

基于深度平行残差神经网络的质子交换膜燃料电池故障诊断^①



宫文峰^{1,2}, 石磊^{1,2}, 盛晨兴³, 张泽辉⁴

¹(北部湾大学 机械与船舶海洋工程学院, 钦州 535011)

²(北部湾大学 广西海洋工程装备与技术重点实验室, 钦州 535011)

³(武汉理工大学 船海与能源动力工程学院, 武汉 430063)

⁴(杭州电子科技大学 自动化学院, 杭州 310018)

通信作者: 张泽辉, E-mail: zhangtianxia918@163.com

摘要: 质子交换膜燃料电池 (proton exchange membrane fuel cell, PEMFC) 作为一种新型可再生清洁能源设备具有巨大的市场应用价值. PEMFC 在复杂多变的运行工况下长时间连续工作易发生水管理故障. 然而, 传统的故障诊断方法难以有效地从动态变化的监测数据中提取出关键故障特征. 为此, 提出了一种基于深度平行残差神经网络的 PEMFC 故障诊断方法. 该方法首先将采集的电流、电压等多源信号进行数据处理; 然后, 设计了一种深度平行残差神经网络 (deep parallel residual neural network, DP-ResNet) 解决残差网络多尺度特征提取能力不足的问题; 最后, 将提出的算法应用于质子交换膜燃料电池在负载变化工况下的水管理故障数据集进行诊断验证. 实验结果表明, 提出的 DP-ResNet 模型在真实的 PEMFC 实验数据集中对水淹故障的诊断准确率高达 99.46%. 该方法相比于传统机器学习 Decision-tree、GaussianNB、KNN 和 CNN 算法具备更高的特征提取能力和诊断精度.

关键词: 燃料电池; 故障诊断; 质子交换膜; 深度平行残差神经网络

引用格式: 宫文峰, 石磊, 盛晨兴, 张泽辉. 基于深度平行残差神经网络的质子交换膜燃料电池故障诊断. 计算机系统应用, 2026, 35(2): 269-279. <http://www.c-s-a.org.cn/1003-3254/10065.html>

Fault Diagnosis for Proton Exchange Membrane Fuel Cell Based on Deep Parallel Residual Neural Network

GONG Wen-Feng^{1,2}, SHI Lei^{1,2}, SHENG Chen-Xing³, ZHANG Ze-Hui⁴

¹(College of Mechanical and Marine Engineering, Beibu Gulf University, Qinzhou 535011, China)

²(Guangxi Key Laboratory of Ocean Engineering Equipment and Technology, Beibu Gulf University, Qinzhou 535011, China)

³(School of Naval Architecture, Ocean and Energy Power Engineering, Wuhan University of Technology, Wuhan 430063, China)

⁴(School of Automation, Hangzhou Dianzi University, Hangzhou 310018, China)

Abstract: As an innovative renewable and clean energy device, the proton exchange membrane fuel cell (PEMFC) holds immense market application value. PEMFCs are susceptible to water management faults during prolonged operation under complex and varying conditions. However, traditional fault diagnosis methods struggle to effectively extract key fault features from dynamically changing monitoring data. To address this, this study proposes a PEMFC fault diagnosis method based on a deep parallel residual neural network (DP-ResNet). This method initially processes the collected multi-source signals, such as current and voltage. Subsequently, a DP-ResNet is designed to overcome the limitation of residual

① 基金项目: 国家自然科学基金 (52401376); 国家水运安全工程技术研究中心开放基金 (A202501); 广西自然科学基金 (2025GXNSFHA069145); 广西高校中青年骨干教师科研基础能力提升项目 (2025KY0482); 广西揭榜制科技项目 (2025JBGS035); 广西教育厅高等教育本科教学改革工程重点项目 (2024 JGZ146)

收稿时间: 2025-07-07; 修改时间: 2025-08-01, 2025-08-15; 采用时间: 2025-09-01; csa 在线出版时间: 2025-12-19

CNKI 网络首发时间: 2025-12-22

networks in multi-scale feature extraction. Finally, the proposed algorithm is applied to a dataset of PEMFC water management faults under varying load conditions for diagnostic verification. Experimental results demonstrate that the proposed DP-ResNet model achieves a diagnostic accuracy of up to 99.46% for flooding faults in real PEMFC experimental datasets. Compared with traditional machine learning algorithms such as Decision-tree, GaussianNB, KNN, and CNN, the proposed method demonstrates superior feature extraction and diagnostic accuracy.

Key words: fuel cell; fault diagnosis; proton exchange membrane; deep parallel residual neural network (DP-ResNet)

近年来,随着化石能源燃烧的排放物对全球的环境污染、温室效应和气候变化紊乱等负面影响的日益加剧,世界各国普遍提出了碳达峰与碳中和(即“双碳”)目标^[1].因此,探索和开发绿色清洁能源已成为亟待解决的关键问题^[2].质子交换膜燃料电池(proton exchange membrane fuel cell, PEMFC)作为一种高效、清洁的新型氢能源转换装置,因其具有高能量转换效率、低污染和零排放等优点,得到了业界的广泛研究和应用^[3,4].氢燃料电池作为一种前景广阔的能源供给装备,其健康状态和安全稳定性至关重要^[5,6].然而,在湿热、高温和复杂多变的运行工况条件下,PEMFC容易发生各种故障^[7],尤其是发生水淹故障,若不及时检查、辨识和报警,将直接影响PEMFC系统的稳定性和工作效率,甚至会产生系统瘫痪的风险^[8].为此,针对PEMFC进行故障诊断和风险预报是至关重要的.

近年来,国内外业内学者和科研院所针对PEMFC的故障诊断问题,开展了探索研究^[9,10].当前针对PEMFC的故障诊断方法有基于信号处理的诊断方法和基于模型的诊断方法^[11].基于信号处理的PEMFC故障诊断研究是通过原始信号进行滤波、变换、分析等操作,以提取对故障诊断有用信息的技术手段,比较有代表性的研究有:Steiner等^[12]通过对采集到的燃料电池电堆的电压信号使用能多尺度分解信号的离散小波从而进行故障诊断,获得了较好的诊断识别效果.Arama等^[13]通过使用快速傅里叶变换脉宽调制技术,对燃料电池的电压和电流信号进行频谱幅度分析,从而进行特征提取实现对PEMFC的水管理和早期故障检测.Damour等^[14]主要利用经验模态分解,将PEMFC的输出电压分解为多个本征模态函数(intrinsic mode function, IMF),并计算每个IMF的能量,以量化其对总能量的贡献,量化后的IMF作为特征向量来评估PEMFC的水淹或膜干故障状态.基于模型的PEMFC故障诊断方法是将实验条件及实物参数构建出仿真物理系统的数字模型,并把预设的实验条件数据输入到模型中得到响应输出,

进而实现对PEMFC关键参数的变化监测^[15],通过分析模型模拟系统关键参数的演化趋势或者数据残差,从而判断实际系统的工作状态.目前此类方法比较有代表性的研究有:Sun等^[16]通过开发一个三维、多分组、多物理场的PEMFC模型,模拟了PEMFC的不同衰退机制,研究了不同机制下磁场的幅值和分布.黄赵军等^[17]通过基于修正后的燃料电池电堆Fouquet等效电路模型,并结合电堆阻抗谱实验数据,得到电堆的多种工作状态与电路模型参数的对应关系,进而提取合适的故障特征量作为聚类算法的特征输入从而进行故障诊断.以上两类故障诊断方法虽然在PEMFC故障诊断中得到一定应用并取得一定诊断效果,但是仍然存在一些不足:基于信号处理的PEMFC故障诊断方法通常需掌握各种先进信号处理技术并依赖工程师操作经验和先验知识进行信号处理,当需要处理的数据量较大时该方法的效率低下^[18].基于模型的PEMFC故障诊断方法通常需要依赖专家的丰富专业知识和经验对燃料电池进行数学建模以描述其内部的工作机理,从而达到故障检测和诊断的目的,但是随着不同类型的燃料电池复杂度的提升,期望建立高精度的故障诊断数学模型是极其困难的^[19].因此,需要进一步研究更加智能高效的故障诊断方法.

