

AR-ELM在SOFC参数辨识中的应用

李博远, 简献忠, 杨翼天, 邹杰信, 胡子翼

上海理工大学光电信息与计算机工程学院, 上海

收稿日期: 2025年3月11日; 录用日期: 2025年4月4日; 发布日期: 2025年4月14日

摘要

针对 I - V 特性数据集不足时会使启发式算法(MhAs)对SOFC的参数辨识精度不高的问题, 本文提出了一种基于自适应正则化极限学习机算法(AR-ELM)的MhAs辨识策略——AR-ELM-MhAs。首先, 引入验证误差反馈机制, 根据验证集精度自适应调整传统ELM中正则化项的正则化系数, 从而加强算法的泛化能力, 提高数据预测精度。其次, 利用改进后的AR-ELM对两种不同条件的SOFC原始 I - V 特性数据进行训练并预测, 对数据集进行扩展, 从而为MhAs的参数辨识提供更可靠的 I - V 特性数据。最后, 将MhAs应用于扩展后的数据集的SOFC参数辨识中, 对比不同数据预处理下MhAs对SOFC的参数辨识效果, 以探究所提策略的可行性和改进的有效性。对比实验结果表明, AR-ELM-MhAs有效提高了SOFC参数辨识的精度。

关键词

固体氧化物燃料电池, 参数辨识, 极限学习机, 启发式算法, 数据预测

Application of AR-ELM in SOFC Parameter Identification

Boyuan Li, Xianzhong Jian, Yitian Yang, Jiexin Zou, Ziyi Hu

School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Mar. 11th, 2025; accepted: Apr. 4th, 2025; published: Apr. 14th, 2025

Abstract

To address the accuracy degradation of metaheuristic algorithms (MhAs) in solid oxide fuel cell (SOFC) parameter identification under insufficient I - V characteristic datasets, this study proposes a novel AR-ELM-enhanced MhAs strategy (AR-ELM-MhAs). First, we introduce a validation error feedback mechanism to adaptively adjust the regularization coefficient of the regularization term in traditional Extreme Learning Machine (ELM) based on the accuracy of the validation set. This enhances the

algorithm's generalization ability and improves the accuracy of data prediction. Second, the improved AR-ELM is used to train and predict the raw I - V characteristic data of SOFC under two different conditions, thereby expanding the dataset and providing more reliable I - V characteristic data for the parameter identification of MhAs. Finally, MhAs are applied to the parameter identification of SOFC using the expanded dataset, and the parameter identification performance of MhAs under different data preprocessing methods is compared to explore the feasibility and effectiveness of the proposed strategy. The comparative experimental results indicate that the AR-ELM-MhAs approach significantly improves the accuracy of SOFC parameter identification.

Keywords

Solid Oxide Fuel Cell (SOFC), Parameter Identification, Extreme Learning Machine (ELM), Metaheuristic Algorithms, Data Prediction

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

固体氧化物燃料电池(SOFC)因其燃料适应性强和能源转换效率高,在分布式发电与储能领域具有重要应用价值。在 SOFC 系统优化研究中,精确的参数辨识是构建可靠电化学模型、实现性能预测与寿命评估的关键技术基础[1]。该过程的准确性直接影响着系统控制策略的制定和材料体系的优化设计。

传统的参数辨识方法包括数学解析法如牛顿法[2]、最小二乘法[2]等。然而这些算法在面对 SOFC 参数辨识这类非线性问题时存在较大的缺点和不足导致辨识精度较低[3]。相比之下,基于启发式算法(Meta-Heuristic Algorithms, MhAs)的参数辨识方法,通过搜索和优化等方式可以更好地处理非线性问题,逐渐成为燃料电池模型参数辨识优化问题的主流。如文献[4]利用粒子群算法(PSO)对燃料电池模型参数辨识问题进行求解,可以在非线性模型中找到最优解或近似最优解;文献[5]采用灰狼优化算法(GWO)对 SOFC 模型进行参数辨识,可以以较快的收敛速度搜索到全局最优解;此外,其他先进的 MhAs 在 SOFC 参数辨识领域中也有着广泛、有效的应用,例如:白头鹰搜索算法[6]、非洲秃鹫优化器(AVO) [7]等。

