

DOI: 10.19783/j.cnki.pspc.240871

改进灰狼优化算法优化 CNN-LSTM 的 PEMFC 性能衰退预测

高峰阳¹, 刘庆寅¹, 赵丽丽², 齐丰旭¹, 刘嘉¹

(1. 兰州交通大学自动化与电气工程学院, 甘肃 兰州 730070; 2. 中车唐山机车车辆有限公司, 河北 唐山 063035)

摘要: 为进一步提高车用质子交换膜燃料电池(proton exchange membrane fuel cell, PEMFC)电堆性能衰退预测与剩余使用寿命预测精度, 提出一种改进灰狼优化算法优化卷积神经网络-长短期记忆(convolutional neural network-long short-term memory, CNN-LSTM)的车用 PEMFC 性能衰退预测方法。首先, 通过稳定小波变换对数据集去噪重构, 使用改进灰狼算法对实测 PEMFC 电堆衰退数据进行分析, 获得 CNN-LSTM 最优超参数。其次, 利用最优超参数训练 CNN-LSTM 网络模型进行 PEMFC 性能衰退预测, 并计算 PEMFC 电堆剩余使用寿命。最后, 在电堆静态和动态工况下, 将所提方法与传统长短期记忆循环网络、门控循环单元循环网络和未经优化的 CNN-LSTM 等模型预测进行比较。结果表明: 在静态工况中, 当训练集占比为 60%时, 所提方法相比传统 CNN-LSTM 预测结果均方根误差缩小 59.02%, 当训练集占比为 70%时, PEMFC 剩余使用寿命预测与实际相差 1.16 h; 在动态工况中, 当训练集占比为 40%时, 平均绝对误差缩小 18.78%。

关键词: 质子交换膜燃料电池; 改进灰狼优化算法; 卷积神经网络-长短期记忆; 衰退预测; 剩余使用寿命

PEMFC performance degradation prediction based on optimized CNN-LSTM using improved grey wolf optimization algorithm

GAO Fengyang¹, LIU Qingyin¹, ZHAO Lili², QI Fengxu¹, LIU Jia¹

(1. School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China;
2. CRRC Tangshan Co., Ltd., Tangshan 063035, China)

Abstract: To further improve the prediction accuracy of stack degradation and remaining useful life of proton exchange membrane fuel cell (PEMFC) for vehicles, a novel vehicle PEMFC degradation prediction method is proposed based on convolutional neural network-long short-term memory (CNN-LSTM) optimized by improved grey wolf algorithm (IGWO). First, the data set is denoised and reconstructed using stationary wavelet transform, and IGWO is then used to analyze the measured PEMFC stack degradation data to obtain the optimal hyperparameters for the CNN-LSTM model. Next, the CNN-LSTM network model is trained with the optimal hyperparameters to predict PEMFC performance degradation and calculate the remaining useful life of the PEMFC stack. Finally, under both static and dynamic operating conditions, the proposed method is compared with traditional LSTM, gated recurrent unit network, and unoptimized CNN-LSTM models. Results show that under static conditions with a 60 % training set ratio, the proposed method reduces the root mean square error by 59.02 % compared with the traditional CNN-LSTM. With a 70% training set ratio, the predicted remaining service life differs from the actual value by only 1.16 hours. Under dynamic conditions with a 40% training set ratio, the average absolute error is reduced by 18.78 %.

This work is supported by the CRRC "14th Five-Year Plan" Science and Technology Major Special Program (No. 2021CXZ021).

Key words: proton exchange membrane fuel cell; improved grey wolf optimization algorithm; convolutional neural network-long short-term memory; degradation prediction; remaining useful life

基金项目: 中车“十四五”科技重大专项计划项目资助(2021CXZ021)

0 引言

近年新能源技术发展迅速^[1-3], 质子交换膜燃料电池(proton exchange membrane fuel cell, PEMFC)拥有能量转换效率高、超低污染、可靠性高和维护方便等优点, 被认为是最有前途的新能源之一^[4-5]。然而在逐渐广泛的商业化应用过程中, PEMFC 较差的耐久性急需解决的关键问题^[6]。

PEMFC 剩余使用寿命(remaining useful life, RUL)预测技术可预测 PEMFC 性能衰退趋势, 有利于其状态维护和制定更优良的控制策略, 进一步提高其耐久性。基于机理的性能衰退预测模型能够揭示燃料电池系统中多种操作参数之间的相互作用关系, 从而为理解性能衰退的内在机制提供理论支持。文献[7]使用卡尔曼滤波器预测燃料电池的衰退状态, 然而 PEMFC 内部特性复杂, 机理模型预测方法建立精确模型十分困难, 致使衰退预测精度低。文献[8]使用半经验模型引入电化学表面积和等效电阻的降解对燃料电池的性能衰退趋势进行了准确描述, 相较于建立机理模型更简单, 但整体泛用性差, 且需要更多实验数据确定模型多维度参数。为解决上述问题, 文献[9]使用数据驱动方法, 建立一个单隐含层的反向传播神经网络, 进而预测 PEMFC 衰退趋势, 增强模型泛用性的同时, 进一步减少了建模难度, 但降低了预测精度且计算复杂度较高。在此基础上, 核超限学习机结合局部加权回归散点平滑法的 PEMFC 性能衰退模型^[10]以及基于长短期记忆(long short-term memory, LSTM)循环网络的 PEMFC 性能衰退预测方法^[11]被提出, 两种方法都大幅降低了计算复杂度, 但需要较多时间进行超参数调整, 且易发生过拟合。随后, 衰退预测结合循环网络的方法被相继提出, 文献[12]引入粒子群寻优算法对 LSTM 进行超参数优化, 并对 PEMFC 电堆电压进行了衰退预测, 相较于传统 LSTM 模型, 预测精度提升了约 50%, 但粒子群算法易陷入局部最优。文献[13]使用改进鲸鱼优化算法结合门控循环单元循环网络(gated recurrent unit, GRU)进一步提升了 PEMFC 性能衰退以及剩余使用寿命预测精度, 增强了模型泛化能力并解决了梯度消失问题, 但无法突破 LSTM 和 GRU 特征提取能力较差的局限, 且处理长期依赖关系能力较弱。为了准确获取衰退特征参数和更高预测精度, 文献[14]使用最小二乘支持向量机结合正则化粒子滤波混合方法, 预测出 RUL 与不确定表征概率分布, 但没有在多工况下进行对比验证, 且模型驱动与数据驱动相混合的预测方法^[15-16]虽然能够提高预测的精度和可靠

性, 但是依然存在精确模型难以建立的问题^[17]。

PEMFC 衰退影响因素之间大部分互相耦合, 许多无法量化只能定性分析, 很难将这些影响因素单独地剥离出来讨论衰退现象, 所以使用外部数据来研究衰退特性是建立 PEMFC 衰退模型的重要方法。多种数据驱动的混合预测方法只需依靠大量燃料电池衰退数据就可以做出较为准确的预测^[18-21], 卷积神经网络(convolutional neural network, CNN)-长短期记忆模型中, CNN 层通过卷积和池化操作, 可以有效地从原始数据中捕捉不同时间尺度中有判别性的特征; LSTM 层可以自动学习数据中的时序模式和依赖关系。在数据中存在噪声、缺失值或异常值的情况下, CNN-LSTM 也能够同时捕捉时序和空间关键特征进行预测, 更好地适应不同数据分布和特征表示, 具有处理多尺度信息的能力, 从而提升 PEMFC 性能衰退预测精度和鲁棒性。

为此, 使用 CNN-LSTM 网络模型对 PEMFC 进行性能衰退预测并计算剩余使用寿命。首先通过 PEMFC 衰退相关性分析确定电压为衰退预测指标, 使用稳定小波变换对测得数据去噪重构, 在预测模型中引入改进后灰狼优化(improved grey wolf optimization, IGWO)算法增强局部和全局之间的平衡, 防止出现局部最优, 提高模型探索性和精度, 再利用最优超参数训练 CNN-LSTM 网络模型进行 PEMFC 性能衰退和 RUL 预测, 最后将所提模型与传统 LSTM、GRU 和未经优化的 CNN-LSTM 等模型进行比较, 验证所提方法在 PEMFC 衰退和 RUL 预测中的可行性和精度。

1 CNN-LSTM 预测方法

1.1 CNN 结构与实现

对于大量数据在时间序列的分析, 一维神经网络有着较强的特征提取能力, 可以被用于固定长度信号分析。CNN 由多层构成, 数据由输入层输入, 经过卷积层和池化层的特征转换与提取后, 再通过全连接层将全部信息整合, 并由输出层输出, 卷积计算过程如式(1)所示。

$$k^l = f(W^l \cdot P^{l-1} + b^l) \quad (1)$$

式中: k^l 表示第 l 层特征向量; f 表示激活函数; W^l 表示第 l 层滤波器的权重矩阵; P^{l-1} 表示第 $l-1$ 层输出; b^l 表示从第 $l-1$ 层到 l 层的偏置量(模型中用于平移加权的可训练参数)。池化计算如式(2)所示。

$$y_\lambda^\xi(w) = \max\{k_i^l(\gamma)\}, \gamma \in K_w \quad (2)$$

式中: $y_\lambda^\xi(w)$ 为池化后第 ξ 层中第 λ 个特征矩阵中的组成元素; $k_i^l(\gamma)$ 为第 l 层的第 i 个特征向量中的

