

污水处理决策优化控制

栗三一^{1,2} 乔俊飞^{1,2} 李文静^{1,2} 顾镛^{1,2}

摘要 以抑制出水氨氮浓度、总氮浓度峰值和降低能耗为目标, 提出污水处理决策优化控制方法. 首先利用神经网络建立出水氨氮和总氮预测模型; 其次使用多目标进化算法得到溶解氧浓度和硝态氮浓度设定值; 最后, 根据出水氨氮和总氮浓度预测结果选择控制策略(优化控制和抑制控制). 以仿真基准模型(BSM1)为平台, 采用提出的决策优化控制方法进行控制, 实验结果表明, 该控制方法有效抑制了出水氨氮和总氮浓度峰值, 出水超标时间和能耗明显少于所对比决策控制方法.

关键词 污水处理, 决策控制, 优化控制, 预测模型

引用格式 栗三一, 乔俊飞, 李文静, 顾镛. 污水处理决策优化控制. 自动化学报, 2018, 44(12): 2198–2209

DOI 10.16383/j.aas.2018.c170257

Advanced Decision and Optimization Control for Wastewater Treatment Plants

LI San-Yi^{1,2} QIAO Jun-Fei^{1,2} LI Wen-Jing^{1,2} GU Ke^{1,2}

Abstract In order to inhibit the peak of ammonia nitrogen ($S_{NH,e}$) and total nitrogen ($S_{Ntot,e}$) concentrations in effluent and reduce energy consumption, we present in this paper a decision and optimization control method. Firstly, we establish the prediction models of $S_{NH,e}$ and $S_{Ntot,e}$ with neural network. Secondly, we optimize the set points of dissolved oxygen concentration and nitrate nitrogen concentration with multiobjective evolutionary algorithm. Lastly, select control strategy (optimal control strategy or inhibitory control strategy) based on the outcome of prediction models. Evaluation is carried out with the Benchmark Simulation Model No.1. The results show that the proposed method restrains the peaks of $S_{NH,e}$ and $S_{Ntot,e}$ effectively while the percentages of time of $S_{NH,e}$ and $S_{Ntot,e}$ violations are less than those of the compared inhibitory control methods, and that the energy consumption using the proposed method is less than that using the counterpart inhibitory control method significantly.

Key words Wastewater treatment, optimal control, inhibitory control, prediction model

Citation 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

污水处理可有效缓解水资源匮乏问题和减少环境污染^[1–2]. 然而污水处理过程的控制面临以下难题^[3]: 1) 生化反应过程十分复杂, 拥有众多变量且变量之间耦合严重; 2) 流入污水的浓度和流量是时变的; 3) 在出水达标的情况下需要尽可能降低能耗, 提高水质.

针对污水处理过程控制问题, 国内外学者做了大量研究. Mulas 等^[4] 将多变量预测控制应用于市政污水处理的活性污泥过程, 以最小化经济花费和

提高总氮去除率为目标, 使用动态矩阵控制算法控制水总氮浓度 ($S_{Ntot,e}$), 实验表明该方法可以同时减少能耗和降低 $S_{Ntot,e}$ 峰值. Santín 等^[5] 针对污水处理过程提出一种二级分层控制结构, 使用模糊控制动态调节第五分区溶解氧浓度 ($S_{O,5}$) 设定值, 底层使用模型预测控制器对 $S_{O,5}$ 进行跟踪控制, 达到降低能耗和提高水质的目标. Egea 等^[6] 以能耗和水质为目标, 使用 epsilon 约束和分散搜索技术搜索 pareto 解, 直接对第五分区氧转换系数 ($K_{La,5}$) 和内回流量 (Q_a) 进行控制. Yang 等^[7] 使用模糊 c 均值聚类方法和最小二乘方法对污水处理过程建立模糊模型, 根据模糊模型设计模型预测控制器对 $S_{O,5}$ 进行控制, 实验表明该控制器在暂态过程和稳态过程都有很好的控制效果. Vega 等^[8] 将非线性模型预测控制应用于污水处理分层控制, 在优化层分别使用静态优化算法和动态优化算法对 $S_{O,5}$ 和第二分区硝态氮浓度 ($S_{NO,2}$) 进行优化, 底层跟踪控制使用非线性模型预测控制, 该控制策略在固定设定值、PID 控制的基础上降低 20% 能耗. Han 等^[9] 对污水处理过程提出非线性多目标模型预测控制方法, 该方法

收稿日期 2017-05-12 录用日期 2017-08-02
Manuscript received May 12, 2017; accepted August 2, 2017
国家自然科学基金(61533002), 国家杰出青年科学基金项目(61603009) 资助

Supported by National Natural Science Foundation of China (61533002) and National Science Fund for Distinguished Young Scholars (61603009)

本文责任编辑 赵千川
Recommended by Associate Editor ZHAO Qian-Chuan

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

使用自组织径向基函数 (Radial basis function, RBF) 神经网络建立预测模型, 使用多目标梯度优化方法对 $S_{O,5}$ 和 $S_{NO,2}$ 进行动态调节, 以达到降低能耗的目标. 以上研究以提高水质或减少能耗为目标, 取得了令人满意的效果, 但忽视了出水氨氮浓度 $S_{NH,e}$ 和 $S_{Ntot,e}$ 峰值超标的问题. $S_{NH,e}$ 和 $S_{Ntot,e}$ 超标不仅会污染环境、危害人体健康, 而且会因排污超标受到罚款, 造成污水处理厂的经济损失.

在解决 $S_{NH,e}$ 和 $S_{Ntot,e}$ 峰值超标问题方面, Santín 等^[10] 于 2016 年首次提出污水处理决策控制方法. 该方法以入水流量、入水氨氮浓度预测 $S_{NH,e}$ 和 $S_{Ntot,e}$, 对外加碳源量和 Q_a 进行模糊控制, 从而达到抑制 $S_{NH,e}$ 和 $S_{Ntot,e}$ 峰值的目的. 该方法有效抑制了 $S_{NH,e}$ 和 $S_{Ntot,e}$ 峰值, 但存在能耗较大的问题.

以在抑制 $S_{NH,e}$ 和 $S_{Ntot,e}$ 峰值的情况下降低能耗为目标, 本文提出污水处理决策优化控制方法. 首先使用神经网络建立 $S_{NH,e}$ 和 $S_{Ntot,e}$ 预测模型; 然后使用局部搜索 NSGA2 算法对能耗和水质进行优化, 结合预测模型从 Pareto 解中选取合适的解作为溶解氧和硝态氮浓度设定值; 最后根据预测模型的输出判断 $S_{NH,e}$ 和 $S_{Ntot,e}$ 是否超标. 如果超标, 则使用模糊控制方法对外部碳源和 Q_a 进行控制, 抑制峰值. 如果不超标, 则使用模糊控制器控制 Q_a 和 $K_{La,5}$ 对设定值进行跟踪控制. 本文提出方法的优势在于:

1) 将 $S_{O,5}$ 和 $S_{NO,2}$ 加入预测模型输入. 由于 $S_{O,5}$ 和 $S_{NO,2}$ 对 $S_{NH,e}$ 和 $S_{Ntot,e}$ 有重要影响^[11], 将其加入预测模型输入端, 提高了预测模型的精度.

2) 提出时滞时间计算方法. 根据每天的入水氨氮和 $S_{NH,e}$ 峰值时间差估算延迟时间, 对建立预测模型数据采样提供支持.

