

基于改进长短期记忆网络的质子交换膜 燃料电池长期老化预测

查鹏堂¹, 齐丰旭¹, 杨雨泽², 刘 嘉¹, 高峰阳¹

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

摘 要: 针对质子交换膜燃料电池 (PEMFC) 的长期老化预测问题, 提出了一种基于局部加权散点平滑 (LOWESS) 去噪的二维网格长短期记忆网络 (2D-G-LSTM) PEMFC 输出电压预测方法。首先, 通过 LOWESS 进行数据重构和平滑处理, 获得消除噪声和尖峰后的平滑数据。其次, 采用 2D-G 结构优化 LSTM 确定最优参数, 并基于最优参数构建 2D-G-LSTM, 实现 PEMFC 输出电压在未来几百小时区间内的长期预测。最后, 在代表静态和动态工况的 2 组老化数据集下对本文方法进行测试并与扩展卡尔曼滤波、长短期记忆网络、相关向量机、回声状态网络以及反向传播神经网络 5 种经典方法进行比较。结果表明, 当静态和动态工况数据集的训练时长分别达到 550 h 和 700 h 时, 与 LSTM 相比, 本文方法的均方根误差和平均绝对百分比误差分别降低了 51.19%、53.66% 和 43.88%、49.43%。因此, 本文方法预测误差更小, PEMFC 的长期老化趋势更接近真实值, 并且能够在一定程度上提高 PEMFC 的老化预测精度。

关键词: 质子交换膜燃料电池; 长短期记忆网络; 局部加权散点平滑去噪; 二维网格结构; 老化预测

中图分类号: TK91 **文献标志码:** A **文章编号:** 1671-5497(2026)01-0064-12

DOI: 10.13229/j.cnki.jdxbgxb.20240663

Long-term aging prediction of proton exchange membrane fuel cell based on improved long short term memory networks

ZHA Peng-tang¹, QI Feng-xu¹, YANG Yu-ze², LIU Jia¹, GAO Feng-yang¹

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

Abstract: Aiming at the long-term aging prediction problem of Proton exchange membrane fuel cell (PEMFC), this paper proposes a PEMFC output voltage prediction method of 2D-grid long short term memory networks (2D-G-LSTM) by denoising through locally weighted scatterplot smoothing (LOWESS). First, data reconstruction and smoothing are performed by LOWESS to obtain smoothed

收稿日期: 2025-06-14.

基金项目: 中车“十四五”科技重大专项计划项目 (2021CXZ021); 甘肃省教育厅优秀研究生“创新之星”项目 (2023CXZX-616).

作者简介: 查鹏堂 (1980-), 男, 讲师, 博士研究生. 研究方向: 质子交换膜燃料电池寿命预测.

E-mail: ppzha@mail.lzjtu.cn

data after eliminating noise and spikes. Second, a 2D-G structure is used to optimize the LSTM to determine the optimal parameters, and a 2D-G-LSTM is constructed based on the optimal parameters to achieve long-term prediction of the PEMFC output voltage over the next several hundred hour intervals. Finally, the proposed method is tested and compared with five classical methods, namely, extended Kalman filter, long short term memory network, correlation vector machine, echo state network, and back-propagation neural network, under two sets of aging datasets representing static and dynamic operating conditions, respectively. The results show that the root mean square error and the mean absolute percentage error of the proposed method are reduced by 51.19%, 53.66% and 43.88% and 49.43%, respectively, compared with LSTM when the training duration of the static and dynamic condition datasets reaches 550 h and 700 h, respectively. Therefore, the proposed method predicts a smaller error and the long-term aging trend of PEMFC is closer to the real value, and it can improve the aging prediction accuracy of PEMFC to some extent.

Key words: proton exchange membrane fuel cell; long short term memory network; locally weighted scatterplot smoothing denoising; 2D-grid structure; aging prediction

0 引言

近年来,随着环境污染和能源危机愈发严重,清洁可替代能源受到人们广泛关注。质子交换膜燃料电池(Proton exchange membrane fuel cell, PEMFC)作为一种重要的可持续能源发电装置,具有零污染、能量转换效率高、低噪声、快速启动等优点^[1],被认为是解决环境污染和能源危机最具前景的技术之一。然而,PEMFC系统的材料属性、结构特征及运行环境会引起其不可逆的性能老化^[2],导致耐久性下降、剩余使用寿命(Remaining useful life, RUL)缩短,严重制约了PEMFC系统在各个领域中的广泛应用。因此,准确预测PEMFC的长期老化趋势,对降低维护更换成本、延长RUL和保证其长期稳定运行的可靠性具有重要意义^[3]。

PEMFC老化预测方法可分为3种类型,即基于模型的预测方法、基于数据的预测方法和基于混合的预测方法^[4]。基于模型的预测方法依托燃料电池的材料属性、衰退机理和退化模型实现老化预测,主要包括粒子滤波^[5](Particle filter, PF)、扩展卡尔曼滤波^[6](Extended Karman filter, EKF)、退化机理模型^[7]和经验退化模型^[8]。谢宏远等^[5]采用对数线性模型作为电压衰减的状态空间方程,结合PF实现氢燃料电池的RUL预测,但该方法的预测精度易受燃料电池自身状态、负载状况、环境等因素影响。Bressel等^[6]利用EKF估计半经验模型的时变参数,实现了PEMFC电堆