元素; K_w 为第 w 个池化覆盖区域。

1.2 LSTM 结构及实现

LSTM 使用了 3 个门控单元来更新或丢弃历史信息, 其具体结构如图 1 所示。

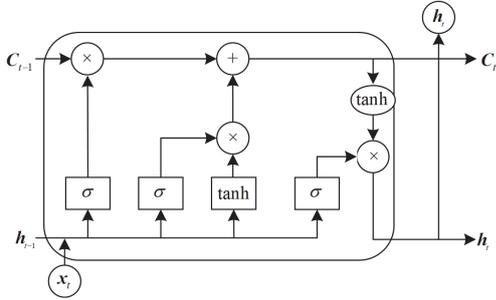


图 1 LSTM 神经网络结构

Fig. 1 LSTM neural network structure

1) 遗忘门

遗忘门利用 Sigmoid 来决定哪些数据信息可以通过单元状态传输, 基于上一时刻输出来判断信息。遗忘门的门控信号表达式为

$$f_t = \sigma(U_f \cdot [h_{t-1}, x_t] + b_1) \quad (3)$$

式中: f_t 为遗忘门门控信号; U_f 表示 f_t 的权重矩阵; b_1 为遗忘门偏置量; σ 表示 Sigmoid 激活函数, 取值范围为 $[0,1]$; h_{t-1} 表示上一时刻的隐藏状态矩阵; x_t 表示当前时刻的输入信息。

2) 输入门

输入门通过 Sigmoid 来决定哪些数值用于更新; 之后由 \tanh 层来生成候选值并将其相加, 得到新候选值。结合这两个步骤, 可在大量数据中舍弃不需要的信息并添加新信息, 其表达式为

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (4)$$

$$i_t = \sigma(U_i \cdot [h_{t-1}, x_t] + b_2) \quad (5)$$

$$\tilde{C}_t = \tanh(U_c \cdot [h_{t-1}, x_t] + b_3) \quad (6)$$

式中: C_t 为 t 时刻的单元状态矩阵; \tilde{C}_t 为候选状态矩阵; i_t 为输入门门控信号; U_i 和 b_2 分别为门控信号 i_t 的权重矩阵与输入门偏置量; U_c 为 \tanh 的权重矩阵; b_3 为状态更新偏置量。

3) 输出门

通过 Sigmoid 层获得一个初始输出后, 使用 \tanh 函数将输出减小到 $[-1,1]$ 区间内, 再与 Sigmoid 得到的输出逐对相乘, 从而得到模型输出, 其表达式为

$$o_t = \sigma(U_o \cdot [h_{t-1}, x_t] + b_4) \quad (7)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (8)$$

式中: o_t 为输出门门控信号; U_o 和 b_4 分别表示 o_t 的权重矩阵与偏置量。

CNN-LSTM 预测流程如图 2 所示。

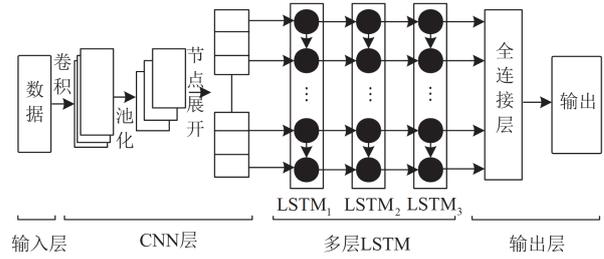


图 2 CNN-LSTM 预测流程

Fig. 2 CNN-LSTM prediction process

1.3 改进灰狼优化算法

1.3.1 灰狼优化算法

灰狼优化(grey wolf optimization, GWO)算法在灰狼群个体之间的合作和竞争关系中产生, 利用灰狼的行动来搜索问题最优解^[22]。GWO 算法流程涵盖灰狼社会等级划分、围捕猎物、攻击猎物以及搜寻猎物等多个环节。

1) 社会等级分层

根据灰狼在种群中适应性高低, 对灰狼社会等级进行分层, 适应性最高的灰狼称为 α 狼, 其次为 β 狼和 δ 狼, 其余灰狼统称为 ω 狼。GWO 优化结果主要由每代种群中适应性最高的 3 个解(α 、 β 、 δ)来指导实现。

2) 包围猎物

狼群进行围捕行动时会逐步靠近附近猎物, 其行动过程可描述为

$$D = C \odot X_p(e) - X(e) \quad (9)$$

$$X(e+1) = X_p(e) - A \odot D \quad (10)$$

$$A = 2a \odot r_1 - a \quad (11)$$

$$C = 2r_2 \quad (12)$$

式中: D 为候选灰狼与最优灰狼之间的距离; e 为灰狼算法流程迭代次数; “ \odot ” 表示 Hadamard 乘积操作; A 、 C 均为协同系数向量; X_p 为猎物位置向量; $X(e)$ 为当前灰狼所在位置向量; 在整个迭代过程中, a 由 2 线性降低到 0; r_1 和 r_2 均为区间 $[0,1]$ 内随机向量。

3) 狩猎

灰狼能确定猎物所在区域, 但不能精确判断出其具体位置。为了再现灰狼(候选最优解)搜寻行为, 假设适应性最高的 3 个解(α 、 β 、 δ)具有最高的猎物搜索能力, 在算法迭代过程中, 每次保留当前种群中适应性最好的 3 只灰狼(α 、 β 、 δ)的位置, 然后其余 ω 狼(可能解)根据 α 、 β 、 δ 提供的信息来更新位置。该行动过程可描述为

$$\begin{cases} D_\alpha = C_1 \odot X_\alpha - X \\ D_\beta = C_2 \odot X_\beta - X \\ D_\delta = C_3 \odot X_\delta - X \end{cases} \quad (13)$$

$$\begin{cases} X_1 = X_\alpha - A_1 \odot D_\alpha \\ X_2 = X_\beta - A_2 \odot D_\beta \\ X_3 = X_\delta - A_3 \odot D_\delta \end{cases} \quad (14)$$

$$X(e+1) = \frac{X_1 + X_2 + X_3}{3} \quad (15)$$

式中： X_α 、 X_β 、 X_δ 分别表示狼群中3个最优解 α 、 β 、 δ 的位置向量； X 与 X_1 、 X_2 、 X_3 为其余灰狼的位置向量； D_α 、 D_β 、 D_δ 分别表示候选灰狼与最优 α 、 β 、 δ 狼之间的距离； C_1 、 C_2 、 C_3 分别表示最优 α 、 β 、 δ 狼的协同系数向量； A_1 、 A_2 、 A_3 为随机系数向量， $|A|$ 的大小决定种群灰狼搜索模式是分散还是集中。可能解位置会出现在 α 、 β 、 δ 所划定的随机圆内。

4) 攻击猎物

由式(11)可知， a 值发生改变会引起 A 值的相应变化。 A 表示一个在区间 $[-a, a]$ 上的随机协同系数向量，且在迭代过程中， a 值会线性减少。当 A 位于区间 $[-1, 1]$ 内时，在下一时刻，灰狼可能移动到当前所在位置与猎物之间区域内的任意一个位置。

5) 搜寻猎物

灰狼主要依赖适应性最好的 α 、 β 、 δ 信息来寻找猎物。建立模型时，如3)中所述，当 $|A| > 1$ 时灰狼会分散搜寻区域各处，当 $|A| < 1$ 时灰狼则会集中起来寻找猎物，这种行为方式使GWO具有在局部搜索的同时，兼顾全局搜索的能力。在GWO算法里， C 是另一个搜索系数，从式(12)可知， C 向量由区间范围 $[0, 2]$ 内的随机值组成，其为区域内猎物提供了随机权重， $|C| > 1$ 时权重增加， $|C| < 1$ 时权重减小，这有助于GWO在优化过程中展示出随机搜索行为，以避免算法陷入局部最优。

1.3.2 改进灰狼算法

为解决GWO算法缺乏种群多样性、开发与探索不平衡以及过早收敛等问题，引入基于维度学习的狩猎(dimension learning-based hunting, DLH)搜索策略，增强局部搜索和全局搜索之间的平衡，狼的个体狩猎会被邻居学习，从而保持多样性。

$$R_q(e) = \|X_q(e) - X_{q-GWO}(e+1)\| \quad (16)$$

$$N_q(e) = \{X_j(e) | D_q(X_q(e), X_j(e)) \leq R_q(e), X_j(e) \in P_{op}\} \quad (17)$$

$$X_{q-DLH,d}(e+1) = X_{q,d}(e) + \text{rand} \times (X_{g,d}(e) - X_{p,d}(e)) \quad (18)$$

