

• 燃料电池汽车技术专题 •

基于 NGO-CNN-BiLSTM 神经网络的动态质子交换膜 燃料电池剩余使用寿命预测*

许亮 任圆圆 李俊芳

(天津理工大学,天津市新能源电力变换传输与智能控制重点实验室,天津 300384)

【摘要】为解决质子交换膜燃料电池(PEMFC)剩余使用寿命(RUL)预测精度不高的问题,提出了一种基于北方苍鹰优化(NGO)、卷积神经网络(CNN)和双向长短时记忆(BiLSTM)神经网络的动态燃料电池 RUL 预测模型。首先,利用 NGO 对 CNN-BiLSTM 模型的学习率、隐藏节点及正则化系数进行寻优,然后通过 CNN-BiLSTM 模型的卷积层对输入数据进行特征提取,输入到 BiLSTM 层进行时序建模和预测。同时,利用小波阈值去噪算法对原始数据进行平滑处理,采用皮尔逊相关系数提取模型输入变量,并搭建 NGO-CNN-BiLSTM 神经网络功率预测模型。仿真验证结果表明,该方法预测精度达 99.49%,高于其他对比模型的预测精度。

关键词:质子交换膜燃料电池 NGO-CNN-BiLSTM 网络 剩余使用寿命预测

中图分类号:TM911.4

文献标志码:A

DOI: 10.20104/j.cnki.1674-6546.20230313

Prediction of Remaining Useful Life for Proton Exchange Membrane Fuel Cell Based on NGO-CNN-BiLSTM Neural Network

Xu Liang, Ren Yuanyuan, Li Junfang

(Tianjin Key Laboratory of New Energy Power Conversion, Transmission and Intelligent Control, Tianjin University of Technology, Tianjin 300384)

【Abstract】In order to solve the problem of low accuracy in predicting the remaining service life of proton exchange membrane fuel cells, this paper proposed a dynamic fuel cell Remaining Useful Life (RUL) prediction model based on Northern Goshawk Optimization (NGO), Convolutional Neural Network (CNN) and Bi-directional Long Short-Term Memory (BiLSTM) neural network. Firstly, NGO optimized the learning rate, hidden nodes and regularization coefficient of the CNN-BiLSTM model, and then the CNN-BiLSTM model extracted the features of the input data through the convolutional layer, and input it into the BiLSTM layer for timing modeling and prediction. In addition, wavelet threshold de-noising algorithm was used to smoothen the original data. Pearson correlation coefficient was used to extract model input variables, and NGO-CNN-BiLSTM network power prediction model was built. The simulation and verification results show that this method can effectively improve the prediction accuracy of the remaining service life of fuel cells up to 99.49%, which is higher than that of other comparative models.

Key words: Proton Exchange Membrane Fuel Cell (PEMFC), NGO-CNN-BiLSTM network, Remaining Useful Life (RUL) prediction

【引用格式】许亮,任圆圆,李俊芳.基于 NGO-CNN-BiLSTM 神经网络的动态质子交换膜燃料电池剩余使用寿命预测[J].汽车工程师,2024(3):1-7.

XU L, REN Y Y, LI J F. Prediction of Remaining Useful Life for Proton Exchange Membrane Fuel Cell Based on NGO-CNN-BiLSTM Neural Network[J]. Automotive Engineer, 2024(3): 1-7.

1 前言

质子交换膜燃料电池(Proton Exchange

Membrane Fuel Cell, PEMFC)与其他类型的燃料电池相比,具有转换效率高、排放物无污染、启动快和工作温度适宜等优点,广泛应用于交通运输、便携

*基金项目:国家自然科学基金项目(61975151,61308120)。

通信作者:李俊芳(1974—),女,副教授,主要研究方向为数据智能处理、自抗扰控制等,lijunfang_tjut@163.com。

式电源和军事装备等领域^[1]。然而,PEMFC的寿命和成本成为制约其进一步商业化发展的主要因素^[2]。除实现材料突破和改进堆栈设计外,剩余使用寿命(Remaining Useful Life, RUL)预测与健康管理是确保 PEMFC 长时间安全稳定运行的方法之一^[3]。