的RUL预测,然而雅可比矩阵的引入导致计算量过大、复杂度较高。胡捷等^[7]根据PEMFC电堆输出特性经验公式及电化学、热力学原理,建立电堆输出电压的退化机理模型,并采用最小二乘法进行模型参数辨识,但建模过程复杂且计算烦琐。Chen等^[8]结合无迹卡尔曼滤波与经验电压衰减模型预测燃料电池RUL,但燃料电池内部反应的老化机理难以准确建立,且受操作条件等因素的影响较大。

基于数据的预测方法无须先验知识建立精确的老化模型,也无须考虑电池实际老化原理,其目的是通过机器学习方法学习可用的老化数据挖掘PEMFC的老化规律。目前,已有大量文献证实基于数据的预测方法能够有效预测PEMFC的老化趋势,包括灰色神经网络模型^[9](Grey neural networks model, GNNM)、反向传播神经网络^[10](Back propagation neural network, BPNN)、回声状态网络^[11](Echo state network, ESN)、循环神经网络^[12](Recurrent neural networks, RNN)、长短期记忆网络^[13](Long short term memory, LSTM)、门控循环单元网络^[14](Gated recurrent unit, GRU)等。Chen等^[9]提出一种结合粒子群优化和移动窗口法的GNNM预测方法,实现了不同工况下PEMFC的老化预测,并验证了不同移动窗口大小对预测结果的影响。然而,尽管GNNM在燃料电池性能退化预测领域有所应用,但是与其他方法相比预测精度偏低,仅适用于初始

运行数据较少的 PEMFC 老化预测。为了解决这一问题,Chen 等^[10]基于 BPNN,以电堆电流、电堆温度、空气压力、氢气压力及空气湿度 5 个物理量为输入特征参数,建立 PEMFC 寿命预测模型。结果表明,在学习 400 h 后,模型预测相对误差 < 5%,比 GNNM 预测精度高,但 BPNN 存在训练时间较长、过拟合等问题,限制了其应用范围。潘诗媛等^[11]提出改进 ESN 结构以实现 PEMFC 输出电压的精准预测,采用多个“储备池”构建级联型 ESN 结构,并利用遗传算法优化结构参数,在稳态和准动态工况下实现了 PEMFC 长期输出电压预测,在确保预测精度的同时显著减少了计算量。此外,在基于数据的预测方法中,RNN 更适合处理序列数据^[2],在燃料电池退化预测领域是一种强大的方法。然而,RNN 存在梯度爆炸、梯度消失的问题,难以有效捕捉较长时间数据依赖关系^[12]。因此,更多的 LSTM 模型及其变体被应用于序列数据预测领域。Wang 等^[13]提出一种用于拟合 PEMFC 系统退化的堆叠 LSTM 模型,通过带有剔除参数的堆叠操作提高 PEMFC 退化预测的准确性。与 RNN 相比,LSTM 具有记忆细胞,能够有效控制和更新记忆细胞的内容,可以捕捉长期依赖关系,但存在参数较多且结构复杂的问题。Zuo 等^[14]基于 GRU 模型,利用动态循环耐久性测试数据对静态和准动态 2 种工况下 PEMFC 输出电压衰退进行预测,验证了 GRU 模型具有较高的预测精度。与 LSTM 相比,GRU 将输出门和遗忘门合并为更新门,结构更为简洁,降低了计算成本。

基于混合的预测方法通常是将多种预测方法以不同的混合策略相结合,以弥补单一方法预测的不足,包括考虑模型和数据的混合方法,以及由数据驱动的多种混合方法^[15]。考虑模型和数据的混合方法虽然可以提高 PEMFC 系统老化预测的精度和准确率^[16],但需要先构建预测所需的数学模型,再借助各种算法实现 PEMFC 老化和 RUL 预测,该方法本质上仍依赖系统内部模型的构建。由数据驱动的多种混合方法能够结合各类方法的优势,提高预测准确性和鲁棒性,但需要大量实验数据,存在时间资源浪费、计算过于复杂等局限性。综上所述,相较于基于模型和基于混合的预测方法,基于数据的预测方法既无需先验知识建立精确的老化模型,也无需考虑电池实际老

化原理,并且可以灵活地表征从老化数据中观察到的退化特征^[17],更适用于 PEMFC 老化趋势的预测。

基于上述分析,本文提出了一种基于局部加权散点平滑(Locally weighted scatterplot smoothing, LOWESS)去噪的 2D-G-LSTM PEMFC 长期老化数据驱动预测方法。首先,通过 LOWESS 去噪对原始数据进行预处理,在保留原始数据老化趋势的同时显著降低计算复杂度,为后续高精度长期老化预测提供条件;其次,采用 2D-G 结构优化 LSTM 并确定最优参数,并基于该参数构建 2D-G-LSTM 预测网络,实现 PEMFC 输出电压在未来几百小时区间内的长期预测,相比单个 LSTM 结构提高了预测精度和稳定性;最后,在 2 组工况数据集下进行仿真分析,验证所提预测方法的有效性及其优越性。