然而,现有 SOFC 参数辨识的相关研究较少关注在实际工程场景中因测量不易或厂家不提供等因素导致实际 SOFC 电池或发电系统的 I - V 数据集不足,对 SOFC 电池参数辨识造成干扰,导致其辨识结果的误差增大,在后续实际应用产生不良影响的情况。因此,对数据量不足的数据集进行合理的扩充显得尤为重要。

其中人工神经网络技术(ANN)凭借自主学习能力,通过模拟人脑神经元的协同以实现信息的传递和处理,在数据预测领域得到了广泛关注。其中卷积神经网络(CNN)能通过深层特征的提出实现了多变量的时序数据预测[8],文献[9]将其应用于锂电池的剩余寿命预测当中,然而其复杂的网络结构以及对数据的需求量较高的特点,在对 SOFC 不足的原始 I - V 数据扩展的小样本场景中效率较低且并不适用;而极限学习机(ELM)技术采用随机权重初始化与解析解计算策略,在保证预测精度的同时将训练耗时降低 1~2 个数量级[10],凭借其较低的计算成本和较高的预测精度为数据预测提供了更加高效的解决思路。然而传统的极限学习机技术在面对不同的实际需求时也有一些缺陷,为此,研究学者们提出了许多关于 ELM 的改进优化算法。如 Lan 等[11]引入随机搜索方法,提出了一种增强型 EM-ELM 算法,更科学地确定了 ELM 的隐藏层节点个数,使网络结构化更为紧凑;然而,相较上述改进方向,在 SOFC 参数辨识研究中所用

的 I - V 特性数据集扩展的实验研究中,更需要一种可以提高 ELM 泛化能力的同时保证算法的数据集扩展的运算效率的改进策略,基于此,本文通过验证误差的实时反馈机制,动态调整正则化系数的自适应改进策略,提出了一种自适应正则化极限学习机策略(AR-ELM)。为验证所提算法改进的有效性,采用两种不同条件下的 SOFC I - V 特性数据集,并基于原始 ELM 和 AR-ELM 对两种数据集进行扩充,并与四种典型的启发式辨识算法相结合,应用于的 SOFC 参数辨识仿真实验,研究本文所提出的 AR-ELM 对 SOFC 参数辨识精度提升的有效性。实验结果表明,基于提出的 AR-ELM 策略的数据预测扩展后的数据集,利用 4 种启发式算法的 SOFC 参数辨识实验中其性能均优于基于改进前 ELM 和原始数据集。

2. 固体氧化物燃料电池系统建模

2.1. SOFC 电化学模型

近年来,固体氧化物燃料电池(SOFC)的数学建模研究取得突破性进展,逐步形成了包含电化学模型(ECM)、降阶模型、稳态模型和动态模型在内的完整建模体系。其中,基于 Butler-Volmer 方程构建的完整电化学模型因其卓越的预测精度,在系统优化与控制领域获得广泛应用。本研究聚焦该模型的参数辨识问题,旨在通过改进辨识算法提升模型实用价值。

在典型 ECM 架构中,电池输出电压可分解为 Nernst 平衡电势与三类极化损耗的综合体现[12]:

$$V_{\text{out}} = E_0 - V_{\text{act}} - V_{\text{con}} - V_{\text{om}} \quad (1)$$

式中: E_0 表征理想条件下的可逆电势; V_{act} 、 V_{con} 、 V_{om} 分别对应活化极化、浓差极化和欧姆极化损耗。各极化项的物理建模直接影响模型精度:

活化极化项采用双电极修正的 Butler-Volmer 方程描述:

$$V_{\text{act}} = A_r \left[\operatorname{arcsinh} \left(\frac{I_{\text{load}}}{2I_{\text{a0}}} \right) + \operatorname{arcsinh} \left(\frac{I_{\text{load}}}{2I_{\text{c0}}} \right) \right] \quad (2)$$