目前,燃料电池 RUL 的预测方法可以分为基于模型的预测方法、基于数据的预测方法和混合方法 3 种。基于模型的方法考虑 PEMFC 降解过程中真实的物理老化现象,需要开展大量的计算和建立复杂的物理模型。由于还未完全掌握燃料电池内部退化机理,很难建立精确的降解模型,所以目前多采用基于数据的方法预测 RUL。基于数据的方法不需深入了解燃料电池的退化机理,只需学习监测到的非线性的降解数据即可进行精准预测。Xie^[3]等采用深度信念网络与极限学习机相结合的方法在稳态条件下对燃料电池进行了 RUL 预测。Chen^[4]等提出了粒子群算法优化灰色神经网络的方法来预测 PEMFC 在不同工况下的退化情况。

基于数据的方法中,循环神经网络(Recurrent Neutral Network, RNN)对数据具有记忆能力,特别适合处理燃料电池时序数据。然而,RNN 存在梯度消失和梯度爆炸的风险,因此,目前更常采用长短时记忆(Long Short-Term Memory, LSTM)神经网络^[5-8]。虽然 LSTM 神经网络解决了 RNN 梯度消失和梯度爆炸的问题,但单向 LSTM 神经网络只能单向训练输入序列,且仅考虑历史信息,获取的数据特征相对单一。

为提高燃料电池 RUL 数据中的空间序列特征提取和预测的准确性,本文在 LSTM 神经网络基础上提出 NGO-CNN-BiLSTM 神经网络组合模型。北方苍鹰优化(Northern Goshawk Optimization, NGO)算法用于优化 CNN-BiLSTM 模型中的学习率、隐藏节点和正则化系数,以确定最佳参数,卷积神经网络(Convolutional Neural Networks, CNN)用于特征提取,双向长短时记忆(Bi-directional Long Short-Term Memory, BiLSTM)神经网络用于对燃料电池数据进行双向分析,综合考虑数据的历史和未来信息,使预测更全面,从而提高预测准确性。最后,本文选择电堆功率作为退化指标,利用法国燃料电池实验室公开的 PEMFC 测试数据集开展试验,并与 LSTM、BiLSTM、麻雀搜索算法优化卷积神经网络-双向长短时记忆(Sparrow Search Algorithm-

Convolutional Neural Networks-Bi-directional Long Short-Term Memory, SSA-CNN-BiLSTM) 预测模型进行对比。

2 氢燃料电池老化测试及数据分析

2.1 氢燃料电池系统

本文使用的燃料电池衰退试验数据集来自法国燃料电池实验室公开的 PEMFC 测试数据^[9]。该数据集由 FCLAB 研究联盟在 1 kW 功率燃料电池试验台上获得,如图 1 所示。为了解燃料电池的工作状态,对电堆中涉及的多个物理参数进行了测量和控制,如表 1 所示。



图 1 PEMFC 电堆试验平台^[9]

表 1 PEMFC 的试验操作参数

参数	控制范围
冷却水温度/°C	20~80
冷却水流速/L·min ⁻¹	0~10
气体温度/°C	20~80
气体相对湿度/%	0~100
空气流速/L·min ⁻¹	0~100
氢气流速/L·min ⁻¹	0~30
气体压力/MPa	0~0.2
燃料电池电流/A	0~300

该测试设置了 2 个独立的加湿器,其中一个用于对空气和氢气进行加湿处理,另一个仅对空气进行加湿处理,以达到所需的湿度。此外,燃料电池通过冷却水系统将其温度控制在合理范围内,电流输出由 TDI Dynaload 有源负载控制^[10]。PEMFC 系统平台如图 2 所示。




