Vol.44 No.4 Apr. 2024

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

刘昕宇,韩 莹,陈维荣,李 奇,杨哲昊 (西南交通大学 电气工程学院,四川 成都 611756)

摘要:为了实现质子交换膜燃料电池(PEMFC)系统水故障的高效快速分类,提出了基于改进麻雀搜索算法(SSA)优化深度置信网络(DBN)的PEMFC故障分类方法。采用归一化处理消除故障数据参数之间量纲不同的影响,使用核主成分分析对数据进行故障特征提取,有效地缩减了原始数据维度,降低了运算复杂度,并避免低贡献度数据对故障分类造成干扰。引入柯西-高斯变异策略改进SSA,并利用SSA对DBN进行参数寻优,确定网络结构,通过优化后的DBN实现对PEMFC水故障的快速分类。对3000组PEMFC水故障数据进行测试,结果表明:所提方法可以快速准确地识别PEMFC的正常状态、膜干故障、水淹故障3种健康状态;总体的分类准确率为98.67%,运算时间为0.89s,相比支持向量机、概率神经网络方法,所提方法的故障分类精度分别提升了4%、3.34%,运算时间分别减少了15.35、0.35 s。

 关键词:质子交换膜燃料电池;故障分类;深度置信网络;麻雀搜索算法;核主成分分析;柯西-高斯变异策略

 中图分类号:TM911.4
 文献标志码:A
 DOI:10.16081/j.epae.202310008

0 引言

氢能作为绿色低碳、来源广泛的二次能源正逐 步成为全球能源转型发展的重要载体,对助力实现 "双碳"目标、构建安全高效的能源体系具有重要的 意义。质子交换膜燃料电池(proton exchange membrane fuel cell,PEMFC)是一种通过电化学反应使 氢能转化为电能的绿色环保发电装置,其具有清洁 高效、可靠性高、发电效率平稳等突出优点,在新能 源领域有广阔的应用前景。然而,燃料电池在面临 复杂工况和极端环境时易发生故障且使用寿命短, 这些缺陷始终制约着其大规模商用。为了解决以上 问题,亟需进行燃料电池故障分类的相关研究^[1-2]。 PEMFC故障分类系统的主要功能是检测系统运行 时发生的故障并进行故障定位及分类,为后续的故 障隔离、容错控制等研究提供基础,进而提高系统的 运行稳定性,并延长使用寿命。

目前,故障分类的相关研究主要分为基于模型的故障分类方法和基于数据驱动的故障分类方法。 其中,基于模型的故障分类方法的基本原理是通过 建立PEMFC仿真模型,计算模型输出与实际输出之 间的参数偏差,进行残差处理和决策以实现故障分 类,常见的模型包括参数辨识模型、观测器模型、等

收稿日期:2023-02-10;修回日期:2023-07-01

在线出版日期:2023-10-17

基金项目:国家自然科学基金资助项目(52007157,52077180); 四川省自然科学基金资助项目(2022NSFSC0269)

Project supported by the National Natural Science Foundation of China (52007157, 52077180) and the Natural Science Foundation of Sichuan Province(2022NSFSC0269) 价空间模型等。文献[3]建立了燃料电池的等效电路模型,提出了基于等效电路参数辨识的水淹故障分类方法;文献[4]设计了基于改进超扭曲滑模算法的非线性观测器模型,用于PEMFC供气系统的故障诊断;文献[5]提出了基于自适应模糊推理系统和电化学阻抗谱的PEMFC故障诊断方法,可以精确识别PEMFC系统中的膜干、水淹以及传质故障。然而,PEMFC是一种多物理场多相耦合的复杂系统,其模型可能存在频繁调参、适应性差等问题。同时,电堆是密封体系,内部反应机理复杂,特别是膜干、水淹等故障难以检测和排除,机理模型难以准确、快速反映PEMFC故障问题。

基于数据驱动的故障分类方法的基本思想主要 是利用人工智能算法分析历史数据并建立故障分类 器,通过分类器判断燃料电池实时数据的状态类别 并完成故障分类,这类方法主要包括神经网络[6]、模 糊逻辑^[7]、支持向量机(support vector machine, SVM)^[8]等。文献[9]对长短期记忆网络模型进行研 究,并将其应用于PEMFC水淹故障分类,相比于传 统的神经网络,该方法更擅于处理时间序列;文献 [10]在传统SVM的基础上,利用改进的人工蜂群算 法对模型中的惩罚因子和核函数进行优化,可有效 诊断PEMFC的空气供应系统故障;文献[11]提出了 基于在线序列超限学习机的蒸汽冷却型燃料电池故 障诊断方法,该方法结合主成分分析(principal component analysis, PCA)可以快速完成多数据维度的 燃料电池在线故障分类;文献[12]提出了一种基于 信息融合的有轨电车 PEMFC 故障分类方法,结果表 明该方法测试集的kappa系数可达到0.9884。基于

数据驱动的故障分类方法基于历史数据了解系统特性,无须搭建复杂的燃料电池模型,实现难度低且分 类效率较高。但传统的机器学习方法普遍需要大量 的实测数据样本,在特征学习时易受时间复杂度和 空间复杂度制约,对输入数据的要求高,收敛速度 慢,且容易陷入局部最优点。