3) 为了避免多目标进化算法陷入局部最优, 使用基于密度的局部搜索 NSGA2 算法 (NSGA2-DLS)^[12] 对能耗和水质进行优化, 在出水达标的情况下有效地降低能耗.

4) 将预测模型应用于最优解的选取过程, 从而将优化控制与决策控制有机结合. 该最优解选取策略可以优先通过调节设定值确保出水水质达标, 从而尽可能降低能耗.

5) 预测模型可以预测一段时间之后的 $S_{NH,e}$ 和 $S_{Ntot,e}$, 从而可以根据预测结果进行提前控制, 有效抑制峰值超标.

1 建立预测模型

考虑到污水处理是一个大滞后过程, 根据当前入水情况建立预测模型, 预测一段时间之后的出水污染物浓度, 从而可以根据预测结果进行提前控制.

1.1 数据采集

本文以活性污泥污水处理基准仿真模型 BSM1^[13] 为实验平台进行数据采集和实验验证. 首先使 BSM1 模型开环运行 14 天, 记录入水氨氮浓度、第二分区氨氮浓度、第五分区氨氮浓度和 $S_{NH,e}$, 其浓度变化曲线如图 1 所示. 记录每天各区域氨氮浓度峰值对应的时刻, 计算每天从入水到第二分区、第五分区和出水的滞后时间, 每天的滞后时间如表 1 所示.




图 1 14 天不同区域氨氮浓度曲线

Fig. 1 Ammonia nitrogen concentration curve in different regions within 14 days

表 1 不同区域到入水氨氮浓度最大时刻滞后时间 (h)

Table 1 The time lag from inflow to different regions (h)

	第二分区	第五分区	出水
第 1 天	0.2375	1.1000	4.4375
第 2 天	0.2375	1.3250	4.5750
第 3 天	0.2375	1.1625	4.6000
第 4 天	0.2375	1.3500	4.6875
第 5 天	0.2375	1.1500	4.6500
第 6 天	0.4875	1.5625	5.2875
第 7 天	0.4875	1.6750	5.2750
第 8 天	0.2375	1.1250	4.4875
第 9 天	0.2375	1.3250	4.5750
第 10 天	0.2375	1.1625	4.6000
第 11 天	0.2375	1.3500	4.6875
第 12 天	0.2375	1.1500	4.6500
第 13 天	0.4875	1.5625	5.2875
第 14 天	0.4875	1.6750	5.2750

然后根据每天的滞后时间对数据进行采样. 由于 $S_{O,5}$ 和 $S_{NO,2}$ 对 $S_{NH,e}$ 和 $S_{Ntot,e}$ 有重要影

响^[11], 本文以入水流量、入水氨氮、当前出水氨氮浓度、 $S_{O,5}$ 和 $S_{NO,2}$ 作为 $S_{NH,e}$ 预测模型输入变量, 以入水流量、入水总氮、当前出水总氮浓度、 $S_{O,5}$ 和 $S_{NO,2}$ 作为 $S_{Ntot,e}$ 预测模型输入变量. 根据实际经验将 $S_{O,5}$ 浓度设定值设定在 1.4~2.4 mg/l, $S_{NO,2}$ 浓度设定值设定在 0.5~1.5, 设定值设定后即在 BSM1 模型上运行 14 天, 每 15 分钟采样一次, 取不同的设定值的组合方式, 共获得 199 727 组数据.

1.2 神经网络建模

本文使用前馈神经网络建立出水氨氮和总氮浓度预测模型, 模型示意图如图 2 和图 3 所示. 两个神经网络模型的结构均为 5-50-1 (试错法确定隐含层神经元数). 将采样获得的 199 727 组数据随机选取 181 570 组作为训练样本, 剩余数据作为测试样本. 权值初始化采用文献 [14] 提出的方法, 训练时将数据归一化到 [-1, 1], 使用 BP 算法对网络进行训练^[15], 初始学习率设为 0.1, 最大学习步数为 4 000 步. 模型测试均方根误差 (Root mean square error, RMSE) 如表 2 所示. Santín 等^[10] 建立预测模型时仅将入水氨氮浓度、入水流量和温度作为预测模型的输入, 本文将对 $S_{NH,e}$ 和 $S_{Ntot,e}$ 有重要影响的 $S_{O,5}$ 和 $S_{NO,2}$ 加入输入变量, 从表 2 的结果可以看出, 将 $S_{O,5}$ 和 $S_{NO,2}$ 加入模型输入端有效提高了预

表 2 预测模型测试均方根误差 (10 次实验平均值)
Table 2 Test RMSE of prediction model
(mean value of ten test results)

方法	氨氮预测模型	总氮预测模型
	RMSE	RMSE
决策优化控制	0.4241	0.3506
Santín ^[10]	0.9771	0.7515

测模型的精度.

污水处理过程中各变量耦合严重, 对 $S_{NH,e}$ 和 $S_{Ntot,e}$ 浓度有影响的变量很多, 根据机理分析和已有的研究^[10-11, 16], 本文选取影响最大的五个变量作为模型输入, 但预测值不可避免与实际值存在误差, 下面讨论该误差对本文提出的控制策略的影响.

在 BSM1 平台上进行开环运行 14 天, 使用建立的预测模型对 $S_{NH,e}$ 和 $S_{Ntot,e}$ 进行预测并与实际值进行对比, 仿真结果如图 4 和图 5 所示. 图中实线曲线表示实际浓度曲线, 虚线表示模型预测曲线, 从图 4 和图 5 可以看出, 每天城市污水的出水量是




图 2 出水氨氮浓度预测模型

Fig. 2 Prediction model of $S_{NH,e}$

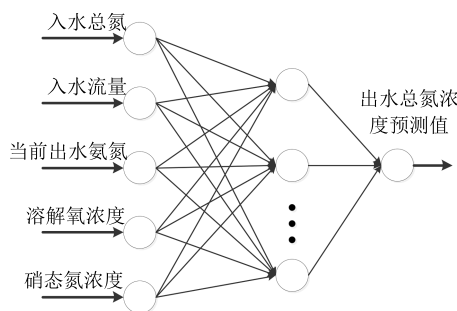


图 3 出水总氮浓度预测模型

Fig. 3 Prediction model of $S_{Ntot,e}$




图 4 出水氨氮浓度预测曲线

Fig. 4 Prediction curve and actual curve of $S_{NH,e}$




图 5 出水总氮浓度预测曲线

Fig. 5 Prediction curve and actual curve of $S_{Ntot,e}$

不断变化的, 而且最高值和最低值相差比较大, 在国家规定的浓度上限值 ($S_{\text{NH},e}$ 和 $S_{\text{Ntot},e}$ 的上限值分别为 4 mg/l 和 18 mg/l) 附近曲线的变化率很大, 模型在该上限值附近预测误差并不大. 共存在四种情况, 下面分别进行讨论.

第一种情况是峰值超标严重, 从图 4 和图 5 可以看出, 最多提前或滞后半小时启动应急操作, 对于污水处理这样的慢反应过程而言在可接受范围之内. 根据实际情况, 当对污水处理过程没有相应操作时, 出水不会长时间固定在国家标准附近, 也就是说不存在长时间误判超标的情况.