1 PEMFC 老化预测算法原理

1.1 长短期记忆网络

LSTM 作为改进型 RNN,旨在解决传统 RNN 处理长序列数据和长期依赖关系时存在的梯度消失和梯度爆炸问题。其核心思想是引入“门”结构单元,通过学习的方式控制信息的流动和记忆的更新。LSTM 单元主要由遗忘门、输入门和输出门组成,单元执行流程如图 1 所示。其中, x_t 为当前时刻的输入; c_t 和 c_{t-1} 分别为当前时刻和前一时刻的记忆,且 c_{t-1} 可以自适应传递至 c_t ,以实现保存信息的功能; h_t 和 h_{t-1} 分别为当前时刻和前一时刻的输出;Sigmoid 为激活函数。

LSTM 中各门控变量由以下复合函数实现:

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (1)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \quad (2)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (3)$$

式中: i_t 、 f_t 、 o_t 分别表示输入门、遗忘门、输出门; $\sigma(\cdot)$ 为门激活函数; W_{xi} 、 W_{xf} 和 W_{xo} 为与输入 x_t 相连的权重参数矩阵; W_{hi} 和 W_{hf} 为与隐藏层输出 h_t 相连的权重参数矩阵; W_{ho} 代表与隐藏层输出 h_t 相连的权重参数矩阵; b_i 、 b_f 和 b_o 为各门控对应的偏置参数。

内部状态 c_t 、隐藏层输出 h_t 和误差的计算公式分别为:

$$c_t = f_t \odot c_{t-1} + i_t \odot \hat{c}_t \quad (4)$$

$$\hat{c}_t = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (5)$$

$$h_t = o_t \odot \tanh(c_t) \quad (6)$$

$$\tanh(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (7)$$

式中: $\tanh(\cdot)$ 为输出激活函数,能在一定程度上

缓解梯度消失和梯度爆炸问题,并加快模型收敛;

W_{xc} 代表连接输入 x_t 到内部状态 c_t 的权重参数矩阵; $\odot$ 表示向量元素的乘法; W_{hc} 代表连接前一时
刻输出 h_{t-1} 到内部状态 c_t 的权重参数矩阵; b_c 代
表内部状态 c_t 对应的偏置参数。




图 1 LSTM 单元执行流程

Fig. 1 LSTM unit execution flow

将误差项向前传递到任意时间步长 k 的表达
式为:

$$\delta_k^T = \delta_t^T \prod_{j=k}^{t-1} (\delta_{i,j}^T \omega_{xi} + \delta_{f,j}^T \omega_{xf} + \delta_{o,j}^T \omega_{xo} + \delta_{c,j}^T \omega_{xc}) \quad (8)$$

式中: δ 为每个神经单元的误差。

1.2 二维网格长短期记忆网络

基于 LSTM 单元结构的特征,通过构建网格

可以连接不同时刻的单元。因此,本文通过对
LSTM 单元进行连接和组合,构建了 2D-G-
LSTM 结构,如图 2 所示。2D-G-LSTM 结构除
了具有时间记忆能力外,还具有深度记忆功能,沿
着网络的深度维度增加 LSTM 单元,可以同时获
得时间记忆和深度记忆^[18]。与单个 LSTM 结构
相比,2D-G-LSTM 提高了模型的学习能力,更
适用于长周期预测问题。




图 2 2D-G-LSTM 结构

Fig. 2 2D-G-LSTM structure

针对燃料电池的老化现象,2D-G 结构允许
各个层记忆或忽略输入信息,从而有效缓解梯度
消失问题。此外,2D-G 结构支持预测任务在线

执行,不仅有助于实时预测燃料电池的老化状态,
还能实时预测其 RUL,相比于单个 LSTM 结构具
有更强的鲁棒性。为了防止模型过拟合,在模型

参数更新环节采用 2D-G 结构对 LSTM 的超参数进行优化。因此,将 2D-G-LSTM 应用于数据训练,可提高预测精度。

在 2D-G 结构中, t 时刻的权重梯度计算公式为:

$$\frac{\partial E}{\partial \omega_{xi,t}} = \delta_{i,t} \mathbf{h}_{t-1}^T \quad (9)$$

$$\frac{\partial E}{\partial \omega_{xf,t}} = \delta_{f,t} \mathbf{h}_{t-1}^T \quad (10)$$

$$\frac{\partial E}{\partial \omega_{xo,t}} = \delta_{o,t} \mathbf{h}_{t-1}^T \quad (11)$$

$$\frac{\partial E}{\partial \omega_{xc,t}} = \delta_{c,t} \mathbf{h}_{t-1}^T \quad (12)$$

式中: E 代表总损失函数。

因此,权重参数矩阵的最终梯度可以表示为:

$$\frac{\partial E}{\partial \omega} = \sum_{j=1}^t \delta_j \mathbf{h}_{j-1}^T \quad (13)$$

