3 中所示, 将 KBMOPSO 随机搜索种群初始化后计算得到的最优解作为新工况的解决方案, 建立工况识别参考变量与最优解之间关系, 形成知识模型存储在知识库中.

2.2 多目标优化模块

多目标优化模块包括目标函数的建立、多目标优化和 Pareto 解选取. 本文首先建立模糊神经网络的能耗和出水水质的数据驱动软测量模型作为目标函数, 然后利用多目标粒子群优化算法对目标函数进行优化, 最后利用模糊隶属函数法选取最优折衷解, 从而获得控制变量的优化设定值. 在 FNN 建模中, 将入水流量、溶解氧设定值和硝态氮设定值作为输入量, 能耗和出水水质作为输出量, 利用 BSM1 基准平台离线产生 500 组数据, 建立软测量模型. 在多目标粒子群优化算法 (Multi-objective particle swarm optimization, MOPSO) 中, 为了能够提供给决策系统足够多和足够好的解, 期望算法获得 Pareto 前沿尽可能收敛且分布均匀. 本文参考文献 [22], 利用动态拥挤距离法设计了一个新颖的 MOPSO 算法.

在 MOPSO 中, 粒子通过不断调整位置和速度的更新公式来寻找全局最优解, 本文所提的 MOPSO 算法更新公式如下:

$$v_i(t+1) = wv_i(t) + c_1r_1(pb_i - x_i(t)) + c_2r_2(gb_i - x_i(t)) + c_3r_3(pb_i - gb_i) \quad (6)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (7)$$

其中, t 为迭代次数, w 为惯性权重, c_1 , c_2 和 c_3 为学习因子, r_1 , r_2 和 r_3 为 $[0, 1]$ 之间均匀分布的随机数, pb_i 和 gb_i 为粒子 p_i 的个体引导者和全局引导者. 在式 (6) 中, 通过增加个体引导者和全局引导者之间的随机扰动提供给粒子更多的位置搜索信息, 有助于提高算法跳出局部最优的能力.

在 MOPSO 中, 利用外部档案 (Archive, AC) 保存非支配解, 通过判断拥挤距离维护外部档案.

首先将种群中的非支配解加入外部档案, 当外部档案中的非支配解个数超出设定的容量后, 动态删除拥挤距离小的非支配解. 个体引导者的选择利用 Pareto 支配关系确定, 全局引导者的选择利用规模为 2 的锦标赛法决定. 最终外部储备集中的非支配解作为多目标优化模块的输出结果提交给决策系统.

本文采用模糊隶属函数法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 x_k 的满意度定义如下:

$$\mu_i^k = \begin{cases} 1, & F_i(x_k) \leq F_i^{\min} \\ \frac{F_i^{\max} - F_i(x_k)}{F_i^{\max} - F_i^{\min}}, & F_i^{\min} < F_i(x_k) < F_i^{\max} \\ 0, & F_i(x_k) \geq F_i^{\max} \end{cases} \quad (8)$$

其中, $F_{\max,i}$ 和 $F_{\min,i}$ 分别是第 i 个目标函数 F_i 的最大值和最小值. 非支配解 x_k 的满意度为

$$\mu^k = \frac{\sum_{i=1}^M \mu_i^k}{\sum_{k=1}^{|A_r|} \sum_{i=1}^M \mu_i^k} \quad (9)$$

其中, M 是目标个数, $|A_r|$ 是外部储备集元素个数. 选取 μ_k 的最大值对应的解为折衷解. MOPSO 算法的伪代码如下:

算法 1. MOPSO 算法

- 1 set $t = 0$;
- 2 **Initialize the population**;
- 3 set $pb_i = p_i$;
- 4 add the nondominated vectors to the AC;
- 5 select gb_i from the AC;
- 6 **while** $t < T_{\max}$
- 7 **for** $i = 1$ to N
- 8 update the position x_i of p_i using (6) and (7);
- 9 evaluate the objective values for p_i ;
- 10 **if** pb_i cannot dominate p_i
- 11 set $pb_i = p_i$;
- 12 **end if**
- 13 add the nondominated vectors to the AC;
- 14 control the size of the AC;
- 15 select gb_i from the AC;
- 16 **end for**
- 17 $t = t + 1$
- 18 **end while**
- 19 Output A ;
- 20 Execute decision making system using (8) and (9);
- 21 Output the optimal solution.

