

DOI: 10.3969/j.issn.1673-4785.201205034

网络出版地址: <http://www.cnki.net/kcms/detail/23.1538.TP.20120925.1101.002.html>

基于改进粒子群算法的 污水处理过程神经网络优化控制

乔俊飞, 逢泽芳, 韩红桂

(北京工业大学电子信息与控制工程学院, 北京100124)

摘要:针对活性污泥法污水处理过程高能耗的问题, 综合考虑污水处理出水水质和生化反应参数之间的关系, 文中设计了一种智能优化控制系统. 该系统以国际水协(IWA)开发的基准仿真模型 BSM1为研究对象, 利用改进粒子群算法优化BSM1第2分区的硝态氮浓度和第5分区的溶解氧浓度、混合液悬浮物固体浓度的设定值; 同时利用感知器神经网络预测污水处理过程的输出, 在出水水质达标的前提下降低污水处理能耗. 仿真实验结果表明, 系统总能耗相比闭环控制策略降低4.614%, 该神经网络智能优化控制系统能够有效降低污水处理的能耗.

关键词:污水处理; 智能控制; 优化控制; 粒子群算法; 神经网络

中图分类号: TP18 **文献标志码:** A **文章编号:** 16734785(2012)05-0429-08

Neural network optimal control for wastewater treatment process based on APSO

QIAO Junfei, PANG Zefang, HAN Honggui

(College of Electronic and Control Engineering, Beijing University of Technology, Beijing 100124, China)

Abstract: Due to the high energy consumption of activated sludge wastewater treatment process, a new intelligent optimal control system is designed in this paper by considering the effluent quality and the relationship between the biochemical reaction parameters. This control system is used for the benchmark simulation model (BSM1) proposed by the International Water Association (IWA). The APSO is utilized to optimize the dissolved oxygen and MLSS levels in the fifth compartment and the nitrate level in the second anoxic tank. Meanwhile, the outputs of BSM1 are predicted by the neural network, and the energy consumption is cut down within the effluent water quality standards. The simulation results show that, comparing to the close-loop control strategy, the total energy consumption of this proposed optimal control system is lowered by 4.614%, the neural network optimal control strategy can significantly reduce the energy consumption of activated sludge wastewater treatment process.

Keywords: wastewater treatment; intelligent control; optimal control; particle swarm optimization; neural network

环境保护部2011年发布的《中国环境状况公报》中指出, 2010年全国废水排放总量为617.3亿吨, 比2009年增加4.7%, 而全年累计处理污水397.3亿立方米, 水污染防治形势依然严峻. 因此, 建立污水处理厂, 最大限度地保护水环境显得尤为

重要. 截至2011年3月底, 全国各个城市、县累计建成城镇污水处理厂2996座, 处理能力达到1.33亿立方米每日. 但是由于污水处理的经济成本高、能耗大, 尚有607座投入运行1年以上的城镇污水处理厂平均运行负荷率不足60%. 因此, 在出水水质达标的前提下, 降低运行能耗是污水处理过程中亟待解决的问题.

为了优化运行成本, 国内外学者进行了大量的研究. R. Piotrowskia等对采用分层控制策略实现水溶解氧浓度的控制, 上层采用非线性模型预测设

收稿日期: 2012-05-21, 网络出版日期: 2012-09-25.

基金项目: 国家自然科学基金重点资助项目(61034008); 北京市自然科学基金资助项目(4122006)北京市教育委员会科技计划项目(KZ201010005005).

通信作者: 韩红桂. E-mail: isibox@sina.com.

