



基于KPCA-MTCN的锂离子电池故障诊断方法

谭启鹏 李勇琦 陈满 张领先 彭鹏 万民惠

Lithium-ion battery fault diagnosis method based on KPCA-MTCN

TAN Qipeng, LI Yongqi, CHEN Man, ZHANG Lingxian, PENG Peng, WAN Minhui

引用本文:

谭启鹏, 李勇琦, 陈满, 张领先, 彭鹏, 万民惠. 基于KPCA-MTCN的锂离子电池故障诊断方法[J]. 北科大: 工程科学学报, 2024, 46(12): 2297–2306. doi: 10.13374/j.issn2095–9389.2024.01.30.001

TAN Qipeng, LI Yongqi, CHEN Man, ZHANG Lingxian, PENG Peng, WAN Minhui. Lithium-ion battery fault diagnosis method based on KPCA-MTCN[J]. *Chinese Journal of Engineering*, 2024, 46(12): 2297–2306. doi: 10.13374/j.issn2095–9389.2024.01.30.001

在线阅读 View online: <https://doi.org/10.13374/j.issn2095–9389.2024.01.30.001>

您可能感兴趣的其他文章

Articles you may be interested in

基于WOA-VMD与PSO-SVM的锂离子电池内短路故障诊断方法

Research on internal short-circuit fault diagnosis methods for lithium-ion batteries based on WOA-VMD and PSO-SVM
工程科学学报. 2023, 45(12): 2162 <https://doi.org/10.13374/j.issn2095–9389.2022.10.04.004>

基于剩余充电电量的锂离子电池模组内短路在线定量诊断算法

Online quantitative diagnosis algorithm for the internal short circuit of a lithium-ion battery module based on the remaining charge capacity
工程科学学报. 2023, 45(1): 158 <https://doi.org/10.13374/j.issn2095–9389.2021.08.02.002>

基于CEEMDANLSTM组合的锂离子电池寿命预测方法

Combined prediction method of lithium-ion battery life based on CEEMDANLSTM
工程科学学报. 2021, 43(7): 985 <https://doi.org/10.13374/j.issn2095–9389.2020.06.30.007>

基于NARX动态神经网络的锂离子电池剩余寿命间接预测

An indirect remaining useful life prediction of lithium-ion batteries based on a NARX dynamic neural network
工程科学学报. 2022, 44(3): 380 <https://doi.org/10.13374/j.issn2095–9389.2020.10.22.005>

基于ELM和MCCKF的锂离子电池SOC估计

ELM- and MCCKF-based state of charge estimation for lithium-ion batteries
工程科学学报. 2023, 45(6): 995 <https://doi.org/10.13374/j.issn2095–9389.2022.05.10.003>

高功率锂离子电池研究进展

Progress of high-power lithium-ion batteries
工程科学学报. 2022, 44(4): 612 <https://doi.org/10.13374/j.issn2095–9389.2021.08.16.004>

基于 KPCA-MTCN 的锂离子电池故障诊断方法

谭启鹏¹⁾, 李勇琦^{1)✉}, 陈 满¹⁾, 张领先²⁾, 彭 鹏¹⁾, 万民惠¹⁾

1) 南方电网调峰调频发电有限公司储能科研院, 广州 511400 2) 北京四方继保工程技术有限公司, 北京 100085

✉通信作者, E-mail: 13926159055@139.com

摘 要 为了维护储能系统的安全稳定运行, 本文针对锂离子电池故障诊断这一重要问题, 提出了一种结合核主成分分析 (KPCA) 和多尺度时序卷积网络 (MTCN) 的故障诊断方法. 该方法首先归一化故障数据, 然后利用 KPCA 降低数据维度并校验数据的可靠性; 其次, 根据故障类型对数据进行标注, 并按比例划分训练集和测试集; 接着在训练阶段使用霜冰算法 (RIME) 优化 MTCN 模型的超参数以提高模型的精度; 最后基于故障数据验证 MTCN 的分类精度, 并与长短期记忆神经网络 (LSTM)、卷积神经网络 (CNN)、Xception 和 ResNet50 进行比较. 在 KPCA 验证充电故障和未知故障数据的可靠性后, 基于两组数据测试的结果表明, 相比于 CNN 和 LSTM, MTCN 对于两组故障的分类准确率均为最高, 分别达到了 99.265% 和 99.688%, 与 Xception 和 ResNet50 较为接近. 同时针对训练数据量的测试结果表明, 在训练数据量较少时 MTCN 仍能保持较好的诊断效果, 说明 MTCN 的并行结构可以从不同的尺度提取更多的时序信息.

