

控制与决策

Control and Decision

基于自适应鲁棒模糊神经网络的MBR膜透水率软测量

张祎邢, 刘峥, 韩红桂

引用本文:

张祎邢, 刘峥, 韩红桂. 基于自适应鲁棒模糊神经网络的MBR膜透水率软测量[J]. *控制与决策*, 2025, 40(2): 665-674.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.1591>

您可能感兴趣的其他文章

Articles you may be interested in

[航天器输入受限的鲁棒自适应姿态跟踪控制](#)

Robust adaptive attitude tracking control of spacecraft with constrained inputs
控制与决策. 2021, 36(9): 2297-2304 <https://doi.org/10.13195/j.kzyjc.2020.0013>

[磁悬浮开关磁阻电机的自适应终端滑模控制](#)

Adaptive terminal sliding mode control of bearingless switched reluctance motor
控制与决策. 2021, 36(6): 1449-1456 <https://doi.org/10.13195/j.kzyjc.2019.1064>

[基于神经网络的电力系统暂态稳定分布式自适应控制](#)

Neural network-based distributed adaptive control for power system transient stability
控制与决策. 2021, 36(6): 1407-1414 <https://doi.org/10.13195/j.kzyjc.2019.1168>

[面向工业软测量应用的定制化生成对抗数据填补模型](#)

Customized generative adversarial data imputation model for industrial soft sensing
控制与决策. 2021, 36(12): 2929-2936 <https://doi.org/10.13195/j.kzyjc.2020.0974>

[复杂背景下全景视频运动小目标检测算法](#)

Panoramic video motion small target detection algorithm in complex background
控制与决策. 2021, 36(1): 249-256 <https://doi.org/10.13195/j.kzyjc.2019.0686>

基于自适应鲁棒模糊神经网络的 MBR 膜透水率软测量

张祎邢^{1,2}, 刘 峥^{1,2†}, 韩红桂^{1,2}

(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)

摘要: 针对膜生物反应器 (MBR) 污水处理工艺易受到进水水量、水质波动等外部干扰因素的影响导致膜透水率难以准确测量的问题, 提出一种基于自适应鲁棒模糊神经网络 (ARFNN) 的膜透水率软测量模型. 首先, 构建一种对称抗噪损失函数, 降低了模型对外部干扰的敏感度, 提高了软测量模型的鲁棒性; 然后, 设计一种自适应梯度下降算法, 动态优化模型参数, 提升了软测量模型的检测精度; 最后, 利用李雅普诺夫函数验证了 ARFNN 的收敛性, 分析了模型的鲁棒性, 保证了模型的收敛速度和抗干扰能力. 将所设计的基于 ARFNN 的膜透水率软测量模型应用于实际的污水处理过程中, 实验结果表明, 在有外部干扰的情况下, 该模型不但能够实现膜透水率的在线检测, 而且可以获得较高的检测精度.

关键词: 模糊神经网络; 膜生物反应器; 膜透水率; 鲁棒性; 软测量; 梯度下降

中图分类号: TP181 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2023.1591

引用格式: 张祎邢, 刘峥, 韩红桂. 基于自适应鲁棒模糊神经网络的 MBR 膜透水率软测量 [J]. 控制与决策, 2025, 40(2): 665-674.

Soft-sensor method for permeability of membrane bio-reactor based on adaptive robust fuzzy neural network

ZHANG Yi-xing^{1,2}, LIU Zheng^{1,2†}, HAN Hong-gui^{1,2}

(1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China; 2. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing 100124, China)

Abstract: Aiming at the problem that the membrane bio-reactor(MBR) wastewater treatment process is susceptible to the influence of external disturbances such as influent water quantity and water quality fluctuations, which makes it difficult to accurately measure the membrane permeability, a soft-sensor method for permeability of membrane based on an adaptive robust fuzzy neural network(ARFNN) is proposed. Firstly, a symmetric anti-noise loss function is constructed to reduce the sensitivity of the model to external interference and improve the robustness of the soft measurement model. Then, an adaptive gradient descent algorithm is designed to dynamically optimize the model parameters and improve the detection accuracy of the soft measurement model. Finally, the convergence of the ARFNN is verified using the Lyapunov function to analyze the model's robustness, which ensures the model's convergence speed and anti-interference ability. The designed ARFNN-based membrane permeability soft-sensor method is applied to the actual wastewater treatment process, and the experimental results show that the model can not only realize the online detection of membrane permeability, but also obtain high detection accuracy under the condition of external interference.

Keywords: fuzzy neural network; membrane bio-reactor; permeability; robustness; soft-sensor; gradient descent

0 引言

在城市污水处理过程中, 膜生物反应器 (membrane bio-reactor, MBR) 是一种微滤膜工艺与生物废水处理工艺相结合的新型高效污水处理技术^[1], 具有占地

面积小、出水水质良好稳定、无污泥沉降性问题、易于实现自动化控制等优点^[2-3], 已广泛应用于城市污水处理过程中. 然而, 由于污水处理过程中的微粒、胶体粒子或溶质大分子与膜之间存在物理、化学以

收稿日期: 2023-11-14; 录用日期: 2024-04-16.

基金项目: 国家自然科学基金项目 (62125301, 62021003, 62303024); 国家重点研发计划项目 (2022YFB3305800-5); 中国博士后科学基金项目 (2022M720319); 北京市自然科学基金项目 (KZ202110005009); 青年北京学者基金项目 (037); 北京市博士后工作经费资助项目 (2023-zz-91).

责任编辑: 姜斌.

†通讯作者. E-mail: liuzheng@bjut.edu.cn.

及机械等作用,使得膜孔径逐渐变小或发生堵塞,导致膜污染现象的发生^[4-6]。因此,如何实现正确预测膜透水率,进而对膜进行及时的清洗和维护,降低膜污染的发生频率,提高膜的使用周期和使用效率^[7-8],是 MBR 污水处理过程中亟需解决的重大挑战^[9-10]。

膜污染程度与膜透水率的大小有关,在实际应用中可通过预测膜透水率的大小来分析膜污染状况。由于膜透水率难以直接检测,专家学者们研究了基于机理分析的膜透水率检测方法^[11-13]。例如, Wang 等^[14]设计了一种基于动力学特性的膜透水率检测方法,该方法利用动力学方程建立了可溶性微生物浓度与膜透水率之间的关系,实现了膜透水率的准确检测。Zheng 等^[15]提出了一种基于机理分析的膜透水率检测方法,该方法分析了溶解氧浓度、跨膜压差等因素与膜透水率之间的关系,实现了膜透水率的有效检测。此外,基于数学模型的膜透水率检测方法受到了专家学者们的青睐^[16-18]。例如, Lindamulla 等^[19]提出了一种基于数学模型的膜透水率检测方法,建立污水处理过程变量和膜透水率之间的关系,实验结果验证了该方法能够实现膜透水率的检测。Huang 等^[20]提出了一种基于敏感参数模型的膜透水率检测方法,建立了出水化学需氧量浓度、氨氮浓度与膜透水率之间关系的表达,结果表明,该方法能够提高膜透水率的检测精度。虽然基于数学模型的检测方法可以检测膜透水率,但由于膜污染是一个复杂的动态过程,影响膜污染因素具有多样性和耦合性,利用数学关系难以直接精确描述膜透水率的变化规律。因此,如何及时精准检测膜透水率,实现对膜污染的有效判断成为专家学者们研究的焦点问题。