优先候选人通过比较 $X_{q-GWO}(e+1)$ 和 $X_{q-DLH}(e+1)$ 的适应值来决定

$$X_q(e) = \begin{cases} X_{q-GWO}(e+1), & f(X_{q-GWO}) < f(X_{q-DLH}) \\ X_{q-DLH}(e+1), & \text{其他} \end{cases} \quad (19)$$

式中： $R_q(e)$ 表示当前位置和候选位置的欧式距离； $X_q(e)$ 与 $X_j(e)$ 分别表示第 e 次迭代中第 q 、 j 只灰狼的位置； $X_{q,d}(e)$ 表示 $X_q(e)$ 的第 d 个分量； $X_{q-GWO}(e+1)$ 和 $X_{q-DLH}(e+1)$ 分别表示GWO和DLH选择的第 q 只灰狼的位置； $X_{q-DLH,d}(e+1)$ 表示 $X_{q-DLH}(e+1)$ 的第 d 个分量； $N_q(e)$ 为 $X_q(e)$ 的邻近区域； $X_{g,d}(e)$ 表示从 $N_q(e)$ 中随机选择的灰狼的第 d 个分量； D_q 表示 $X_q(e)$ 与 $X_j(e)$ 的欧式距离； P_{op} 表示灰狼个体集合； $X_{p,d}(e)$ 表示从 P_{op} 中随机选择的灰狼的第 d 个分量； $f(\cdot)$ 表示适应度函数。

为了进一步说明IGWO算法的优势，分别使用4种测试函数从收敛速度、寻优精确性、实用性和全局寻优能力方面，与改进鲸鱼优化算法(improved whale optimization algorithm, IWOA)^[13]和贝叶斯优化(Bayesian optimization, BO)^[23]算法进行性能评估。

Sphere函数与Quartic函数只有一个全局最优解，用来测试算法收敛速度和精确性，分别如式(20)和式(21)所示。

$$S(m) = \sum_{s=1}^n m_s^2 \quad (20)$$

$$Q(z) = \sum_{s=1}^n s z_s^4 + \text{rand}(0, 1) \quad (21)$$

式中： $S(m)$ 和 $Q(z)$ 分别表示Sphere函数与Quartic函数； m_s 和 z_s 分别表示Sphere函数与Quartic函数的待优化变量； n 表示变量维度。

Rastrigin函数和Ackley函数具有多个局部最优解和一个全局最优解，用来检测算法实用性^[24]和避免局部最优并寻得全局最优的能力，分别如式(22)和式(23)所示。

$$R(v_1, v_2) = 20 + v_1^2 + v_2^2 - 10 \cos(2\pi v_1) - 10 \cos(2\pi v_2) \quad (22)$$

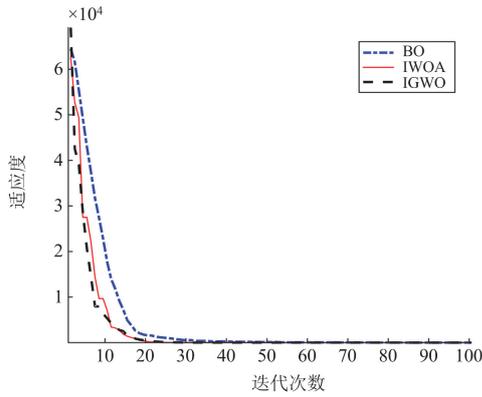
$$A(u_1, u_2) = -20e^{-0.2\sqrt{0.5(u_1^2 + u_2^2)}} - e^{-0.5(\cos(2\pi u_1) + \cos(2\pi u_2))} + 22.71282 \quad (23)$$

式中： $R(v_1, v_2)$ 和 $A(u_1, u_2)$ 分别表示Rastrigin函数和Ackley函数； v_1 、 v_2 和 u_1 、 u_2 分别表示Rastrigin

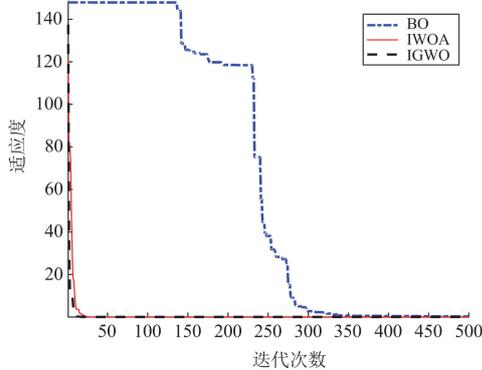
函数和 Ackley 函数的待优化变量。

当进行性能评估时, 上述函数选取个体数为 30, Sphere 函数评估迭代次数取 100, 其余函数评估迭代次数取 500, 性能评估对比结果如图 3 所示。

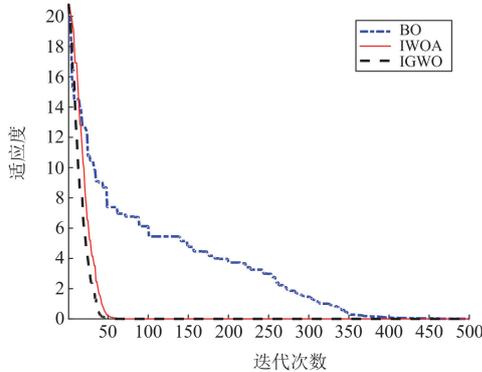
由图 3 可知, 上述 3 种算法都具有较快收敛速度, BO 相比另外两种算法寻优精确度有较大不足; IGWO 算法与 IWOA 都有较高寻优精度, 但 IGWO 在实用性和全局寻优方面较强; 由于电池衰退数据具有较多维度, 且数据量极大, 对算法实用性和全局寻优能力要求较高, 因此选择综合性能较优的 IGWO 更能满足预测需求。



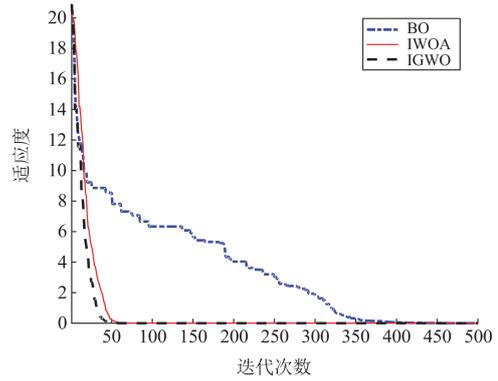
(a) Sphere函数适应度曲线



(b) Quartic函数适应度曲线



(c) Rastrigin函数适应度曲线



(d) Ackley函数适应度曲线

图 3 性能评估对比结果

Fig. 3 Comparison results of performance evaluation

1.4 IGWO 优化 CNN-LSTM 衰退预测流程

基于 IGWO 优化 CNN-LSTM 的 PEMFC 性能衰退预测流程如图 4 所示。图中: e 为算法寻优迭代次数; E 为模型训练迭代次数。

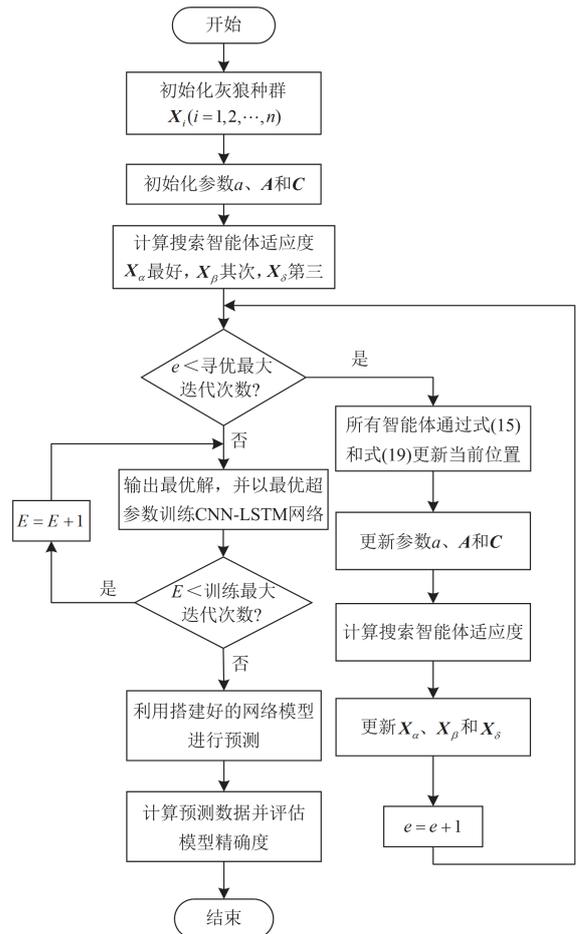


图 4 基于 IGWO 优化 CNN-LSTM 的 PEMFC 性能衰退预测流程

Fig. 4 Performance degradation prediction process of PEMFC based on IGWO-optimized CNN-LSTM