关键词 锂离子电池; 故障诊断; 核主成分分析; 多尺度时序卷积网络; 霜冰算法

分类号 TM911.2

Lithium-ion battery fault diagnosis method based on KPCA-MTCN

TAN Qipeng¹⁾, LI Yongqi^{1)✉}, CHEN Man¹⁾, ZHANG Lingxian²⁾, PENG Peng¹⁾, WAN Minhui¹⁾

1) CSG PGCEnergy Storage Research Institute, Guangzhou 511400, China

2) Beijing Sifang Jibao Engineering Technology Company Limited, Beijing 100085, China

✉Corresponding author, E-mail: 13926159055@139.com

ABSTRACT The paper proposes a method based on kernel principal component analysis (KPCA) and multi-scale temporal convolution network (MTCN) for identifying faults in lithium-ion batteries, which is crucial for ensuring the safe and stable operation of energy-storage systems. Lithium-ion batteries are the primary component of energy storage units. The method involves the following steps: First, fault data are normalized, and KPCA is used for dimensionality reduction and single fault detection to reduce computational complexity and improve data reliability. According to the different types of overcharge faults and unknown faults, KPCA is used to reduce the data from the original dimension to 2 or 4 dimensions. The KPCA model is trained using the normal data corresponding to the two groups of fault data, and the fault data are inputted as the test data. The results show that the SPE statistic and the T2 statistic considerably exceed the control limit, verifying the reliability of the data. Then, the data are labeled according to the fault type: the overcharge data are labeled as D0 (normal) and D1 (fault), and the unknown fault data as F0 (normal) and F1 (fault). The labeled data are divided into training and test sets according to a specific proportion. Afterward, the MTCN model is trained with the training dataset, and its hyperparameters are optimized with the frost algorithm to improve model accuracy. Finally, the trained MTCN model is used to classify the test dataset. The method is validated on two groups of data: overcharge fault data and unknown fault data. The results show that the frost algorithm can optimize the hyperparameters after about 20 iterations. Compared with LSTM and CNN, which are also optimized by the frost algorithm, MTCN achieves a higher classification accuracy, reaching 99.265% and 99.688%, on the overcharge

收稿日期: 2024-01-30

基金项目: 国家重点研发计划资助项目(2021YFB2402004); 中国南方电网有限责任公司创新项目(STKJXM20210091)

fault dataset and unknown fault dataset, respectively, while maintaining comparable performance to Xception and ResNet50. Additionally, to verify the influence of the training data amount, the training and test sets are divided according to different proportions, and the three algorithms are tested. KPCA verifies the reliability of charging fault and unknown fault data, and the results show that MTCN has the highest classification accuracy, especially on the overcharge fault dataset. Owing to the low dimensionality of the original data set, LSTM and CNN exhibit poor classification performance. In contrast, MTCN can extract more temporal information, achieving high classification accuracy. These results demonstrate the effectiveness and superiority of the method in fault diagnosis of lithium-ion batteries.

KEY WORDS Lithium-ion battery; fault diagnosis; kernel principal component analysis; multi-scale sequential convolutional network; frost and ice algorithm

锂离子电池具有寿命长、能量密度高和成本低等优点,因此在储能领域有广泛的应用前景^[1].然而,锂离子电池的安全性仍然是一个亟待解决的难题,由于电池的充放电过程涉及电化学反应,可能会出现过充、过放、短路以及过热等异常情况^[2],导致电池性能下降,甚至发生热失控等事故^[3].这些故障不仅会危及电池本身,还会影响储能和电网的安全^[4].因此,对锂离子电池的状态实时监测,及时诊断并处理故障,是保障储能系统安全的重要措施之一^[5].

通常,按照危害程度可以将锂离子电池故障分为渐变性故障和突发性故障,渐变性故障是指电池的老化程度超出阈值,突发性故障是指电池突然失效^[6].对渐变性故障的诊断主要通过剩余使用寿命预测实现^[7],而对突发性故障的诊断一般有两种方法:基于模型驱动和基于数据驱动的方法^[8].

基于模型驱动是指构建故障模型,与系统模型进行比较获得残差信号,并使用状态评估和参数辨识等方法对残差信号进行评估. Feng 等^[9]提出将电化学热耦合模型应用于内短路故障诊断,并分析出荷电(State of charge, SOC)状态和发热功率是有效的诊断指标. Sidh 等^[10]使用阻抗谱和等效电路构建非线性电池特征故障模型,并利用卡尔曼滤波器来估计每个模型的端电压并计算残差,实现锂离子电池过充和过放故障的诊断. Wei 等^[11]设计多个等效电路模型以拟合不同的故障,并使用强跟踪扩展卡尔曼滤波估计模型电压,与测量值比较生成残差信号. Yang 等^[12]使用分数阶模型和一阶电阻-电容电路(Resistor-capacitance circuit, RC)模型预测电压,并计算电压的均方根误差,输入随机森林进行故障分类. 基于模型驱动虽然可以对故障进行定性和定量分析,但其受限于建模精度和参数不确定性.

基于数据驱动的方法无需考虑电池内部的电化学机理,具有较高的兼容度和诊断精度. Yao 等^[13]

用离散余弦滤波去噪,修正协方差矩阵作为状态指标,用网格搜索优化的支持向量机分类故障,但是预处理耗时较长,且方法的适应性较差. 贾等^[14]开发了基于多维特征和混合聚类算法的健康状态综合评价体系,虽然该类方法的预测精度较高且适应性较好,但数据样本量大收敛时间长. Li 等^[15]提出了一种结合长短时记忆神经网络和等效电路模型的电池故障诊断方法,虽然从机理层面增强了故障诊断的可解释性,但该方法较为复杂. Wang 等^[16]对径向基函数网络进行改进,能有效诊断锂离子电池组的故障,但该方法无法对未知的故障类型进行诊断.

