

数据驱动的溶解氧浓度在线自组织控制方法

权利敏^{1,2} 杨翠丽¹ 乔俊飞¹

摘要 针对城市污水处理过程的非线性、不确定性以及非高斯等特点,提出一种数据驱动的溶解氧(Dissolved oxygen, DO)浓度在线自组织控制方法.首先,设计一种基于相关熵的自组织模糊神经网络控制器(Correntropy-based self-organizing fuzzy neural network, CSOFNN),采用相关熵与规则贡献度指标实现控制器结构与参数的自动构建或修剪.其次,设计基于相关熵诱导准则的补偿控制器及参数自适应律,充分利用相关熵抑制非高斯噪声的能力,能够有效地降低系统中的不确定性.然后,分析所提出的控制方法的稳定性,从而保证其在实际应用中的可靠性.最后,基于基准仿真 1 号模型(Benchmark simulation model No. 1, BSM1)的实验验证了所提方法的有效性.

关键词 数据驱动控制, 相关熵, 在线自组织, 模糊神经网络, 溶解氧浓度, 稳定性分析

引用格式 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, 2023, 49(12): 2582–2593

DOI 10.16383/j.aas.c210041

Data-driven Online Self-organizing Control for Dissolved Oxygen Concentration

QUAN Li-Min^{1,2} YANG Cui-Li¹ QIAO Jun-Fei¹

Abstract To deal with the nonlinearity, uncertainty and non-Gaussianity of urban wastewater treatment processes, this paper proposes a data-driven online self-organizing control method for dissolved oxygen (DO). First, a correntropy-based self-organizing fuzzy neural network (CSOFNN) controller is designed. For CSOFNN, its structure and parameters can be automatically generated or pruned based on the correntropy and rules-contribution indexes. Second, the compensation controller and parameter adaptive laws are developed using the correntropy-induced criterion, thus can tackle non-Gaussian noise and reduce the system uncertainty. Third, the stability of the proposed control method is analyzed theoretically, thus ensuring its feasibility in practice. Finally, the proposed control method is tested in the benchmark simulation model No. 1 (BSM1). The experimental results show its effectiveness.

Key words Data-driven control, correntropy, online self-organizing, fuzzy neural network (FNN), dissolved oxygen concentration, stability analysis

Citation Quan Li-Min, Yang Cui-Li, Qiao Jun-Fei. Data-driven online self-organizing control for dissolved oxygen concentration. *Acta Automatica Sinica*, 2023, 49(12): 2582–2593

随着城市化进程的加快,城市污水已成为水体污染的重要来源之一^[1].城市污水处理能够去除水中有机污染物,以及氮、磷等污染物,是防治水污染、改善城市生态环境的有效手段^[2].目前,活性污泥法

是利用微生物反应脱氮除磷的主要方法之一,在国内外城市污水处理中已得到广泛应用^[3].在活性污泥污水处理过程中,溶解氧(Dissolved oxygen, DO)浓度直接影响着好氧区微生物的生长与活性,是决定污水中氨氮、硝态氮的去除率的关键因素^[3-4].因此,DO浓度的实时精确控制对于提高城市污水处理效率至关重要.然而,城市污水处理过程包含复杂的生物化学反应,易受进水流量、进水污染物组分变化等干扰,是一个强非线性、非平稳动态过程,难以对其建立精确的数学模型^[5-6].因此,传统的基于机理模型的控制方法容易出现模型失配的问题,难以取得满意的DO浓度控制效果.

近年来,随着信息科学技术的发展,数据采集与监控系统(Supervisory control and data acquisition, SCADA)已在城市污水处理厂中得到广泛应用.因此,城市污水处理厂能够获得大量蕴含设备状态、运行状态等信息的过程数据^[2].另一方面,数

收稿日期 2021-01-13 录用日期 2021-05-10

Manuscript received January 13, 2021; accepted May 10, 2021

国家自然科学基金(62021003, 61890930-5, 61973010), 科技创新 2030——“新一代人工智能”重大项目(2021ZD0112302), 北京市自然科学基金(4202006)资助

Supported by National Natural Science Foundation of China (62021003, 61890930-5, 61973010), National Key Research and Development Program of China (2021ZD0112302), and Natural Science Foundation of Beijing (4202006)

本文责任编辑 刘艳军

Recommended by Associate Editor LIU Yan-Jun

1. 北京工业大学信息学部, 智慧环保北京实验室, 计算智能与智能系统北京市重点实验室 北京 100124 2. 青岛理工大学信息与控制工程学院 青岛 266520

1. Faculty of Information Technology, Beijing University of Technology, Beijing Laboratory of Smart Environmental Protection, Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing 100124 2. School of Information and Control Engineering, Qingdao University of Technology, Qingdao 266520

据驱动的控制方法,能够直接利用历史数据或在线数据构建控制器,是解决复杂过程控制问题的有效方法^[7].因此,为了实现 DO 浓度的精确控制,学者们对模糊控制^[8]、基于神经网络的直接或间接控制^[9-11],以及集成以上方法的混合控制等数据驱动的方法^[12-15]开展了广泛的研究.其中,基于神经网络的控制方法因为能够充分利用神经网络的非线性逼近能力和自学习能力,已成为 DO 浓度控制领域的研究热点.例如,韩广等^[16]提出一种基于前馈神经网络的建模控制方法,采用前馈神经网络建立 DO 浓度的辨识模型和控制器,取得了比 PID 和模型预测控制等方法更好的控制精度.Lin 等^[17]提出一种基于径向基函数(Radial basis function, RBF)神经网络的 DO 浓度自适应控制方法,实验结果表明该方法能有效地跟踪 DO 浓度.但是,以上方法采用试凑法选择固定的神经网络结构,控制系统的设计效率低且难以处理具有强不确定性的城市污水处理过程.

近年来,模糊神经网络(Fuzzy neural network, FNN)因为具有模糊系统处理不确定信息的能力以及神经网络的自学习能力,在污水处理过程控制领域得到广泛的应用^[18-20].针对污水处理过程的不确定性,为了提高控制系统的设计效率,乔俊飞等^[20]提出一种基于自组织 T-S 模糊神经网络(Self-organizing T-S fuzzy neural network, SOTS-FNN)的 DO 浓度控制方法.该方法利用在线数据自动生成控制器的模糊规则,提高了 DO 浓度的控制性能.但是, SOTS-FNN 控制器的规则只能增加不能删减,面临规则爆炸的风险.为了避免网络结构过大,周红标等^[21]提出一种基于自组织模糊神经网络的控制器(Self-organizing fuzzy neural network, SOFNN),基于模糊规则的激活强度和互信息自动增加或修剪控制器规则,控制器能以较少的规则获得较高的控制精度.虽然以上基于模糊神经网络的控制方法取得了较为满意的 DO 浓度控制效果,但是这些方法均采用最小均方误差(Minimum mean square error, MMSE)准则,其目标是 minimized 跟踪误差的方差,仅在误差服从零均值的高斯分布时能获得最优解^[22].然而,城市污水处理过程易受随机过程扰动及传感器故障等影响,导致过程数据受非高斯噪声或异常值污染,表现出非高斯特性^[23].因此,采用 MMSE 准则的控制器在实际应用中容易出现控制性能退化的问题.迄今,如何提高 DO 浓度控制器抗非高斯噪声干扰的能力仍然是一个开放性的难点问题.

