

基于TS-FNN的城市固废焚烧过程MIMO被控对象建模

丁海旭, 汤 健, 夏 恒, 乔俊飞[†]

(1. 北京工业大学 信息学部, 北京 100124; 2. 智慧环保北京实验室, 北京 100124)

摘要: 针对城市固废焚烧(MSWI)过程中因机理反应复杂、不确定性严重等原因导致被控对象模型难以建立的问题, 设计了一种基于(T-S)型模糊神经网络(FNN)的多输入多输出(MIMO)模型. 首先, 描述了MSWI过程的核心工艺流程并分析了模型的影响因素; 接着, 设计了面向过程控制的被控对象建模策略, 其由工况识别模块、数据预处理模块、特征约简模块、被控对象模型训练模块与被控对象模型测试模块组成; 最后, 通过实验表明了所构建模型的有效性, 为研究MSWI过程的优化控制算法奠定了基础.

关键词: 城市固废焚烧; 被控对象模型; 多输入多输出; 模糊神经网络; 过程控制

引用格式: 丁海旭, 汤健, 夏恒, 等. 基于TS-FNN的城市固废焚烧过程MIMO被控对象建模. 控制理论与应用, 2022, 39(8): 1529 – 1540

DOI: 10.7641/CTA.2022.10524

Modeling of MIMO controlled object in municipal solid waste incineration process based on TS-FNN

DING Hai-xu, TANG Jian, XIA Heng, QIAO Jun-fei[†]

(1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China;
2. Beijing Laboratory of Smart Environmental Protection, Beijing 100124, China)

Abstract: Aiming at the problem that the model of controlled object is difficult to establish due to the complicated mechanism reaction and serious uncertainty in the municipal solid wastes incineration (MSWI) process, a multi-input multi-output (MIMO) model based on Takagi-Sugeno (T-S) fuzzy neural network (FNN) is designed. First, the core process flow of MSWI process is described and the influence factors of model are analyzed. Then, a modeling strategy for controlled object of process control is designed, which is composed of an operating condition recognition module, a data preprocessing module, a feature reduction module, a training module for the model of controlled object, and a testing module for the model of controlled object. Finally, the effectiveness of the constructed model is verified by experiments, which lays the foundation for studying the optimal control algorithm of MSWI process.

Key words: municipal solid wastes incineration; model of controlled object; multi-input multi-output; fuzzy neural networks; process control

Citation: DING Haixu, TANG Jian, XIA Heng, et al. Modeling of MIMO controlled object in municipal solid waste incineration process based on TS-FNN. *Control Theory & Applications*, 2022, 39(8): 1529 – 1540

1 引言

城市固废焚烧(municipal solid wastes incineration, MSWI)技术具有无害化、减量化、资源化等突出优势, 已成为目前世界范围内处理城市固废(municipal solid wastes, MSW)的主要技术手段之一^[1-2]. 截至2020年, 我国使用机械炉排炉的固废焚烧发电厂占比已超过86%^[3]. MSWI过程具有强非线性、强耦合、大时变、

不确定性等诸多特征^[4-5], 建立精准的被控对象模型是实施智能控制技术的基础与必要准备. 因此, 针对MSWI过程进行被控对象模型设计的研究具有重要意义.

传统的被控对象模型通常是基于机理分析构建的. 机理模型通常是依据于物料平衡方程、能量平衡方程、化学动力学等原理建立的数学模型. 文献[6]针对

收稿日期: 2021-06-18; 录用日期: 2022-01-25.

[†] 通信作者. E-mail: adqiao@bjut.edu.cn; Tel.: +86 10-67391766.

本文责任编辑: 龙离军.

国家自然科学基金项目(62021003, 61890930, 62073006), 北京市自然科学基金项目(4212032, 4192009), 科学技术部国家重点研发计划项目(2018YFC1900800-5), 矿冶过程自动控制技术国家(北京市)重点实验室项目(BGRIMM-KZSKL-2020-02)资助.

Supported by the National Natural Science Foundation of China (62021003, 61890930, 62073006), the Beijing Natural Science Foundation (4212032, 4192009), the National Key R & D Program of the Ministry of Science and Technology (2018YFC1900800-5) and the Beijing Key Laboratory of Process Automation in Mining & Metallurgy (BGRIMM-KZSKL-2020-02).

并罐式无钟布料设备建立了从流量控制闸门到坯料表面的综合数学模型,改善了并联料斗式高炉负荷分布不均的问题.文献[7]针对高炉中竖井角度和炉料消耗不均匀的问题,在几何轮廓模型和势流模型上进行改进,提高了机理模型的精度.文献[8]基于离子液体体系的传递机理开发了一种用于实际溶剂的筛查模型,其为被研究系统提供了温度效应预测.虽然机理模型具有直观反映系统内在规律与结构联系的能力,然而,MSWI过程在本质上具有复杂多变和不确定的特性^[9].近年来,随着人工智能的兴起,基于数据驱动的机器学习方法为MSWI过程的被控对象建模提供了解决思路.