同样,偏置矩阵的梯度为:

$$\frac{\partial E}{\partial b_{i,t}} = \delta_{i,t} \quad (14)$$

$$\frac{\partial E}{\partial b_{o,t}} = \delta_{o,t} \quad (15)$$

$$\frac{\partial E}{\partial b_{f,t}} = \delta_{f,t} \quad (16)$$

$$\frac{\partial E}{\partial b_{c,t}} = \delta_{c,t} \quad (17)$$

因此,偏置参数矩阵的最终梯度可以表示为:

$$\frac{\partial E}{\partial b} = \sum_{j=1}^t \delta_j \quad (18)$$

1.3 局部加权散点平滑去噪

原始数据中存在的尖峰和噪声会影响算法对数据的提取,降低模型预测精度。为便于后续处理并提高数据质量,本文采用 LOWESS 进行数据重构和平滑处理,以抑制“异点”的影响^[19]。

LOWESS 的核心思想是选取一定比例的局部数据,以其中一个数据点 x 为中心,在 x 前后分别截取长度为 F_{rac} 的数据段,利用权值函数 ω 进行加权线性回归,拟合后回归线的中心值为 γ ^[20]。通过拟合所取数据的趋势线,将距离趋势线较远的数据点剔除,从而得到数据中主要的趋势成分。权值函数 ω 的表达式为:

$$\omega_i = \begin{cases} 1 - |x - x_i|^3, & |x - x_i| \leq 1 \\ 0, & |x - x_i| > 1 \end{cases} \quad (19)$$

式中: $-F_{\text{rac}} + x \leq x_i \leq x + F_{\text{rac}}$ 。

曲线中心值 γ 可通过平滑拟合方程 $\gamma = ax + b$ 得到,其中回归系数 a 和常数 b 的定义如下:

$$a = \frac{\sum_{i=1}^n \omega_i^2 (x - \bar{x})(y - \bar{y})}{\sum_{i=1}^n \omega_i^2 (x - \bar{x})} \quad (20)$$

$$b = \bar{y} - a\bar{x} \quad (21)$$

式中: $\bar{x}$ 和 $\bar{y}$ 分别为中心数据点 x 和拟合值 γ 的加权平均值。

LOWESS 去噪利用区间加权系数和区间原始数据进行线性回归,得到平滑后的数据。该方法具有较强的拟合性和鲁棒性,同时模型参数可以随着自变量的变化而调整,具备较强的可扩展性^[21]。

2 基于 LOWESS-2D-G-LSTM 的长期老化预测流程

根据时间尺度可将 PEMFC 老化预测分为短期预测和长期预测。与短期预测相比,长期预测通常采用闭环预测,即从预测起点开始预测后,后续预测过程中不再有测量数据输入^[22]。通过训练 2D-G-LSTM 网络建立 PEMFC 长期老化预测模型,基于预测起始点前的老化数据预测未来数百小时的老化趋势。当 PEMFC 发生故障或性能下降到一定程度时,模型可提前发出预警通知。具体预测流程如图 3 所示。

(1) 对 PEMFC 原始老化数据进行重构和平滑处理,然后根据不同预测起始点,将 FC1 和 FC2 数据集划分为不同长度的训练集和验证集。

(2) 将训练集数据输入模型,初始化模型参数,包括 i_t, f_t, o_t, c_t 和 $\mathbf{h}_t$ 。

(3) 通过各神经单元输出的前向传播和反向传播计算模型参数,并在每个时刻步骤中计算当前时间步的误差。

(4) 根据误差项计算各权重的梯度,并采用随机梯度下降方法更新权重参数。

(5) 判断梯度精度是否达到预设目标,若达到则输出 LSTM 预测网络,否则重复步骤(4)。

(6) 调整网络超参数,判断模型变化精度是否达到预设目标,若达到则输出最优参数;否则重复步骤(3)~(5)。

(7) 基于最优超参数构建 2D-G-LSTM 预测模型,对 PEMFC 进行长期老化预测,并评估 LOWESS-2D-G-LSTM 模型的性能。




图 3 基于 LOWESS-2D-G-LSTM 的长期老化预测流程

Fig. 3 Long-term aging prediction process based on LOWESS-2D-G-LSTM

3 预测结果与讨论

3.1 实验数据介绍

为充分验证 LOWESS-2D-G-LSTM 的预测性能,采用法国燃料电池实验室(Fuel cell laboratory, FCLAB)在 IEEE PHM 2014 数据挑战赛中公开的 PEMFC 电堆实验数据集^[23],对 1 kW 燃料电池电堆进行 1 000 h 以上的测试,实验平台^[23]如图 4 所示。被测试的 PEMFC 电堆由 5 片有效活化面积为 100 cm²的单电池构成。该数据集包括 2 组老化测试数据,分别对应静态和动态 2 种老化工况:第一组为静态工况数据集 FC1,由 PEMFC 电堆在 0.70 A/cm² 恒定电流密度的稳态条件下运行 1 154 h 得到;第二组为动态工况数据集 FC2,由 PEMFC 电堆在 5 kHz 频率、(0.70±0.07) A/cm² 纹波工作电流密度下运行 1 019 h 得到。在 PEMFC 测试平台中,电堆运行涉及的物理参数和控制范围如表 1 所示。

PEMFC 电堆测试原理如图 5 所示。氢气和空气分别通过各自的控制器进入 PEMFC 电堆,气体在进入电堆前需经独立放置的加湿器进行加湿。其中,只对空气加湿器进行加热以获得所需的相对湿度,而氢气加湿器则在干燥阳极气体的