为了校验故障数据的可靠性,并提高数据特征的提取能力,本文提出一种结合核主成分分析(Kernel principle component analysis, KPCA)和多尺度时序卷积网络(Multi-scale temporal convolutional network, MTCN)的锂离子电池故障诊断方法. 首先使用 KPCA 对数据进行降维的同时检测是否存在故障,然后使用霜冰算法优化 MTCN 网络的超参数. 基于两组数据验证了本文所提方法的诊断精度,其中一组数据是电池组发生了过充故障,另一组数据是电池组发生了未知的故障.

1 实验数据

本文的 2 组故障数据来源于不同的实验平台,因此分别展开介绍.

1.1 过充故障数据

过充实验的对象为方形锂离子电池,电池的正极柱材料为 1060 H14 铝合金,负极柱材料为 1060 H112 铝合金和 Cu T2 铜合金,在标准放电工况下测量的基本参数如表 1 所示,标准放电工况指的是在 $25\pm 2\text{ }^{\circ}\text{C}$ 环境下,以 $0.5\text{P}(448\text{ W})$ 恒功率放电至单体电芯电压上限后,停止放电,并且在下一个工步开始前静置 30 min.

根据电池说明书的安全操作指导和已有的研

表 1 电池基本参数

Table 1 Essential parameters of the battery

Rated Capacity/(A·h)	Rated voltage/V	Rated energy/(W·h)	Battery weight/kg	Battery volume/L	Internal resistance/mΩ
280	3.2	896	5.35±0.16	2.55	≤0.25

究结果^[17], 本文的过充实验设置如下: (1) 完全充电: 将电池以 1 倍标称容量的电流充电至 3.8 V 后, 恒压充电至电流下降为 0, 静置 1 h 后继续补电, 循环此过程直至电池完全充满; (2) 解出能量管理系统的限制, 然后施加 5.2 V 的充电电压, 持续 200 s 后将电压降为 0, 此时过充实验结束。本次测试用到的实物电池如图 1 所示, 在测试过程中持续监测电流、电压和温度数据; (3) 正常充电: 将电池以 1 倍标称容量的电流充电至 3.8 V 后, 恒压充电至电流降为 0, 多次重复该过程, 并记录电流、电压和温度数据, 作为正常充电状态下的数据。将正常充电数据的状态标注为 D0, 过充数据的状态标注为 D1。




图 1 锂电池过充实验

Fig.1 Lithium battery overcharge experiment

1.2 未知故障数据

未知故障数据来源于 100 MW/200 MW·h 储能电站电池管理系统采集的运行数据, 一定数量的电芯串联组成电池模组, 若干个电池模组串联组成电池簇, 6~8 个电池簇并联组成储能单元。在储能电站调试过程中, 需要进行多次满充满放实验, 以完成充放电控制策略和实际容量的验证。根据调度的计划, 储能电站当天以满功率 100 MW 充电, 然后再以满功率 100 MW 放电, 在此过程中, 电池管理系统采集电芯、电池模组和电池簇的电压、电流、温度、阻抗等数据, 同步计算 SOC、健康状态 (State of health, SOH)、能量状态 (State of energy, SOE) 等状态, 并进行故障预警和诊断。由于采集的数据量较大, 为了简化计算以及与过充故障数据进行对比, 从中筛选出可能与电池运行状态相关的 12 个参数, 如表 2 所示。共采集到 4 组正常状态下的数据, 以及 2 组未知故障的数据, 每

组包含 5761 个数据点。将正常状态数据的状态标注为 F0, 未知故障数据的状态标注为 F1。

表 2 运行状态相关的监测变量

Table 2 Monitoring variables related to operating status

Variables	Unit	Variables	Unit
Main circuit current	A	Minimum cell temperature	℃
Maximum cell voltage	mV	Average cell temperature	℃
Minimum cell voltage	mV	Maximum pole temperature	℃
Average cell voltage	mV	Maximum high-pressure box temperature	℃
Insulation resistance	kΩ	SOC	%
Maximum cell temperature	℃	SOH	%

2 故障诊断原理

2.1 核主成分分析

KPCA 是一种基于核函数的经典非线性降维方法, 可以有效降低数据的维度和计算量, 同时还能保留数据的重要特征和信息^[18]。此外, KPCA 还可以对单个数据样本进行故障检测, 判断其与正常数据是否有显著差异, 从而保证数据的可靠性^[19]。KPCA 的基本原理是将原始的低维度数据通过非线性的方式映射到高维度向量空间 K 中, 然后再对向量空间 K 中的数据使用 PCA 降维。KPCA 的主要求解目标为通过核函数计算高维度向量空间 K 中协方差矩阵的特征值和特征向量。协方差矩阵 C_{var} 的计算方式如式 (1) 所示:

$$C_{var} = \frac{1}{n} \sum_{j=1}^n \phi(x_j) \phi(x_j)^T \quad (1)$$

式中, n 为原始数据的维度; x_j 为第 j 维原始数据; ϕ 为映射函数。 C_{var} 的特征方程为:

$$\lambda v = C_{var} v \quad (2)$$

式中, λ 为特征值; v 为对应的特征向量。经过推导, v 可以表达为:

$$v = \sum_{j=1}^n \alpha_j \phi(x_j) \quad (3)$$

式中, α 为原始数据点在构成特征向量 v 时的权重, 可通过对特征方程求解计算。联立式 (1)、式 (2) 和式 (3) 可得:

$$\lambda \sum_{j=1}^n \alpha_j [\phi(x_i), \phi(x_j)] = \frac{1}{n} \sum_{j=1}^n \alpha_j \left[\phi(x_i), \sum_{k=1}^n \phi(x_k) \right] [\phi(x_k), \phi(x_j)] \quad (4)$$

