

粒子群优化算法结合改进回声状态网络的 PEMFC 剩余使用寿命预测

高峰阳¹, 刘嘉¹, 杨栋¹, 韩国鹏², 齐丰旭¹, 刘庆寅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:为提高质子交换膜燃料电池(proton exchange membrane fuel cell, PEMFC)退化预测的精度,提出一种基于粒子群(particle swarm optimization, PSO)算法优化改进回声状态网络(revised echo state network, RESN)的 PEMFC 电压预测方法。通过改进回声状态网络水库中各神经元连接方式,加快非线性拟合过程;利用 PSO 算法优化模型谱半径、泄漏率、神经元数量等,提高模型预测精度,采用 SG (Savitzky-Golay)滤波算法对原始数据有效去峰去噪,再利用 PSO-RESN 准确预测 PEMFC 电压;采用不同样本数据集作为训练集和测试集,将所提模型在静态和准动态实验数据集下与扩展卡尔曼滤波、传统回声状态网络进行对比。结果表明,在训练集占比为 80% 时,对于静态工况 FC1,相较于 ESN, PSO-RESN 方法的均方根误差(root mean square error, RMSE)和平均百分比误差(mean absolute percentage error, MAPE)分别降低了 17.50% 和 25.53%;对于准动态工况 FC2,相较于 ESN 方法, PSO-RESN 方法的均方根误差和平均百分比误差分别降低了 16.93% 和 21.28%。所提方法能够实现 PEMFC 更高精度退化趋势与剩余使用寿命预测。

关 键 词:质子交换膜燃料电池;退化预测;回声状态网络;粒子群算法;剩余使用寿命

中图分类号: TM911.4

文献标志码: A

文章编号: 1000-2758(2025)03-0478-10

质子交换膜燃料电池具有能量密度高、转换效率高、无污染等特点,被广泛应用在各种车载储能装置、微电网中^[1]。然而,不良的操作方式、燃料电池对运行环境的敏感以及自身结构都会引起不可逆的性能衰退^[2]。PEMFC 耐久性成为制约其工程应用的关键因素。因此,需要使用预后管理与健康管理(prognostics and health management, PHM)技术保障燃料电池正常运行。其中,剩余使用寿命(remaining useful life, RUL)预测是当前健康管理的关键^[3]。

PEMFC 退化预测方法主要有 3 类:模型驱动方法、数据驱动方法、混合方法。模型驱动方法通过燃料电池老化机理和材料属性进行退化预测,通常依据物理建模与经验建模来描述 PEMFC 的退化轨迹。主要方法有粒子滤波(particle filter, PF)^[4]、扩

展卡尔曼滤波(extended Karman filter, EKF)^[5]、半经验退化模型^[6]等。但是此类方法常常依赖于模型的内部退化机制,简化后的方法忽略了一些内部退化机制且在不同工况下模型驱动方法通用性较差,难以进行准确预测^[7]。

数据驱动方法无需模拟任何燃料电池退化的物理现象,在学习阶段使用大量历史数据进行训练。这个过程可以看作“黑匣子”。数据驱动方法一般选择电堆电压作为预测 RUL 的健康指标,包括长短期记忆(long short-term memory, LSTM)网络^[8]、反向神经网络(back propagation neural network, BPNN)^[9]、超限学习机(extreme learning machine, ELM)^[10]、回声状态网络(echo state network, ESN)^[11]等。文献[12]提出了一种堆叠长短期记忆网络(S-LSTM)模型来模拟 PEMFC 系统退化的预测方法,可以准确地预测燃料电池短期剩余使用寿命,但没有对长期剩余寿命进行预测,而长期预测对未来长时间的变化进行有很好的指示作用。此外,传

