



Gappy POD算法重构储能电池组核心温度及与BP神经网络预测能力对比

苑清扬 薛珂 张博 兰天

Gappy POD algorithm for reconstructing the core temperature of energy-storage battery packs and its comparison with BP neural network prediction ability

YUAN Qingyang, XUE Ke, ZHANG Bo, LAN Tian

引用本文:

苑清扬, 薛珂, 张博, 兰天. Gappy POD算法重构储能电池组核心温度及与BP神经网络预测能力对比[J]. *工程科学学报*, 2024, 46(1): 166–177. doi: 10.13374/j.issn2095–9389.2023.05.24.001

YUAN Qingyang, XUE Ke, ZHANG Bo, LAN Tian. Gappy POD algorithm for reconstructing the core temperature of energy-storage battery packs and its comparison with BP neural network prediction ability[J]. *Chinese Journal of Engineering*, 2024, 46(1): 166–177. doi: 10.13374/j.issn2095–9389.2023.05.24.001

在线阅读 View online: <https://doi.org/10.13374/j.issn2095–9389.2023.05.24.001>

您可能感兴趣的其他文章

Articles you may be interested in

高温相变储能微胶囊研究进展

Research progress of high-temperature phase change energy storage microcapsules

工程科学学报. 2021, 43(1): 108 <https://doi.org/10.13374/j.issn2095–9389.2020.07.21.004>

BP神经网络IF钢铝耗的预测模型

Prediction model of aluminum consumption with BP neural networks in IF steel production

工程科学学报. 2017, 39(4): 511 <https://doi.org/10.13374/j.issn2095–9389.2017.04.005>

基于集成神经网络的剩余寿命预测

Remaining useful life prediction based on an integrated neural network

工程科学学报. 2020, 42(10): 1372 <https://doi.org/10.13374/j.issn2095–9389.2019.10.10.005>

一维卷积神经网络特征提取下微震能级时序预测

Time series prediction of microseismic energy level based on feature extraction of one-dimensional convolutional neural network

工程科学学报. 2021, 43(7): 1003 <https://doi.org/10.13374/j.issn2095–9389.2020.11.22.001>

基于BP神经网络的机器人波动摩擦力矩修正方法

Wave friction correction method for a robot based on BP neural network

工程科学学报. 2019, 41(8): 1085 <https://doi.org/10.13374/j.issn2095–9389.2019.08.014>

卷积神经网络在矿区预测中的研究与应用

Research and application of convolutional neural network in mining area prediction

工程科学学报. 2020, 42(12): 1597 <https://doi.org/10.13374/j.issn2095–9389.2020.01.02.001>

Gappy POD 算法重构储能电池组核心温度及与 BP 神经网络预测能力对比

苑清扬¹⁾, 薛珂²⁾, 张博^{1,2)✉}, 兰天³⁾

1) 大连理工大学能源与动力工程学院, 大连 100083 2) 大连理工大学宁波研究院, 宁波 315000 3) 浙江一舟储能集团, 宁波 315191

✉通信作者, E-mail: zhangbo@dlut.edu.cn

摘要 储能电池组中电池核心温度的实时监控对于防控电池热失控有着重要的意义。为克服工业实际中电池组内部无法布置多温度测点导致的温度数据获取不全面等问题, 本文将 Gappy POD 重构算法引入储能电池核心温度实时监控问题中, 通过监测电池组表面温度预测内部核心温度。通过搭建简化的拟储能电池实验台模拟电池温升, 测试了 Gappy POD 算法在工况平稳变化和工况剧烈变化条件下的稳定性和对核心温度的实时重构能力; 对比了 Gappy POD 算法的重构能力和 BP 神经网络 (Back propagation neural network) 的预测能力, 并探究了 Gappy POD 算法和 BP 神经网络在不同大小的数据库训练条件下的重构预测能力。研究表明, Gappy POD 重构算法具有高预测精度、稳定性强并且对数据库数据量依赖性低等优势, 为算法在储能电池热管理中的实际应用提供了基础。

关键词 Gappy POD; BP 神经网络; 储能电池; 热管理; 核心温度预测

分类号 TK311

Gappy POD algorithm for reconstructing the core temperature of energy-storage battery packs and its comparison with BP neural network prediction ability

YUAN Qingyang¹⁾, XUE Ke²⁾, ZHANG Bo^{1,2)✉}, LAN Tian³⁾

1) School of Energy and Power Engineering, Dalian University of Technology, Dalian 116081, China

2) Ningbo Institute of Dalian University of Technology, Ningbo 315000, China

3) Ningbo Ship Group Co., Ltd, Ningbo 315191, China

✉Corresponding author, E-mail: zhangbo@dlut.edu.cn

ABSTRACT The reliability and safety of energy-storage battery packs have always been an industry priority. Large energy-storage battery modules are characterized by high power, numerous built-in energy-storage batteries, complex structures, and a heightened risk of thermal runaway. Monitoring the core temperature in energy-storage battery packs in a noncontact, real-time manner is essential for preventing and controlling thermal runaway events. In response to the challenge of incomplete temperature data acquisition, especially in industrial settings where arranging multiple temperature measurement points inside the battery pack may not be feasible, this study introduced the Gappy POD reconstruction algorithm. Gappy POD is a data analysis method based on proper orthogonal decomposition (POD), which is commonly used in inverse heat transfer and fluid mechanics problems. This enables the prediction of the internal core temperature by monitoring the surface temperature of the battery pack. Considering the safety concerns of battery experiments, this study simulated battery temperature changes using a simplified simulated energy-storage battery experimental platform. The platform tests the stability and real-time reconstruction capabilities of the Gappy POD algorithm under stable and drastic changes in operating conditions.

收稿日期: 2023–05–24

基金项目: 2023 年宁波市重点研发计划资助项目 (2023Z150)

Although we did not introduce the equivalent circuit model in the experiment, this preliminary study verified the reconstruction ability of the algorithm under significant fluctuations in working conditions. Neural networks are renowned for their nonlinear solid prediction capabilities and have extensive applications in predicting the temperatures of energy-storage batteries. This study compares the reconstruction ability of the Gappy POD algorithm with the prediction capability of a back-propagation (BP) neural network. This study also explored the reconstruction and prediction capabilities of the Gappy POD and BP neural networks under varying database sizes for training. The research presented in this study indicates that the Gappy POD reconstruction algorithm exhibits high prediction accuracy, particularly under stable working conditions and with smaller training sample sizes. In these scenarios, it outperformed the BP neural network. Moreover, this algorithm demonstrates strong stability and low dependence on the volume of database data, providing a solid foundation for further applications in the thermal management of energy-storage batteries. It also presents a viable approach for noncontact monitoring of the core temperature of energy-storage battery packs. In conclusion, this study acknowledges areas for improvement in the current research and outlines prospects for future research.