计好氧区的期望曝气量,下层控制器采用分段线性化原理对设定值进行跟踪^[2].虽然该分层控制策略能够实现溶解氧的优化控制,但是由于控制变量单一,其应用受到了很大的限制. V. Chandramouli 等利用神经网络设计了一种污水生化处理自适应控制器,该控制器以回流污泥量和氧气传递速率为控制量,底物浓度和溶解氧浓度为被控量,实现了污水处理过程底物浓度和溶解氧浓度的控制^[3],但是该控制器的控制量设定值为固定经验值. B. Beraud 等在 BSM1 (benchmark simulation model No. 1) 基础上,为使曝气能耗和泵送能耗达到最小,采用了多目标遗传算法 (multi objectives genetic algorithm, MOGA) 对污水处理过程进行优化控制^[4]. 张平等针对活性污泥前置反硝化污水生化处理工艺,采用混合遗传算法优化曝气能耗和泵送能耗达到最小,改变混合液悬浮物固体浓度 (mixed liquor suspended solids, MLSS) 和溶解氧浓度 (dissolved oxygen, DO) 的设定值,使得出水水质达标的情况下能耗最小^[5]. 虽然文献[4-5]中曝气能耗和泵送能耗都有所降低,但是以上2种方法采用的遗传算法需要复杂的交叉变异操作,容易陷入“早熟”^[6]. 近年来,粒子群算法由于其与遗传算法相比具有算法简单、参数少、求解速度快、易于实现等优势,得到了广大学者的关注^[7-8]. A. Alireza 提出了具有适应性突变和惯性权重因子的粒子群算法^[7],以粒子的适应度值作为变量,采用双曲正切函数对惯性权重因子进行修改,在参数估计的动态系统中证实该算法可行. 但该算法只是对权重惯性因子进行修改,忽略了加速因子对算法的影响. Xiao 等提出了一种新的自适应粒子群算法^[8],将惯性权重因子采用线性的过渡方法,加速因子采用二次函数的方法对粒子群算法进行改进,取得了较快的收敛速度. 但是算法中采用线性的过渡方法改变惯性权重因子,不能反映实际的搜索过程,描述得不够精确. 综上所述,根据污水处理过程的特点,文中提出了一种改进型自适应粒子群算法 (advanced self-adaptive particle swarm optimization, APSO), 基于 APSO 设计了一种神经网络优化控制系统,以国际水协会 (International Water Association, IWA) 提供的 BSM1 为研究对象,根据能耗的影响因素,选择第5分区的溶解氧 (DO) 浓度、混合液悬浮物固体浓度 (MLSS) 和第2分区硝酸氮 (SNO) 浓度为控制变量,基于神经网络预测模型,采用改进的自适应粒子群算法优化 DO、MLSS 和 SNO 的设定值,

实现污水处理优化控制.

1 优化算法

1.1 标准粒子群算法

PSO 求解最优化问题时,将所求问题的变量设计为搜索空间的粒子. 每个粒子由3部分组成:当前位置 \mathbf{x}_i 、飞行速度 \mathbf{v}_i 和粒子的适应度 f 组成,表示为 $P(\mathbf{x}_i, \mathbf{v}_i, f)$,在迭代的过程中:

1) 粒子本身所找到的最优解,称之为粒子的自身认知能力,记为 \mathbf{p}_{best} ;

2) 整个粒子群目前所找到的最优解,称之为粒子的社会认知能力,记为 \mathbf{g}_{best} .

粒子通过式(1)、(2)更新速度和位置^[9]:

$$\mathbf{v}_i(t+1) = \omega \cdot \mathbf{v}_i(t) + c_1 \cdot r_1 \cdot (\mathbf{p}_i - \mathbf{x}_i(t)) + c_2 \cdot r_2 \cdot (\mathbf{g}_i - \mathbf{x}_i(t)), \quad (1)$$

$$\mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \mathbf{v}_i(t+1). \quad (2)$$

式中: \mathbf{v}_i 是粒子的速度向量; \mathbf{x}_i 是粒子的位置向量; ω 是惯性权重因子; \mathbf{p}_i 表示粒子 i 在经历 n 次搜索后找到的个体最优位置,粒子根据当前个体经验执行下一步动作; \mathbf{g}_i 表示粒子 i 保存的种群最优位置,来源于种群中全体粒子的经验部分,表现为知识的共享和合作; c_1 和 c_2 是非负常数,称为加速因子,其中 c_1 为自身认知系数, c_2 为社会认知系数; r_1 和 r_2 是 $[0,1]$ 的独立随机数.

每一时刻 t , 粒子在群体信息和自身历史经验的引导下,在一定范围的空间内进行搜索,当发现更优解时,对引导信息进行更新,展开新的搜索,寻优过程不断推进. 但由于所有粒子的飞行方向是根据全体和自身经验决定的,因此搜索后期收敛速度明显减慢,达到一定程度后,算法甚至陷入了停滞,致使后期很难得到精确解^[10].

实验研究发现,一般 ω 、 c_1 、 c_2 越大,不收敛的概率越大,其中 ω 的影响更大些,选择适当的 ω 、 c_1 、 c_2 可以保证粒子的收敛性^[11].