表 1 电堆运行物理参数和控制范围

Table 1 Physical parameters and control ranges of stack operation

物理参数	控制范围
冷却温度/℃	20~80
冷却流量/(L·min ⁻¹)	0~10
气体温度/℃	20~80
气体相对湿度/%	0~100
空气流量/(L·min ⁻¹)	0~100
氢气流量/(L·min ⁻¹)	0~30
气体压力/bar	0~2
燃料电池电流/A	0~300




图 4 1 kW 燃料电池电堆测试平台

Fig. 4 1 kW fuel cell stack test bed

操作下保持室温。PEMFC 电堆的温度由冷却水系统控制,电堆输出的电流由有源负载控制。最后由排气口排出剩余的氢气、空气和水。




图 5 PEMFC 电堆测试原理

Fig. 5 PEMFC stack test principle

3.2 PEMFC 性能退化指标

实验运行期间监测的特征参数如表 2 所示。为确定 PEMFC 的性能退化指标,对表 2 中的特征参数进行相关性分析,并分别基于数据集 FC1 和 FC2 绘制相关性矩阵图,结果如图 6 所示。

由图 6 可知,电堆电压和 5 片单电池电压与时间呈明显负相关,而其他参数的相关性不强,这表

表 2 实验期间采集的特征参数
Table 2 Characterization parameters collected during experiment

特征参数	物理意义
Time/h	时间
$U_1 \sim U_5/V; U_{tot}/V$	单电池 1~5 电压;电堆电压
$I/A; J/(A \cdot cm^{-2})$	电流;电流密度
$T_{inH_2}/^{\circ}C; T_{outH_2}/^{\circ}C$	氢气进口温度;氢气出口温度
$T_{inAIR}/^{\circ}C; T_{outAIR}/^{\circ}C$	空气进口温度;空气出口温度
$T_{inWAT}/^{\circ}C; T_{outWAT}/^{\circ}C$	冷却水进口温度;冷却水出口温度
$P_{inH_2}/10^2Pa; P_{outH_2}/10^2Pa$	氢气进口压力;氢气出口压力
$P_{inAIR}/10^2Pa; P_{outAIR}/10^2Pa$	空气进口压力;空气出口压力
$D_{inH_2}/(L \cdot mn^{-1}); D_{outH_2}/(L \cdot mn^{-1})$	氢气进口流速;氢气出口流速
$D_{inAIR}/(L \cdot min^{-1}); D_{outAIR}/(L \cdot min^{-1})$	空气进气流速;空气出口流速
$D_{WAT}/(L \cdot min^{-1})$	冷却水流速
HrAIRFC/%	空气湿度

明电压数据更适合表征 PEMFC 的老化过程。此外,文献[2,3,22,24]均只采用电压维度作为 PEMFC 性能退化指标,进一步说明以电堆电压作为其老化程度主要评价指标的合理性。因此,本文选择电堆电压作为 PEMFC 性能退化指标。

3.3 实验数据预处理

通过原始电压数据可以观察到,PEMFC 的老化趋势具有非线性、周期性和随机性特征,导致其电压波动非常剧烈。因此,需要对实验数据进行预处理,具体步骤如下:

(1)根据法国 FCLAB 在 IEEE PHM 2014 数据挑战赛上公开的数据可知,数据集 FC1 包含 143 862 组老化数据,FC2 包含 127 371 组老化数据。由于计算量过于庞大,因此以 1 h 为时间间隔对原始老化数据进行重构。

(2)原始老化数据中存在部分尖峰和大量噪声,若直接将其用于训练模型,则会影响模型的预测精度。因此,训练前采用 LOWESS 对重构数据进行平滑处理,数据预处理结果如图 7 所示。

由图 7 可知,平滑处理后的数据不仅有效去除了尖峰和噪声,还保留了原始老化数据的主要趋势,后续均以平滑处理后的数据为基础对 PEMFC 进行老化分析。

(3)与短期预测类似,在进行长期迭代预测前需对预处理数据进行归一化,以减少变量间差异较大对模型性能的影响。同时,对数据集进行划分,一部分作为训练集用于训练模型,另一部分作为测试集用于后续老化状态预测。

3.4 老化预测结果及分析

3.4.1 失效阈值和预测评估指标

PEMFC 的失效阈值并不是恒定标准,因此根据初始总电压百分比定义 PEMFC 的失效阈值。对于数据集 FC1,失效阈值设定为初始总电压的 96.5%,即 3.23 V;对于数据集 FC2,失效阈值设定为初始总电压的 95.5%,即 3.18 V^[2]。当电堆电压降至失效阈值时,判定燃料电池失效,必须对其进行修复或更换。

选取均方根误差(Root mean square error, RMSE)和平均绝对百分比误差(Mean absolute percentage error, MAPE)2 个常用的模型预测评估指标,评估模型的预测结果。其中,RMSE 主要反映预测值与真实值之间的偏差程度,MAPE




