

基于知识图谱的鼓风机轴承温度智能预测^①

韩春荣¹, 杨自强¹, 郭俊温¹, 王鹏飞¹, 伍小龙², 孙晨暄²

¹(北京城市排水集团有限责任公司, 北京 100044)

²(北京工业大学 信息学部, 北京 100124)

通信作者: 孙晨暄, E-mail: xuanchensunnj@163.com



摘要: 轴承温度是衡量鼓风机是否正常运行的重要指标之一。然而, 轴承通常安装在狭小密闭的空间中, 导致其温度难以实时准确检测。为了解决这个问题, 设计了基于知识图谱的鼓风机轴承温度智能预测方法。利用统计方法分析鼓风机运行系统, 获取与轴承温度相关的影响因素。结合运行机理和领域知识构建知识图谱, 提取影响轴承温度的直接和间接特征变量。采用双模块模糊神经网络对知识图谱进行推理, 实现对鼓风机轴温的实时准确预测。结果表明, 基于知识图谱的鼓风机轴承温度智能预测方法可以准确地建模鼓风机系统, 具有良好的温度预测能力。该项研究可以为轴承温度的实时监测和变化趋势预测提供支持。

关键词: 轴承温度; 目标预测; 知识图谱; 模糊神经网络; 检测方法

引用格式: 韩春荣, 杨自强, 郭俊温, 王鹏飞, 伍小龙, 孙晨暄. 基于知识图谱的鼓风机轴承温度智能预测. 计算机系统应用, 2024, 33(2): 105–114.
<http://www.c-s-a.org.cn/1003-3254/9386.html>

Intelligent Prediction of Blower Bearing Temperature Based on Knowledge Graph

HAN Chun-Rong¹, YANG Zi-Qiang¹, GUO Jun-Wen¹, WANG Peng-Fei¹, WU Xiao-Long², SUN Chen-Xuan²

¹(Beijing Drainage Group Co. Ltd., Beijing 100044, China)

²(Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China)

Abstract: The bearing temperature of the blower is an important indicator to evaluate its stable operation. However, since bearings are usually installed in a relatively closed environment, it is difficult to achieve real-time and accurate detection of bearing temperature. To address this issue, a knowledge graph-based intelligent prediction of the bearing temperature of blowers is presented. First, a statistical method is applied to analyze the operational system of blowers, and the influencing factors related to bearing temperature are obtained. Second, a knowledge graph is constructed by combining mechanism and domain knowledge. In addition, the direct and indirect feature variables that affect the bearing temperature are extracted. Third, a dual modular fuzzy neural network is designed to deduce the knowledge graph, and the real-time and accurate prediction of the bearing temperature of blowers is realized. Finally, the results show that the intelligent prediction method of bearing temperatures of blowers based on a knowledge graph can accurately model the blower system and has good temperature prediction ability. This research can provide support for real-time monitoring and change trend prediction of bearing temperatures.

Key words: bearing temperature; target prediction; knowledge graph; fuzzy neural network; detection method

污水处理是实现水资源循环利用的重要举措^[1]。作为污水处理系统的核心设备, 鼓风机具有输送、增压和

曝气等重要作用^[2]。然而, 由于鼓风机长期不间断运行, 轴承的磨损与故障不可避免, 这将对系统正常运行造

① 收稿时间: 2023-08-03; 修改时间: 2023-09-01; 采用时间: 2023-09-15; csa 在线出版时间: 2023-11-24

CNKI 网络首发时间: 2023-11-27

成严重影响^[3-5]. 因此, 准确预测轴承温度并及时进行维护保养对保证鼓风机正常运行至关重要^[6].

传统的鼓风机轴温监测方法多采用温度传感器进行实时监测, 例如热电偶温度计^[7], 霍尔效应传感器^[8], 微机电系统温度传感器^[9], 电感-电容温度传感器^[10], 基于纳米颗粒的测温技术^[11]. 然而, 这类方法无法预知轴温的变化趋势, 只能进行现场监控和发生异常后报警处理, 不能提前采取预防措施^[12].

近年来, 利用物联网技术和传感器网络, 通过对鼓风机系统进行全面监测和数据采集, 可以获取海量的数据资源^[13]. 然后, 借助智能技术^[14], 从数据中提取运行规律和趋势, 预测鼓风机轴温未来的变化趋势, 为鼓风机轴承温度监控提供新的解决方案^[15]. 例如, 王新^[16]利用回归参数算法建立系统模型, 捕捉相关变量与轴温的关系, 实现轴承超温的提前预警. 卢艳霞^[17]引入支持向量机作为预测模型, 从历史监测数据中挖掘变量间的关联性, 实现轴承温度的预测. 然而, 由于轴承温度变化具有季节特性^[18], 上述统计方法中静态模型难以模拟鼓风机动态运行规律, 导致预测精度降低^[19].

为了实现轴承温度的动态预测, 马明骏等^[20]利用威布尔比例风险-长短期记忆神经网络模型建立轴承温度与外界环境和风机运行特性的映射关系, 实现鼓风机在不同运行状态下轴承温度的趋势预测. Li 等^[21]利用径向基神经网络建立鼓风机系统的仿真模型. 该模型结合历史数据和实时数据, 利用最小二乘算法对参数进行实时调整并预测轴承的工作温度. 动态智能方法分析了数据的动态规律, 并挖掘出轴承温度随时间变化的季节特征^[22]. 然而, 由于鼓风机系统复杂的运行机理, 上述模型需要大量参数进行模拟, 容易导致过拟合问题^[23].

为此, 本文提出一种基于知识图谱的鼓风机轴承温度智能预测方法, 实现鼓风机轴温的实时监测. 这有助于提前发现和解决潜在问题, 提高鼓风机设备的稳定性. 本文提出的方法具有以下优势: 1) 采集与鼓风机运行相关的数据和信息, 包括环境因素, 运行状态等, 从而实现鼓风机系统的全面, 准确描述; 利用统计方法分析运行特点, 获取与轴承温度相关的影响因素; 2) 采用知识图谱系统地描述鼓风机运行系统和相关因素之间的关系, 辨识直接相关特征和间接相关特征; 3) 设计一种双模块模糊神经网络 (dual modular fuzzy neural network, DMFNN), 通过对 DMFNN 进行推理, 综合考虑各种因素对轴温的影响, 实现轴承温度的高精度, 实

时预测.