将 CNN 的局部特征提取能力与 LSTM 网络的时序建模能力相结合, 设计出 CNN-LSTM 混合模型, 使用 IGWO 算法优化后, 对 PEMFC 性能进行衰退预测。首先, 初始化灰狼种群以及参数, 计算搜索智能体适应度; 其次, 判断满足循环条件后更新智能体当前位置和参数, 再次更新适应度; 当完成迭代后, 使用最优超参数与输入的特征参数训练 CNN-LSTM 模型, 进行 PEMFC 性能衰退预测并计算出电池剩余使用寿命。

2 实验与分析

2.1 数据处理

2.1.1 数据相关性分析

为验证所提 IGWO 算法优化 CNN-LSTM 模型的预测性能和泛化能力, 分别在静态工况和动态工况下对 PEMFC 进行性能衰退长期和短期预测, FC1 为长期静态工况数据集, FC2 为短期动态工况数据集。PEMFC 测试原理如图 5 所示。

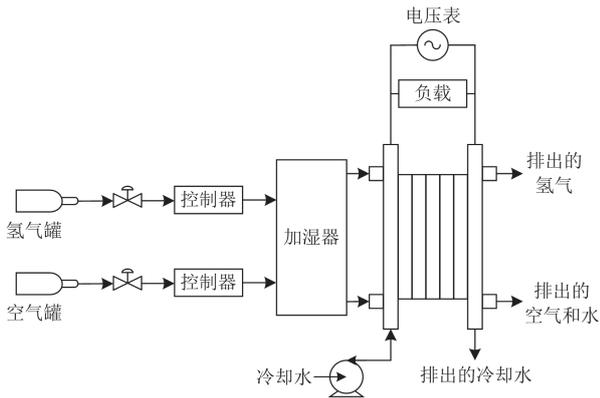


图 5 PEMFC 测试原理

Fig. 5 PEMFC test principle

数据集 FC1 使用来自法国燃料电池研究联盟 (fuel cell laboratory, FCLAB)提供的实验数据^[25], 测试平台如图 6 所示。

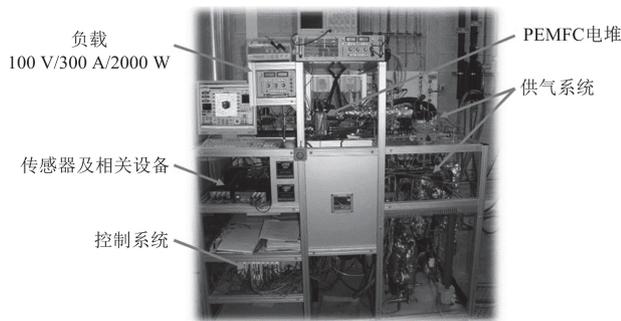


图 6 PEMFC 测试平台

Fig. 6 PEMFC test platform

电池电堆由 5 个单体组成, 额定功率为 1 kW, 单体活化面积为 100 cm², 额定电流密度为 0.70 A/cm², 最大电流密度为 1 A/cm²。

FC1 特征参数包括单体电压、电堆电压、电流以及反应气体出入口的温湿度、流量以及压力等, 如表 1 所示。在长期衰退测试过程中, 参数数值由 PXI/SCXI 测量控制平台实时记录。为确保 PEMFC 长时间安全运行以及数据连续有效, 定期对电池进行性能表征并记录电化学阻抗谱与极化曲线, 排除故障原因导致的数据异常, 表征时刻为: 0 h、48 h、185 h、348 h、515 h、658 h、823 h、991 h。

表 1 数据集 FC1 特征参数

Table 1 Feature parameters of data set FC1

参数	物理意义
$U_1 - U_5, U_{tot}/V$	单电池和电堆电压
$I/A, J/(A/cm^2)$	电流和电流密度
$T_{inH_2}, T_{outH_2}/^{\circ}C$	氢气入口和出口温度
$T_{inWAT}, T_{outWAT}/^{\circ}C$	冷却水入口和出口温度
$T_{inAIR}, T_{outAIR}/^{\circ}C$	空气入口和出口温度
$P_{inH_2}, P_{outH_2}/kPa$	氢气入口和出口压力
$P_{inAIR}, P_{outAIR}/kPa$	空气入口和出口压力
$D_{inH_2}, D_{outH_2}/(L/min)$	氢气入口和出口流量
$D_{inAIR}, D_{outAIR}/(L/min)$	空气入口和出口流量
$D_{WAT}/(L/min)$	冷却水流量
$H_{rAIRFC}/\%$	空气入口湿度

数据集 FC2 选取的是由 Greenlight20 测试站^[26]对单片 PEMFC 进行了约 1000 h 的动态负载实验所得数据, 特征参数^[27]如表 2 所示。

表 2 数据集 FC2 特征参数

Table 2 Feature parameters of data set FC2

参数	物理意义
$C_{current}/A, V_{oltage}/V$	电流、电压
P_{ower}/W	功率
$P_{a_in}, P_{a_out}/kPa$	阳极入口、出口压力
$P_{c_in}, P_{c_out}/kPa$	阴极入口、出口压力
$T_{a_in}, T_{a_out}/^{\circ}C$	阳极入口、出口温度
$T_{c_in}, T_{c_out}/^{\circ}C$	阴极入口、出口温度
$T_{dew_H_2}/^{\circ}C$	氢气露点水温
$T_{dew_O_2}/^{\circ}C$	空气露点水温
$D_{total_H_2}/(L/min)$	氢气总流量
$D_{total_O_2}/(L/min)$	空气总流量
$T_{a_endplate}/^{\circ}C$	电池工作温度

FC2 中每个完整动态循环都进行了极化特性测试, 获取 PEMFC 输出电压、电流、功率以及温度等参数。测试时氢气和空气进口压力均设为 110 kPa, 氢气入口温度和氢气露点水温分别设置为 70 °C 和

55 ℃, 进风口温度设置为 70 ℃, 空气露点水温设置为 65 ℃。

对衰退数据进行相关性分析, 计算方法如式(24)所示^[28]。

$$\rho_{ij} = \frac{\text{cov}(H_i, H_j)}{\sqrt{\text{var}(H_i)\text{var}(H_j)}} \quad (24)$$

式中: ρ_{ij} 为衰退相关系数; H_i 、 H_j 为实验采集数据集; $\text{cov}(H_i, H_j)$ 表示协方差; $\text{var}(\cdot)$ 表示方差。以 FC1 数据集为例, 除去冗余数据后, 各参数与 PEMFC 衰退相关性^[29]如表 3 所示。

表 3 特征参数与 PEMFC 性能衰退相关性

Table 3 Correlation between feature parameters and PEMFC performance degradation

参数	衰退相关系数 ρ
U_{tot}	-0.943
I	0.592
T_{inH_2} 、 T_{outH_2}	0.079、0.04
T_{inWAT} 、 T_{outWAT}	-0.203、-0.072
T_{inAIR} 、 T_{outAIR}	-0.088、-0.02
P_{inH_2} 、 P_{outH_2}	-0.011、0.314
P_{inAIR} 、 P_{outAIR}	-0.053、-0.09
D_{inH_2} 、 D_{outH_2}	-0.06、-0.19
D_{inAIR} 、 D_{outAIR}	0.014、-0.060
D_{WAT} 、 H_{tAIRFC}	-0.22、0.258

表 3 中电堆电压与 PEMFC 性能衰退呈现强负相关, 为-0.943, 而其他参数相关性相比较低, 说明电堆电压变化能更直观地反映出 PEMFC 性能变化。因此, 采用电堆电压变化作为 PEMFC 性能衰退预测与寿命预测指标。此外, 为进一步简化计算并提升预测精度, 采用多元时间预测序列, 舍弃相关性极弱特征参数, 将相关性较强的电流、冷却水入口温度、氢气出口压力、氢气出口流量、冷却水流量和空气入口湿度作为数据输入, 进行 PEMFC 电堆性能衰退与 RUL 预测。

2.1.2 数据处理

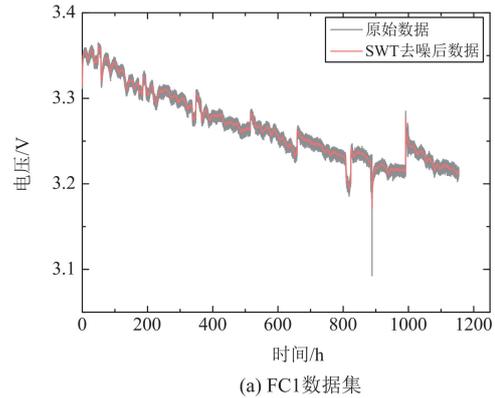
按预测时间是否大于 50 h, PEMFC 性能衰退预测可分为长期和短期预测^[28], 为验证所提模型在多工况下的鲁棒性和预测精度, 选取静态工况数据集 FC1 约 1150 h 运行数据用于长期预测, 选取动态工况数据集 FC2 约 3500 s 运行数据用于短期预测。

数据集在测量过程中会受到外界因素干扰, 存在大量噪声和尖峰, 尤其在每个周期中电压衰退和恢复现象^[19]发生时严重影响了模型预测精确度。为了更精确地预测 PEMFC 衰退趋势与 RUL, 使用稳