第二种情况是峰值超标但超标值很少, 从图中可以看到, 峰值持续时间都比较短, 即使误判为没有超标, 出水氨氮和总氮浓度也会很快降到标准以下, 因此这种情况影响不大.

第三种情况是峰值接近上限值但没有超标, 这种情况可能存在误判超标从而启动应急操作. 从实验结果可以看到, 误判的时间持续很短暂, 在 $1 \sim 2$ 个小时内就会达到终止应急操作的条件, 因此造成的损失有限.

第四种情况为峰值距离上限值较远, 这种情况下判断基本准确, 不会进行误操作.

从以上分析可以看出, 出水氨氮和总氮预测模型的输出与实际值存在偏差, 但对实际操作造成的损失并不大, 即使误判也会在较短时间内更正操作.

2 设定值动态优化

$S_{\text{O},5}$ 和 $S_{\text{NO},2}$ 不仅对 $S_{\text{NH},e}$ 和 $S_{\text{Ntot},e}$ 有重要影响, 而且直接受 $K_{\text{La},5}$ 和 Q_a 的影响, 对其浓度设定值进行优化可以有效降低能耗^[11]. 因此本文首先使用神经网络建立能耗模型和水质模型作为优化目标函数, 然后使用多目标进化算法对目标进行优化, 结合之前建立的预测模型挑选合适的解作为 $S_{\text{O},5}$ 和 $S_{\text{NO},2}$ 的设定值.

2.1 建立能耗、水质模型

使用多目标优化算法调整 $S_{\text{O},5}$ 和 $S_{\text{NO},2}$ 设定值, 首先需要确定目标函数. 根据课题研究背景, 将能耗和水质作为优化算法的两个目标函数. 由于污水处理过程影响能耗和水质的因素众多, 且各影响因素之间关系复杂, 能耗模型和水质模型难以直接获得. 本文使用前馈神经网络建立能耗和水质模型.

能耗模型和水质模型输入变量均为出水悬浮物浓度、 $S_{\text{NH},e}$ 、 $S_{\text{O},5}$ 和 $S_{\text{NO},2}$ ^[17]. 数据采集不考虑时间延迟, 每 15 分钟采集一次数据, 数据采集方法与第 1.1 节相同, $S_{\text{NO},2}$ 浓度设定值和 $S_{\text{O},5}$ 浓度设定值在取值范围内取不同的数值在 BSM1 平台上进行实验, 共记录 295 669 组数据进行建模, 其中 268 790

组数据用于训练, 26 879 组数据用于测试, 模型结构 4-40-1 (试错法确定隐含层神经元). 参数设定和训练方法与建立预测模型相同. 能耗模型测试 RMSE 为 0.0883, 水质模型测试 RMSE 为 0.4202.

2.2 优化问题模型

污水处理过程优化问题可以表示为以下数学形式:

$$\min \begin{cases} F_1(X) = f_1(X) + \Delta \\ F_2(X) = f_2(X) + \Delta \end{cases}$$

$$X = (x_1, x_2), \quad l_i \leq x_i \leq u_i, \quad i = 1, 2 \quad (1)$$

其中, F_1 和 F_2 为两个目标函数, 分别代表能耗和水质; f_1 和 f_2 为第 2.1 节建立的能耗模型和水质模型; 决策向量 X 的两个元素 (x_1, x_2) 分别表示第五分区溶解氧浓度和第二分区硝态氮浓度; l_i 和 u_i 分别为第 i 个决策变量的下界和上界; Δ 为超标惩罚项, 计算公式为

$$\Delta = 100(C_{\text{NH}} + C_{\text{Ntot}})$$

$$C_{\text{NH}} = \begin{cases} f_{\text{NH}}(x_1, x_2) - 4, & \text{若 } f_{\text{NH}}(x_1, x_2) \geq 4 \\ 0, & \text{若 } f_{\text{NH}}(x_1, x_2) < 4 \end{cases}$$

$$C_{\text{Ntot}} = \begin{cases} f_{\text{Ntot}}(x_1, x_2) - 18, & \text{若 } f_{\text{Ntot}}(x_1, x_2) \geq 18 \\ 0, & \text{若 } f_{\text{Ntot}}(x_1, x_2) < 18 \end{cases} \quad (2)$$

其中, C_{NH} 和 C_{Ntot} 分别表示预测出水氨氮浓度超标值和预测出水总氮超标值; f_{NH} 和 f_{Ntot} 分别表示第 1 节建立的 $S_{\text{NH},e}$ 预测模型和 $S_{\text{Ntot},e}$ 预测模型; 4 和 18 分别为国家规定的 $S_{\text{NH},e}$ 和 $S_{\text{Ntot},e}$ 上限值.

2.3 种群稀疏度求取

本文实验初始种群总数 N 为 100, 即有 N 个解, 首先对目标函数值进行归一化. 设第 i 个解 X^i 的目标向量为 $(F_1(X^i), F_2(X^i))$, 则归一化公式为^[18]

$$\bar{F}_j(X^i) = \frac{F_j(X^i) - F_{j \min}}{F_{j \max} - F_{j \min}} \quad (3)$$

其中, $F_{j \min}$ 和 $F_{j \max}$ 分别为当前所有解对应的第 j 个目标函数值的最大值和最小值. 归一化后第 i 个解 X^i 的稀疏度计算公式为

$$SP(X^i) = \frac{n_i}{N} \quad (4)$$

其中, n_i 为目标函数空间中与目标向量 $F(X^i)$ 欧氏距离小于 r 的其他目标向量的个数, r 的取值范围为 $0 < r < 1$, 本文所有实验取 0.1.

2.4 局部搜索过程

将当前稀疏度最小的非支配解 $X = (x_1, x_2)$ 作为稀疏解, 种群总数 N 为 100, 决策变量个数 n 为 2. 为了增加收敛精度, 首先使用极限优化^[19] 变异方法进行局部搜索, 产生局部解个数为 n , 产生局部解的变异公式为

$$X_i = \{x_1, \dots, x'_i, \dots, x_n\}, \quad 0 < i \leq n \quad (5)$$

$$x'_i = x_i + \alpha \times \beta_{\max}(x_i), \quad 0 < i \leq n \quad (6)$$

$$\alpha = \begin{cases} (2h)^{\frac{1}{q+1}} - 1, & 0 < h < 0.5 \\ 1 - (2(1-h))^{\frac{1}{q+1}}, & 0.5 \leq h < 1 \end{cases} \quad (7)$$

$$\beta_{\max}(x_i) = \max[x_i - l_i, u_i - x_i], \quad 0 < i \leq n \quad (8)$$

其中, x_i 为决策变量; h 为 0~1 的随机数; q 为正实数, 称为形状参数, 本文将 q 设为 11; $\beta_{\max}(x_i)$ 为当前决策变量 x_i 可变动的最大值.

其次使用随机移民策略进行变异操作, 增加收敛速度的同时避免陷入局部最优. 该变异策略则产生局部解个数为种群总数的 20% (如不能整除则取整), 变异公式为

$$X_k = (x'_1, \dots, x'_i, \dots, x'_n), \quad k = 1, 2, \dots, [0.2N] \quad (9)$$

$$x'_i = \gamma x_i, \quad i = 1, 2, \dots, n, \quad 0 < \gamma < 1.2 \quad (10)$$

其中, γ 为 0~1.2 的随机数. 以上两种变异策略共产生 $n + [0.2N]$ 个局部解.