2.3 底层控制模块

由于污水处理过程控制变量设定值频繁变化, 使得底层跟踪控制过程增加了难度, 本文基于模糊

神经网络 (Fuzzy neural network, FNN) 设计底层控制器, 利用梯度下降法在线更新网络中所含参数, 使得控制器的参数可以随着控制变量设定值的变化而调整, 改善了优化控制下的跟踪控制性能. FNN 结构如图 4 所示.

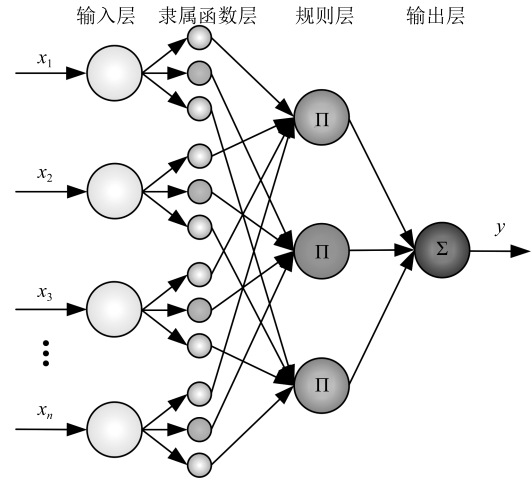


图 4 FNN 结构图

Fig. 4 The structure of FNN

采用 S 型 FNN 建立直接自适应控制器, 神经网络输出为

$$f(X) = \sum_{j=1}^n w_j \varphi_j = \frac{\sum_{j=1}^n \left[w_j \exp \left(-\frac{\|X - c_j\|^2}{\delta_j^2} \right) \right]}{\sum_{j=1}^n \exp \left(-\frac{\|X - c_j\|^2}{\delta_j^2} \right)} \quad (10)$$

其中, $X = [x_1, x_2, \dots, x_m]$ 为 FNN 的输入向量, m 为输入变量数, $c_j = [c_{1j}, c_{2j}, \dots, c_{mj}]$ 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, φ_j 是规则层第 j 个神经元归一化后的输出, w_j 为规则层第 j 个神经元与输出层神经元之间的连接权, $j = 1, 2, \dots, n$, n 为规则层神经元数.

控制量 u 为

$$u(t+1) = u(t) + \Delta u(t) \quad (11)$$

其中, $\Delta u(t) = f(X)$.

FNN 的参数学习采用梯度下降算法, 定义目标函数为

$$E(t) = \frac{1}{2} e_m(t)^2 = \frac{1}{2} (y_d(t) - y(t))^2 \quad (12)$$

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

$$\Theta(t+1) = \Theta(t) - \eta \frac{\partial E(t)}{\partial \Theta(t)} \quad (13)$$

其中, η 为 FNN 参数学习率.

3 实验结果及分析

3.1 评价指标

实验基于国际通用仿真平台 BSM1 进行, 评价指标由 BSM1 定义的曝气能耗 AE 、泵送能耗 PE 和出水水质 EQ 组成. 具体公式如下:

$$AE(k) = \frac{S_o^{sat}}{T \times 1.8 \times 1,000} \int_{kT}^{(k+1)T} V_5 K_L a_5(t) dt \quad (14)$$

$$PE(k) = \frac{1}{T} \int_{kT}^{(k+1)T} 0.004 Q_a(t) dt \quad (15)$$

$$EQ(k) = \frac{1}{T \times 1000} \int_{kT}^{(k+1)T} (B_{SS} \times SS_e(t) + B_{COD} \times COD_e(t) + B_{NO} \times S_{NO,e}(t) + B_{Nkj} \times S_{Nkj,e}(t) + B_{BOD5} \times BOD_e(t)) dt \quad (16)$$

3.2 参数设置

所有仿真实验均采用 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 秒, 优化周期为 2 小时, 采用晴好天气数据进行仿真分析. 底层控制器由两个自适应 FNN 组成, 通过试错法确定了网络结构 2-6-1, 为了保证控制器的稳定性, 参数学习率 η 不宜过大, 通过经验选择为 0.01.