图 2 PEMFC 平台示意

测试中,使用了 2 个燃料电池堆。每个燃料

电池堆由5个单块燃料电池串联组成,每个电池的横截面积为100 cm²,标称电流密度为0.7 A/cm²,最大电流密度为1.0 A/cm²。第1个燃料电池堆的工作电流密度保持恒定,为0.7 A/cm²,测得的数据集为FC1。第2个燃料电池堆附加振幅为0.7 A/cm²的电流,即在动态电流条件下测得的数据集为FC2。测试中共实时监测了25个参数,分别为老化时间、5片单电池电压和电堆总电压、电流和电流密度、氢气入口和出口温度、空气入口和出口温度、冷却水入口和出口温度、氢气入口和出口压力、空气入口和出口压力、氢气入口和出口流速、空气入口和出口流速、冷却水流速、空气入口湿度。FC1的记录时长为1 154.213 h,包含143 862组数据;FC2的记录时长为1 020.536 h,包含127 370组数据。

2.2 氢燃料电池数据处理

本文采用FC2数据集,由于该数据集数据在动态电流条件下测得,功率和电压随着时间的推移波动较大,本文选择功率作为预测燃料电池剩余使用寿命的退化指标。鉴于测试中仅采集了电堆电压和电流数据,而未直接采集功率数据,根据欧姆定律计算功率:

$$P=UI \quad (1)$$

式中: P 为电堆输出功率, U 、 I 分别为电堆电压、电流。

由于原始数据的数据量庞大且包含大量噪声和尖峰,会导致计算时间过长和计算结果误差较大,为减轻计算负担并提高精度,本文每隔1 h提取一组数据来重新构建数据集,选择了1 021组原始数据,并采用小波去噪方法对数据进行平滑处理,该方法计算简单,对噪声有较强的抑制作用,同时能够有效保留原始信号的有用信息。本文采用软阈值、硬阈值和固定阈值3种方式对燃料电池数据进行降噪处理,信噪比和均方根误差的比较结果表明,固定阈值降噪效果最佳。小波去噪的流程如图3所示。




图3 小波去噪流程

经过平滑处理的数据不仅保留了原始数据的主要趋势,还有效地去除了噪声和尖峰值。图4展示了经固定阈值降噪处理后的电堆电压、电堆电流和电堆功率数据。




图4 数据预处理前、后对比

2.3 输入数据的选择

测试中实时监测了25个参数,若使用所有参数作为输入,会导致模型复杂化,影响计算效率,降低模型的泛化能力。因此,采用SPSS统计分析软件对输入数据进行特征选择,依据皮尔逊相关系数 b 和双尾检验显著性 p 值的结果,选择与功率高度相关

的变量作为输入,如表2所示。其中, $p < 0.05$ 代表相关性显著, $p > 0.05$ 代表相互独立。相关系数 b 的取值范围为 $[-1,1]$, $b > 0$ 表示正相关, $b < 0$ 表示负相关, $b = 0$ 表示零相关, $|b|$ 越接近1,表示变量与功率的相关性越强。

表2 变量与功率的相关性分析

参数	b	p	数据数量/条
功率	1		1 021
电堆总电压	0.999**	0	1 021
电流	-0.468**	0	1 021
氢气入口温度	-0.725**	0	1 021
氢气出口温度	-0.605**	0	1 021
空气入口温度	-0.560**	0	1 021
空气出口温度	0.037	0.237	1 021
冷却水入口温度	0.135**	0	1 021
冷却水出口温度	0.044	0.163	1 021
氢气入口压力	-0.010	0.760	1 021
氢气出口压力	0.011	0.716	1 021
空气入口压力	-0.022	0.480	1 021
空气出口压力	-0.196**	0	1 021
氢气入口流速	0.042	0.183	1 021
氢气出口流速	-0.023	0.464	1 021
空气入口流速	-0.018	0.561	1 021
空气出口流速	0.436**	0	1 021
冷却水流速	-0.155**	0	1 021
空气入口湿度	-0.054	0.087	1 021