1.2 改进的自适应粒子群算法

PSO 算法中,将 ω 的值进行线性变化来实现对 ω 值的更新^[9],即

$$\omega = (\omega_{\text{max}} - \omega_{\text{min}}) \cdot G/G_{\text{max}} + \omega_{\text{min}}. \quad (3)$$

式中: G 是当前迭代次数, G_{max} 是最大迭代次数. 但是 PSO 算法是一个非线性的复杂过程,惯性权重因子采用线性的过渡方法不能反映实际的搜索过程,描述不够精确. 正切 Sigmoid 函数 (S 函数) 比线性函数更平滑,有很好的衡性^[12],因此采用正切

Sigmoid函数更新惯性权值,其更新式为

$$\omega = (\omega_{\max} - \omega_{\min})[1 - 2/(e^{2G/G_{\max}} + 1)] + \omega_{\min} \quad (4)$$

式中: ω_{\max} 和 ω_{\min} 分别为0.9和0.4,这样 ω 就会限定在 $[0,0.5]$.当 ω 从大到小变化时,粒子搜索的范围可从一个较大的空间逐渐变化到很小的区域,这正好符合PSO的基本思想^[13].

在式(1)中学习因子 c_1 和 c_2 分别调节 p_{best} 和 g_{best} 方向的飞行距离,因此可以调节自身认知和群体认知的比例大小,从而优化全局最优解的精度.在标准PSO中, c_1 和 c_2 是一个固定的常数,但合理地调节 c_1 、 c_2 参数的大小,在搜索前期增大群体认知比例,防止陷入局部最优解,并且在后期加强自身认知比例,提高搜索精度.因此采用二次函数 $y = ax^2 + b$ 调节学习因子项:

$$c_1 = (c_{1s} - c_{1f}) \cdot (1 - G/G_{\max})^2 + c_{1f} \quad (5)$$

$$c_2 = (c_{2s} - c_{2f}) \cdot (1 - G/G_{\max})^2 + c_{2f} \quad (6)$$

式中: c_{1s} 和 c_{1f} 为 c_1 参数的初始值和最终值, c_{2s} 、 c_{2f} 为 c_2 参数的初始值和最终值,学习系数 c_1 、 c_2 的取值范围为 $[0.5, 2.5]$.由于粒子在运动初期,粒子本身的经验不足,因此需要更多地向群体学习,也就是说 c_1 的取值比 c_2 要小.当粒子运动到一定阶段时,粒子本身积累了一定的经验后,自我学习的能力加强,因此 c_1 的取值比 c_2 要大^[13].所以对参数 c_1 由小到大,而 c_2 由大到小进行改进,能有效地抑制局部解,加强搜索精度.

APSO算法的步骤如下(具体流程图如图1).

1)在搜索空间中随机生成粒子个数 m ,构成初始微粒种群pop,并初始化粒子的位置 x_i 及相应的速度 v_i ;

2)评价每个粒子的适应度(代入适应值函数),对每个微粒,将其适应值 f 与当前最优个体粒子 p_{best}

比较,若较好,则将其作为 p_{best} ;

3)从所有微粒的个体最优解 p_{best} 中找出全局最优 g_{best} ;

4)按式(1)~(2)更新粒子的位置速度 v_i 和位置 x_i ,按式(4)~(6)更新 ω 、 c_1 和 c_2 ;

5)判断是否满足终止条件,即当前迭代次数是否大于最大迭代次数,若不满足则返回步骤2),满足则算法结束.

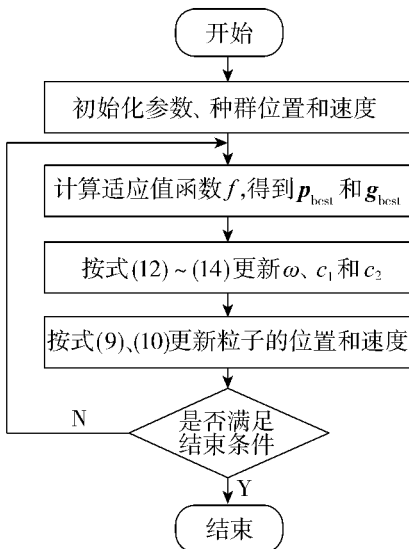


图1 APSO 算法流程

Fig.1 The flow chart of APSO algorithm

2 活性污泥法优化控制系统

2.1 过程模型

活性污泥污水处理基准仿真模型BSM1^[14]是IWA和欧盟科学技术与合作组织(COST Actions 682 and 624)共同开发的,提供了合理的评价控制策略在污水处理系统中性能的平台.BSM1的总体布局如图2所示,包括生化反应池和二沉池.