KEY WORDS Gappy POD; back-propagation neural network; energy-storage battery; thermal management; core temperature prediction

储能系统在电力及能源系统中发挥着至关重要的作用,是可再生能源的大规模接入和电网稳定运行的保证^[1]。而电化学储能具有能量密度高、响应时间快、维护成本低、灵活方便等优点,已成为目前大规模储能技术的发展方向。集装箱式储能电柜将电池组系统、管理系统、预警系统等集成一体化,具有方便运输、占地较小以及储能量较大等特点,被广泛使用。

作为储能系统的核心组成部分,储能电池的性能对于储能系统至关重要。研究表明,温度是影响储能电池安全性、寿命^[2-3]和性能^[4-6]的关键因素,而集装箱式储能电池组的环境密闭性较强,散热不良时便会导致储能电柜中温度异常升高,影响系统运行,严重时甚至会引发储能电池组的热失控^[7-9]从而引发爆炸和火灾。由于储能电池组结构的复杂性和受内部电池数量较多的制约,无法通过传统的测温方式,如热电偶、红外热成像技术等对电池组内部所有电池的核心温度进行测量。因此如何对储能电池柜中成千上万组储能电池核心温度进行有效的实时监控是电化学储能行业的一大亟待解决的难题。

Debert 等^[10], Lin 等^[11]和 Sun 等^[12]尝试涉及使用自适应算法根据数据和模型估计电池的核心温度;Richardson 等^[13]提出了一种基于电-热的算法,将电化学阻抗谱(EIS)与表面温度测量相结合,用于估计电池的核心温度;其他文献还提出使用高精度电化学产热模型预测电池温度分布^[14-15]。这些方法对电池核心温度的估计具有重要的意义,但是其模型稳定性较差,仅适合于一种或部分类型的电池,具有较强的局限性,并且需要使用者对电化学原理有深入的了解。近些年随着机器学习和

深度学习领域的发展,人工智能被应用于储能电池状态运行状态监测,赵泽昆等^[16]提出了一种基于 BP 神经网络的储能电池衰减容量预测方法,可以准确地预测储能电池的容量衰减情况,提高电池储能系统的稳定性;李昕光等^[17]将 BP 神经网络和多目标遗传算法相结合设计储能电池用换热器并实时监测系统运行中的温度状态;陈实等^[18]基于人工神经网络构建了锂离子电池表面温度的预测模型。机器学习等方法虽然在储能电池温度预测上具有较高的精度,但是其预测能力过于依赖训练数据库的大小,较小的数据量往往会导致机器学习模型训练失败,而获取较大的数据量则需要较大的实验成本和代价。

本征正交分解(Proper orthogonal decomposition, POD)是一种高阶数据降维常用的方法,已被广泛的应用于流体力学^[19-20]、结构力学和振动分析^[21]、大气科学^[22]等领域中。在 POD 的基础上 Everson 和 Sirovich^[23]提出了一种利用 POD 模式进行稀疏采样重构的方式——缺失 POD(Gappy POD),该方法利用了稀疏和压缩采样算法的思想,通过少量样本就能重构完整场。该方法具有计算速度快、数据库依赖性小等优势。李静和张伟伟^[24]利用 Gappy POD 方法高效的重构了参数范围内的任意完整流场数据;李天一等^[25]研究了 Gappy POD 算法在湍流重构中的应用,并分析了影响重构精度的因素;罗芸等^[26]将 Gappy POD 算法拓展至双峰温度场的重构预测中。本文尝试将 Gappy POD 算法引入储能电池核心温度重构中以实现不依赖于电化学产热模型,从数据层面实现基于较小容量的数据库对电池核心温度的有效重构预测,并前瞻 Gappy POD 算法在储能电池热管理中的应用。

通过搭建拟储能电池发热实验平台获取测试数据, 构建温度数据库用于算法训练, 在稳定和剧烈工况变化工况条件下分别测试算法的精度和稳定性, 并将 Gappy POD 算法的重构能力与神经网络的预测能力进行对比以显示 Gappy POD 算法的非线性重构能力以及在小样本数据库条件下的温度预测优势.

1 正交分解算法

1.1 本征正交分解 (POD)

本征正交分解方法(POD)可以提供一组正交基底, 这些基底包含了所描述的系统的主要特征信息, 利用所选基底的线性组合可以近似系统, 从而将一个高维问题转化为低维问题. 为节省计算资源, 通常使用 Sirovich^[27] 提出的“快照”POD 方法(Snapshot POD method)对数据库进行降维处理. “快照”POD 方法对系统特征提取及降维的具体流程如下:

(1) 构建由 M 个系统参数组合、 N 个时刻瞬时流场或温度场数据构成的快照矩阵合集 \mathbf{D} . 假设系统参数用 SP(System parameter) 表示, 时间变量用 t 表示, 其中第 i 种系统参数组合方式, 第 q 时刻的所有测点的快照数据列表示为 $\mathbf{D}_{(SP_i, t_q)}$. 则集合了所有测点位置的样本的矩阵形式可以表示为多个快照数据列的集合, 如式(1)所示:

$$\mathbf{D} = [\mathbf{D}_{(SP_1, t)}, \mathbf{D}_{(SP_2, t)}, \mathbf{D}_{(SP_3, t)} \cdots \mathbf{D}_{(SP_M, t)}] \quad (1)$$

上式中 t 代表所有时刻, 即 $t = (t_1, t_2, t_3, \cdots, t_N)$, $SP_i (i = 1, 2, \cdots, M)$ 表示第 i 种系统参数的组合.

(2) 对样本矩阵形式的各行进行归一化处理, 样本矩阵 \mathbf{D} 归一化后形式为 $\hat{\mathbf{D}}$.

(3) 计算归一化样本矩阵的相关矩阵 \mathbf{R} , 并求其特征值和特征向量如式(2)和式(3)所示:

$$\mathbf{R} = \frac{1}{N} \hat{\mathbf{D}}^T \hat{\mathbf{D}} \quad (2)$$

$$\mathbf{R}\mathbf{A} = \lambda\mathbf{A} \quad (3)$$

式中, λ 为特征值矩阵, λ_j 为特征值矩阵中对角线上第 j 个特征值, \mathbf{A} 为特征向量矩阵, \mathbf{A}_j 为特征向量矩阵的第 j 列. 通过式(4)和式(5)可计算各阶 POD 正交基底 Φ_j 和其对应的模态系数 $\mathbf{a}_j(t)$:

$$\Phi_j = \frac{1}{\sqrt{\lambda_j}} \hat{\mathbf{D}} \mathbf{A}_j \quad (4)$$

$$\mathbf{a}_j(t) = \frac{\Phi_j^T \cdot \hat{\mathbf{D}}}{\Phi_j^T \cdot \Phi_j} \quad (5)$$

前 n 个 POD 模态所捕获的能量占全阶模态的能量 E 为式(6)所示, 其中 k 为最高阶模态阶数:

$$E = \frac{\sum_{j=1}^n \lambda_j}{\sum_{j=1}^k \lambda_j} \quad (6)$$

任意时刻场数据可以由场数据的时间平均值和一组模态系数和基底来重构, 即:

$$\hat{\mathbf{D}}_{(SP_i, t_q)} = \sum_{j=1}^N \Phi_j \cdot \mathbf{a}_j(t) \quad (7)$$

1.2 缺失本征正交分解 (Gappy POD)

Gappy POD 方法被广泛应用于传热学等反问题的求解中. 已知某个系统的样本矩阵为 \mathbf{D} , 该样本矩阵也即完整目标场. 通过正交分解得到正交基底 Φ_j 以及模态系数 $\mathbf{a}_j(t)$. 任意时刻, 任意系统参数组合条件下的部分数据缺失场 $\hat{\mathbf{D}}$ 可定义为一个掩码向量 $\vec{\alpha}$ 和一个完整场 \mathbf{D} 的点积, 其中 m 为测点个数, x_i 为第 i 个测点:

$$\hat{\mathbf{D}} = \vec{\alpha} \cdot \mathbf{D} = \sum_{i=1}^m \vec{\alpha}_i \mathbf{D}(x_i) \quad (8)$$