随着城市污水处理过程中数据采集技术的不断发展,基于数据驱动的在线膜透水率软测量方法得到了广泛的研究^[21-23]。其中,神经网络作为一种典型数据驱动方法,已广泛应用于膜透水率检测领域中。例如, Wang 等^[24]构建了一种基于反向传播神经网络(back propagation, BP)的膜透水率软测量模型,该模型能够实现膜透水率的实时检测。Yang 等^[25]提出了一种基于 RBFNN(radial basis function neural network)的膜透水率软测量模型,提高了膜透水率检测精度,实验结果显示,该模型能够有效提高检测精度。上述研究方法能够实时检测膜透水率,但由于污水处理过程中不可避免地存在外部干扰因素,在应用过程中具有鲁棒性差、检测精度较低等问题。为了进一步提高膜透水率的检测精度,许多学者采用具有推理能力和抗噪能力的模糊神经网络为载体,完成膜透水率的在线检测^[26-28]。例如, Hosseinzadeh 等^[29]提出了一种基于自适应网络的模糊推理系统

(adaptive network-based fuzzy inference system, ANFIS)的膜透水率软测量模型,建立了电导率、溶解氧浓度与膜透水率之间的关系,实验结果显示,该模型能够实现膜透水率的实时检测,具有较好的检测精度。Wu 等^[30]提出了一种基于递归模糊神经网络(recurrent fuzzy neural network, RFNN)的膜透水率软测量模型,通过设计递归层形式的记忆单元来存储动态系统的先前特征,进行实时膜透水率检测,实验结果表明,该模型具有较高的膜透水率检测精度。虽然上述基于模糊神经网络的检测模型能够提高膜透水率的检测精度,但由于城市污水处理过程中入水水质的显著波动和众多干扰因素,导致在数据采集过程中存在大量的噪声,从而对模型性能产生负面影响。因此,如何有效提高模糊神经网络的抗噪能力,仍是膜透水率检测亟待解决的难题。

为了解决上述难题,本文提出一种基于自适应鲁棒模糊神经网络(adaptive robust fuzzy neural network, ARFNN)的膜透水率软测量模型,设计一种基于对称抗噪的鲁棒损失函数,提出一种基于自适应梯度下降的参数更新方法,降低了非线性系统中外部噪声对膜透水率软测量方法的影响。本文的主要工作如下。

1) 构造一种对称抗噪损失函数,通过计算模型输出真实值与预测值的数值以及概率分布差异,从整体上考虑了噪声对模型的影响,提高了模型的抗噪能力,降低了模型学习过程中对外部噪声干扰的敏感性,获得更好的鲁棒性。

2) 提出一种基于自适应梯度下降的参数更新方法,优化模型的中心值、宽度值、权值以及学习率,提高了模糊神经网络的参数更新效率和收敛速度,保证了膜透水率的检测性能,为膜污染的有效识别奠定基础。

3) 从理论方面分析 ARFNN 的收敛性和鲁棒性,并进行实验验证,结果表明所提出的 ARFNN 能够成功应用于城市污水处理过程膜污染检测。

1 膜透水率软测量模型

软测量模型是一种利用计算机技术构建易于测量的变量与难以测量或不便测量的关键变量之间关系的方法,从而实现了对关键变量的在线估计。本文通过应用软测量模型,对于污水处理过程中的膜透水率的检测效率,其设计主要包括数据采集与预处理、辅助变量的选择以及软测量模型的建立,其步骤如图 1 所示。

1) 数据采集与预处理

在城市污水处理过程膜透水率软测量模型设计

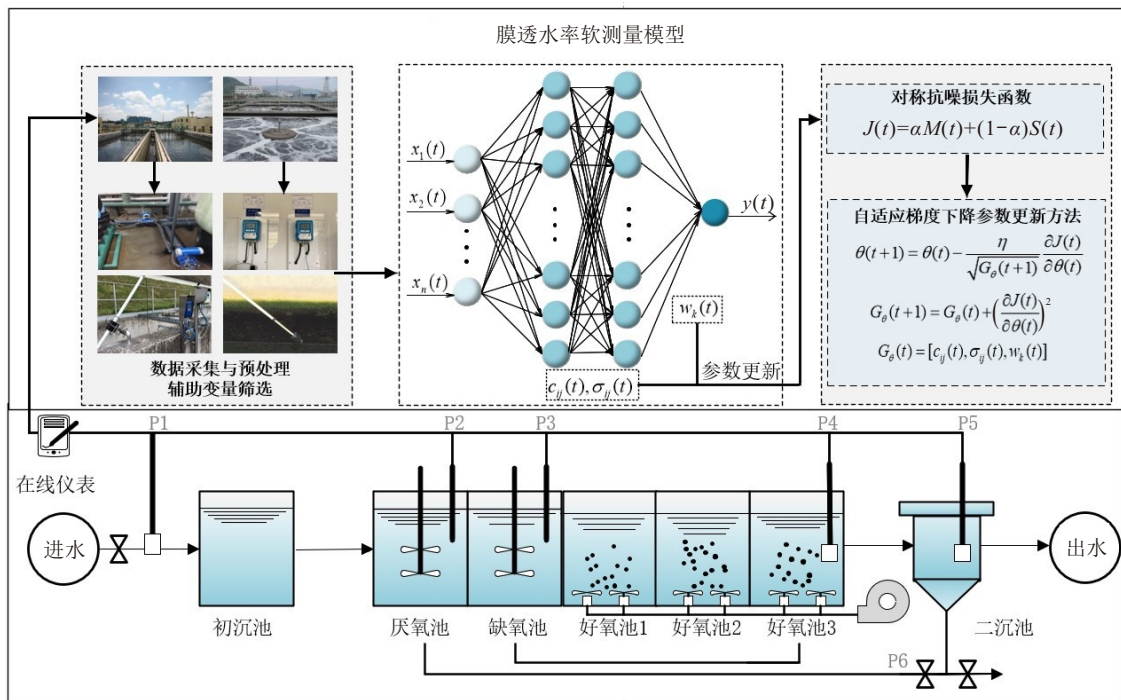


图1 膜透水性软测量模型

中, 硬件平台的搭建是保证数据采集和处理的重要环节, 也是实现膜透水率准确检测的关键. 在城市污水处理厂中控室加装一台上位机协助进行数据采集与处理, 该电脑运行于 Windows 10 系统, 系统支持酷睿 3.60 GHz CPU、8 GRAM 以及 MATLAB R2021a 版本, 用于收集初沉池、厌氧区、缺氧区、好氧区以及二沉池的数据, 以实现城市污水处理过程中各项参数的实时数据采集, 为后续的软测量模型建立提供重要的数据基础. 在进行数据采集的过程中, 为保证软测量模型的准确性和可靠性, 需对数据进行归一化处理.