收稿日期:2024-05-07

基金项目:中车“十四五”科技重大专项计划(2021CXZ021)资助

作者简介:高峰阳(1970—),教授

通信作者:刘嘉(2000—),硕士研究生 e-mail:735375719@qq.com

统循环神经网络(recurrent neural networks, RNN)存在梯度爆炸缺点,无法捕捉数据序列的长时属性。针对上述问题,文献[13]提出了一种网格长短期记忆(G-LSTM)算法来预测电堆电压,能够在不同训练时长下保持有效长期预测,克服梯度爆炸缺点。文献[14]提出基于BP网络的老化预测模型,考虑了不同工况下 PEMFC 电流、温度、相对湿度和氢气压力对燃料电池老化的影响,但 BP 网络学习速度较慢,需要大量数据进行训练,还可能出现过拟合现象。文献[15]提出了一种自适应相关向量机(relevance vector machine, RVM)来预测 PEMFC 的电压退化,所提方法具有更高的自由度,可以降低计算复杂度。文献[16]提出了一种基于遗传算法和极限学习机的新型预测方法,有效提高了训练速度。文献[17]将回声状态网络与马尔可夫链相结合,可以在不事先了解负载分布的情况下预测动态负载中燃料电池寿命。但所提方法未将模型参数优化,训练速度有待提升。文献[18]通过多个“蓄水池”构成一种级联回声状态网络,利用遗传算法对模型参数进行优化,有效提高了训练速度、减少了训练时间。文献[19]提出一种结合回声状态网络和最小绝对收敛算法(LASSO-ESN)的预测策略,通过迭代消除权重最小的输入参数,确定不同工况下最优输入参数,并提供准确的 PEMFC 退化趋势预测。相比之下,回声状态网络具有更高的计算效率和更好的泛化性能,而且可以更高效地处理长期预测问题。

混合方法有3类:第1类是采用模型驱动方法提取退化指标,然后采用数据驱动方法实现退化趋势和 RUL 预测^[20];第2类是采用数据驱动方法对退化模型或测量数据进行提取和拟合,再采用基于模型方法对 RUL 进行估计^[21];第3类是使用2种或2种以上数据驱动方法来实现预测,并对每个结果进行加权和求和,得到最终的预测结果^[22]。但模型和数据结合的方法实质上还需依靠物理模型的构建,测量和运行环境的干扰、老化机理复杂性都会影响物理模型预测结果的准确性。多种数据结合的方法需要大量数据支撑,长时运用会造成误差积累,无法保证长期预测结果的可释性。

为进一步提高 PEMFC 退化趋势及 RUL 预测精度,考虑到传统数据驱动方法预测精度效果不佳,大量数据训练可能会出现过拟合现象,本文提出一种改进回声状态网络模型预测 PEMFC 电压退化趋势与 RUL 的方法。主要贡献如下:

1) 对于 ESN 方法,改变储层内传统神经元连接方式,使储层内部神经元能够双向传递,改变后的模型具有更好的非线性拟合能力。

2) 在预测模型中引入 PSO 算法,将 PSO 算法全局寻优速度快、收敛性强的优点与 RESN 进行结合,得到适应于 RESN 网络模型超参数的最优调整,提高了训练速度与预测精度。

3) 分别在不同训练集与不同实验数据下与 EKF 和 ESN 方法进行对比,验证所提方法的有效性。

1 粒子群优化算法和回声状态网络算法原理

1.1 粒子群优化算法

粒子群优化算法利用群体中个体间的协作和信息共享来寻找最优解,通过不断更新粒子速度和位置,计算目标函数适应度值,得到粒子个体最优位置和全局最优位置。将训练误差作为适应度值,速度和位置更新的数学公式为

$$v_{ij}(t+1) = \omega v_{ij}(t) + c_1 r_{ij}(t)(p_{ij}(t) - s_{ij}(t)) + c_2 \bar{r}_{ij}(t)(p_{gj}(t) - s_{ij}(t)) \quad (1)$$

$$s_{ij}(t+1) = s_{ij}(t) + v_{ij}(t+1) \quad (2)$$

式中: i 为第 i 个粒子; j 为维度空间; ω 为惯性权值因子; v 为粒子速度; s 为当前位置; c_1 和 c_2 为学习因子,取值一般为2; r_{ij} 和 $\bar{r}_{ij}$ 是介于(0,1)之间的随机数; p_{gj} 为所有粒子在 t 时刻的历史最优位置; p_{ij} 为个体粒子的历史最优位置。

为了保证全局搜索能力和收敛能力,权值更新采用线性递减策略,如(3)式所示。

$$\omega = \omega_{\max} - \frac{t(\omega_{\max} - \omega_{\min})}{t_{\max}} \quad (3)$$