深度置信网络(deep belief network,DBN)是一个由多层受限玻尔兹曼机(restricted Boltzmann machine,RBM)和一个反向传播神经网络(back propagation neural network,BPNN)构成的深度学习分类器,其通过非线性的神经网络结构拟合复杂函数,来提高分类和预测的准确率^[13]。DBN作为深度学习的经典模型,可以有效地解决燃料电池故障分类过程中存在的故障特征变量间具有复杂关联特性和高维度特征的问题。然而,DBN的网络结构设置对其性能有着重要的影响,其层数或节点数不合理会造成训练精度不足与特征丢失问题,因此有必要优化DBN结构以提升特征提取与分类效率。

本文提出了基于改进麻雀搜索算法(sparrow search algorithm,SSA)优化DBN(SSA-DBN)的PEMFC 故障分类方法,可以显著提高故障分类精度,大幅降 低计算复杂度并加快收敛速度。首先,利用归一化 处理对PEMFC原始数据进行量纲消除,进而利用核 主成分分析(kernel principal component analysis, KPCA)对消除量纲后的数据进行降维,通过数据预 处理可以有效地提取故障特征向量;然后,使用改进 SSA获取DBN的最优模型参数,并利用DBN对PEMFC 故障样本实现故障分类;最后,基于3000组PEMFC 故障样本数据集(包含正常状态、水淹故障、膜干故 障数据各1000组)对所提方法进行实验验证。

1 PEMFC系统及故障类型

1.1 PEMFC系统简介

本文使用的PEMFC故障实验数据及实验测试 系统来自拉夫堡大学航空与汽车工程系^[14-15],其实 验系统实物图见附录A图A1,系统原理图见图1。 采用80W的PEMFC构成测试系统,其包括燃料电 池电堆、电子负载、冷却系统、氢气和空气供应系统。 燃料电池的活化面积为100 cm²,膜厚度为25 μm。

1.2 故障类型

PEMFC系统的故障种类繁多,包括可逆故障和 不可逆故障,其中电堆水淹、质子交换膜干燥这2种 故障最为常见,因此本文针对 PEMFC的水淹和膜干 故障开展研究。由于 PEMFC 的水淹和膜干均会导 致 PEMFC性能衰退,但在 PEMFC 发生水淹故障时, 电堆输出电压首先出现剧烈波动,然后会降低至一 个相对稳定的电压值,而发生膜干故障时,电堆电压 的变化趋势与发生水淹故障时并不一致。文献[14]



Fig.1 Schematic diagram of PEMFC experimental system

对燃料电池的水淹、膜干故障状态进行实验,得到的 燃料电池输出电压变化曲线见附录A图A2,其中水 淹故障实验运行了4次,因此输出电压呈现上下波 动的状态,膜干故障实验下的初始电压在300s之前 存在跳变,然后逐渐趋于稳定。可见,良好的控制策 略可以在 PEMFC 发生水淹故障的初期减缓其性能 衰减,即水淹故障是可逆的;而膜干故障一旦发生便 无法恢复,即膜干故障是不可逆的。因此,有必要采 取适当的故障分类策略区分这2种故障类型,进而 保证 PEMFC系统的安全稳定运行。

在PEMFC的运行过程中,电堆内部主要有两部 分会产生水,分别是电化学反应生成的水、两极气体 输入电堆时经过加湿器带入的水。水的排出主要由 两极排出尾气时共同排出,包括阴极侧的脉冲排气 和反应剩余气体排气、阳极侧的脉冲排气。PEMFC 的内部水活动如图2所示。





水在质子交换膜上的传输过程存在复杂的反向 扩散、电渗透阻力机制之间的平衡。两极中的水会 穿过质子交换膜活动,因此当膜两端存在浓度差时, 水会通过膜反向扩散到另一极。当PEMFC工作时, 阴极发生电化学反应产生水,此时阴极侧的液态水 浓度高于阳极侧,水会穿过膜扩散到阳极侧以保持 两极浓度平衡。此外,在电堆反应过程中,阳极催化 层中的氢质子以水合质子的形式存在,水会随着质 子的运动被拖动,将部分阳极侧的水带到阴极侧^[16]。

水淹是一种由于电堆内部排水受阻造成水不断 增加,进而影响电化学反应进行的电堆内部故障。 在PEMFC电堆中,水的生成会随着工作电流密度的 增加而不断累积,当水蒸气压力超过饱和压力时,就 会发生凝结。液态水会堵塞扩散介质中的开放孔 隙,阻碍气体运输,特别是氧气从流道转移到阴极侧 的催化层。此外,液态水还会在电极中凝结,阻挡活 性反应点,导致电池性能变差。液态水的逐渐累积 会导致PEMFC系统发生水淹故障。

膜干是一种因电堆内液态水含量不足,导致质 子交换膜过于干燥,使电极水合作用受阻的故障状 态。当PEMFC电堆温度过高或阴极入口空气加湿 时,PEMFC阴极内部的水含量会降低,使质子交换膜 的导电性能变差,最终引起PEMFC出现膜干故障^[17]。