2) 辅助变量的选择.

辅助变量的选择是软测量模型设计过程中重要组成部分, 辅助变量的选择决定了模型的输入输出关系以及能否准确推断主导变量. 本文在对膜透水率的研究中, 污水处理过程中可供采集的过程变量有 9 个, 分别为进水氨氮、好氧区溶解氧、厌氧区氧化还原电位、产水压力、单池膜擦洗气量、pH 值、水温、产水流量和跨膜压差. 通过采用偏最小二乘法 (partial least squares, PLS) 对数据进行分析, 实现对高维变量空间的降维处理, 在保证过程变量数据空间变化信息的同时, 尽可能简化模型的输入, 提高模型的计算效率与精度. 本文选取进水氨氮、产水压力、产水流量、跨膜压差、厌氧区氧化还原电位 5 个过程变量作为软测量模型输入.

3) 软测量模型建立.

利用城市污水处理厂的实测数据建立膜透水率

软测量模型, 并进行实际应用. 本文提出一种 ARFNN 的膜透水率软测量模型, 其输入为进水氨氮, 产水压力、产水流量、跨膜压差、厌氧区氧化还原电位, 输出为膜透水率.

2 膜透水性软测量模型设计

为了有效提高膜透水率的检测精度, 本文提出一种基于自适应鲁棒模糊神经网络的膜透水率软测量模型, 该模型中包含一种对称抗噪损失函数, 利用自适应梯度下降更新方法对模型的参数进行更新, 以保证膜透水率的检测性能.

2.1 对称抗噪损失函数

损失函数是模型优化和训练中的核心部分. 本文提出一种对称抗噪损失函数, 该损失函数旨在平衡噪声对训练过程的影响.

定义对称抗噪损失函数

$$J(t) = \alpha M(t) + (1 - \alpha)S(t). \quad (1)$$

其中: α 为自适应权重因子, 取值在 0 ~ 1 之间; $M(t)$ 和 $S(t)$ 可表示为

$$M(t) = \frac{1}{n} \sum_{i=1}^n |y_{pi}(t) - y_i(t)|, \quad (2)$$

$$S(t) = \frac{\sum p(t) \log \frac{p(t)}{q(t)} + \sum q(t) \log \frac{q(t)}{p(t)}}{2}. \quad (3)$$

其中: $M(t)$ 反映了模型输出预测值与真实值之间的数值分布差异, 衡量了模型对单个样本的拟合精度. 当存在噪声时, 模型的预测值可能受到随机扰动, 从

而导致 $M(t)$ 增大. 因此, $M(t)$ 能够间接体现由噪声引起的单个样本的影响. $S(t)$ 则通过计算模型输出真实值与预测值的概率分布差异, 从整体上考虑噪声对模型的影响. $S(t)$ 通过使用对数函数计算交叉熵的形式, 在对比两者的分布情况的同时, 将真实值和预测值分布差异的相对概率转化为对数差, 既降低了计算负担, 也更全面地反映了模型在整个样本集上的性能, 进一步强调了模型对外部噪声的适应能力. 在 $M(t)$ 和 $S(t)$ 中, n 表示样本总数; $y_{pi}(t)$ 表示膜透水率预测输出值; $y_i(t)$ 表示膜透水率真实值; $p(t)$ 表示 t 时刻样本的真实值与总样本数的重合率; $q(t)$ 表示 t 时刻样本的预测值占总样本数的重合率; 第 i 个样本的预测值 $y_{pi}(t)$ 是基于模糊神经网络的膜透水率软测量模型的输出值, 其计算式可表示为

$$y_{pi}(t) = w(t)v_j(t). \quad (4)$$

其中: $w(t)$ 表示 t 时刻输出层与归一层间的连接权值; $v_j(t)$ 表示归一化层第 $j(j = 1, 2, \dots, n)$ 个神经元 t 时刻的输出值, 其计算式可表示为

$$v_j(t) = \frac{\phi_j(t)}{\sum_{j=1}^n \phi_j(t)} = \frac{e^{-\sum_{j=1}^n \frac{(u_i(t)-c_{ij}(t))^2}{2\sigma_{ij}^2(t)}}}{\sum_{j=1}^n e^{-\sum_{j=1}^n \frac{(u_i(t)-c_{ij}(t))^2}{2\sigma_{ij}^2(t)}}}. \quad (5)$$

其中: $\phi_j(t)$ 表示径向基函数层第 $j(j = 1, 2, \dots, n)$ 个神经元的 t 时刻输出值, 其计算式可表示为

$$\phi_j(t) = \prod_{i=1}^n e^{-\frac{(u_i(t)-c_{ij}(t))^2}{2\sigma_{ij}^2(t)}} = e^{-\sum_{i=1}^n \frac{(u_i(t)-c_{ij}(t))^2}{2\sigma_{ij}^2(t)}}. \quad (6)$$

其中: $c_{ij}(t)$ 表示 t 时刻第 j 个神经元的第 i 个隶属度函数的中心值, $c_j(t) = [c_{1j}(t), c_{2j}(t), \dots, c_{nj}(t)]$ 表示 t 时刻第 j 个神经元的中心向量; $\sigma_{ij}(t)$ 表示 t 时刻第 j 个神经元的第 i 个隶属度函数的宽度值, $\sigma_j(t) = [\sigma_{1j}(t), \sigma_{2j}(t), \dots, \sigma_{nj}(t)]$ 表示 t 时刻第 j 个神经元的宽度向量; $u_i(t)$ 表示第 i 个神经元的 t 时刻输出值, 其计算式可表示为

$$u_i(t) = x_i(t), \quad i = 1, 2, \dots, 5, \quad (7)$$

其中 $x_i(t)$ 表示 t 时刻网络输入值. 与传统的损失函数相比, 对称抗噪损失函数的设计目的在于更有效地抑制噪声对模型的干扰, 从而提高模型的鲁棒性, 同时保持模型性能的稳定.

2.2 自适应梯度下降参数更新方法

为了使膜透水率软测量模型具有更快的收敛速度, 本文设计一种自适应梯度下降参数更新方法, 实现对 ARFNN 神经网络中心值、宽度值和权值进行在线调整, 图 2 介绍了自适应梯度下降参数更新方

法的流程.