根据粒子群算法标准,最大惯性系数 $\omega_{\max} = 0.9$,最小惯性系数 $\omega_{\min} = 0.4$; t 为当前迭代次数。

1.2 回声状态网络算法

回声状态网络被称为循环神经网络(RNN)的另一种趋势。ESN 由输入层、储层、输出层组成。ESN 的2个优点也适合于长期预测问题。首先,回声状态网络训练速度非常快,不需要局部最优。其次,传统 RNN 存在梯度消失问题,使得 RNN 的记忆只关注数据序列的短期属性^[23]。相反,通过设置大量神经元数量,可以在回声状态网络结构中维持较

长的依赖关系。ESN 结构如图 1 所示。




图 1 ESN 基本结构示意图

传统 ESN 中,储层单元内部状态 $x(t)$ 用(4)~(5)式更新。

$$\tilde{x}(t+1) = f(W_{in}u(t+1) + W_{res}x(t)) \quad (4)$$

$$x(t+1) = (1 - \alpha)x(t) + \alpha\tilde{x}(t+1) \quad (5)$$

式中: W_{in} 和 W_{res} 为输入权值矩阵和储层内部矩阵,被随机初始化为固定值; f 为储层单元的激活函数; $u(t+1)$ 为输入数据; α 为泄漏率。

储层内激活函数 f 一般采用 $\tanh$ 函数,用于加速收敛和缓解梯度消失问题,如(6)式所示。

$$\tanh(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (6)$$

线性输出层更新方程为

$$y(t+1) = W_{out}x(t) \quad (7)$$

式中: W_{out} 为输出权值矩阵。

训练 ESN 模型的主要目的是将输出值 $y(t)$ 与目标值 $y_t(t)$ 之间的均方根误差 RMSE 最小化,如(8)式所示。

$$W_{out} = \operatorname{argmin} \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t(t) - y(t))^2} \quad (8)$$

输出层采用脊回归法(ridge regression, RR)得到(9)式所示结果。

$$W_{out} = X^T Y_t (X^T X + \lambda I)^{-1} \quad (9)$$

式中: X 和 Y_t 分别为储层和目标输出; λ 为正则化参数; I 为单位矩阵。

1.3 改进 ESN 原理

RESN 为改进回声状态网络结构,如图 2 所示,同样具有 3 层结构,输入为 K 个节点,状态方程为 $u(t) = [u_1(t), u_2(t), \dots, u_K(t)]^T$; 储层有 N 个节点,状态方程为 $x(t) = [x_1(t), x_2(t), \dots, x_N(t)]$; 输出层为 $y(t) = [y_1(t), y_2(t), \dots, y_M(t)]$, M 为节点个数; 与 ESN 模型不同的是, W_{in} 是固定的,水库中 W_{RESN}

的权值由 A_c 与 A_l 确定,而不是随机生成。 A_c 为循环权值矩阵, A_l 为跨越权值矩阵, RESN 储层状态更新方程与输出方程如(10)~(12)式所示。




图 2 RESN 基本结构示意图

$$\tilde{x}_{RESN}(t+1) = \tan(W_{in}^{RESN}u(t+1) + W_{res}^{RESN}x_{RESN}(t)) \quad (10)$$

$$x_{RESN}(t+1) = (1 - \alpha)x_{RESN}(t) + \alpha\tilde{x}_{RESN}(t+1) \quad (11)$$

$$W_{out} = X^T Y_t (X^T X + \lambda I)^{-1} \quad (12)$$

式中: W_{in}^{RESN} 为 RESN 模型输入权值矩阵; W_{out} 为输出权值矩阵。

传统 ESN 水库的循环矩阵中部分神经元单向传递,根据连接状态, $W_{12} = W_{23} = W_{34} = W_{41} = 1$, 表示互相连接。其余神经元连接权值为 0, 虚线表示没有连接。改进回声状态网络水库中神经元可以双向连接,既可实现跨越连接也可实现循环连接,根据跨越矩阵连接状态, $W_{13} = W_{31} = 1, W_{24} = W_{42} = 1$ 。储层内部连接关系如图 3 所示。




图 3 储层内部连接关系

1.4 模型超参数优化

回声状态网络的超参数包括输入矩阵 W_{in} 、循环权值矩阵 A_c 、输入大小 K 、输出大小 L 、储层神经元个数 N_{res} 、泄漏率 α 、谱半径 ρ 、正则化参数 b 。矩陣由以 0 为中心的正态分布得到。一般原则是,神经元个数越多,回声状态网络的输出性能越好。谱半径 ρ 是储层的最大绝对特征值,可以实现循环矩阵的缩放并保持良好性能,它决定了输入影响随时间在储层中消失的速度。为使回声状态网络稳定,