引入核函数 $\text{Ker}(x_j, x_i) = [\phi(x_j), \phi(x_i)]$, 则可计算出原始数据在高维向量空间 K 的投影为:

$$P_j = \sum_{j=1}^n \alpha_j^i \cdot \text{Ker}(x_j, x_i) \quad (5)$$

本文中采用的核函数为高斯核函数, 带宽为 128^{-2} . 为了判断是否发生故障, 计算统计量 T2 和 SPE 是否超过对应的控制限. T2 统计量是衡量多变量数据在主成分空间中的变化程度的指标, 其公式为:

$$T2 = x_{\text{new}}^T p \Lambda^{-1} p^T x_{\text{new}} \quad (6)$$

式中, Λ^{-1} 为相应特征值的倒数; x_{new} 为 PCA 降维后的数据; p 为主成分矩阵. SPE 统计量是用于衡量多变量数据在残差空间中的变化程度的指标, 其公式为:

$$\text{SPE} = x_{\text{new}}^T (1 - pp^T) x_{\text{new}} \quad (7)$$

将过充实验中的正常数据输入 KPCA 模型, 计算 T2 和 SPE 控制限. 然后从过充故障数据中任意选取 1000 个数据点, 通过 KPCA 计算的 T2 和 SPE 均远远超出对应的控制限, 如图 2 所示, 验证了过充故障数据的可靠性.




图 2 过充故障 T2 和 SPE 统计量

Fig.2 Overcharge fault T2 and SPE statistics

对未知故障数据采取相同的操作, 通过 KPCA 计算的 T2 和 SPE 也均远远超出其对应的控制限, 如图 3 所示, 这验证了未知故障数据的可靠性.

2.2 霜冰算法

霜冰 (RIME) 算法是 Su 等^[20] 受到自然界中雾




图 3 未知故障 T2 和 SPE 统计量

Fig.3 Unknown fault T2 and SPE statistics

淞的生长现象的启发, 在 2023 年新提出的一种智能优化算法. RIME 算法通过模拟软雾淞和硬雾淞的生长过程, 构建了一个软雾淞搜索策略和一个硬雾淞穿刺机制, 来实现优化问题的探索 and 开发. 同时, 该算法还引入了一个正向贪婪选择机制, 来增加种群的多样性, 避免陷入局部最优. RIME 算法通过软雾淞搜索策略更新粒子位置的方式为:

$$R_{ij}^{\text{new}} = R_{\text{best},j} + r_1 \cdot \cos \theta \cdot \beta \cdot (h \cdot (U_{b_{ij}} - L_{b_{ij}}) + L_{b_{ij}}), r_2 < E \quad (8)$$

式中, R_{ij}^{new} 为粒子更新后的位置; i 和 j 表示第 i 个雾淞代理中的第 j 个粒子; R_{best}^j 为雾淞种群 R 中最佳雾淞代理的第 j 个粒子; r_1 为 $(-1,1)$ 的随机数; θ 为控制粒子移动方向的参数, 计算公式如式 (9) 所示; β 为环境因素, 会随着迭代次数的变化而变化, 保证算法的收敛性, 计算方法如式 (10) 所示; h 为粘附度, 是一个范围在 $(0,1)$ 的随机数; $U_{b_{ij}}$ 和 $L_{b_{ij}}$ 分别为逃逸空间的上限和下限; r_2 为一个范围在 $(0,1)$ 的随机数; E 是粘附系数, 影响代理的凝结率, 计算公式如式 (11) 所示:

$$\theta = \pi \frac{t}{10T} \quad (9)$$

式中, t 是当前的迭代次数; T 为最大迭代次数.

$$\beta = 1 - \frac{\left\lceil \frac{wt}{T} \right\rceil}{w} \quad (10)$$

式中, $\lceil \cdot \rceil$ 为取整计算; w 的默认值为 5, 用来控制阶跃函数的分段数. 粘附系数 E 计算如下:

$$E = \sqrt{\frac{t}{T}} \quad (11)$$

硬雾淞穿刺机制模拟了不同的雾淞代理之间的交叉, 提高了算法的开发能力和跳出局部最优

的能力. 更新的公式如下:

$$R_{ij}^{new} = R_{best,j}, r_3 < F^{normr}(S_i) \tag{12}$$

式中, $F^{normr}(S_i)$ 为当前代理的适应度的归一化值, 表示第 i 个雾凇代理被选中的概率; r_3 为一个范围在 $(-1,1)$ 的随机数.