近年来,随着新一代人工智能技术的快速发展,深度学习(deep learning, DL)作为一种智能高效的模式识别技术得到PEMFC故障诊断领域的广泛关注^[20].基于DL的故障诊断方法可通过强大的深度学习模型直接从多源传感器实时监测的数据以及历史“大数据”中挖掘隐藏在复杂数据背后的故障特征和潜在规律,可以获得更加高效的故障诊断效果.残差网络作为一种新型的深度学习代表性算法,相比于传统的卷积神经网络、循环神经网络等深度学习算法具有网络训练更高效、特征提取能力更强等优点,并因其能解决深层神经网络退化问题,更加适合PEMFC的故障诊断应用^[21].通过运用深度学习模型强大的特征提取能力,深入挖

掘隐藏在复杂数据背后的故障特征信息和潜在规律. 文献[22-24]等将残差神经网络分别应用于燃料电池、航空航天和行星减速机等设备的故障诊断, 获得了较好的诊断效果. 文献[25,26]将残差神经网络进行改进并应用于滚动轴承的故障诊断, 在故障诊断的性能上也有不小的提升. 虽然上述基于改进的残差神经网络在故障诊断领域得到一些研究和应用, 通过结合长短时记忆神经网络、Transformer 等模块解决时序关联预测、局部特征捕捉等问题, 但未能从 ResNet 自身的网络结构上进行优化改进应用, 同一网络层级结构上, 仍存在平行时空上, 对于多尺度特征提取能力不足的网络层级结构扩展问题, 诊断性能还可以进一步提升. 为此, 本文提出一种深度平行残差神经网络 (deep parallel residual network, DP-ResNet) 的算法, 用于解决 PEMFC 的故障诊断问题, 并加强残差神经网络模型的多尺度特征提取能力.

1 残差网络算法原理

卷积神经网络 (convolutional neural network, CNN) 随着层级在深度方向的叠加会导致梯度爆炸或梯度消失的发生, 潜在地导致网络退化和一个较差的学习效果, 这些问题限制了网络深度的扩展和性能. 为了解决这一问题, He 等^[27,28]提出了残差网络 (residual network, ResNet), 其网络模型结构块当中包含了一个跨卷积层的残差映射连接, 在训练过程中可以直接将输入信息通过残差连接传递到后续层级, 使得训练不仅可以利用目标函数梯度, 还可以利用残差梯度; 正是因为残差连接的存在, 梯度可以更容易地传播, 网络模型也可以构建得更深、更复杂, 也有助于网络提取深层次的复杂特征, 从而提高网络模型性能. 因此, ResNet 能够解决传统 CNN 结构层级在深度扩展时的退化问题, 并且可以优化误差的反向传播并促进模型训练. 其中, x 是残差块的输入, $F(x)$ 表示残差映射函数, $H(x)$ 是残差块的输出. 输入 x 和输出 $H(x)$ 通过恒等残差连接线直接相连, 它们的关系表达式可以表示为:

$$H(x) = F(x) + x \quad (1)$$

一个带有残差连接的基础残差块如图 1 所示. 残差块中权重层一般是卷积层, 权重层负责学习输入数据的特征表示, 并通过权重参数来转换输入数据. 输入 x 直接加权到权重层的输出 $F(x)$ 上; 残差映射 $F(x) = H(x) - x$ 比恒等映射 $H(x) = x$ 更容易学习, 而且在训练

过程中可以通过残差连接将不同层级的误差进行传递, 使得训练不仅可以利用目标函数梯度, 还可以利用残差梯度. 由于 ResNet 能解决传统 CNN 在深层级方面的退化问题, 因此引入残差网络解决燃料电池的故障诊断问题. 同时, 针对现行残差网络中存在的“平行时空特征提取能力较差”的问题进一步改进优化, 并提升其特征提取能力和诊断精度.

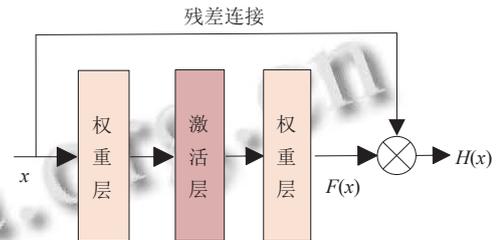


图 1 基础残差块

2 深度平行残差神经网络 DP-ResNet

2.1 算法的逻辑流程

DP-ResNet 智能燃料电池故障诊断算法的基本流程如图 2 所示.

通过平行残差网络模型对燃料电池所采集的预处理后的数据进行特征提取、关联和训练, 从而精确识别燃料电池的运行状态. 该算法流程中包含训练过程和测试过程两个阶段. 模型训练阶段, 通过挖掘和学习训练集和验证集中的特征和标签之间的关系、潜在规律, 不断调整网络模型的内部参数, 如权重和偏置, 并且最小化损失函数, 进而实现对输入数据的准确分类或者预测. 而在测试阶段, 测试集则是用来评估训练好的模型性能, 也可以检查模型对输入的新数据的泛化能力; 并且测试集不应该在模型训练过程中使用, 以保证评估的有效性.

2.2 算法模型框架

本文提出的 DP-ResNet 模型结构如图 3 所示. 模型初期通过 7×7 卷积核尽可能地扩大特征提取的范围, 然后再通过一层非残差的多通道特征提取层, 最后再输入平行残差块当中, 网络模型中残差连接中的 1×1 卷积层是为了调整模型的输入、输出或者进行升维、降维处理, 并且在模型最后应用了全局平均池化层能更好地实现对整个特征图全局信息的整合. 从全局角度进行分析, 对每个特征图的所有元素取平均值, 可以降低过拟合风险、整合全局特征信息, 并为后续的全连接层和逻辑判别故障状态奠定基础.