3.3 结果及分析

知识库中初始案例数为 15 个, 采用区域平均分割生成. 实验数据源于 BSM1 文件, 晴朗天气共包含 14 天数据 (前 7 天数据用于训练, 后 7 天数据用于测试). 入水流量和入水组分变化如图 5 和图 6 所示, 图 5 显示入水流量及组分变动比较剧烈. 图 6 中 S_S 、 S_{NH} 和 S_{ND} 分别代表入水易生物降解底物、入水氨氮和入水溶性可生物降解有机氮.

案例生成曲线如图 7 所示, 图中显示案例在第 7 天左右达到 41 个时已包含所有案例, 之后优化时新案例不再增加, 这与 BSM1 对于数据的设置模式相符 (前 7 天数据和后 7 天数据类似), 表明了本文中所提方法关于知识库案例生成机制设置的合理性.

图 8 和图 9 分别给出了能耗和水质的 FNN 建




图 5 晴朗天气入水流量

Fig. 5 Influent flow in dry weather




图 6 晴朗天气入水组分

Fig. 6 Influent component in dry weather




图 7 案例数

Fig. 7 The case numbers

模效果. 从图 8 和图 9 可以看出, 通过数据驱动建立的模型精度较高, 可以作为多目标优化算法的目标函数. 图 10 给出了 KBMOPSO 与 MOPSO 在某个优化周期获得的 Pareto 解集以及通过智能决策系统选取的最优折衷解. 从图 10 可以看出, KBMOPSO 比 MOPSO 的收敛性更好, 获取的优化设定值能够使污水处理过程达到节能降耗的目的.




图 8 能耗建模效果

Fig. 8 Model performance of EC




图 9 出水水质建模效果

Fig. 9 Model performance of EQ

图 11 和图 12 分别给出了设定值优化结果及跟踪效果和出水水质参数变化情况. 由图 11 可以看出, KBMOPSO 能够根据处理工况的变化自适应调整优化设定值. 优化设定值的调整趋势与入水流量和入水水质参数的变化一致. 同时, 利用 FNN 实现的底层跟踪控制能够满足对控制精度的需求. 由图 12 可以看出, 相比 PID 恒定值控制, KBMOPSO 控制方法出水 N_{tot} 明显降低, 出水 SNH 等都没有较大变化. KBMOPSO 方法的出水水质指标也有一定程度的下降.