2 故障分类方法

针对PEMFC的水故障分类问题,本章提出基于 改进SSA-DBN的PEMFC故障分类方法。该方法利 用KPCA对原始实验数据进行降维处理以提取故障 特征向量,进而使用DBN对处理过的故障数据进行 深度学习训练,同时利用改进SSA来优化DBN中的 超参数,最后通过DBN实现对故障特征样本的故障 分类。

2.1 KPCA

KPCA 是一种具有高维映射能力的非线性降 维方法。相比于传统的数据降维方法, KPCA 方法 的计算量较少,且能较好地处理更为常见的非线性 问题,对输入的训练数据没有过多要求。KPCA将 核技术应用于 PCA 方法中,其思路为:先将数据 $\{x_i, i=1, 2, ..., n\}(n为数据量)$ 升高维度至 $\{\varphi(x_i), i=1, 2, ..., n\}(\varphi(x_i))$ 为 D×1 维高维映射样本向量 $(D \gg d), d$ 为数据特征维度),使高维空间中非线性 相关的变量间尽可能为线性相关,然后采用 PCA 方 法实现数据降维^[18],算法流程图见附录A图A3。

KPCA的基本实现步骤如下。

对高维样本数据的协方差矩阵 $C = \frac{1}{n} \sum_{i=1}^{n} \varphi(x_i) \varphi^{\mathsf{T}}(x_i)$ 进行特征分解,得到:

$$\phi(\boldsymbol{X})\phi^{\mathrm{T}}(\boldsymbol{X})\boldsymbol{\omega}_{j} = \lambda_{j}\boldsymbol{\omega}_{j}$$
(1)

式中: $\phi(X) = [\varphi(x_1), \varphi(x_2), \dots, \varphi(x_n)]; \lambda_j (j=1, 2, \dots, d)$ 为*C*的特征值, ω_j 为其对应的*D*×1维特征向量。

可用高维映射样本向量 $\varphi(x_i)$ 来线性表示特征向量 ω_i ,如式(2)所示。

$$\boldsymbol{\omega}_{j} = \sum_{i=1}^{n} \alpha_{i} \boldsymbol{\varphi}(x_{i}) = \boldsymbol{\phi}(\boldsymbol{X}) \boldsymbol{\alpha}$$
(2)

式中: α 为n×1维列向量; α_i 为 α 的第i个元素。将式 (2)代人式(1),且等号两边同时左乘 $\phi^{T}(X)$,可得:

 $\phi^{\mathrm{T}}(X)\phi(X)\phi^{\mathrm{T}}(X)\phi(X)\alpha = \lambda_{i}\phi^{\mathrm{T}}(X)\phi(X)\alpha \quad (3)$

式(3)的求解只与高维映射向量 $\phi(X)$ 的内积矩 阵有关,可定义如下核函数:

$$\boldsymbol{K} = \boldsymbol{\phi}^{\mathrm{T}}(\boldsymbol{X})\boldsymbol{\phi}(\boldsymbol{X}) = [k_{i,i}]_{n \times n}$$
(4)

式中:K为 $n \times n$ 阶核函数矩阵; $k_{i,j} = \boldsymbol{\varphi}^{\mathsf{T}}(x_i)\boldsymbol{\varphi}(x_j)$ 。将 式(4)代人式(3)并简化可得:

$$K^{2}\alpha = \lambda_{i}K\alpha \implies K\alpha = \lambda_{i}\alpha \qquad (5)$$

由式(5)可求解得到 $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$,且对于 任意样本x,将高维映射 $\varphi(x)$ 在特征向量 ω_j 方向上 进行投影,就可得到x非线性降维后的 x^{new} ,见式(6)。

$$x^{\text{new}} = \boldsymbol{\omega}_{j}^{\text{T}} \boldsymbol{\varphi}(x) = \left(\sum_{i=1}^{n} \alpha_{i} \boldsymbol{\varphi}(x_{i})\right)^{\text{T}} \boldsymbol{\varphi}(x)$$
(6)

2.2 DBN

DBN 是由 RBM、BPNN 构成的深度学习分类器, 其本质为具有多个隐含层的多层神经网络。RBM 是 构成 DBN 的基本单元,其结构图见附录 A 图 A4。 RBM 将神经元"限制"在2层网络中,二者为可视层、 隐含层,分别用于训练输入数据、特征提取。若 RBM 系统有 *u* 个可视层单元(用向量 *x* 表示)、*v* 个隐含层单 元(用向量 *y* 表示),则其能量*E*(*x*,*y*|*θ*)可定义为:

$$E(\mathbf{x}, \mathbf{y} | \theta) = -\sum_{i=1}^{u} p_i x_i - \sum_{j=1}^{v} q_j y_j - \sum_{i=1}^{u} \sum_{j=1}^{v} x_i w_{ij} y_i \quad (7)$$

式中: θ ={ w_{ij} , p_i , q_j }为RBM结构中的系统参数, w_{ij} 为 隐含层j和可视层i之间的连接权重, p_i 、 q_j 分别为可 视层i、隐含层j神经元的偏置。