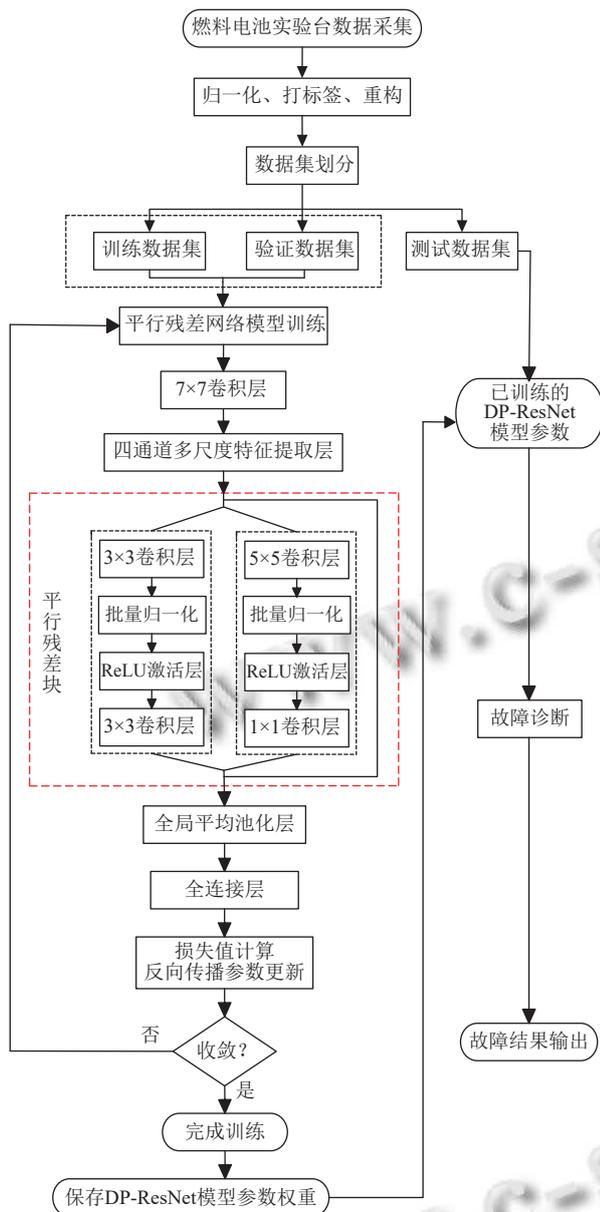


图2 DP-ResNet 智能故障诊断算法流程

2.3 平行残差块及相关算法公式

本文提出的平行残差块如图4所示,平行残差块之所以可以进行多尺度特征提取,主要是因为“平行”残差块内在的卷积核大小不同.块内的基本组成单元有卷积层、批量归一化层、激活层.各层的详细原理、作用、算法公式介绍如下.

2.3.1 卷积层

卷积层是神经网络模型中重要的组成部分,每个卷积层都由多个滤波器构成,每个滤波器内包含多个卷积核,卷积层的作用就是提取图像的信息特征,不同大小的卷积核所关注的特征信息是不同的,所以需要

采用多个滤波器来获取图像的更多细节和范围上的特征信息.卷积运算可以表示为:

$$y_j^l = f\left(\sum_{i=1}^k w_{i,j}^l \otimes x_j^{l-1} + b_j^l\right) \quad (2)$$

其中, l 表示层数, $w_{i,j}^l$ 表示连接到第 j 个输入映射的第 i 个滤波器的核, x_j^{l-1} 表示第 j 个输入映射, b_j^l 表示偏置, f 表示非线性激活函数, \otimes 表示卷积运算.其卷积操作的基本过程如图5所示.

2.3.2 批量归一化层

深度学习网络模型中通常对初始权重参数和优化器的设置很敏感^[29,30].当模型权重更新时,网络内部中各层的输入分布可能会发生变化.这种对各层输入分布的调整被称为内部协变量移位,这可能会增加模型的复杂性和不稳定性,降低收敛速度和泛化能力,甚至是引发梯度爆炸或梯度消失等问题.为了解决这些问题,本文采用批量归一化方法(batch normalization, BN)作为神经网络的一种参数优化方法.它可以对每个小批量数据进行归一化处理^[31],从而可以减少计算资源和模型训练的时间、增强模型的鲁棒性. BN的计算公式可以表示为:

$$\psi_B \leftarrow \frac{1}{m} \sum_{i=1}^m x_i \quad (3)$$

$$\omega_B^2 \leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \psi_B)^2 \quad (4)$$

$$\hat{x}_i \leftarrow \frac{x - \psi_B}{\sqrt{\omega_B^2 + \epsilon}} \quad (5)$$

$$y_i \leftarrow \eta \hat{x}_i + \mu \equiv BN_{\eta, \mu}(x_i) \quad (6)$$

其中, m 是每个批量样本大小, ψ_B 和 ω_B^2 分别为批量样本的均值和方差值; η 和 μ 分别为尺度因子和运动因子.

2.3.3 激活层

在神经元中,激活函数是重要的组成部分,为了增强网络的表征和学习能力,神经网络中的激活函数引入了非线性处理单元到神经元中,使其能够模拟逼近各种复杂的线性或者非线性函数,最终可以输出各种结果.这一特性极大地拓展了应用范围,同时可以使神经网络能够应用到更多非线性模型中.常见的激活函数有: Sigmoid 函数、tanh 函数、ReLU 函数、ELU 函数等^[32].经过多次的对比实验与计算,本文优先采用整流线性单元 ReLU 函数作为网络模型的激活函数,

其可以加快收敛速度, 缓解梯度消失, ReLU 函数可以表示为^[33]:

$$f(x) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (7)$$

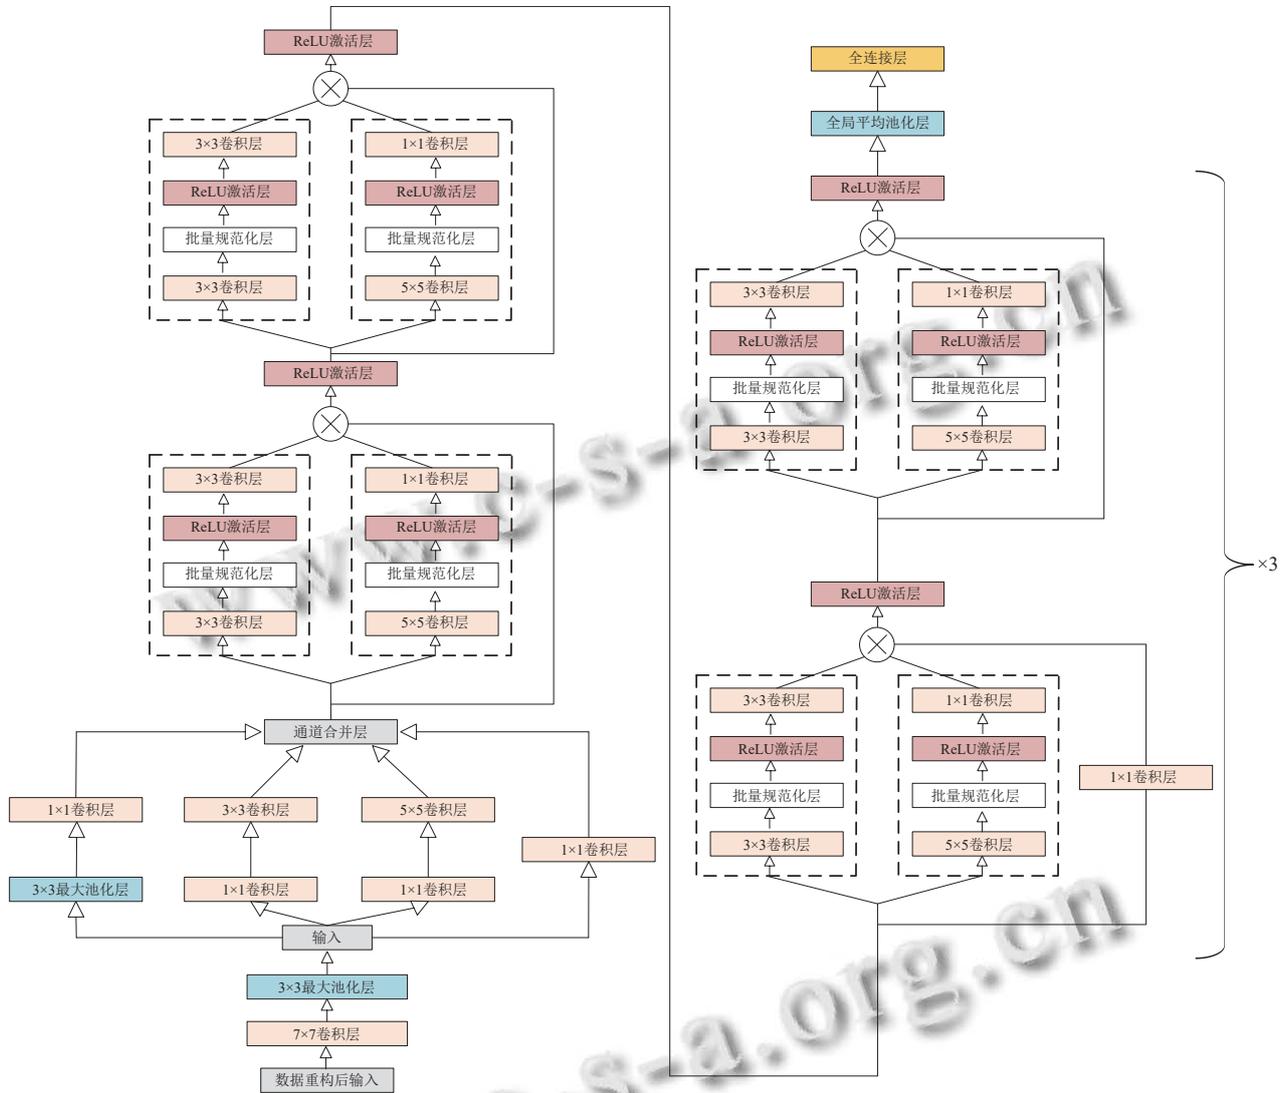


图3 DP-ResNet 模型结构图

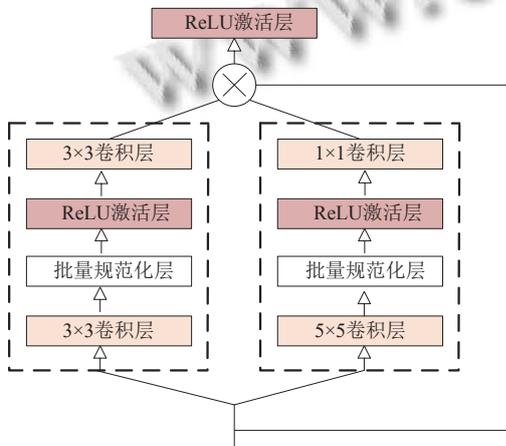


图4 平行残差块

2.3.4 损失函数

本文算法采用交叉熵误差损失函数^[34]计算故障诊断预测输出结果与真实标签之间的误差值, 并利用反向传播算法调整网络权重参数以最小化预测误差和训练模型, 交叉熵损失函数的数学表达式^[34]为:

$$J(\mu) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=1}^n U\{\bar{y}_i = j\} \log \frac{e^{x_i^T \cdot \mu}}{\sum_{l=1}^n e^{x_i^T \cdot \mu}} \right] \quad (8)$$

其中, $J(\mu)$ 是交叉熵损失函数, i 表示第 i 个训练样本, j 表示归属于第 j 个类别 (共有 n 个类别); $U\{\cdot\}$ 是逻辑指示函数, 即大括号内的值判别为真时, $U=1$; \bar{y}_i 表示

第 i 个样本对应的真实标签.

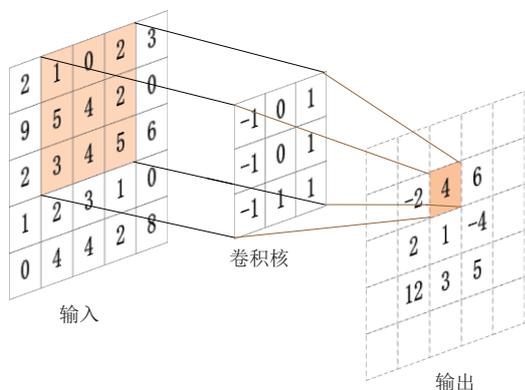


图5 卷积过程示意图

3 实验验证

3.1 实验介绍

3.1.1 PEMFC 工作原理

质子交换膜燃料电池可以在电池内部通过将氢气和氧气反应所产生的化学能转化成电能, 并且产物只有水和热^[35]. 现有的 PEMFC 已在汽车、船舶、工业生产等领域中应用, 质子交换膜燃料电池系统是由电堆与氢气供给系统、空气供给系统、温控系统、排气系统、水管理系统、电子负载系统、温度控制模块等辅机系统组成的多物理场耦合作用的系统, 其中氢气供给系统、空气供给系统为整个系统提供反应燃料. PEMFC 的系统图如图 6 所示.

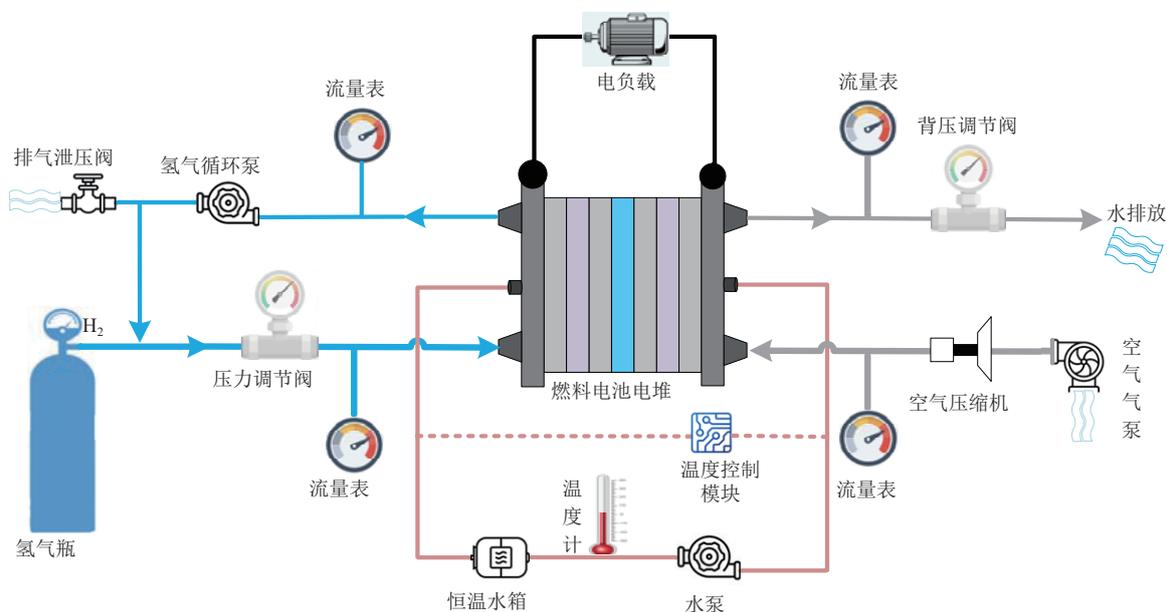
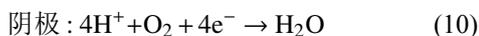
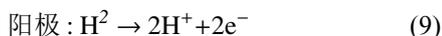


图6 PEMFC 系统图

PEMFC 中质子交换膜允许质子的转移, 但是电子则不能, 在阳极催化剂处, 氢原子被分裂成质子和电子. 质子和电子分别穿过膜和外部电路, 当电子流通外部电路的时候产生电流并为外部电力负载提供电能从而产生动力^[36]. 此外, 在阴极催化剂层处产生水和热, 如图 7 所示.