注:*表示在0.05级别(双尾),相关性显著;**表示在0.01级别(双尾),相关性显著。

3 氢燃料电池的剩余使用寿命预测

3.1 BiLSTM模型原理

LSTM神经网络在每个时间步内都有一个记忆细胞,使其能够选择性地记住重要的信息,同时忘记无关紧要的信息,从而减轻记忆负担^[8]。

LSTM神经网络中的信息只能单向训练输入序列且只能考虑历史信息,获取的数据特征相对单一;而BiLSTM神经网络可对燃料电池数据进行双向分析,利用前后连接的思想可以综合考虑数据的历史和未来信息,使预测过程更加全面,能够提高燃料电池寿命预测的准确性,BiLSTM神经网络如图5所示。其中, X_t, Y_t 分别为 t 时刻的输入、输出数据, $\vec{h}_t, \overleftarrow{h}_t$ 分别为 t 时刻的正向传播和反向传播隐藏状态向量。




图5 BiLSTM神经网络

BiLSTM神经网络由2个独立的传播方向相反的LSTM神经网络构成,正向传播的LSTM神经网络顺序读取数据,获取输入序列的历史数据信息,反向传播的LSTM神经网络逆序读取序列,获取输入序列的未来数据信息,最后将2个隐含层的输出拼接得到当前时刻的输出。

3.2 北方苍鹰优化算法

NGO算法主要包括猎物逃跑阶段和追逐逃生阶段。在第一阶段识别猎物后,北方苍鹰向猎物高速移动,并在第二阶段以短尾追逐的方式追捕猎物。

在第一阶段,对搜索空间进行全局搜索,目的是确定最优区域,对猎物的选择是随机的。猎物识别阶段的数学表达式为:

$$P_i = X_k, i=1,2,\dots,N, k=1,2,\dots,i-1,i+1,\dots,N \quad (2)$$

$$x_{ij}^{new,p_1} = \begin{cases} x_{ij} + r(p_{ij} - Y_{x_{ij}}), F_{p_i} < F_i \\ x_{ij} + r(x_{ij} - p_{ij}), F_{p_i} \geq F_i \end{cases} \quad (3)$$

$$X_i = \begin{cases} X_i^{new,p_1}, F_i^{new,p_1} < F_i \\ X_i, F_i^{new,p_1} \geq F_i \end{cases} \quad (4)$$

式中: X_i 为第 i 只北方苍鹰的位置; x_{ij} 为第 i 只北方苍鹰在第 j 维空间的位置; F_i 为第 i 只北方苍鹰的目标函数值; p_{ij} 为第 i 只北方苍鹰的猎物在第 j 维空间的位置; P_i 为第 i 只北方苍鹰猎物的位置; F_{p_i} 为目标函数值; k 为区间 $[1,N]$ 且不等于 i 的随机自然数; x_{ij}^{new,p_1} 为第 i 只北方苍鹰在第 j 维的新状态; X_i^{new,p_1} 为第 i 只北方苍鹰的位置; F_i^{new,p_1} 为北方苍鹰在第一阶段的目标函数值; $r \in [0,1], Y=1,2$ 为随机数,用于在搜索和更新过程中产生随机NGO行为。

猎物被北方苍鹰攻击后会试图逃跑,故北方苍鹰继续追逐猎物,由于北方苍鹰的速度高,它们几乎可在任何情况下追逐猎物并最终捕猎。对这种行为的模拟提高了算法对搜索空间的局部搜索能力。本文假设这次狩猎靠近半径为 R 的攻击位置,第二阶段的数学模型为:

$$x_{ij}^{new,p_2} = x_{ij} + R(2r - 1)x_{ij} \quad (5)$$

$$R=0.02(1-a/A) \quad (6)$$

$$X_i = \begin{cases} X_i^{new,p_2}, & F_i^{new,p_2} < F_i \\ X_i, & F_i^{new,p_2} \geq F_i \end{cases} \quad (7)$$

式中: a 为当前迭代次数, A 为最大迭代次数, X_i^{new,p_2} 为第 i 只北方苍鹰的新位置, x_{ij}^{new,p_2} 为第二阶段第 i 只北方苍鹰在第 j 维的新状态, F_i^{new,p_2} 为新状态下的目标函数值。