1 相关知识

1.1 污水处理过程鼓风机运行概况

污水处理过程中, 一级处理过程主要用于去除水体中的悬浮物, 沉淀物等. 这些物质会堵塞鼓风机和其他处理设备. 二级处理过程是全流程的核心环节, 利用生化反应去除水体中的有害物质, 如磷和氮等物质. 这个过程需要鼓风机为生化反应提供充足的氧气, 它们通过向反应池中注入空气来促进微生物的新陈代谢和分解过程. 三级处理过程可以深度去除水体中的悬浮物, 有机污染物等.

鼓风机稳定运行对污水处理过程的稳定性和经济性至关重要. 设备温度是影响鼓风机稳定运行的关键因素. 通过温度监控, 可以及时发现和解决设备过热, 故障预防, 优化运行效率. 图 1 为鼓风机运行原理图.

1.2 知识图谱

知识图谱是描述研究对象中实体(节点)及其关系(边)的一种具有有向关系的知识网, 由多个<实体, 关系, 实体>的三元组构成. 其中, 知识图谱被形式化定义为 $G=\{G_1, G_2, \dots, G_d, \dots, G_D\}$, $G_d=(E_i, R_{ij}, E_j)$ 为第 d 个三元组, E_i 是第 i 个实体, E_j 是第 j 个实体, R_{ij} 是第 i 个和第 j 个实体的有向关系, D 是知识图谱中三元组的数量.

知识图谱将实体和关系组织成知识网, 以便清晰, 完整地展示实体之间的各种关联关系, 具有强大的语义表达能力, 使机器能够理解和处理知识.

2 基于知识图谱的鼓风机轴温智能预测方法

2.1 鼓风机轴温相关因素

电机轴承温度过高导致鼓风机发生故障. 对电机轴承温度进行监测和控制可以降低其他故障的发生概率, 保证鼓风机的使用寿命. 因此, 通过对鼓风机轴温进行监测, 保证其在正常范围内对于保障污水处理系统的稳定运行至关重要.

根据鼓风机运行机理, 电机的轴温受多种相关因素影响, 主要包括以下方面.

进气状态: 相关变量有进口空气温度, 压力, 流量. 进气状态会影响到鼓风机的进气阻力和进气流量, 容易导致电机轴承温度过高, 甚至引起安全事故.

轴承状态: 主要指轴承磨损度和润滑度. 轴承磨损或润滑不足均造成轴温超过正常限值.

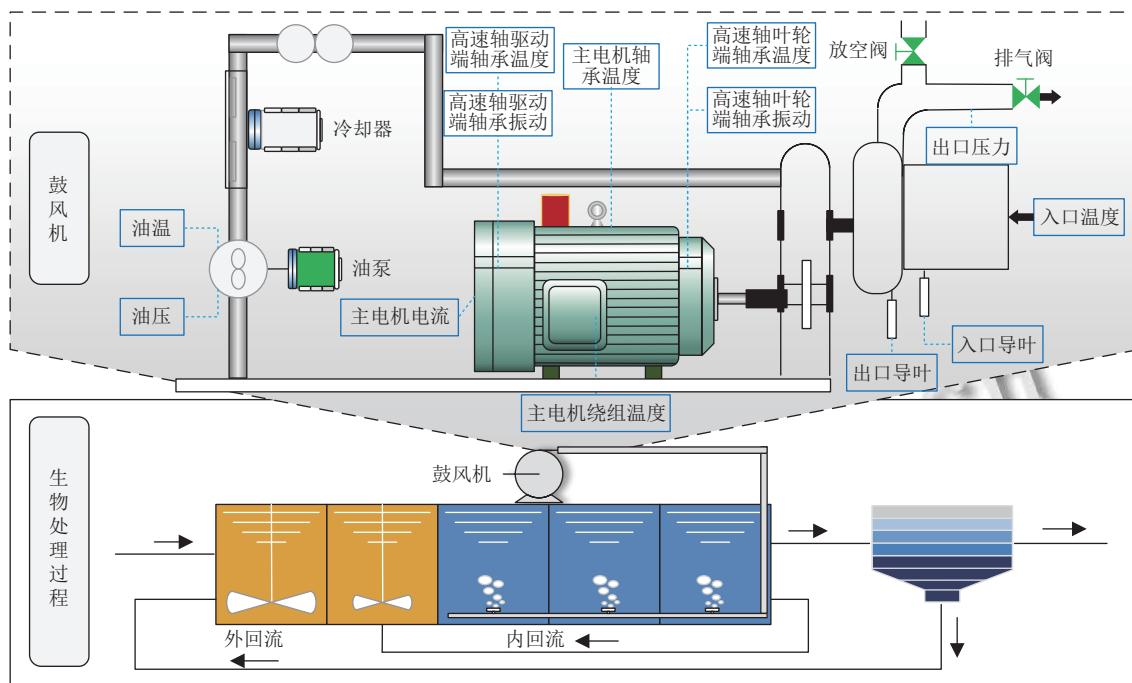


图1 鼓风机运行原理图

电机状态: 电机电流, 电机绕组温度, 电机振动情况等过高会导致电机散热不良, 使电机的轴承温度急速升高.

其他因素: 过大的电机负载, 过高的电机转速或者过长的电机运行时间均使轴承温度升高. 此外, 鼓风机的出口压力直接影响电机的输出功率和流量, 从而影响到其运行效率和能耗. 出口压力过大会造成电机轴温过高.

2.2 基于知识图谱的特征提取

(1) 基于运行机理的知识图谱建立

为了构建知识图谱, 利用鼓风机机理知识获取描述鼓风机系统中的实体(节点)及其关系(边). 基于鼓风机轴温相关因素分析, 鼓风机系统中具体实体见表1.

鼓风机系统中实体间的关系包括: 线性相关(正相关, 负相关), 非线性相关和不相关. 例如, 过高的负荷导致轴承温度升高, 具有正相关关系; 高轴承润滑度可以减少轴承摩擦损失和轴承温度, 其呈现负相关关系; 某些因素可能会在一定范围内对轴承温度产生正相关影响, 超过一定范围则产生负相关影响, 呈现非线性相关; 进口空气温度与出口空气压力不相关. 图2为构建的知识图谱.