数据驱动模型是通过挖掘系统输入输出数据间的映射关系构建的.人工神经网络(artificial neural network, ANN)因其良好的学习能力和非线性逼近能力而广泛地应用于复杂工业过程的过程分析^[10-12].文献[13]采用动态递归神经网络构建多输入被控对象模型,在识别具有连续生产性质的工业被控对象中具有较好的应用前景.文献[14]针对锅炉燃烧发电中煤质与负荷波动频繁难以建模的问题,将锅炉模型的输入按照实际物理规律进行优化组合,设计了一种基于非对称神经网络的被控对象模型.综上所述,ANN在工业过程的被控对象建模中已成为目前的研究热点.

MSWI过程内部机理反应复杂,多个操作量与被控量耦合严重,系统规则难以挖掘,具有典型的模糊特性.针对MSWI这类复杂工业过程,模糊神经网络(fuzzy neural network, FNN)提供了良好的解决方案^[15-16].FNN作为一种模糊的自适应方案,其兼具模糊系统的非线性处理与分析能力,又具有ANN的参数学习与动态优化能力,近年来已被广为研究^[17-18].当前大多数FNN的设计都是多输入单输出(multi-input single-output, MISO)模型,其具有建模精度高、参数优化快的优势.文献[19]针对系统建模和噪声消除问题,提出了一种自演化补偿的区间二型FNN,通过多个基准非线性实验证明了模型的有效性.文献[20]设计了一种基于合作策略的FNN,提出了一种与参数优化配合的综合评估算法(comprehensive evaluation algorithm, CEA)以增强网络泛化性能,通过污水处理中的氨氮预测实验验证了模型的精度.文献[21]将T-S(Takagi-Sugeno)型FNN与遗传算法相结合,并利用此模型实现了对丙烯酸苄酯合成工艺条件及关键指标的准确预测与有效优化.然而,MSWI过程是一个典型的多输入多输出(multiple-input multiple-output, MIMO)的工业过程,构建其被控对象模型要求FNN不但要具有良好的非线性逼近能力,还要具有同步输出多个参数的能力.

在现有研究中,一些学者采用构建多个单输出网络模型的方法以满足复杂系统的多输出需求.文献

[22]设计了一种多RBF神经网络板形识别模型,用多个子网络分别识别不同的特征参数,识别模型能够正确识别出全部板形缺陷的类型.文献[23]使用深度特征聚类(deep feature clustering, DFC)组合了多个神经网络的特征,该方法在较短的处理时间内提高了情感识别的性能.然而,对于强耦合的复杂系统而言,构建多个单输出网络的建模方法割裂了系统多变量之间的关系且难以保证输出间的同步性.

最近的研究表明,模型对同一系统中多个任务同时学习可以彼此助益,即利用多个学习任务中所包含的有用信息可帮助其提升获取更精确的模型参数.文献[24]针对火力发电厂因非线性强、多变量耦合等原因导致难以建立精确数学模型的问题,采用MIMO神经网络进行建模,取得了良好的效果.文献[25]针对污水处理运行过程的重要指标出水总磷和出水氨氮难以实时测量的问题,设计了一种基于FNN的多参数软测量方法.根据以上分析,本文对T-S型FNN的结构进行了如下改进:构建共享隶属函数层与共享规则层,使用多输出误差对隶属函数的中心、宽度进行多角度校正,使得同一对象中的多任务学习具有协调兼顾的能力;构建多个后件子网络,使其分别针对不同输出任务进行校正,对多输出任务进行精准拟合,并保证其同步输出.

综上所述,本文针对MSWI过程的工艺特点,构建了一种基于MIMO的Takagi-Sugeno型FNN(MIMO Takagi-Sugeno FNN, MIMO-TSFNN)被控对象模型.首先,设计了专家评判机制用于运行工况识别,通过异常数据剔除与数据归一化进行预处理;然后,结合布风布料过程机理分析,通过计算皮尔逊相关系数(pearson correlation coefficient, PCC)提取能够反应系统状态的关键操作量与被控量;最后,构建MIMO-TSFNN多任务学习模型,采用梯度下降算法对网络参数进行优化,同步调整网络共享神经元参数,针对多输出任务对后件子网络的模糊系统参数能够进行校正.通过北京市某MSWI电厂的过程数据验证了被控对象模型的有效性.

2 面向被控对象建模的MSWI特性分析

2.1 MSWI工艺流程

基于炉排炉的MSWI工艺流程包括:固废储运系统、固废焚烧系统、余热锅炉系统、蒸汽发电系统、烟气处理系统与烟气排放系统.固废进入焚烧炉,在炉体的高温热辐射和加温后的助燃风作用下,经过干燥、燃烧、燃烬过程,固废在高温作用下转化成为气体无机物并释放热量.如图1所示.