4 NGO-CNN-BiLSTM模型

本文在CNN-BiLSTM网络的基础上,以均方差作为适应度函数,通过NGO算法得到一组该网络的最优参数,最终使得CNN-BiLSTM的预测值误差最小。

NGO-CNN-BiLSTM模型分为NGO部分、CNN-BiLSTM部分和数据采集部分。在数据采集部分,先将采集的数据进行预处理,然后将数据划分为训练集和测试集。CNN-BiLSTM模型经过对NGO算法传入的超参数进行解码,从而得到学习率、隐藏节点、正则化系数的最优值。

将不同的输入数据分别经过卷积层和LSTM层,并将其输出特征拼接在一起,作为单一输入向量输入到全连接层中进行回归预测。利用数据处理获得的训练集开展网络模拟训练,最后对试验集数据加以预测,从而得出预测输出值与实际值的最大误差均方差。同时,以均方差作为适应性度值传递给NGO算法部分。NGO算法部分可以按照适应性度值进行苍鹰和猎物之间的移动位置控制,从而实现对猎物结构与全局问题最优解的迭代优化。采用这种方法,可以得到最终优化后的网络模式与参数。综上,本文构建了基于NGO-CNN-BiLSTM的剩余使用寿命功率预测模型,预测流程如图6所示。

4.1 氢燃料电池寿命预测的评价指标

采取均方根误差(Root Mean Squared Error, RMSE)、平均绝对误差(Mean Absolute Error, MAE)、预测寿命的相对误差(Relative Error, RE)和决定系数 R^2 来评价不同神经网络预测燃料电池RUL的可靠性和准确性。其中RMSE和MAE均指预测功率与实际功率间的误差,RE指预测RUL与实际RUL之间的偏差,都是预测误差的一种体现, R^2 表征真实数据曲线与预测数据曲线的拟合效果,RMSE、MAE和 R^2 越小,说明预测值与真实值越接近, R^2 的取值范围为 $[0,1]$, R^2 值越接近1,说明预测的精度越高,模型的预测效果越好。均方根误差、平均绝对误差、相对误差、决定系数的计算公式分别为:

$$R_{MSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (\hat{x}_i - x_i)^2} \quad (8)$$

$$M_{AE} = \frac{1}{m} \sum_{i=1}^m |x_i - \hat{x}_i| \quad (9)$$

$$R_E = \frac{|R_p - R_t|}{R_t} \times 100\% \quad (10)$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (\hat{x}_i - x_i)^2}{\sum_{i=1}^m (\bar{x}_i - x_i)^2} \quad (11)$$

式中: x_i 、 \hat{x}_i 分别为电堆功率的实际值和预测值; \bar{x}_i 为实际电堆功率的平均值; m 为实际电堆功率的数据数量; R_p 为预测的RUL,即预测寿命终点时刻与测试集起始时刻之差; R_t 为实际RUL,即实际寿命终点时刻与测试集起始时刻之差。