2.3 多尺度时序卷积网络

Bai 等^[21] 提出了一种时序卷积网络 (TCN), 能有效提取时序数据的特征, 其由一维扩张因果卷积层和残差块组成. 扩张因果卷积层使得输出只依赖于当前和过去的输入, 以指数方式扩大了输出的感受野, 即增加了对历史输入信息的感知能力. 随着卷积层的增加, TCN 能够提取更多的输入特征, 从而提高了输出的性能、稳定性和准确性, 同时降低了计算量. 给定一个滤波器 $f: \{0, 1, \cdots, k-1\} \rightarrow \mathbf{R}$, 扩张卷积 F 对一维序列 $\mathbf{x} \in \mathbf{R}^n$ 的元素 s 的定义如下式所示:

$$F(s) = (\mathbf{x}_d^* f)(s) = \sum_{i=0}^{k-1} f(i) \cdot \mathbf{x}_{s-d \cdot i} \tag{13}$$

式中, k 为滤波器的大小; d 为扩张因子; $*$ 是卷积运算符. 显然, 滤波器大小 k 或扩张因子 d 越大, 网络的感受野越广.

随着深度学习网络层的增加, 深度网络可能会变得饱和, 因此仅增加网络层数, 其性能不会持续提高, 甚至可能变差. 残差块通过输入和输出的相加, 从而增强了信息的流动和保存, 如图 4 和公式 (14) 所示, 残差块由一个恒等映射和一个残差函数 $f(x)$ 组成:

$$y = f(x) + x \tag{14}$$




图 4 TCN 残差块结构
Fig.4 TCN residual block structure

为了进一步增加 TCN 的视野, 同时能从数据中深度提取时序特征, 降低噪声对数据的干扰, 本文通过并行搭建不同大小的卷积核^[22], 从锂电池不同维度的运行数据中提取更多尺度的信息, 其结构如图 5 所示. 最后将每个尺度的信息汇总至一个全连接层, 并输入 Softmax 层进行加工, 最终




图 5 MTCN 结构
Fig.5 MTCN structure

通过分类层实现故障的准确分类.

2.4 故障诊断流程

本文提出的结合 KPCA 和 MTCN 的故障诊断方法流程如图 6 所示, 该方法的主要步骤如下:




图 6 锂电池故障诊断流程
Fig.6 Lithium battery fault diagnosis process

- (1) 将数据进行归一化处理, 并任意从中选出一组正常数据, 训练 KPCA 模型;

(2) 将剩余的数据组依次输入到 KPCA 模型中, 在降维的同时进行单故障检测, 以验证数据的可靠性, 并完成对数据故障类型的标注;

(3) 将数据划分为训练集和测试集, 基于训练集对 MTCN 模型进行训练, 同时使用霜冰算法优化 MTCN 网络的超参数, 以提高模型精度;

(4) MTCN 优化完成后, 输入测试集的数据进行故障诊断, 并参考评价指标, 对本文所提故障诊断方法的性能进行评估。

3 故障诊断结果

为了验证本文所提方法的实际诊断效果, 现分别基于两组故障数据, 将 MTCN 算法与长短期记忆神经网络 (Long short term memory, LSTM)、卷积神经网络 (Convolutional neural network, CNN) 算法^[23]、Xception^[24] 和 ResNet50^[25] 的诊断精度进行对比。

3.1 评价指标

本文选取用于评价故障诊断性能的指标有以下 4 个^[26]: 准确率 (Accuracy)、精准率 (Precision)、召回率 (Recall) 和 F1 分数 (F1-Score)。其中, 准确率指的是故障分类正确的样本数量之和占总样本数量的百分比; 精准率指的是被分类为故障的样本中, 分类正确样本的比例; 召回率指的是实际为故障的样本中, 分类正确样本的比例; F1 分数是精准率和召回率平衡的结果。假设为二分类故障, 4 个指标的计算方法如下:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FN + FP} \times 100\% \quad (15)$$

$$\text{Precision} = \frac{TP}{TP + FP} \times 100\% \quad (16)$$

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% \quad (17)$$

$$\text{F1-Score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (18)$$

式中, TP 为实际 (1) 与诊断 (1) 相符的样本数量; FN 为实际 (1) 与诊断 (0) 不相符的样本数量; FP 为实际 (0) 与诊断 (1) 不相符的样本数量; TN 为实际 (0) 与诊断 (0) 相符的样本数量。

3.2 过充故障诊断结果

使用 KPCA 确认过充故障数据的可靠性后, 对运行数据进行降维, 计算主元贡献率如图 7 所示, 从图中可以看到, 原始的故障数据仅有 2 维, 而第一主成分的贡献率只有 55.13%, 第二主成分的贡献率为 44.87%, 因此仍然保留 2 维数据。




图 7 过充故障主元贡献率

Fig.7 Main element contribution rate of overcharge fault

将标注完成的数据按照 7 : 3 的比例划分为训练集和测试集。在训练阶段, 为了进行分类精度对比, 同时使用霜冰算法优化 MTCN、LSTM 和 CNN 的超参数, 包括最小批数量、残差块层数、卷积核数量、神经元数量等, 目标优化函数为诊断结果的准确率误差, 即用 $1 - \text{Accuracy}$ 。基于过充故障数据, 使用 RIME 算法优化 MTCN 的适应度值收敛曲线如图 8 所示, 从图中可以看出, RIME 在迭代次数为 20 次左右就已经收敛, 且适应度值整体较小, 这也从侧面说明 MTCN 的诊断精度高。




图 8 RIME 算法收敛过程

Fig.8 RIME algorithm convergence process

RIME 算法优化三种模型超参数的结果如表 3 所示, 在程序中按照优化结果设置超参数, 运行环境为: CPU: R7 4800H; 内存: 16GB; GPU: GTX 1650 (桌面端), 三种算法训练过程中的分类正确率如图 9 所示, 从图中可以看出, MTCN 的收敛速度最快, 且训练误差波动相对较小。