其中掩码向量的构成为:

$$\vec{\alpha}_i = \begin{cases} 0, & \hat{\mathbf{D}}(x_i) \text{ 缺失} \\ 1, & \hat{\mathbf{D}}(x_i) \text{ 未缺失} \end{cases} \quad (9)$$

$\mathbf{b}_j(t)$ 为一组待求模态系数:

$$\hat{\mathbf{D}} \approx \sum_{j=1}^n \vec{\alpha} \cdot \Phi_j \cdot \mathbf{b}_j(t) \quad (10)$$

重构误差可以表示为 e :

$$e = \left\| \hat{\mathbf{D}} - \sum_{j=1}^n \vec{\alpha} \cdot \Phi_j \cdot \mathbf{b}_j(t) \right\|_2 \quad (11)$$

利用最小二乘法最小化重构误差 e 可以得到一组最优的模态系数 $\mathbf{b}_j(t)$, 利用该组模态系数和正交基底可以重构出完整的目标场. 重构后的完整目标场可以表示为 $\bar{\mathbf{D}}$, 则 $\bar{\mathbf{D}}$ 可由式(12)计算得:

$$\bar{\mathbf{D}} = \sum_{j=1}^n \Phi_j \cdot \mathbf{b}_j(t) \quad (12)$$

2 模拟储能电池发热实验

储能电池组模组中的电池单元的容量、电阻、寿命等有所差异, 这些差异会导致电池组的电压分布不均, 部分电池的电压可能会超过其承受的范围, 从而影响整个储能电池组的性能和寿命. 因此在工业中, 储能电池组在充电之前均会通过电池管理系统(BMS)对电池组进行均衡电压处理,

将电池组中每个电池单元的电压调整至相等的水平. 本文模拟电池组恒压放电过程中的温度变化情况, 设定工况用于模拟储能电池中电池在电压不均衡的较极端条件下的温升情况. 因为储能电池单体在电压不均衡条件下的发热实验热失控风险较高, 需要专业的防爆实验台和复杂的安全措施. 本文在不考虑电化学模型的情况下, 利用含内热

源的热传导模型近似模拟在无外部冷却措施状态下的储能电池恒压放电过程中的温度变化曲线, 以及电压突变条件下的异常温升状况. 搭建拟储能电池发热实验台如图 1 所示, 用以模拟电池发热及异常温升情况、测试 Gappy POD 算法的温度场实时重构预测能力, 以及算法在工况参数变化条件下的稳定性.




图 1 拟储能电池发热实验台

Fig.1 Simulated experimental bench for heating energy-storage batteries

2.1 实验材料

本实验主要材料及设备如表 1 所示, 包括可控直流加热片、64 通道温度采集卡、3 通道可编程控制电源、40 cm×30 cm 铝板, 利用 Labview 和 Matlab 编制计算平台通将数据采集卡得到的温度数据进行实时重构处理. 实验部分外罩玻璃箱以防止对流对于温升的影响并模拟封闭电池箱箱体环境. 实验前利用本地气压(997 hPa)下的沸腾蒸馏水对 64 通道采集卡所连的热电偶进行统一温度测试, 绝对误差小于 0.1 °C, 为减少接触热阻的影响, 热电偶采用点焊的方式与待测物体相连接.

表 1 实验设备及材料

Table 1 Experimental equipment and materials

Experimental materials	Quantity	Parameter
Controllable thermal source	4	Maximum power 60 W
Temperature acquisition card	1	64 channel
Programmable power supply	1	3 channels, 30 V
Aluminum panel	1	40 cm × 30 cm

2.2 实验测点布置

实验中四个加热片布置位置的俯视图以及测点布置的位置如图 2 所示, 其中共有 13 个测点, 4 个测点直接布置于加热片上测量加热片温度, 编

号为 1~4, 用于监测模拟电池核心温度; 其余 9 个测点放置于铝板下底面, 编号为 5~13, 用于监测模拟电池箱外部温度; 通过该 9 个测点中的部分测点的温度值并结合 Gappy POD 算法重构预测放置于加热片上的 4 个内部测点温度值, 实现通过测量电池箱外壳部分测点的温度预测电池组内各电池核心温度的实验目的.

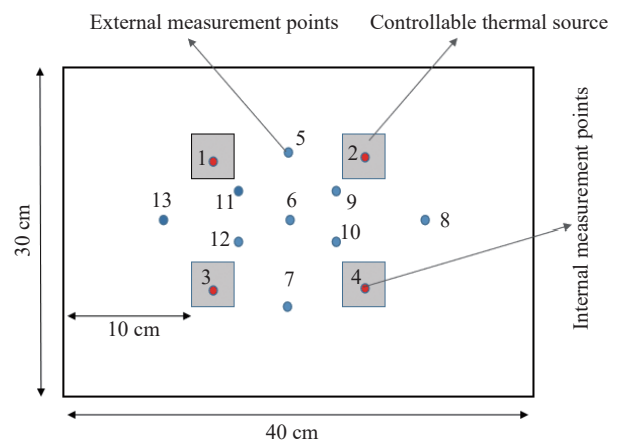


图 2 温度测点布置示意图

Fig.2 Schematic diagram illustrating the layout of temperature measurement points

2.3 实验变量

实验中将 1 号和 2 号测点所在的加热片串联

后接入可编程控制电源通道 1, 3 号和 4 号测点所在加热片分别接入可编程控制电源通道 2 和通道 3, 改变可编程控制电源的通道输出电压即可实现对于加热片的温度控制. 为了增加实验的非线性, 在通道 3 电压的基础上增加实时小幅波动的随机电压, 随机电压的波动值在基础值的 1% 范围内并符合时间序列上的正态分布.

2.4 实验数据收集

令可编程电源通道 1、2、3 输出电压值取值分别在 (15、20 和 25 V) 三个电压值中选取, 其中通道 2 和通道 3 输出电压取值相同, 通道 3 中引入实时小幅波动且满足正态分布的随机电压. 在确定各通道输出电压后, 进行 35 min 的温升实验, 间隔 1 s 利用采集卡同时对 13 通道的温度数据进行收集. 每次实验后待装置各测点温度自然冷却至室温后改变通道电压进行下一次实验. 实验共收集 9 组数据, 每组数据包含 2200 个时间点上的 13 个测点的温度值.

因为在 1 s 的时间间隔内测点的温度变化并不明显, 且较小的采集温度数据时间间隔会导致数据库中存在较多的噪声和异常数据值, 并且数据库的大小会显著影响计算效率. 因此对收集的数据进行进一步处理, 将时间间隔扩大至 15 s, 则处理后的 9 组数据, 每组数据包含 148 个时间点上的 13 个测点的温度值.