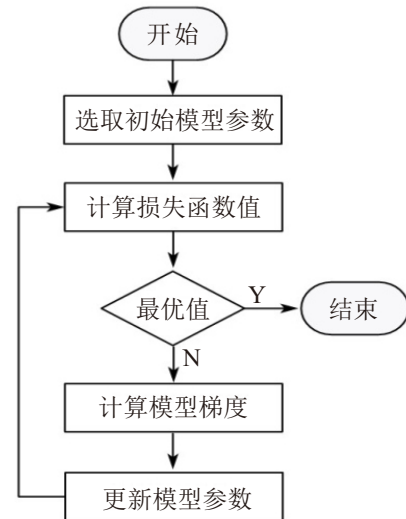


图2 自适应梯度下降参数更新方法流程图

自适应梯度下降参数更新方法对软测量模型的中心值、宽度值和权值进行训练, 即

$$c_{ij}(t+1) = c_{ij}(t) - \eta_c \frac{\partial J(t)}{\partial c_{ij}(t)}, \quad (8)$$

$$\sigma_{ij}(t+1) = \sigma_{ij}(t) - \eta_\sigma \frac{\partial J(t)}{\partial \sigma_{ij}(t)}, \quad (9)$$

$$w_{k+1}(t+1) = w_k(t) - \eta_w \frac{\partial J(t)}{\partial w_k(t)}. \quad (10)$$

其中: $c_{ij}(t)$ 为 ARFNN 神经网络的中心值, $\sigma_{ij}(t)$ 为 ARFNN 神经网络中心值的宽度值, $w_k(t)$ 为 ARFNN 神经网络的权重. 采用迭代更新方法对 ARFNN 中心值、宽度值和权重的学习率 $\eta_c(t)$, $\eta_\sigma(t)$, $\eta_w(t)$ 进行更新, 可表示为

$$\eta_c(t) = \eta_0 \frac{1}{\sqrt{G_c(t+1)}}, \quad (11)$$

$$\eta_\sigma(t) = \eta_0 \frac{1}{\sqrt{G_\sigma(t+1)}}, \quad (12)$$

$$\eta_w(t) = \eta_0 \frac{1}{\sqrt{G_w(t+1)}}, \quad (13)$$

其中 $G(t)$ 表示累计平方梯度, 即参数更新的累计和, 指参数在当前迭代次数之前的所有梯度的平方之和. 对于在 $t+1$ 时刻 $G(t)$ 的输出值 $G(t+1)$ 的计算式可表示为

$$G_c(t+1) = G_c(t) + \left(\frac{\partial J(t)}{\partial c_{ij}(t)} \right)^2, \quad (14)$$

$$G_\sigma(t+1) = G_\sigma(t) + \left(\frac{\partial J(t)}{\partial \sigma_{ij}(t)} \right)^2, \quad (15)$$

$$G_w(t+1) = G_w(t) + \left(\frac{\partial J(t)}{\partial w_k(t)} \right)^2. \quad (16)$$

梯度的计算式可表示为

$$\frac{\partial J(t)}{\partial c_{ij}(t)} = -\frac{e(t)\left(x_i(t) - c_{ij}(t) \sum_{k=1}^n w_k(t)v_k(t)\right)}{\sigma_{ij}^2(t)}, \quad (17)$$

$$\frac{\partial J(t)}{\partial \sigma_{ij}(t)} = -\frac{e(t) \sum_{k=1}^n w_k(t)v_k(t)}{\sigma_{ij}^3(t)}, \quad (18)$$

$$\frac{\partial J(t)}{\partial w_k(t)} = -e(t)v_k(t). \quad (19)$$

其中 $e(t)$ 表示透水率测量误差, 计算式可表示为

$$e(t) = y_{pi}(t) - y_i(t). \quad (20)$$

根据以上分析, 基于 ARFNN 的膜透水率软测量模型计算过程可归纳为:

1) 初始化基于 ARFNN 软测量模型的输入层、隐含层、输出层神经元数量, 分别设为 5, 10, 1; 对于神经网络的中心值、宽度值和权值, 进行 0~1 之间的随机赋值; 设置更新神经网络中心值、宽度值、权值的初始学习率 η_0 为 0.3; 设置自适应权重因子为 0.7.

2) 根据式 (1) ~ (7), 计算膜透水率软测量模型输出值.

3) 利用式 (8) ~ (20) 对模型参数进行更新.

3 理论证明

3.1 收敛性证明

收敛性证明对于模型能否成功应用起到了至关重要的作用, 本小节详细地分析了 ARFNN 的收敛性, 其李雅普诺夫函数可表示为

$$V(t) = \frac{1}{2}e^2(t), \quad (21)$$

其中 $e(t) = y_{pi}(t) - y_i(t)$ 是 t 时刻 ARFNN 的误差. 李雅普诺夫函数 $V(t)$ 的改变量可表示为

$$\begin{aligned} \Delta V(t) &= V(t+1) - V(t) = \\ &= \frac{1}{2}((e(t) + \Delta e(t))^2 - e^2(t)). \end{aligned} \quad (22)$$

ARFNN 的误差改变量可表示为

$$\Delta e(t) = e(t+1) - e(t) = \left[\frac{\partial e(t)}{\partial \theta(t)}\right]^T \Delta \theta(t) + O(t). \quad (23)$$

其中: $O(t)$ 为泰勒级数展开项的最高项; $\theta(t)$ 表示模型参数的变化量, 可表示为

$$\theta(t) = [c_{ij}(t), \sigma_{ij}(t), w_k(t)]^T. \quad (24)$$

$\partial O(t)/\partial \theta(t)$ 表示误差关于参数的梯度, 可表示为

$$\frac{\partial e(t)}{\partial \theta(t)} = \left[\frac{\partial e(t)}{\partial c_{ij}(t)}, \frac{\partial e(t)}{\partial \sigma_{ij}(t)}, \frac{\partial e(t)}{\partial w_k(t)}\right]^T. \quad (25)$$

假设 1 泰勒级数展开式的高次项 $O(t)$ 约束可表示为

$$\begin{aligned} & - \left[1 - \frac{\rho^T(t)\eta(t)\rho(t)}{2}\right]e(t) - A(t) < O(t) < \\ & - \left[1 - \frac{\rho^T(t)\eta(t)\rho(t)}{2}\right]e(t) + A(t). \end{aligned} \quad (26)$$

其中, $\eta(t)$ 为神经网络参数的学习率, 可表示为

$$\eta(t) = \begin{bmatrix} \eta_c(t) & 0 & 0 \\ 0 & \eta_\sigma(t) & 0 \\ 0 & 0 & \eta_w(t) \end{bmatrix}; \quad (27)$$

$\rho(t)$ 为模型输出对参数的梯度, 可表示为

$$\rho(t) = \frac{\partial y(t)}{\partial \theta(t)}; \quad (28)$$

$A(t)$ 为在时间 t 时的一个值, 可表示为

$$\begin{aligned} A(t) &= \\ &= \sqrt{\left[1 - \frac{\rho^T(t)\eta(t)\rho(t)}{2}\right]^2 e^2(t) + \rho^T(t)\eta(t)\rho(t)e^2(t)}. \end{aligned} \quad (29)$$

定理 1 如果假设 1 成立, 则模型参数学习率满足

$$0 < \eta_c(t) < \frac{1}{3}\nu_{c,\max}, \quad (30)$$

$$0 < \eta_\sigma(t) < \frac{1}{3}\nu_{\sigma,\max}, \quad (31)$$

$$0 < \eta_w(t) < \frac{1}{3}\nu_{w,\max}. \quad (32)$$

其中: 若满足

$$\begin{aligned} \nu_{\max} &= [\nu_{c,\max}, \nu_{\sigma,\max}, \nu_{w,\max}]^T = \\ &= \left[\max_t \left\| \frac{\partial y(t)}{\partial c_{ij}(t)} \right\|^2, \max_t \left\| \frac{\partial y(t)}{\partial \sigma_{ij}(t)} \right\|^2, \max_t \left\| \frac{\partial y(t)}{\partial w_k(t)} \right\|^2\right]^T, \end{aligned} \quad (33)$$

则当 $t \rightarrow \infty$ 时, $e(t) = 0$, ARFNN 收敛.