从知识图谱可以看出, 鼓风机系统主要由电机和风机两部分组成, 两部分之间通过联轴器连接. 主电机电流受到设备在工作时产生, 消耗的功率的影响, 即主

电机负荷的影响; 流量, 入口温度影响主电机负荷. 主电机负荷与三相绕组温度呈正相关. 影响电机运行的关键因素为主电机电流, 轴承温度和三相绕组温度. 其中, 影响电机轴承温度的因素有鼓风机罩内的环境温度, 轴承润滑度和电机振动值. 影响风机运行的关键因素为风机低速轴轴承温度, 高速轴轴承温度, 进气温度, 高速轴振动值和出口空气压力. 影响风机高速轴温度的因素有导叶开度和轴承润滑度.

表1 鼓风机系统中的实体

序号	类型	实体(节点)
1	温度	进口空气温度
2		主电机轴承温度
3		高速轴轴承温度
4		低速轴轴承温度
5		三相绕组温度
6		主电机罩内温度
7	压力	进口空气压力
8		出口空气压力
9	振动值	主电机振动值
10		高速轴振动值
11	电流	主电机电流
12		进口空气流量
13	其他	主电机负荷
14		主电机轴承润滑度
15		高速轴轴承润滑度
16		高速轴导叶开度
17		廊道总风量

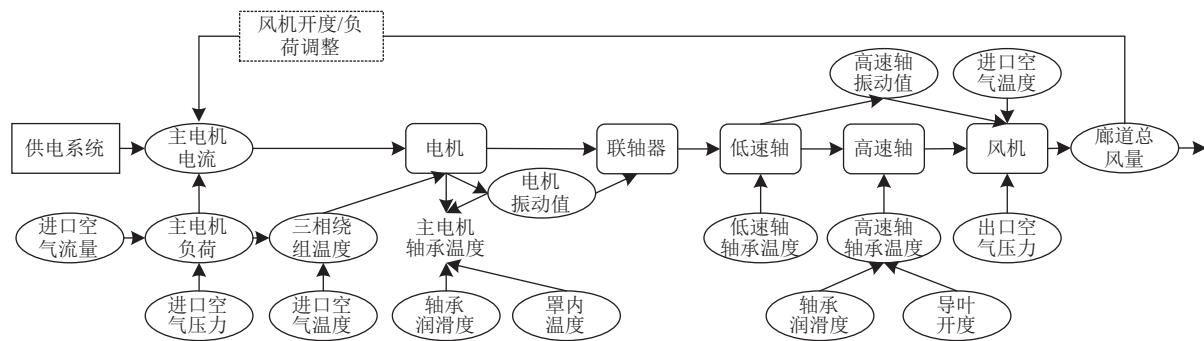


图 2 鼓风机运行关系知识图谱

(2) 特征提取

为了提取预测鼓风机电机轴温的相关变量, 利用知识图谱从上述变量中提取特征变量。核心思想为: 1) 提取间接特征变量: 该类特征变量可以直接预测风机轴承温度, 再通过风机轴承温度的变化来间接地预测电机轴承温度; 2) 提取直接特征变量: 该类变量与电机轴温直接相关, 实现电机轴承温度的直接预测。表 2 为实体中的间接特征变量和直接特征变量。

2.3 基于双模块模糊神经网络的轴温预测

针对鼓风机运行系统中提取的直接特征变量与电机轴温的关系简单且存在较强的关联性, 可以利用简单的模型进行表达; 间接特征变量与电机轴温的关系复杂且相关关系被弱化, 需要复杂的模型捕获相关关系。由于直接特征变量与间接特征变量提供的信息不同, 需要不同的特征处理方式, 单一建模方法难以同时处理两种特征变量, 导致检测效果差。因此, 设计了双模块模糊神经网络预测轴温, 如图 3 所示。

表 2 间接/直接特征变量总结

类型	特征变量
	进气温度
间接特征变量	高速轴轴承温度 低速轴轴承温度 出口空气压力 高速轴振动值 高速轴轴承润滑度 高速轴导叶开度
	罩内温度 轴承润滑度 主电机振动值 三相绕组温度 进口空气流量 进口空气压力 进口空气温度 主电机电流 主电机负荷 主电机轴承润滑度
直接特征变量	

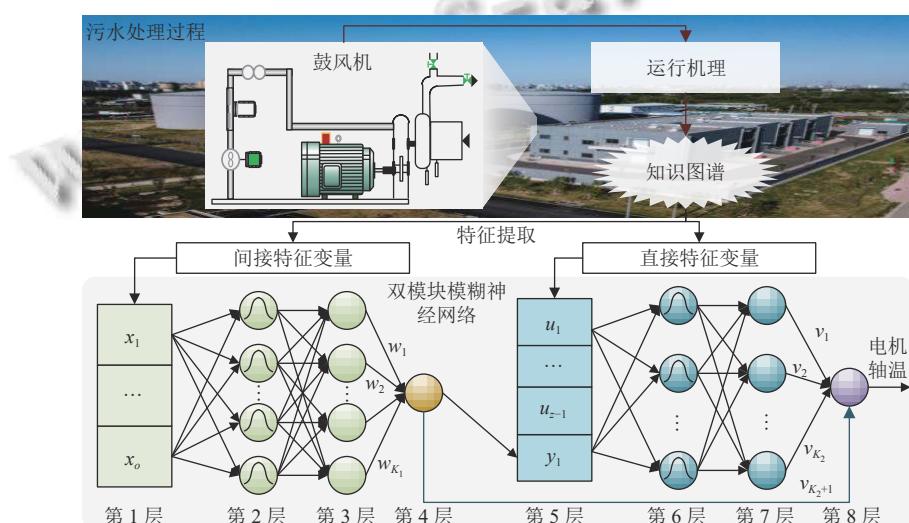


图 3 基于双模块模糊神经网络的轴温预测模型

(1) 预测模型

结合知识图谱和双模块模糊神经网络(knowledge graph-based DMFNN, KG-DMFNN)的轴温预测模型由两个模块组成,共8层,各层具体表达式如下。

模块1输入层(第1层):该层神经元将间接特征变量输入到预测模型。该层神经元的输出为 $x(t)=[x_1(t), x_2(t), \dots, x_o(t)]$, $x_i(t)$ 为 t 时刻第*i*个间接特征变量, $i=1, 2, \dots, o$, o 是间接特征变量的数量。

模块1径向基函数层(第2层):该层共有 K_1 个神经元。该层利用高斯函数作为隶属函数,用于模拟间接特征变量与轴温的关系。该层 t 时刻第*j*个神经元的输出为高斯隶属函数的乘积,计算公式为:

$$\mu_j(t) = \prod_{i=1}^o e^{-\frac{(x_i(t)-c_{ij}(t))^2}{2(\sigma_{ij}(t))^2}} \quad (1)$$