图 6 相关性分析矩阵图
Fig. 6 Correlation analysis matrix diagram




图 7 预处理后的老化数据

Fig. 7 Aging data after preprocessing

主要用于衡量预测结果的准确性,二者分别用 f_{RMSE} 和 f_{MAPE} 表示,计算公式如下:

$$f_{\text{RMSE}} = \sqrt{\frac{1}{n} \cdot \sum_{j=1}^n (\hat{v}_j - v_j)^2} \tag{22}$$

$$f_{\text{MAPE}} = \frac{1}{n} \sum_{j=1}^n \left| \frac{v_j - \hat{v}_j}{v_j} \right| \tag{23}$$

式中: v_j 为实际电压值; $\hat{v}_j$ 为模型预测电压值; n 为预测结果的个数。 f_{RMSE} 和 f_{MAPE} 的值越小,说明模型对电压趋势的预测效果越好^[24]。

3.4.2 网格超参数优化

为防止模型在训练阶段出现网格过拟合现象,本文采用 2D-G 结构优化 LSTM 网络参数。待优化的超参数包括输入层维数、隐藏层神经元个数、输出层维数、批大小、训练轮数、学习率及验证频率,优化后的结果如表 3 所示。

3.4.3 基于 FC1 的长期预测结果及分析

根据不同的训练时长,将重构平滑后的数据集 FC1 分为 6 组,用于训练 LOWESS-2D-G-LSTM,并与相关向量机 (Relevance vector machine, RVM)、EKF 和 LSTM 3 种算法^[25]进行对比,预测曲线如图 8 所示。总时长为 1 000 h,预测起始点 T_p 设为 550、600、650、700、750、800 h,剩余的老化数据作为测试集用于验证预测结果。计算得到

表 3 网格参数优化结果

Table 3 Grid parameters optimization results

网格类型	参数	数值
2D-G-LSTM	输入层维数	20
	隐藏层神经元个数	60
	输出层维数	5
	批大小	56
	训练轮数	54
	学习率	0.001
	验证频率	10

4 种算法的预测评估指标对比结果如图 9 所示。

与短期预测相比,长期预测的时间跨度更长、预测精度略低,但可以对未来长时间的变化趋势提供很好的指示作用。从图 8 的预测曲线可以看出,4 种算法均可以根据数据集 FC1 预测 PEMFC 的老化趋势。在预测初期,LSTM 方法可以预测局部非线性特征,并且有助于预测电压恢复现象;但是随着预测时间的延长,预测电压逐渐与实际电压产生偏差。由于测试数据未参与模型参数更新,因此 EKF 方法的预测曲线呈线性趋势,且随着训练时长的增加,基于 EKF 预测的输出电压老化率基本保持恒定。RVM 方法的预测结果虽然呈现非线性,但是与原始数据差距较大。相比之下,随着训练时长的增加,LOWESS-2D-G-LSTM 方法的电压预测曲线能够平稳有效地拟合实际老化趋势,而其余 3 种方法的预测曲线与真实值存在明显偏差。

从图 9 中可以看出,LOWESS-2D-G-LSTM 方法的 f_{RMSE} 和 f_{MAPE} 变化较小且保持在最低水平,说明该方法具有较高的预测精度和稳定性。特别地,当预测起始点为 550 h 时,相比于单个 LSTM,LOWESS-2D-G-LSTM 方法的 f_{RMSE} 和 f_{MAPE} 分别降低了 51.19% 和 53.66%。同时,对比 4 种方法在不同训练时长下的预测评估指标可以看出,LOWESS-2D-G-LSTM 不仅在训练时长较短的情况下对老化趋势具有较好的拟合能力,在训练时长较长的情况下也具有较高的稳定性和预测精度。

3.4.4 基于 FC2 的长期预测结果及分析

根据不同训练时长将重构平滑后的数据集 FC2 分为 6 组,用于训练 LOWESS-2D-G-LSTM,并与 RVM、EKF 和 LSTM 3 种算法^[25]进行对比,预测曲线如图 10 所示。总时长为 1 000 h,预测起始点




图 8 FC1 中 4 种算法在不同训练时长下的预测曲线

Fig. 8 Prediction curves of the four algorithms in FC1 for different training duration




图 9 FC1 中 4 种算法的预测评估指标

Fig. 9 Predictive evaluation metrics for four algorithms in FC1

设为 $T_p=550$ h、 600 h、 650 h、 700 h、 750 h、 800 h, 剩余数据作为测试集对算法进行测试。图 11 为

计算所得 4 种算法预测评估指标的对比结果。

从图 10 的预测曲线中可以看出, LOWESS-2D-G-LSTM 方法可以根据动态工况 FC2 稳定预测不同训练阶段下 PEMFC 的老化趋势, 并能够适应电压数据的跳跃变化。然而, EKF 方法的预测曲线仍呈线性趋势, 只有当预测起始点 > 650 h 时才能获得良好的预测效果, 预测起始点的变化会对其预测结果产生较大影响, LOWESS-2D-G-LSTM 预测方法则会克服这一缺点。此外, 在准动态运行工况下, RVM 和 LSTM 方法难以提取 PEMFC 电压数据的内在特征, 因此在各训练阶段都无法保证预测结果的准确性。LOWESS-2D-G-LSTM 对运行条件和干扰具有更强的鲁棒性, 说明该方法相比于其他方法具有更稳定的网络结构和学习能力, 这一特性有助于提高预测精度, 总体上能反映实际老化趋势, 并为预后决策提供额外的信息。从图 11 中可以看出, 随着训练时长的增加, 除了预测起始点为 650 h 时, 电压恢




