

DOI: 10.19650/j.cnki.cjsi.J2412376

随机工况下基于改进 ANFIS 的锂电池容量衰减实时估计

刘彤宇¹, 陆起涌^{1,2}, 李旦^{1,2}, 张建秋¹, 王开钊¹

(1. 复旦大学电子工程系 上海 200433; 2. 复旦大学义乌研究院 义乌 322001)

摘要: 锂电池容量的衰减会影响其安全性和稳定性, 准确的容量估计能够帮助用户进行更好的决策。目前, 广泛使用的黑盒数据驱动模型因其不可解释性很难被应用于安全相关的领域中, 并且大多方法都基于固定工况进行特征提取, 对具有随机性的实际工况不具有普适性。因此, 本文构建了一种基于随机工况数据的改进自适应模糊神经网络推理系统 (ANFIS)。首先分析了容量衰减的影响因素, 据此从电池监测数据中提取和筛选健康特征; 其次系统内部利用激活机制简化系统结构, 并引入衰减系数更好地拟合电池单体特性; 然后通过自适应粒子滤波算法优化模糊聚类中心; 最后使用 NASA 随机工况数据集验证了该系统的有效性, 其容量估计 RMSE 为 3.73%。与其他方法相比, 本文提出的方法结果精度更高且具有一定的可解释性。

关键词: 锂电池; 模糊推理系统; 容量估计; 可解释性

中图分类号: TH165 TM911 **文献标识码:** A **国家标准学科分类代码:** 510.40

Real-time estimation of lithium battery capacity degradation based on an improved neural fuzzy inference system under random operating conditions

Liu Tongyu¹, Lu Qiyong^{1,2}, Li Dan^{1,2}, Zhang Jianqiu¹, Wang Kaiyin¹

(1. Department of Electronic Engineering, Fudan University, Shanghai 200433, China;

2. Yiwu Research Institute, Fudan University, Yiwu 322001, China)

Abstract: The decline in lithium battery capacity can compromise its safety and stability, emphasizing the importance of accurate capacity estimation for better decision-making. However, prevailing black-box data-driven models face challenges in safety-critical applications due to their lack of interpretability. Additionally, these models often rely on fixed operating conditions for feature extraction, limiting their suitability for real-world scenarios with variable conditions. To address these issues, this paper presents an enhanced adaptive neural fuzzy inference system (ANFIS) designed to accommodate random operating conditions. Firstly, the factors influencing capacity degradation are analyzed, and relevant features are extracted and refined from battery measurement data. Subsequently, an activation mechanism simplifies the system structure, while an attenuation coefficient is introduced to tailor the model to battery cell characteristics. Further refinement is achieved through continuous optimization of fuzzy clustering centers using an adaptive particle filter algorithm. Validation of the system is conducted using the NASA random walk battery dataset, resulting in a capacity estimation root mean square error (RMSE) of 3.73%. Comparative analysis demonstrates that the proposed system offers superior accuracy and a degree of interpretability when contrasted with other methods.

Keywords: Lithium-ion battery; fuzzy inference system; capacity estimation; interpretability

0 引言

随着以可再生能源取代化石燃料发电的全球趋势, 开发可靠的储能系统已成为全球优先考虑的问题。锂电

池具有寿命长、能量密度高、重量轻、自放电率低等优点, 已经取代了铅酸电池、镍氢电池、镍镉电池等其他类型的电池^[1-2], 并应用于各种领域, 如电动汽车、手机、笔记本电脑和其他消费电子产品。但是, 锂电池的性能会随着反复的充放电循环而不断降低。当电池容量退化到一定