3 工况变化剧烈程度对 Gappy POD 算法的重构能力影响

3.1 Gappy POD 算法在拟储能电池温升实验中的应用

本实验目的在于利用储能电池组箱体外测点 (编号 5~13) 中的部分测点实时测温数据并结合 Gappy POD 算法实时重构电池箱体内核心测点 (编号 1~4) 温度, 从而实现核心温度的间接预测, 避免在储能箱体内置测点影响电池组结构以及增加成本. Gappy POD 算法在储能电池温升实验中的应用流程图如图 3 所示.

3.2 传感器数量和布放位置的确定

Gappy POD 算法的重构预测能力与传感器布放的数量和布放的位置密切相关. 本文采用图 4 所示的“遗传-交叉验证”算法来确定传感器布放的最佳位置和数量. 在“遗传-交叉验证”算法中, 适应度函数是重构数据和测量数据的均方根误差的倒数, 因此适应度值越大, 重构误差越小. 当所选传感器数量分别为 2、3、4、5、6、7 和 8 个时, 对

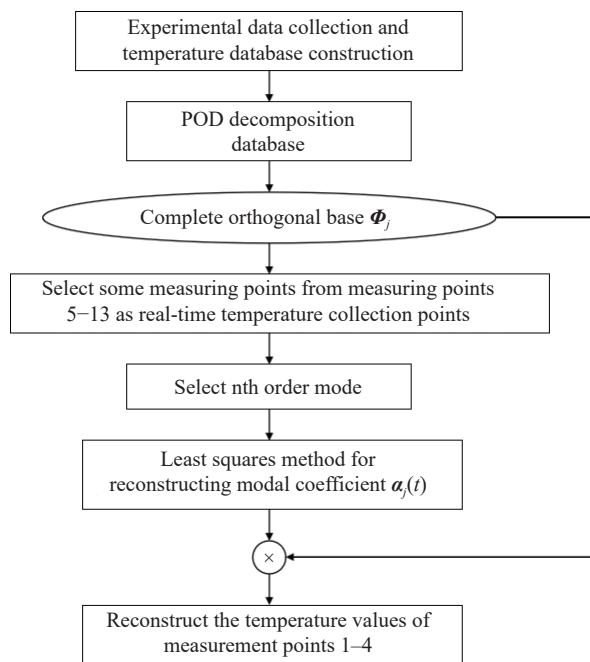


图 3 Gappy POD 算法在拟储能电池温升实验中应用流程

Fig.3 Application process of the Gappy POD algorithm in temperature rise experiments for quasi-energy-storage batteries

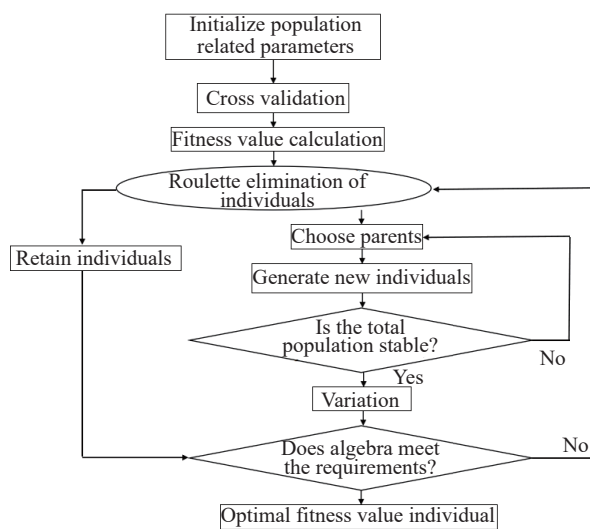


图 4 “遗传-交叉验证算法”流程

Fig.4 Flowchart of the “Genetic-Cross Validation” method

应的最优测点布置位置和适应度值如表 2 所示, 其中测点编号对应于图 2 所示.

由图 5 可以看出, 适应度值随着测点个数的增加逐渐变大, 即重构误差随着测点个数的增加逐渐减小. 但是较高的重构精度意味着测点个数的增加, 实验或工程应用中成本显著增加, 综合衡量成本和重构精度两个因素, 选择测点数量为 4, 最优测点位置编号如表 2 所示.

3.3 工况变化平稳条件下数据的重构

将传感器布放在编号为 8、10、12、13 四个测

表2 最优测点数量和位置及其适应度值表

Table 2 Optimal number and location of measurement points, along with their corresponding fitness values

Number of measuring points	Point number for measurement location	Fitness value
2	6, 8	1.257610907
3	5, 12, 7	1.281934902
4	10, 8, 13, 12	1.335612046
5	6, 13, 10, 11, 12	1.345101599
6	13, 12, 7, 11, 6, 10	1.391952749
7	13, 10, 5, 12, 11, 7, 9	1.437521604
8	9, 8, 5, 6, 7, 13, 10, 11	1.495752957




图5 适应度值随测点数量变化

Fig.5 Relationship between fitness value and the number of measurement points

点上,利用数据库数据和传感器实时测量数据实时重构预测核心测点 1、2、3、4 四个测点位置温度.可编程电源输出电压波动较小时,加热片的温度波动也相对较小.首先探究利用 Gappy POD 算法在工况变化平稳条件(下文中简称为“弱工况”)下的重构精度.实验中工况(可编程控制电源电压)变化情况如表 3 所示,首先在 22 V 和 18 V 电源电压下进行 360 s 温升实验,随后调整电压至 16 V 和 24 V 后再进行 480 s 温升实验,最后在电压 20 V 和 23 V 条件下实验 660 s 至实验结束.

表3 工况变化平稳条件下可编程控制电源电压设定

Table 3 Programmable control power supply voltage setting under stable working conditions

Programmable control power supply 1's voltage value/V	Programmable control power supply 2's voltage value/V	Experimental duration/s
22	18	360
16	24	840
20	23	1500

为避免系统开机时噪声对初始数据产生较大

的噪声影响,从系统运行的第 50 s 开始利用 Gappy POD 算法对 1、2、3、4 号测点温度进行实时重构,得到重构值和实际值如图 6 所示.

3.4 工况变化较剧烈条件下数据的重构

如 3.3 节所示,保持传感器数量和布置位置不变,改变实验中工况(可编程控制电源电压)的变化情况如表 4 所示.相比表 3 所示工况,表 4 中工况变化更加复杂,具体表现为:电压改变频率更高(由 3 次/1500 s 增加至 6 次/1500 s)、电压变化间隔更短(由 480 s 缩短为 120 s)、电压值变化幅度更大(可编程控制电源 1 输出电压范围由 16 ~ 22 V 变为 15 ~ 23 V、可编程控制电源 2 输出电压范围由 18 ~ 23 V 变为 16 ~ 25 V),因此将得到一组变化较剧烈的温度数据.利用 Gappy POD 算法得到对于工况变化较剧烈条件(下文简称为“强工况”)下的 1 至 4 号测点温度的实时重构值和实际值如图 7 所示.

3.5 结果分析

选取均方根误差 RMSE(Root mean squared error)和相关系数 CCOE(Correlation coefficient)两个参数分别衡量重构误差大小和趋势预测能力,其中 RMSE 和 CCOE 的定义分别如式 (13) 和式 (14) 所示:

$$\text{RMSE} = \sqrt{\frac{1}{s} \left(\sum_{i=1}^s (y_i - \hat{y}_i) \right)^2} \quad (13)$$

$$\text{CCOE} = \frac{\text{Cov}(y, \hat{y})}{\sqrt{\text{Var}[y] \cdot \text{Var}[\hat{y}]}} \quad (14)$$

其中, y 为一组真实值, \hat{y} 为一组预测值, y_i 为第 i 个真实值, \hat{y}_i 为第 i 个预测值, s 为测点总数, $\text{Cov}(y, \hat{y})$ 表示协方差, $\text{Var}[y]$ 表示方差.