2.2 模型影响因素分析

研究MSWI的控制过程是分析模型影响因素的基础,其主要操作对象为一次风机及其风门挡板、二次

风机、干燥炉排、燃烧炉排、燃烬炉排等设备; 主要被控变量为烟气含氧量、炉膛温度、主蒸汽流量等。MSWI过程的控制过程如图2所示。

根据MSWI的工艺特点, 可将其归纳以一个典型的“布风布料”过程, 关键操作变量包括: 各段炉排空

气流量、一次风总流量、二次风流量、各段炉排速度。根据MSWI控制需求, 采集的关键被控变量包括: 主蒸汽流量、炉膛温度和烟气含氧量。本节采用皮尔逊相关系数PCC对操作变量与被控变量之间的相关性评估如下。




图 1 MSWI的工艺流程

Fig. 1 MSWI process flow




图 2 MSWI的控制过程

Fig. 2 MSWI control process

$$\rho_{XY} = \frac{N \sum_{i=1}^N x_i y_i - \sum_{i=1}^N x_i \sum_{i=1}^N y_i}{\sqrt{N \sum_{i=1}^N x_i^2 - (\sum_{i=1}^N x_i)^2} \sqrt{N \sum_{i=1}^N y_i^2 - (\sum_{i=1}^N y_i)^2}}, \quad (1)$$

其中: x_i 和 y_i 分别为两组变量所对应的数据序列, N 为样本个数.

根据PCC的定义: 当 ρ_{XY} 为正数时, 变量之间为正相关, 反之为负相关, ρ_{XY} 的绝对值越大相关性越强, 当计算结果为非数值(not a number, NAN)时, 则说明某一变量未发生变化. 计算结果如图3-8所示.




图3 布风操作变量与主蒸汽流量的PCC值

Fig. 3 PCC value of air distribution operating variable and main steam flow




图4 布风操作变量与炉膛温度的PCC值

Fig. 4 PCC value of air distribution operating variable and furnace temperature




图5 布风操作变量与烟气含氧量的PCC值

Fig. 5 PCC value of air distribution operating variable and flue gas oxygen content




图 6 布料操作变量与主蒸汽流量的PCC值

Fig. 6 PCC value of material distribution operating variable and main steam flow




图 7 布料操作变量与炉膛温度的PCC值

Fig. 7 PCC value of material distribution operating variable and furnace temperature




图 8 布料操作变量与烟气含氧量的PCC值

Fig. 8 PCC value of material distribution operating variable and flue gas oxygen content

由图3-4可知, 部分一次风各段流量PCC值较高且正负相关均存在, 而一次风总流量却与主蒸汽流量、炉膛温度的PCC值极低, 这表明各子管之间存在着强

耦合性, 并不能选取局部某一根子管作为主要变量。此外, 由图3-4可知, 二次风流量与主蒸汽流量、炉膛温度的PCC值是最高的, 因此可选取二次风作为操作

变量. 由图5可知, 一次风各段流量与烟气含氧量均呈现正相关, 且一次风总流量与烟气含氧量的PCC值最高, 因此选取一次风总流量作为关键操作变量. 由图6–8可知, 干燥炉排与主蒸汽流量、炉膛温度、烟气含氧量的PCC值均为最高. 此外, 各段炉排之间的机械结构是相互独立的, 并不存在耦合, 因此, 选取干燥炉排平均速度作为关键操作变量.

3 MSWI过程被控对象模型

3.1 建模策略

针对MSWI过程工艺特点, 本文提出的MSWI过程MIMO被控对象建模策略如图9所示.




图9 基于数据驱动的MSWI过程MIMO被控对象建模策略

Fig. 9 Modeling strategy of MIMO controlled object based on data drive in MSWI process

3.2 建模算法及算法实现

3.2.1 工况识别模块

MSWI过程受MSW分类程度、经济水平、气候季节等因素影响, 具有多工况特性, 通常需要依靠专家经验对不同工况进行判别. 现场领域专家依据先验知识判断当前工况. 在此基础上, 本模块建立了一种工况识别专家评判机制.

3.2.2 数据预处理模块

1) 异常数据剔除.

MSWI过程检测环境恶劣、设备损耗大, 如未及时发现并排除仪器故障等因素, 会造成检测数据失真. 通过绘制分位数图对数据的正态分布性进行检测并采用 3σ 准则^[26]对异常数据进行剔除. 设定样本数据的维度为 $q \times K$, q 为MSWI过程的被控变量数量, K 为样本