其中,第1层神经元的输出 $x_i(t)$ 作为第2层神经元的输入, $\mu_j(t)$ 为第*j*个神经元的输出值, $j=1, 2, \dots, K_1$, K_1 为该层神经元的数量,e为自然对数的底数, $c_{ij}(t)$ 和 $\sigma_{ij}(t)$ 分别为 t 时刻第1个模块中第*j*个神经元第*i*个输入对应的中心和宽度。

模块1归一化层(第3层):该层由 K_1 个神经元组成。第2层神经元的输出 $\mu_j(t)$ 作为该层神经元的输入。该层 t 时刻第*j*个神经元的输出 $\varphi_j(t)$ 为:

$$\varphi_j(t) = \frac{\mu_j(t)}{\sum_{j=1}^{K_1} \mu_j(t)} \quad (2)$$

模块1输出层(第4层):该层具有一个神经元, t 时刻输出 $y_1(t)$ 计算为:

$$y_1(t) = \sum_{j=1}^{K_1} w_j(t) \varphi_j(t) \quad (3)$$

其中,第3层神经元的输出 $\varphi_j(t)$ 作为该层神经元的输入, $w_j(t)$ 为 t 时刻第1个模块中归一化层和输出层之间的第*j*个权值。

模块2输入层(第5层):该层神经元用于将从鼓风机中提取的直接特征变量输入到预测模型。该层神经元的输出为 $u(t)=[u_1(t), u_2(t), \dots, u_z(t)]$,其中, $u_1(t), \dots, u_{z-1}(t)$ 为 t 时刻直接特征变量, $z-1$ 是直接特征变量的数量, $u_z(t)$ 为第4层神经元的输出值 $y_1(t)$ 。

模块2径向基函数层(第6层):该层包括 K_2 个神

经元。神经元利用高斯隶属函数模拟直接特征变量与轴温的关系。该层第*n*个神经元的输出 $\eta_n(t)$ 为:

$$\eta_n(t) = \prod_{m=1}^z e^{-\frac{(u_m(t)-\alpha_{mn}(t))^2}{2(\beta_{mn}(t))^2}} \quad (4)$$

其中, $u_m(t)$ 为该层神经元的输入, $m=1, 2, \dots, z$, z 是第5层神经元的数量, $n=1, 2, \dots, K_2$, K_2 为该层神经元的数量, $\alpha_{mn}(t)$ 和 $\beta_{mn}(t)$ 分别为 t 时刻第2个模块中第*n*个神经元第*m*个输入对应的中心和宽度。

模块2归一化层(第7层):该层的神经元数量为 K_2 , t 时刻第*n*个神经元的输出为:

$$\phi_n(t) = \frac{\eta_n(t)}{\sum_{n=1}^{K_2} \eta_n(t)} \quad (5)$$

其中,第6层神经元的输出值 $\eta_n(t)$ 为该层神经元的输入, $\phi_n(t)$ 为第2个模块中第*n*个神经元输出。

集成输出层(第8层):该层具有一个神经元,该层神经元的输入向量为 $[\phi_1(t), \dots, \phi_{K_2}(t), y_1(t)]$,该层神经元输出计算为:

$$y(t) = \left(\sum_{n=1}^{K_2} v_n(t) \phi_n(t) \right) + v_{K_2+1}(t) y_1(t) \quad (6)$$

其中, $v_n(t)$ 为第2个模块中归一化层和集成输出层之间的第*n*个权值, $v_{K_2+1}(t)$ 为第2个模块中归一化层和集成输出层之间的第 K_2+1 个权值, $y(t)$ 为双模块模糊神经网络的输出,表示鼓风机主电机的轴承温度的预测值。

(2) 学习目标函数

KG-DMFNN学习的目标是模拟鼓风机运行系统中特征变量与轴承温度的非线性映射关系。学习目标函数的设置可以明确训练目标,通过最小化目标函数值,使神经网络在训练过程中逐步学习到期望的结果。在本文中,将误差平方和作为目标函数,公式如下:

$$E(t) = \frac{1}{2} \sum_{t=1}^D (y(t) - y_d(t))^2 \quad (7)$$

其中, D 为样本数, $E(t)$ 为目标函数的输出值, $y_d(t)$ 为轴承温度的真实值。通过最小化式(7),即最小化预测结果与实际结果之间的差异,实现KG-DMFNN对鼓风机运行系统的模拟仿真。

(3) 学习算法

为了提高模型预测精度,根据式(7),利用梯度下

降算法对 KG-DMFNN 的参数同时进行更新。参数更新公式为:

$$\begin{cases} C(t+1) = C(t) - \lambda \Delta C(t) \\ \Theta(t+1) = \Theta(t) - \lambda \Delta \Theta(t) \\ W(t+1) = w(t) - \lambda \Delta w(t) \\ \Phi(t+1) = \Phi(t) - \lambda \Delta \Phi(t) \\ \Lambda(t+1) = \Lambda(t) - \lambda \Delta \Lambda(t) \\ V(t+1) = v(t) - \lambda \Delta v(t) \end{cases} \quad (8)$$

其中, λ 为学习因子, $C(t) = [c_1(t), c_2(t), \dots, c_{K_1}(t)]$, $c_j(t) = [c_{1j}(t), c_{2j}(t), \dots, c_{oj}(t)]$, $\Theta(t) = [\sigma_1(t), \sigma_2(t), \dots, \sigma_{K_1}(t)]$, $\sigma_j(t) = [\sigma_{1j}(t), \sigma_{2j}(t), \dots, \sigma_{oj}(t)]$, $W(t) = [w_1(t), w_2(t), \dots, w_{K_1}(t)]$, $\Phi(t) = [\alpha_1(t), \alpha_2(t), \dots, \alpha_{K_2}(t)]$, $\alpha_j(t) = [\alpha_{1j}(t), \alpha_{2j}(t), \dots, \alpha_{ej}(t)]$, $\Lambda(t) = [\beta_1(t), \beta_2(t), \dots, \beta_{K_2}(t)]$, $\beta_j(t) = [\beta_{1j}(t), \beta_{2j}(t), \dots, \beta_{ej}(t)]$, $V(t) = [v_1(t), v_2(t), \dots, v_{K_2+1}(t)]$, $\Delta C(t)$, $\Delta \Theta(t)$, $\Delta w(t)$, $\Delta \Phi(t)$, $\Delta \Lambda(t)$, $\Delta v(t)$ 为模型参数的梯度, 可以指示模型参数的更新方向, 指导网络向更优的方向调整。