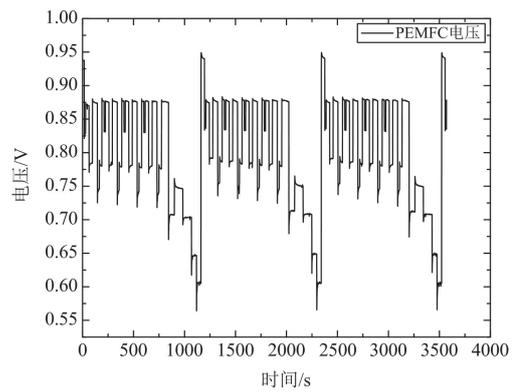
定小波变换(stationary wavelet transform, SWT)对 FC1 数据进行去噪平滑处理。

SWT 是一种基于小波分解和重构的分析方法, 具有尺度和平移不变性, 在 SWT 中, 首先选择一个稳定小波函数作为基础小波, 并构建高通滤波器和低通滤波器, 信号通过卷积操作在每一阶滤波器进行上采样, 延展滤波信号, 使得原始信号在小波变换后分解成近似信号和多个频率下的细节信号, 将这些信号分别进行去噪处理后再合并, 最大限度保持信号长度和信息完整性。相比离散小波变换(discrete wavelet transform, DWT)下采样方式^[29], SWT 能有效解决数据处理中关键信息缺失问题, 准确还原原始信号, 保证数据连续有效。

选取的动态工况数据集 FC2 中, 包含了 3 个完整动态循环, 用于 PEMFC 性能衰退短期预测。由于短期预测时, 噪声影响相比长期预测不明显, 因此不做去噪处理以验证所提预测模型抗噪能力。处理后实验数据如图 7 所示。



(a) FC1数据集



(b) FC2数据集

图 7 预处理后实验数据集

Fig. 7 Preprocessed experimental data set

2.2 测试对比分析

2.2.1 数据集 FC1 长期预测

利用 FC1 数据训练 IGWO 算法优化 CNN-LSTM

预测模型对 PEMFC 性能衰退进行长期预测, 通过划分不同比例的训练数据集(50%、60%、70%、80%), 分别构建预测模型并生成对应的性能衰退预测曲线, 如图 8 所示。

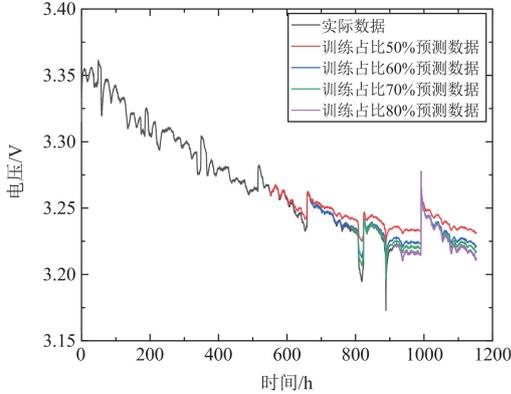


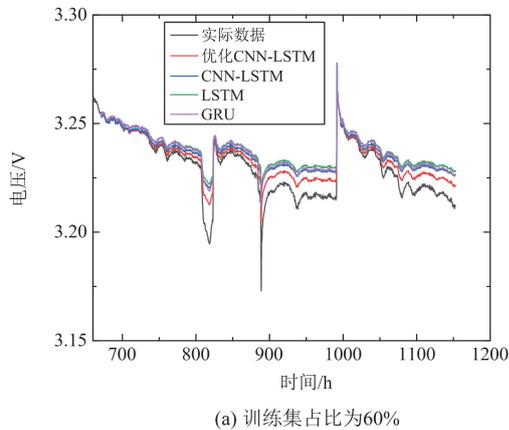
图 8 IGWO 优化 CNN-LSTM 在数据集 FC1 中的衰退预测
Fig. 8 Degradation prediction on data set FC1 using IGWO-optimized CNN-LSTM

从图 8 中可以看出, 训练集占比为 50% 的预测曲线误差相对较大, 这是由于训练集数据较少, 预测模型还没有完全掌握电堆衰退特性导致。训练集占比为 60% 时, 预测曲线能对实际数据进行准确预测, 且训练所用数据越多, 后续预测结果越贴近实际数据, 当训练集占比为 80% 时, 预测曲线基本与实际数据曲线重合。

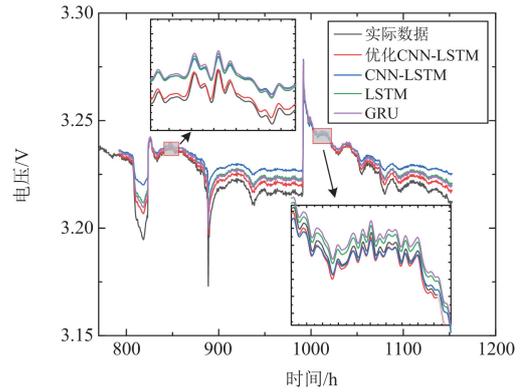
将上述方法与 LSTM、GRU 和未经优化的 CNN-LSTM 进行对比验证, 4 种模型在数据集 FC1 中的电池性能衰退预测如图 9 所示。

当训练集占比小于等于 50% 时, 虽然所提预测模型有优势, 但上述预测模型的精度都相对较低, 因此不再对比验证, 仅进行训练集占比为 60%、70%、80% 的 PEMFC 性能衰退预测趋势对比。

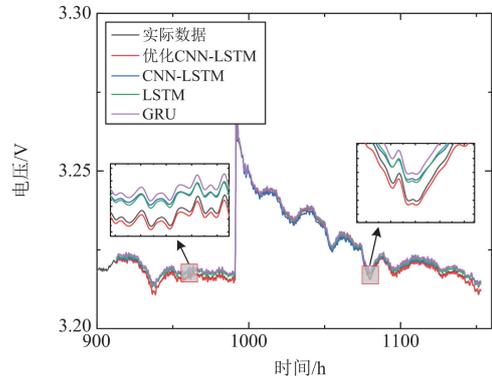
从图 9(a) 可以看出, 当训练集占比为 60% 时, 虽然 IGWO 优化 CNN-LSTM 模型相比其他循环网



(a) 训练集占比为60%



(b) 训练集占比为70%



(c) 训练集占比为80%

图 9 4 种模型在数据集 FC1 中的电池性能衰退预测
Fig. 9 Performance degradation prediction on data set FC1 using four models

络能更好地预测衰退趋势, 但在 810 h 和 900~1000 h 以及 1100 h 后, 所有方法都产生了相对较大误差, 这是由模型没有完全学习电堆性能衰退特性导致的。图 9(b) 和图 9(c) 中, 所提 4 种循环网络模型在衰退趋势精确度上均有明显提升, 而 IGWO 算法优化后 CNN-LSTM 模型相比传统 CNN-LSTM、GRU 和 LSTM 预测精度提升更显著, 当训练集占比为 70% 时, 预测值相比实际电压最多相差约 0.025 V, 当训练集占比为 80% 时, 预测值与实际电压基本重合, 最多相差约 0.002 V, 所提算法更能精确地描述 PEMFC 的衰退趋势。

引入平均绝对误差(mean absolute error, MAE)、决定系数(R-squared, R^2)、平均绝对百分比误差(mean absolute percentage error, MAPE)和均方根误差(root mean square error, RMSE)进一步判断各方法的预测精度, 对应数学表达式如式(25)~式(28)所示, 所得电池性能衰退预测误差如图 10 所示。