PEMFC 的电化学反应表达式如下:



3.1.2 故障描述

PEMFC 的故障诊断, 旨在准确无误地发现 PEMFC

系统运行故障, 从而提升燃料电池的安全性和稳定性, 运行状态包括正常状态及最常见的水淹故障. 水淹故障是由于燃料电池内部水含量过高, 阻塞了质子交换膜的气体扩散层或多孔介质, 也阻碍了气体反应物向反应部位的转移, 在“水淹”状态下催化剂接触到的气体变少、活性降低, 电化学的反应速率也随之降低^[37], 进而导致电荷传递的效率降低和功耗损失明显增加. 长时间地处于水淹故障状态下会导致催化剂作用的下降甚至失效, 会加快电池材料的腐蚀^[38]以及增大反应物流经气体扩散层时的阻力^[22]; 水淹故障严重地影响 PEMFC 的正常运行和使用寿命. PEMFC 中水含量的上升有如下几种原因: (1) 功耗的增加, 即电流密度也

随之变大会加速电化学反应的产水。(2) 提高反应温度时, 由于分子热运动的加剧, 氢、氧燃料物之间的反应速率加快, 也会提高 PEMFC 中的水含量。(3) 催化剂的活性、催化剂与反应物的接触面增大都将可能增加反应后生成水的量。(4) 特别地, 当 PEMFC 系统排水速率跟不上产水量的时候, 水淹故障就更容易发生。

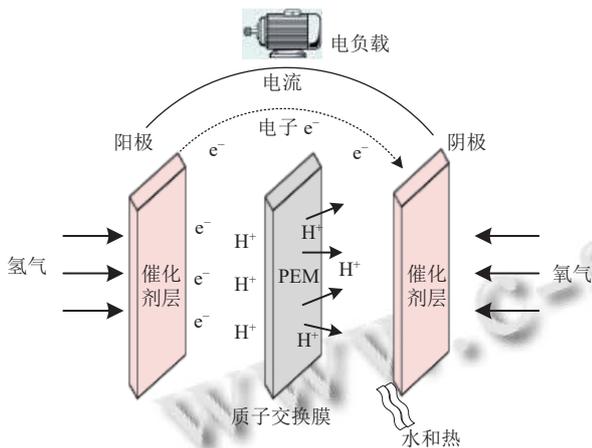


图7 PEMFC 内部工作原理示意图

3.1.3 PEMFC 实验台

PEMFC 实验台架构如图8所示, 其中包括 PEMFC 单电池堆、温控系统、TDI 电负载设备以及氢气和空气的供给辅助装置, 功率标准为 80 W 的 PEMFC 系统. PEMFC 温控系统的冷却功能是通过使用去离子水来对电堆温度进行冷却, 使得电堆反应生成的水蒸汽更快地凝结成液态水从而加快电堆的液态水堆积, 并且输入的氧气会被加湿器加湿. 加湿的气体会导致在电池内部经过温控系统降温后更快地凝结从而加速水淹故障发生. 在该实验台中采集正常运行和定向植入的水淹故障两种类型的数据. 其中正常的样本会在后续数据预处理时标签为“0”, 而水淹故障则是会被标签为“1”. 最终采集到的样本总量为 43 733 条, 其中, 36 106 条为正常运行状态数据, 7 627 条则为 PEMFC 水淹状态下的故障数据.

PEMFC 实验台监测的参数指标种类包括电压、电流、电堆温度、阳极(阴极)出口湿度、阳极(阴极)出口压力等, 指标参数如表1所示. 而 PEMFC 水淹故障实验台部分传感器在植入水淹故障状态时测量采集的数据绘制成曲线如图9所示, 由于采集了极化时的数据(如 1 000–1 500 s、3 000–3 400 s), 从而电池电压会有多个相似的变化周期. 在水淹状态时分析电

流和电压的曲线可以同步得知, 在故障状态下负载功率也会受到影响下降.

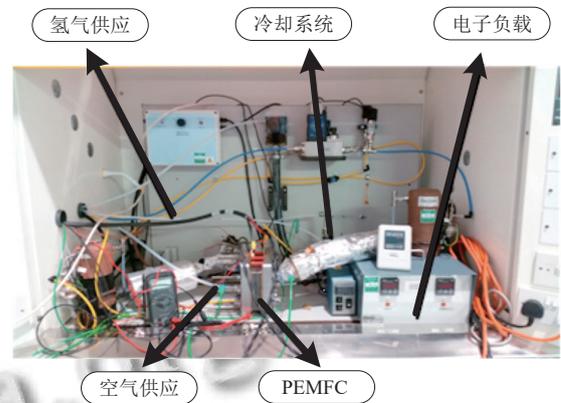


图8 PEMFC 实验台

表1 PEMFC 实验台监测的参数种类

序号	参数	序号	参数
1	电压	7	阳极出口压力
2	电流	8	阴极出口温度
3	电堆温度	9	阳极出口温度
4	阴极出口湿度	10	阴极出口流量
5	阳极出口湿度	11	阳极出口流量
6	阴极出口压力	—	—

3.1.4 故障数据集

在进行 DP-ResNet 模型训练之前, 需预先做好数据采集及数据处理工作, 以下为该过程的详细介绍.

(1) 数据采集: 为了更好地采集水淹故障数据, 实验台降低了电堆的温度, 这将有利于水分子的冷凝和积累, 从而产生水淹故障进而可以收集到不同程度的故障数据. 但是原始数据点通常范围不同, 比如过大的数据使得计算量增大, 收敛速度变慢, 所以需要进一步的数据处理操作.

(2) 数据处理: 首先, 使用最大-最小归一化方法对初始数据进行归一化处理, 经过归一化处理后的数据可以简化计算、统一量纲、加快模型的收敛速度. 其数学计算公式如下所示:

$$x = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (11)$$

然而由于电压、电流、温度等各类传感器采集的原始一维时序数据 l 的长度可达百万级以上, 若不进行数据重构直接输入训练则很有可能导致大量数据“淹没”模型造成无法有效训练, 并且卷积层是通过卷积核进行“矩阵式”特征提取的, 故更加需要使用数据重构

操作将采集到的一维时间序列监测数据进行结构调整成二维数据,即转化为矩阵格式的滑动窗口,从而让模型拥有更广阔的数据视野.根据文献[39-41]研究表明,PEMFC中二维数据比一维数据所包含的信息更丰富,并且能更有效地被CNN等深度学习模型提取特征,进而获取更高的故障诊断识别性能.对于PEMFC实验台传感器采集的每一个时序数据样本从(6,24)的数据格式重构为(1,12,12)的格式,也同步适配于本文提出的DP-ResNet算法所设置的卷积核大小和步长等参数.该过程如图10所示.