由于模块 1 的输出既作为模块 2 的输入也是集成输出层的输入, 模块 2 和集成输出层的误差均反馈到模块 1。因此, 模块 1 的中心 $\Delta C(t)$, 宽度 $\Delta \Theta(t)$, 权值 $\Delta w(t)$ 对应的梯度同时受到模块 2 和集成输出层的影响。模块 2 的输出仅作用于集成输出层, 因此, 模块 2 的中心 $\Delta \Phi(t)$, 宽度 $\Delta \Lambda(t)$, 权值 $\Delta v(t)$ 对应的梯度仅依赖于集成输出层。

(4) 鼓风机轴温预测流程

结合上述内容, 为了准确预测鼓风机轴温, 首先, 根据知识图谱确定直接特征变量和间接特征变量; 其次, 利用梯度下降算法同时更新 KG-DMFNN 的参数 $C(t)$, $\Theta(t)$, $W(t)$, $\Phi(t)$, $\Lambda(t)$, $V(t)$, 具体流程如下。

步骤 1: 初始化最大迭代次数, 滑窗数 P , 双模块模糊神经网络隐含层节点数 K_1 和 K_2 , 参数 $C(1)$, $\Theta(1)$, $W(1)$, $\Phi(1)$, $\Lambda(1)$, $V(1)$, 初始时刻 $t=1$ 。

步骤 2: 获取当前 t 时刻样本, 利用知识图谱确定模型的直接特征变量值和间接特征变量值。

步骤 3: 若时刻 $t < P$, 对 $1:t$ 组输入和输出变量分别归一化处理, 根据式(1)~式(3)计算模块 1 输出 $y_1(1), \dots, y_1(t)$; 根据式(4)~式(6)计算模块 2 输出 $y(1), \dots, y(t)$ 并得到误差 $e(1), \dots, e(t)$; 利用梯度下降算法完成网络参数梯度求解。若 $t \geq P$, 对 $t-P+1:t$ 组输入和输出变量分别归一化处理, 根据式(1)~式(3)计算模块 1 输

出 $y_1(t-P+1), \dots, y_1(t)$; 根据式(4)~式(6)计算模块 2 输出 $y(t-P+1), \dots, y(t)$ 并得到误差 $e(t-P+1), \dots, e(t)$; 利用梯度下降算法完成网络参数梯度求解。

步骤 4: 根据式(8)获得 $C(t+1)$, $\Theta(t+1)$, $W(t+1)$, $\Phi(t+1)$, $\alpha_j(t+1)$, $\Lambda(t+1)$, $\beta(t+1)$, $V(t+1)$ 。

步骤 5: 根据式(1)~式(6)预测下一时刻轴温并存储数据。

步骤 6: 判断是否可以获取新数据, 若可以获取, 则 $t=t+1$ 并返回步骤 2; 否则, 停止计算。

3 实验结果与分析

3.1 实验设计

为了验证 KG-DMFNN 的有效性, 本文利用来自某实际污水处理厂鼓风机系统运行的真实数据为实验样本进行仿真实验, 并分析相应实验结果。算法运行环境为英特尔酷睿 i7-11700, 内存 16 GB 和 Windows 10 操作系统。选取均方根误差 (root mean square error, RMSE), 平均绝对百分比误差 (mean absolute percent error, MAPE) 和决定系数 (R -square, R^2) 作为评价指标, 评估所提出方法的轴温预测精度。上述指标的具体计算公式为:

$$\begin{cases} RMSE = \sqrt{\sum_{t=1}^T (y(t) - \hat{y}(t))^2 / T} \\ MAPE = \frac{1}{T} \sum_{t=1}^T \frac{|y(t) - \hat{y}(t)|}{\hat{y}(t)} \\ R^2 = 1 - \frac{\sum_{t=1}^T (\hat{y}(t) - y(t))^2}{\sum_{t=1}^T (\hat{y}(t) - \bar{y})^2} \end{cases} \quad (9)$$

其中, $y(t)$ 是模型输出, $\hat{y}(t)$ 为实际轴承温度值, $\bar{y}(t)$ 为实际轴承温度的平均值, T 为样本总数。

本文采用鼓风机系统 2022.7.1~2022.12.31 中的运行数据, 采样间隔为 4 h。可采集到的变量包括: 出口空气回压 (kPa), 高速轴驱动端轴承温度 (°F), 高速轴振动值 (mm/s), 进口空气温度 (°F), 主电机电流 (A), 主电机轴承温度 (°F)。KG-DMFNN 中模块 1 和 2 中的中心、宽度和权值从 (0, 1) 被随机选取, 模块 1 的径向基函数层和归一化层神经元数均为 4, 模块 2 的径向基函数层和归一化层神经元数均 3, 学习率为 0.005, 最大迭代次数为 50, 滑窗数为 18。由于鼓风机系统的过程变量对鼓风机电机轴承温度具有季节性的影响, 因此, 本方法

基于滑动窗口进行在线实时预测。具体过程如下：在训练阶段使用 $t-18, t-17, \dots, t-1$ 时刻的样本训练本文提出模型，然后使用该模型来预测时间 t 的输出。该模型的训练和测试过程交替进行。

3.2 实验结果与分析

本节通过对轴温进行实时预测和超前预测以验证本文提出的模型。首先，对现场采集的数据进行预处理（异常处理和归一化处理）。其次，根据基于知识图谱的特征提取方法确定出口空气压力，高速轴驱动端轴承温度和高速轴振动值为鼓风机预测模型的间接特征变量；进口空气温度，主电机电流和历史主电机轴承温度为鼓风机预测模型的直接特征变量。

(1) 鼓风机轴温实时预测结果

为了证明所提出的方法，分别与基于间接特征变量的 FNN (I-FNN)，基于直接特征变量的 FNN (D-FNN) 和基于两类特征变量的 FNN (ID-FNN) 进行比较。I-FNN, D-FNN 和 ID-FNN 的结构分别为 3-4-4-1, 3-3-3-1 和 6-7-7-1。其中， $S_1-S_2-S_3-S_4$ 的物理意义为输入神经元数-径向基函数层神经元数-归一化层神经元数-输出层神经元数；I-FNN, D-FNN 和 ID-FNN 的中心，宽度和权值均从 $(0, 1)$ 被随机选取，其他参数与训练过程与 KG-DMFNN 一致。