证明 由式 (21) 可得

$$V(t) > 0. \quad (34)$$

李雅普诺夫函数 $V(t)$ 的改变量可表示为

$$\Delta V(t) = e(t)\Delta e(t) + \frac{1}{2}\Delta e^2(t). \quad (35)$$

根据式 (8) ~ (16), 将式 (23) 代入 (35) 可得

$$\begin{aligned} \Delta V(t) &= \\ &= \frac{1}{2} \left\{ \left[e(t) + \left(\frac{\partial e(t)}{\partial \theta(t)} \right)^T \Delta \theta(t) + O(t) \right]^2 - e^2(t) \right\}. \end{aligned} \quad (36)$$

展开并化简式 (36) 可得

$$\begin{aligned} \Delta V(t) &= \\ &= \frac{1}{2} \left\{ 2e(t) \left[\left(\frac{\partial e(t)}{\partial \theta(t)} \right)^T \Delta \theta(t) + O(t) \right] + \right. \end{aligned}$$

$$\begin{aligned}
& e^2(t) + \left[\left(\frac{\partial e(t)}{\partial \theta(t)} \right)^T \Delta \theta(t) + O(t) \right]^2 - e^2(t) \} = \\
& e(t) \left[\left(\frac{\partial e(t)}{\partial \theta(t)} \right)^T \Delta \theta(t) + O(t) \right] + \\
& \frac{1}{2} \left[\left(\frac{\partial e(t)}{\partial \theta(t)} \right)^T \Delta \theta(t) + O(t) \right]^2, \quad (37)
\end{aligned}$$

进一步简化可得

$$\begin{aligned}
& \Delta V(t) = \\
& [-\rho^T(t)\eta(t)\rho(t)e(t) + O(t)] \times \\
& \left[e(t) - \frac{1}{2}\rho^T(t)\eta(t)\rho(t)e(t) + \frac{1}{2}O(t) \right] = \\
& -\rho^T(t)\eta(t)\rho(t)e^2(t) \left[1 - \frac{1}{2}\rho^T(t)\eta(t)\rho(t) \right] + \\
& O(t)e(t) \left[1 - \frac{1}{2}\rho^T(t)\eta(t)\rho(t) \right] + \frac{1}{2}O^2(t). \quad (38)
\end{aligned}$$

假设 $\rho(t) = 0$ 为时间 t 下的导数, 表示为

$$\begin{aligned}
& \rho^T(t)\eta(t)\rho(t) = \\
& \rho_c(t)\eta_c(t)\rho_c(t) + \rho_\sigma(t)\eta_\sigma(t)\rho_\sigma(t) + \rho_w(t)\eta_w(t)\rho_w(t), \quad (39)
\end{aligned}$$

如果参数学习率满足式 (30) ~ (32), 则有

$$0 < \rho^T(t)\eta(t)\rho(t) < 1. \quad (40)$$

若假设 1 成立, 则有

$$\begin{aligned}
& \Delta V(t) < \\
& -\frac{1}{2}\rho^T(t)\eta(t)\rho(t)e^2(t) \left[1 - \frac{1}{2}\rho^T(t)\eta(t)\rho(t) \right] + \\
& O(t)e(t) \left[1 - \frac{1}{2}\rho^T(t)\eta(t)\rho(t) \right] + \frac{1}{2}O^2(t) < \\
& -\frac{1}{2}\rho^T(t)\eta(t)\rho(t)e^2(t) + \\
& \frac{1}{2} \left\{ A(t) - \left[1 - \frac{1}{2}\rho^T(t)\eta(t)\rho(t) \right] e(t) \right\} \times \\
& \left\{ A(t) + \left[1 - \frac{1}{2}\rho^T(t)\eta(t)\rho(t) \right] e(t) \right\} = \\
& -\frac{1}{2}\rho^T(t)\eta(t)\rho(t)e^2(t) + \\
& \frac{1}{2} \left[1 - \frac{1}{2}\rho^T(t)\eta(t)\rho(t) \right]^2 e^2(t) + \frac{1}{2}A^2(t) = \\
& -\frac{1}{2}\rho^T(t)\eta(t)\rho(t)e^2(t) - \\
& \frac{1}{2} \left[1 - \frac{1}{2}\rho^T(t)\eta(t)\rho(t) \right]^2 e^2(t) = 0. \quad (41)
\end{aligned}$$

由此, ARFNN 收敛. \square

3.2 鲁棒性证明

鲁棒性证明对模型在实际应用中的成功运用至关重要, 本小节详细地研究了 ARFNN 的鲁棒性, 以确保其能够在面对噪声和不确定性的实际环境中表现出色.

定理 2 对于具有非高斯噪声或异常值的未知

系统 (42), 所提出的基于 ARFNN 的软测量模型为正常样本分配较大权重, 为噪声样本或异常值分配较大权重, 为噪声样本或异常值分配较小权重, 从而获得鲁棒模型.

与传统的基于模糊神经网络 FNN 的模型相比, 所提出的方法具有更稳健的性能, 其中

$$y_p(t) = y(t) + \varepsilon. \quad (42)$$

其中: $y_p(t)$ 表示引入对抗性扰动后的模型输出, $y(t)$ 表示原始模型的输出, ε 表示对抗性扰动.

证明 假设传统基于模糊神经网络 FNN 模型中第 k 个样本的建模误差占所有样本的比例为

$$S_{\text{FNN}}^k(t) = \frac{e_k^2(t)}{\sum_{i=1}^N e_i^2(t)}. \quad (43)$$

其中: $e_i(t)$ 表示为 t 时刻第 i 个样本的模型误差, $e_k(t)$ 表示 t 时刻第 k 个样本的模型误差, N 为样本总数. 对于所提出的基于 ARFNN 的软测量模型中第 k 个样本的建模误差占所有样本的比例可表示为

$$S_{\text{ARFNN}}^k(t) = \frac{(e_k(t) - M(t))^2 + \mu M(t)^2}{\sum_{i=1}^N (e_i(t) - M(t))^2 + N\mu M(t)^2}. \quad (44)$$

其中: $M(t)$ 为模型的全局误差 (如式 (2) 所示), μ 为模型的正则化参数. 两种模型下的第 k 个样本的建模误差差值 δ^k 可表示为

$$\delta^k(t) = S_{\text{ARFNN}}^k(t) - S_{\text{FNN}}^k(t). \quad (45)$$

如果 δ^k 大于 0, 则所提出的基于 ARFNN 的软测量模型中第 k 个样本的建模误差占比大于传统的 FNN 模型; 反之, 则小于传统的 FNN 模型.