式中,变量 I_{load} 和 I_0 分别代表负载电流密度和交换电流密度,单位 mA/cm^2 ; $A_r = \frac{R \cdot T}{F}$ 代表 Tafel 曲线斜率,单位为伏特(V)。为考虑阴阳两极电化学反应的差异性,该式通过分离阳极交换电流密度 I_{a0} 和阴极交换电流密度 I_{c0} ,保证模型的精准度。

浓差极化项建模采用极限电流密度约束方程:

$$V_{\text{con}} = -B \ln \left(1 - \frac{I_{\text{load}}}{I_{\text{max}}} \right) \quad (3)$$

式中 B 为浓差极化系数, I_{max} 表征物质传输极限条件下的临界电流密度。欧姆损耗项遵循改进型欧姆定律:

$$V_{\text{om}} = RI_{\text{load}} \quad (4)$$

其中 R 不仅包含本征体电阻,还计入了接触电阻等二次损耗因素。

综合上述子模型,系统输出电压方程可表述为:

$$V_{\text{out}} = E_0 - A_r \operatorname{arcsinh} \left(\frac{I_{\text{load}}}{2I_{\text{a0}}} \right) - A_r \operatorname{arcsinh} \left(\frac{I_{\text{load}}}{2I_{\text{c0}}} \right) - RI_{\text{load}} + B \ln \left(1 - \frac{I_{\text{load}}}{I_{\text{max}}} \right) \quad (5)$$

该模型包含 E_0 、 A_r 、 B 、 I_{a0} 、 I_{c0} 、 I_{max} 、 R 等 7 个待辨识参数,其物理意义明确但存在强非线性耦合特性,构成复杂的参数辨识问题。

2.2. SOFC 参数辨识评价函数

为精确辨识出 ECM 模型中的 7 个未知参数, 需要最小化实验数据与模型数据之间的误差: 本文采用均方根误差作为评价 SOFC 参数辨识精度的适应度函数, 如下所示:

$$e_{\text{RMSE}}(x) = \sqrt{\frac{1}{K} \sum_{k=1}^K [V_k - V_{\text{out}}(\mathbf{x}, I_k)]^2} \quad (6)$$

式中 k 为数据集中数据的个数; I_k 是数据集中的第 k 个电流密度; V_k 为数据集中的第 k 个输出电压; V_{out} 是模型输出电压。

3. AR-ELM 算法设计

3.1. ELM 基本原理

极限学习机(ELM)作为一种单隐层前馈神经网络, 其核心优势在于随机化隐层参数与解析式权值求解相结合的建模策略。

对于给定训练数据集 $\{(\mathbf{x}_i, \mathbf{t}_i) | \mathbf{x}_i \in \mathbf{R}^n, \mathbf{t}_i \in \mathbf{R}^m, i = 1, 2, \dots, N\}$, 其中 $\mathbf{x}_i \in \mathbf{R}^n$ 为输入向量, $\mathbf{t}_i \in \mathbf{R}^m$ 为期望输出, 隐层节点数设为 L 。算法首先随机生成输入权重矩阵 $\omega_i \in \mathbf{R}_n$ 和隐层偏置 $b_i \in \mathbf{R}$, 并通过非线性激活函数 $g(\cdot)$ 构建隐层特征空间。单个隐层节点对输入样本 x 的输出响应可表示为[13]:

$$h_i(x) = g(\omega_i^T x + b_i) \quad (7)$$

由此可得全体训练样本的隐层输出矩阵 $H \in \mathbf{R}^{N \times L}$, 其第 i 行对应样本 $\mathbf{x}_i$ 的隐层特征映射:

$$H = \begin{bmatrix} h(\mathbf{x}_1) \\ \vdots \\ h(\mathbf{x}_N) \end{bmatrix} \quad (8)$$

输出层权重 $\beta \in \mathbf{R}^{L \times m}$ 通过最小化正则化损失函数解析确定:

$$\min_{\beta} \|H\beta - T\|_F^2 \quad (9)$$

其中 $T \in \mathbf{R}^{N \times m}$ 为期望输出矩阵, $\|\cdot\|_F$ 表示 Frobenius 范数, 根据 Moore-Penrose 广义逆理论, 该优化问题具有闭式解:

$$\beta = H^+ T \quad (10)$$

式中 H^+ 为隐含层输出矩阵 H 的 Moore-Penrose 广义逆矩阵。可通过奇异值分解稳定求解。这种将非线性网络训练转化为线性系统求逆的机制, 使 ELM 在保证逼近精度的同时获得确定性的全局最优解, 显著提升了算法的训练效率与数值稳定性。