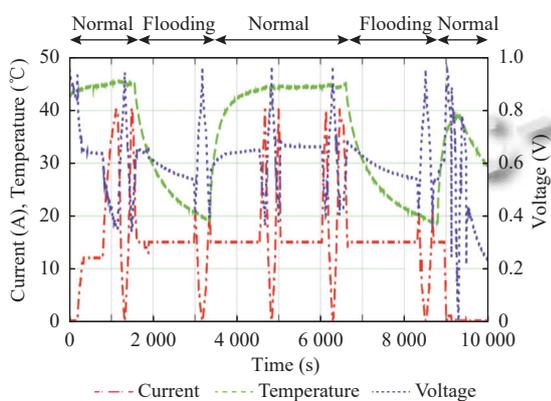


图9 PEMFC 电流、电压、温度变化曲线

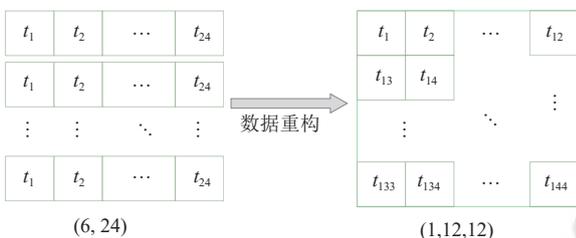


图10 数据重构

重构后的数据样本还需要进行“标签化”处理,其中“0”和“1”分别表示正常和水淹故障状态.

(3) 数据分割:最后是将样本进行数据分割处理,对43733条数据样本进行随机分割,70%的样本量为训练数据集,10%的样本量为验证数据集,余下的样本作为测试数据集.首先使用训练集训练DP-ResNet模型,并根据验证集的精度曲线调整训练过程中的模型超参数,然后则是利用验证集对训练后的DP-ResNet模型进行准确性验证,最后则用测试集对DP-ResNet模型进行故障诊断性能与精度的评估.

3.2 实验环境及模型超参数

在本研究中,实验使用的电脑硬件配置是 Intel®

CoreTMi5-8300H 和 NVIDIA 1050Ti,使用 PyTorch 和 scikit-learn 框架在 Python 版本为 3.10.14 的环境上开发故障诊断方法并执行.实验中设置的模型超参数有学习率 η 为 0.001, batch_size 为 64, 训练周期 epoch 为 40, 并选用准确率、精度、召回率这 3 个指标量化模型的诊断性能.

3.3 实验结果

DP-ResNet 模型诊断准确率和损失函数迭代曲线如图11所示,从图中可以看到改进后的DP-ResNet模型测试集准确率可达99.46%,并且损失函数也较低, test loss 为 0.0114,有效改善了过拟合问题.为了进一步考察DP-ResNet算法对故障误判的细节情况,文中采用了混淆矩阵对训练、验证、测试这3个过程的阶段诊断结果进行量化分析.图12的混淆矩阵可以直观而全面地反映PEMFC的故障诊断准确率和错误分类结果的数量,其中x轴横坐标是故障的预测标签,y轴纵坐标表示故障的真实标签.

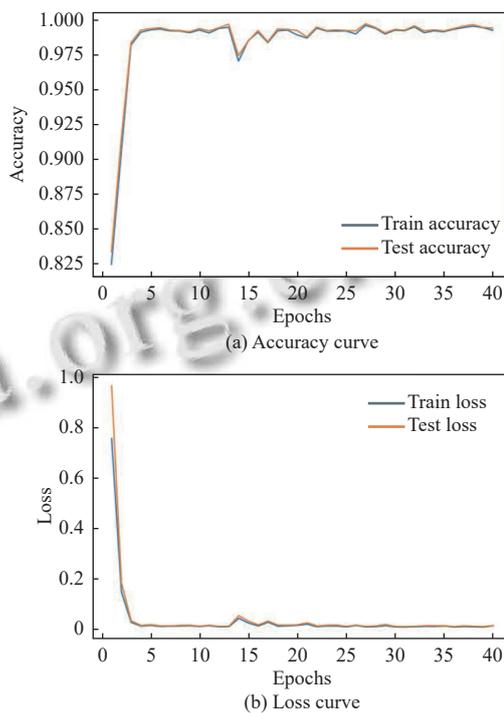
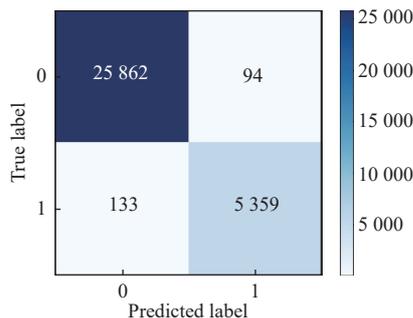
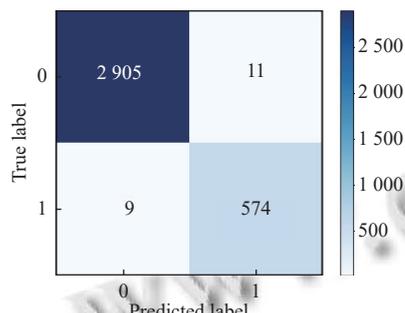


图11 模型诊断准确率和损失函数曲线图

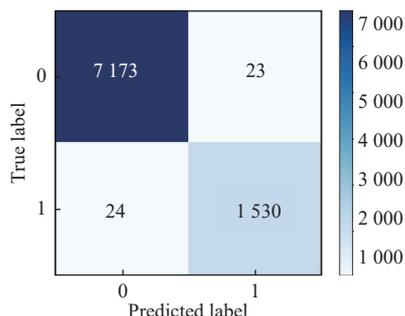
本文中只有 PEMFC 正常与水淹两种运行状况.在经过训练集的模型训练后,在测试集中正常类别 7197 个样本量中只有 24 个分类错误,而水淹故障 1553 个样本量中只有 23 个分类错误,模型整体诊断性能较好,不存在过拟合现象.