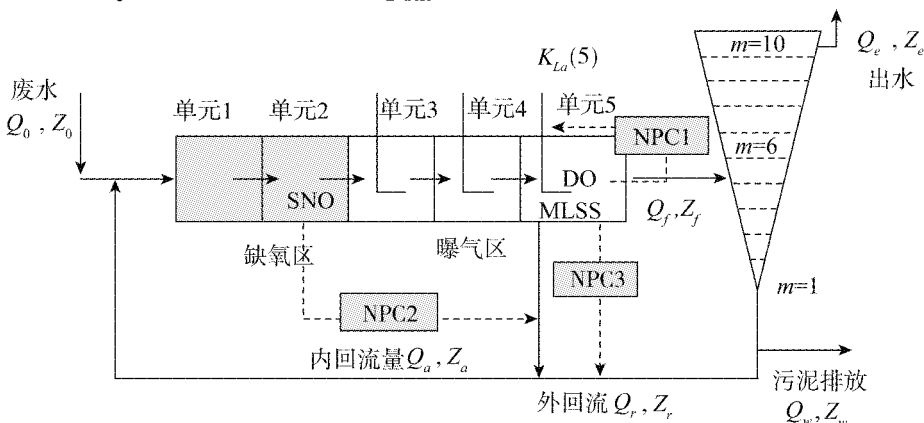


图2 BSM1 结构

Fig.2 General overview of the BSM1 plant

每一个单元,均以 Q_k 表示流量, Z_k 表示各组分的浓度, $Z = (S_1, S_5, X_1, X_5, X_{BH}, X_P, S_{NO}, S_{NH}, S_{ND}, X_{ND}, S_{ALK})$, $r_k = v_{k1}\rho_1 + v_{k2}\rho_2 + \dots + v_{k8}\rho_8$ 表示各组分的反应速率,缺氧区 2 个单元的体积 $V_1 = V_2 = 1\ 000\text{ m}^3$,好氧区 3 个单元的体积 $V_3 = V_4 = V_5 = 1\ 333\text{ m}^3$,各单元的物料平衡方程如下。

对于单元 1, $k=1$,有

$$\frac{dZ_1}{dt} = \frac{1}{V_1}(Q_a Z_a + Q_r Z_r + Q_0 Z_0 + r_1 V_1 - Q_1 Z_1). \quad (7)$$

式中: $Q_1 = Q_a + Q_r + Q_0$, Q_a 、 Q_r 、 Q_0 分别为混合液回流量、污泥回流量和入水流量。

对于其他单元, $k=2, 3, 4, 5$,有

$$\frac{dZ_k}{dt} = \frac{1}{V_k}(Q_{k-1} Z_{k-1} r_k V_k - Q_k Z_k). \quad (8)$$

式中: $Q_k = Q_{k-1}$ 。

溶解氧的物料平衡表示为

$$\frac{dS_{DO,k}}{dt} = \frac{1}{V_k}(Q_{k-1} S_{DO,k-1} + r_k V_k - Q_k S_{DO,k} + K_{La}(k) V_k (S_{DO,sat} - S_{DO,k})). \quad (9)$$

式中: K_{La} 表示氧气转换速率, $S_{DO,sat}$ 代表饱和溶解氧浓度,仿真中取 $S_{DO,sat} = 8\text{ g} \cdot \text{m}^{-3}$ 。

在活性污泥法污水处理中,混合液悬浮固体浓度表示为

$$S_{MLSS} = M_a + M_e + M_i + M_{ii}. \quad (10)$$

式中: M_a 代表活性污泥中活的微生物量, M_e 代表活性污泥中微生物内源呼吸残留物, M_i 代表活性污泥中不可生物降解的有机悬浮固体, M_{ii} 代表活性污泥中由原废水带入的无机悬浮固体。

2.2 过程控制系统

在活性污泥污水处理系统中,可以选择的控制变量较多,例如进水流量、污泥回流量、污泥排放量、曝气量等。在污水处理过程中,能耗包括曝气能耗和泵送能耗,影响曝气能耗的因素主要是溶解氧的浓度;影响泵送能耗的主要因素则是内外回流的流量。而且在活性污泥系统中溶解氧浓度、硝态氮浓度和混合液悬浮物固体浓度是影响硝化反硝化进程的重要参数,因此选择曝气量、污泥回流量和内循环回流量作为控制变量,对系统中溶解氧浓度 $S_{DO,SP}$ 、硝态氮浓度 $S_{NO,SP}$ 和混合液悬浮物固体浓度 $S_{MLSS,SP}$ 的设定点进行优化控制,以提高活性污泥系统处理效果和降低运行成本。