3.2. 自适应正则化极限学习机(AR-ELM)

在极限学习机(ELM)的训练中, 随机生成的隐藏层权重和偏置可能导致隐层输出矩阵 H 病态[14], 特别是在样本量不足或特征相关性较高的情况下。这种不稳定性可能导致输出权重解 β 的数值波动, 进而影响模型的可靠性。为了改善这一问题, 常常引入正则化, 通过对输出权重 β 的范数或稀疏性进行约束, 平衡模型的拟合能力与泛化能力, 从而确保数值求解的稳定性。如下所示:

$$\beta = (H^T H + \lambda I)^{-1} H^T T \quad (11)$$

在传统的 ELM 中, 正则化系数 λ 通常设为固定值, 但这种方法在样本量稀缺的情况下无法有效平衡模型复杂性与泛化能力。针对该问题, 本文提出一种基于验证误差反馈的自适应正则化改进方法(AR-ELM)。其核心思想是通过验证集误差实时反馈动态调整正则化系数 λ , 实现模型复杂度与泛化能力的自适应平衡。

具体来说, 首先将原始数据集 D 按 8:2 的比例划分为训练集 D_{train} 与验证集 D_{val} , 其中训练集用于模型的训练, 验证集用于监控模型的泛化性能。验证集误差 $E_{\text{val}}(t)$ 定义为第 t 次迭代时的均方误差(MSE), 其计算公式为:

$$E_{\text{val}}(t) = \frac{1}{N_{\text{val}}} \sum_{j=1}^{N_{\text{val}}} (t_j - \hat{t}_j)^2 \quad (12)$$

式中, $\hat{t}_j$ 表示第 t 次迭代时验证样本 x_j 的预测值。基于此, 正则化系数 λ 的动态更新规则定义为:

$$\lambda(t+1) = \lambda(t) \cdot \left(1 + \alpha \cdot \frac{E_{\text{val}}(t)}{\max(E_{\text{val}})} \right) \quad (13)$$

式中 $\alpha \in [0.1, 0.2]$ 为调节因子, 分母项通过历史最大误差归一化抑制参数震荡。当验证误差上升时, 增大 λ 以强化正则化约束; 误差下降时则减小 λ 以释放模型容量, 形成闭环反馈机制。

在每次训练过程中, 根据调整后的正则化系数 λ , 重新计算输出权重 β 。将输出权重的计算公式(10)更新为:

$$\beta(t) = (H^T H + \lambda(t) I)^{-1} H^T T \quad (14)$$

与传统的固定正则化系数方法相比, AR-ELM 算法通过引入基于验证误差的动态反馈机制, 使得模型能够根据训练过程中的误差变化动态调整正则化系数, 从而在对小样本数据(SOFC 的 I - V 特性数据集)下实现更好的泛化性能和更强的鲁棒性。

3.3. AR-ELM 操作步骤




Figure 1. AR-ELM algorithm flowchart
图 1. AR-ELM 算法流程图

AR-ELM 算法的整体流程图如图 1 所示。

4. 算例分析

为进一步探究所提出的 AR-ELM 对 SOFC 数据集扩展后对基于 MhAs 的 SOFC 参数辨识结果改进的有效性。本文基于 4 种先进的 MhAs 算法, 包括 PSO、GWO、BES、AVO 对式(5) SOFC 电化学模型中的 7 个参数进行辨识。同时实验分别选择一种单体 SOFC 电池和一种堆栈 SOFC 电池的 I - V 特性数据作为 SOFC 参数辨识的研究对象, 并利用 ELM 和 AR-ELM 两种技术分别对原始数据集进行预测并扩展, 并应用于基于启发式算法的 SOFC 参数辨识实验当中。