电机轴温的实验结果如图 4–图 6 所示。图 4 为 4 种方法的训练 RMSE 结果。从图 4 中可以看出，I-FNN, D-FNN 和 ID-FNN 的训练 RMSE 呈现锯齿状，在多个训练过程难以收敛到较好的 RMSE。相比于 I-FNN, D-FNN 和 ID-FNN, KG-DMFNN 在训练过程较为稳定，具有最好的训练效果。图 5 和图 6 展示了方法预测输出和预测误差。由于 I-FNN, D-FNN 和 ID-FNN 具有多个过大的训练 RMSE 值，这说明其无法对鼓风机系统进行高精度建模，导致预测效果差。从图 6 中可以看出，除了第 38 天和 42 天的预测点，KG-DMFNN 的预测误差均小于其他对比方法，具有良好的预测效果。

此外，表 3 提供了 KG-DMFNN, I-FNN, D-FNN, ID-FNN, 反向传播神经网络 (back propagation neural network, BPNN)^[24], 长短时记忆神经网络 (long short term memory neural network, LSTM) 和基于 FNN 的自回归模型 (autoregressive model with FNN, FNN-AR) 的测试 RMSE, 测试 MAPE 和测试 R^2 。指标结果的平均值 (mean) 根据 20 次实验独立运行获得。I-FNN 和 D-FNN 的输入变量仅包括部分变量，由于提供的特征信息不

足，导致模型训练和预测效果差。相比于 ID-FNN, KG-DMFNN 引入知识图谱将特征变量分为间接特征变量和直接特征变量，同时利用两个模块提供合适的特征处理方式以期望提高建模精度。FNN-AR 利用轴承温度的历史数据，而没有考虑到特征变量对输出的影响。由于特征变量包含大量当前的运行信息，KG-DMFNN 可以提取特征变量与轴承温度的非线性关系，具有比 FNN-AR 更好的运行效果。相比于 LSTM 和 BPNN，KG-DMFNN 引入高斯隶属函数降低的数据噪声对建模效果的影响。测试 RMSE 指标比测试 MAPE 指标对较大误差值更加敏感。虽然 KG-DMFNN 的测试 MAPE (0.0499) 比 BPNN 的测试 MAPE 大，但是 KG-DMFNN 的测试 RMSE (3.5648) 比 BPNN 的测试 MAPE 小。这说明 BPNN 存在非常显著的误差，而 KG-DMFNN 的预测误差相对较小。根据表 3 结果可以看出，KG-DMFNN 对测试样本具有最小的测试 RMSE (3.5648) 和最大的测试 R^2 (0.9001)，这证明了本文提出方法的有效性。

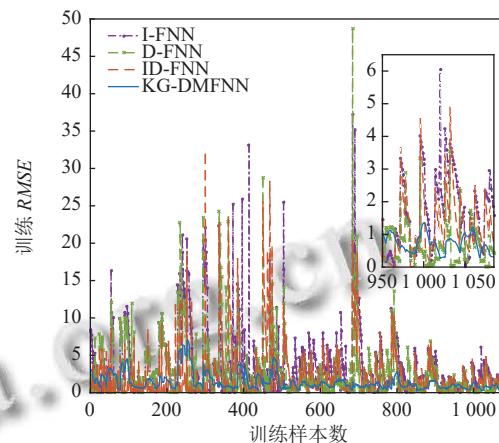


图 4 训练过程的 RMSE

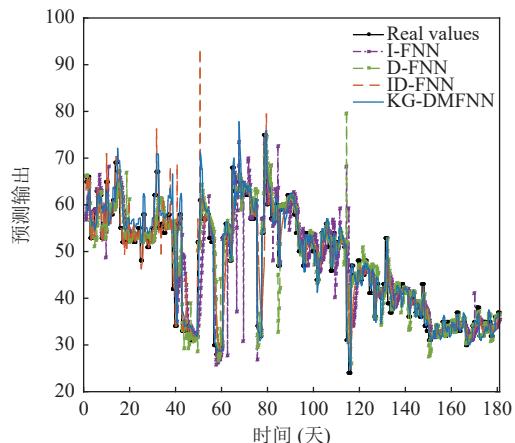


图 5 测试过程的预测输出值

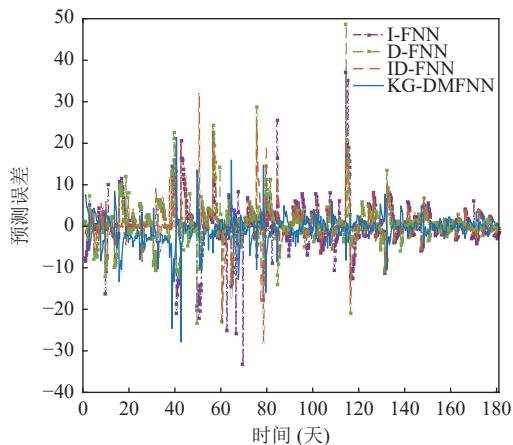


图 6 测试过程的预测误差值

表 3 不同算法的性能比较

模型	测试RMSE (mean)	测试MAPE (mean)	测试R ² (mean)
KG-DMFNN	3.5648	0.0499	0.9001
I-FNN	5.4859	0.0776	0.7567
D-FNN	5.2052	0.0673	0.7826
ID-FNN	4.5346	0.0584	0.8314
BPNN ^[24]	4.2761	0.0385	0.8576
LSTM	4.3922	0.0559	0.8466
FNN-AR	5.2184	0.0709	0.7849

(2) 鼓风机轴温超前预测结果

为了进一步评估 KG-DMFNN 的有效性, 将待建模的鼓风机系统设计为:

$$h(t) = g(\Gamma(t-6)) \quad (10)$$

其中, $h(t)$ 为 t 时刻的轴温, $\Gamma(t-6)$ 为 $t-6$ 时刻特征变量, $g(\cdot)$ 为特征变量与轴温的映射关系。因此, KG-DMFNN 利用当前时刻特征变量 $\Gamma(t)$ 预测 $t+6$ 时刻轴温 $h(t+6)$ 。