在信息论学习领域,相关熵是一种定义在核空间中的局部非线性相似度量^[23],因此具有对异常

值不敏感的特性.近年来,基于最大相关熵准则(Maximum correntropy criterion, MCC)的方法,因其对非高斯噪声和异常值的鲁棒性,已在信号处理和机器学习领域中得到广泛应用^[24-27].为了实现非线性系统的辨识, Bao 等^[25]提出一种基于相关熵的进化模糊神经网络(Correntropy-based evolving fuzzy neural system, CEFNS),该方法基于相关熵与距离准则自动构建 CEFNS 的结构,并采用基于 MCC 的梯度下降算法在线更新 CEFNS 的后件参数.实验结果表明, CEFNS 比其他基于 MMSE 准则的 EFNS 具有更好的鲁棒性和辨识精度.但是, CEFNS 的规则在学习过程中只增不减,处理复杂的非线性系统时,容易出现规则数目过大的问题.此外,针对有机朗肯循环余热回收系统的控制问题, Ren 等^[28]提出一种基于广义相关熵的单神经元自适应多步预测控制方法,通过优化基于广义相关熵的性能指标调整单神经元控制器的权值参数,能够有效地抑制系统中的非高斯扰动.但是,该方法缺少对控制系统的稳定性分析.

基于以上分析,本文提出一种数据驱动的 DO 浓度在线控制方法,该方法的控制系统由一个基于相关熵的自组织模糊神经网络(Correntropy-based self-organizing fuzzy neural network, CSOFNN)控制器和一个补偿控制器组成.首先,建立基于相关熵的自组织机制,根据在线输入/输出数据自动构建 CSOFNN 控制器的结构.然后,设计基于相关熵准则的补偿控制器和控制器参数自适应律,并分析控制系统的稳定性.最后,基于活性污泥污水处理基准仿真 1 号模型(Benchmark simulation model No. 1, BSM1)^[29],在有外部环境干扰及噪声的工况下进行实验验证.本文的创新点如下:

1) 提出一种基于相关熵补偿的自组织算法,实现 CSOFNN 控制器规则的自动增加或删减,能够利用相关熵准则抑制异常值或外部扰动对控制器结构调整带来的不良影响,从而提高控制器性能;

2) 设计基于相关熵诱导准则的补偿控制器和参数自适应律,利用相关熵诱导准则能够提高控制器抗非高斯噪声干扰能力,同时,补偿控制器能够减小 CSOFNN 控制器的逼近误差和降低系统的不确定性.

1 城市污水处理过程及控制问题描述

1.1 城市污水处理 A/O 工艺过程描述

以广泛应用的缺氧/好氧(Anoxic/oxic, A/O)工艺为例,基于活性污泥法的城市污水处理工艺流程如图 1 所示.首先,污水进入初沉池,在其中去除




图 1 A/O 工艺城市污水处理流程图

Fig.1 Schematic diagram of urban wastewater treatment with the A/O process

固体悬浮物颗粒. 然后, 污水进入缺氧池初步降解有机物, 该过程主要对内回流的硝化液进行反硝化脱氮. 接着, 污水进入好氧池进一步降解有机物, 同时进行硝化反应去除污水中的氨氮. 最后, 处理达标的污水经二沉池顶部进行排放, 部分污泥经二沉池底部与好氧池硝化混合液同时回流到缺氧池, 其余污泥直接排出污水处理系统.

生化反应池是 A/O 工艺的核心区域, 包含两个缺氧池和三个好氧池. 在好氧池中, 硝化反应需要高 DO 浓度; 然而, 在缺氧池中, 反硝化反应需要低 DO 浓度. 如果好氧池 DO 浓度过高, 经内回流进入缺氧池, 势必会对缺氧池的反硝化过程产生影响. 因此, 对第 5 个反应池的溶解氧浓度进行精确控制十分重要. 根据国际水协会 (International Water Association, IWA) 提出的活性污泥 1 号模型 (Activated sludge model No. 1, ASM1)^[20], DO 浓度的质量平衡方程表示为

$$\frac{dS_{o,k}}{dt} = \gamma_k - \frac{Q_k S_{o,k}}{V_k} + S_{o,sat} K_{La,k} - S_{o,k} K_{La,k} + \frac{Q_{k-1} S_{o,k-1}}{V_k} \quad (1)$$

式中, $S_{o,k}$ 表示第 k 个反应池 DO 浓度, $S_{o,sat}$ 表示 DO 的饱和浓度, V_k 和 Q_k 分别表示第 k 个反应池的体积和流量, γ_k 和 $K_{La,k}$ 分别为第 k 个反应池的呼吸速率和氧气传递速率. 其中, Q_k 的值易受外部环境变化的影响 (如降雨、暴雨等天气变化), 可视为 DO 浓度控制系统的外部干扰. 而且, 在实际过程中, $S_{o,sat}$, γ_k 为固定常数. 因此, 选择 $K_{La,5}$ 作为第 5 个反应池的 DO 浓度控制的操作变量.

1.2 溶解氧浓度控制问题描述

令 $x = S_{o,5}$, $u = K_{La,5}$, $d = Q_4 S_{o,4} / V_5$, $f(x) = \gamma_5 - S_{o,5} Q_5 / V_5$, $g(x) = S_{o,sat} - S_{o,5}$, 结合式 (1), 则第 5 个反应池中 DO 浓度的动力学模型可表示为

$$\begin{cases} \dot{x} = f(x) + g(x)u + d \\ y = x \end{cases} \quad (2)$$

其中, $x \in \mathbf{R}$ 为系统的一个状态量, $u \in \mathbf{R}$ 和 $y \in \mathbf{R}$ 分别为控制系统的输入与输出. $f(\cdot) \in \mathbf{R}$ 和 $g(\cdot) \in \mathbf{R}$ 分别为未知的光滑函数, d 表示外部干扰, 且 d 是有界的.

假设系统 (2) 是可控的, 控制系统的跟踪误差 e 表示为

$$e = r - y \quad (3)$$

其中, r 与 y 分别为系统设定值与实际输出值. 如果函数 $f(\cdot)$, $g(\cdot)$ 与 d 是已知的, 且 $g^{-1}(\cdot)$ 存在, 则理想控制器根据反馈线性化方法^[30] 表示为

$$u^* = g^{-1}(r) (\dot{r} - f(r) - d + \lambda e) \quad (4)$$

其中, λ 为正常数, 表示反馈增益. 然而, 城市污水处理过程包含复杂的生物化学反应, 是一个强非线性动态过程, 且外部干扰严重, 其状态量与输入/输出之间的关系难以描述, 函数 $f(\cdot)$, $g(\cdot)$ 与 d 都是未知的, 所以无法通过建立精确的数学模型获得理想控制律 u^* .

基于以上分析, 本文提出一种基于 CSOFNN 的 DO 浓度控制系统, 其结构如图 2 所示, 可表示为

$$u = u_n + u_c \quad (5)$$

其中, u_n 表示 CSOFNN 控制器的输出, u_c 表示补偿控制器的输出, 用于消除 CSOFNN 控制律与理想控制律之间的逼近误差 ε .