为确保实验结果的公平和所得结论的准确性, 将所有算法的最大迭代次数均设置为 500 次, 初始种群为 $N=30$ 。所有仿真配置为 Intel (R) Core (TM) i7-8750H CPU @ 2.20GHz, 16.0 GB RAM, 64 位 Windows 10 的个人电脑上通过 MATLAB 2021b 环境运行。


4.1. 单体 SOFC 参数辨识实验

本小节采用波兰 CEREL 公司制造的支撑式单体固体氧化物燃料电池(SOFC)测试数据集[15], 包含 21 组 I - V 特性数据。本小节实验将其中 16 组数据用于训练, 6 组数据用于测试, 分别基于 ELM 和 AR-ELM 算法进行训练, 并等间隔预测出 11 组新 I - V 特性数据, 最终将原 CEREL 单体 SOFC 电池数据集扩展至 32 组。训练实验结果如表 1 所示。

Table 1. CEREL monomer SOFC data prediction performance results
表 1. CEREL 单体 SOFC 数据预测性能结果

方法	训练误差(RMSE)	测试误差(RMSE)
原始 ELM	4.3315e^{-3}	1.0637e^{-2}
AR-ELM	5.8940e^{-3}	9.5213e^{-3}

从实验结果可见, AR-ELM 技术通过牺牲较小的训练精度, 从而降低对训练数据的拟合程度换取更优秀的泛化能力, 并相较于原 ELM 显著减少了测试误差, 从 2.06e^{-2} 降至 9.52e^{-3} , 进一步证明了 AR-ELM 具有更好的数据预测能力, 且在 CEREL 单体 SOFC 数据集预测中能获得更为准确的 I - V 特性数据。






Figure 2. Comparison of convergence curves of various algorithms before and after the CEREL monomer SOFC dataset
图 2. 对 CEREL 单体 SOFC 数据集前后的各算法的收敛曲线对比

在验证了 ELM 和 AR-ELM 对 CEREL 单体 SOFC 数据集预测性的可行性后，将两种算法的预测输出加入到原始数据集并应用于基于参数辨识实验中。各算法的三种实验数据(预测前实验数据、基于 ELM 预测后的和基于 AR-ELM 预测后的实验数据)下的收敛曲线图如图 2 所示。

从图 2 中各算法参数辨识结果对比可以看到，AR-ELM 算法预测扩展后的数据集可以大幅提高算法基于原始 CEREL 单体 SOFC 数据和基于 ELM 扩充后的数据集的参数辨识精度和收敛速度，验证了所提出的对 ELM 技术改进的有效性以及所提出的数据集扩展策略对 SOFC 参数辨识精度提升的有效性。

表 2 为各算法在对三种数据集参数辨识下的最优 RMSE 结果对比，其中原始数据集参数辨识结果用符号“N”表示，基于 ELM 技术的数据预测的参数辨识结果用符号“E”表示，基于 AR-ELM 技术的数据集扩展后的参数辨识结果用符号“A”表示；综合表 2 各算法对 SOFC 三种数据集参数辨识的结果来看，基于 AR-ELM 技术在 SOFC 参数辨识应用中可以更有效地提高各算法的参数辨识精度。

Table 2. Comparison of optimal RMSE results of various algorithms before and after prediction on the EREL monomer SOFC dataset
表 2. EREL 单体 SOFC 数据预测前后各算法的最优 RMSE 结果对比