将式 (43) 和 (44) 代入 (45) 可得

$$\begin{aligned}
& \delta^k(t) = \\
& [M(t)^2 + \mu M(t)^2 - 2M(t)e_k(t)] \sum_{i=1}^N e_i^2(t) + \\
& [2M(t)e_i(t) - (\mu + 1)NM(t)^2] e_k^2(t) / \\
& \sum_{i=1}^N e_i^2(t) \left\{ \sum_{i=1}^N [e_i(t) - M(t)]^2 + N\mu M(t)^2 \right\}. \quad (46)
\end{aligned}$$

当满足 $|e_k(t)| < 0.5|M(t)|$ 时, 式 (46) 可改写成

$$\begin{aligned}
& [M(t)^2 + \mu M(t)^2 - 2M(t)e_k(t)] \sum_{i=1}^N e_i^2(t) + \\
& \left[2M(t) \sum_{i=1}^N e_i(t) - (\mu + 1)NM(t)^2 \right] e_k^2(t) \geq
\end{aligned}$$

$$\mu M(t)^2 \sum_{i=1}^N e_i^2(t) + \left[2M(t) \sum_{i=1}^N e_i(t) - (\mu + 1)NM(t)^2 \right] e_k^2(t). \quad (47)$$

将 $|e_k(t)| < 0.5|M(t)|$ 代入式 (47) 可得

$$2M(t) \sum_{i=1}^N e_i(t) - (\mu + 1)NM(t)^2 = (\mu + 1)NM(t)^2 \geq 0, \quad (48)$$

因此, 根据式 (45) ~ (47) 可得

$$\delta^k(t) > 0. \quad (49)$$

根据式 (49), 所提出的基于 ARFNN 的软测量模型与传统的 FNN 模型相比, 对误差较小的训练样本赋予了更大的权重.

对于所有训练样本, 有

$$\sum_{i=1}^N S_{\text{ARFNN}}^i(t) = \sum_{i=1}^N S_{\text{FNN}}^i(t) = 1, \quad (50)$$

由式 (49) 和 (50) 可得

$$\sum_{|e_k(t)| < 0.5|M(t)|} S_{\text{ARFNN}}^i(t) > \sum_{|e_k(t)| < 0.5|M(t)|} S_{\text{FNN}}^i(t). \quad (51)$$


式 (51) 表明, 在给定训练数据样本的情况下, 总能找到满足 $|e_k(t)| < 0.5|M(t)|$ 的边界, 当一个样本的绝对误差 $|e_k|$ 在边界外时, 它将被赋予较小的权重, 减少了对模型的影响. 因此, 基于 ARFNN 的软测量模型对噪声或异常值具有鲁棒性. □

综上所述, 在一定条件下, 模型在训练过程中能够趋向于稳定的状态, 即模型的输出不再发生明显的变化, 证明模型是训练充分且稳定的. 在给定的收敛性证明中, 利用对称抗噪损失函数和动态学习率来描述模型在训练中的更新过程, 学习率的动态调整保证了模型在训练过程中既不会发散也不会收敛过慢. 在实际应用过程中, 为验证理论约束条件的有效性, 需按照理论和实际需求, 对模型参数进行设置, 保证模型的收敛性.


4 实验结果和分析

4.1 数值仿真测试


为了进一步验证模型的抗干扰能力, 实验中通过随机生成模拟数据, 创建一个包含 100 个数值的数组, 该数组数据在 $[-5, 5]$ 内均匀分布, 可表示预测误差. 设定扰动均值为 0, 标准差为 0.2, 计算对抗性扰动值并添加到函数的预测误差上, 获得扰动后的预测误差, 并计算扰动后对称损失函数的函数值. 预测误差和添加扰动后的预测误差结果对比如图 3(a) 所示.




(a) 包含扰动点的对称抗噪损失函数



(b) 不同噪声水平下的对称抗噪损失函数



(c) 无噪声情况下ARFNN建模效果



(d) 有噪声情况下ARFNN建模效果

图3 包含扰动点的对称抗噪损失函数曲线

在此基础上, 通过调整正态分布标准差的方式模拟不同噪声强度, 分别观察噪声水平为 0.1、0.5、1.0 三种情况下损失函数图像的变化, 不同噪声水平下的对称抗噪损失函数如图 3(b) 所示.

其次, 将所提出的 ARFNN 用于对以下非线性系统进行建模, 可表示为

$$y(t+1) = \frac{y(t)y(t-1)[y(t)+2.5]}{1+y^2(t)+y^2(t-1)} + u(t). \quad (52)$$

其中: $y(0) = 0, y(1) = 0, u(t) = \sin(2\pi t/25)$. 上述模型可表示为

$$\hat{y}(t+1) = \hat{f}(y(t), y(t-1), u(t)). \quad (53)$$

在本实验中, ARFNN 包含 5 个输入变量和 1 个输出变量. 训练样本数为 400, 测试样本数为 100, 分别在 [1, 400] 和 [401, 500] 区间内. 在此示例中, 设置更新神经网络中心值、宽度值、权值的学习率为 0.1, 自适应权重参数为 0.7. 利用均方根误差 (root mean square error, RMSE) 和平均绝对误差 (mean absolute error, MAE) 评价模型的精度, 其可表示为

$$\text{RMSE} = \sqrt{\frac{1}{2n} \sum_{i=1}^n (y_i(t) - y(t))^2}, \quad (54)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_{pi}(t) - y_i(t)|. \quad (55)$$

ARFNN 跟踪结果如图 3(c) 和 3(d) 所示. 图 3(c) 为无噪声干扰情况下 ARFNN 的建模效果, 可以看出 ARFNN 输出曲线与真实值曲线拟合度较高, 该实验结果表明所提出的基于 ARFNN 的软测量模型能够实现膜透水率的准确预测. 为了验证 ARFNN 的抗干扰能力, 在原有数据基础上, 通过添加高斯噪声的方式, 对基于 ARFNN 的模型进行了验证, 实验结果如图 3(d) 所示. 该测试所使用的数据集从 [1, 400] 中选择, 这些数据集在 [-1, 4] 范围内均匀生成, 并在 [-0.2, 0.2] 范围内有一些微小的高斯噪声. 由图 3(d) 可以看出, 在加入外部噪声后, 预测输出值受到了一定的影响, 但与真实值曲线的拟合程度较高, 表明基于 ARFNN 的软测量模型有较好的抗噪能力. 同时, 为验证 ARFNN 的抗干扰能力, 在原有数据基础上, 通过添加高斯噪声的方式, 对基于 ARFNN 的模型进行了验证, 实验结果如图 3(d) 所示. 该测试所使用的数据集从 [1, 400] 中选择, 这些数据集在 [-1, 4] 范围内均匀生成, 并在 [-0.2, 0.2] 范围内有一些微小的高斯噪声. 由图 3(d) 可以看出, 在加入外部噪声后, 预测输出值受到了一定的影响, 但与真实值曲线的拟合程度较高, 表明基于 ARFNN 的软测量模型有较好的抗噪能力.