优化控制系统采用智能优化算法与神经网络预测相结合的方法,实现基础回路设定值的动态优化。通过智能优化算法对控制指标寻优,寻优过程终止

的条件为出水水质达标的情况下满足局部的能耗指标。由于反映出水水质的参数存在测量滞后,有些甚至无法在线测量,因此采用神经网络对部分出水水质参数进行预测,通过预测指标与约束条件的对比作为判断智能优化算法寻优过程停止的依据。

图 3 为污水处理过程的动态优化控制系统结构,以溶解氧浓度 S_{DO} 、混合液悬浮物固体浓度 S_{MLSS} 和硝态氮浓度 S_{NO} 的设定值作为优化对象。在底层控制回路中采用 3 个神经网络控制器,第 1 个通过调节第 5 分区的氧气转换系数 $K_{La}(5)$ 控制 S_{DO} ,第 2 个通过调节外回流量 Q_r 控制第 5 分区的 S_{MLSS} ,第 3 个通过调节内回流量 Q_a 控制第 2 分区的 S_{NO} 。通过神经网络预测模型寻找 $K_{La}(5)$ 、 Q_r 和 Q_a 与出水水质参数(BOD(biochemical oxygen demand)、COD(chemical oxygen demand)、TSS(total suspended solids)、 S_{NH} 和 N_{tot})的非线性关系,对实时获得的数据进行判断,剔除异常数据,通过实际出水水质与神经网络预测结果的对比偏差,对神经网络进行在线修正和调整。这里神经网络预测模型采用的是 BP 神经网络。




图3 优化控制系统

Fig.3 Optimal control system

2.3 优化问题描述

综合考虑运行成本和出水水质 2 个方面,采用改进的自适应粒子群优化算法优化控制策略,动态调整控制回路的设定值 $S_{DO,SP}$ 、 $S_{NO,SP}$ 和 $S_{MLSS,SP}$ 。优化问题的目标函数^[13]为

$$J = \min \frac{1}{T} \int_t^{t+T} (E + Q) dt. \quad (11)$$

式中: $E = E_A + E_P$ 表示运行费用, E_A 为曝气耗能, E_P 为泵送耗能; Q 表示向受纳水体排放污染物需要支付的费用。 E_A 、 E_P 、 Q 的表示如式(12)~(14), Q 的大小与出水水质有关,出水水质越好, Q 值越小。

$$E_A = \frac{S_{DO,sat}}{T \times 1.8 \times 1\ 000} \int_t^{t+T} \sum_{i=1}^5 V_i \cdot K_{La}(t) dt, \quad (12)$$

$$E_P = \frac{1}{T} \int_t^{t+T} (0.004 Q_a(t) + 0.05 Q_w(t) + 0.008 Q_r(t)) dt, \quad (13)$$

$$Q = \frac{1}{T \times 1\ 000} \int_t^{t+T} (2SS_e(t) + COD_e(t) + 30S_{NO,e}(t) + 10S_{Nkj,e}(t) + 2BOD_e(t)) dt. \quad (14)$$

$$\begin{aligned}
 \text{式中: } S_{\text{Nkj},e} &= S_{\text{NH},e} + S_{\text{ND},e} + i_{\text{XB}}(X_{\text{BH},e} + X_{\text{XA},e} + \\
 &\quad X_{\text{ND},e} + i_{\text{XP}}(X_{\text{P},e} + X_{\text{I},e}), \\
 \text{SS}_e &= 0.75 \times (X_{\text{S},e} + X_{\text{I},e} + X_{\text{BH},e} + X_{\text{P},e}), \\
 \text{BOD}_e &= 0.25 \times (S_{\text{S},e} + X_{\text{S},e} + (1 - f_p)(X_{\text{BH},e} + X_{\text{BA},e})), \\
 \text{COD}_e &= S_{\text{S},e} + S_{\text{I},e} + X_{\text{S},e} + X_{\text{BH},e} + X_{\text{BA},e} + X_{\text{P},e}.
 \end{aligned}$$

在以上目标函数的基础上,优化控制系统还必须满足以下约束条件:

1) 物料平衡约束,如式(7)~(9);