DBN结构见附录A图A5,其实现思路是:利用多 层RBM组成网络结构并提取所处理对象的特征,进 而利用分类器进行分类。DBN训练过程包括预训 练、微调整。先利用无监督贪婪逐层训练的思想对每 层RBM进行预训练,进而获取连接权重,将所处理数 据输入第1层RBM的可视层,通过迭代训练得到连 接权重、偏置,并输出数据到隐含层,这一层的输出 数据成为下一层RBM的输入,逐层训练直至结束。 但预训练所获得的DBN结构并非最优状态,因此需 进一步处理,进入微调整阶段。在最后一层RBM后 面设置 BPNN,将最后一个 RBM 的输出向量作为 BPNN的输入向量,进行有监督地训练分类器,完成 对DBN参数的微调整,以提高模型的分类精度。

2.3 改进SSA

SSA 是一种受麻雀生存习惯和觅食特性启发而 提出的元启发式算法,相比于传统优化算法,其结构 简单,易于实现,且控制参数较少,局部搜索能力较 强。但传统的SSA 在迭代后期容易出现局部最优停 滞的现象,这源于麻雀个体的快速同化,因此本文引 入柯西-高斯变异策略^[19]改进SSA中的反捕食行为。 利用SSA-DBN主要对DBN中的隐含层数量及各隐 含层节点数、学习率等网络参数进行寻优。算法流 程图见附录A图A6。

SSA的数学模型如下^[20]:种群中h只麻雀的所 有个体可表示为 $X = [x_1, x_2, \dots, x_h]^T$,个体所对应的 适应度函数 $F = [f(x_1), f(x_2), \dots, f(x_h)]^T$ 。在SSA中, 具有较好适应度的发现者在搜索过程中会优先获取 食物,发现者可获得比加入者更大的觅食搜索范围。 在每次迭代过程中,发现者的位置更新公式为:

$$x_{i,j}^{(t+1)} = \begin{cases} x_{i,j}^{(t)} \exp\left[-i/(\alpha I_{\text{iter, max}})\right] & R_2 < S_{\text{safe}} \\ x_{i,j}^{(t)} + Q & R_2 \ge S_{\text{safe}} \end{cases}$$
(8)

式中: $x_{i,j}^{(i)}(i=1,2,...,h;j=1,2,...,d)$ 为第t次迭代时 第i只麻雀的第j维位置信息; $I_{iter,max}$ 为最大迭代次 数; α 为0~1内的随机数;Q为服从正态分布的随机 数; $R_2(R_2 \in [0,1]), S_{safe}(S_{safe} \in [0.5,1])$ 分别为预警值、 安全值。

跟随者的位置更新公式为:

$$x_{i,j}^{(t+1)} = \begin{cases} Q \exp\left[\left(x_{\text{worst}}^{(t)} - x_{i,j}^{(t)}\right)/i^{2}\right] & i > n / 2 \\ x_{\text{P}}^{(t+1)} + \left|x_{i,j}^{(t)} - x_{\text{P}}^{(t+1)}\right| \mathbf{A}^{+} \mathbf{L} & i \le n / 2 \end{cases}$$
(9)

式中: $x_{P}^{(t+1)}$ 为第t+1次迭代时发现者的最优位置; $x_{worst}^{(t)}$ 为第t次迭代时全局的最差位置; $A^{+}=A^{T}(AA^{T})^{-1}$, A为一个维度为d且元素仅为1或-1的行向量;L为 一个维度为d且元素全为1的行向量。

当麻雀意识到危险时,种群会做出反捕食行为, 此时引入柯西-高斯变异策略,选择当前适应度最好 的个体进行变异,然后比较其变异前、后的位置,选 择较优的位置进行下一次迭代,其数学表达式为:

$$u_{\text{best}}^{(t)} = x_{\text{best}}^{(t)} \left(1 + \lambda_1 C_{\text{Cauchy}}(0, \sigma^2) + \lambda_2 G_{\text{Gauss}}(0, \sigma^2) \right) \quad (10)$$

$$\sigma = \begin{cases} 1 & f_{\text{best}} < f_i \\ \exp\left[\left(f_{\text{best}} - f_i\right) / |f_{\text{best}}|\right] & f_{\text{best}} \ge f_i \end{cases}$$
(11)

式中: $x_{\text{best}}^{(i)}$ 为第t次迭代时适应度最好个体所在的位置; $u_{\text{best}}^{(i)}$ 为第t次迭代时最优个体变异后的位置; σ 为柯西-高斯变异策略的标准差; $C_{\text{Cauchy}}(0,\sigma^2)$ 为满足柯西分布的随机变量; $G_{\text{Causs}}(0,\sigma^2)$ 为满足高斯分布的随机变量; λ_1,λ_2 为随迭代次数自适应调整的动态参数, λ_1 逐渐减小, λ_2 逐渐增大,使算法跳出停滞; f_{best} 为当前全局最优个体的适应度值; f_i 为当前个体i的适应度值。则将警戒者的位置更新为:

$$x_{i,j}^{(t+1)} = \begin{cases} u_{\text{best}}^{(t)} + \beta \left| x_{i,j}^{(t)} - u_{\text{best}}^{(t)} \right| & f_i \neq f_{\text{best}} \\ x_{i,j}^{(t)} + K \left[\frac{\left| x_{i,j}^{(t)} - x_{\text{worst}}^{(t)} \right|}{(f_i - f_{\text{worst}}) + \varepsilon} \right] f_i = f_{\text{best}} \end{cases}$$
(12)