2.5 多目标优化步骤

使用 NSGA2-DLS^[12] 算法进行多目标优化. 溶解氧浓度取值范围为 [1.4, 2.7], 硝态氮浓度取值范围为 [0.5, 1.5]. 初始种群数量 N 为 100, 最大函数调用次数 I_{\max} 为 30, 交叉概率 0.9; 变异概率 0.01. 形状参数 q 为 11. 具体优化步骤如下:

步骤 1. 在取值范围内随机初始化种群 $P_I = \{X^1, X^2, \dots, X^N\}$, 其中, $X^i = (x_1^i, x_2^i)$.

步骤 2. 计算 P_I 中所有解的适应度值和拥挤距离 (与标准 NSGA2 相同), 对 P_I 中的解进行非支配排序, 当前种群中所有非支配解记为 P_C .

步骤 3. 按照标准 NSGA2 算法对 P_I 中的种群进行交叉变异, 形成子代 P_M .

步骤 4. 在目标函数空间内, 按式 (3) 和式 (4) 计算 P_C 中所有解的稀疏度, 选择稀疏度最小的解作为稀疏解 $X = (x_1, x_2)$.

步骤 5. 按式 (5)~(10) 形成 $n + [0.2N]$ 个局部解, 所有局部解组成种群 P_N , P_N 参与到下一代的竞争中.

步骤 6. 将 P_I , P_N 和 P_M 合并, 并对所有解进行非支配排序和拥挤距离计算, 从中选取最优的 N 个解形成下一代种群 P_O , 并设 $P_I = P_O$. P_O 的选取规则为: 优先选取非支配解, 当非支配解数量不足 N 时, 选取次优解, 以此类推, 直到解的数量达到 N 为止; 在同一等级的解中, 拥挤距离大的解优先选取.

步骤 7. 重复步骤 2~6, 当达到最大迭代步数 I_{\max} 时进行下一步.

步骤 8. 当前 P_I 中的非支配解即为得到的最优解.

2.6 最优解选取

使用多目标优化算法得到多个非支配解, 需要从中选取合适的解作为 $S_{O,5}$ 和 $S_{NO,2}$ 设定值. 从非支配解集中选取解时, 具体步骤如下:

步骤 1. 将得到的所有非支配解带入预测模型, 将出水指标达标的解加入解集 P_D .

步骤 2. 若 P_D 不为空集, 则降低能耗为主要目标, 从 P_D 中选取能耗最低的解作为设定值.

步骤 3. 若 P_D 为空集, 则抑制出水污染浓度为重要目标, 从非支配解中选取水质最高的解作为设定值.

该最优解选取方法将预测模型应用于最优解的选取过程, 可以优先通过调节设定值确保出水水质达标, 从而尽可能降低能耗.

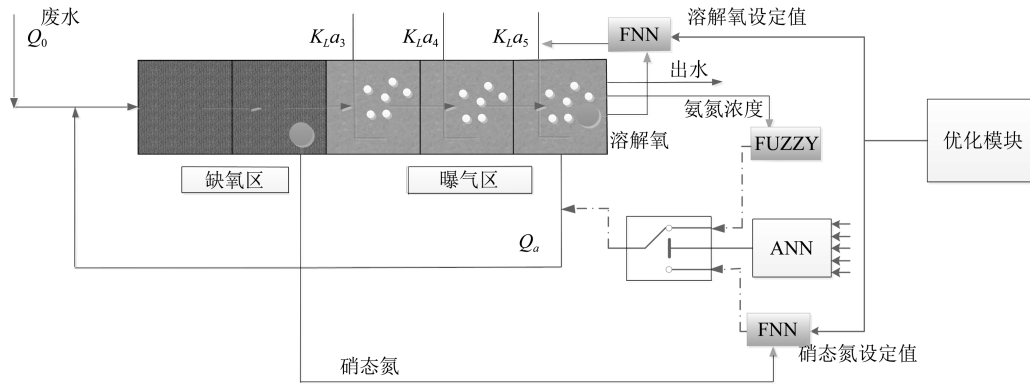
3 决策优化控制

根据第 2 节得到 $S_{O,5}$ 和 $S_{NO,2}$ 设定值, 将设定值带入 $S_{NH,e}$ 和 $S_{Ntot,e}$ 预测模型. 如果预测出水水质达标则切换到跟踪控制策略, 对 $S_{O,5}$ 和 $S_{NO,2}$ 进行跟踪控制. 如果预测 $S_{NH,e}$ 或 $S_{Ntot,e}$ 超标, 则切换到抑制控制策略, 对峰值进行抑制. 控制策略图如图 6 所示.

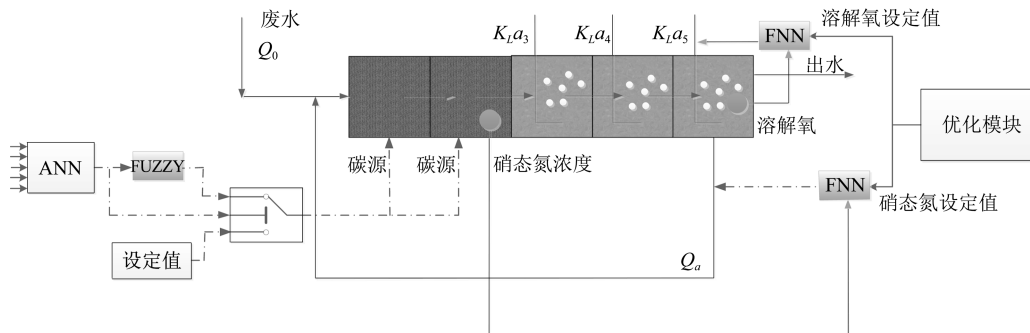
3.1 溶解氧、硝态氮浓度跟踪控制

当预测 $S_{NH,e}$ 和 $S_{Ntot,e}$ 都不超标时, 使用两个模糊控制器分别控制 $K_{La,5}$ 和 Q_a , 从而对 $S_{O,5}$ 和 $S_{NO,2}$ 进行跟踪控制.

$S_{O,5}$ 模糊跟踪控制器的输入为当前浓度与设定值之间的误差 e_o 和 Δe_o 误差变化量, 输出为 $K_{La,5}$ 变化量 $\Delta K_{La,5}$. K_e , K_{ec} 和 K_u 分别为误差、误差变化量的量化因子和曝气变化量的比例因子, 分别设为 10, 6, -20. e_o 和 $\Delta K_{La,5}$ 的基本论域为 [-6, 6], Δe_o 的基本论域为 [-4, 4]. e_o 和 $\Delta K_{La,5}$ 对应的模糊子集为: {NB, NM, NS, ZO, PS, PM, PB}, 分别表示负大, 负中, 负小, 零, 正小, 正中, 正大. Δe_o 的模糊子集为: {NB, NS, ZO, PS, PB}, 分别表示负大, 负小, 零, 正小, 正大. e_o 和 Δe_o 的语言变量



(a) $S_{NH,e}$ 峰值超标抑制控制策略图
(a) Control strategy for $S_{NH,e}$ violations removal



(b) $S_{Ntot,e}$ 峰值超标抑制控制策略图
(b) Control strategy for $S_{Ntot,e}$ violations removal

图 6 决策优化控制示意图

Fig. 6 The proposed decision and optimization control system

分别用 E 和 EC 表示, 模糊控制器规则表如表 3 所示.