图 10 Pareto 最优解集及最优折衷解确定

Fig. 10 Pareto optimal solutions and identify of optimal





图 11 设定值优化结果及跟踪效果

Fig. 11 Optimization and tracking results of the set point values

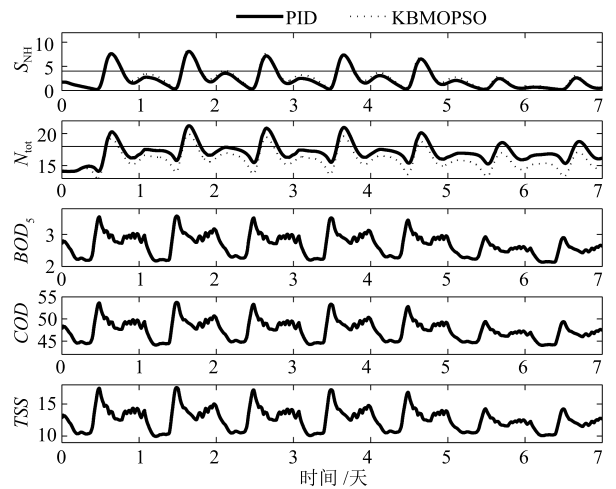


图 12 出水水质参数变化情况

Fig. 12 The change of water quality parameters

表2 不同算法性能比较
Table 2 Performance comparison for different algorithm

	$S_{O,5}$	$S_{NO,2}$	AE	PE	Energy	Up/Down	Fines	Up/Down
PID ^[8]	2*	1*	841.1*	86.2*	927.3*	—	5129.5	—
DDAOC ^[8]	1.5799*	1.087*	758.2*	89.8*	848.0*	↓ 8.50%*	5185.6	↑ 1.79%*
Hopfield ^[9]	—	—	814.8	63.4	878.2	↓ 5.30%*	—	—
SOOC ^[14]	—	—	852.6	53.8	906.4	↓ 2.25%*	—	—
DMOOC ^[14]	—	—	849.2	30.4	879.6	↓ 5.14%*	5440.9	↑ 6.07%*
MOPSO	1.5012	1.077	840.4	35.7	876.1	↓ 5.52%	5409.1	↑ 5.17%
KBMOPSO	1.3999	1.294	763.2	102.7	865.9	↓ 6.62%	5092.4	↓ 0.7%

* 表示参考了原文给出的结果

表2给出了不同算法之间的性能比较。从表2可以看出, KBMOPSO方法的总能耗为865.9 kWh/d, 出水水质5092.4 kg pollution/d, 相比PID恒定值控制, 分别下降了6.62%和0.7%。可见, 基于KBMOPSO的优化控制方法, 可以在不降低出水水质指标的前提下, 有效地降低了能耗, 节约了运行总成本。

4 结论

针对污水处理过程能耗较大的问题, 提出一种基于知识的智能优化控制方法。该方法采用具有案例表达、检索和修订等功能的知识模型对MOPSO的搜索过程进行引导, 实现了对溶解氧和硝态氮设定值的实时调优, 采用模糊神经网络构建底层控制器, 实现污水处理过程的底层精确跟踪控制。所提方法在实现出水水质达标的前提下, 有效地降低了能耗, 节约了操作成本。仿真实验结果也验证了混合智能优化方法能够有效降低系统运行总成本, 取得了较好的节能效果。

References

- Shannon M A, Bohn P W, Elimelech M, Georgiadis J G, Mariñas B J, Mayes A M. Science and technology for water purification in the coming decades. *Nature*, 2008, **452**(7185): 301–310
- Hamilton R, Braun B, Dare R, Koopman B, Svoronos S A. Control issues and challenges in wastewater treatment plants. *IEEE Control Systems*, 2006, **26**(4): 63–69
- Åmand L, Carlsson B. Optimal aeration control in a nitrifying activated sludge process. *Water Research*, 2012, **46**(7): 2101–2110
- Carlsson B, Rehnström A. Control of an activated sludge process with nitrogen removal — a benchmark study. *Water Science and Technology*, 2002, **45**(4–5): 135–142
- Wahab N A, Katebi R, Balderud J. Multivariable PID control design for activated sludge process with nitrification and denitrification. *Biochemical Engineering Journal*, 2009, **45**(3): 239–248
- Harja G, Nascu I, Muresan C, Nascu I. Improvements in dissolved oxygen control of an activated sludge wastewater treatment process. *Circuits, Systems, and Signal Processing*, 2016, **35**(6): 2259–2281
- Ostace G S, Baeza J A, Guerrero J, Guisasaola A, Cristea V M, Agachi P S, Lafuente J. Development and economic assessment of different WWTP control strategies for optimal simultaneous removal of carbon, nitrogen and phosphorus. *Computers and Chemical Engineering*, 2013, **53**: 164–177
- Qiao J F, Bo Y C, Chai W, Han H G. Adaptive optimal control for a wastewater treatment plant based on a data-driven method. *Water Science and Technology*, 2013, **67**(10): 2314–2320
- Han Guang, Qiao Jun-Fei, Han Hong-Gui, Chai Wei. Optimal control for wastewater treatment process based on Hopfield neural network. *Control and Decision*, 2014, **29**(11): 2085–2088
(韩广, 乔俊飞, 韩红桂, 柴伟. 基于Hopfield神经网络的污水处理过程优化控制. *控制与决策*, 2014, **29**(11): 2085–2088)
- Santín I, Pedret C, Vilanova R. Applying variable dissolved oxygen set point in a two level hierarchical control structure to a wastewater treatment process. *Journal of Process Control*, 2015, **28**: 40–55
- Zhang R, Xie W M, Yu H Q, Li W W. Optimizing municipal wastewater treatment plants using an improved multi-objective optimization method. *Bioresour Technol*, 2014, **157**: 161–165
- Sweetapple C, Fu G T, Butler D. Multi-objective optimisation of wastewater treatment plant control to reduce greenhouse gas emissions. *Water Research*, 2014, **55**: 52–62
- Hreiz R, Roche N, Benyahia B, Latifi M A. Multi-objective optimal control of small-size wastewater treatment plants. *Chemical Engineering Research and Design*, 2015, **102**: 345–353
- Qiao J F, Zhang W. Dynamic multi-objective optimization control for wastewater treatment process. *Neural Computing and Applications*, 2016. 1–11, DOI: 10.1007/s00521-016-2642-8