式中:β为步长控制参数;K为一个随机数,且有

 $K \in [-1, 1]; \varepsilon$ 为非零常数,防止分母为0; f_{worst} 为当前 全局最差个体的适应度值。

SSA 在大多数测试函数的收敛精度方面优于常见的粒子群优化算法、灰狼优化算法、引力搜索算法,且具有更好的稳定性和更快的收敛速度。此外, SSA 相比于其他3种优化算法具有更好的全局搜索能力,极少陷入局部最优解。PEMFC的水故障诊断需要使诊断准确率达到最高,且需要更快的诊断速度,因此 SSA 更适用于对 DBN 参数进行优化,其在较短的时间就可完成优化并得到最优解。

本文利用 SSA 进行参数优化时,以 DBN 结构参数中的隐含层数量和学习率为控制变量,以 DBN 训练时的均方误差 *F*_{MSE} 为适应度函数,如式(13)所示。

$$F_{\rm MSE} = \frac{1}{m} \sum_{i=1}^{m} (y_i - \hat{y}_i)$$
(13)

式中:m为训练数据数量; y_i 为第i个训练数据的真实输出; \hat{y}_i 为模型对第i个训练数据的预测值。

经过 DBN 训练运算可以得到最优隐含层数量 为4层(RBM₁— RBM₄),最优学习率为0.01。DBN 的输入节点数量取决于训练数据的特征维度,输出 节点数量为3个,代表PEMFC的3种健康状态,各隐 含层节点数量设置为[100,100,50,20],所采用的 DBN结构如图3所示。



2.4 故障分类方法

基于改进 SSA-DBN 的 PEMFC 水故障分类流程 图见附录 A 图 A7,具体步骤如下。

1)为保证本文所提方法的可靠性,使用PEMFC 的实际运行数据对算法进行分类验证。数据类别 包括正常状态、水淹故障以及膜干故障3种,共有 3000组原始数据,其中正常状态、水淹故障、膜干故 障各有1000组数据。

2)原始数据的不同特征参数间存在较大的量纲

差异,为了减少这部分因素对实验结果造成的负面 影响,需对原始数据进行归一化处理,以将数据投影 到0~1内。

3)PEMFC系统的特征参数维度较大,直接计算 不但复杂度高而且分类精度较差,需对数据进行故 障主特征提取。因此使用KPCA对归一化后的数据 进行维度缩减,以降低计算复杂度。

4)将数据样本划分为训练数据样本和测试数据 样本。在保证训练集和测试集数据分布一致性的前 提下,本文选取的训练集数据占比为3:4。

5)初始化DBN模型参数,采用SSA计算种群适 应度并更新最优个体,进行觅食与反捕食行为,更新 个体位置,满足终止准则时输出最优模型参数,并将 训练样本代入SSA-DBN模型中,得到已完成训练的 分类模型。

6) 将测试样本输入已完成训练的 SSA-DBN 模型中,输出故障分类结果。

3 分类结果分析

3.1 原始数据提取

本文所采用的原始数据为进行 PEMFC 系统故 障实验时采集的实测数据。考虑机器学习的数据均 衡,本文对每种状态各采样1000组数据,总样本数 量为3000组。利用留出法进行数据集划分,训练集 数据一般占总数据量的2/3~4/5。在保证训练集和 测试集数据分布一致性的前提下,本文选取的训练 集数据占比为3/4,实验结果表明该划分比例可以得 到相对良好的训练效果和测试精度。每种健康状态 的样本总数见附录A表A1。

3.2 故障特征提取

PEMFC的参数取值见附录A表A2,可监测数据 共有14个,则每组原始数据为1个14维的特征向 量。过高的数据维度不仅会延长算法的运算时间, 还会影响最终的分类准确率。因此,为了提高故障 分类准确率及运算效率,选用KPCA对归一化后的 数据进行降维处理。首先,利用核函数将数据中的 低维且线性不可分特征映射到更高维的空间中,在 高维空间中使其线性可分;然后,使用PCA进行后 续降维处理。经过降维处理的数据各维度间的相关 度较小,这样可大幅简化模型的复杂度。

使用 KPCA 进行数据降维前需对原始数据进行 特征贡献率计算,各样本的特征贡献率由高到低排 列,当累计贡献率达到95%时,认为累计的数据可 以表征原始数据中的大部分信息。利用帕累托图作 图,样本特征贡献率如图4所示。由图可知,前4个 贡献率最高的主成分特征的累计贡献率达到 99.49%,则原始数据的14维特征可用4维特征向量 表示,从而可舍去其余10维贡献率较低的特征。因 此,将原始数据降维至4维的特征空间,降维后的部分样本数据见附录A表A3,3种状态的数据相互分离,更易于区分。