表 3 $S_{O,5}$ 模糊跟踪控制器模糊规则
Table 3 Fuzzy rules of $S_{O,5}$ fuzzy controller

E	EC				
	NB	NS	ZO	PS	PB
NB	PB	PB	PB	PM	ZO
NM	PB	PB	PM	PS	ZO
NS	PM	PM	PS	ZO	NS
ZO	PM	PS	ZO	NS	NS
PS	PS	ZO	NS	NM	NM
PS	ZO	NS	NM	NB	NB
PB	ZO	NM	NB	NB	NB

$S_{NO,2}$ 模糊跟踪控制器的输入为当前浓度与设定值之间的误差 e_{NO} 和误差变化量 Δe_{NO} , 输出为 Q_a , 对应的量化因子和比例因子分别为 12, 40 和 -2500. 论域、模糊子集和模糊规则与 $S_{O,5}$ 跟踪控制器相同.

3.2 出水氨氮浓度峰值抑制控制

当预测 $S_{NH,e}$ 超标时, 使用一个模糊控制器对 Q_a 进行控制, 从而抑制出水氨氮峰值. 当预测出水氨氮超标时, 首先增加 Q_a 稀释流入第一分区的氨氮浓度; 当氨氮浓度峰值到达第五分区时, 减少 Q_a 以增加水力停留时间, 从而促进硝化反应. 在调整 Q_a 的同时, 将第五分区溶解氧设定值设定为原来的 1.5 倍.

模糊控制器的输入为第五分区氨氮浓度 ($S_{NH,5}$), 输出为 Q_a . 输入和输出变量都包含三个模糊子集: {L, M, H} 分别表示低、中和高. 模糊规则如下:

- If** ($S_{NH,5}$ is H), **then** (Q_a is L);
- If** ($S_{NH,5}$ is M), **then** (Q_a is M);
- If** ($S_{NH,5}$ is L), **then** (Q_a is H).

$S_{NH,5}$ 的取值范围为 3~4.1 mg/l, Q_a 的取值范围为 3 000~200 000 m^3/d . 当预测出水氨氮达标并且 $S_{NH,5}$ 小于 3.5 mg/l 时切换回模糊跟踪控制.

3.3 出水总氮浓度峰值抑制控制

当预测 $S_{Ntot,e}$ 超标时, 根据 $S_{Ntot,e}$ 预测值对

第一分区外加碳源 ($qEC1$) 和第二分区外加碳源 ($qEC2$) 进行模糊控制, 增加碳源可以促进反硝化作用, 去除氮元素. 模糊控制器的输入为出水总氮预测值 ($S_{N_{tot}}$), 输出为外加碳源量 qEC . 输入和输出变量都包含三个模糊子集: {L, M, H} 分别表示低、中和高. 模糊规则如下:

If ($S_{N_{tot}}$ is H), then (qEC is H);
 If ($S_{N_{tot}}$ is M), then (qEC is M);
 If ($S_{N_{tot}}$ is L), then (qEC is L).

$S_{N_{tot}}$ 的取值范围为 $17 \sim 19.5$ mg/l, qEC 的取值范围为 $4 \sim 7$ m³/d, $qEC1$ 的最大值为 5, 若 $qEC < 5$, 则 $qEC1 = qEC$, 否则 $qEC1 = 5$, $qEC2 = qEC - 5$. 当预测出水总氮低于 17 mg/l 并且第五分区总氮低于 13.5 mg/l 时, 切换回模糊跟踪控制.

4 实验结果及分析

本文主要做了两组实验, 一组实验采用基于 NSGA2-DLS 的优化控制策略进行污水处理控制, 结果与已有的优化控制方法对比, 主要目的为验证 NSGA2-DLS 在解决污水处理优化问题方面的有效性. 另一组实验采用本文提出的决策优化控制策略, 结果与其他决策控制方法对比, 验证本文提出的决策优化控制策略可以在抑制 $S_{NH,e}$ 和 $S_{N_{tot},e}$ 超标的基础上降低能耗. 所有实验采用 MATLAB10.0b 软件进行仿真实验, 实验平台为国际通用仿真平台 BSM1.

4.1 评价指标

污水处理后出水水质限制如表 4 所示, 包括 $S_{NH,e}$, $S_{N_{tot},e}$, 固体悬浮物浓度 TSS, 5 天生物需氧量 BOD₅ 和化学需氧量 COD.

表 4 出水水质限制
 Table 4 Effluent quality limits

水质	上限值 (mg/l)
$S_{NH,e}$	4
$S_{N_{tot},e}$	18
TSS	30
BOD ₅	10
COD	100

本文使用的评价指标主要有: 水质 EQ 、总费用 OCI 和水质超标时间百分比 P , 具体公式为

$$EQ = \frac{1}{1000T} \times \int_{t_0}^{t_f} (2TSS(t) + COD(t) +$$

$$30S_{NK_j}(t) + 10S_{NO}(t) + 2BOD_5(t))Q_e dt \quad (11)$$

其中, T 为观察周期, S_{NK_j} 为凯氏氮浓度, S_{NO} 为硝态氮浓度, Q_e 为出水流量.

$$OCI = AE + PE + 3EC \quad (12)$$

其中, AE 为曝气能耗, PE 为泵送能耗, EC 为碳源费用, 计算公式为

$$AE = \frac{8}{1800T} \int_{t_0}^{t_f} \sum_{k=1}^5 V_k \times K_{La,k}(t) dt \quad (13)$$

其中, $K_{La,k}$ 为第 k 个池子氧转换系数, V_k 为系数.

$$PE = \frac{1}{T} \int_{t_0}^{t_f} (0.004Q_a(t) + 0.008Q_r + 0.05Q_w) dt \quad (14)$$

其中, Q_a 为内回流速度, Q_r 为外回流速度, Q_w 为污泥流速.

$$EC = \frac{400}{T} \int_{t_0}^{t_f} \sum_{k=1}^5 q_{EC,k} dt \quad (15)$$

其中, $q_{EC,k}$ 为第 k 个池子的外加碳源流速.

水质超标时间百分比计算公式为

$$P = \frac{T_c}{T_z} \quad (16)$$

其中, T_c 为水质超标总时间, T_z 为总运行时间.

4.2 基于 NSGA2-DLS 的优化控制

为验证本文使用优化控制方法的有效性, 使用基于 NSGA2-DLS 的优化控制方法对 BSM1 污水处理模型进行控制, 但不抑制超标峰值, 模拟在晴天天气下连续进行 7 天优化控制. 首先使用优化算法对 $S_{O,5}$ 和 $S_{NO,2}$ 设定值进行优化, 由于污水处理是一个慢过程, 控制需要一定的反应时间, 因此每 2 小时优化一次设定值. 然后使用模糊控制器对设定值进行跟踪控制.