图 10 FC2 中 4 种算法在不同训练时常下的预测曲线

Fig. 10 Prediction curves of the four algorithms in FC2 for different training duration




图 11 FC2 中 4 种算法的预测评估指标

Fig. 11 Predictive evaluation metrics for four algorithms in FC2

复效应导致预测稍有偏差,在其余预测起始点 LOWESS-2D-G-LSTM 均取得了较优的预测指标, $f_{RMSE} < 0.024$, $f_{MAPE} < 0.006$, 远低于其余 3 种方法。这说明 LOWESS-2D-G-LSTM 方法具有较强的泛化能力,可以有效提取 PEMFC 输出电压数据中的退化特征。

综上所述,LOWESS-2D-G-LSTM 在静态和动态工况下的预测精度均得到提升,验证了本文方法的有效性。

3.5 对比分析

为验证本文方法的预测性能,将 LOWESS-2D-G-LSTM 与 2 种传统方法(BPNN 和 ESN)进行对比分析。表 4 列出了当预测起始点为 550 h 时,不同工况下 3 种方法的预测评估指标。由表 4 可以看出,与传统方法 BPNN 和 ESN 相比,LOWESS-2D-G-LSTM 方法在静态和动态工况下的 f_{RMSE} 和 f_{MAPE} 值均最小,说明本文方法获得了更佳的老化预测精度。主要原因是:本文 2D-G-

LSTM结构通过更深的网络和更稳定的架构对模型参数进行了优化,并且通过LOWESS平滑重构数据,在保留数据主要趋势的同时去除噪声和尖峰。综上,仿真分析和对比分析表明,无论是在静态工况下还是在动态工况下,本文方法均具有最佳的老化预测精度和鲁棒性。

表4 不同工况下3种方法的预测评估指标

Table 4 Predictive evaluation metrics for three methods under different operating conditions

工况	预测方法	f_{RMSE}	f_{MAPE}
静态 (FC1)	BPNN ^[25]	0.016 8	0.003 8
	ESN ^[25]	0.027 1	0.007 1
	LOWESS-2D-G-LSTM	0.008 2	0.001 9
动态 (FC2)	BPNN ^[25]	0.023 6	0.006 1
	ESN ^[25]	0.037 9	0.017 8
	LOWESS-2D-G-LSTM	0.019 5	0.005 1

4 结 论

(1)通过LOWESS去噪对原始数据进行处理,在保留原始数据老化趋势的同时显著降低计算复杂度,为后续PEMFC长期老化趋势预测提供先决条件。采用2D-G结构优化LSTM确定最优参数,并构建2D-G-LSTM预测网络,相比于单个LSTM,预测稳定性得到提升。

(2)以 f_{RMSE} 和 f_{MAPE} 作为预测评估指标,以电堆电压作为性能退化指标,在FC1和FC2数据集下对不同训练时长的PEMFC系统进行长期老化预测。结果表明,相比于EKF、LSTM、RVM、ESN和BPNN算法,本文方法误差更小,且具有最佳的老化预测效果。当训练时长为550 h时,在静态工况数据集FC1下 f_{RMSE} 和 f_{MAPE} 分别为0.008 2和0.001 9,相比单个LSTM分别降低了51.19%和53.66%;当训练时长为700 h时,在动态工况数据集FC2下 f_{RMSE} 和 f_{MAPE} 分别为0.018 8和0.004 4,相比单个LSTM分别降低了43.88%和49.43%。

参考文献:

[1] 高锋阳, 强雅昕, 高智山, 等. 计及驾驶风格的氢燃料电池有轨电车自适应能量管理策略[J]. 铁道科学与工程学报, 2024, 21(4): 1379-1390.
Gao Feng-yang, Qiang Ya-xin, Gao Zhi-shan, et al. Counting and driving style hydrogen fuel cell trams adaptive energy management strategy[J]. Journal of Railway Science and Engineering, 2024, 21(4):

1379-1390.