$$M_{AE} = \frac{1}{n} \sum_{k=1}^n (\hat{Y}_k - Y_k)^2 \quad (25)$$

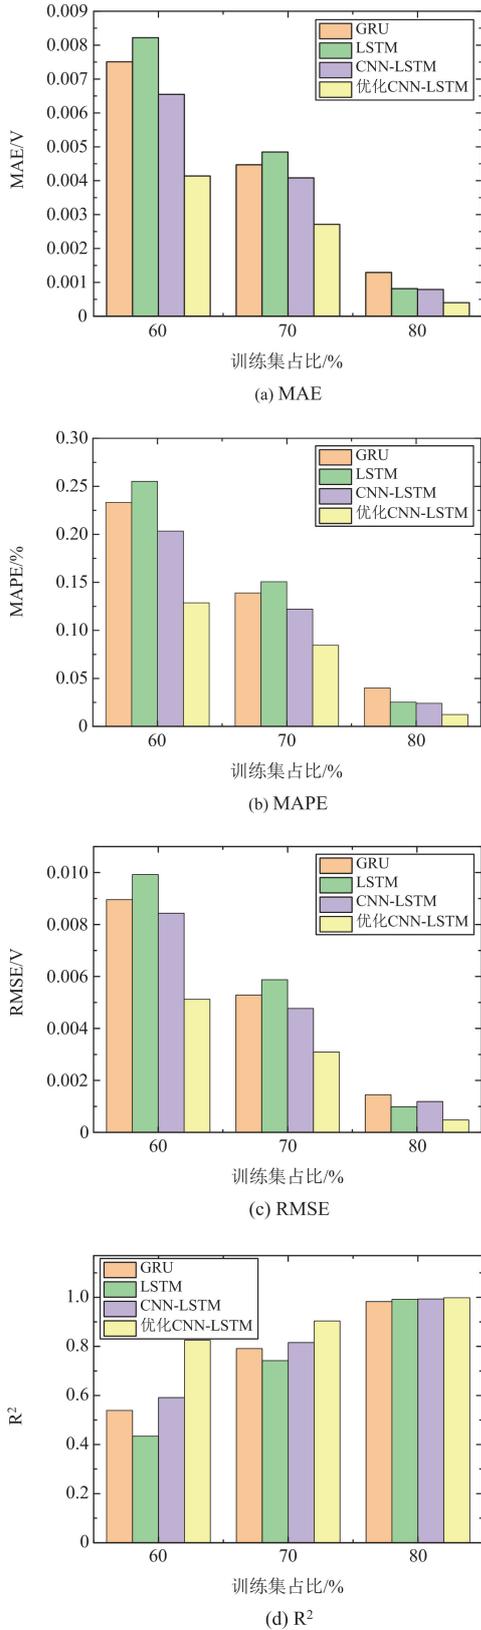


图 10 4 种模型在数据集 FC1 中的电池性能衰退预测误差
Fig. 10 Prediction errors of battery performance degradation on dataset FC1 using four models

$$R^2 = \frac{\sum_{k=1}^n \|\hat{Y}_k - \bar{Y}_k\|^2}{\sum_{k=1}^n \|Y_k - \bar{Y}_k\|^2} \quad (26)$$

$$M_{APE} = \frac{100\%}{n} \sum_{k=1}^n \left| \frac{\hat{Y}_k - Y_k}{Y_k} \right|^2 \quad (27)$$

$$R_{MSE} = \sqrt{\frac{1}{n} \sum_{k=1}^n (\hat{Y}_k - Y_k)^2} \quad (28)$$

式中： n 为预测数据的数量； Y_k 、 \hat{Y}_k 、 \bar{Y}_k 分别为电压真实值、电压预测值和输出电压平均值。

由图 10 可以看出，CNN-LSTM 相比 LSTM 和 GRU 模型已有不少提升，使用 IGWO 算法后，预测精度再次提高，优化后 CNN-LSTM 预测模型，在训练集占比为 60% 时 MAE 和 RMSE 分别为 0.004 141 4 V 和 0.005 121 3 V，相比未经优化的 CNN-LSTM 分别减小 36.7% 和 59.02%；优化后 CNN-LSTM 模型的 MAPE、 R^2 在各训练集占比中也均优于其他 3 种算法。随着训练集占比增加，相比 CNN-LSTM、LSTM 和 GRU，IGWO 优化后 CNN-LSTM 模型的预测误差有较大幅度降低，训练集占比为 80% 时，MAE 为 0.000 402 48 V，MAPE 为 0.012 478%，RMSE 为 0.000 479 41 V， R^2 为 0.998。将所提方法与文献[19, 29-30]所用方法在静态工况数据集 FC1 中进行电池性能衰退预测误差对比，如表 4 所示。

表 4 不同方法的电池性能衰退预测误差对比

Table 4 Comparison of prediction errors for battery performance degradation using different methods

训练集 占比/%	RMSE/V			
	文献[30]	文献[19]	文献[29]	IGWO-CNN-LSTM
60	0.011 0	0.008 91	0.005 4	0.005 12
70	0.010 4	0.006 10	0.003 3	0.003 09

由表 4 可知，当训练集占比为 60% 时，所提方法 RMSE 相比其他方法，从左到右分别降低 53.45%、42.53% 和 5.19%；训练集占比为 70% 时，所提方法相比其他方法，RMSE 分别降低 70.29%、49.34% 和 6.36%，说明所提方法的预测精度更高。

为了保证公平性，以 FC1 训练集占比 60% 为例，将 LSTM、GRU 以及 CNN-LSTM 模型都使用 IGWO 算法优化，进行电池性能衰退预测趋势对比，如图 11 所示。

对比图 11 和图 9(a) 可知，经过 IGWO 算法优化后，LSTM 和 GRU 模型预测精确度都有较大提升，RMSE 相比优化前分别由 0.0099 V 和 0.009 V 降低

到 0.0067 V 和 0.0064 V，分别降低了 32.3%和 28.8%，说明了所提优化算法的有效性。优化后 CNN-LSTM 模型预测趋势更贴合实际数据，RMSE 为 0.0055 V，说明了所提模型预测精度更高。

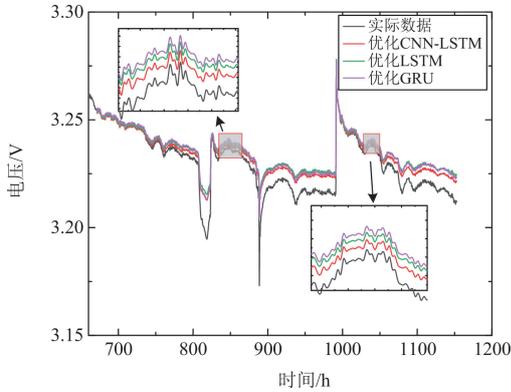


图 11 IGWO 优化 3 种模型后的电池性能衰退预测对比
Fig. 11 Comparison of battery performance degradation prediction among three IGWO-optimized models

2.2.2 数据集 FC2 短期预测

数据集 FC2 选取 3 个完整的动态循环，时长约 3500 s，验证所提模型在动态工况下，PEMFC 性能衰退短期预测精度。不同训练集占比下，IGWO 优化 CNN-LSTM 模型在数据集 FC2 中的衰退预测趋势如图 12 所示。

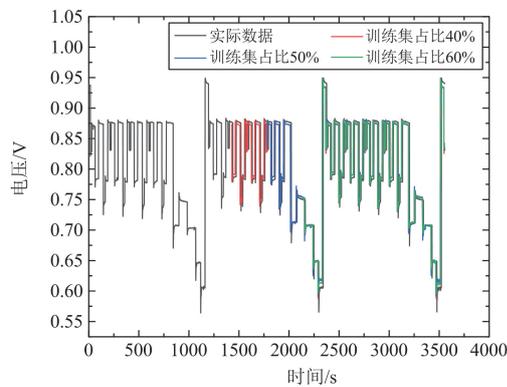
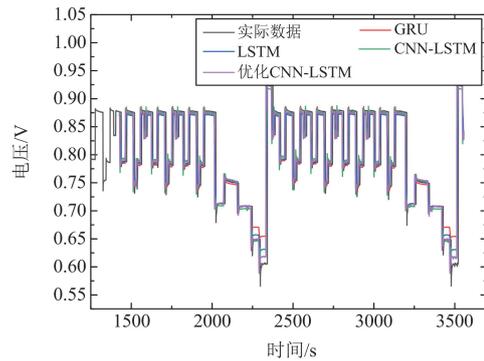


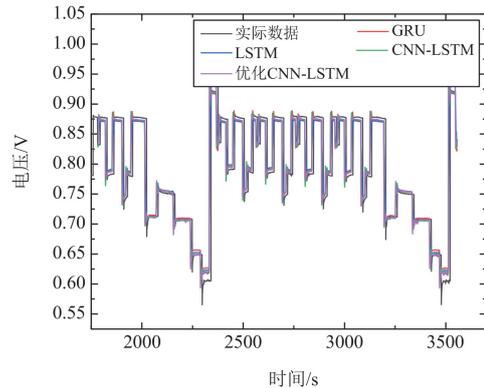
图 12 IGWO 优化 CNN-LSTM 在数据集 FC2 中的衰退预测
Fig. 12 Degradation prediction on data set FC2 using IGWO-optimized CNN-LSTM

由图 12 可知，动态工况下 IGWO 算法优化 CNN-LSTM 预测模型也能准确完成短期性能衰退预测，随着训练集占比增加，预测精度进一步提高。

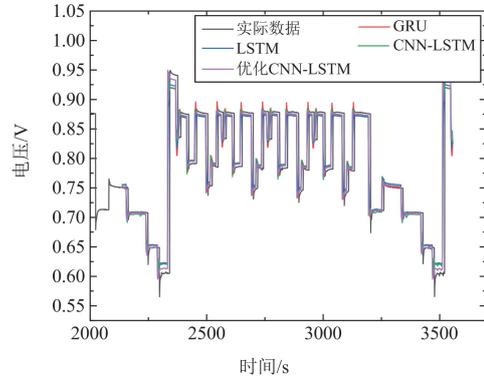
为验证动态工况数据集 FC2 中 IGWO 算法优化 CNN-LSTM 预测模型精度，按上述训练集占比划分，与 LSTM、GRU 和未经优化的 CNN-LSTM 进行对比验证，性能衰退预测趋势如图 13 所示。