各出水指标变化曲线如图 7 所示, $S_{O,5}$ 和 $S_{NO,2}$ 设定值变化及跟踪效果如图 8 和图 9 所示. 控制效果如表 5 所示, 控制效果与固定设定值 ($S_{O,5}$ 和 $S_{NO,2}$ 设定值分别为 2 和 1), 不抑制峰值 (记为 F1), DPSO^[20], APSO^[21] 和 ESN^[22] 进行对比. 从图 7 可以看出, 出水 TSS, BOD₅ 和 COD 浓度均保持在规范范围以内, 出水 S_{NH} 和 $S_{N_{tot}}$ 浓度虽然大部分时间在要求范围以内, 但在峰值处超标严重. 从图 8 和图 9 可以看出, 本文使用的模糊控制器虽然可以

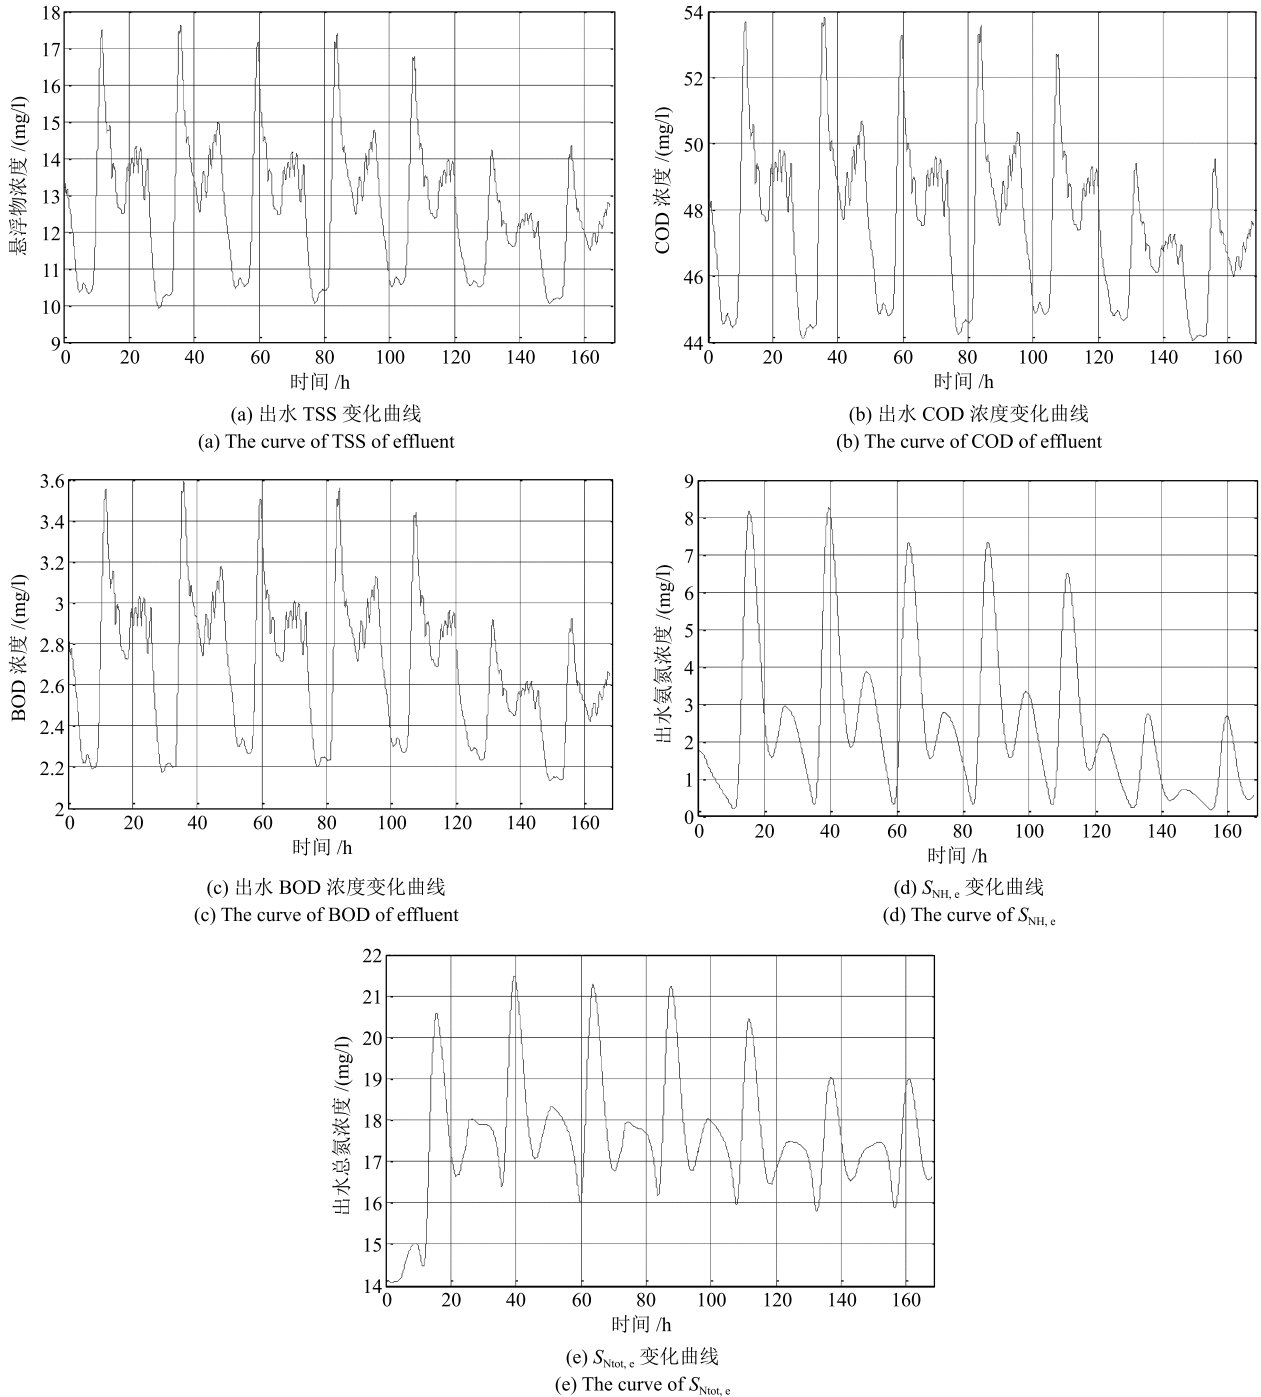


图7 各出水水质浓度变化曲线

Fig. 7 The change of water quality parameters

有效跟踪设定值,但是在设定值变化时有超调,但此问题不是本文研究的重点.表5给出了不同优化控制方法对 BSM1 模型的控制效果,从表5可以看出,各出水指标均值都在限定范围之内,本文使用的 NSGA2-DLS 算法得到的能耗最低,但水质指标也有所升高.

通过以上分析可知,NSGA2-DLS 算法在污水处理优化控制中的应用可以有效降低能耗,各指标

均值都达到出水标准,但是 $S_{NH,e}$ 和 $S_{Ntot,e}$ 峰值超标严重,峰值的抑制控制十分必要.