图4 样本特征贡献率

Fig.4 Sample feature contribution rate

3.3 分类结果

将4维故障特征数据输入SSA-DBN分类模型中,并设置4个隐含层。使用训练样本进行模型训练,得到已完成训练的神经网络,再将测试集输入训练分类器中得到测试结果,并与真实值进行对比。 分类准确率为98.67%,DBN分类时间为0.89 s。测试集的分类结果如图5所示。图中:N表示正常状态;F₁表示水淹故障状态;F₂表示膜干故障状态。



Fig.5 Classification results of test set

测试集的混淆矩阵如表1所示。由表可知,仅 有2组属于膜干故障状态的数据被错误地分类为水 淹故障状态,这是由于水淹故障和膜干故障均会导 致PEMFC电堆电压下降、输出功率降低,所表现出 的故障特征较为类似,因此发生误判。

表1 测试集的混淆矩阵

Table 1 Confusion matrix of test set

金际快太米 则	预测状态类别的样本数量		
头阶机芯矢剂	Ν	F ₁	F_2
Ν	39	0	0
F ₁	0	55	0
F_2	0	2	54

3.4 方法对比

为了验证本文所提改进SSA-DBN方法的性能、 可行性,分别采用改进SSA-DBN、SSA-DBN、DBN、概 率神经网络(probabilistic neural network, PNN)、 SVM方法进行故障分类,并对比故障分类结果。为了 对故障分类方法做出公平合理的对比,使用KPCA 降维后的数据作为各方法的训练样本、测试样本。

各方法的参数设置如下:①DBN方法,利用SSA 进行参数寻优后,设隐含层数量为4层,batch规模为 16,学习速率为0.01,最大迭代次数为32次;②SVM 方法,惩罚系数为362.04,引入径向基函数作为核函 数,自带的gamma参数为0.125;③PNN方法,算法中 的超参数SPREAD值为1.1。

不同方法的分类精度、运算时间分别如表2和 表3所示。由表可知:改进SSA-DBN方法具有最高 的分类准确率,且运算时间比SVM方法大幅减少; SSA-DBN方法的分类准确率为97.33%,说明利用改 进SSA进行参数优化可以显著提高分类准确率;各 方法均有较高的分类准确率,说明利用KPCA降维 可以准确保留贡献度较高的4维特征向量,利用低 维数据集进行故障分类可大幅减少计算机的运算 量,提高分类准确率。

表2 不同方法的分类精度

Table 2 Classification accuracy of different methods

实际状态	分类准确率 / %				
类别	改进SSA-DBN	SSA-DBN	DBN	SVM	PNN
Ν	100	92.86	100	100	99.90
F_1	100	100	100	100	100
F_2	97.14	100	84.10	86.21	85.95
总体准确率 / %	98.67	97.33	95.33	94.67	93.48

表 3	不同方法的运算时间
100	

Table 3 Calculation time of different methods

分类方法	运算时间 / s	分类方法	运算时间 / s
改进SSA-DBN	0.89	SVM	16.24
SSA-DBN	0.81	PNN	1.24
DBN	0.76	KPCA	2.01

综上,改进SSA-DBN分类方法具有以下优势:

1)训练速度快,完成故障分类所需时间少于 SVM、PNN方法所需时间;

2)利用改进SSA进行模型优化可获取最优网络 参数,有利于提高分类准确率;

3)适用于处理高维、小样本故障数据,对训练样 本数量没有过高的要求,适当增/减训练样本对分 类结果没有影响。

4 结论

本文主要针对PEMFC系统进行了故障分类研究,提出了一种基于改进SSA-DBN的PEMFC水故障 智能分类方法,所得结论如下。

1)利用 KPCA 将原始数据从 14 维特征降到 4 维 特征空间,有效地解决了燃料电池故障特征变量间 存在复杂关联特性和高维度特征的问题,显著缩短 了故障分类的运算时间。

2)利用柯西-高斯变异策略改进SSA有助于算

法跳出局部最优解;采用改进SSA-DBN结构和模型 参数,可以提高特征提取能力和训练精度,有效避免 了网络参数优化陷入局部最优解,进而保证分类方 法的有效性。

3)本文所提方法可有效识别 PEMFC 电堆正常状态、水淹故障和膜干故障这3种健康状态,测试集的分类准确率为98.67%,分类总时长为2.9 s。相比于 SVM、PNN、DBN 方法,所提方法的测试集分类精度分别提高了4%、5.19%、3.34%,运算时间相比 SVM、PNN方法分别节省了15.35、0.35 s。

总体而言,本文所提方法不仅分类精度优于传统机器学习方法,还拥有更短的运算时间,能在提高 故障分类精度的同时显著降低计算复杂度,加快收 敛速度,适用于PEMFC的故障分类相关问题。后期 可将分类方法的训练集数据进行实时更新,进而提 高故障分类准确率;此外,还可将该方法进行多标签 化以解决多堆PEMFC故障分类相关问题。

附录见本刊网络版(http://www.epae.cn)。

参考文献:

 [1]陈维荣,刘嘉蔚,李奇,等.质子交换膜燃料电池故障诊断方法 综述及展望[J].中国电机工程学报,2017,37(16):4712-4721, 4896.