将工况较平稳变化和工况剧烈变化条件下的 1、2、3、4 号测点的温度实时重构值和测量值的均方根误差、相关系数分别绘制在表 5 中.由表 5 可知, Gappy POD 算法对于强工况条件下数据的重构误差要明显高于弱工况条件下;但是二者的相关系数差异并不明显且均在 0.9 左右,说明无论是强工况条件下的数据还是弱工况条件下的数据, Gappy POD 算法都有较好的趋势预测能力,并且由图 6 和图 7 可以看出,当工况发生改变时, Gappy POD 算法的重构值的变化趋势可以较快的追随测量值的变化趋势,图线的变化趋势具有高度一致性.

同时注意到,测点 3 因为人工引入了随机波动,温度处于实时波动变化中,而 Gappy POD 算法对于测点 3 的重构误差和相关系数相较于测点 1、2 和 4 并未发生显著差异,说明 Gappy POD 算法对

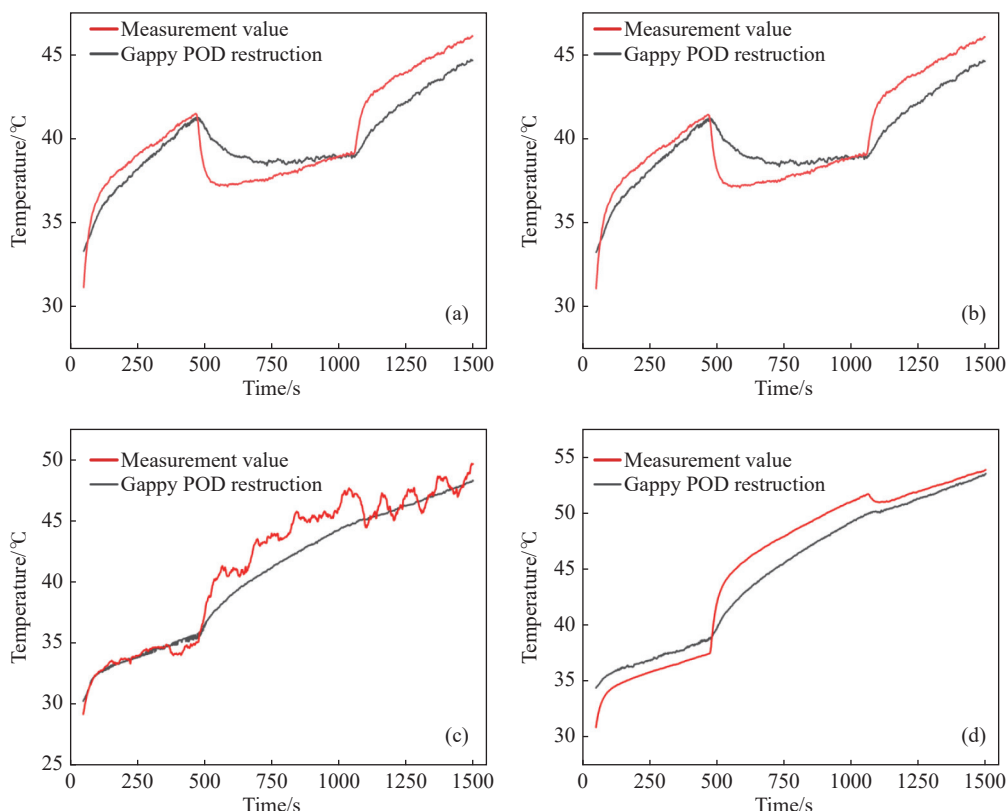


图 6 工况变化平稳条件下 Gappy POD 算法重构值与测量值对比。(a)1 号测点; (b) 2 号测点; (c) 3 号测点; (d) 4 号测点

Fig.6 Comparison of reconstructed and actual values using the Gappy POD algorithm under stable operating conditions at measurement points: (a) point 1; (b) point 2; (c) point 3; (d) point 4

表 4 工况变化剧烈条件下可编程控制电源电压设定

Table 4 Programmable control power supply voltage setting under drastic changes in operating conditions

Programmable control power supply 1's voltage value/V	Programmable control power supply 2's voltage value/V	Experimenta l duration/s
17	20	120
15	18	240
17	25	360
23	24	480
15	25	600
21	16	1500

于被随机噪声干扰的数据也具有较好的重构能力,算法本身具有一定的滤波作用。

在图 7 中我们注意到,在某些时刻以及部分时间段内的重构误差依然较大,为满足算法的工程应用,结合 Gappy POD 算法重构预测的全过程,本文提出了如下的改进方法以进一步提升算法的重构精度:

(1) 选用更高阶的模态进行本征正交分解 (POD), 以使模态系数和正交基底保留更多的数据库特征;

(2) 本文利用最小二乘法最小化重构误差 e 得

到重构模态系数,在数据量较小以及拟合工况较复杂的条件下最小二乘法易发生过拟合导致精度下降,可以通过 L1 正则化最小二乘法以减小过拟合风险。

4 Gappy POD 算法的重构能力与 BP 神经网络预测能力对比

4.1 BP 神经网络对于强波动和弱波动数据的预测能力

BP (Back propagation) 神经网络是一种按照误差反向传播算法训练的多层前馈神经网络,常用于储能电池温度预测中,具有很强的非线性映射能力和柔性的网络结构,适用于复杂的非线性问题,并且可以处理高维数据和含有噪声的数据。为对比说明 Gappy POD 算法的重构预测能力以及算法具有一定的非线性预测能力,利用相同数据库 (间隔 15 s) 训练具有非线性预测能力的 BP 神经网络后,利用神经网络对温度变化进行预测,并与 Gappy POD 算法的重构结果进行对比。