2 CSOFNN 控制器设计

为了设计 CSOFNN 控制器, 采用一个多输入单输出模糊神经网络^[3], 其结构包括输入层、隶属函数层、规则层以及输出层, 如图 2 所示. CSOFNN 控制器的输入为系统跟踪误差 e 与误差变化率 Δe , 即

$$\mathbf{x} = [x_1, x_2]^T = [e, \Delta e]^T \quad (6)$$

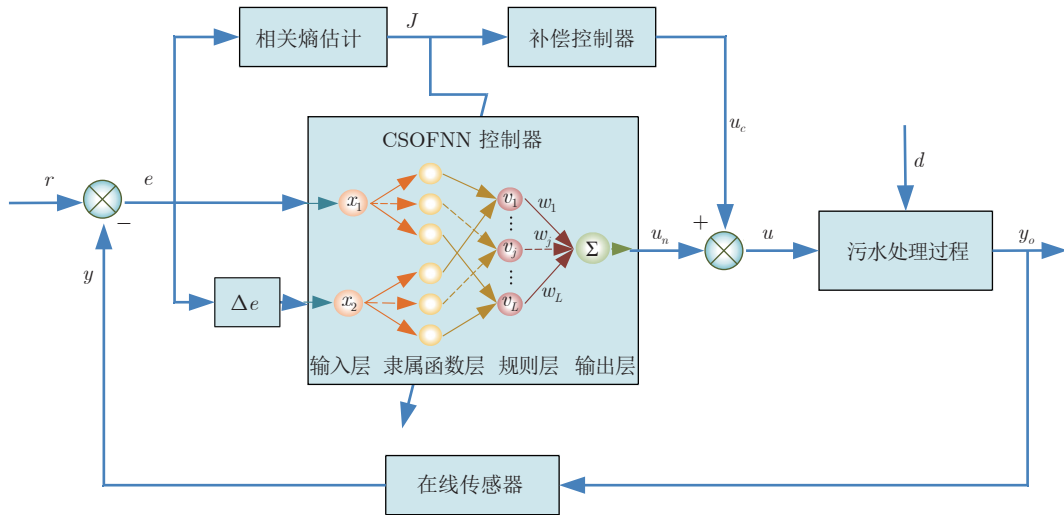


图 2 基于 CSOFNN 的溶解氧浓度控制系统框图

Fig. 2 Diagram of the CSOFNN-based control system for the DO concentration

其中, x_i ($i = 1, 2$) 表示 CSOFNN 控制器的第 i 个输入变量. CSOFNN 控制器的输出 u_n 用于逼近理想控制律 u , 其计算式为

$$u_n = \mathbf{W}^T \boldsymbol{\nu} = \sum_{j=1}^L w_j \nu_j \quad (7)$$

$$\nu_j = \frac{\exp\left(-\sum_{i=1}^2 \frac{(x_i - c_{ij})^2}{2\sigma_{ij}^2}\right)}{\sum_{j=1}^L \exp\left(-\sum_{i=1}^2 \frac{(x_i - c_{ij})^2}{2\sigma_{ij}^2}\right)} \quad (8)$$

其中, L 为 CSOFNN 的模糊规则数, 即规则层神经元数目. $\mathbf{W} = [w_1, w_2, \dots, w_L]^T$ 为连接规则层与输出层的权值矩阵, $\boldsymbol{\nu} = [\nu_1, \nu_2, \dots, \nu_L]^T$ 为规则层的归一化输出向量, 表示规则激活强度. c_{ij} 与 σ_{ij} 分别为关联第 i 个输入与第 j 条规则的隶属函数中心值与宽度值. $\mathbf{c}_j = [c_{1j}, c_{2j}]^T$ 与 $\boldsymbol{\sigma}_j = [\sigma_{1j}, \sigma_{2j}]^T$ 分别表示第 j 条规则对应隶属函数的中心向量与宽度向量.

神经网络控制器一般采用 MMSE 准则求解最优参数, 仅在误差服从高斯分布的情形下是最优的^[22]. 然而, 城市污水处理过程数据易受测量噪声或异常值干扰, 具有非高斯特性. 因此, 为获取 CSOFNN 控制器的最优参数, 采用 MCC 准则. MCC 的原理是最大化原点附近的误差概率密度, 能有效抑制非高斯噪声和异常值^[24]. k 时刻控制系统实际输出 y_k 与期望值 r_k 之间的相关熵 J_{Ck} , 表示为

$$J_{Ck} = \exp\left(-\frac{(r_k - y_k)^2}{2\sigma_g^2}\right) = \exp\left(\frac{-e_k^2}{2\sigma_g^2}\right) \quad (9)$$

其中, $\sigma_g > 0$ 为核宽度. 相关熵是一种局部相似度量, 由于式 (9) 中高斯函数的特性, 系统误差越大, J_{Ck} 的值越小, 且 $0 < J_{Ck} \leq 1$.

2.1 CSOFNN 控制器的结构学习算法

城市污水处理过程包含多种工况 (例如晴天、降雨、暴雨等不同天气的工况), 在不同的工况下, 进水流量与污染物浓度不同. 因此, 为了提高 DO 浓度的控制性能, DO 浓度的设定值需要根据工况变化进行调整. 当 DO 浓度设定值变化时, 固定结构的控制器不能及时调整网络结构, 难以适应新的处理要求. 另一方面, 采用试凑法设计控制器的结构, 不仅耗时耗力而且控制器的性能也受到限制. 因此, 本文提出基于相关熵补偿的结构在线自组织算法, 通过补偿系统输出与设定值之间的局部相似度量, 自动构建 CSOFNN 控制器的结构, 控制器能够在学习过程中自动增加或删除模糊规则, 提高了控制器的自适应性. CSOFNN 结构在线学习算法的具体步骤如下.

步骤 1. 规则增长. CSOFNN 的原始结构为空, 根据第 1 组输入网络的数据对 (\mathbf{x}_1, y_1) 进行结构与参数的初始化, 即

$$\begin{cases} \mathbf{c}_1 = \mathbf{x}_1 \\ \sigma_1 = \mu \|\mathbf{x}_1\| \\ w_1 = 0 \end{cases} \quad (10)$$

其中, μ 是一个正的宽度调节系数, 决定了不同模糊规则之间的差异性, 一般在区间 $[0.5, 1]$ 之间取值. 初始网络模糊规则数为 $L = 1$.

在 k 时刻, 网络输入为 \mathbf{x}_k , 假设当前模糊规则

数为 L , 如果溶解氧浓度 y_k 与设定值 r_k 之间的相关熵 J_{Ck} 满足

$$G_d < J_{Ck} < G_u \tag{11}$$

则需要增加规则进行相似度补偿, 即

$$\begin{cases} c_{L+1} = \mathbf{x}_k \\ \sigma_{L+1} = \mu \|\mathbf{x}_k\| \\ w_{L+1} = 0 \end{cases} \tag{12}$$

并设定网络规则数为 $L = L + 1$. 式中, G_u 与 G_d 是预设的规则增长阈值, 分别表示相关熵的上限与下限. G_u 表示系统输出与设定值之间的期望相似度.

注 1. G_d 的设置是为了抑制系统外部干扰 (或异常值) 引起的较大误差对网络性能产生的不良影响. 与已有方法^[20-21, 25] 不同, 所提出的规则增加方法无需计算新规则与已有规则之间的欧氏距离, 能有效提高控制器规则的构建效率.