(a) 训练集混淆矩阵



(b) 验证集混淆矩阵



(c) 测试集混淆矩阵

图 12 混淆矩阵

3.4 对比验证

由图 13 可以直观地看到未改进的 ResNet-18 在该数据集的诊断性能只有 98.28%，低于改进后的 DP-ResNet 模型。并且为了验证所提方法的有效性，将 DP-ResNet 的故障诊断精度结果与传统的机器学习模型 Decision-tree、GaussianNB、KNN、CNN (模型的结构简图如图 14 所示)、ResNet-18 进行了对比验证。

为了保证对比实验的公平性，对于 CNN、ResNet-18 保持了输入数据的维度和大小相同；而传统机器学习算法 KNN、GaussianNB、Decision-tree 虽然对输入维度形式无强制要求，但为消除数据格式差异对实验结果的潜在影响，将二维结构的 (1, 12, 12) 数据格式通过展平操作仅恢复了原始一维数据的排列形式，即将

二维结构中按空间维度分布的特征转化为一维序列中的特征，原始数据所包含的全部特征信息 (如幅值、变化趋势等关键故障特征) 并未丢失，本质上保持了数据的特征完整性，严格确保了不同模型对比的公平性与结果的可靠性，使各模型的性能差异能真实地反映其在故障诊断任务中的能力差异。模型的分类结果如表 2 所示。虽然这些模型在训练数据集上具有优异的诊断性能，但它们在测试数据集上表现的结果不佳。从表 2 中可以看到，提出的模型在训练集、验证集上取得了出色的故障诊断性能，验证集的准确率可达 99.43%；而且测试集的准确率高达 99.46%，精度和召回率都在 99% 以上，这体现了所提模型方法的有效性。

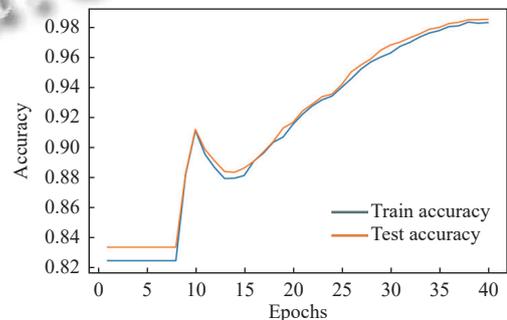


图 13 ResNet-18 诊断准确率

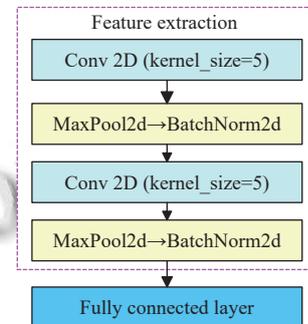


图 14 对比实验 CNN 模型结构简图

4 结论与展望

本文提出基于改进 DP-ResNet 的深度学习算法，用于解决 PEMFC 在多传感器监测数据下的快速故障诊断问题。所提出的方法基于 ResNet 算法能够解决深度学习模型中随着网络层级的加深而产生的梯度消失和爆炸、网络退化等问题；并针对现行的 ResNet 算法多尺度特征提取能力不足，提出了一种“平行架构”的多尺度特征提取的残差网络，采用分别对两个“平行残差块”使用不同卷积核大小的卷积层来进行多尺度特征提取的改进方法。结果表明，改进的 DP-ResNet 算法

诊断准确率为 99.46%，相比于未改进的 ResNet 模型在诊断精度上有所提升，并且诊断性能也明显优于传统的机器学习算法 Decision-tree、GaussianNB、KNN、CNN。并通过真实的 PEMFC 实验台在负载变化中采集的数据来训练 DP-ResNet 故障诊断模型，强化该模

型在 PEMFC 的不同负载工况下的水淹故障诊断性能。所提出的方法通过神经网络自动提取特征并挖掘与故障之间的潜在关系，从而实现故障诊断与分类，无需任何手动特征提取，这种“端到端”的算法更适用于在多种传感器数据采集与监测环境下 PEMFC 的快速故障诊断。

表 2 传统机器学习模型和提出模型分类结果 (%)

模型	训练集			验证集			测试集		
	准确率	精度	召回率	准确率	精度	召回率	准确率	精度	召回率
ResNet-18	97.51	97.56	97.54	98.07	97.94	98.15	98.28	97.85	98.19
Decision-tree	96.91	97.91	97.64	96.69	97.47	97.16	79.43	82.86	78.84
GaussianNB	97.34	97.25	97.19	96.93	97.04	96.86	89.87	90.03	88.69
KNN	99.66	99.88	99.23	99.18	99.78	99.54	87.63	88.97	87.73
CNN	97.17	97.22	97.08	98.74	98.17	98.22	98.19	97.88	98.34
DP-ResNet	99.28	99.49	99.64	99.43	99.69	99.62	99.46	99.67	99.68

注：加粗数据表示最佳结果

参考文献

- Massaro MC, Pramotton S, Marocco P, *et al.* Optimal design of a hydrogen-powered fuel cell system for aircraft applications. *Energy Conversion and Management*, 2024, 306: 118266. [doi: 10.1016/j.enconman.2024.118266]
- Lebrouhi BE, Djoupo JJ, Lamrani B, *et al.* Global hydrogen development—A technological and geopolitical overview. *International Journal of Hydrogen Energy*, 2022, 47(11): 7016–7048. [doi: 10.1016/j.ijhydene.2021.12.076]
- Hassan Q, Sameen AZ, Salman HM, *et al.* Hydrogen energy future: Advancements in storage technologies and implications for sustainability. *Journal of Energy Storage*, 2023, 72: 108404. [doi: 10.1016/j.est.2023.108404]
- Kurnia JC, Chaedir BA, Sasmito AP, *et al.* Progress on open cathode proton exchange membrane fuel cell: Performance, designs, challenges and future directions. *Applied Energy*, 2021, 283: 116359. [doi: 10.1016/j.apenergy.2020.116359]
- Von Tettau P, Sterlepper S, Mauermann P, *et al.* Laboratory assessments applied to mass-produced automotive fuel cells. *International Journal of Hydrogen Energy*, 2024, 52: 1127–1136.
- Chen JH, He P, Cai SJ, *et al.* Modeling and temperature control of a water-cooled PEMFC system using intelligent algorithms. *Applied Energy*, 2024, 372: 123790. [doi: 10.1016/j.apenergy.2024.123790]
- Zhang YQ, Li Y, Zhang CZ, *et al.* Intelligent diagnosis of proton exchange membrane fuel cell water states based on flooding-specificity experiment and deep learning method. *Renewable Energy*, 2024, 222: 119966. [doi: 10.1016/j.renene.2024.119966]
- Hong JC, Yang JS, Weng ZP, *et al.* Review on proton exchange membrane fuel cells: Safety analysis and fault diagnosis. *Journal of Power Sources*, 2024, 617: 235118. [doi: 10.1016/j.jpowsour.2024.235118]
- 张杰, 谌祺, 韩小涛. 基于典型机器学习的 PEMFC 故障诊断综述. *电源技术*, 2022, 46(7): 710–715.
- 李奇, 刘嘉蔚, 陈维荣. 质子交换膜燃料电池剩余使用寿命预测方法综述及展望. *中国电机工程学报*, 2019, 39(8): 2365–2375.
- Gong WF, Wang YZ, Zhang ML, *et al.* A fast anomaly diagnosis approach based on modified CNN and multisensor data fusion. *IEEE Transactions on Industrial Electronics*, 2022, 69(12): 13636–13646. [doi: 10.1109/TIE.2021.3135520]
- Steiner NY, Hissel D, Moçotéguy P, *et al.* Non intrusive diagnosis of polymer electrolyte fuel cells by wavelet packet transform. *International Journal of Hydrogen Energy*, 2011, 36(1): 740–746. [doi: 10.1016/j.ijhydene.2010.10.033]
- Arama FZ, Laribi S, Mammam K, *et al.* Efficient water-related failure detection in PEM fuel cells: Combining a PEMFCs fractional order impedance model with FFT-PWM techniques and artificial neural network classification. *Heliyon*, 2024, 10(7): e29084. [doi: 10.1016/j.heliyon.2024.e29084]
- Damour C, Benne M, Grondin-Perez B, *et al.* Polymer electrolyte membrane fuel cell fault diagnosis based on empirical mode decomposition. *Journal of Power Sources*, 2015, 299: 596–603. [doi: 10.1016/j.jpowsour.2015.09.041]
- Petrone R, Zheng Z, Hissel D, *et al.* A review on model-based diagnosis methodologies for PEMFCs. *International Journal of Hydrogen Energy*, 2013, 38(17): 7077–7091. [doi: 10.1016/j.ijhydene.2013.03.106]
- Sun YN, Mao L, Wang H, *et al.* Simulation study on magnetic field distribution of PEMFC. *International Journal of Hydrogen Energy*, 2022, 47(78): 33439–33452. [doi: 10.1016/j.ijhydene.2022.07.228]