神经网络输入参数为测点 8、10、12 和 13 的实时温度值,输出参数为待预测测点 1、2、3、4 温度。构造具有 4 个输入节点,2 个隐含层每层各分

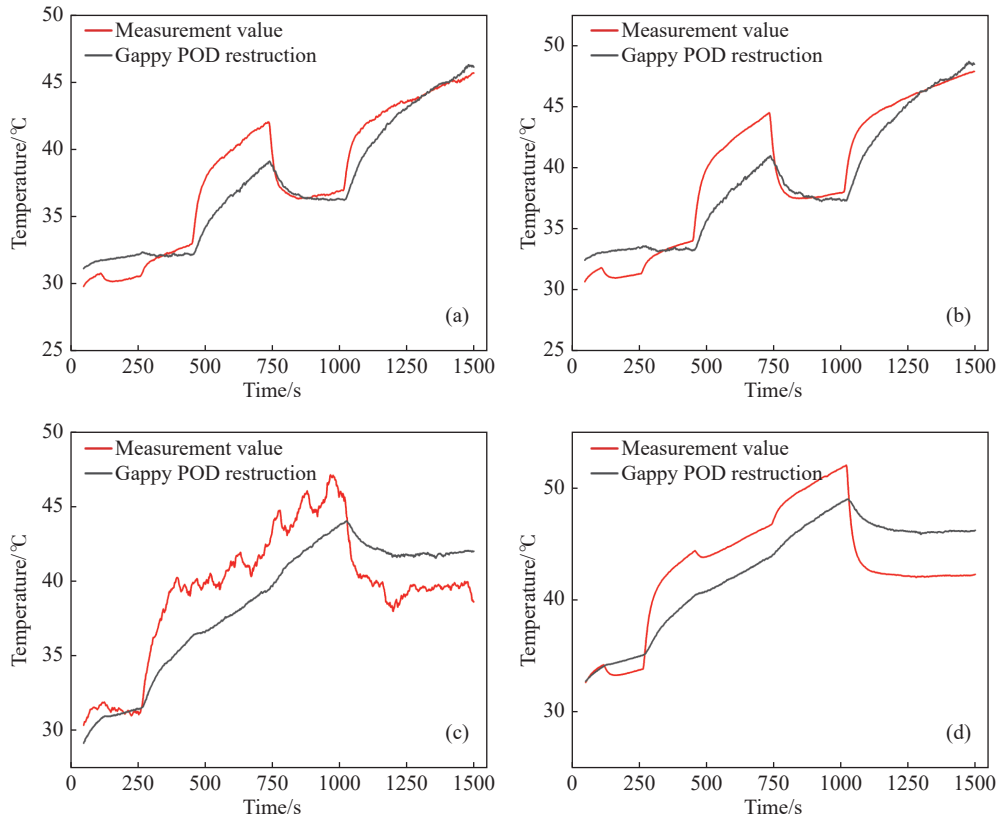


图7 工况变化较剧烈条件下 Gappy POD 算法重构值与测量值对比。(a)1号测点;(b)02号测点;(c)3号测点;(d)4号测点

Fig.7 Comparison of reconstructed and actual values using the Gappy POD algorithm under severe changes in operating conditions at measurement points: (a) point 1; (b) point 2; (c) point 3; (d) point 4

表5 温度实时重构值和测量值的均方根误差、相关系数表

Table 5 RMSE and CCOE for real-time temperature reconstruction and measurement values

Measurement point number	RMSE under stable working conditions	CCOE under stable working conditions	RMSE under drastic working conditions	CCOE under extreme working conditions
1	1.4171	0.9187	1.7707	0.947
2	1.5872	0.8914	2.1238	0.9355
3	1.4782	0.9804	2.6738	0.8253
4	1.6876	0.9822	3.3226	0.7763

布 20 个神经元和 4 个输出节点的神经网络. 训练结束后各项误差如图 8 所示, 设置学习率为 0.0001, 当训练进行至 62 步时候, 训练、校正和测试误差均降至 0.1 以下, 达到精度要求, 训练结束.

利用训练好的神经网络对强工况条件下的测点 1~4 温度数据进行时候预测, 并与 Gappy POD 算法实时重构结果进行对比, 绘制温度变化曲线如图 9 所示. 可以看出 BP 神经网络也具有较好的温升趋势预测能力, 并且 BP 神经网络的预测结果的波动性更强, 对于测点 3 随机波动的温度值具有更强的趋势预测能力. 为定量说明 Gappy POD 算法和 BP 神经网络对于温度值预测的精度和趋势预测能力, 分别计算二者对于弱工况条件下和

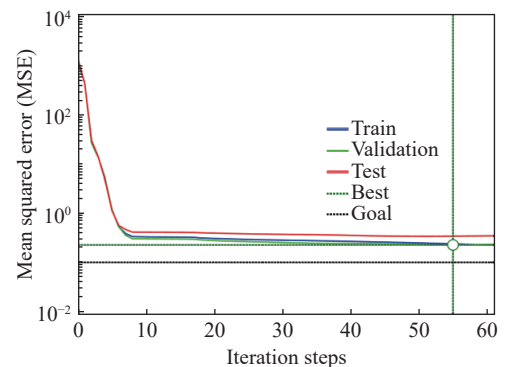


图8 BP 神经网络训练结果

Fig.8 Training results of the BP neural network

强工况条件下测点的预测值和实际测量值的均方根误差(Root mean square error, RMSE)和相关系数

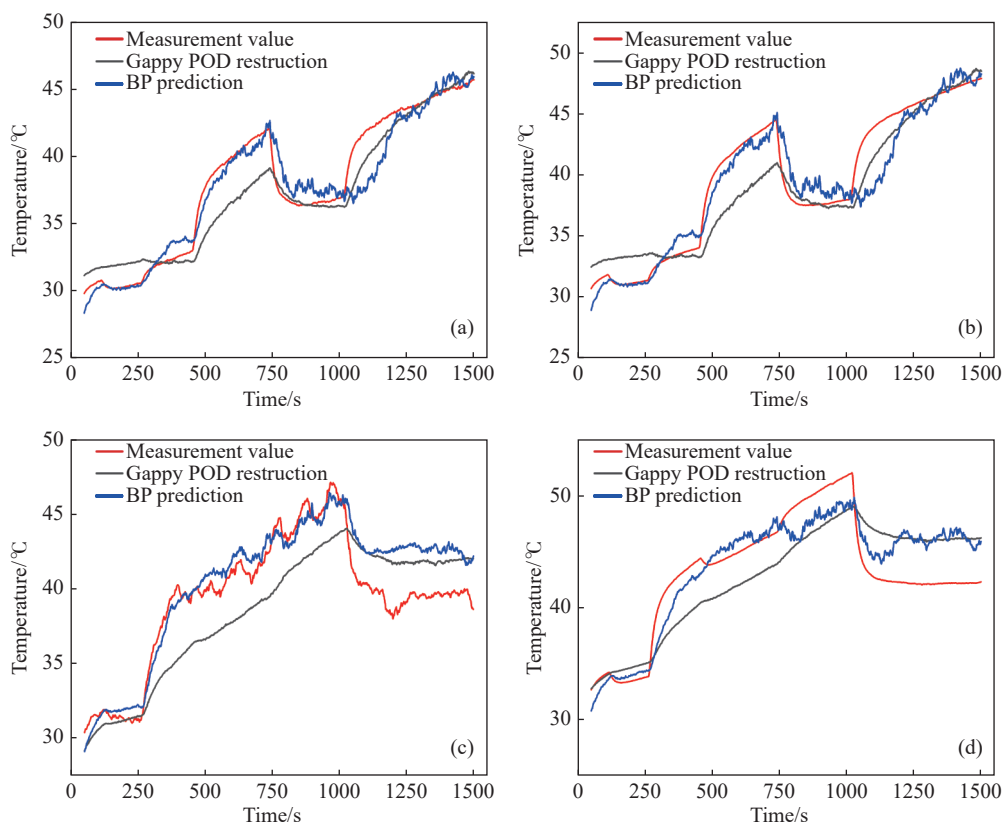


图9 工况剧烈变化条件下神经网络、Gappy POD 重构和测量值对比。(a)1号测点;(b)2号测点;(c)3号测点;(d)4号测点

Fig.9 Neural network, Gap POD reconstruction, and comparison of measured values under severe changes in operating conditions at measurement points: (a) point 1; (b) point 2; (c) point 3; (d) point 4