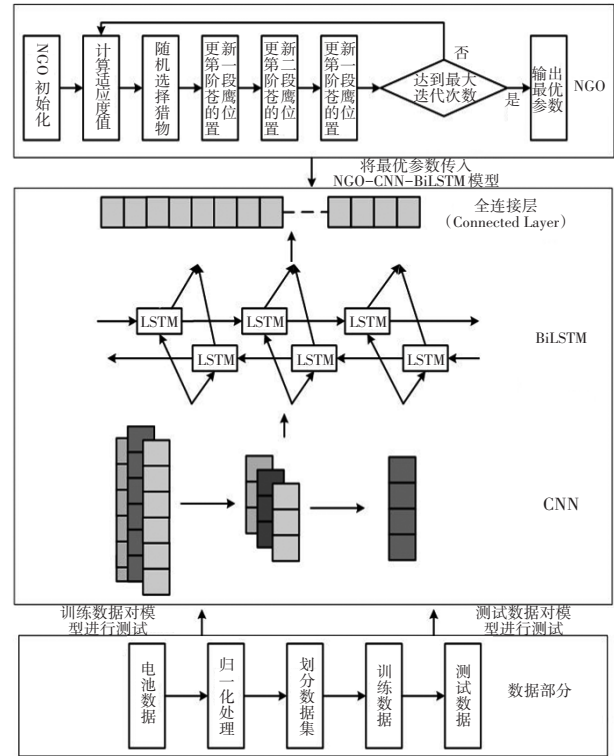


图6 NGO-CNN-BiLSTM神经网络模型预测流程

4.2 基于NGO-CNN-BiLSTM的预测结果分析

本文选取法国燃料电池实验室公开的PEMFC测试数据,采用MATLAB R2022a对提出的模型进行仿真验证。NGO-CNN-BiLSTM模型得到的最优参数为:最佳隐藏层节点数为25,最佳初始学习率为0.010 0,最佳L2正则化系数为0.000 1。训练配置为:随机失活率为0.25,即以25%的概率对输入进行随机失活,优化器选择Adam,激活函数选择线性整流函数(Rectified Linear Unit, ReLU),即将输入信

号小于零的部分置零,其余部分保持不变,以有效引入非线性特性,并帮助模型学习非线性关系,最大迭代次数为500。本文使用第0~649 h的共650个数据作为训练集,使用第650~1 021 h的共372个数据作为测试集,如图7所示。






图7 数据集划分


将650组训练集数据输入NGO-CNN-BiLSTM模型中进行训练,其中输出层为电堆功率;将372组测试集数据输入NGO-CNN-BiLSTM模型中进行测试验证,输出预测的电堆功率。为了验证本文所提出方法的有效性,将NGO-CNN-BiLSTM模型与LSTM模型、BiLSTM模型和SSA-CNN-BiLSTM模型进行对比,图8所示为预测起点 $T=650$ h时(对应图8中起始时刻),各模型预测的试验效果。各模型进行500次预测后测试集的比较结果如表3所示。




(a)LSTM



(b)BiLSTM



(c)SSA-CNN-BiLSTM



(d)NGO-CNN-BiLSTM

图8 4种神经网络燃料电池剩余使用寿命预测结果对比

表3 4种神经网络预测结果对比

预测方法	RMSE	MAE	RE/%	R^2
LSTM	0.486 6	0.409 8	1.24	0.913 4
BiLSTM	0.440 4	0.376 9	0.54	0.964 6
SSA-CNN-BiLSTM	0.287 5	0.197 0	4.04	0.969 8
NGO-CNN-BiLSTM	0.111 3	0.088 1	0.51	0.995 5

本文定义预测开始时的功率为初始功率,当功率降低到初始功率的98.5%时^[11],燃料电池的寿命达到终点。燃料电池的初始功率为224.554 72 W,故障阈值为221.186 399 2 W,当 $T=934.457 4$ h时,电池组实际功率为221.185 3 W,这是最接近实际故障功率的功率,由于第0~649 h时间段内燃料电池处于训练阶段,所以剩余使用寿命为285.457 4 h。当 $T=933$ h时,NGO-CNN-BiLSTM模型对电堆功率的预测值为221.272 06 W,最接近故障阈值,当训练阶段设定为第0~649 h时,预测的剩余使用寿命和实际剩余使用寿命分别为284 h和285.457 4 h,预测剩余使用寿命小于实际剩余使用寿命,有助于提升实际装置中的性能稳定性。

NGO-CNN-BiLSTM模型与LSTM模型、BiLSTM模型和SSA-CNN-BiLSTM模型的预测使用寿命分别为284 h、289 h、287 h和297 h,预测精度分别为

99.49%、98.76%、99.46%和95.96%。从表3中可以看出:本文提出的方法的决定系数和预测精度最高,分别为0.995 47和99.49%;本文方法的RMSE、MAE和RE均比其他网络小得多,表明NGO-CNN-BiLSTM模型具有较好的预测效果,更适用于PEMFC系统的剩余使用寿命预测。

5 结束语

本文在动态条件下对燃料电池的剩余使用寿命进行研究,提出了一种基于NGO-CNN-BiLSTM的剩余使用寿命预测方法。仿真验证结果表明,该方法的预测精度为99.49%,比SSA-CNN-BiLSTM神经网络的预测精度高3.53个百分点,且RE、MAE和RMSE均较LSTM模型、BiLSTM模型和SSA-CNN-BiLSTM模型小得多。因此,本文所提出的方法可以快速准确地预测动态条件下燃料电池的剩余使用寿命。