为验证方法性能, KG-DMFNN 与 I-FNN, D-FNN 和 ID-FNN 进行比较。本节对比实验与第 3.2 节第(1)部分参数设置一致。轴温超前预测结果如图 7~图 9 所示。其中, 图 7 为 4 种方法的训练 RMSE 结果。从图 7 中可以看出, 本文提出的方法在训练全程均具有较小的训练 RMSE, 可以获得具有高训练精度的模型。图 8, 图 9 为测试样本的预测输出和预测误差。相比于图 5, 图 6, 由于轴温超前预测任务复杂, 该种情况下的预测效果变差。与 I-FNN, D-FNN 和 ID-FNN 相比, KG-DMFNN 预测结果与真实轴温曲线最接近。该方法提高了模型的总体性能。

此外, 从表 4 可以看出, 由于 I-FNN 和 D-FNN 中少量的特征变量提供的信息不足, 其具有较差的预测效果。ID-FNN 将特征变量同时输入到模型, 无法适应不同

特征信息的提取需求, 导致检测效果差。由于 FNN-AR 忽略了特征变量与轴承温度的相关关系, FNN-AR 的预测表现不佳。在超前预测需求下, LSTM 侧重于捕捉长期依赖关系, 从而可以较好地处理复杂的超前预测任务。根据表 4 的实验结果, LSTM 的预测性能仅次于 KG-DMFNN。BPNN 难以克服数据噪声对预测效果的影响, 会存在非常显著的误差值。根据表 4 的结果可以看出, KG-DMFNN 对测试样本具有最小的测试 RMSE (4.7374), 最小的测试 RMSE (0.0709)(除了 BPNN 和 LSTM) 和最大的测试 R² (0.8191)。相较于其他方法, KG-DMFNN 总体预测性能较好, 可以更好地满足轴温预测要求, 保证预测准确性和实时性。

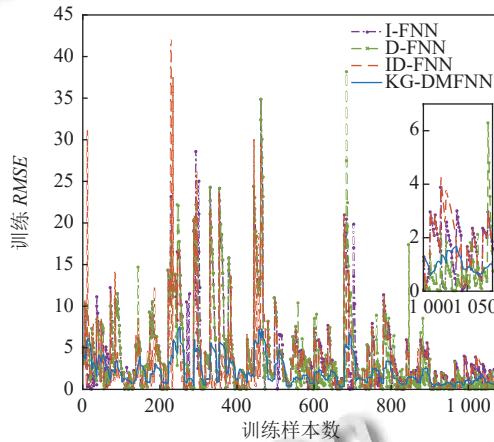


图 7 训练过程的 RMSE 值

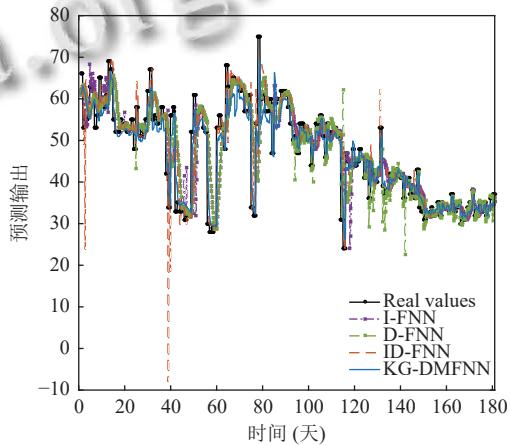


图 8 测试过程的预测输出值

4 结论与展望

本文提出一种基于知识图谱的鼓风机轴温智能预测方法, 通过实验验证了方法性能, 得出以下结论。

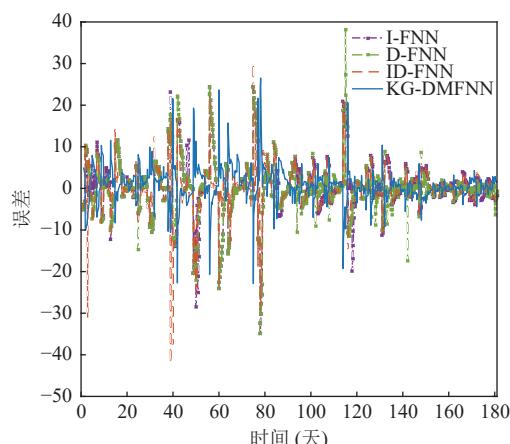


图9 测试过程的预测误差值

表4 不同算法的性能比较

算法	测试RMSE (mean)	测试MAPE (mean)	测试R ² (mean)
KG-DMFNN	4.7374	0.0709	0.8191
I-FNN	6.6332	0.0921	0.6555
D-FNN	6.2952	0.0875	0.6868
ID-FNN	5.9381	0.0799	0.7202
BPNN ^[24]	5.4709	0.0492	0.7645
LSTM	4.8144	0.0632	0.8159
FNN-AR	5.7453	0.0732	0.7441

(1) 在特征选取方面, 利用知识图谱分析鼓风机运行系统中变量的相关关系, 直观地展示了与主电机轴承温度相关的直接特征变量和间接特征变量, 提高了特征选取的可解释性。同时, 通过对比实验, 验证了 KG-DMFNN 相较于 ID-FNN 在预测轴温时的优势。

(2) 在模型设计方面, 应用双模块模糊神经网络分别模拟直接和间接特征变量与主电机轴温间的映射关系, 通过提供适当的隐含层神经元数量, 保证模型简洁性的基础上提高模型的预测精度。通过两组对比实验, 验证了模型相较于其他方法在预测结果上具有优势。

(3) 针对污水处理过程鼓风机中主电机轴温预测问题, 实验部分展示 KG-DMFNN 在轴温实时预测和超前预测两种情况下的仿真结果。可以看出, KG-DMFNN 可以较好地满足轴温预测要求, 保证预测的准确性。