通常将谱半径 ρ 设置为小于 1,但在某些应用中,谱半径大于 1 可以获得更好的性能。泄漏率 α 值同样对储层动态性能有很大影响, α 越小,储层内状态更新越慢。说明电堆电压对预测的影响越大^[24]。因此,为了达到更好的预测效果,需要用粒子群优化算法获取模型超参数。优化后的 RESN 模型关键参数如表 1 所示。

表 1 PSO-RESN 模型关键参数

参数	数值
储层库神经元数量	500
泄漏率 α	0.3
谱半径 ρ	0.4
正则化参数 b	8×10^{-8}
输入权值矩阵 W_{in}	$[-0.5,0.5]$
循环权值矩阵 A_c	(0.5)
跳跃权值矩阵 A_1	(0.7)

2 基于 PSO-RESN 的 PEMFC 长期老化预测

基于 PSO-RESN 的 PEMFC 长期老化预测流程如图 4 所示,选取电堆电压作为退化指标。预测步骤总结如下:

- 1) 处理原始老化数据,对于 FC1(静态工况数据集)与 FC2(准动态工况数据集),每间隔 0.5 h 提取 1 组数据点,采用 SG 滤波算法对数据预处理,分别取 50%,60%,70%和 80%的数据作为训练集,其余数据作为测试集。对于 FC3(工况数据集),每隔 1 h 提取 1 组数据点,分别选取 500,600,700 和 800 h 的数据作为训练集,其余数据用于测试。
- 2) 选取粒子群优化算法,设定种群参数和种群位置,其中取 RMSE 作为适应度值。
- 3) 构建 RESN 模型,调整水库神经元连接方式,更新状态方程与输出方程。
- 4) 根据最新位置计算适应度值,指导粒子全局最优和个体最优位置的更新,最终得到最优粒子。
- 5) 利用粒子群算法确定 RESN 模型优化后的关键参数,如泄漏率、谱半径、正则化参数、库中神经元数量等。
- 6) 将采样数据 $\{(t_1,u_1),(t_2,u_2),\cdots,(t_n,u_n)\}$ 作为更新后的 RESN 模型输入进行训练,其中 t_i 为训练集, u_i 为电堆电压,计算输出权值矩

- 阵 W_{out} 。
- 7) 判断预测结果是否达到老化精度,若达到则输出最优参数,否则重复步骤 4) ~ 5)。
- 8) 基于输出矩阵 W_{out} 和采样电压 U_n ,预测下一时刻的电压值和剩余使用寿命。




图 4 基于 PSO-RESN 的 PEMFC 老化预测流程

3 验证与讨论

3.1 实验数据集

实验数据采用 3 组数据集(FC1 静态工况数据集、FC2 准动态工况数据集以及 FC3 工况数据集)进行验证。

FC1 和 FC2 数据来自法国 FCLAB 实验室 IEEE PHM 2014 data CHALLENGE,包括 5 个单体电池组成的 PEMFC 电堆,功率为 1 kW(电堆功率)。每个电池有效面积为 100 cm²,最大电流密度为 1 A/cm²。静态工况 FC1 数据集指 PEMFC 在标称电流密度为 0.70 A/cm² 条件下工作,共运行 1 054 h;准动态工况 FC2 数据集指 PEMFC 在电流密度为 (0.70 ± 0.07) A/cm² 条件下工作,共运行 1 020 h。

FC3 数据集来自绿光 Greenlight 20(G20)测试站对 PEMFC 进行约 1 008 h 的动态负载测试^[25],采用欧洲协调的测试协议作为标准,包含 3 076 个动态负载循环,每个动态负载循环通过极化测试,获取电堆电压、电流、功率等 16 维共 362 960 组数据。

相较于其他商用燃料电池,实验电堆可以较好


地反映燃料电池老化趋势,更适用于验证 PEMFC 寿命预测方法的可行性和大规模的工业部署。

3.2 数据预处理

SG 算法是一种基于最小二乘原理的多项式平滑算法,又称卷积平滑。利用最小二乘法拟合一个假设的高阶多项式,对一段数据进行加权滤波。设置滤波器窗宽为 51,多项式阶数为 3。