该策略由工况识别模块、数据预处理模块、特征约简模块、被控对象模型训练模块与被控对象模型测试模块共5个模块组成, 相关变量及符号定义如下: 原始操作变量为 N 个, 记为 $x_1^{\text{or}}, x_2^{\text{or}}, \dots, x_N^{\text{or}}$; 被控变量为 q 个, 记为 $y_1^{\text{or}}, y_2^{\text{or}}, \dots, y_q^{\text{or}}$; 工况识别结果为 l 种, 记为 $g_1, \dots, g_l$; 数据预处理后变量, 记为 $x_1^{\text{pr}}, x_2^{\text{pr}}, \dots, x_N^{\text{pr}}, y_1^{\text{pr}}, y_2^{\text{pr}}, \dots, y_q^{\text{pr}}$; 特征约简后的训练集输入变量为 n 个, 记为 $x_1^{\text{tr}}, \dots, x_n^{\text{tr}}$; 特征约简后的训练集输出变量为 q 个, 其中真值记为 $y_1^{\text{tr}}, \dots, y_q^{\text{tr}}$, 预测值记为 $\hat{y}_1^{\text{tr}}, \dots, \hat{y}_q^{\text{tr}}$; 模型输出误差记为 $e_1^{\text{tr}}, \dots, e_q^{\text{tr}}$; 测试集输入变量记为 $x_1^{\text{te}}, \dots, x_n^{\text{te}}$; 模型计算输出变量记为 $\hat{y}_1^{\text{te}}, \dots, \hat{y}_q^{\text{te}}$; 模型内部结构参数记为 $c_{ij}, \delta_{ij}, p_{ij}$.

的总数量, 样本数据用 φ_{sk} , $s = 1, 2, \dots, q$, $k = 1, 2, \dots, K$ 表示, 其中 $\bar{\varphi}_{sk}$ 为样本均值, 其标准偏差为

$$\sigma_s = \sqrt{\sum_{k=1}^K (\varphi_{sk} - \bar{\varphi}_{sk})^2 / (K - 1)}. \quad (2)$$

当 φ_{sk} 对应的剩余误差 $(\varphi_{sk} - \bar{\varphi}_{sk})$ 符合以下条件时, 则对此 φ_{sk} 执行剔除操作, 其计算方法为

$$|\varphi_{sk} - \bar{\varphi}_{sk}| > 3\sigma_s. \quad (3)$$

2) 数据归一化处理.

MSWI过程高度复杂, 测得的变量较多且量纲不同. 为了保证数据指标之间的统一性, 对其执行归一化操作如下:

$$\varphi_{sk}^* = \frac{\varphi_{sk} - \min(\varphi_s)}{\max(\varphi_s) - \min(\varphi_s)}, \quad (4)$$

其中 φ_s 为变量 s 的样本向量.

3.2.3 特征约简模块

研究MSWI被控对象模型的关键是选择合适的操作量与被控量, MSWI过程的操作量与被控量多达几十个, 且部分变量之间具有高度耦合性. 针对我国MSWI国情, 需要在实际运行情况进行特征约简, 从而用于构建被控对象模型. 因此, 本模块建立了一种基于过程数据分析的特征约简机制, 通过计算变量之间PCC值对MSWI过程中的变量进行选取与融合.

3.2.4 MIMO-TSFNN模型训练模块

1) 模型结构设计.

针对MSWI过程设计了如图10所示的MIMO-TSFNN模型结构, 对其数学描述如下.




图10 MIMO-TSFNN模型

Fig. 10 MIMO-TSFNN model

输入层: 该层设有 n 个神经元, 其作用是将输入值进行传递, 当第 k 个样本进入时, 其输出可表示为

$$x_i^{\text{tr}}(k), i = 1, 2, \dots, n. \quad (5)$$

隶属函数层: 该层设有 $n \times m$ 个神经元, 每个节点代表对应输入量的隶属度值, 隶属函数可表示为

$$u_{ij}(k) = \exp[-(x_i^{\text{tr}}(k) - c_{ij}(k))^2 / \delta_{ij}(k)], \quad (6)$$

式中 $c_{ij}(k)$ 和 $\delta_{ij}(k)$ 是隶属函数的中心和宽度, $j = 1, 2, \dots, m$.

规则层: 该层设有 m 个神经元, 采用模糊连乘算子作为模糊逻辑规则, 规则层第 j 个神经元输出为

$$w_j(k) = \prod_{i=1}^n u_{ij}(k), \quad (7)$$

对规则层输出进行去模糊化以获得输出权重为

$$\theta_j(k) = w_j(k) / \sum_{j=1}^m w_j(k). \quad (8)$$

后件层: 该层共有 $m \times q$ 个神经元, 每个节点执行T-S型模糊规则的线性求和, 该层的作用是计算每条规则所对应输出的后件参数, 后件参数由后件网络计算得出, 将其表示为

$$\hat{y}_j^s(k) = p_{0j}^s(k)x_0^{\text{tr}}(k) + p_{1j}^s(k)x_1^{\text{tr}}(k) + \dots + p_{nj}^s(k)x_n^{\text{tr}}(k), s = 1, 2, \dots, q, \quad (9)$$

式中 $p_{0j}^s(k), p_{1j}^s(k), \dots, p_{nj}^s(k)$ 是模糊系统的参数.