为了验证所提出 ARFNN 的性能, 与其他方法进行了比较, 结果如表 1 所示. 表 1 给出了有无额外噪声情形下不同软模型在膜透水率测量过程中的 RMSE 和 MAE 对比, 可以看出无额外噪声情况下, 基于 ARFNN 的软测量模型 RMSE 为 0.0293, MAE 为 0.0209, 均低于其他模型的误差值; 加入额外噪声后, 基于 ARFNN 的软测量模型的 RMSE 和 MAE 分别为 0.0603 和 0.0420, 误差明显低于其他对比的软测量模型. 由表 1 可以看出: 相较于其他模型, 在无外部噪声条件下, 基于 ARFNN 的软测量模型优势明显, 具有最小的训练误差和测试误差; 在有外部噪声

的条件下, 虽然相较无噪声情况下测试误差和训练误差有所增加, 但基于 ARFNN 的软测量模型相对于其他模型, 仍具有最小的误差, 具有较好的抗噪能力. 同时, 在无外部噪声条件下, 相对于 FNN、RBFNN、ECA-CNN、ANN, ARFNN 的检测性能分别提高了 43.46%, 22.34%, 15.75% 和 11.51%; 在有外部噪声条件下, 相对于 FNN、RBFNN、ECA-CNN、ANN, ARFNN 的检测性能分别提高了 72.37%, 19.62%, 80.67% 和 83.76%. 因此, 尤其是在有外部干扰的情况下, 所提出的 ARFNN 具有较好的抗噪能力和检测精度.

表1 有无噪声情形下不同软模型的误差对比

软测量模型	无外部噪声		有外部噪声	
	测试RMSE	测试MAE	测试RMSE	测试MAE
ARFNN	0.029 3	0.020 9	0.060 3	0.042 0
FNN	0.052 0	0.039 3	0.218 8	0.165 2
RBFNN	0.037 6	0.029 6	0.075 1	0.061 7
ECA-CNN	0.034 7	0.028 7	0.312 5	0.105 3
ANN	0.033 1	0.030 2	0.371 1	0.191 4


4.2 实际运行数据仿真测试

为验证方法的科学性与合理性, 本文利用来自于北京某城市污水处理厂 2022 年采集的 MBR 实际运行数据进行实验. 数据共 330 组, 选择其中 250 组作为训练数据, 80 组作为测试数据, 使用 PLS 算法对水质指标进行分析, 选取进水氨氮、产水压力、产水流量、跨膜压差和厌氧区氧化还原电位 5 个指标作为软测量模型的输入变量, 以膜透水率作为输出变量, 建立基于 ARFNN、FNN、RBFNN、ECA-CNN 和 ANN 的软测量模型, 仿真结果如图 4(a) 所示.

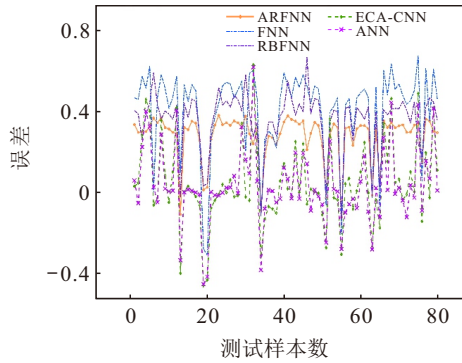
为保证实验的公平性, 在文中统一将神经网络结构设定为 5-10-1, 学习率设置为 0.3, 并设置训练次数为 300 次. 这些参数的设置是通过反复试验和调整得出的最优参数, 以确保模型的性能和稳定性.

图 4 给出了不同软测量模型对膜透水率的预测效果对比, 从图中可以看出, 相较于其他软测量模型, 基于 ARFNN 的软测量模型预测输出曲线与实际输出曲线拟合度较高, 预测输出值与实际输出值相差较小、误差较小.

为了验证 ARFNN 的抗干扰能力, 在原有数据基础上, 通过添加高斯噪声的方式, 对基于 ARFNN、FNN、RBFNN、ECA-CNN 和 ANN 的软测量模型进行训练和预测. 实验结果表明: 基于 ARFNN 的软测量模型训练效果好于 FNN、RBFNN、ECA-CNN 和 ANN; 相较于 FNN、RBFNN、ECA-CNN 和 ANN, ARFNN 在训练过程中加入了自适应参数更新反馈



(a) ARFNN 仿真效果



(b) ARFNN 仿真误差

图4 ARFNN 仿真结果

环节, 使神经网络的各项参数在训练过程中不断优化, 实现实时校正, 适合处理动态非线性过程, 更适合应用于实际的污水处理过程。

表 2 给出了不同软模型在膜透水率测量过程中的 RMSE 和 MAE 对比, 可以看出基于 ARFNN 的软测量模型 RMSE 为 0.030 1, MAE 为 0.025 6, 误差值低于其他软测量模型的误差。通过加入额外噪声后, 不同软测量模型的误差数据对比, 根据对比表 2 数据可知, 基于 ARFNN 的软测量模型训练误差、测试误差小, 具备一定的抗噪能力, 能够满足城市污水处理过程中膜透水率的预测要求。

表2 添加高斯噪声情形下不同软模型的误差对比

软测量模型	测试RMSE	测试MAE
ARFNN	0.030 1	0.025 6
FNN	0.051 6	0.041 3
RBFNN	0.037 6	0.030 6
ECA-CNN	0.050 1	0.045 9
ANN	0.049 8	0.047 6

5 结 论

针对膜生物反应器污水处理工艺易受到进水水量、水质波动等外部干扰因素的影响而导致膜透水率难以准确测量的问题, 文中提出了一种基于 ARFNN 的膜生物反应器 MBR 透水率软测量模型, 通过构造对称抗噪损失函数, 有效抑制了噪声对膜透水率软测量模型的干扰, 提高了模型的鲁棒性; 同

时, 利用自适应梯度下降方法, 实现了模型参数动态更新, 提高了膜透水率检测效率, 并且保证了收敛性。实验结果表明, 所提出的 ARFNN 可以获得较好的检测精度。此外, 理论与实验证明 ARFNN 具有较好的鲁棒能力和检测精度, 在实际工业应用过程中, 不仅能够实现污水处理过程膜污染的在线准确检测, 还可以在冶金、化工等流程工业中对关键指标参数的有效检测, 进而为后续的优化调控奠定基础。

参考文献 (References)