算法	符号	所需辨识的参数							RMSE (V)
		E_0 (V)	A_T (V)	B (V)	I_{a0} (mA/cm ²)	I_{c0} (mA/cm ²)	I_{max} (mA/cm ²)	R (k Ω ·cm ²)	
PSO	N	1.085	0.0451	0.7088	247.4177	161.4515	1188.3507	2.833e ⁻³	2.4354e ⁻³
	E	1.084	0.0796	0.6844	238.4033	93.4563	1832.4981	1.024e ⁻³	1.9073e ⁻³
	A	1.090	0.0547	0.5942	189.4023	65.4015	1653.9077	9.380e ⁻⁴	1.3500e ⁻³
GWO	N	1.094	0.0941	0.6311	231.7576	71.8741	1997.3992	2.093e ⁻³	2.2118e ⁻³
	E	1.084	0.2011	0.8431	199.0357	18.9304	1938.7821	7.341e ⁻⁴	1.4437e ⁻³
	A	1.089	0.0887	0.6108	237.4556	100.3844	1920.2215	3.408e ⁻⁴	1.1220e ⁻³
BES	N	1.088	0.248	0.6355	133.0083	24.6090	1372.3345	1.227e ⁻³	1.5532e ⁻³
	E	1.083	0.1077	0.9011	116.1326	138.7114	1477.7879	5.640e ⁻⁴	1.0337e ⁻³
	A	1.083	0.0714	0.5774	269.5648	48.5331	1480.0733	8.471e ⁻⁴	8.3722e ⁻⁴
AVO	N	1.088	0.1405	0.6532	215.9875	148.9349	1636.0894	9.034e ⁻⁴	1.5918e ⁻³
	E	1.085	0.0473	0.7955	232.5682	34.4326	1757.5189	1.304e ⁻³	9.8113e ⁻⁴
	A	1.092	0.0697	0.7854	201.1911	108.3349	1525.3906	7.231e ⁻⁴	7.6554e ⁻⁴

4.2. 堆栈 SOFC 参数辨识实验

本小节选用华中科技大学(HUST)研制的 1 kW 级平板式 SOFC 堆栈电池组的实验测量所得的 I - V 特性数据[16]来研究 PSO、GWO、BES 和 AVO 四种算法在 SOFC 参数辨识中的性能的提升效果。现有的 HUST 堆栈 SOFC 电池 I - V 特性数据集中包含 18 组数据, 从现有的 18 组数据中选取 13 组为训练数据, 5 组为测试数据。并分别基于 ELM 和 AR-ELM 技术学习现有数据的特性并进行训练和测试, 所得实验结果如表 3 所示。

Table 3. HUST stack SOFC data prediction performance results
表 3. HUST 堆栈 SOFC 数据预测性能结果

方法	训练误差(RMSE)	测试误差(RMSE)
原始 ELM	1.0219e^{-2}	4.116e^{-2}
AR-ELM	1.3668e^{-2}	2.8675e^{-2}




Figure 3. Comparison of convergence curves of various algorithms before and after the HUST stack SOFC dataset
图 3. 对 HUST 堆栈 SOFC 数据集前后的各算法的收敛曲线对比

从实验结果来看,AR-ELM 算法较传统 ELM 算法在测试误差上有所下降(从 4.116e^{-2} 降至 2.8675e^{-2}),且训练误差和测试误差之间的差距较小,表明该算法在改善训练稳定性和泛化能力方面表现更优,验证了它们在 HUST 堆栈 SOFC 数据集上的预测能力具有可行性。

在此基础上,分别利用 ELM 和 AR-ELM 算法等间隔预测出 12 组新的 I - V 特性数据,扩展原数据集至 30 组。随后,将扩展后的数据集应用于 SOFC 参数辨识实验(实验设置与第四章相同)。基于这两种数据集,各算法的参数辨识实验收敛曲线如图 3 所示。

从图 3 中的各算法参数辨识结果的收敛曲线可以看出,基于 AR-ELM 处理后的数据集相比于基于 ELM 处理的数据集,在各算法的收敛速度上表现更优。这进一步验证了 AR-ELM 改进策略的有效性,显著提升了 ELM 的抗过拟合能力和泛化能力,从而增强了各算法在 SOFC 参数辨识中的性能表现。

表 4 为各算法在对三种数据集参数辨识下的最优 RMSE 结果对比,从参数辨识结果来看,AR-ELM 数据预测扩展后的参数辨识精度较改进前有较大提升,尤其对于搜索能力较强的 AVO 算法来说,可以进一步发挥算法的寻优能力,从而提高对 SOFC 参数辨识的精度。

Table 4. Comparison of the optimal RMSE results of each algorithm before and after HUST stack SOFC data prediction
表 4. HUST 堆栈 SOFC 数据预测前后各算法的最优 RMSE 结果对比