对于原始老化数据集 FC1 和 FC2,由于数量庞大,数据集包含大量的噪声和峰值,直接用于训练会造成计算量大、计算时间过长问题。因此,以 0.5 h 为时间间隔进行数据重构,并采用 SG 滤波算法对数据进行平滑处理。

对于 FC3,实验数据根据负载电流划分为 9 个电流等级,动态工况由负载电流 9 个电流等级反映电压变化的数据组成,其中选取占比较多的 10.4 A 电流等级表征燃料电池电压变化的数据,构建“伪稳态”工况^[25]。以 1 h 为时间间隔进行数据重构,构成新的 FC3 数据集。



3.3 退化趋势预测

为比较预测结果,采用均方根误差(E_{RMS})和平均百分比误差(E_{MAP})2 个定量指标来评价不同模型的预测性能,如(13)~(14)式所示。

$$E_{\text{RMS}} = \sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t(n) - \tilde{Y}_t(n))^2} \quad (13)$$

$$E_{\text{MAP}} = \frac{1}{T} \sum_{t=1}^T \left| \frac{Y_t(n) - \tilde{Y}_t(n)}{Y_t(n)} \right| \quad (14)$$

式中: $Y_t(n)$ 和 $\tilde{Y}_t(n)$ 为模型在 RUL 时间(n 个数据点)的实际电压和预测电压; T 表示点数。 E_{RMS} 和 E_{MAP} 值越低,其相应的退化性能越好。

3.3.1 基于静态工况 FC1 预测

对于数据集 FC1,在训练集占比分别为 50%, 60%, 70% 和 80% 时的预测结果如图 5 所示,将所提方法与实际测得电压数据、静态 EKF、ESN 预测方法进行对比,预测评估指标对比如图 6 所示。




图 5 FC1 中不同方法在不同训练占比下的预测结果

从图 5 可以看出,静态 EKF 与 ESN 方法不能同时捕捉电压恢复信息和整体老化部分。对于静态 EKF,用于模型的测试数据没有进行参数更新,导致 EKF 方法呈现线性趋势。随着训练集百分比增加,预测趋势基本保持恒定。当训练集占比较低时,ESN 方法无法跟踪整个退化趋势并捕获电压恢复

信息,但在训练集占比较高的情况下可以跟踪整个退化趋势。随着训练占比的提高,PSO-RESN 方法与实际电压曲线高度吻合。相比于单一的 ESN 与静态 EKF 方法能更有效预测并准确跟踪燃料电池退化趋势,能够较好地利用历史数据中时间序列与非线性特性。

从图 6 可以看出,PSO-RESN 的 E_{RMS} 、 E_{MAP} 值最小,说明 PSO-RESN 具有最高的预测精度。在训练集为 50% 占比时,对于 EKF,PSO-RESN 的预测结果的 E_{RMS} 和 E_{MAP} 分别降低了 46.10% 和 50.85%; 对




图 6 FC1 中不同训练占比的 E_{RMS} 和 E_{MAP}

于 ESN,PSO-RESN 预测结果的 E_{RMS} 和 E_{MAP} 分别降低了 50.17% 和 47.27%。同时在训练占比较高时,PSO-RESN 的 E_{RMS} 和 E_{MAP} 均低于 EKF 和 ESN。说明所提方法在稳态工况中训练集占比较低和较高情况下都拥有最高预测精度。

3.3.2 基于准动态工况 FC2 预测

对于准动态数据集 FC2,不同训练集占比的预测结果如图 7 所示,预测评估对比指标如图 8 所示。从图 7 可以看出,EKF 方法无法捕捉电压恢复信息,预测结果呈线性趋势,在训练集占比为 50%,70% 和 80% 时无法跟踪退化趋势。训练集占比的变化会对预测结果产生不同影响,传统 ESN 方法在训练集占比较高时可以跟踪退化趋势,训练占比较低时无法准确预测。在准动态工况中 EKF 和 ESN 方法无法准确提取 PEMFC 电压数据中的时间序列,而 PSO-RESN 方法可以克服这一缺点,采用内部神经元相互连接方式,能够增强跟踪电压退化趋势的能力,捕捉电压恢复信息。对于不同运行条件具有较强的抗干扰能力,进一步提高预测准确性,减少了预后延迟。