2) 输出约束^[14]:

$$N_{\text{tot}} < 18 \text{ g N} \cdot \text{m}^{-3}, \text{COD}_e < 100 \text{ g COD} \cdot \text{m}^{-3},$$

$$S_{\text{NH}} < 4 \text{ g N} \cdot \text{m}^{-3}, \text{TSS} < 30 \text{ gSS} \cdot \text{m}^{-3},$$

$$\text{BOD}_5 < 10 \text{ g BOD} \cdot \text{m}^{-3};$$

3) 执行器约束包括:

$$\text{操作变量: } 0 < S_{\text{DO},\text{SP}} < 4, 0 < S_{\text{NO},\text{SP}} < 3,$$

$$1\,500 < S_{\text{MLSS},\text{SP}} < 3\,500;$$

$$\text{控制变量: } 0 < K_{\text{La}} < 240, 0 < Q_a < 92\,230,$$

$$0 < Q_r < 92\,230.$$

3 仿真研究

将提出的智能优化控制方法应用于BSM1模型,实验数据来源于实际污水处理厂,同时采用国际水协会(IWA)提供的3个污水参数输入文件^[5],该参数输入包括晴天、雨天和暴雨天3种天气下的污水流量和组分变化情况.文中采用第1组晴天下7天的数据和文献[15]中的优化周期(2h)进行仿真.第1组代表正常天进水浓度和进水量的昼夜变化,这些数据的采样间隔为15 min,且污水组分已经抽象为ASM1中对应的13种元素.以溶解氧浓度 S_{DO} 、混合液悬浮物固体浓度 S_{MLSS} 和硝态氮浓度 S_{NO} 的设定值作为优化对象,实现第5分区的氧气转换系数 $K_{\text{La}}(5)$ 、外回流量 Q_r 以及内回流量 Q_a 的优化控制.实验分为两部分进行:1)无优化控制;2)优化控制.

在无优化控制的条件下,图4~6是在 S_{NO} 、 S_{DO} 和 S_{MLSS} 设定值分别为2 mg/L、1 mg/L和2 987.2 mg/L^[5]时,神经网络控制器的控制效果图.由实验结果可以看出,神经网络控制器的误差较小,有较好的鲁棒性.

在加入优化控制的条件下,图7~9分别是第2分区硝态氮浓度、第5分区溶解氧浓度和混合液悬浮物固体浓度的优化设定值变化图.图中 S_{NO} 、 S_{DO} 和 S_{MLSS} 的设定值随着入水水质的变化而变化.同时对闭环控制和优化控制2种控制策略进行对比,表1所示为出水水质重要参数的平均值,表2所示为运行费用.




图4 第2分区 S_{NO} 浓度的变化曲线

Fig.4 The response curve of S_{NO} concentration in the 2th unit




图5 第5分区 S_{DO} 浓度的变化曲线

Fig.5 The response curve of S_{DO} concentration in the 5th unit




图6 第5分区 S_{MLSS} 浓度的变化曲线

Fig.6 The response curve of S_{MLSS} concentration in the 5th unit

表1显示优化控制与闭环控制的出水水质参数均达标.表2表明优化控制的 Q 比闭环控制增大1.847%, E_A 减少6.665%, E_P 增加30.754%,而总能耗 E 减小4.614%.




图7 S_{NO} 浓度的优化曲线

Fig. 6 The optimal curve of S_{NO} concentration




图8 S_{DO} 浓度的优化曲线

Fig. 8 The optimal curve of S_{DO} concentration

式(14)显示 Q 与出水水质参数成正比,而在表1中,优化控制的出水水质参数 BOD_5 、 COD 、 S_{NH} 和 TSS 比闭环控制的高,优化控制的 Q 增大.图8显示

优化控制下 S_{DO} 的平均值明显小于闭环控制时的经验值,而曝气系数 $K_{La}(5)$ 与 S_{DO} 成正比,根据式(12),优化控制的 E_A 减小.式(13)中的内回流量 Q_a 和外回流 Q_r 根据 S_{NO} 浓度和 S_{MLSS} 浓度的变化而变化,图7和图9显示 S_{NO} 浓度和 S_{MLSS} 浓度的平均值比闭环控制的经验值偏大, E_p 增大.表2显示优化控制的能耗低于闭环控制,具有较好的节能效果.




图9 S_{MLSS} 浓度的优化曲线

Fig. 9 The optimal curve of S_{MLSS} concentration

在污水处理过程中,优化控制系统的目标是在出水水质达标的前提下,减少污水处理能耗.表1显示优化控制能够保证污水处理后出水水质均达标,同时根据表2的结果可以发现,污水处理过程经过优化控制后 E 减少了4.614%,节能效果明显.实验结果表明,智能优化控制方法能够在保证出水水质达标的前提下减少运行费用.