算法	符号	所需辨识的参数							RMSE (V)
		E_0 (V)	A_T (V)	B (V)	I_{a0} (mA/cm ²)	I_{c0} (mA/cm ²)	I_{max} (mA/cm ²)	R (k Ω ·cm ²)	
PSO	N	1.085	0.0715	0.6340	77.8180	38.1066	1055.4257	3.62e^{-4}	2.4354e^{-3}
	E	1.084	0.1092	0.6857	242.1396	131.2685	866.6353	3.93e^{-3}	1.9073e^{-3}
	A	1.088	0.092	0.1237	299.4562	323.1159	1278.3542	1.25e^{-3}	1.3500e^{-3}
GWO	N	1.086	0.0843	0.0258	235.2333	221.2598	1008.0038	3.57e^{-3}	2.2118e^{-3}
	E	1.092	0.274	0.012	140.0660	58.8408	1906.1221	1.8479e^{-4}	1.4437e^{-3}
	A	1.088	0.0316	0.0335	11.2685	62.8461	987.5643	3.65e^{-3}	1.1220e^{-3}
BES	N	1.090	0.4536	0.3581	68.8495	101.8456	1357.5645	7.65e^{-4}	1.5532e^{-3}
	E	1.088	0.1267	0.1689	152.3633	110.8460	987.5861	8.17e^{-4}	1.0337e^{-3}
	A	1.093	0.0320	0.0417	18.9793	529.0021	776.0636	3.812e^{-3}	8.3722e^{-4}
AVO	N	1.088	0.0156	0.0567	25.4865	56.3442	1354.7866	1.22e^{-3}	1.5918e^{-3}
	E	1.091	0.0356	0.0816	137.5644	255.8635	1325.8562	1.86e^{-3}	9.8113e^{-4}
	A	1.083	0.0931	0.0896	76.9854	79.8795	1477.7879	6.225e^{-4}	7.6554e^{-4}

综上,本文通过对两种不同条件的 SOFC 数据集的预测扩展,并将其应用于基于启发式算法的 SOFC 参数辨识实验,其结果显示,所提出的 AR-ELM 相较原 ELM 可以更精准地对 SOFC 参数辨识实验数据集进行预测扩展,同时对 SOFC 参数辨识的精度也有较大提升。

5. 结论

针对 SOFC 原始数据集不足或缺失而导致参数辨识精度较低的问题,本文提出了基于自适应正则化极限学习机(AR-ELM)的数据扩展方法,并结合启发式算法 MhAs 进行 SOFC 模型参数辨识。本文对一种单体 SOFC 和一种堆栈 SOFC 的 I - V 特性数据集分别使用 4 种 MhAs 算法进行了 SOFC 参数辨识的仿真实验,并与原始数据集进行对比。实验结果表明,在单体和堆栈两种 SOFC 数据集下,AR-ELM 方法通过引入基于验证误差的自适应调整策略,显著提升了模型的泛化能力,并降低了过拟合的风险,确保了

对 SOFC 的 I - V 特性数据集预测扩展的可行性。采用 AR-ELM 预测扩展后的数据集在参数辨识实验中的收敛速度和精度明显优于基于 ELM 预测扩展后和原始数据集的辨识结果, 各算法在辨识过程中的收敛速度较原始数据集更快, 参数辨识过程中更加准确的结果, 进一步验证了 AR-ELM 在提升 SOFC 参数辨识精度和稳定性方面的优越性。因此, 本文所提的 AR-ELM-MhAs 参数辨识方法, 能够有效解决 SOFC 参数辨识中数据不足或缺失带来的辨识误差问题, 为实际应用中提供了更加可靠的解决方案。