- 17 黄赵军, 苏建徽, 解宝, 等. 基于模糊 C 均值聚类和概率神经网络的 PEMFC 故障诊断方法研究. 太阳能学报, 2024, 45(1): 475–483.
- 18 宫文峰, 张美玲, 陈辉. 基于深度学习的旋转机械大数据智能故障诊断方法. 计算机集成制造系统, 2025, 31(1): 264–277.
- 19 孙誉宁, 毛磊, 黄伟国, 等. 基于磁场的质子交换膜燃料电池故障诊断方法. 机械工程学报, 2022, 58(22): 106–114.
- 20 Lv JF, Kuang JY, Yu ZL, *et al.* Diagnosis of PEM fuel cell system based on electrochemical impedance spectroscopy and deep learning method. IEEE Transactions on Industrial Electronics, 2024, 71(1): 657–666. [doi: 10.1109/TIE.2023.3241404]
- 21 Zhang W, Li X, Ding Q. Deep residual learning-based fault diagnosis method for rotating machinery. ISA Transactions, 2019, 95: 295–305. [doi: 10.1016/j.isatra.2018.12.025]
- 22 Yuan H, Tan DY, Wei XZ, *et al.* Fault diagnosis of fuel cells by a hybrid deep learning network fusing characteristic impedance. IEEE Transactions on Transportation Electrification, 2024, 10(1): 1482–1493. [doi: 10.1109/TTE.2023.3272654]
- 23 魏轩, 慕晓冬, 曾昭菊, 等. 基于残差网络的航天器测控系统诊断. 兵器装备工程学报, 2023, 44(3): 254–260.
- 24 Zhao MH, Kang M, Tang BP, *et al.* Multiple wavelet coefficients fusion in deep residual networks for fault diagnosis. IEEE Transactions on Industrial Electronics, 2019, 66(6): 4696–4706. [doi: 10.1109/TIE.2018.2866050]
- 25 池福临, 杨新宇, 邵思羽, 等. 基于深度收缩残差网络的轴承变工况故障诊断. 计算机集成制造系统, 2023, 29(4): 1146–1156.
- 26 Liang PF, Wang WH, Yuan XM, *et al.* Intelligent fault diagnosis of rolling bearing based on wavelet transform and improved ResNet under noisy labels and environment. Engineering Applications of Artificial Intelligence, 2022, 115: 105269. [doi: 10.1016/j.engappai.2022.105269]
- 27 He KM, Zhang XY, Ren SQ, *et al.* Deep residual learning for image recognition. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016. 770–778.
- 28 He KM, Zhang XY, Ren SQ, *et al.* Identity mappings in deep residual networks. Proceedings of the 14th European Conference on Computer Vision. Amsterdam: Springer, 2016. 630–645.
- 29 Zhang ZH, Zhang LL, Li QD, *et al.* Privacy-enhanced momentum federated learning via differential privacy and chaotic system in industrial cyber-physical systems. ISA Transactions, 2022, 128: 17–31. [doi: 10.1016/j.isatra.2021.09.007]
- 30 Zhang LL, Zhang ZH, Guan C. Accelerating privacy-preserving momentum federated learning for industrial cyber-physical systems. Complex & Intelligent Systems, 2021, 7(6): 3289–3301.
- 31 王宏, 冯佳俊, 戴旗, 等. 基于 CNN-LSTM-CS 工业管道腐蚀率预测模型. 计算机系统应用, 2024, 33(5): 103–109. [doi: 10.15888/j.cnki.csa.009493]
- 32 Dubey SR, Singh SK, Chaudhuri BB. Activation functions in deep learning: A comprehensive survey and benchmark. Neurocomputing, 2022, 503: 92–108. [doi: 10.1016/j.neucom.2022.06.111]
- 33 汪志立, 王定成, 曹蓉, 等. 融合注意力机制和二次特征提取的 ResNet 小样本农作物病虫害识别. 计算机系统应用, 2024, 33(9): 208–215. [doi: 10.15888/j.cnki.csa.009619]
- 34 Li F, Min YJ, Zhang Y, *et al.* Towards general and efficient fault diagnosis: A novel framework for multi-fault cross-domain diagnosis of lithium-ion batteries in real-world scenarios. Energy, 2025, 334: 137825. [doi: 10.1016/j.energy.2025.137825]
- 35 Ijaodola OS, El-Hassan Z, Ogungbemi E, *et al.* Energy efficiency improvements by investigating the water flooding management on proton exchange membrane fuel cell (PEMFC). Energy, 2019, 179: 246–267. [doi: 10.1016/j.energy.2019.04.074]
- 36 Zuo B, Zhang ZH, Cheng JS, *et al.* Data-driven flooding fault diagnosis method for proton-exchange membrane fuel cells using deep learning technologies. Energy Conversion and Management, 2022, 251: 115004. [doi: 10.1016/j.enconman.2021.115004]
- 37 张雪霞, 蒋宇, 孙腾飞, 等. 质子交换膜燃料电池水淹和膜干故障诊断研究综述. 西南交通大学学报, 2020, 55(4): 828–838, 864.
- 38 Zhao JJ, Tu ZK, Chan SH. Carbon corrosion mechanism and mitigation strategies in a proton exchange membrane fuel cell (PEMFC): A review. Journal of Power Sources, 2021, 488: 229434. [doi: 10.1016/j.jpowsour.2020.229434]
- 39 Liu ZY, Pei ML, He QB, *et al.* A novel method for polymer electrolyte membrane fuel cell fault diagnosis using 2D data. Journal of Power Sources, 2021, 482: 228894. [doi: 10.1016/j.jpowsour.2020.228894]
- 40 Liu ZY, Pan WT, Abuker YYA, *et al.* A novel method of PEM fuel cell fault diagnosis based on signal-to-image conversion. Advances in Condition Monitoring and Structural Health Monitoring: WCCM 2019. Singapore: Springer, 2021. 251–259. [doi: 10.1007/978-981-15-9199-0_23]
- 41 Liu ZY, Mao L, Hu ZY, *et al.* A novel densely connected neural network for proton exchange membrane fuel cell fault diagnosis. International Journal of Hydrogen Energy, 2022, 47(94): 40041–40053. [doi: 10.1016/j.ijhydene.2022.09.158]

(校对责编: 张重毅)