(a) 训练集占比为40%



(b) 训练集占比为50%



(c) 训练集占比为60%

图 13 4 种模型在数据集 FC2 中的电池性能衰退预测

Fig. 13 Performance degradation prediction on data set FC2 using four models

从图 13 可以看出，CNN-LSTM 相比 GRU 和 LSTM，预测结果更加贴合实际数据曲线，证明 CNN-LSTM 有更强的特征提取能力和时序建模能力。优化后 CNN-LSTM 能更准确地捕捉动态工况下电压变化规律和波动特性，训练集占比为 40%时，预测电压与实际电压最大差值不超过 0.025 V，训练集占比为 60%时，最大电压差值不超过 0.015 V。性能衰退预测误差如图 14 所示。

由图 14 对比可知, 在动态工况数据集 FC2 中进行电池性能衰退预测时, CNN-LSTM 有更好的特征提取能力, 使预测结果更加精确。在训练集占比为 40% 时, 未优化的 CNN-LSTM 在 RMSE 指标上相较 LSTM 与 GRU 分别降低了 35.04%、26.88%; IGWO 优化后 CNN-LSTM 模型预测误差相对较小且稳定, 相比未优化的 CNN-LSTM 在 MAE 和 RMSE 指标上分别降低 18.78% 和 4.83%, R^2 也更接近于 1, 表明 IGWO 算法能够有效优化 CNN-LSTM

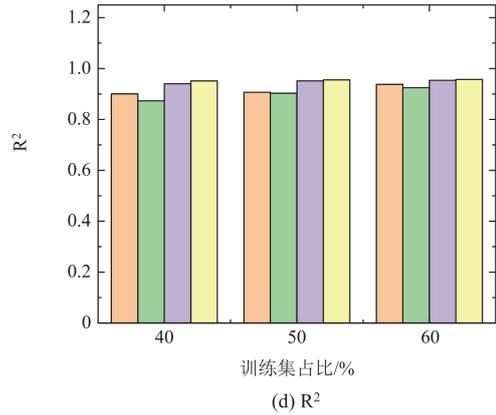
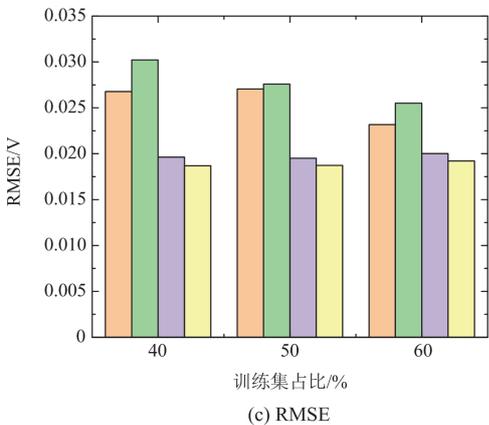
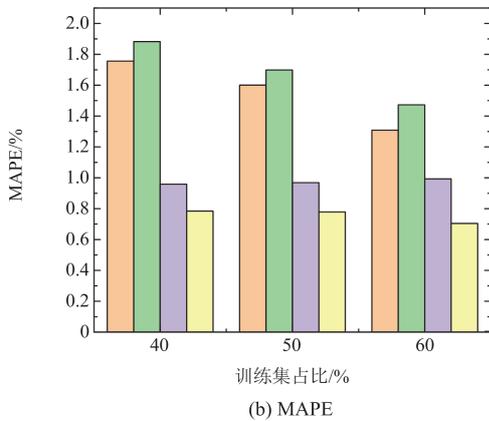
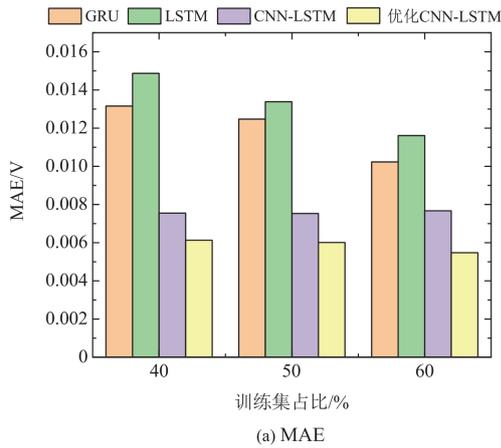


图 14 4 种模型在数据集 FC2 中的电池性能衰退预测误差
Fig. 14 Prediction errors of battery performance degradation on data set FC2 using four models

模型的超参数, 提高模型在动态工况数据集 FC2 中的预测精度。

2.3 剩余使用寿命预测

由 PEMFC 剩余使用寿命的定义可知, 当 FC1 数据集中电堆电压下降到初始电压的 96% 时, 认为燃料电池无法继续使用, 即失效电压为 3.211 V。以 FC1 训练集占比 70% 为例, PEMFC 剩余使用寿命预测结果如图 15 所示。

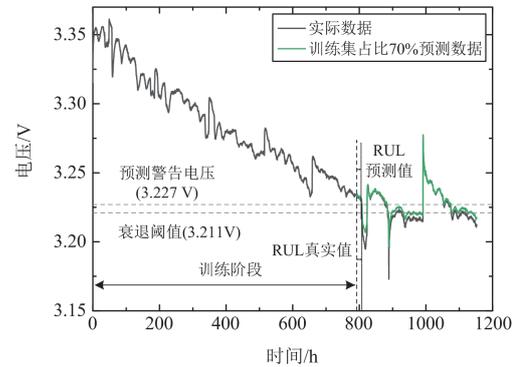


图 15 PEMFC 剩余使用寿命预测

Fig. 15 Remaining useful life prediction of PEMFC

由图 15 可知, PEMFC 电堆电压下降到 3.211 V 时, 对应时间为 808.77 h。为留有一部分缓冲时间, 设置预测警告电压为初始电压的 96.5% 即 3.227 V, 对应时间为 807.61 h, 预测警告时间相比实际衰退阈值仅相差 1.16 h, 说明 IGWO 算法优化的 CNN-LSTM 模型能够准确预测 PEMFC 的剩余使用寿命。

3 结论

针对 PEMFC 电堆性能衰退和 RUL 预测问题, 使用 IGWO 算法对 CNN-LSTM 模型进一步优化, 通过对静态和动态工况衰退数据分析, 确定输入参

数, 并进行性能衰退和 RUL 预测, 核心优势如下:

1) 使用 SWT 去噪, 解决了 DWT 易引起关键数据缺失的问题; 通过相关性分析与多元时间序列预测, 选取相关性强的多维特征参数作为输入, 相较于单时间序列预测更为精确; CNN 与 LSTM 结合可以增强其特征提取和时序建模能力, 有效捕捉较早时刻信息与当前时刻预测结果的关系; 结合改进灰狼优化算法, 能从大量数据分析中得到 CNN-LSTM 最优超参数, 从而使预测模型获得更优权重与偏差配置, 提升模型收敛速度, 同时有效避免了收敛过快陷入局部最优和过拟合问题。

2) 采用不同规格燃料电池在不同工况下数据, 验证了所提模型鲁棒性与泛化性以及预测精度, 静态工况训练集占比为 60% 时, IGWO 算法优化后模型的 MAE 和 RMSE 相比优化前分别降低了 36.7% 和 59.02%; 动态工况训练集占比为 40% 时, 算法优化后模型的 MAE 和 RMSE 相比优化前分别降低 18.78% 和 4.83%。

在静态工况下 PEMFC 电堆 RUL 预测中, 采用 IGWO 算法优化 CNN-LSTM 模型进行长期离线预测能准确预测出电堆剩余使用寿命, 为动态工况下 PEMFC 电堆短期在线 RUL 预测提供了参考。后续研究拟从在线故障预测入手, 探究 PEMFC 在实际工况下, 电堆故障对燃料电池衰退和剩余使用寿命的影响, 再结合容错控制, 以增强燃料电池运行稳定性, 延长剩余使用寿命。