输出层: 该层设有 q 个输出节点, 每个节点对输入参数执行加权求和, 得到输出层输出为

$$\hat{y}_s(k) = \sum_{j=1}^m \theta_j(k) \hat{y}_j^s(k). \quad (10)$$

2) 模型参数学习.

通过梯度下降法对模型参数进行迭代求解^[27], 相关算法定义如下.

模型误差 $e_s^{\text{tr}}(k)$ 定义如下:

$$e_s^{\text{tr}}(k) = (y_s^{\text{tr}}(k) - \hat{y}_s^{\text{tr}}(k))^2 / 2, \quad (11)$$

式中: $y_s^{\text{tr}}(k)$ 为第 k 个输入样本对应的第 s 个实际输出, $\hat{y}_s^{\text{tr}}(k)$ 为第 k 个输入样本对应的第 s 个计算输出.

隶属函数的中心 $c_{ij}(k)$ 、宽度 $\delta_{ij}(k)$ 的更新算法定义如下:

$$c_{ij}(k) = c_{ij}(k-1) - \eta \frac{\partial (\sum_{s=1}^q (e_s^{\text{tr}}(k)))}{\partial c_{ij}(k)}, \quad (12)$$

$$\delta_{ij}(k) = \delta_{ij}(k-1) - \eta \frac{\partial (\sum_{s=1}^q (e_s^{\text{tr}}(k)))}{\partial \delta_{ij}(k)}, \quad (13)$$

式中 η 为在线学习率, 其取值范围为 $[0.01, 0.05]$.

模糊系统参数 $p_{ij}^s(k)$ 的更新算法定义如下:

$$p_{ij}^s(k) = p_{ij}^s(k-1) - \eta \frac{\partial e_s^{\text{tr}}(k)}{\partial p_{ij}^s(k)}. \quad (14)$$

3) 模型评价指标.

采用均方根误差(root mean squared error, RMSE)与平均百分比误差(average percentage error, APE)评估建模效果, 相关定义如下:

$$\text{RMSE}_s^{\text{tr}} = \sqrt{\sum_{k=1}^K (y_s^{\text{tr}}(k) - \hat{y}_s^{\text{tr}}(k))^2 / K}, \quad (15)$$

$$\text{APE}_s^{\text{tr}} = \frac{1}{K} \sum_{k=1}^K \left| \frac{y_s^{\text{tr}}(k) - \hat{y}_s^{\text{tr}}(k)}{y_s^{\text{tr}}(k)} \right| \times 100\%, \quad (16)$$

式中: k 为当前输入样本, K 为样本总数.

3.2.5 MIMO-TSFNN模型测试模块

MIMO-TSFNN模型在训练完成后, 需要通过测试以证明模型的有效性. 测试集输入变量记为: $x_1^{\text{te}}(k), \dots, x_n^{\text{te}}(k)$; 模型计算输出变量记为: $\hat{y}_1^{\text{te}}(k), \dots, \hat{y}_q^{\text{te}}(k)$. 计算测试数据集的RMSE与APE, 当模型测试模块达到期望的拟合效果与建模误差后, 则表明

MSWI过程的被控对象模型建模有效。

4 实验验证

4.1 实验描述

本实验对北京市某MSWI发电厂的进行数据采集, 采样频率为1 s/次。本节分别针对数据预处理、特征约简、被控对象模型训练与测试进行相应实验, 结果如下。

4.2 实验结果

4.2.1 数据预处理实验

通过绘制样本数据的分位数图以验证数据集是否满足正态分布的特性。原始数据 $y_1^{\text{or}}, y_2^{\text{or}}, \dots, y_q^{\text{or}}$ 中关键被控量的分位数如图11所示。




图11 关键被控量分位数图

Fig. 11 Quantile chart of key controlled quantities

由图11可知, 提取的MSWI过程数据较好地分布

于直线附近, 验证了其正态分布的特性。在此基础上, 使用 3σ 准则对异常数据进行剔除并对全部数据进行归一化处理, 得到预处理后的变量为 $x_1^{\text{pr}}, x_2^{\text{pr}}, \dots, x_N^{\text{pr}}, y_1^{\text{pr}}, y_2^{\text{pr}}, \dots, y_q^{\text{pr}}$ 。

4.2.2 特征约简实验

选择 1×10^5 时刻的炉排速度值, 绘制图像如图12所示。




图12 MSWI过程的炉排速度变化

Fig. 12 Grate speed change in MSWI process

布料过程中, 干燥炉排对MSW的脱水作用至关重要, 对干燥炉排的速度调节是目前MSWI行业内公认的结论, 结合图12可知, 对干燥炉排的调节最为频繁, 其与被控变量的关系最为紧密, 而燃烧炉排1、燃烧炉排2的调速并不多, 且其几乎是联动进行变化的, 燃烬炉排全程均未发生变化。计算模型操作/被控变量之间PCC值如表1所示。