步骤 2. 规则修剪. 当 CSOFNN 具有一定的信息处理能力后, 考虑网络中是否有冗余规则存在. 对于新输入的数据, 规则 l 表示对应激活强度最小的规则, 其激活强度为 v_j , 即

$$l = \arg \min \{v_j, j = 1, 2, \dots, L\} \tag{13}$$

如果第 l 条规则的激活强度非常小, 表示该规则对整个系统输出的贡献很小, 可以删除, 其删除条件定义为

$$J_{Ck} > P_d \ \& \ v_l < I_{th} \tag{14}$$

式中, P_d 与 I_{th} 分别表示预设的相关熵与激活强度阈值. 当条件 (14) 满足时则删除第 l 条规则, 即

$$c'_l = \mathbf{0}, \ \sigma'_l = \mathbf{0}, \ w'_l = \mathbf{0} \tag{15}$$

此时, 其他规则的激活强度更新为

$$v'_j = \frac{v_j}{1 - v_l} \tag{16}$$

为了保证规则删减阶段网络性能的不变性, 对删减后的网络参数进行如下调整, 即

$$\begin{cases} c'_j = c_j \\ \sigma'_j = \sigma_j \\ w'_j = \left(w_j + \frac{w_l v_l}{L-1}\right) (1 - v_l) \end{cases} \tag{17}$$

则网络输出可根据式 (18) 计算, 即

$$u'_n = \sum_{j=1, j \neq l}^L \left(w_j + \frac{w_l v_l}{L-1}\right) v_j = \sum_{j=1}^L w_j v_j = u_n \tag{18}$$

由式 (18) 可知, 规则删减后网络输出不变. 式

中, $c_j, \sigma_j, w_j, v_j, u_n$ 分别表示删除第 l 条规则前网络相应参数以及网络输出.

最后, 设置网络规则数为 $L = L - 1$.

注 2. 当 $J_{Ck} > P_u$ ($P_u > P_d$), 表示网络性能达到要求, 则不再进行结构调整. P_d 的设置能够避免在控制器构建初期误删有用的规则.

2.2 基于相关熵诱导准则的自适应控制律

控制器一般通过最小化性能指标求解最优参数, 因此基于式 (9) 定义如下相关熵诱导准则, 即

$$\min_{\Theta} J_k = 1 - \exp\left(\frac{-e_k^2}{2\sigma_g^2}\right) \tag{19}$$

其中, J_k 表示 k 时刻控制器参数优化的目标函数, $\Theta = [\mathbf{C}, \mathbf{B}, \mathbf{W}]^T$ 表示网络参数矩阵, $\mathbf{C} = [c_1^T, c_2^T, \dots, c_L^T]^T$ 与 $\mathbf{B} = [\sigma_1^T, \sigma_2^T, \dots, \sigma_L^T]^T$ 分别表示网络中心矩阵与宽度矩阵.

理论上, 存在一个最优 CSOFNN 控制器 u_n^* , 即

$$u^* = u_n^* + \Delta = \mathbf{W}^{*T} \boldsymbol{\nu}^* + \Delta \tag{20}$$

其中, Δ 为理想控制律的逼近误差, $\mathbf{C}^*, \mathbf{B}^*, \mathbf{W}^*, \boldsymbol{\nu}^*$ 分别为对应 $\mathbf{C}, \mathbf{B}, \mathbf{W}, \boldsymbol{\nu}$ 的最优参数. 实际中, 通过自适应算法对最优参数进行估计, 令 \hat{u}_n 表示 u_n^* 的估计值, 即

$$\hat{u}_n = \hat{\mathbf{W}}^T \hat{\boldsymbol{\nu}} \tag{21}$$

其中, $\hat{\mathbf{C}}, \hat{\mathbf{B}}, \hat{\mathbf{W}}, \hat{\boldsymbol{\nu}}$ 为最优参数的估计值, 则 CSOFNN 控制器的逼近误差可表示为

$$\tilde{u}_n = u^* - \hat{u}_n = \mathbf{W}^{*T} \boldsymbol{\nu}^* - \hat{\mathbf{W}}^T \hat{\boldsymbol{\nu}} + \Delta = \tilde{\mathbf{W}}^T \tilde{\boldsymbol{\nu}} + \hat{\mathbf{W}}^T \tilde{\boldsymbol{\nu}} + \tilde{\mathbf{W}}^T \hat{\boldsymbol{\nu}} + \Delta \tag{22}$$

其中, $\tilde{\mathbf{W}} = \mathbf{W}^* - \hat{\mathbf{W}}, \tilde{\boldsymbol{\nu}} = \boldsymbol{\nu}^* - \hat{\boldsymbol{\nu}}$. 对 $\tilde{\boldsymbol{\nu}}$ 进行泰勒展开, 可以得到

$$\tilde{\boldsymbol{\nu}} = \boldsymbol{\nu}_C^T \tilde{\mathbf{C}} + \boldsymbol{\nu}_B^T \tilde{\mathbf{B}} + \mathbf{h} \tag{23}$$

$$\boldsymbol{\nu}_C = \begin{bmatrix} \frac{\partial v_1}{\partial C} & \frac{\partial v_2}{\partial C} & \dots & \frac{\partial v_L}{\partial C} \end{bmatrix}^T \tag{24}$$

$$\boldsymbol{\nu}_B = \begin{bmatrix} \frac{\partial v_1}{\partial B} & \frac{\partial v_2}{\partial B} & \dots & \frac{\partial v_L}{\partial B} \end{bmatrix}^T \tag{25}$$

其中, $\tilde{\mathbf{C}} = \mathbf{C}^* - \hat{\mathbf{C}}, \tilde{\mathbf{B}} = \mathbf{B}^* - \hat{\mathbf{B}}, \mathbf{h}$ 表示泰勒展开的高阶项向量.

将式 (2) 代入式 (5), 结合式 (4) 可以得到系统的误差动力学计算式, 即

$$\begin{aligned} \dot{e} = & -\lambda e + b(u^* - u_n - u_c) = \\ & -\lambda e + b(\tilde{\mathbf{W}}^T \boldsymbol{\nu}_C^T \tilde{\mathbf{C}} + \hat{\mathbf{W}}^T \boldsymbol{\nu}_B^T \tilde{\mathbf{B}} + \\ & \mathbf{W}^T \hat{\boldsymbol{\nu}} + \varepsilon - u_c) \end{aligned} \tag{26}$$

其中, $\lambda = 1, b = 1, \varepsilon = \hat{\mathbf{W}}^T \mathbf{h} + \tilde{\mathbf{W}}^T \hat{\boldsymbol{\nu}} + \Delta$ 表示系

统的不确定性, 假设 ε 的估计值为 $\hat{\varepsilon}$. 为了消除逼近误差, 降低系统不确定性, 设计基于相关熵诱导准则的补偿控制器为

$$u_c = \hat{\varepsilon} + \frac{\rho e}{\Lambda_e} \quad (27)$$

其中, $\Lambda_e = \exp(-e^2/(2\sigma_g^2))/\sigma_g^2$, ρ 为正常数.