在测试阶段, 将测试集数据输入充分训练的模型中, MTCN、LSTM、CNN、Xception 和 ResNet50 诊断结果对应的评价指标如表 4 所示, 对应的混淆矩阵如图 10 所示。从图 10 中可以看出, MTCN 将少部分的过充故障数据错误诊断为正常数据, 但是总体上的诊断正确率比较高。从表 4 中对两类数据的诊断结果的差异来看, MTCN 对正常数

表 3 过充故障数据超参数优化结果

Table 3 Overcharge fault data hyperparameter optimization results

Network type	Hyperparameters	Value	Hyperparameters	Value
MTCN	Minimum batch size	500	Number of filters	21
	Number of residual blocks	2	Filter size	2
LSTM	Number of hidden layers	2	Number of neurons	25
	Minimum batch size	1000	Drop layer probability	0.1
CNN	Number of convolutional layers	5	Number of convolution kernels	30
	Convolution kernel size	2	Drop layer probability	0.1




图 9 训练过程的分类正确率

Fig.9 Classification accuracy of the training process

据和过充数据的诊断结果的精准率和召回率相差不大,说明其对两类数据的识别能力较为平衡. LSTM 和 CNN 对正常数据诊断结果的精准率均较高,而召回率均较低,说明这两种方法对正常数据的识别能力较强,但是对过充数据的识别能力较弱. Xception 和 ResNet50 则对两类数据的识别能力较为接近.

从诊断方法的角度来看, MTCN 的 4 个评价指标均显著优于 LSTM 和 CNN, 而 CNN 稍优于 LSTM.

这说明当数据特征数量比较少时, MTCN 能更好地处理时序数据并捕获长期的历史信息. 此外, 从表 4 中的模型预测时间来看, LSTM 和 CNN 耗时间比较接近, 而 MTCN 的计算时间显然高出一截, 这是因为多个 TCN 并行的结构提取特征的能力更强, 同时也带来了更高的计算负荷. 而 Xception 和 ResNet50 作为比较新颖的算法, 其性能与 MTCN 较为接近.

3.3 未知故障诊断结果

使用 KPCA 确认过充故障数据的可靠性后, 对原始的 12 维数据进行降维, 计算主元贡献率如图 11 所示, 从图中可以看到, 第一主成分、第二主成分、第三主成分和第四主成分的累积贡献率为 95.894%, 这意味着原始的 12 维数据可以用 4 维特征空间表示.

同样将标注完成的数据按照 7 : 3 的比例划分为训练集和测试集, 并按照与过充故障相同的操作方式进行超参数的优化. 随即将测试集数据输入到充分训练的模型中, MTCN、LSTM、CNN、Xception 和 ResNet50 诊断结果对应的评价指标如

表 4 过充故障诊断的评价指标

Table 4 Evaluation indicators for overcharge fault diagnosis

Diagnosis method	Fault type	Evaluation index				Time/s
		Precision/%	Recall/%	F1 score/%	Accuracy/%	
MTCN	D0	99.980	98.928	99.452	99.265	0.817
	D1	97.834	99.960	98.885		
LSTM	D0	97.952	79.801	87.950	82.106	0.457
	D1	50.414	92.486	62.256		
CNN	D0	98.700	80.540	88.700	82.235	0.434
	D1	52.304	95.265	67.531		
Xception	D0	99.980	98.813	99.393	99.186	0.828
	D1	97.598	99.960	98.764		
ResNet50	D0	100.000	98.411	99.199	98.923	0.928
	D1	96.770	100.000	98.359		




图 10 过充故障混淆矩阵

Fig.10 Overcharge fault confusion matrix

表 5 所示, 对应的混淆矩阵如图 12 所示. 从图 12 中的结果来看, MTCN 仅将少量的故障数据诊断为正常状态. 从表 5 中对两类数据的诊断结果的差异来看, MTCN 基本能完全正确诊断故障数据. 而 LSTM、CNN、Xception 和 ResNet50 的诊断准确率也相对较高, 但是更易将故障数据分类为正常数据.

从诊断方法的角度来看, MTCN 稍优于 LSTM 和 CNN, 而 CNN 仍然优于 LSTM. 但是相较于过充故障数据, CNN 和 LSTM 的准确率均有显著的上升, 这是由于增加数据的维度有利于 LSTM 和 CNN 提取更多的信息. 对比表 4 和表 5 的模型计算时间可以看出, 表 5 中所有模型的时间均短于表 4, 这是由于未知故障的总数据量要少于过充故障, 在同样的划分比例下, 在测试阶段需要进行故障诊断的数据量更少.

3.4 训练数据量的影响

为了分析并比较训练数据量对分类精度的影




图 11 未知故障主元贡献率

Fig.11 Main element contribution rate of unknown fault

响, 按照不同的比例划分训练集和测试集, 三种模型对应的诊断结果如表 6 所示. 从表中可以看出, 对于两类数据而言, 随着比例的增大, 即训练数据量的增加, 三种模型均呈现由欠拟合到中间状态再到过拟合的趋势, 综合几种模型的诊断准确率考虑, 本文以 7 : 3 的比例重点研究并对比了三种模型的分类效果.