表1 操作/被控变量间PCC值

Table 1 PCC value of manipulation variables and controlled variables

PCC值	烟气含氧量	炉膛温度	主蒸汽流量
一次风总流量	0.2527	-0.0117	-0.0090
二次风流量	0.0117	0.3215	0.4159
干燥炉排平均速度	0.1303	-0.4199	-0.6042
燃烧炉排1平均速度	0.1156	-0.1008	-0.1603
燃烧炉排2平均速度	0.0691	-0.1556	-0.0892
燃烬炉排平均速度	NAN	NAN	NAN

根据表1的结果, 选取的关键操作变量为一次风总流量、二次风流量和干燥炉排平均速度, 关键被控变量为烟气含氧量、炉膛温度和主蒸汽流量。

4.2.3 MIMO-TSFNN模型训练实验

MIMO-TSFNN模型训练实验在工况识别、数据预处理和特征约简实验的基础上, 将得到的 1×10^5 组数据中的 8×10^4 组作为训练样本。模型的参数设置为: 输入层神经元为3个, 隶属度函数层神经元个数为 3×12 个, 规则层神经元个数为12个, 后件层神经元个数为 12×3 个, 输出层神经元为3个, 训练迭代步数为500次。被控对象模型训练过程中的RMSE与参数

学习的变化曲线如图13所示; 参数学习的变化曲线如图14所示, 其中每个子图代表神经元的隶属函数中心 c_{ij} 、宽度 δ_{ij} 和模糊系统参数 p_{ij}^s 在迭代过程中的变化; 模型的训练过程中的拟合效果如图15所示。




图13 模型训练过程RMSE变化

Fig. 13 RMSE changes during model training

由图13–15可知, 本文所提出的MIMO-TSFNN模型在训练过程中收敛速度快, 能够快速达到期望误差, 模型的建模精度较高。

4.2.4 MIMO-TSFNN模型测试实验

将 1×10^5 组数据中的 2×10^4 组作为测试样本, 模型的测试拟合效果如图16所示。

由图16可知, 模型在多输出样本中均体现出了良好的逼近能力, 兼顾了多样本输出的学习任务, 具有良好的泛化能力。

4.3 方法比较

为了验证该模型的有效性, 本节选取基准前馈神经网络TSFNN、RBFNN和反向传播神经网络(back propagation neural network, BPNN)进行对比实验, 其中: TSFNN、RBFNN和BPNN的隐含层神经元设置为12, 网络训练的迭代步数设置为500次。使用RMSE与APE作为性能评价指标, 对计算结果进行反归一化以

使针对不同量纲的评价指标更清晰, 被控对象模型的建模效果评价如表2所示。

表2 被控对象模型的建模效果评价

Table 2 Evaluation of modeling effect of controlled object model

网络模型	评价指标	主蒸汽流量	炉膛温度	烟气含氧量
MIMO-TSFNN	训练	RMSE	0.5994	4.6586
		APE	0.0062	0.0005
	测试	RMSE	2.5848	16.7950
		APE	0.0272	0.0102
TSFNN	训练	RMSE	0.9108	7.4278
		APE	0.0073	0.0078
	测试	RMSE	2.7799	18.6144
		APE	0.0791	0.0141
RBFNN	训练	RMSE	1.7212	11.4466
		APE	0.1515	0.0287
	测试	RMSE	4.5065	20.5438
		APE	0.1942	0.0395
BPNN	训练	RMSE	2.2761	13.7859
		APE	0.1418	0.0369
	测试	RMSE	7.9097	23.1730
		APE	0.2143	0.0404

根据表2进行分析可知:

1) MIMO-TSFNN模型在实验中体现了良好的泛化能力, 训练与测试的RMSE和APE均达到了理想的精度。与同类基准网络相比, 本文提出的MIMO-TSFNN模型具有良好的预测精度, 达到了最小训练RMSE (0.5994, 4.6586, 0.6148), APE (0.0062, 0.0005, 0.0698)和最小的测试RMSE (2.5848, 16.7950, 1.5411), APE (0.0272, 0.0102, 0.1092)。这是因为MIMO模型针对同一工业过程的对象的多任务学习具有协调兼顾的能力, 模型对多个任务的学习可以彼此助益且多个输出任务之间具有互补性与容错性。MIMO-TSFNN能够利用多个学习任务中所包含的有用信息帮助每个任务学习, 从而得到更为准确的回归模型。

2) 结合图13中模型训练过程的RMSE变化可知, 不同网络均实现了对MSWI被控对象的建模。此外, 模型对不同回归任务的收敛速度也体现出差异性, RBFNN与BPNN的收敛速度相对较慢, 学习能力也相对较弱, 而MIMO-FNN在收敛速度上具有明显的优势且学习能力较强, 这是因为其兼具模糊系统的非线性处理与分析能力, 且其利用了多任务之间的多个损失函数, 提高了网络的学习能力, 具有更强的动态优化能力。




图 14 模型训练过程参数变化

Fig. 14 Parameters changes during model training




图 15 训练样本拟合效果

Fig. 15 Training sample fitting effect




图 16 测试样本拟合效果

Fig. 16 Testing sample fitting effect

3) 结合图14可知, 网络共享的隶属函数层神经元具有同步调整中心、宽度的能力, 后件子网络的模糊系统参数能够针对不同输出任务进行校正, 各参数学习速度较快. 分析图15-16可知, 模型能够同步输出多个参数, 网络训练及测试的拟合效果好, 对强非线性实际工业数据具有较强的逼近能力.