为了保证控制系统的稳定性 (将在第 2.3 节进行分析), 基于相关熵诱导准则定义 CSOFNN 控制器参数以及 $\hat{\varepsilon}$ 的自适应律为

$$\dot{C} = \eta_C \nu_C W \Lambda_e e \quad (28)$$

$$B = \eta_B \nu_B W \Lambda_e e \quad (29)$$

$$\dot{W} = \eta_W \nu_W \Lambda_e e \quad (30)$$

$$\dot{\hat{\varepsilon}} = \eta_\varepsilon \Lambda_e e \quad (31)$$

其中, η_C , η_B , η_W , η_ε 分别为取值在 $(0, 1)$ 区间的学习率参数. 基于以上分析, 基于 CSOFNN 的溶解氧浓度控制方法的主要步骤如下:

步骤 1. 初始化. 设置学习率 η , 阈值参数 G_u , G_d , P_u , P_d , I_{th} , 并根据式 (10) 初始化控制器.

步骤 2. 控制器参数学习. 根据自适应律 (28) ~ (31) 更新控制器参数; 根据式 (5), (7), (27) 计算控制律 u_n , 并根据 u_n 调整控制量 $K_{La,5}$.

步骤 3. 控制器结构调整. 如果 $J_{Ck} < P_u$, 则进行控制器结构调整. 如果满足条件 (11), 则根据式 (12) 增加一条规则; 如果满足条件 (14), 则根据式 (15) 删减一条规则, 且根据式 (17) 调整网络参数.

步骤 4. 若全部数据运行完毕, 结束循环; 否则, 转到步骤 2.

2.3 稳定性分析

定理 1. 当溶解氧浓度控制系统采用如式 (6) 所示的控制律, CSOFNN 控制器和补偿控制器分别设计如式 (11) 和式 (27), 且采用式 (28) ~ (31) 所示自适应律, 可以保证控制系统稳定以及误差 e 收敛到零.

证明. 首先构造李雅普诺夫候选函数如下:

$$V = 1 - \exp\left(\frac{-e^2}{2\sigma_g^2}\right) + \frac{1}{2\eta_C} \tilde{C}^T \tilde{C} + \frac{1}{2\eta_B} \tilde{B}^T \tilde{B} + \frac{1}{2\eta_W} \tilde{W}^T \tilde{W} + \frac{1}{2\eta_\varepsilon} \tilde{\varepsilon}^2 \quad (32)$$

其中, $\tilde{\varepsilon} = \varepsilon - \hat{\varepsilon}$.

对式 (32) 求导, 可得

$$\dot{V} = \Lambda_e e \dot{e} - \frac{1}{\eta_C} \tilde{C}^T \dot{\tilde{C}} - \frac{1}{\eta_B} \tilde{B}^T \dot{\tilde{B}} - \frac{1}{\eta_W} \tilde{W}^T \dot{\tilde{W}} - \frac{1}{\eta_\varepsilon} \tilde{\varepsilon} \dot{\tilde{\varepsilon}} \quad (33)$$

将式 (26) 代入式 (33), 可得

$$\begin{aligned} \dot{V} = & \Lambda_e \left(\tilde{C}^T \left(\tilde{W} \nu_C e - \frac{1}{\Lambda_e \eta_C} \dot{\tilde{C}} \right) + \right. \\ & \tilde{B}^T \left(\tilde{W} \nu_B e - \frac{1}{\Lambda_e \eta_B} \dot{\tilde{B}} \right) + \\ & \left. \tilde{W}^T \dot{\nu} e - \frac{1}{\Lambda_e \eta_W} \tilde{W}^T \dot{\tilde{W}} + \right. \\ & \left. e \varepsilon - \frac{1}{\Lambda_e \eta_\varepsilon} \tilde{\varepsilon} \dot{\tilde{\varepsilon}} - e u_c - \lambda e^2 \right) \quad (34) \end{aligned}$$

将式 (28) ~ (31) 代入式 (34), 得

$$\dot{V} = -\lambda \Lambda_e e^2 - \rho e^2 \quad (35)$$

由于 $0 < \Lambda_e \leq 1/\sigma_g^2$, $\lambda > 0$ 且 $\rho > 0$, 可得

$$\dot{V} \leq -\rho e^2 \leq 0 \quad (36)$$

由式 (32) 和式 (36) 可知, $V(t) \geq 0$ 且 $V(t)$ 是非递增的, 则 $V(\infty)$ 存在. 由式 (36), 可得

$$\lim_{t \rightarrow \infty} \int_0^t e^2 d\tau \leq \frac{1}{\rho} (V(0) - V(\infty)) \quad (37)$$

不等式 (37) 右侧有界, 由 Barbalat 引理^[31], 得

$$\lim_{t \rightarrow \infty} e^2 = 0 \quad (38)$$

即 $t \rightarrow \infty$ 时, $e \rightarrow 0$. \square

注 3. 在 CSOFNN 结构调整阶段, 由式 (12) 和式 (18) 可知, CSOFNN 的输出不变, 即结构调整不会改变 CSOFNN 的收敛性, 控制系统的稳定性分析可参照定理 1 的证明.

3 实验与分析

为了验证基于 CSOFNN 的溶解氧浓度控制方法的性能, 基于 BSM1 进行实验, 并采用平方误差积分 (Integral of squared error, ISE)、绝对误差积分 (Integral of absolute error, IAE)、最大绝对误差 (Maximal deviation from set point, Dev^{max}) 三个性能指标评估控制方法的性能^[20].

$$\begin{aligned} IAE &= \int_{t_0}^{t_f} |e| dt \\ ISE &= \int_{t_0}^{t_f} e^2 dt \\ Dev^{\max} &= \max\{|e|\} \quad (39) \end{aligned}$$

其中, e 表示溶解氧浓度设定值 r 与系统实际输出测量值 y 之间的误差, 且 $y = y_o + d_{\text{noise}}$, y_o 表示系统正常输出, d_{noise} 表示传感器噪声.

为了评估 CSOFNN 控制器的精度和抗干扰能力, 选取入水波动较大的阴雨工况和暴雨工况下的

14 天数据进行测试, 采样周期 15 min, 并用后 7 天的数据评估控制器的性能. 阴雨工况的数据包含前 7 天的干燥天气数据, 并在第 9 ~ 11 天增加了长时间持续降雨过程, 入水污染物浓度随之发生变化. 而暴雨工况的数据, 是在第 10 天和第 12 天模拟突发暴雨, 引起入水流量激增.

此外, 为了模拟溶解氧浓度传感器的噪声, 每隔 1 小时在数据中添加分布在 $[-0.02 \text{ mg/l}, 0.02 \text{ mg/l}]$ 范围的随机脉冲噪声. 图 3 描述了污水处理过程的外部干扰情况, 分别为阴雨和暴雨工况下的入水流量与入水氨氮浓度 (S_{NH} , 单位为 mg/l) 变化, 以及传感器噪声分布曲线. 噪声是模拟溶解氧浓度传感器的噪声, 因此单位与溶解氧浓度一致, 为 mg/l .

为了减小 CSOFNN 控制器规则冗余度, μ 的值在 $[0.5, 0.55]$ 之间随机选取, μ 的值越小, 控制器结构越紧凑. 其他参数的设置如下: $\sigma_g = 0.05$, $\rho = 4$, 学习率参数设定为 $\eta_c = \eta_\sigma = \eta_w = \eta_\varepsilon = 1 \times 10^{-3}$, 结构调整参数设定为 $G_u = 0.95$, $G_d = 0.85 - 0.4 \times 0.99^{(k-1)}$, $P_u = 0.99$, $P_d = P_u - 0.04 \times 0.99^{(k-1)}$, $I_{th} = 0.1/L$. 实验中, DO 浓度设定值分别为恒定值 ($S_o = 2 \text{ mg/l}$) 和阶跃变化 ($S_o = 1.8 \sim 2.2 \text{ mg/l}$) 两种情况.