受水平和条件所限,本文只针对PEMFC在单指标下的短期剩余使用寿命预测进行了研究,未来可以考虑进行多指标下的短期和长期剩余使用寿命预测。此外,为了不造成资源浪费,还应进一步研究废旧燃料电池在寿命预测中的应用^[12]。

参 考 文 献

- [1] 谢宏远. 氢燃料电池的剩余使用寿命预测研究[D]. 哈尔滨: 哈尔滨工业大学, 2021.
XIE H Y. Research on Hydrogen Fuel Cell Remaining Useful Life Prediction[D]. Harbin: Harbin Institute of Technology, 2021.
- [2] WANG J, WANG H, FAN Y. Techno-Economic Challenges of Fuel Cell Commercialization[J]. Engineering, 2018: 352-360.
- [3] XIE Y, ZOU J, LI Z, et al. A Novel Deep Belief Network and Extreme Learning Machine Based Performance Degradation Prediction Method for Proton Exchange Membrane Fuel Cell[J]. IEEE Access, 2020: 176661-176675.
- [4] CHEN K, LAGHROUCHE S, DJERDIR A. Degradation Prediction of Proton Exchange Membrane Fuel Cell Based on Grey Neural Network Model and Particle Swarm Optimization[J]. Energy Conversion and Management, 2019, 195: 810-818.
- [5] ZUO J, LÜ H, ZHOU D, et al. Deep Learning Based Prognostic Framework Towards Proton Exchange Membrane Fuel Cell for Automotive Application[J]. Applied Energy, 2021, 281.
- [6] LIU J, LI Q, CHEN W, et al. Remaining Useful Life Prediction of PEMFC Based on Long Short-Term Memory Recurrent Neural Networks[J]. International Journal of Hydrogen Energy, 2019, 44(11): 5470-5480.
- [7] 王蓝煜, 吴占宽, 姜琦, 等. 基于机器学习的质子交换膜燃料电池寿命预测研究[J]. 现代机械, 2022(5): 1-5.
WANG L Y, WU Z K, JIANG Q, et al. Life Prediction of Proton Exchange Membrane Fuel Cells Based on Machine Learning[J]. Modern Machinery, 2022(5): 1-52.
- [8] WANG H, PENG M, MIAO Z, et al. Remaining Useful Life Prediction Techniques for Electric Valves Based on Convolution Auto Encoder and Long Short Term Memory[J]. ISA Transactions, 2021, 108: 333-342.
- [9] FCLAB Research. IEEE PHM 2014 Data Challenge[EB/OL]. [2023-09-25]. <http://eng.fclab.fr/ieee-phm-2014-data-challenge/>.
- [10] 刘嘉蔚, 李奇, 陈维荣, 等. 基于核超限学习机和局部加权回归散点平滑法的PEMFC剩余使用寿命预测方法[J]. 中国电机工程学报, 2019, 39(24): 7272-7279+7500.
LIU J W, LI Q, CHEN W R, et al. Remaining Useful Life Prediction Method of PEMFC Based on Kernel Extreme Learning Machine and Locally Weighted Scatterplot Smoothing[J]. Proceedings of the CSEE, 2019, 39(24): 7272-7279+7500.
- [11] 刘嘉蔚. 数据驱动的PEMFC发电系统故障诊断与寿命预测方法研究[D]. 成都: 西南交通大学, 2020.
LIU J W. Data-Driven Fault Diagnosis and Life Prediction Methods for PEMFC Power Generation System[D]. Chengdu: Southwest Jiaotong University, 2020.
- [12] 任圆圆, 许亮, 蔡远利. 质子交换膜燃料电池剩余使用寿命预测研究进展[J]. 电源技术, 2023, 47(8): 984-988.
REN Y Y, XU L, CAI Y L. Progress on Remaining Useful Life Prediction for Proton Exchange Membrane Fuel Cell [J]. Chinese Journal of Power Sources, 2023, 47(8): 984-988.

(责任编辑 斛 畔)

修改稿收到日期为2023年9月15日。