5 结论

MSWI过程具有多对象、多参量、强耦合和大时变等特征, 是一个高度复杂的强非线性过程, 构建该过程的被控对象模型是研究其优化控制的基础. 针对这一问题, 本文建立数据驱动MIMO-TSFNN的被控对

象模型, 其具有如下贡献: 解决了MSWI过程内部机理难以分析, 多变量耦合性强、内部规则难以挖掘的问题, 为研究该过程的优化控制奠定了模型基础; 针对工艺特点, 设计了具有多工况识别与特征约简的建模策略, 模型具有较好的鲁棒性与适用性; 建立的MIMO-TSFNN模型具有多输出学习能力, 利用多任务之间的互补信息同时对多个被控量进行精准拟合, 并对网络参数进行在线更新. 综上所述, 本文提出的基于MIMO-TSFNN的MSWI过程被控对象建模方法具有多任务学习能力, 建模精度较高, 针对炉排炉被控对象建模具有一定的应用价值.

参考文献:

- [1] LU J W, ZHANG S K, HAI J, et al. Status and perspectives of municipal solid waste incineration in China: A comparison with developed regions. *Waste Management*, 2017, 69: 170 – 186.
- [2] KORAI M S, MAHAR R B, UQAILI M A. The feasibility of municipal solid waste for energy generation and its existing management practices in Pakistan. *Renewable and Sustainable Energy Reviews*, 2017, 72: 338 – 353.
- [3] DING H, TANG J, QIAO J. Control methods of municipal solid wastes incineration process: A survey. *The 40th Chinese Control Conference*. Shanghai: IEEE, 2021: 662 – 667.
- [4] MAGNANELLI E, TRANÁS O L, CARLSSON P, et al. Dynamic modeling of municipal solid waste incineration. *Energy*, 2020, 209: 118426.
- [5] DING H, TANG J, QIAO J. Multi-input and multi-output modeling method based on TS fuzzy neural network and its application. *The 3rd International Conference on Industrial Artificial Intelligence*. Shenyang: IEEE, 2021: 1 – 6.
- [6] ZHAO G L, CHENG S S, XU W X, et al. Comprehensive mathematical model for particle flow and circumferential burden distribution in charging process of bell-less top blast furnace with parallel hoppers. *ISIJ International*, 2015, 55(12): 2566 – 2575.
- [7] DONG F, YAN C, ZHOU C Q. Mathematical modeling of blast furnace burden distribution with non-uniform descending speed. *Applied Mathematical Modelling*, 2015, 39(23/24): 7554 – 7567.
- [8] WLAZŁO M, ALEVIZOU E I, VOUTSAS E C, et al. Prediction of ionic liquids phase equilibrium with the COSMO-RS model. *Fluid Phase Equilibria*, 2016, 424: 16 – 31.
- [9] XIE Qiang. *Energy Utilization Technology of Municipal Solid Waste*. Second edition. Beijing: Chemical Industry Press, 2018: 129 – 140. (解强. 城市固体废弃物资源化利用技术. 第2版. 北京: 化学工业出版社, 2018: 129 – 140.)
- [10] DING H X, LI W J, QIAO J F. A self-organizing recurrent fuzzy neural network based on multivariate time series analysis. *Neural Computing and Applications*, 2021, 33(10): 5089 – 5109.
- [11] LI D, HAN H, QIAO J. Deterministic learning-based adaptive neural control for nonlinear full-state constrained systems. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, DOI: 10.1109/TNNLS.2021.3126320, 2021.
- [12] QIAO Junfei, DING Haixu, LI Wenjing. Structure design for recurrent fuzzy neural network based on wavelet transform fuzzy Markov chain. *Acta Automatica Sinica*, 2020, 46(11): 2367 – 2378. (乔俊飞, 丁海旭, 李文静. 基于WTFMC算法的递归模糊神经网络结构设计. 自动化学报, 2020, 46(11): 2367 – 2378.)
- [13] SHUMIXIN A G, ALEKSANDROVA A S. Identification of a controlled object using frequency responses obtained from a dynamic neural network model of a control system. *Computer Research and Modeling*, 2017, 9(5): 729 – 740.
- [14] WU Hengyun, GAO Lin, TIAN Jianyong, et al. Intelligent combustion control model for utility boilers based on asymmetric artificial neural networks. *Thermal Power Generation*, 2017, 46(12): 6 – 10, 17. (吴恒运, 高林, 田建勇, 等. 基于非对称神经网络结构的电站锅炉智能燃烧控制模型. 热力发电, 2017, 46(12): 6 – 10, 17.)