程度时,电池的性能就会不稳定。因此,准确估计锂电池容量是保证锂电池安全使用和评估电池剩余电量的必要条件^[3]。

由于锂电池老化过程缓慢,且老化状态受到复杂因素的影响,其衰减曲线难以跟踪。现有的研究方法主要可以分为基于模型的方法和数据驱动的方法。基于模型的方法根据锂电池的物理化学特性建立,包括经验模型^[4-5]、等效电路模型^[6]和电化学模型^[7]。一般来说,这些模型需要大量的实验来将多种环境因素考虑在内。然而,由于锂电池内部复杂的反应和多变的应用环境,这些参数很难确定,使得电池容量估计不准确。随着电池数据存储技术的发展,数据驱动跟踪电池退化的方法得到了广泛的研究。这些方法不依赖于物理模型,可以将输入特征非线性地映射到输出,包括支持向量机^[8-9]、人工神经网络^[10-11]、高斯过程回归^[12]和模糊系统^[13-17]等。尽管这些数据驱动的方法有很大的前景,但对可解释性问题的担忧已经被频繁提出。大多数数据驱动的方法都是黑盒模型,其中有大量物理意义不明确的超参数,即使是专家也很难解释其中的意义,导致这些方法很难被应用到安全相关的领域中。而基于规则的模糊系统可以模仿人类的推理过程,灵活地整合数据信息和描述信息,从而尽可能准确地建立输入与输出之间的非线性映射关系。模糊系统的最简约模糊划分、完备-清晰性、紧凑型 and 一致性^[18]使得其模型结构和参数具有较强的可解释性,为用户提供了便利。

在锂电池这样复杂的非线性系统中很难直接通过专家知识确定可靠的模糊规则和隶属函数。因此,可以将模糊逻辑和神经网络相结合,通过数据自适应地确定规则参数,即自适应模糊神经网络推理系统(adaptive neural fuzzy inference system, ANFIS)^[19]。ANFIS 具有较好的非线性拟合能力,广泛应用于回归问题、非线性建模和函数逼近问题当中。

目前为止,已经有一些论文使用模糊系统估计电池的容量老化情况。Zenati 等^[13]将电流与温度作为系统输入,利用专家知识直接构建模糊推理系统。Chen 等^[14]采用周期数、充满电后的静置电压、长时间静置后的内阻作为输入量,采用 T-S 模糊控制建立容量估计模型。Hou 等^[15]采集了恒流充电过程中工作电压的变化率,建立了电压变化率曲线位置与循环次数间的关系,对锂电池容量进行估计。这些研究主要基于固定的工况进行健康特征的提取,然后映射到容量上。这样基于特定条件下的特征提取过程无需考虑复杂的运行工况,有时能够取得良好的估计效果,但不能适用于所有的工况。此外,还有研究将电池的容量退化数据作为流数据,基于模糊系统使用历史容量预测未来容量^[16-17]。但这类方法忽略了电池在实际使用过程中不同运行条件对电池容量衰减的

影响。总体来说,锂电池在实际使用过程中,受到使用者不同操作、不同环境状态等因素的影响,每次循环过程中的工况都是随机的,在这种情况下,很多现有方法无法对锂电池容量衰减进行实时的估计。而随机工况下提取的健康特征更加贴近电池的实际使用情况,因此更能反映电池在不同环境下的实际性能。

考虑到锂电池容量估计算法在实际工况下的可用性和可靠性,本文提出了随机工况下基于改进 ANFIS 的锂电池容量估计的新方法。基于随机工况的特点使得本文方法具有实时性,无需等待电池循环至某个特定工况下进行特征提取和估计。而 ANFIS 透明的规则结构能够帮助识别电池中的关键老化机制和参数变化,这对于安全稳定地使用锂电池、指导用户的使用和决策十分重要。

因此,本文分析了影响锂电池容量衰减的因素并从中提取适用于任意充放电工况下的特征,基于改进的 ANFIS 建立了特征与容量变化的映射关系,最后利用 NASA 随机数据集对本系统进行了验证。

1 锂电池老化特性分析及特征提取

1.1 容量老化特性

锂电池容量衰减受到多种因素的影响,这些因素相互耦合导致锂电池的退化表现出很强的非线性及不确定性。其中充放电电流倍率、温度、累积安培小时吞吐量等反映了电池的循环老化特性,累积时间反映了电池的日历老化特性^[20]。