由于鼓风机系统中各种变量的采集频率难以同步, 未来工作将着重研究在多时间尺度数据下的轴承预测问题。

参考文献

- Han HG, Sun CX, Wu XL, et al. Dynamic-static model for monitoring wastewater treatment processes. *Control Engineering Practice*, 2023, 132: 105424. [doi: [10.1016/j.conengprac.2022.105424](https://doi.org/10.1016/j.conengprac.2022.105424)]
- 周月侠. 污水处理中鼓风机智能控制方案的研究. *现代制造技术与装备*, 2021, 57(4): 131–132. [doi: [10.3969/j.issn.1673-5587.2021.04.046](https://doi.org/10.3969/j.issn.1673-5587.2021.04.046)]
- Sun YL, Zhang C, Zhao X, et al. Transient thermal analysis model of damaged bearing considering thermo-solid coupling effect. *Sensors*, 2022, 22(21): 8171. [doi: [10.3390/s2218171](https://doi.org/10.3390/s2218171)]
- Dindar A, Hong I, Garg A, et al. A methodology to measure power losses of rolling element bearings under combined radial and axial loading conditions. *Tribology Transactions*, 2022, 65(1): 137–152. [doi: [10.1080/10402004.2021.1937760](https://doi.org/10.1080/10402004.2021.1937760)]
- Huang HB, Yi TH, Li HN, et al. Sparse Bayesian identification of temperature-displacement model for performance assessment and early warning of bridge bearings. *Journal of Structural Engineering*, 2022, 148(6): 04022052. [doi: [10.1061/\(ASCE\)ST.1943-541X.0003354](https://doi.org/10.1061/(ASCE)ST.1943-541X.0003354)]
- Wang BS, Liu YQ, Zhang B, et al. Analysis of the temperature characteristics of high-speed train bearings based on a dynamics model and thermal network method. *Chinese Journal of Mechanical Engineering*, 2022, 35(1): 104. [doi: [10.1186/s10033-022-00789-y](https://doi.org/10.1186/s10033-022-00789-y)]
- Li N, Yun XH, Han QK, et al. Characterization method of rolling bearing operation state based on feature information fusion. *Journal of Mechanical Science and Technology*, 2023, 37(3): 1197–1205. [doi: [10.1007/s12206-023-0207-1](https://doi.org/10.1007/s12206-023-0207-1)]
- Kumar D, Suman KG. Noninvasive temperature measuring and early fault detecting system for manufacturing industry. *MAPAN-Journal of Metrology Society of India*, 2019, 34(4): 541–550.
- Scott S, Sadeghi F, Peroulis D. Highly reliable mems temperature sensors for 275 °C applications-part 1: Design and technology. *Journal of Microelectromechanical Systems*, 2013, 22(1): 225–235. [doi: [10.1109/JMEMS.2012.2227947](https://doi.org/10.1109/JMEMS.2012.2227947)]
- Li C, Feng QY, Hong YP, et al. Wireless LC conformal temperature sensor based on Ag film (9912-K FL) for bearing temperature measurement. *Nanomaterials*, 2022, 12(17): 2899. [doi: [10.3390/nano12172899](https://doi.org/10.3390/nano12172899)]
- Zhang P, Pan AZ, Yan K, et al. High stability temperature sensors by CdTe quantum dots encapsulated in SiO₂/PVA hybrids for bearing rotating elements. *Materials Today Communications*, 2023, 34: 105456. [doi: [10.1016/j.mtcomm.2023.105456](https://doi.org/10.1016/j.mtcomm.2023.105456)]
- Nikolic N, Antonic Z, Doric J, et al. An analytical method for the determination of temperature distribution in short

- journal bearing oil film. *Symmetry*, 2020, 12(4): 539. [doi: [10.3390/sym12040539](https://doi.org/10.3390/sym12040539)]
- 13 Wu XL, Han HG, Qiao JF. Data-driven intelligent warning method for membrane fouling. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(8): 3318–3329. [doi: [10.1109/TNNLS.2020.3041293](https://doi.org/10.1109/TNNLS.2020.3041293)]
- 14 Lv MZ, Liu SX, Su XM, et al. General log-linear Weibull model combining vibration and temperature characteristics for remaining useful life prediction of rolling element bearings. *Shock and Vibration*, 2020, 2020: 8829823.
- 15 Cheng Y, Wang ZW, Zhang WH. A novel condition-monitoring method for axle-box bearings of high-speed trains using temperature sensor signals. *IEEE Sensors Journal*, 2019, 19(1): 205–213. [doi: [10.1109/JSEN.2018.2875072](https://doi.org/10.1109/JSEN.2018.2875072)]
- 16 王新. 基于回归参数算法的风机轴承超温故障预警. *数字技术与应用*, 2020, 38(2): 98, 180.
- 17 卢艳霞. 基于机器学习算法在风机故障预测中的分析与应用[硕士学位论文]. 北京: 华北电力大学(北京), 2018.
- 18 Ai SY, Wang WZ, Wang YL, et al. Temperature rise of double-row tapered roller bearings analyzed with the thermal network method. *Tribology International*, 2015, 87: 11–22. [doi: [10.1016/j.triboint.2015.02.011](https://doi.org/10.1016/j.triboint.2015.02.011)]
- 19 Hu YG, Li H, Shi PP, et al. A prediction method for the real-time remaining useful life of wind turbine bearings based on the wiener process. *Renewable Energy*, 2018, 127: 452–460. [doi: [10.1016/j.renene.2018.04.033](https://doi.org/10.1016/j.renene.2018.04.033)]
- 20 马明骏, 赵海心, 姜孝谋, 等. 基于 LSTM-WPHM 模型的风机轴承故障报警与寿命预测方法. *风机技术*, 2022, 64(3): 63–71. [doi: [10.16492/j.fjjs.2022.03.0010](https://doi.org/10.16492/j.fjjs.2022.03.0010)]
- 21 Li J, Xiao JW, Hu YL, et al. Temperature prediction of multi-factor rolling bearings based on RBF neural network. *Proceedings of the 2017 Chinese Automation Congress*. Jinan: IEEE, 2017. 425–429.
- 22 Laubichler C, Kiesling C, da Silva M M, et al. Data-driven sliding bearing temperature model for condition monitoring in internal combustion engines. *Lubricants*, 2022, 10(5): 103. [doi: [10.3390/lubricants10050103](https://doi.org/10.3390/lubricants10050103)]
- 23 Xiao XC, Liu JX, Liu DS, et al. SSAE-MLP: Stacked sparse autoencoders-based multi-layer perceptron for main bearing temperature prediction of large-scale wind turbines. *Concurrency and Computation: Practice and Experience*, 2021, 33(17): e6315. [doi: [10.1002/cpe.6315](https://doi.org/10.1002/cpe.6315)]
- 24 Mokhtari HA, Mirbagheri SA. Investigation and modeling of a hybrid activated sludge system for municipal wastewater treatment using multi-layer perceptron neural networks. *Desalination and Water Treatment*, 2021, 210: 123–133. [doi: [10.5004/dwt.2021.26599](https://doi.org/10.5004/dwt.2021.26599)]

(校对责编: 孙君艳)