CHEN Weirong, LIU Jiawei, LI Qi, et al. Review and prospect of fault diagnosis methods for proton exchange membrane fuel cell[J]. Proceedings of the CSEE, 2017, 37(16): 4712-4721,4896.

- [2]高锋阳,张浩然,王文祥,等.氢燃料电池有轨电车混合储能系统的节能运行优化[J].电工技术学报,2022,37(3):686-696.
 GAO Fengyang,ZHANG Haoran,WANG Wenxiang,et al. Energy saving operation optimization of hybrid energy storage system for hydrogen fuel cell tram[J]. Transactions of China Electrotechnical Society,2022,37(3):686-696.
- [3] PARK J Y, LIM I S, CHOI E J, et al. Fault diagnosis of thermal management system in a polymer electrolyte membrane fuel cell[J]. Energy, 2021, 214:119062.
- [4] LIU J X, LUO W S, YANG X Z, et al. Robust model-based fault diagnosis for PEM fuel cell air-feed system[J]. IEEE Transactions on Industrial Electronics, 2016, 63(5):3261-3270.
- [5] AO Y J, LAGHROUCHE S, DEPERNET D. Diagnosis of proton exchange membrane fuel cell system based on adaptive neural fuzzy inference system and electrochemical impedance spectroscopy[J]. Energy Conversion and Management, 2022, 256:115391.
- [6] SHAO M, ZHU X J, CAO H F, et al. An artificial neural network ensemble method for fault diagnosis of proton exchange membrane fuel cell system [J]. Energy, 2014, 67: 268-275.
- [7] MAMMAR K, SAADAOUI F, LARIBI S. Design of a PEM fuel cell model for flooding and drying diagnosis using fuzzy logic clustering[J]. Renewable Energy Focus, 2019, 30:123-130.
- [8] 范贤浩,刘捷丰,张镱议,等.融合频域介电谱及支持向量机的 变压器油浸纸绝缘老化状态评估[J].电工技术学报,2021,36 (10):2161-2168.

FAN Xianhao, LIU Jiefeng, ZHANG Yiyi, et al. Aging evaluation of transformer oil-immersed insulation combining frequency domain spectroscopy and support vector machine [J]. Transactions of China Electrotechnical Society, 2021, 36(10):21612168.

24

- [9] GU X, HOU Z J, CAI J. Data-based flooding fault diagnosis of proton exchange membrane fuel cell systems using LSTM networks[J]. Energy and AI, 2021, 4:100056.
- [10] 田颖,韩峰,李贺,等.聚合物电解质膜燃料电池空气供应系统 故障诊断[J].北京交通大学学报,2020,44(4):116-123.
 TIAN Ying,HAN Feng,LI He, et al. Fault diagnosis of polymer electrolyte membrane fuel cell air supply system[J].
 Journal of Beijing Jiaotong University,2020,44(4):116-123.
- [11] 刘嘉蔚,李奇,陈维荣,等. 基于在线序列超限学习机和主成分分析的蒸汽冷却型燃料电池系统快速故障诊断方法[J]. 电工技术学报,2019,34(18):3949-3960.
 LIU Jiawei,LI Qi, CHEN Weirong, et al. Fast fault diagnosis method of evaporatively cooled fuel cell system based on online sequential extreme learning machine and principal component analysis[J]. Transactions of China Electrotechnical Society,2019,34(18):3949-3960.
- [12] ZHANG X X, GUO X Q. Fault diagnosis of proton exchange membrane fuel cell system of tram based on information fusion and deep learning[J]. International Journal of Hydrogen Energy, 2021, 46(60): 30828-30840.
- [13] 李俊卿,陈雅婷,李斯璇. 基于深度置信网络的同步发电机励 磁绕组匝间短路故障预警[J]. 电力自动化设备,2021,41(2): 153-158.
 LI Junqing, CHEN Yating, LI Sixuan. Early warning of inter-

turn short circuit fault in excitation windings of synchronous generator based on deep belief network [J]. Electric Power Automation Equipment, 2021, 41(2):153-158.

- [14] MAO L, JACKSON L. Effect of sensor set size on polymer electrolyte membrane fuel cell fault diagnosis[J]. Sensors, 2018,18(9):2777.
- [15] MAO L, DAVIES B, JACKSON L. Application of the sensor selection approach in polymer electrolyte membrane fuel cell prognostics and health management[J]. Energies, 2017, 10(10): 1511.
- [16] 彭跃进,张国瑞,王勇,等. 阴、阳极加湿对质子交换膜燃料电

池性能影响的差异性[J]. 电工技术学报,2017,32(4):196-203. PENG Yuejin, ZHANG Guorui, WANG Yong, et al. Differences on the influences of humidity of cathod and anode on the performance of proton exchange membrane fuel cell[J]. Transactions of China Electrotechnical Society,2017,32(4):196-203.