4.3 决策优化控制



将优化控制与决策控制相结合,使用优化控制降低能耗,决策控制对 $S_{NH,e}$ 和 $S_{Ntot,e}$ 峰值进行抑制,模拟在晴天天气下连续进行7天决策优化控制.首先使用优化算法对 $S_{O,5}$ 和 $S_{NO,2}$ 设定值进行优化,

表 5 不同算法控制效果比较 (出水指标、能耗和水质)

Table 5 Performance comparison for different control algorithms (effluent parameters, *OCI* and *EQ*)

算法	EC					<i>OCI</i> (kWh/d)	<i>EQ</i> (kg poll.Units/d)
	S_{NH} (mg/l)	S_{Ntot} (mg/l)	TSS (mg/l)	BOD ₅ (mg/l)	COD (mg/l)		
F1	2.3037	16.8006	12.6219	2.6763	47.5114	3 909.5	6 080.9
NSGA2-DLS	2.4389	17.5298	12.6200	2.6791	47.5189	3 688.1	6 203.9
DPSO ^[18]	3.2387	14.9184	12.6227	2.6894	47.5503	3 702.3	6 180.3
APSO ^[19]	3.1398	14.5995	12.9990	2.7660	48.0766	3 700.4	6 198.7
ESN ^[20]	2.8723	15.6014	12.5917	2.6784	47.5114	3 756.8	6 134.5

优化周期为 2 小时. 然后使用预测模型预测 $S_{NH,e}$ 和 $S_{Ntot,e}$ 是否超标, 如果都不超标, 则对 $S_{O,5}$ 和 $S_{NO,2}$ 进行跟踪控制; 如预测 $S_{NH,e}$ 超标, 则切换到 $S_{NH,e}$ 峰值抑制控制; 如预测 $S_{Ntot,e}$ 超标, 则切换到 $S_{Ntot,e}$ 峰值抑制控制.

图 8 $S_{NO,2}$ 设定值及跟踪曲线Fig. 8 Optimization and tracking results of $S_{NO,2}$ 图 9 $S_{O,5}$ 设定值及跟踪曲线Fig. 9 Optimization and tracking results of $S_{O,5}$


决策优化控制的出水 TSS, BOD₅ 和 COD 浓度变化如图 10 所示. 决策优化控制与 NSGA2-DLS 优化控制下 $S_{NH,e}$ 和 $S_{Ntot,e}$ 的对比如图 11 和图 12 所示. $S_{O,5}$ 和 $S_{NO,2}$ 设定值变化及跟踪效果如图 13 和

图 14 所示, Q_a 和 $K_{La,5}$ 变化曲线如图 15 和图 16 所示. 实验结果与其他抑制 $S_{NH,e}$ 和 $S_{Ntot,e}$ 峰值方法进行比较, 对比方法有: 固定 $S_{O,5}$ 和 $S_{NO,2}$ 设定值抑制峰值 (记为 F2)、Jeppsson^[23]、Nopens^[24]、Flores-Alsina^[25] 和 Santín^[10], 对比结果如表 6 所示.


表 6 不同 $S_{NH,e}$ 和 $S_{Ntot,e}$ 峰值抑制方法效果对比
Table 6 Performance comparison for different $S_{NH,e}$ and $S_{Ntot,e}$ peak suppression methods

方法	<i>OCI</i> (KWh/d)	<i>EQ</i> (kg poll.Units/d)	$P(S_{NH,e})$ (%)	$P(S_{Ntot,e})$ (%)
决策优化控制	5 526.7	5 797.1	0	0
F2	6 268.6	5 350.1	0.74	0.77
Jeppsson	9 447.24	5 577.97	0.41	1.18
Nopens	9 348	5 447	0.92	*
Flores-Alsina	8 024.5	5 022.5	0.2	0.25
Santín	6 289.59	5 318.95	0.15	0.0046


从图 10 可知, 决策优化控制下出水 TSS, BOD₅ 和 COD 浓度均保持在规定范围以内. 图 11 和图 12 表明, 抑制控制的加入有效抑制了 $S_{NH,e}$ 和 $S_{Ntot,e}$ 峰值. 从图 13 和图 14 的 $S_{O,5}$ 和 $S_{NO,2}$ 跟踪曲线可以看出, 当切换到抑制控制时, 抑制峰值为首要目标, 因此在抑制控制时 $S_{O,5}$ 和 $S_{NO,2}$ 与设定值相差较大. 图 15 和图 16 表示的 Q_a 变化曲线和 $K_{La,5}$ 变化曲线显示了 $S_{NH,e}$ 和 $S_{Ntot,e}$ 在预测达标和超标两种情况下, 决策优化控制对 Q_a 和 $K_{La,5}$ 的控制. 从表 6 的对比结果可以看出, 本文提出的决策优化控制方法可以有效抑制 $S_{NH,e}$ 和 $S_{Ntot,e}$ 峰值, 出水 $S_{NH,e}$ 和 $S_{Ntot,e}$ 始终保持在规定范围以内, 超标时间百分比均为 0%. 其他抑制峰值方法均不能保持出水 $S_{NH,e}$ 和 $S_{Ntot,e}$ 始终达标. 与其他方法相比, 决策优化控制消耗的能耗明显降低, 虽然水质指标高于其他方法, 但污水控制目标为在出水达标的情况下尽可能降低能耗, 因此本文提出的决策优化控制



(a) 出水 TSS 变化曲线
(a) The curve of TSS of effluent



(b) 出水 BOD 浓度变化曲线
(b) The curve of BOD of effluent



(c) 出水 COD 浓度变化曲线
(c) The curve of COD of effluent

图 10 出水 TSS、BOD₅ 和 COD 浓度变化曲线

Fig. 10 The curves of TSS, BOD₅ and COD of effluent

节能降耗效果优于所对比控制方法, 实现了在抑制 S_{NH_4-e} 和 $S_{N_{tot},e}$ 峰值的情况下降低能耗的目标。

5 总结与展望

本文提出的决策优化控制将决策控制与优化控制相结合, 在抑制出水氨氮和总氮浓度峰值的情况下降低能耗。理论分析与实验结果表明, 决策优化控




图 11 决策优化控制与优化控制 S_{NH_4-e} 变化曲线
Fig. 11 The curves of S_{NH_4-e} with decision and optimization control system and optimization control system




图 12 决策优化控制与优化控制 $S_{N_{tot},e}$ 变化曲线
Fig. 12 The curves of $S_{N_{tot},e}$ with decision and optimization control system and optimization control system







图 13 S_{O_2} 设定值及跟踪曲线

Fig. 13 Optimization and tracking results of S_{O_2}

制在以下方面对污水处理控制做出了贡献。

1) 在预测模型建立方面, 本文提出的时滞时间计算方法对建模数据采样提供了新思路; 将第二分区溶解氧浓度和第五分区硝态氮浓度作为预测模型输入变量提高了模型的精度。

图 14 $S_{NO,2}$ 设定值及跟踪曲线Fig. 14 Optimization and tracking results of $S_{NO,2}$ 图 15 Q_a 变化曲线Fig. 15 The curve of Q_a 图 16 $K_{La,5}$ 变化曲线Fig. 16 The curve of $K_{La,5}$

2) 将 NSGA2-DLS 优化算法应用于设定值优化环节, 提高了优化解的质量, 降低了能耗。

3) 在优化过程和最优解选取过程中引入预测模型, 将优化控制与决策控制有效结合, 实验结果显示, 决策优化控制可以有效抑制 $S_{NH,e}$ 和 $S_{Ntot,e}$ 峰值, 与其他抑制控制相比, 决策优化控制的能耗更低, 达到了出水达标的情况下节能降耗的目的。

虽然决策优化控制取得了较好的效果, 但仍然有一些方面需要改进, 决策优化控制使用的模糊控制器跟踪性能一般, 在设定值变化时超调严重; 本文使用多层感知器进行建模, 可以在权值初始化、权值调整算法等方面进行改进, 提高建模精度, 也可以尝试其他建模方法。