然而,即使是同一批电池在上述老化工况都相同的情况下,容量衰减速度也是不相同的,如图 1 中 NASA 固定工况数据集下 4 个电池衰减曲线所示。因此为了表征每个单体电池的个体差异性,后文在模糊系统中引入了衰减系数。




图 1 NASA 固定工况数据集容量衰减曲线

Fig. 1 Capacity decay curve of NASA fixed condition dataset

此外,在锂电池老化过程中,锂电池的容量并不总是减少,时常会发生容量再生现象。很多研究^[17]认为容量

再生是随机的,使用经验模态分解等信号分解方法直接将其进行分解,然后通过时间序列预测的方法对这种突变进行预测。但深入探究 NASA 数据后,可以发现这种再生很大程度上与锂电池的休息时间相关,容量再生的时间节点与容量测量时间间隔较大的时间节点是一致的^[21],如图 2 所示。在实际工况下,可以根据容量测量时间间隔和电流、吞吐量粗略推测出休息时间。因此,在最终的容量衰减估计中,提取锂电池容量测试时间间隔作为输入特征。




图 2 容量再生现象与测试时间间隔之间的关系

Fig. 2 Relationship between capacity regeneration phenomenon and test interval

1.2 特征提取

本文全面地考虑了影响锂电池容量衰减和再生的因素,以更好地捕捉随机工况下锂电池的老化情况。随机工况下的测量数据是时变的,数据量庞大,因此需要对其进行统计处理^[22-23]。从数据集中提取每两次参考容量测试时的实测充放电电流、温度、吞吐量、累积时间、测试时间间隔等数据,从中计算平均值、方差、范围等作为可选特征。根据每个特征与系统输出(容量变化)之间的 Spearman 相关系数选择生成的特征,表示为

$$Spearman = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (1)$$

式中: d_i 表示第 i 个数据对的位次值之差, n 为总的观测样本数。Spearman 相关系数绝对值越大,表明相关程度越高。考虑到系统的复杂性,需要在保证结果准确性的同时,选择尽量少的变量输入,因此选取相关系数较大的特征作为最终的系统输入。

2 改进的 ANFIS 锂电池估计模型

2.1 传统的 ANFIS

ANFIS 结合了模糊系统的语言推理能力和神经网络的学习机制,具有便捷高效的特点。系统中使用多条模糊规则描述系统输出与输入之间的映射关系,并且可以

通过数据集进行模糊规则的自适应调整。模糊推理规则为 Takagi-Sugeno 类型,可以描述为:

$$\text{Rule } j: \text{If } (x_1 \text{ is } A_1^j) \text{ and } (x_2 \text{ is } A_2^j) \cdots \text{ and } (x_n \text{ is } A_n^j) \\ \text{then } f_j = a_0^j + a_1^j x_1 + a_2^j x_2 + \cdots + a_n^j x_n \quad (2)$$

式中: x_n 为系统输入, A_n^j 为模糊集的语言变量, f_j 为第 j 条模糊规则, $j \in [1, R]$, R 为规则总数。该系统由一个五层模糊神经网络组成,结构如图 3 所示。




图 3 传统的 ANFIS 结构

Fig. 3 Classical ANFIS structure

系统中每层的功能如下:

1) 模糊化层:使用模糊化过程将每个输入转换为模糊隶属度值,利用高斯隶属度函数将输入转换为语言变量。第 j 条规则对应的输入 x_i 的隶属度值计算为:

$$u_{A_i^j} = \exp\left(-\frac{(x_i - m_{ij})^2}{2\sigma_{ij}^2}\right) \quad (3)$$