(Correlation coefficient, CCOE), 制成表6和表7。

由表6和表7可以看出,在弱工况条件下,Gappy POD算法的RMSE值要明显小于BP神经网络的,表明Gappy POD在弱工况条件下具有更高的重构

预测精度;而二者的CCOE值均在0.9左右,表明Gappy POD算法和BP神经网络都具有良好的趋势预测能力.而在强工况条件下,Gappy POD算法的重构误差要略高于BP神经网络的预测误差,且

表6 BP神经网络和Gappy POD算法对于工况平稳变化条件下数据的重构预测能力

Table 6 The reconstruction and prediction ability of the BP neural network and Gappy POD algorithm for data under stable changes in operating conditions

Measurement point number	Gappy POD RMSE	Gappy POD CCOE	BP RMSE	BP CCOE
1	1.3171	0.9187	1.3965	0.9618
2	1.5872	0.8914	1.7061	0.9532
3	1.4782	0.9804	1.8717	0.9355
4	1.6876	0.9822	2.4446	0.8884

表7 BP神经网络和Gappy POD算法对于工况剧烈变化条件下数据的重构预测能力

Table 7 The reconstruction and prediction abilities of the BP neural network and Gappy POD algorithm for data under drastic changes in operating conditions

Measurement point number	Gappy POD RMSE	Gappy POD CCOE	BP RMSE	BP CCOE
1	1.7707	0.947	1.3965	0.9618
2	2.1238	0.9355	1.7061	0.9532
3	2.6738	0.8253	1.8717	0.9355
4	3.3226	0.7763	2.4446	0.8884

Gappy POD 算法对于测点 4 的重构温度和实时测量值的相关系数 (CCOE) 低于 0.8, 表明在强波动条件下 Gappy POD 算法的趋势预测能力有所降低.

4.2 数据库大小对于 Gappy POD 及神经网络预测能力影响

神经网络的预测能力依赖于数据库的大小. 为探究数据库的大小对 Gappy POD 算法的重构能力和 BP 神经网络的预测能力的影响, 从未处理数据中分别间隔 15、30、60、100、200 以及 400 s 提取数据构成不同大小的数据库. 分别利用不同大小的数据库训练 Gappy POD 算法和 BP 神经网络并对弱工况和强工况条件下温度值实时重构, 得到实时重构预测数据和测量数据的 RMSE 和 CCOE 如图 10 和图 11 所示.

由图 10 和图 11 可知, 随着数据库中数量的减小, 弱工况条件下 Gappy POD 算法和 BP 神经网络的预测误差均有所升高, 对于趋势的预测能力均

有不同程度的降低; 而在强工况条件下, Gappy POD 算法的重构精度和趋势能力受数据库大小的影响较小, 甚至随着数据库中数据的减小重构能力有小幅度的提升. 综合图 10 和图 11 分析知, BP 神经网络的预测能力受数据库中数据量的大小影响较大, 而 Gappy POD 算法受数据库大小影响较小, 具体表现为图中双划线的波动幅度较大而实线几乎没有明显的波动; 在弱工况条件下, Gappy POD 算法在重构精度和趋势预测能力方面均优于 BP 神经网络; 在强工况条件下, 当数据库中数据量较大时, BP 神经网络的预测精度和趋势预测能力均优于 Gappy POD 算法, 但随着数据库中数据量的减少, BP 神经网络的预测误差显著增大而趋势预测能力也有较明显的下降, 而 Gappy POD 算法的重构能力受数据库大小影响几乎不发生变化, 这也显示了 Gappy POD 算法在小样本数据库的条件下的预测重构能力的优越性.

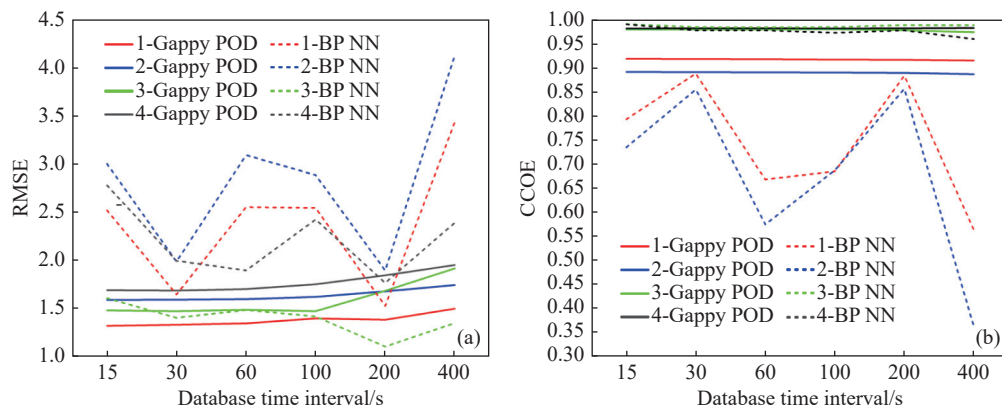


图 10 工况平稳变化条件下, 基于不同大小的数据库训练的 Gappy POD 算法和 BP 神经网络重构值与实际值的均方根误差和相关系数变化. (a) 均方根误差变化; (b) 相关系数变化

Fig.10 Changes in RMSE and CCOE between reconstructed values and actual values for the Gappy POD algorithm and BP neural network trained on databases of different sizes under stable operating conditions: (a) root mean square error; (b) correlation coefficient




图 11 工况剧烈变化条件下, 基于不同大小的数据库训练的 Gappy POD 算法和 BP 神经网络重构值与实际值的均方根误差和相关系数变化. (a) 均方根误差变化; (b) 相关系数变化

Fig.11 Changes in RMSE and CCOE between reconstructed values and actual values for the Gappy POD algorithm and BP neural network trained on databases of different sizes under drastic changes in operating conditions: (a) root mean square error; (b) correlation coefficient

5 结论

本文通过搭建拟储能电池发热实验台, 评估了 Gappy POD 算法在储能电池温度场重构中的效果. 研究分别在工况平稳变化和工况剧烈变化条件下, 测试了 Gappy POD 算法的重构能力, 并与 BP 神经网络进行了比较. 此外, 还讨论了数据库大小对 BP 神经网络预测能力和 Gappy POD 算法重构能力的影响, 并得到以下结论:

(1) Gappy POD 算法在工况平稳变化和工况剧烈变化条件下均有较好的重构精度和趋势预测能力, 并且该算法对于被随机噪声干扰的数据也具有较好的重构能力, 算法的稳定性较强;

(2) 相较于 BP 神经网络, Gappy POD 算法在工况平稳变化条件下具有更高的重构精度, 而工况变化剧烈条件下 Gappy POD 算法的重构精度有所降低; BP 神经网络和 Gappy POD 算法均具有较强的趋势预测能力, 可以实时重构温度值并反映温度值波动和温度变化趋势;

(3) BP 神经网络的预测能力对数据库数据量的大小更为敏感, 而 Gappy POD 算法受数据库中数据量大小影响较小, 尤其在小样本数据库条件下, Gappy POD 算法的重构能力相较于 BP 神经网络具有较大的优势.

本文用加热棒代替储能电池单体进行发热实验以测试 Gappy POD 算法的重构能力, 尽管本文引入了随机电压波动等增强系统的非线性度, 但相比于真实的电池系统, 该拟储能电池温升实验台的非线性依然偏弱. 下一步将利用真实电池的 HPPC 测试数据等以及电容器、电阻元件和控制芯片等器件制作数字拟态电池电路板, 配合加热棒以更准确的模拟储能电池的充放电过程中的温度变化情况, 提高系统的非线性度并测试 Gappy POD 算法的重构能力.