图 7 FC2 中不同方法在不同训练集占比下的预测结果

从图 8 可以看出,准动态工况下 EKF 和 ESN 方法中 E_{RMS} 相较于静态工况有所增加。准动态工况 PEMFC 退化更复杂,会受到更多输入参数的影响。

但 PSO-RESN 拥有最小 E_{MAP} 与最高预测精度,这是因为所提方法进行了模型超参数优化,而其他方法的超参数是随机设置,导致预测效果不佳。在训练

集为 50% 占比时,相比于 ESN, PSO-RESN 的预测结果的 E_{RMS} 和 E_{MAP} 分别降低了 46.63% 和 47.13%。同样在训练占比较高时, PSO-RESN 的 E_{RMS} 和 E_{MAP} 均低于 EKF 和 ESN。




图 8 FC2 中不同训练集占比的 E_{RMS} 和 E_{MAP}

3.3.3 基于 FC3 数据集预测

针对数据集 FC3, PSO 算法得到最优参数设置 储层神经元数量为 500, 泄漏率 α 为 0.5, 谱半径 ρ 为 1.2, 正则化参数 b 为 1×10^{-8} , 输入循环跳跃权值矩阵与表 1 中设置一致。图 9 展示了不同方法在数

据集 FC3 下,不同训练时长电压退化趋势预测结果。从图 9 看出,随着训练时长的增加, PSO-RESN 较于其他方法进一步提升了对波峰、波谷的预测效果,预测结果更接近实际值。




图 9 FC3 数据集在不同训练时长下的预测结果

表 2 总结了不同方法在不同训练时长下的评估指标,由于所提方法引入 PSO 算法自适应搜索模型最优超参数,在新构建的 FC3 数据集中同样可以拥有最高精度,进一步验证了所提方法可适用于不同实验数据。

表 2 FC3 不同预测方法结果对比

预测方法	E_{MSE}				E_{MAP}			
	500 h	600 h	700 h	800 h	500 h	600 h	700 h	800 h
EKF	0.64	0.58	0.56	0.54	0.603 0	0.573 1	0.566 7	0.511 3
ESN	0.51	0.49	0.47	0.44	0.429 5	0.422 3	0.413 2	0.369 7
PSO-RESN	0.41	0.39	0.36	0.35	0.338 6	0.329 8	0.314 1	0.293 7

3.4 RUL 预测

RUL 可以看作是电堆达到一定功率或电压损失前的时间,通常使用预测寿命结束时刻 T_{EOL} 与预测寿命开始时刻 T_{BOL} 之差,来确定 RUL 预测结果如 (15) 式所示。

$$L_{\text{RU}} = T_{\text{EOL}} - T_{\text{BOL}}$$

(15)

图 10 展示了所提 PSO-RESN 方法 RUL 的实际值 $L_{\text{RU, real}}$ 与估计值 $L_{\text{RU, prdt}}$, 对于 FC1, 当电堆总电压降至初始电压的 96.5% 时, 即电堆总电压为 3.203 V

时, PEMFC 被定义为失效^[23], 对应预测寿命时间为 805 h。对于 FC2, 当电堆总电压降至初始电压的 96% 时, 预测电压低于 3.182 V 时, 电堆寿命结束, 对应预测寿命时间为 774 h。PSO-RESN 方法的估计 L_{RU} 与实际 L_{RU} 基本一致, 随着训练数据量的增加, 预测曲线与实际曲线的拟合也更加接近。精度随训练集占比的增加明显升高。在准动态电流下, 所提模型仍具有良好的性能, 说明所提方法更适合于 PEMFC 的 RUL 预测。




图 10 60%训练集下 FC1 与 FC2 的 RUL 预测

4 结 论

针对 PEMFC 长期退化和 RUL 预测问题,提出一种粒子群算法优化改进回声状态网络数据驱动预测模型;利用燃料电池非线性和多时间老化尺度特

性,实现 PEMFC 性能退化预测。并采用不同实验数据集和不同方法进行对比,结论如下:

1) 通过改变回声状态网络中水库结构,在各种神经元之间形成循环连接和跳跃连接,引入 PSO 算法优化模型超参数。相较于传统 ESN 模型,提高了预测结果的鲁棒性与准确性,RUL 预测值与真实值更加接近。