此外, 无论是过充故障还是未知故障, 在不同的比例下 MTCN、Xception 和 ResNet50 的诊断准确率均非常高, 这也验证了 MTCN 用于锂电池故障诊断时具有较强的泛化能力, 可以适应不同类型和程度的锂电池故障.

尽管目前的研究已经通过现有数据充分验证了 MTCN 在锂电池过充故障和未知故障诊断中的高准确率, 表明了 MTCN 模型在故障诊断方面的强大潜力, 但受限于数据类型和数量的有限性, 特别是对于多种故障类型的效果评估, 因缺乏相应的数据集而尚未进行测试.

表 5 未知故障诊断的评价指标

Table 5 Evaluation indicators for unknown fault diagnosis

Diagnosis method	Fault type	Evaluation index				Time/s
		Precision/%	Recall/%	F1 score/%	Precision/%	
MTCN	F0	100	99.577	99.788	99.688	0.806
	F1	98.817	100	99.405		
LSTM	F0	92.786	100	96.258	94.690	0.394
	F1	100	83.251	90.860		
CNN	F0	96.258	100	98.093	97.245	0.387
	F1	100	90.550	95.041		
Xception	F0	99.036	100	99.515	99.290	0.777
	F1	100	97.381	98.673		
ResNet50	F0	99.151	99.942	99.545	99.333	0.836
	F1	99.839	97.684	98.750		




图 12 未知故障混淆矩阵

Fig.12 Confusion matrix of unknown fault

表 6 数据训练量对准确率的影响

Table 6 Impact of data training volume on accuracy %

Fault type	Method	Ratio			
		5:5	6:4	7:3	8:2
Overcharge	MTCN	99.275	99.311	99.265	99.232
	LSTM	79.693	82.239	82.106	81.236
	CNN	79.260	79.866	82.235	78.854
	Xception	99.015	99.134	99.186	99.390
	ResNet50	99.134	99.055	98.923	99.370
Unknown	MTCN	98.765	99.478	99.688	99.212
	LSTM	95.996	95.315	94.690	96.933
	CNN	95.536	97.412	97.245	95.315
	Xception	99.676	99.805	99.290	99.340
	ResNet50	99.310	99.872	99.333	99.808

4 结论

本文提出了一种结合 KPCA 和 MTCN 的锂电池故障诊断方法,并使用 RIME 算法优化 MTCN 的超参数,最后基于 2 组故障数据分别进行了验证,结果表明:

(1) 通过 KPCA 计算 T2 统计量和 SPE 统计量,并与相应的阈值比较,可以判定单维故障,验证了数据的可靠性.同时,KPCA 也可以在保留主要信息的前提下,对原始数据进行降维;

(2) 对于过充故障和未知故障两组数据,相比于 LSTM 和 CNN,MTCN 均有显著的优势,其诊断准确率分别为 99.265% 和 99.688%,而 MTCN 与 Xception 和 ResNet50 的性能则比较接近;

(3) 按照不同的比例划分训练集和测试集,MTCN 故障诊断准确率均非常高,说明了 MTCN 用于锂电池故障诊断时具有较强的泛化能力.

参 考 文 献

[1] Chen M, Zhao J, Wang Y L, et al. Review on fault monitoring and

diagnosis of large-scale electrochemical energy storage system [J/OL]. *Proc CSEE*, (2023–11–10) [2024–01–30]. <https://doi.org/10.13334/j.0258-8013.pcsee.230549>

(陈萌, 赵谡, 王亚林, 等. 大规模电化学储能系统故障监测与诊断研究综述[J/OL]. *中国电机工程学报*, (2023–11–10) [2024–01–30]. <https://doi.org/10.13334/j.0258-8013.pcsee.230549>)

[2] Wang J R, Wu X J, Zhao D Q, et al. Research on internal short-circuit fault diagnosis methods for lithium-ion batteries based on WOA-VMD and PSO-SVM. *Chin J Eng*, 2023, 45(12): 2162 (王君瑞, 吴新举, 赵东琦, 等. 基于 WOA-VMD 与 PSO-SVM 的锂离子电池内短路故障诊断方法. *工程科学学报*, 2023, 45(12): 2162)

[3] Ma R, Liu J, Wang S, et al. Progress on thermal runaway propagation characteristics and prevention strategies of lithium-ion batteries. *Chin Sci Bull*, 2021, 66(23): 2991

[4] Wu J J, Hou J S, Ma L, et al. Research progress on nanofluids for battery thermal management. *Chin J Eng*, 2024, 46(8): 1498 (吴俊杰, 侯峻升, 马丽, 等. 纳米流体电池热管理研究进展. *工程科学学报*, 2024, 46(8): 1498)

[5] Tran M K, Fowler M. A review of lithium-ion battery fault diagnostic algorithms: Current progress and future challenges. *Algorithms*, 2020, 13(3): 62

[6] Xue Q, Li G, Zhang Y J, et al. Fault diagnosis and abnormality detection of lithium-ion battery packs based on statistical distribution. *J Power Sources*, 2021, 482: 228964