3.1 恒定溶解氧浓度设定值

首先, 采用恒定的 DO 浓度设定值, 即 $S_o = 2 \text{ mg/l}$, 分别在阴雨和暴雨两种工况下进行实验.

图 4 给出了 CSOFNN 控制器在阴雨和暴雨两种工况下的规则变化曲线. 可以看出, 控制器的规则由零开始自动增加和删减, 且能够快速达到稳定状态. 如图 4(a) 和 4(b) 所示, 在阴雨和暴雨两种工况下, CSOFNN 控制器都能获得较为紧凑的结构, 最终规则数目为 4.

图 5 和图 6 分别给出 DO 浓度的跟踪控制效果与控制误差. 可以看出, 随着 CSOFNN 控制器规则的增加, 控制精度不断提高, 控制系统输出能够快速逼近 DO 浓度设定值.

由图 5(a) 和图 6(a) 可以看出, 在阴雨工况下, 控制器输出的最大绝对误差出现在第 9 天, 与出现降雨引起的较大入水扰动有关, 但所有误差仍分布在 $[-0.008, 0.008]$ 范围内, 控制器具有较高的控制精度, 结合图 5(a) 可以看出, 此时控制器的结构并未改变, 这与规则增长条件 (17) 相一致.

由图 5(b) 和图 6(b) 可以看出, CSOFNN 在暴雨工况下也能有效地跟踪 DO 浓度设定值, 且所有误差均分布在 $[-0.005, 0.005]$ 之间. 此外, 由图 5(b) 和图 6(b) 可以看出, CSOFNN 控制器在突降暴雨的第 10 天和第 12 天能够精确地跟踪 DO 浓度设定值, 即系统在短时内受到剧烈外部扰动时, CSOFNN 也能快速响应外部变化并维持较高的控制性能.

图 7 分别给出了阴雨工况下 CSOFNN 控制器输出 u_n 和补偿控制器输出 u_c 对应控制量 $K_{La,5}$ 的






图 3 外部环境干扰

Fig. 3 External environmental disturbance



(a) 阴雨工况
(a) Rain condition




(b) 暴雨工况
(b) Storm condition

图 4 恒定 S_o 下 CSOFNN 控制器规则变化曲线


Fig.4 Rules variations of CSOFNN controller under constant S_o

变化曲线. 由于主控制器 CSOFNN 能够有效应对外部扰动, 所以补偿控制器的输出范围较小 ($[-4/d, 4/d]$). 结合图 3 中阴雨工况入水流量的变化曲线可以看出, 补偿控制器对应控制量的峰值变化与入水流量的峰值变化趋势一致, 即补偿控制器能够根据外部扰动变化自动调整补偿输出.

为了进一步说明所提出的基于 CSOFNN 控制方法的性能, 将所提出的方法与其他基于 FNN 的控制方法进行比较, 包括基于相关熵准则的 CFNN (Correntropy-based fuzzy neural network) 控制方法^[10], 以及基于 MMSE 准则的 SOFC (Self-organizing fuzzy control)^[15]、SOFNN^[20] 等控制方法. 表 1 给出了不同控制方法的控制器规则数目, IAE 、 ISE 、 Dev^{max} 等指标的平均值. 由表 1 中结果可以看出, 以上方法在阴雨与暴雨工况下都能获得较高的 DO 浓度控制精度, 即所有比较的方法在 DO 浓度设定值恒定时都具有较高的适用性. 但是, 与基于 MMSE 准则的控制器相比, CSOFNN 与 CFNN 控制器都具有更低的 IAE 、 ISE 与 Dev^{max} 值, 控制精度更高. 尤其是在暴雨工况下, 基于相关熵准



(a) 阴雨工况
(a) Rain condition



(b) 暴雨工况
(b) Storm condition

图 5 恒定 S_o 控制效果

Fig.5 Control performance of constant S_o


则的控制方法的最大绝对误差比基于 MMSE 准则的其他方法降低了约 30%, 体现了相关熵准则抑制较大误差的能力. 此外, 由表 1 中结果可知, 与不含补偿控制器的 CFNN 控制方法相比, 基于 CSOFNN 控制方法的 IAE 值降低了约 30%, ISE 值降低了 65%. 由以上分析可知, 补偿控制器的设计能有效降低系统中的不确定性, 提高 DO 浓度的控制性能. 因此, 基于 CSOFNN 的控制方法既能获得最紧凑的结构又具有最高的控制精度.

3.2 变溶解氧浓度设定值


为了测试 CSOFNN 控制方法在 DO 浓度设定值变化时的控制性能, 选择阴雨工况并采用阶跃变化的 DO 浓度设定值 ($S_o = 1.8 \sim 2.2$ mg/l, 如式 (40) 所示), 分别在无噪声和脉冲噪声环境下进行实验.

$$S_o = \begin{cases} 2 \text{ mg/l}, & t < 2, 6 \leq t < 8, 12 \leq t < 14 \\ 2.2 \text{ mg/l}, & 2 \leq t < 4, 8 \leq t < 10 \\ 1.8 \text{ mg/l}, & 4 \leq t < 6, 10 \leq t < 12 \end{cases} \quad (40)$$

图 8 给出了 CSOFNN 控制器在无噪声和有噪



(a) 阴雨工况
(a) Rain condition



(b) 暴雨工况
(b) Storm condition


图 6 恒定 S_0 控制误差

Fig.6 Control errors of constant S_0


声干扰下的结构变化曲线. 可以看出, CSOFNN 控制器规则能够从零自动增加和修剪. 由图 8(a) 可以看出, 在无噪声环境下, 控制器规则数目跟随 DO 浓度设定值的变化而自适应调整, 最终规则数目为 5. 而在有噪声的情况下, 如图 8(b) 所示, 控制器规则数目也能跟随设定值自适应增加或删减, 第 12 天后 (天气转晴), 规则数稳定在 6.

图 9 和图 10 分别给出 CSOFNN 控制器在 DO 浓度设定值阶跃变化时的跟踪控制效果与控制误差. 由图 9(a) 和图 10(a) 可以看出, 在设定值阶跃变化时, CSOFNN 控制器仍能较为平稳地跟踪 DO 浓度设定值, 仅在开始降雨的第 9 天出现较大的误差. 在无噪声干扰时, 所有控制误差分布在 $[-0.008, 0.004]$ 范围内. 因此, CSOFNN 控制器无噪声环境下能以较高的精度跟踪阶跃变化的 DO 浓度设定值.