2) 选取平均绝对百分比误差和均方根误差作为评估指标。FC1、FC2 和 FC3 实验数据集预测结果表明,相比于 EKF 和传统 ESN 方法,PSO-RESN 方法具有最小误差和最高的预测精度。在训练集占比为 60%时,对于静态工况 FC1,PSO-RESN 方法相较于 ESN 方法,RMSE 和 MAPE 分别降低了 32.41% 和 40.38%,RUL 实际计算值为 805 h;对于准动态工况 FC2,相较于 ESN 方法,RMSE 和 MAPE 分别降低了 51.92% 和 57.55%,RUL 实际值为 774 h。对于 FC3 数据集,PSO-RESN 相较于其他 2 种方法同样拥有较高精度,表明所提方法适应于不同实验数据。

3) 所提预测模型结合了 PSO 和 ESN 优势,可以在不同实验数据下预测 PEMFC 退化趋势并获得较高的预测精度。下一步尝试探究 PEMFC 中多变量(电压、电流、温度、压力)作为 RUL 输入的预测方法,建立多输入单输出的 RESN 模型。

参考文献:

[1] 张钰凡,李玉忍,马睿,等. 基于 ARIMA-LSTM 深度学习混合模型的 PEMFC 老化预测方法[J]. 西北工业大学学报, 2023, 41(3): 464-470
ZHANG Yufan, LI Yuren, MA Rui, et al. Degradation prediction method of PEMFC based on deep learning hybrid model integrating ARIMA and LSTM[J]. Journal of Northwestern Polytechnical University, 2023, 41(3): 464-470 (in Chinese)

[2] 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 (in Chinese)

[3] WANG Wenxin, YANG Yang, LI Yang, et al. Operating conditions combination analysis method of optimal water management state for PEM fuel cell[J]. Green Energy and Intelligent Transportation, 2023, 2(4): 100105

[4] OU Mingyang, ZHANG Ruofan, SHAO Zhifang, et al. A novel approach based on semi-empirical model for degradation prediction of fuel cells[J]. Journal of Power Sources, 2020, 488: 229435-229445

[5] 刘浩. 质子交换膜燃料电池的寿命预测研究[D]. 杭州: 浙江大学, 2019
LIU Hao. Lifetime prediction study of proton exchange membrane fuel cells[D]. Hangzhou: Zhejiang University, 2019 (in Chinese)

[6] ZHOU Daming, AL-DURRA A, ZHANG Ke, et al. Online remaining useful lifetime prediction of proton exchange membrane fuel cells using a novel robust methodology[J]. Journal of Power Sources, 2018, 399: 314-328