参考文献

- [1] 王俊月, 杨骥, 宋政湘, 等. 基于自适应 SOC 的电池-飞轮混合储能一次调频控制策略[J]. 电力工程技术, 2024, 43(5): 122-130.
WANG Junyue, YANG Kun, SONG Zhengxiang, et al. Primary frequency regulation strategy for battery-flywheel hybrid energy storage based on adaptive state of charge[J]. Electric Power Engineering Technology, 2024, 43(5): 122-130.
- [2] 姜智霖, 郝峰杰, 袁志昌, 等. 考虑 SOC 优化设定的电-氢混合储能系统的运行优化[J]. 电力系统保护与控制, 2024, 52(8): 65-76.
JIANG Zhilin, HAO Fengjie, YUAN Zhichang, et al. Optimal operation of an electro-hydrogen hybrid energy storage system considering SOC optimization setting[J]. Power System Protection and Control, 2024, 52(8): 65-76.
- [3] 叶远波, 王吉文, 汪胜和, 等. 计及故障点两侧零序电流相位差的新能源送出线路接地故障时域距离保护研究[J]. 电力系统保护与控制, 2023, 51(20): 180-187.
YE Yuanbo, WANG Jiwen, WANG Shenghe, et al. Time domain distance protection of new energy transmission line grounding fault considering the phase difference of zero sequence current on both sides of the fault point[J]. Power System Protection and Control, 2023, 51(20): 180-187.
- [4] 高锋阳, 高翔宇, 张浩然, 等. 全局与瞬时特性兼优的燃料电池有轨电车能量管理策略[J]. 电工技术学报, 2023, 38(21): 5923-5938.
GAO Fengyang, GAO Xuanyu, ZHANG Haoran, et al. Management strategy for fuel cell trams with both global and transient characteristics[J]. Transactions of China Electrotechnical Society, 2023, 38(21): 5923-5938.
- [5] 吴磊, 彭黎菊, 李爽, 等. 百千瓦级天然气制氢质子交换膜燃料电池热电联产系统稳态特性模拟分析[J]. 发电技术, 2023, 44(3): 350-360.
WU Lei, PENG Liju, LI Shuang, et al. Simulation and analysis of steady state characteristics of hundred kilowatt proton exchange membrane fuel cell combined heat and power system based on hydrogen production from natural gas[J]. Power Generation Technology, 2023, 44(3): 350-360.
- [6] 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[J]. 中国电机工程学报, 2019, 39(8): 2365-2375, 19.
LI Qi, LIU Jiawei, CHEN Weirong. Review and prospect of remaining useful life prediction methods for proton exchange membrane fuel cell[J]. Proceedings of the CSEE, 2019, 39(8): 2365-2375, 19.
- [7] ZHANG X, PISU P. Prognostic-oriented fuel cell catalyst aging modeling and its application to health-monitoring and prognostics of a PEM fuel cell[J]. International Journal of Prognostics and Health Management, 2020, 5(1): 2153-2648.
- [8] MINGYANG O, RUOFAN Z, ZHIFANG S, et al. A novel approach based on semi-empirical model for degradation prediction of fuel cells[J]. Journal of Power Sources, 2021, 488.
- [9] LEE W Y, PARK G G, YANG T H, et al. Empirical modeling of polymer electrolyte membrane fuel cell performance using artificial neural networks[J]. International Journal of Hydrogen Energy, 2004, 29(9): 961-966.
- [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.
LIU Jiawei, LI Qi, CHEN Weirong, 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.
- [11] ZHENG Lu, HOU Yongping, ZHANG Tao, et al. Performance prediction of fuel cells using long short-term memory recurrent neural network[J]. International Journal of Energy Research, 2021, 45(6): 9141-9161.
- [12] 高金武, 贾志桓, 王向阳, 等. 基于 PSO-LSTM 的质子交换膜燃料电池退化趋势预测[J]. 吉林大学学报(工学版), 2022, 52(9): 2192-2202.
GAO Jinwu, JIA Zhiheng, WANG Xiangyang, et al. Degradation trend prediction of proton exchange membrane fuel cell based on PSO-LSTM[J]. Journal of Jilin University

- (Engineering and Technology Edition), 2022, 52(9): 2192-2202.
- [13] 李浩, 杨扬, 朱文超, 等. 基于改进鲸鱼算法优化 GRU 的 PEMFC 老化预测[J]. 中国电机工程学报, 2024, 44(20): 8166-8178.
- LI Hao, YANG Yang, ZHU Wenchao, et al. PEMFC aging prediction based on improved whale optimization algorithm optimized GRU[J]. Proceedings of the CSEE, 2024, 44(20): 8166-8178.
- [14] CHENG Yujie, ZERHOUNI N, LU Chen. A hybrid remaining useful life prognostic method for proton exchange membrane fuel cell[J]. International Journal of Hydrogen Energy, 2018, 43(27): 12314-12327.
- [15] JACOME A, HISSEL D, HEIRIES V, et al. Prognostic methods for proton exchange membrane fuel cell under automotive load cycling: a review[J]. IET Electrical Systems in Transportation, 2020, 10(4): 369-375.
- [16] 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 Jiawei. Data-driven fault diagnosis and life prediction methods for PEMFC power generation system[D]. Chengdu: Southwest Jiaotong University, 2020.
- [17] SUN Xilei, XIE Mingke, FU Jianqin, et al. An improved neural network model for predicting the remaining useful life of proton exchange membrane fuel cells[J]. International Journal of Hydrogen Energy, 2023, 48(65): 25499-25511.
- [18] 刘昕宇, 韩莹, 陈维荣, 等. 基于改进 SSA-DBN 的质子交换膜燃料电池水故障智能分类方法[J]. 电力自动化设备, 2024, 44(4): 18-24.
- LIU Xinyu, HAN Ying, CHEN Weirong, et al. Intelligent classification method of water faults for proton exchange membrane fuel cell based on improved SSA-DBN[J]. Electric Power Automation Equipment, 2024, 44(4): 18-24.
- [19] 汪建锋, 王荣杰, 林安辉, 等. 质子交换膜燃料电池退化预测方法研究[J]. 电工技术学报, 2024, 39(11): 3367-3378.
- WANG Jianfeng, WANG Rongjie, LIN Anhui, et al. Research on degradation prediction method of proton exchange membrane fuel cell[J]. Transactions of China Electrotechnical Society, 2024, 39(11): 3367-3378.
- [20] 王艳琴, 谢卓峰, 韩国鹏, 等. 基于极端梯度提升的 PEMFC 长短期老化趋势预测[J]. 太阳能学报, 2024, 45(7): 232-239.
- WANG Yanqin, XIE Zhuofeng, HAN Guopeng, et al. Short-and long-term degradation prediction for proton exchange membrane fuel cell based on extreme gradient boosting[J]. Acta Energiac Solaris Sinica, 2024, 45(7): 232-239.
- [21] 马君, 万俊杰. 基于健康特征筛选与 GWO-LSSVM 的锂电池健康状态预测[J]. 电气技术, 2024, 25(2): 37-44.
- MA Jun, WAN Junjie. Prediction of state of health for lithium battery based on health feature screening and GWO-LSSVM[J]. Electrical Engineering, 2024, 25(2): 37-44.
- [22] 徐楚琦, 孙辰昊, 詹明宇, 等. 基于 IGWO-Seq2Seq 的风电故障预测方法[J]. 电力科学与技术学报, 2024, 39(6): 203-211.
- XU Chuqi, SUN Chenhao, ZHAN Mingyu, et al. Wind power fault prediction method based on IGWO-Seq2Seq[J]. Journal of Electric Power Science and Technology, 2024, 39(6): 203-211.
- [23] 刘新宇, 蒲欣雨, 李继方, 等. 基于贝叶斯优化的 VMD-GRU 短期风电功率预测[J]. 电力系统保护与控制, 2023, 51(21): 158-165.
- LIU Xinyu, PU Xinyu, LI Jifang, et al. Short-term wind power prediction of a VMD-GRU based on Bayesian optimization[J]. Power System Protection and Control, 2023, 51(21): 158-165.
- [24] AMIR O, HANS-GEORG B. Progress analysis of a multi-recombinative evolution strategy on the highly multimodal Rastrigin function[J]. Theoretical Computer Science, 2023, 978.
- [25] GOURIVEAU R, HILAIRET M, HISSEL D, et al. IEEE PHM 2014 data challenge: outline experiments scoring of results winners[C]// IEEE Conference Prognostics Health Manage, 2014, Belfort, France.
- [26] ZUO J, LÜ H, ZHOU D, et al. Long-term dynamic durability test datasets for single proton exchange membrane fuel cell[J]. Data in Brief, 2021, 35.
- [27] 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.
- [28] 谢宏远, 刘逸, 候权, 等. 基于粒子滤波和遗传算法的氢燃料电池剩余使用寿命预测[J]. 东北电力大学学报, 2021, 41(1): 56-64.
- XIE Hongyuan, LIU Yi, HOU Quan, et al. Prediction of the remaining useful life of PEMFC based on particle filter and genetic algorithm[J]. Journal of Northeast Electric Power University, 2021, 41(1): 56-64.
- [29] 赵波, 张领先, 章雷其, 等. 基于 TCN 和 AUKF 联合迭代的 PEMFC 寿命融合预测方法[J]. 中国电机工程学报, 2025, 45(9): 3609-3624.
- ZHAO Bo, ZHANG Lingxian, ZHANG Leiqi, et al. PEMFC remaining useful life fusion method based on joint iteration of TCN and AUKF[J]. Proceedings of the CSEE, 2025, 45(9): 3609-3624.
- [30] MA Rui, XIE Renyou, XU Liangcai, et al. A hybrid prognostic method for PEMFC with aging parameter prediction[J]. IEEE Transactions on Transportation Electrification, 2021, 7(4): 2318-2331.

收稿日期: 2024-03-31; 修回日期: 2024-08-25

作者简介:

高锋阳(1970—), 男, 博士生导师, 教授, 研究方向为轨道交通电气自动化; E-mail: ljdgao@lztu.edu.cn

刘庆寅(1998—), 男, 通信作者, 硕士研究生, 研究方向为质子交换膜燃料电池性能衰退与故障诊断。E-mail: 707543697@qq.com

(编辑 张颖)