[7] Yang S C, Wang X, Chen F, et al. Advances in prognosis and health management technologies of lithium-ion batteries [J/OL]. *J Beijing Univ Aeronaut Astronaut*, (2023–12–25) [2024–01–30]. <https://doi.org/10.13700/j.bh.1001-5965.2023.0296> (杨世春, 王潇, 陈飞, 等. 锂离子电池故障预测及健康管理技术研究进展[J/OL]. *北京航空航天大学学报*, (2023–12–25) [2024–01–30]. <https://doi.org/10.13700/j.bh.1001-5965.2023.0296>)

[8] Jiang J C, Gao Y, Zhang C P, et al. Online diagnostic method for health status of lithium-ion battery in electric vehicle. *J Mech Eng*, 2019, 55(20): 60 (姜久春, 高洋, 张彩萍, 等. 电动汽车锂离子动力电池健康状态在线诊断方法. *机械工程学报*, 2019, 55(20): 60)

[9] Feng X, He X, Lu L, et al. Analysis on the fault features for internal short circuit detection using an electrochemical-thermal coupled model. *J Electrochem Soc*, 2018, 165(2): A155

[10] Sidhu A, Izadian A, Anwar S. Adaptive nonlinear model-based fault diagnosis of Li-ion batteries. *IEEE Trans Ind Electron*, 2015, 62(2): 1002

[11] Wei J W, Dong G Z, Chen Z H. Model-based fault diagnosis of Lithium-ion battery using strong tracking Extended Kalman Filter. *Energy Procedia*, 2019, 158: 2500

[12] Yang R X, Xiong R, He H W, et al. A fractional-order model-based battery external short circuit fault diagnosis approach for all-climate electric vehicles application. *J Cleaner Prod*, 2018, 187: 950

[13] Yao L, Fang Z P, Xiao Y Q, et al. An intelligent fault diagnosis

- method for lithium battery systems based on grid search support vector machine. *Energy*, 2021, 214: 118866
- [14] Jia J, Hu X S, Deng Z W, et al. Data-driven comprehensive evaluation of Lithium-ion battery state of health and abnormal battery screening. *J Mech Eng*, 2021, 57(14): 141
(贾俊, 胡晓松, 邓忠伟, 等. 数据驱动的锂离子电池健康状态综合评分及异常电池筛选. *机械工程学报*, 2021, 57(14): 141)
- [15] Li D, Zhang Z S, Liu P, et al. Battery fault diagnosis for electric vehicles based on voltage abnormality by combining the long short-term memory neural network and the equivalent circuit model. *IEEE Trans Power Electron*, 2021, 36(2): 1303
- [16] Wang J, Zhang S L, Hu X. A fault diagnosis method for lithium-ion battery packs using improved RBF neural network. *Front Energy Res*, 2021, 9: 702139
- [17] Xu F, He H, Liu Y D, et al. Failure investigation of LiFePO₄ Cells under overcharge conditions. *J Electrochem Soc*, 2012, 159(5): A678
- [18] Chen X H, Wang H, Li X H. A short-term load forecasting method based on KPCA-CNN-DBiGRU model. *J Ind Eng Eng Manage*, 2024, 38(2): 221
(陈晓红, 王辉, 李喜华. 基于 KPCA-CNN-DBiGRU 模型的短期负荷预测方法. *管理工程学报*, 2024, 38(2): 221)
- [19] Liang S J, Zhang S R, Zheng X, et al. Online fault detection of fixed-wing UAV based on DKPCA algorithm with multiple operation conditions considered. *J Northwest Polytech Univ*, 2020, 38(3): 619
(梁少军, 张世荣, 郑幸, 等. 基于 DKPCA 的固定翼无人机多工况在线故障诊断. *西北工业大学学报*, 2020, 38(3): 619)
- [20] Su H, Zhao D, Heidari A A, et al. RIME: A physics-based optimization. *Neurocomputing*, 2023, 532: 183
- [21] Bai S J, Kolter J Z, Koltun V, et al. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [J/OL]. *arXiv preprint* (2018-03-04) [2024-01-30]. <https://arxiv.org/abs/1803.01271>
- [22] Liang L, Zhang Z S. Short-term load forecasting of a power system based on multi-scale feature enhanced DHTCN. *Power Syst Prot Control*, 2023, 51(10): 172
(梁露, 张智晟. 基于多尺度特征增强 DHTCN 的电力系统短期负荷预测研究. *电力系统保护与控制*, 2023, 51(10): 172)
- [23] Sun Z L, Machlev R, Wang Q C, et al. A public data-set for synchronous motor electrical faults diagnosis with CNN and LSTM reference classifiers. *Energy AI*, 2023, 14: 100274
- [24] Xie F Y, Li G, Song C J, et al. The early diagnosis of rolling bearings' faults using fractional Fourier transform information fusion and a lightweight neural network. *Fractal Fract*, 2023, 7(12): 875
- [25] Han W T, Cheng L, Han W J, et al. Soft fault diagnosis for DC-DC converter based on improved ResNet-50. *IEEE Access*, 2023, 11: 81157
- [26] Zhang Y, Li X J, Ma Z L, et al. A review of fault diagnosis algorithms for lithium ion batteries. *J Chongqing Univ Technol (Nat Sci)*, 2023, 37(9): 49
(张扬, 李晓杰, 马兹林, 等. 锂离子电池故障诊断算法研究综述. *重庆理工大学学报(自然科学)*, 2023, 37(9): 49)