- [1] Bhattacharyya A, Liu L, Lee K, et al. Review of biological processes in a membrane bioreactor (MBR): Effects of wastewater characteristics and operational parameters on biodegradation efficiency when treating industrial oily wastewater[J]. *Journal of Marine Science and Engineering*, 2022, 10(9): 1229.
- [2] Sudiarto S I A, Rengaman A, Choi H L. Floating aquatic plants for total nitrogen and phosphorus removal from treated swine wastewater and their biomass characteristics[J]. *Journal of Environmental Management*, 2019, 231: 763-769.
- [3] Hube S, Eskafi M, Hrafnkelsdottir K F, et al. Direct membrane filtration for wastewater treatment and resource recovery: A review[J]. *Science of the Total Environment*, 2020, 710: 136375.
- [4] 周平, 张天娇. 基于隐性记忆的非平稳时变污水处理过程多目标运行优化[J]. *控制与决策*, 2023, 38(8): 2389-2400.
(Zhou P, Zhang T J. Implicit memory based multi-objective operation optimization of wastewater treatment process under nonstationary time-varying conditions[J]. *Control and Decision*, 2023, 38(8): 2389-2400.)
- [5] 韩广, 乔俊飞, 韩红桂, 等. 基于 Hopfield 神经网络的污水处理过程优化控制[J]. *控制与决策*, 2014, 29(11): 2085-2088.
(Han G, Qiao J F, Han H G, et al. Optimal control for wastewater treatment process based on Hopfield neural network[J]. *Control and Decision*, 2014, 29(11): 2085-2088.)
- [6] He H Y, Xin X D, Qiu W, et al. Role of nano-Fe₃O₄ particle on improving membrane bioreactor(MBR) performance: Alleviating membrane fouling and microbial mechanism[J]. *Water Research*, 2022, 209: 117897.
- [7] Gharibian S, Hazrati H. Towards practical integration of MBR with electrochemical AOP: Improved biodegradability of real pharmaceutical wastewater and fouling mitigation[J]. *Water Research*, 2022, 218: 118478.
- [8] Cui Y, Gao H, Yu R, et al. Biological-based control strategies for MBR membrane biofouling: A review[J]. *Water Science and Technology*, 2021, 83(11): 2597-2614.
- [9] Mishra S, Singh R P, Rout P K, et al. Membrane

- bioreactor (MBR) as an advanced wastewater treatment technology for removal of synthetic microplastics[C]. Development in Wastewater Treatment Research and Processes. Amsterdam: Elsevier Inc., 2022: 45-60.
- [10] Liu D, Song K, Xie G J, et al. MBR-UV/Cl₂ system in treating polluted surface water with typical PPCP contamination[J]. Scientific Reports, 2020, 10(1): 8835.
- [11] Du X J, Shi Y K, Jegatheesan V, et al. A review on the mechanism, impacts and control methods of membrane fouling in MBR system[J]. Membranes, 2020, 10(2): 24.
- [12] Ninomiya Y, Kimura K, Sato T, et al. High-flux operation of MBRs with ceramic flat-sheet membranes made possible by intensive membrane cleaning: Tests with real domestic wastewater under low-temperature conditions[J]. Water Research, 2020, 181: 115881.
- [13] Zhang H N, Wang H Q, Jie M R, et al. Performance and microbial communities of different biofilm membrane bioreactors with pre-anoxic tanks treating mariculture wastewater[J]. Bioresource Technology, 2020, 295: 122302.
- [14] Wang C S, Ng T C A, Ding M Y, et al. Insights on fouling development and characteristics during different fouling stages between a novel vibrating MBR and an air-sparging MBR for domestic wastewater treatment[J]. Water Research, 2022, 212: 118098.
- [15] Zheng Y, Zhang W X, Tang B, et al. Membrane fouling mechanism of biofilm-membrane bioreactor (BF-MBR): Pore blocking model and membrane cleaning[J]. Bioresource Technology, 2018, 250: 398-405.
- [16] Singh R P, Fu D F, Yang J H, et al. Operational performance and biofoulants in a dynamic membrane bioreactor[J]. Bioresource Technology, 2019, 282: 156-162.
- [17] 鲁树武, 伍小龙, 郑江, 等. 基于动态融合 LOF 的城市污水处理过程数据清洗方法[J]. 控制与决策, 2022, 37(5): 1231-1240.
(Lu S W, Wu X L, Zheng J, et al. Data-cleaning method based on dynamic fusion LOF for municipal wastewater treatment process[J]. Control and Decision, 2022, 37(5): 1231-1240.)
- [18] Liu Q, Ren J Y, Lu Y S, et al. A review of the current *in situ* fouling control strategies in MBR: Biological versus physicochemical[J]. Journal of Industrial and Engineering Chemistry, 2021, 98: 42-59.
- [19] Lindamulla L M L K B, Jegatheesan V, Jinadasa K B S N, et al. Integrated mathematical model to simulate the performance of a membrane bioreactor[J]. Chemosphere, 2021, 284: 131319.
- [20] Huang S J, Pooi C K, Shi X Q, et al. Performance and process simulation of membrane bioreactor (MBR) treating petrochemical wastewater[J]. Science of the Total Environment, 2020, 747: 141311.
- [21] Zhong H, Yuan Y, Luo L, et al. Water quality prediction of MBR based on machine learning: A novel dataset contribution analysis method[J]. Journal of Water Process Engineering, 2022, 50: 103296.
- [22] Roy D, Drogui P, Tyagi R D, et al. MBR treatment of leachates originating from waste management facilities: A reference study of the design parameters for efficient treatment[J]. Journal of Environmental Management, 2020, 259: 110057.
- [23] Jawad J, Hawari A H, Javaid Zaidi S. Artificial neural network modeling of wastewater treatment and desalination using membrane processes: A review[J]. Chemical Engineering Journal, 2021, 419: 129540.
- [24] Wang M Y, Li C Q. Research of BP neural network based on GA-WOA algorithm optimization in MBR membrane pollution simulation[J]. Frontiers in Computing and Intelligent Systems, 2022, 2(1): 26-28.
- [25] Yang Y X, Wang P, Gao X J. A novel radial basis function neural network with high generalization performance for nonlinear process modelling[J]. Processes, 2022, 10(1): 140.
- [26] Algoufily Y, Hong P Y, Kirati T M L. Membrane bioreactor control and fouling Monitoring using artificial neural network-based approach[J]. IFAC-PapersOnLine, 2022, 55(33): 66-71.
- [27] Ba-Alawi A H, Nam K, Heo S, et al. Explainable multisensor fusion-based automatic reconciliation and imputation of faulty and missing data in membrane bioreactor plants for fouling alleviation and energy saving[J]. Chemical Engineering Journal, 2023, 452: 139220.
- [28] Han H G, Zhang Q, Liu Z, et al. Knowledge-based fuzzy broad learning algorithm for warning membrane fouling[J]. International Journal of Fuzzy Systems, 2021, 23(1): 13-26.
- [29] Hosseinzadeh A, Zhou J L, Altaee A, et al. Modeling water flux in osmotic membrane bioreactor by adaptive network-based fuzzy inference system and artificial neural network[J]. Bioresource Technology, 2020, 310: 123391.
- [30] Wu X L, Han H G, Qiao J F. Data-driven intelligent warning method for membrane fouling[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(8): 3318-3329.

作者简介

张祎邢 (2002-), 男, 本科生, 主要研究方向为复杂系统智能特征建模、异常工况自愈控制, E-mail: allen_scofield@126.com;

刘峥 (1994-), 男, 讲师, 硕士生导师, 主要研究方向为复杂系统智能特征建模、智能优化控制, E-mail: liuzheng@bjut.edu.cn;

韩红桂 (1983-), 男, 教授, 博士生导师, 主要研究方向为神经元网络、过程控制, E-mail: rechardhan@bjut.edu.cn.