由图 9(b) 可以看出, 受脉冲噪声干扰时, CSOFNN 仍能有效跟踪 DO 浓度的设定值, 且由图 10(b) 可以看出, 所有误差均分布在 $[-0.02,$



(a) CSOFNN 控制器
(a) CSOFNN controller



(b) 补偿控制器
(b) Compensation controller

图 7 阴雨工况 $K_{La,5}$ 变化曲线

Fig.7 Variations of $K_{La,5}$ in rain weather


表 1 恒定 S_0 时不同控制器的性能比较
Table 1 Performance comparisons of different controllers under constant S_0

干扰类型	控制器	规则数	IAE	ISE	Dev^{\max}
连续降雨	CSOFNN	4	2.1×10^{-3}	3.00×10^{-6}	7.44×10^{-3}
	CFNN ^[19]	6*	$3.2 \times 10^{-3*}$	$8.76 \times 10^{-6*}$	$7.56 \times 10^{-3*}$
	SOFC ^[12]	10*	$3.1 \times 10^{-2*}$	$7.26 \times 10^{-4*}$	$3.6 \times 10^{-2*}$
	SOFNN ^[20]	12*	$4.2 \times 10^{-2*}$	$1.81 \times 10^{-4*}$	$1.12 \times 10^{-2*}$
突发暴雨	CSOFNN	4	1.9×10^{-3}	1.44×10^{-6}	3.42×10^{-3}
	CFNN ^[19]	6*	$2.1 \times 10^{-3*}$	$1.75 \times 10^{-6*}$	$3.46 \times 10^{-3*}$
	SOFC ^[12]	9*	$2.5 \times 10^{-2*}$	$8.63 \times 10^{-4*}$	$9.7 \times 10^{-2*}$
	SOFNN ^[20]	12*	$6.0 \times 10^{-2*}$	$1.19 \times 10^{-3*}$	$8.22 \times 10^{-2*}$


注: * 表示原文中的结果, 粗体表示最好的结果.

0.02] 之间. 由图 8 和图 9 可以看出, 在设定值变化以及外部扰动幅度较大时 (如第 10 天和第 12 天), CSOFNN 控制器可以自动调整其结构以维持较高的控制性能.

为了测试 CSOFNN 控制方法在设定值变化以及存在非高斯噪声干扰时的性能, 将 CSOFNN 与



(a) 无噪声干扰
(a) Without noise




(b) 脉冲噪声干扰
(b) With impulse noise


图 8 变 S_o 下 CSOFNN 控制器规则变化曲线

Fig.8 Rules variations of CSOFNN controller under variable S_o

CFNN^[19]、SOFC^[15]、SOTSFNN^[20] 等控制方法进行对比, 具体结果如表 2 所示. 从表 2 可以看出, 在无噪声环境下, CSOFNN、CFNN、SOFC 等控制方法均能获得比 SOTSFNN 控制方法更高的 DO 浓度控制精度, 但是 SOFC 控制方法的规则数目最多. 与之相反, 基于相关熵准则的 CSOFNN 和 CFNN 控制器都具有更紧凑的结构和更高的控制精度, 其 IAE , ISE 与 Dev^{max} 值比 SOFC 和 SOTSFNN 控制方法降低了约 5%. 在有噪声环境下, 基于 SOTSFNN 控制方法的精度最低, 所需规则数目最多, 因此在设定值变化的阴雨工况下该方法适用性较差. 与其他方法相比, 基于 CSOFNN 的控制方法能够充分利用相关熵与补偿控制器抑制非高斯噪声, 补偿外部环境干扰引起的逼近误差, 因而能以较为紧凑的结构 (6 个规则) 获得更高的控制精度. 实验结果表明, 在设定值变化和有脉冲噪声时, 基于 CSOFNN 的控制方法具有较好的自适应性和稳定性, 在外部扰动较大时适用性更强.



(a) 无噪声干扰
(a) Without noise



(b) 脉冲噪声干扰
(b) With impulse noise

图 9 变 S_o 控制效果


Fig.9 Control performance of variable S_o

4 结束语

城市污水处理过程中存在强非线性、不确定性、非高斯等问题, 难以通过建立溶解氧浓度的精确数学模型实现其在线精准控制. 为了解决以上问题, 提出一种基于数据驱动的在线自组织控制方法, 控制系统由基于相关熵的自组织模糊神经网络 (CSOFNN) 控制器与补偿控制器组成. 通过实验与分析得到以下结论:

1) 设计了 CSOFNN 的自组织机制, 利用相关熵补偿与规则贡献度指标, 控制器能够根据在线数据自动增加或删减规则, 保证了控制器结构的紧凑性, 提高了控制器性能.

2) 设计了基于相关熵诱导准则的补偿控制器与参数自适应律, 补偿控制器能够降低 CSOFNN 的逼近误差, 利用相关熵准则抑制非高斯噪声提高了控制系统抑制外部干扰的能力, 提高了 DO 浓度的控制精度.

图 10 变 S_o 控制误差Fig. 10 Control errors of variable S_o 表 2 变 S_o 下不同控制器的性能比较Table 2 Performance comparisons of different controllers under variable S_o

干扰类型	控制器	规则数	IAE	ISE	Dev^{max}
降雨	CSOFNN	5	2.4×10^{-3}	1.67×10^{-4}	7.14×10^{-3}
	CFNN ^[10]	6*	$2.1 \times 10^{-3*}$	$2.34 \times 10^{-4*}$	$7.60 \times 10^{-3*}$
	SOFC ^[15]	14*	$2.2 \times 10^{-2*}$	$2.86 \times 10^{-4*}$	$3.5 \times 10^{-2*}$
	SOTSFNN ^[20]	9*	0.48*	$9.7 \times 10^{-4*}$	$1.0 \times 10^{-2*}$
降雨 + 脉冲噪声	CSOFNN	6	4.8×10^{-3}	3.41×10^{-4}	2.02×10^{-2}
	CFNN ^[10]	6	3.63×10^{-2}	1.11×10^{-3}	3.22×10^{-2}
	SOFC ^[15]	10	4.49×10^{-2}	9.97×10^{-4}	3.62×10^{-2}
	SOTSFNN ^[20]	20	1.33	2.47×10^{-2}	4.29×10^{-2}

注: * 表示原文中的结果, 粗体表示最好的结果.

3) 基于李雅普诺夫稳定原理证明了控制方法的稳定性, 保证 CSOFNN 控制方法在实际应用中的可行性. 实验结果表明, 在不同干扰的环境下, 所提出的 CSOFNN 控制方法比其他方法具有更好的

DO 浓度控制性能.

本文仅考虑了城市污水处理过程 DO 浓度的跟踪控制性能, 然而城市污水处理过程包含多个单元过程, 涉及多个重要控制变量且控制变量之间存在耦合. 因此, 下一步工作重点是考虑污水处理过程中多变量耦合特性, 将本文工作扩展到城市污水处理过程的多变量控制研究中.