- [2] 李浩, 李浩, 杨扬, 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, Li Hao, Yang Yang, et al. PEMFC aging prediction based on improved whale optimization algorithm optimized GRU[J]. Proceedings of the CSEE, 2024, 44(20): 8166-8178.
- [3] 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 Ling-xian, Zhang Lei-qi, 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.
- [4] 苏雨临, 连冠, 张大骋. 等效电路模型法预测动态工况下微型直接甲醇燃料电池剩余使用寿命[J]. 上海交通大学学报, 2024, 58(10): 1575-1584.
Su Yu-lin, Lian Guan, Zhang Da-cheng. Equivalent circuit model-based prognostics for micro direct methanol fuel cell under dynamic operating conditions[J]. Journal of Shanghai Jiaotong University, 2024, 58(10): 1575-1584.
- [5] 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 Hong-yuan, 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.
- [6] Bressel M, Hilairat M, Hissel D, et al. Extended kalman filter for prognostic of proton exchange membrane fuel cell[J]. Applied Energy, 2016, 164: 220-227.
- [7] 胡捷, 苏建徽, 杜燕, 等. 基于最小二乘法的PEMFC电堆模型参数辨识[J]. 太阳能学报, 2021, 42(6): 1-4.
Hu Jie, Su Jian-hui, Du Yan, et al. Parameter identification of PEMFC stack model based on least square method[J]. Acta Energiæ Solaris Sinica, 2021, 42(6): 1-4.
- [8] Chen K, Laghrouche S, Djerdjir A. Fuel cell health prognosis using unscented kalman filter: postal fuel cell electric vehicles case study[J]. International Journal of Hydrogen Energy, 2019, 44(3): 1930-1939.
- [9] Chen K, Laghrouche S, Djerdjir 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.
- [10] Chen K, Laghrouche S, Djerdir A. Proton exchange membrane fuel cell degradation and remaining useful life prediction based on artificial neural network[C]// *Renewable Energy Research and Applications*. Paris: Universit Bourgogne Franche-Comt, 2018: 14-17.
- [11] 潘诗媛, 华志广, 王光伟, 等. 基于级联回声状态网络的氢燃料电池剩余使用寿命预测[J]. *中国电机工程学报*, 2025, 45(12): 4718-4728.
- Pan Shi-yuan, Hua Zhi-guang, Wang Guang-wei, et al. Remaining useful life prediction of hydrogen fuel cell based on cascade echo state network[J]. *Proceedings of the CSEE*, 2025, 45(12): 4718-4728.
- [12] 李鹏程. 基于循环神经网络氢燃料电池寿命预测技术[D]. 成都: 电子科技大学自动化工程学院, 2021.
- Li Peng-cheng. The RUL prediction of hydrogen fuel cells based on recurrent neural network[D]. Chengdu: School of Automation Engineering, University of Electronic Science and Technology of China, 2021.
- [13] Wang F K, Cheng X B, Hsiao K C. Stacked long short-term memory model for proton exchange membrane fuel cell systems degradation[J]. *Journal of Power Sources*, 2020, 448(6): No. 227591.
- [14] Zuo J, Lv H, Zhou D M, et al. Deep learning based prognostic framework towards proton exchange membrane fuel cell for automotive application[J]. *Applied Energy*, 2021, 281: No. 115937.
- [15] 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: 西南交通大学电气工程学院, 2020.
- Liu Jia-wei. Data-driven fault diagnosis and life prediction methods for PEMFC power generation system[D]. Chengdu: School of Electrical Engineering, Southwest Jiaotong University, 2020.
- [16] 张雪霞, 高雨璇, 陈维荣. 基于数据驱动的质子交换膜燃料电池寿命预测[J]. *西南交通大学学报*, 2020, 55(2): 417-427.
- Zhang Xue-xia, Gao Yu-xuan, Chen Wei-rong. Data-driven based remaining useful life prediction for proton exchange membrane fuel cells[J]. *Journal of Southwest Jiaotong University*, 2020, 55(2): 417-427.
- [17] 吴航宇, 王玮, 朱文超, 等. 基于 ARIMA-BiGRU 双数据驱动的燃料电池性能退化预测方法[J]. *中国电机工程学报*, 2025, 45(7): 2690-2699.
- Wu Hang-yu, Wang Wei, Zhu Wen-chao, et al. A fuel cell performance degradation prediction method based on ARIMA-BiGRU dual data-driven approach[J]. *Proceedings of the CSEE*, 2025, 45(7): 2690-2699.
- [18] Werbos P J. Backpropagation through time: what it does and how to do it[J]. *Proc IEEE*, 1990, 78(10): 1550-1560.
- [19] 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 Jia-wei, Li Qi, Chen Wei-rong, 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.
- [20] Cleveland W S. LOWESS: a program for smoothing scatterplots by robust locally weighted regression[J]. *American Statistician*, 1981, 35(1): 54-54.
- [21] 孙想, 吴保国, 吴华瑞, 等. 基于前置平滑的苗圃监测数据多元回归拟合方法[J]. *东北林业大学学报*, 2015, 43(12): 45-50.
- Sun Xiang, Wu Bao-guo, Wu Hua-rui, et al. Multiple regression fitting method of nursery monitoring data by pre-smoothing disposal[J]. *Journal of Northeast Forestry University*, 2015, 43(12): 45-50.
- [22] 赵波, 张领先, 章雷其, 等. PEMFC 剩余使用寿命直接预测的混合方法[J]. *中国电机工程学报*, 2024, 44(21): 8554-8568.
- Zhao Bo, Zhang Ling-xian, Zhang Lei-qi, et al. A hybrid method for direct prediction of PEMFC remaining useful life[J]. *Proceedings of the CSEE*, 2024, 44(21): 8554-8568.
- [23] FCLAB Research. IEEE PHM 2014 data challenge. 2014[DB/OL]. [2024-10-15]. <http://eng.fclab.fr/ieee-phm-2014-data-challenge/>.
- [24] 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 Jian-feng, Wang Rong-jie, Lin An-hui, et al. Research on degradation prediction method of proton exchange membrane fuel cell[J]. *Transactions of China Electrotechnical Society*, 2024, 39(11): 3367-3378.
- [25] Ma R, Xie R Y, Xu L C, et al. A hybrid prognostic method for PEMFC with aging parameter prediction[J]. *IEEE Transactions on Transportation Electrification*, 2021, 7(4): 2318-2331.