- [17] 刘嘉蔚,李奇,陈维荣,等. 基于概率神经网络和线性判别分析的PEMFC水管理故障诊断方法研究[J]. 中国电机工程学报,2019,39(12):3614-3622. LIU Jiawei,LI Qi,CHEN Weirong, et al. Research on PEMFC water management fault diagnosis method based on probabilistic neural network and linear discriminant analysis[J]. Procee-
- dings of the CSEE,2019,39(12):3614-3622.
 [18] 杨启帆,段大卫,李楠,等. 基于主成分分析的串联电池组故障 诊断实用方法[J]. 电力自动化设备,2022,42(12):210-216.
 YANG Qifan, DUAN Dawei, LI Nan, et al. A practical fault diagnosis method for series-connected battery packs based on principle component analysis [J]. Electric Power Automation Equipment,2022,42(12):210-216.
- [19] WANG W C, XU L, CHAU K W, et al. Yin-Yang firefly algorithm based on dimensionally Cauchy mutation [J]. Expert Systems With Applications, 2020, 150:113216.
- [20] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. Systems Science and Control Engineering, 2020,8(1):22-34.

作者简介:

刘昕宇(1997—), 男, 硕士研究生, 主要研究方向为燃料 电池故障诊断(E-mail: 15520773323@163.com);

韩 莹(1990—),男,副教授,博士,通信作者,主要研究 方向为综合能源系统运行与控制、轨道交通新能源技术、混

合动力系统能量管理等(**E-mail**:hanying@swjtu.edu.cn);

陈维荣(1965—),男,教授,博士研究生导师,博士,主要 研究方向为电力系统及其自动化、新能源并网发电技术、燃 料电池技术与应用等(E-mail:wrchen@swjtu.edu.cn)。

(编辑 陆丹)

Intelligent classification method of water faults for proton exchange membrane fuel cell based on improved SSA-DBN

LIU Xinyu, HAN Ying, CHEN Weirong, LI Qi, YANG Zhehao

(School of Electrical Engineering, Southwest Jiaotong University, Chengdu 611756, China)

Abstract: In order to realize efficient and rapid classification of water faults in proton exchange membrane fuel cell(PEMFC) system, a fault classification method of PEMFC based on improved sparrow search algorithm (SSA) optimizing deep confidence network (DBN) is proposed. The normalization process is adopted to eliminate the impact of different dimensions among fault data parameters, and the kernel principal component analysis is used to extract fault features from the data, which effectively reduces the dimensions of the original data and the calculation complexity and avoids the interference of low-contribution data on fault classification. The Cauchy-Gauss variation strategy is introduced to improve SSA, the parameters of DBN are optimized by SSA to determine the network structure, and the optimized DBN is used to quickly classify the water faults of PEMFC. Three thousand sets of PEMFC water fault data are tested. The results show that the proposed method can quickly and accurately identify three health states of PEMFC: normal state, membrane dry fault and flooding fault. The overall classification accuracy is 98.67% and the calculation time is 0.89 s. Compared with the support vector machine and the probabilistic neural network method, the fault classification accuracy of the proposed method is increased by 4% and 3.34% respectively, and the calculation time is reduced by 15.35 s and 0.35 s respectively.

Key words: proton exchange membrane fuel cell; fault classification; deep confidence network; sparrow search algorithm; kernel principal component analysis; Cauchy-Gaussian variation strategy

附录 A



图 A1 PEMFC 系统实物图 Fig.A1 Physical diagram of PEMFC system



Fig.A2 Voltage change curves of single cell under fault conditions



Fig.A6 Optimization process of SSA



图 A7 故障分类流程

Fig.A7 Fault classification process

表 A1 各健康状态的样本总数

Table A1 Total number of samples for each health status

数据集	正常状态	水淹故障	膜干故障
训练样本	750	750	750
测试样本	250	250	250

表 A2 KPCA 降维后部分训练样本和测试样本

Table A2

Some training samples and test samples after KPCA dimension reduction

健康	训练样本			
状态	特征1	特征 2	特征 3	特征 4
正常	0.048	-0.232	0.119	0.189
	0.048	-0.232	0.119	0.189
	0.048	-0.232	0.118	0.188
水淹 ⁻ 故障 -	0.079	-0.632	-0.615	-0.026
	0.079	-0.632	-0.615	-0.026
	0.079	-0.631	-0.618	-0.021
膜干 - 故障 -	0.055	-0.291	0.264	0.847
	0.055	-0.291	0.264	0.847
	0.055	-0.292	0.264	0.849
健康 状态	测试样本			
正常 •	0.049	-0.235	0.121	0.194
	0.049	-0.236	0.122	0.195
水淹 故障	0.08	-0.636	-0.592	-0.058
	0.08	-0.633	-0.601	-0.045
膜干 故障	0.054	-0.291	0.260	0.836
	0.054	-0.291	0.258	0.84

Table A5	Tarameters and variables of TENTC System		
序号	变量参数	单位	
1	电堆电压	V	
2	电堆电流	А	
3	电堆功率	W	
4	加热器温度	°C	
5	加热器功率	W	
6	空气入口压力	bar	
7	氢气入口压力	bar	
8	空气出口压力	bar	
9	氢气出口压力	bar	
10	空气入口流速	SPLM	
11	氢气入口流速	SPLM	
12	空气入口温度	°C	
13	氢气入口温度	°C	
14	电堆温度	°C	

表 A3 PEMFC 系统的各参数变量 Table A3 Parameters and variables of PEMFC system