References

- Deletic A, Wang H. Water pollution control for sustainable development. *Engineering*, 2019, **5**(5): 62–65
- 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)
- 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)
- Wei Wei, Chen Nan, Zuo Min, Liu Zai-Wen. Compound disturbance rejection control of dissolved oxygen concentration. *Control Theory and Applications*, 2020, **37**(9): 1895–1903
(魏伟, 陈楠, 左敏, 刘载文. 基于复合抗扰的溶解氧浓度控制. *控制理论与应用*, 2020, **37**(9): 1895–1903)
- Meng Xi, Qiao Jun-Fei, Han Hong-Gui. Soft measurement of key effluent parameters in wastewater treatment process using brain-like modular neural networks. *Acta Automatica Sinica*, 2019, **45**(5): 906–919
(蒙西, 乔俊飞, 韩红桂. 基于类脑模块化神经网络的污水处理过程关键出水参数软测量. *自动化学报*, 2019, **45**(5): 906–919)
- Santín I, Barbu M, Pedret C, Vilanova R. Dissolved oxygen control in biological wastewater treatments with non-ideal sensors and actuators. *Industrial and Engineering Chemistry Research*, 2019, **58**(45): 20639–20654
- van Waarde H J, Eising J, Trentelman H L, Camlibel M K. Data informativity: A new perspective on data-driven analysis and control. *IEEE Transactions on Automatic Control*, 2020, **65**(11): 4753–4768
- Ding Y S, Xu N, Ren L H, Hao K R. Data-driven neuroendocrine ultrashort feedback-based cooperative control system. *IEEE Transactions on Control Systems Technology*, 2015, **23**: 1205–1212
- Belchior C A C, Rui A M A, Landeck J A C. Dissolved oxygen control of the activated sludge wastewater treatment process using stable adaptive fuzzy control. *Computers and Chemical Engineering*, 2012, **37**: 152–162
- Zhang Wei, Qiao Jun-Fei, Li Fun-Jun. Direct adaptive dynamic neural network control for dissolved oxygen concentration. *Control Theory and Applications*, 2015, **32**(1): 115–121
(张伟, 乔俊飞, 李凡军. 溶解氧浓度的直接自适应动态神经网络控制方法. *控制理论与应用*, 2015, **32**(1): 115–121)
- Wang D, Ha M M, Qiao J F. Data-driven iterative adaptive critic control towards an urban wastewater treatment plant. *IEEE Transactions on Industrial Electronics*, 2021, **68**(8): 7362–7369
- Ruan J, Zhang C, Li Y, Yang Z, Chen X, Huang M, et al. Improving the efficiency of dissolved oxygen control using an on-line control system based on a genetic algorithm evolving FWNN software sensor. *Journal of Environmental Management*, 2017, **187**: 550–559

- 13 Eltag K, Aslamx M S, Ullah R. Dynamic stability enhancement using fuzzy PID control technology for power system. *International Journal of Control, Automation and Systems*, 2019, **17**: 234–242
- 14 Zhang Shuai, Zhou Ping. Recursive bilinear subspace modeling and model-free adaptive control of wastewater treatment. *Acta Automatica Sinica*, 2022, **48**(7): 1747–1759
(张帅, 周平. 污水处理过程递推双线性子空间建模及无模型自适应控制. *自动化学报*, 2022, **48**(7): 1747–1759)
- 15 Qiao J F, Zhang W, Han H G. Self-organizing fuzzy control for dissolved oxygen concentration using fuzzy neural network. *Journal of Intelligent and Fuzzy Systems*, 2016, **30**(6): 3411–3422
- 16 Han Guang, Qiao Jun-Fei, Bo Ying-Chun. Feedforward neural network modeling and control for dissolved oxygen concentration. *Control Theory and Applications*, 2013, **30**(5): 585–591
(韩广, 乔俊飞, 薄迎春. 溶解氧浓度的前馈神经网络建模控制方法. *控制理论与应用*, 2013, **30**(5): 585–591)
- 17 Lin M J, Luo F. An adaptive control method for the dissolved oxygen concentration in wastewater treatment plants. *Neural Computing and Applications*, 2015, **26**(8): 2027–2037
- 18 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
- 19 Quan Li-Min, Yang Cui-Li, Qiao Jun-Fei. CFNN-based online control for dissolved oxygen concentration of wastewater treatment processes. *Chinese Journal of Intelligent Science and Technology*, 2020, **2**(3): 261–267
(权利敏, 杨翠丽, 乔俊飞. 基于 CFNN 的污水处理过程溶解氧浓度在线控制. *智能科学与技术学报*, 2020, **2**(3): 261–267)
- 20 Qiao Jun-Fei, Fu Wen-Tao, Han Hong-Gui. Dissolved oxygen control method based on self-organizing T-S fuzzy neural network. *CIESC Journal*, 2016, **67**(3): 960–966
(乔俊飞, 付文韬, 韩红桂. 基于 SOTSFN 的溶解氧浓度控制方法. *化工学报*, 2016, **67**(3): 960–966)
- 21 Zhou Hong-Biao. Dissolved oxygen control of wastewater treatment process using self-organizing fuzzy neural network. *CIESC Journal*, 2017, **68**(4): 1516–1524
(周红标. 基于自组织模糊神经网络的污水处理过程溶解氧控制. *化工学报*, 2017, **68**(4): 1516–1524)
- 22 Chen B, Liu X, Zhao H, Principe J C. Maximum correntropy Kalman filter. *Automatica*, 2017, **76**: 70–77
- 23 Yu J. A nonlinear kernel Gaussian mixture model based inferential monitoring approach for fault detection and diagnosis of chemical processes. *Chemical Engineering Science*, 2012, **68**: 506–519
- 24 Liu W, Pokharel P P, Principe J C. Correntropy: Properties and applications in non-Gaussian signal processing. *IEEE Transactions on Signal Processing*, 2007, **55**(11): 5286–5298
- 25 Bao R J, Rong H J, Angelov P, Chen B D, Wong P K. Correntropy-based evolving fuzzy neural system. *IEEE Transactions on Fuzzy Systems*, 2018, **26**: 1324–1338
- 26 Cao J W, Dai H Z, Lei B Y, Yin C, Zeng H Q, Kummert A. Maximum correntropy criterion-based hierarchical one-class classification. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, **32**(8): 3748–3754
- 27 Nayyeri M, Yazdi H S, Maskooki A, Rouhani M. Universal approximation by using the correntropy objective function. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, **29**(9): 4515–4521
- 28 Ren M, Gong M, Lin M, Zhang J. Generalized correntropy predictive control for waste heat recovery systems based on organic rankine cycle. *IEEE Access*, 2019, **7**: 151587–151594
- 29 Jeppsson U, Pons M N. The COST benchmark simulation model current state and future perspective. *Control Engineering Practice*, 2004, **12**(3): 299–304
- 30 Chen C S. Robust self-organizing neural-fuzzy control with uncertainty observer for MIMO nonlinear systems. *IEEE Transactions on Fuzzy Systems*, 2011, **19**(4): 694–706
- 31 Sun M A. Barbalat-like lemma with its application to learning control. *IEEE Transactions on Automatic Control*, 2009, **54**: 2222–2225



权利敏 北京工业大学信息学部博士研究生, 青岛理工大学信息与控制工程学院讲师。主要研究方向为数据驱动建模与控制, 城市污水处理过程智能控制, 神经网络结构优化设计。

E-mail: quanlimin12@sina.com

(**QUAN Li-Min** Ph.D. candidate at

the Faculty of Information Technology, Beijing University of Technology, and lecturer at the School of Information and Control Engineering, Qingdao University of Technology. Her research interest covers data-driven modeling and control, intelligent control of urban wastewater treatment process, and structure design and optimization of neural networks.)



杨翠丽 北京工业大学信息学部副教授。主要研究方向为神经网络和智能优化算法。

E-mail: clyang5@bjut.edu.cn

(**YANG Cui-Li** Associate professor at the Faculty of Information Technology, Beijing University of

Technology. Her research interest covers neural network and intelligent optimization algorithm.)



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控制, 神经网络结构设计与分析。本文通信作者。

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 control of urban wastewater treatment process, structure design and analysis for neural networks. Corresponding author of this paper.)