- 15 Mendes R, Rocha I, Pinto J P, Ferreira E C, Rocha M. Differential evolution for the offline and online optimization of fed-batch fermentation processes. *Advances in Differential Evolution*. Berlin: Springer-Heidelberg, 2008. 299–317
- 16 Wang Y, Li B. Investigation of memory-based multi-objective optimization evolutionary algorithm in dynamic environment. In: Proceedings of the 2009 IEEE Congress on Evolutionary Computation. Trondheim, Norway: IEEE, 2009. 630–637
- 17 Chai Tian-You. Operational optimization and feedback control for complex industrial processes. *Acta Automatica Sinica*, 2013, **39**(11): 1744–1757
(柴天佑. 复杂工业过程运行优化与反馈控制. *自动化学报*, 2013, **39**(11): 1744–1757)
- 18 Porter B W, Bareiss R, Holte R C. Concept learning and heuristic classification in weak-theory domains. *Artificial Intelligence*, 1990, **45**(1–2): 229–263
- 19 Cunningham P. A taxonomy of similarity mechanisms for case-based reasoning. *IEEE Transactions on Knowledge and Data Engineering*, 2009, **21**(11): 1532–1543
- 20 Cover T, Hart P. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 1967, **13**(1): 21–27
- 21 Zhou P, Chai T Y, Wang H. Intelligent optimal-setting control for grinding circuits of mineral processing process. *IEEE Transactions on Automation Science and Engineering*, 2009, **6**(4): 730–743
- 22 Cheng S X, Zhan H, Shu Z X. An innovative hybrid multi-objective particle swarm optimization with or without constraints handling. *Applied Soft Computing*, 2016, **47**: 370–388



乔俊飞 北京工业大学教授. 主要研究方向为智能控制, 神经网络分析与设计. 本文通信作者.

E-mail: junfeq@bjut.edu.cn

(QIAO Jun-Fei Professor at Beijing University of Technology. His research interest covers intelligent control, analysis and design of neural networks. Corresponding author of this paper.)



韩改堂 北京工业大学博士研究生. 主要研究方向为计算智能与智能系统, 神经网络结构设计和优化.

E-mail: hangaitang@emails.bjut.edu.cn

(HAN Gai-Tang Ph.D. candidate at Beijing University of Technology. His research interest covers computational intelligence and intelligent systems, analysis and design of neural networks.)



周红标 北京工业大学博士研究生. 主要研究方向为神经网络结构设计与优化, 多目标优化和过程控制系统.

E-mail: hyitzhb@163.com

(ZHOU Hong-Biao Ph.D. candidate at Beijing University of Technology. His research interest covers analysis and design of neural networks, multi-objective optimization, and process control systems.)