表1 闭环控制与优化控制策略的出水水质比较

Table 1 Comparison of effluent quality with closed loop control and our optimal control

控制策略	出水 BOD_5 / ($g\ BOD \cdot m^{-3}$)	出水 COD / ($g\ COD \cdot m^{-3}$)	出水 N_{tot} / ($g\ N \cdot m^{-3}$)	出水 S_{NH} / ($g\ N \cdot m^{-3}$)	出水 TSS / ($g\ SS \cdot m^{-3}$)
闭环控制 ^[5,13]	2.607 3	46.887 4	16.818 2	2.829 8	12.135 8
优化控制	2.766 0	48.076 6	14.599 5	3.139 8	12.999 0

表2 闭环控制与优化控制策略的能耗比较

Table 2 Comparison of energy consumption with closed loop control and our optimal control

控制策略	Q / ($kg\ poll.\ units/d$)	E_A / (kWh/d)	E_p / (kWh/d)	E / (kWh/d)
闭环控制 ^[5,13]	6 086.3	3 666.9	212.512	3 879.4
优化控制	6 198.7	3 422.5	277.869	3 700.4

4 结束语

文中提出一种自适应粒子群优化算法,以污水处理过程能耗最小为目标函数,污水处理过程物料平衡、水质排放标准等限制为约束条件,根据进水水质的变化动态调整 BSM1 中第 5 分区溶解氧浓度、混合液悬浮物固体浓度和第 2 分区硝酸氮浓度的设定值。同时通过神经网络预测模型预测出水水质参数,从而实现污水处理过程不但出水水质达标,而且实现 BSM1 低成本运行。通过仿真实验发现,基于自适应粒子群算法的污水处理神经网络优化控制系统具有以下优点。

1) 实现污水处理过程多变量控制,与单变量控制相比,多变量控制方法提高了污水处理效率。

2) 改进的自适应粒子群算法能够有效地抑制局部最优解,避免过早陷入局部最优,比遗传算法更简单,参数更少,求解速度更快,并且实现了污水处理过程优化控制,降低了污水处理过程能耗。

3) 采用神经网络预测和控制,提高了智能控制系统的自适应性和鲁棒性,以及污水处理过程的稳定性。

综上所述,文中提出的智能优化控制系统能够满足污水处理出水达标,同时降低其运行成本,为实际污水处理厂提供了理论和技术支持。

参考文献:

- [1] 中华人民共和国住房和城乡建设部. 关于全国城镇污水处理设施 2011 年第一季度建设和运行情况的通报[EB/OL]. (2011-05-07)[2012-05-16]. <http://www.mohurd.gov.cn>.
- [2] PIOTROWSKI R, BRDYS M A. Hierarchical dissolved oxygen control for activated sludge processes[J]. *Control Engineering Practice*, 2008, 16 (1): 114-131.
- [3] CHANDRAMOULI V, BRION G, NEELAKANTAN T R, et al. Backfilling missing microbial concentrations in a riverine database using artificial neural networks[J]. *Water Research*, 2007, 41 (1): 217-227.
- [4] BERAUD B, STEYER J P. Towards a global multi objective optimization of wastewater treatment plant based on modeling and genetic algorithms[J]. *Water Science & Technology*, 2007, 56(9): 109-116.
- [5] 张平,苑明哲,王宏. 基于国际评价基准的溶解氧控制方法研究[J]. *信息与控制*, 2007, 36(2): 199-203.
ZHANG Ping, YUAN Mingzhe, WANG Hong. Study on dissolved oxygen control method based on international evaluation benchmark[J]. *Information and Control*, 2007, 36 (2): 199-203.
- [6] 熊伟清,刘明达,魏平. 遗传算法的基因定位算子[J]. *控制理论与应用*, 2005, 22(3): 491-494.
XIONG Weiqing, LIU Mingda, WEI Ping. Gene-orientation operator for genetic algorithm[J]. *Control Theory & Applications*, 2005, 22(3): 491-494.
- [7] ALIREZA A. PSO with adaptive mutation and inertia weight and its application in parameter estimation of dynamic systems[J]. *Acta Automatica Sinica*, 2011, 37(5): 541-549.
- [8] XIAO Renyue, YU Jinhai. A newly self-adaptive strategy for the PSO[C]//*Proceedings of the 2008 Fourth International Conference on Natural Computation*. Washington, DC, USA: IEEE Computer Society, 2008: 396-400.
- [9] 张顶学,关治洪,刘新芝. 一种动态改变惯性权重的自适应粒子群算法[J]. *控制与决策*, 2008, 23(11): 1253-1257.
ZHANG Dingxue, GUAN Zhihong, LIU Xinshi. Adaptive particle swarm optimization algorithm with dynamically changing inertia weight[J]. *Control and Decision*, 2008, 23 (11): 1253-1257.
- [10] 苏守宝,曹喜滨,孔敏. 群活性与粒子群优化的稳定性分析[J]. *控制理论与应用*, 2010, 27(10): 1411-1417.
SUN Shoubao, CAO Xibin, KONG Min. Stability analysis of particle swarm optimization using swarm activity[J]. *Control Theory & Applications*, 2010, 27(10): 1411-1417.
- [11] 李宁,孙德宝,邹彤,等. 基于差分方程的 PSO 算法粒子运动轨迹分析[J]. *计算机学报*, 2006, 29(11): 2050-2062.
LI Ning, SUN Debao, ZOU Tong, et al. An analysis for a particle's trajectory of PSO based on difference equation[J]. *Chinese Journal of Computers*, 2006, 29(11): 2050-2062.
- [12] 熊智挺,谭阳红,易如方,等. 一种并行的自适应量子粒子群算法[J]. *计算机系统应用*, 2011, 20(8): 47-71.
XIONG Zhiting, TAN Yanghong, YI Rufang, et al. Method of parallel adaptive quantum particle swarm optimization[J]. *Computer System and Applications*, 2011, 20(8): 47-71.
- [13] 魏建香,孙越泓,苏新宁. 一种基于免疫选择的粒子群优化算法[J]. *南京大学学报:自然科学版*, 2010, 46(1): 1-9.
WEI Jianxiang, SUN Yuehong, SU Xinning. A novel particle swarm optimization based on immune selection[J]. *Journal of Nanjing University: Natural Sciences*, 2010, 46 (1): 1-9.
- [14] COPP J B. The COST simulation benchmark: description and simulator manual[M]. Luxembourg: Office for Publications of the European Community, 2001.
- [15] 史雄伟,乔俊飞,苑明哲. 基于改进粒子群算法的污水