[7] 张雪霞,黄平,蒋宇,等. 动态机车工况下质子交换膜燃料电池电堆衰退性能分析[J]. 电工技术学报, 2022, 37(18): 4798-4806

- ZHANG Xuexia, HUANG Ping, JIANG Yu, et al. Degradation performance analysis of proton exchange membrane fuel cell stack under dynamic locomotive conditions[J]. Transactions of China Electrotechnical Society, 2022, 37(18): 4798-4806 (in Chinese)
- [8] LIU H, 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: 5470-5480
- [9] CHEN K, LAGHROUCHE S, DJERDIR A. Proton exchange membrane fuel cell degradation and remaining useful life prediction based on artificial neural network [C] // 2018 7th International Conference on Renewable Energy Research and Applications, 2018
- [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 (in Chinese)
- [11] LI Z, ZHENG Z, OUTBIB R. Adaptive prognostic of fuel cells by implementing ensemble echo state networks in time-varying model space[J]. IEEE Trans on Industrial Electronics, 2019, 67(1): 379-389
- [12] WANG F, CHENG X, HSIAO K, et al. Stacked long short-term memory model for proton exchange membrane fuel cell systems degradation[J]. Power Sources, 2020, 488(22): 7591-7598
- [13] MA Rui, YANG Tao, EIENA B, et al. Data-driven proton exchange membrane fuel cell degradation predication through deep learning method[J]. Applied Energy, 2018, 231: 102-115
- [14] CHEN K, LAGHROUCHE S, DJERDIR A. Aging prognosis model of proton exchange membrane fuel cell in different operating conditions[J]. International Journal of Hydrogen Energy, 2020, 45(20): 11761-11772
- [15] WU Y, BREAZ E, GAO F, et al. A modified relevance vector machine for PEM fuel-cell stack aging prediction.[J]. IEEE Trans on Industry Applications, 2016, 52 (3): 2573-2581
- [16] CHEN K, LAGHROUCHE S, DJERDIR A. Proton exchange membrane fuel cell prognostics using genetic algorithm and extreme learning machine[J]. Fuel Cells, 2020, 20(3): 263-271
- [17] MEZZI R, YOUSFI-STEINER N, PÉRA M C, et al. An echo state network for fuel cell lifetime prediction under a dynamic micro-cogeneration load profile[J]. Applied Energy, 2021, 283: 116297
- [18] 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, 2024, 44(11): 3367-3378
- PAN Shiyuan, HUA Zhiguang, WANG Guangwei, et al. Remaining useful life prediction of hydrogen fuel cell based on cascade echo state network[J]. Proceedings of the CSEE, 2024, 44(11): 3367-3378 (in Chinese)
- [19] HE K, MAO L, YU J, et al. Long-term performance prediction of PEMFC based on LASSO-ESN[J]. IEEE Trans on Instrumentation and Measurement, 2021, 70(99): 1-11
- [20] MA R, XIE R, XU L, et al. A hybrid prognostic method for PEMFC with aging parameter prediction[J]. IEEE Trans on Transportation Electrification, 2021, 7(4): 2318-2331
- [21] 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 Lingxian, ZHANG Leiqi, et al. A hybrid method for direct prediction of PEMFC remaining useful life[J]. Proceedings of the CSEE, 2024, 44(21): 8554-8568 (in Chinese)
- [22] LI S, LUAN W, WANG C, et al. Degradation prediction of proton exchange membrane fuel cell based on Bi-LSTM-GRU and ESN fusion prognostic framework[J]. International Journal of Hydrogen Energy, 2022, 47(78): 33466-33478
- [23] 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 (in Chinese)
- [24] DENG Zhihua, CHEN Qihong, ZHANG Liyan, et al. Degradation prediction of PEMFCS using stacked echo state network based on genetic algorithm optimization[J]. IEEE Trans on Transportation Electrification, 2022, 8(1): 1454-1466
- [25] ZUO J, LYU H, ZHOU D, et al. Long-term dynamic durability test datasets for single proton exchange membrane fuel cell[J].

Data in Brief, 2021, 35: 106775

PEMFC remaining useful life prediction method combined particle swarm optimization algorithm with improved echo state network

GAO Fengyang¹, LIU Jia¹, YANG Dong¹, HAN Guopeng²,
QI Fengxu¹, LIU Qingyin¹

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

Abstract: In order to improve the accuracy of degradation prediction of proton exchange membrane fuel cell (PEMFC), a PEMFC voltage prediction method based on particle swarm optimization (PSO) algorithm to optimize the revised echo state network (RESN) is proposed. The nonlinear fitting process is accelerated by improving the connection mode of each neuron in the echo state network reservoir. The PSO algorithm is used to optimize the model spectral radius, leakage rate, number of neurons, etc, to improve the prediction accuracy of the model. The SG (Savitzky-Golay) filtering algorithm is used to retain the original trend of the original data and effectively remove the peak and noise. The PSO-RESN was used to accurately predict the PEMFC voltage. Different sample data sets are used as training sets and test sets, and the proposed model is compared with extended Kalman filter and traditional echo state network under static and quasi-dynamic experimental data sets. The results show that when the proportion of the training set is 80%, for the static condition FC1, compared with ESN, the root mean square error (RMSE) and the average percentage error (MAPE) of PSO-RESN method are reduced by 17.50% and 25.53%, respectively. For the quasi-dynamic condition FC2, compared with ESN, RMSE and MAPE are reduced by 16.93% and 21.28%, respectively. The proposed method can achieve higher precision degradation trend and remaining useful life prediction of PEMFC.

Keywords: proton exchange membrane fuel cell (PEMFC); aging prediction; echo state network; particle swarm algorithm; remaining useful life

引用格式:高峰阳, 刘嘉, 杨栋, 等. 粒子群优化算法结合改进回声状态网络的 PEMFC 剩余使用寿命预测[J]. 西北工业大学学报, 2025, 43(3): 478-487
GAO Fengyang, LIU Jia, YANG Dong, et al. PEMFC remaining useful life prediction method combined particle swarm optimization algorithm with improved echo state network[J]. Journal of Northwestern Polytechnical University, 2025, 43(3): 478-487 (in Chinese)