基金项目

大学生创新创业训练计划 XJ2024063。

参考文献

- [1] Xu, Q. and Ni, M. (2020) Modelling of High Temperature Direct Methanol Solid Oxide Fuel Cells. *International Journal of Energy Research*, **45**, 3097-3112. <https://doi.org/10.1002/er.6003>
- [2] Huo, H., Zhong, Z., Zhu, X. and Tu, H. (2008) Nonlinear Dynamic Modeling for a SOFC Stack by Using a Hammerstein Model. *Journal of Power Sources*, **175**, 441-446. <https://doi.org/10.1016/j.jpowsour.2007.09.059>
- [3] Liu, X., Li, R., Cao, R., et al. (2011) Parameter Identification of Solid Oxide Fuel Cells Based on Kriging Interpolation. *Electric Power Systems Research*, **17**, 1633-1638.
- [4] Salim, R., Nabag, M., Noura, H. and Fardoun, A. (2015) The Parameter Identification of the Nexa 1.2 kW PEMFC's Model Using Particle Swarm Optimization. *Renewable Energy*, **82**, 26-34. <https://doi.org/10.1016/j.renene.2014.10.012>
- [5] Chen, X., Yi, Z., Zhou, Y., Guo, P., Farkoush, S.G. and Niroumandi, H. (2021) Artificial Neural Network Modeling and Optimization of the Solid Oxide Fuel Cell Parameters Using Grey Wolf Optimizer. *Energy Reports*, **7**, 3449-3459. <https://doi.org/10.1016/j.egyr.2021.05.068>
- [6] Rezk, H., Ferahtia, S., Sayed, E.T., Abdelkareem, M.A. and Olabi, A.G. (2022) Robust Parameter Identification Strategy of Solid Oxide Fuel Cells Using Bald Eagle Search Optimization Algorithm. *International Journal of Energy Research*, **46**, 10535-10552. <https://doi.org/10.1002/er.7790>
- [7] Yakout, A.H., Kotb, H., AboRas, K.M. and Hasanien, H.M. (2022) Comparison among Different Recent Metaheuristic Algorithms for Parameters Estimation of Solid Oxide Fuel Cell: Steady-State and Dynamic Models. *Alexandria Engineering Journal*, **61**, 8507-8523. <https://doi.org/10.1016/j.aej.2022.02.009>
- [8] Alkha, M., Venkatesan, M., Prabhavathy, P., et al. (2023) Temporal Convolutional Network Based Rice Crop Yield Prediction Using Multispectral Satellite Data. *Infrared Physics & Technology*, **135**, Article 104960. <https://doi.org/10.1016/j.infrared.2023.104960>
- [9] 高静怡, 陈首轩, 周明博, 等. 充放电多特征融合的锂电池寿命预测方法[J]. 重庆理工大学学报(自然科学), 2023, 37(2): 28-37.
- [10] Yang, L., Zhang, J., Wang, X., Li, Z., Li, Z. and He, Y. (2021) An Improved ELM-Based and Data Preprocessing Integrated Approach for Phishing Detection Considering Comprehensive Features. *Expert Systems with Applications*, **165**, Article 113863. <https://doi.org/10.1016/j.eswa.2020.113863>
- [11] Lan, Y., Soh, Y.C. and Huang, G.B. (2010) Random Search Enhancement of Error Minimized Extreme Learning Machine. *Proceedings of 2010 European Symposium on Artificial Neural Networks*, Bruges, 28-30 April 2010, 327-332.
- [12] Zhu, L., Zhang, L. and Virkar, A.V. (2015) A Parametric Model for Solid Oxide Fuel Cells Based on Measurements Made on Cell Materials and Components. *Journal of Power Sources*, **291**, 138-155. <https://doi.org/10.1016/j.jpowsour.2015.04.155>
- [13] 汪颖, 王欢, 张姝. 基于优化极限学习机的电压暂降源识别方法[J]. 电力系统自动化, 2020, 44(9): 135-143.
- [14] Shi, P., Kuang, L., Yuan, L., Wang, Q., Li, G., Yuan, Y., et al. (2024) Dissolved Oxygen Prediction Using Regularized Extreme Learning Machine with Clustering Mechanism in a Black Bass Aquaculture Pond. *Aquacultural Engineering*, **105**, Article 102408. <https://doi.org/10.1016/j.aquaeng.2024.102408>
- [15] Kler, D., Rana, K.P.S. and Kumar, V. (2019) Parameter Extraction of Fuel Cells Using Hybrid Interior Search Algorithm. *International Journal of Energy Research*, **43**, 2854-2880. <https://doi.org/10.1002/er.4424>
- [16] 荆素文. 固体氧化物燃料电池测试及故障诊断的研究[D]: [硕士学位论文]. 武汉: 华中科技大学, 2017.