处理过程优化控制[J]. 信息与控制, 2011, 40(5): 698-703.

SHI Xiongwei, QIAO Junfei, YUAN Mingzhe. Optimal control for wastewater treatment process based on improved particle swarm optimization algorithm[J]. Information and Control, 2011, 40(5): 698-703.

作者简介:



乔俊飞,男,1968年生,教授,博士生导师,博士,主要研究方向为智能控制、污水处理过程建模与优化控制、智能系统分析与设计.主持完成或承担国家自然科学基金项目4项、国家"863"计划项目2项、教育部博士点基金与北京市自然科学基金等省部级项目共9项.2011年获得教育部高等学校科学研究优秀成果奖科学技术进步奖一等奖.发表学术论文100余篇,其中被SCI检索12篇,EI检索60余篇,获得国家发明专利授权9项、软件著作权8项.



逢泽芳,女,1986年生,硕士研究生,主要研究方向为智能控制理论、方法与应用.



韩红桂,男,1983年生,讲师,主要研究方向为神经网络自组织设计及城市污水处理过程的建模和控制.

欢迎订阅《控制工程》期刊

跟踪国际自动化最新动态 发布自动化领域最新研究成果 展示自动化领域最新产品

《控制工程》(双月刊)

国际刊号:ISSN1671-7848 国内刊号:CN21-1476/TP

邮发代号:8-216 国内定价:15元/期(全年90元)

《控制工程》是由国家教育部主管、东北大学主办的国家级学术性期刊,创刊于1994年.《控制工程》系:北京大学中文核心期刊、中国科技核心期刊、中国科学引文数据库核心期刊(CSCD)、中国科技论文统计用刊、中国科学文献数据用刊、《中国学术期刊综合评价数据库》来源期刊,俄罗斯《文摘杂志》(AJ)、美国《剑桥科学文摘》(CSA)、英国《科学文摘》(SA, INSPEC)三大著名检索机构全文检索期刊.

· 本刊是自动控制学科的学术期刊,主要刊登反映自动化技术及产品的研究开发及应用方面最新成果:的研究报告,以及学术研讨和自动化高技术及其产品的介绍.

· 主要栏目:综述与评论、过程控制技术及应用、智能控制技术及应用、优化控制技术及应用、计算机控制系统及软件、机电一体化、电气自动化、检测装置及仪表、企业资源与管理系统、综合自动化系统、故障诊断、典型自动化工程、模式识别及图像处理等.

地 址:沈阳东北大学310信箱

邮 编:110004

电 话:024-23883498/024-83687509

传 真:024-23883498

E-mail:kzgcjb@mail.neu.edu.cn

http://www.kzgc.com.cn