参 考 文 献

- [1] Luo X, Wang J H, Dooner M, et al. Overview of current development in electrical energy storage technologies and the application potential in power system operation. *Appl Energy*, 2015, 137: 511
- [2] Feng X N, Ouyang M G, Liu X, et al. Thermal runaway mechanism of lithium ion battery for electric vehicles: A review. *Energy Storage Mater*, 2018, 10: 246
- [3] Zhong G B, Wang Y P, Wang C, et al. The review of thermal management technology for large-scale lithium-ion battery energy storage system. *Energy Storage Sci Technol*, 2018, 7(2): 203
- [4] Jiang S S, He Z J, Wen H. Analysis of electro-thermal model and simulation on temperature field for lithium-ion battery. *J Therm Sci Technol*, 2018, 17(3): 238
(姜水生, 何志坚, 文华. 锂离子电池电-热耦合模型分析及其温度场仿真研究. *热科学与技术*, 2018, 17(3): 238)
- [5] Xiao X, Tian P G, Yu L, et al. Status and prospect of safety studies of cascade power battery energy storage system. *J Electr Eng*, 2022, 17(1): 206
(肖曦, 田培根, 于璐, 等. 动力电池梯次利用储能系统电热安全研究现状及展望. *电气工程学报*, 2022, 17(1): 206)
- [6] Hu X S, Li S E, Yang Y L. Advanced machine learning approach for lithium-ion battery state estimation in electric vehicles. *IEEE Trans Transp Electrif*, 2016, 2(2): 140
- [7] Zhu D C, Wang X C. Research on optimal design of air cooling and heat dissipation of energy storage battery module. *Chin J Power Sources*, 2022, 46(5): 523
(祝德春, 王新春. 储能电池模组的风冷散热优化设计研究. *电源技术*, 2022, 46(5): 523)
- [8] Zhang S C, Shen Z Y, Lu Y Y. Research progress of thermal runaway and safety for lithium metal batteries. *Acta Phys Chim Sin*, 2021, 37(1): 55
(张世超, 沈泽宇, 陆盈盈. 金属锂电池的热失控与安全性研究进展. *物理化学学报*, 2021, 37(1): 55)
- [9] Zhu X Q, Wang Z P, Hsin W, et al. Review of thermal runaway and safety management for lithium-ion traction batteries in electric vehicles. *J Mech Eng*, 2020, 56(14): 91
(朱晓庆, 王震坡, WANG Hsin, 等. 锂离子动力电池热失控与安全研究综述. *机械工程学报*, 2020, 56(14): 91)
- [10] Debert M, Colin G, Bloch G, et al. An observer looks at the cell temperature in automotive battery packs. *Contr Eng Pract*, 2013, 21(8): 1035
- [11] Lin X F, Perez H E, Siegel J B, et al. Online parameterization of lumped thermal dynamics in cylindrical lithium ion batteries for core temperature estimation and health monitoring. *IEEE Trans Contr Syst Technol*, 2013, 21(5): 1745
- [12] Sun J L, Wei G, Pei L, et al. Online internal temperature estimation for lithium-ion batteries based on Kalman filter. *Energies*, 2015, 8(5): 4400
- [13] Richardson R R, Ireland P T, Howey D A. Battery internal temperature estimation by combined impedance and surface temperature measurement. *J Power Sources*, 2014, 265: 254
- [14] Gomadam P M, White R E, Weidner J W. Modeling heat conduction in spiral geometries. *J Electrochem Soc*, 2003, 150(10): A1339
- [15] Kim G H, Pesaran A, Spotnitz R. A three-dimensional thermal abuse model for lithium-ion cells. *J Power Sources*, 2007, 170(2): 476
- [16] Zhao Z K, Han X J, Ma H M. Capacity fade prediction model of battery energy storage system based on BP neural network. *Electr*

- Energy Manag Technol*, 2016(19): 68
(赵泽昆, 韩晓娟, 马会萌. 基于 BP 神经网络的储能电池衰减容量预测. *电器与能效管理技术*, 2016(19): 68)
- [17] Li X G, Yuan J Y, Wang W C. Multi-objective optimization of battery pack liquid cooling structure based on uniform design. *Electron Meas Technol*, 2022, 45(13): 33
(李昕光, 元佳宇, 王文超. 基于均匀设计的电池组液冷结构多目标优化. *电子测量技术*, 2022, 45(13): 33)
- [18] Chen S, Fang K Z, Mu D B, et al. Application of neural network model to predicting surface temperature of lithium-ion battery. *Trans Beijing Inst Technol*, 2013, 33(4): 421
(陈实, 方凯正, 穆道斌, 等. 神经网络模型在锂离子电池表面温度预测中的应用研究. *北京理工大学学报*, 2013, 33(4): 421)
- [19] Liu Z, Wang M C, Li J J, et al. Reduced order aerodynamic model of wake excited blade based on POD. *J Ordnance Equip Eng*, 2021, 42(2): 82
(刘钊, 王沐晨, 李金玖, 等. 基于 POD 的尾流激励叶片气动降阶模型. *兵器装备工程学报*, 2021, 42(2): 82)
- [20] Ma H H, Zheng X, Wang Y, et al. POD analysis and low-dimensional model based on POD-galerkin for two-dimensional rayleigh-Bénard convection. *J Harbin Inst Technol*, 2018, 25(1): 67
- [21] Kerschen G, Golinval J C, Vakakis A F, et al. The method of proper orthogonal decomposition for dynamical characterization and order reduction of mechanical systems: An overview. *Nonlinear Dyn*, 2005, 41(1): 147
- [22] Cao Y H, Zhu J A, Luo Z D, et al. Reduced-order modeling of the upper tropical Pacific Ocean model using proper orthogonal decomposition. *Comput Math Appl*, 2006, 52(8-9): 1373
- [23] Everson R, Sirovich L. Karhunen-Loève procedure for gappy data. *J Opt Soc Am A*, 1995, 12(8): 1657
- [24] Li J, Zhang W W. Gappy proper orthogonal decomposition for flow data reconstruction. *Phys Gases*, 2020, 5(4): 1
(李静, 张伟伟. 基于 Gappy POD 的流场数据填补方法. *气体物理*, 2020, 5(4): 1)
- [25] Li T Y, Buzzicotti M, Biferale L, et al. Reconstruction of turbulent data with gappy pod method. *Chin J Theor Appl Mech*, 2021, 53(10): 2703
(李天一, Buzzicotti M, Biferale L, 等. Gappy POD 方法重构湍流数据的研究. *力学学报*, 2021, 53(10): 2703)
- [26] Luo Y, Qian J, Wang Y G, et al. Reconstructing the temperature field from a small amount of measured data based on Gappy POD algorithm. *Intell Comput Appl*, 2022, 12(5): 154
(罗芸, 钱进, 王一桂, 等. 基于降维算法从少量测量数据中重构温度场. *智能计算机与应用*, 2022, 12(5): 154)
- [27] Sirovich L. Turbulence and the dynamics of coherent structures. I. *Coherent structures. Quart Appl Math*, 1987, 45(3): 561