- [15] HAN Gaitang, QIAO Junfei, HAN Honggui. Wastewater treatment control method based on adaptive recurrent fuzzy neural network. *Control Theory & Applications*, 2016, 33(9): 1252 – 1258. (韩改堂, 乔俊飞, 韩红桂. 基于自适应递归模糊神经网络的污水处理控制. 控制理论与应用, 2016, 33(9): 1252 – 1258.)
- [16] ZHANG Wei, QIAO Junfei, LI Fanjun. Direct adaptive dynamic neural network control for dissolved oxygen concentration. *Control Theory & 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.)
- [17] DING Haixu, LI Wenjing, YE Xudong, et al. BOD soft-sensing based on self-organizing recurrent fuzzy neural network. *Computers and Applied Chemistry*, 2019, 36(4): 331 – 336. (丁海旭, 李文静, 叶旭东, 等. 基于自组织递归模糊神经网络的BOD软测量. 计算机与应用化学, 2019, 36(4): 331 – 336.)
- [18] ZHENG K M, ZHANG Q J, HU Y M, et al. Design of fuzzy system-fuzzy neural network-backstepping control for complex robot system. *Information Sciences*, 2021, 546: 1230 – 1255.
- [19] LIN Y, CHANG J, LIN C. A TSK-type-based self-evolving compensatory interval type-2 fuzzy neural network (TSCIT2FNN) and its applications. *IEEE Transactions on Industrial Electronics*, 2013, 61(1): 447 – 459.
- [20] HAN H G, LI J M, WU X L, et al. Cooperative strategy for constructing interval type-2 fuzzy neural network. *Neurocomputing*, 2019, 365(6): 249 – 260.
- [21] FAN Zheng, JI Panpan, LI Chao, et al. Synthetic process optimization of benzyl acrylate using fuzzy neural networks-genetic algorithms. *CIESC Journal*, 2019, 70(11): 4315 – 4324. (范峥, 姬盼盼, 李超, 等. 模糊神经网络-遗传算法优化丙烯酸苄酯合成工艺. 化工学报, 2019, 70(11): 4315 – 4324.)
- [22] ZHANG Xiuling, DAI Jinghuan, KANG Xuenan, et al. Plate data modeling based on multiple RBF neural networks. *Mining and Metallurgical Engineering*, 2019, 39(6): 124 – 128. (张秀玲, 代景欢, 康学楠, 等. 基于多RBF神经网络的板形数据建模. 矿冶工程, 2019, 39(6): 124 – 128.)
- [23] ASGHAR M A, KHAN M J, RIZWAN M, et al. An innovative multi-model neural network approach for feature selection in emotion recognition using deep feature clustering. *Sensors*, 2020, 20(13): 3765.
- [24] LIU X J, KONG X B, HOU G L, et al. Modeling of a 1000 MW power plant ultra super-critical boiler system using fuzzy-neural network methods. *Energy Conversion and Management*, 2013, 65: 518 – 527.
- [25] GUO Min, ZHU Shuguang, HAN Honggui. Soft-sensor method for total phosphorus and ammonia nitrogen based on fuzzy neural network. *Computers and Applied Chemistry*, 2017(1): 82 – 87. (郭民, 祝曙光, 韩红桂. 基于模糊神经网络的出水总磷和氨氮软测量方法研究. 计算机与应用化学, 2017(1): 82 – 87.)
- [26] SHEN C, BAO X J, TAN J B, et al. Two noise-robust axial scanning multi-image phase retrieval algorithms based on Pauta criterion and smoothness constraint. *Optics Express*, 2017, 25(14): 16235 – 16249.
- [27] DING H. *Design of Self-organizing Recurrent Fuzzy Neural Network and Its Application in Wastewater Treatment*. Beijing: Beijing University of Technology, 2020.

作者简介:

丁海旭 博士研究生, 主要研究方向为城市固废焚烧过程特征建模与智能控制等, E-mail: dinghaixu@emails.bjut.edu.cn;

汤健 教授, 博士生导师, 主要研究方向为小样本数据驱动建模、城市固废焚烧过程智能优化控制等, E-mail: freeflytang@bjut.edu.cn;

夏恒 博士研究生, 主要研究方向为城市固废焚烧过程二噁英排放智能预测, E-mail: xiaheng@emails.bjut.edu.cn;

乔俊飞 教授, 博士生导师, 教育部长江学者特聘教授, 主要研究方向为智能控制与智能信息处理、环境感知与保护自动化技术等, E-mail: adqiao@bjut.edu.cn.