References

- 1 Cristea S, de Prada C, Sarabia D, Gutiérrez G. Aeration control of a wastewater treatment plant using hybrid NMPC. *Computers and Chemical Engineering*, 2011, **35**(4): 638–650
- 2 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
(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)
- 3 Han H G, Qiao J F. Adaptive dissolved oxygen control based on dynamic structure neural network. *Applied Soft Computing*, 2011, **11**(4): 3812–3820
- 4 Mulas M, Tronci S, Corona F, Haimi H, Lindell P, Heinonen M, Vahala R, Baratti R. Predictive control of an activated sludge process: an application to the Viikinmäki wastewater treatment plant. *Journal of Process Control*, 2015, **35**: 89–100
- 5 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
- 6 Egea J A, Gracia I. Dynamic multiobjective global optimization of a waste water treatment plant for nitrogen removal. *IFAC Proceedings Volumes*, 2012, **45**(2): 374–379
- 7 Yang T, Qiu W, Ma Y, Chadli M, Zhang L X. Fuzzy model-based predictive control of dissolved oxygen in activated sludge processes. *Neurocomputing*, 2014, **136**: 88–95
- 8 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
- 9 Han H G, Qian H H, Qiao J F. Nonlinear multiobjective model-predictive control scheme for wastewater treatment process. *Journal of Process Control*, 2014, **24**(3): 47–59
- 10 Santín I, Pedret C, Vilanova R, Meneses M. Advanced decision control system for effluent violations removal in wastewater treatment plants. *Control Engineering Practice*, 2016, **49**: 60–75
- 11 Vilanova R, Katebi R, Wahab N. N-removal on wastewater treatment plants: a process control approach. *Journal of Water Resource and Protection*, 2011, **3**(1): 1–11
- 12 Li San-Yi, Li Wen-Jing, Qiao Jun-Fei. A local search strategy based on density for NSGA2 algorithm. *Control and Decision*, 2018, **33**(1): 60–66
(栗三一, 李文静, 乔俊飞. 一种基于密度的局部搜索 NSGA2 算法. *控制与决策*, 2018, **33**(1): 60–66)

- 13 Jeppsson U, Pons M N. The COST benchmark simulation model — current state and future perspective. *Control Engineering Practice*, 2004, **12**(3): 299–304
- 14 Qiao J F, Li S Y, Li W J. Mutual information based weight initialization method for sigmoidal feedforward neural networks. *Neurocomputing*, 2016, **207**: 676–683
- 15 Farajzadeh J, Fard A F, Lotfi S. Modeling of monthly rainfall and runoff of Urmia lake basin using “feed-forward neural network” and “time series analysis” model. *Water Resources and Industry*, 2014, **7–8**: 38–48
- 16 Qiao Jun-Fei, Bo Ying-Chun, Han Guang. Application of ESN-based multi indices dual heuristic dynamic programming on wastewater treatment process. *Acta Automatica Sinica*, 2013, **39**(7): 1146–1151
(乔俊飞, 薄迎春, 韩广. 基于 ESN 的多指标 DHP 控制策略在污水处理过程中的应用. *自动化学报*, 2013, **39**(7): 1146–1151)
- 17 Han Hong-Gui, Zhang Lu, Qiao Jun-Fei. An energy consumption model of wastewater treatment process based on adaptive regressive kernel function. *CIESC Journal*, 2016, **67**(3): 947–953
(韩红桂, 张璐, 乔俊飞. 一种基于自适应回归核函数的污水处理能耗模型. *化工学报*, 2016, **67**(3): 947–953)
- 18 Messac A, Ismail-Yahaya A, Mattson C A. The normalized normal constraint method for generating the Pareto frontier. *Structural and Multidisciplinary Optimization*, 2003, **25**(2): 86–98
- 19 Zeng G Q, Chen J, Li L M, Chen M R, Wu L, Dai Y X, Zheng C W. An improved multi-objective population-based extremal optimization algorithm with polynomial mutation. *Information Sciences*, 2016, **330**: 49–73
- 20 Shi Xiong-Wei, Qiao Jun-Fei, Yuan Ming-Zhe. Optimal control for wastewater treatment process based on improved particle swarm optimization algorithm. *Information and Control*, 2011, **40**(5): 698–703
(史雄伟, 乔俊飞, 苑明哲. 基于改进粒子群优化算法的污水处理过程优化控制. *信息与控制*, 2011, **40**(5): 698–703)
- 21 Qiao Jun-Fei, Pang Ze-Fang, Han Hong-Gui. Neural network optimal control for wastewater treatment process based on APSO. *CAAI Transactions on Intelligent Systems*, 2012, **7**(5): 429–436
(乔俊飞, 逢泽芳, 韩红桂. 基于改进粒子群算法的污水处理过程神经网络优化控制. *智能系统学报*, 2012, **7**(5): 429–436)
- 22 Qiao Jun-Fei, Wang Li-Li, Han Hong-Gui. Optimal control for wastewater treatment process based on ESN neural network. *CAAI Transactions on Intelligent Systems*, 2015, **10**(6): 831–837
(乔俊飞, 王莉莉, 韩红桂. 基于 ESN 的污水处理过程优化控制. *智能系统学报*, 2015, **10**(6): 831–837)
- 23 Jeppsson U, Pons M N, Nopens I, Alex J, Copp J B, Gernaey K V, Rosen C, Steyer J P, Vanrolleghem P A. Benchmark simulation model No 2: general protocol and exploratory case studies. *Water Science and Technology*, 2007, **56**(8): 67–78
- 24 Nopens I, Benedetti L, Jeppsson U, Pons M N, Alex J, Copp J B, Gernaey K V, Rosen C, Steyer J P, Vanrolleghem P A. Benchmark simulation model No 2: finalisation of plant layout and default control strategy. *Water Science and Technology*, 2010, **62**(9): 1967–1974
- 25 Flores-Alsina X, Comas J, Rodríguez R I, Poch M, Gernaey K V, Jeppsson U. Evaluation of plant-wide WWTP control strategies including the effects of filamentous bulking sludge. *Water Science and Technology*, 2009, **60**(8): 2093–2103



栗三一 北京工业大学信息学部博士研究生. 主要研究方向为智能优化控制, 神经网络结构设计和优化.

E-mail: wslisanyi@126.com


(**LI San-Yi** Ph.D. candidate at the Faculty of Information Technology, Beijing University of Technology. His research interest covers intelligent optimization control, analysis and design of neural networks.)



乔俊飞 博士, 北京工业大学信息学部教授. 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** Ph.D., professor at the Faculty of Information Technology, Beijing University of Technology. His research interest covers intelligent control, analysis and design of neural networks. Corresponding author of this paper.)



李文静 博士, 北京工业大学信息学部副教授. 主要研究方向为模块化神经网络设计. E-mail: wenjing.li@bjut.edu.cn

(**LI Wen-Jing** Ph.D., associate professor at the Faculty of Information Technology, Beijing University of Technology. Her research interest covers modular neural networks designing.)



顾镭 博士, 北京工业大学信息学部副教授. 主要研究方向为质量感知和机器学习. E-mail: guke@bjut.edu.cn

(**GU Ke** Ph.D., associate professor at the Faculty of Information Technology, Beijing University of Technology. His research interest covers quality perception and machine learning.)