其中, m_{ij} 和 σ_{ij} 分别是隶属函数的中心和标准差。

2) 规则激活层:将每个输入维度的隶属度值相乘得到第 j 条规则的发射强度,则第 j 条规则对应的发射强度为:

$$w_j = \prod_{i=1}^n u_{A_i^j} \quad (4)$$

3) 归一化层:使用标准归一化技术对 R 条规则的发射强度进行归一化,计算为:

$$\bar{w}_j = \frac{w_j}{\sum_{j=1}^R w_j} \quad (5)$$

4) 去模糊化层:每条规则对应一个函数的计算结果,由输入变量通过线性方程组合,计算为:

$$f_j = a_0^j + a_1^j x_1 + a_2^j x_2 + \cdots + a_n^j x_n \quad (6)$$

5) 输出层:最终的系统输出是各规则结果的加权平均,计算为:

$$\hat{y} = \sum_{j=1}^R \bar{w}_j f_j \quad (7)$$

2.2 改进的 ANFIS

ANFIS 通过输入域的网格划分直观地定义规则,对于具有 d 维输入、每个维度输入包含 n 个隶属函数的系统来说,共需建立 n^d 条模糊规则。输入数据每增加一个

维度,模糊规则就会大量增加,使系统结构变得复杂。在锂电池容量估计的研究中,数据集中的数据量较小,以本文中使用的 NASA 数据集为例,每个锂电池单体在全生命周期中只进行了几十次参考容量测量,生成对应的几十个数据点。而过于复杂的系统结构会产生大量的待估计参数,并且会增加系统过拟合的风险。因此,为了简化系统结构、提升系统的估计精度,本文对 ANFIS 结构进行了改进,如图 4 所示。




图 4 改进的 ANFIS 结构
Fig. 4 Improved ANFIS structure

根据提取特征与输出的相关系数进行筛选可以有效地减少输入的数量,从而简化系统结构。然而,即使使用了尽量少的特征和模糊隶属度函数,一个完全连接的 ANFIS 依旧会生成大量的规则,每次估计都要涉及所有模糊规则来提供系统的输出,并且对所有规则参数进行更新,即使是对输出贡献很小的规则,这大大增加了不必要的计算量。因此本文引入了激活机制^[24],在保证估计精度的基础上,减少了每次估计过程中模糊规则的使用数量。对于每个输入样本并不计算所有的规则,而是有选择性地只激活能够描述样本主要变化特性的部分规则,并且也只对这些规则的后验参数进行更新。将不同规则下的发射强度从大到小进行排序,重新记为 $w_1^*(x_k), w_2^*(x_k), \dots, w_R^*(x_k)$ ($w_1^*(x_k) \geq w_2^*(x_k) \geq \dots \geq w_R^*(x_k)$)。前 N_k^* 条激活的模糊规则可以定义为:

$$N_k^* = \operatorname{argmin}_{n=1,2,\dots,R} \left(\sum_{i=1}^n w_i^*(x_k) > \gamma_0 \sum_{i=1}^R w_i(x_k) \right) \quad (8)$$

其中,取 $\gamma_0 = 0.9$ 。系统输出定义为部分激活规则的加权和,即:

$$y = \sum_{j=1}^{N_k^*} w_j f_j \quad (9)$$

该激活机制简化了系统结构,减少了与样本相关性较小规则的不必要计算,降低了系统计算复杂度。

此外,根据前文中对锂电池老化特性的分析,除了温度、充放电倍率等通用的影响因素外,锂电池还可能由于其生产工艺等因素造成不同的老化路径,因此本文在模型输出部分加入了衰减系数拟合的过程,用来表征不同单体电池的个性化特征。该衰减系数能够将电池单体的

电化学特性以及其他影响因素考虑在内,能够使系统更好涵盖广泛的复杂条件,在特定环境下及时更新模型,保证模型的准确性。

2.3 参数优化方法

对 ANFIS 进行参数优化,主要包括对前提参数(即隶属函数参数)和后件参数(即规则参数和衰减系数)的学习更新。

1) 优化前提参数

隶属度函数的选取直接决定了模型输入空间的划分,决定隶属度函数的参数需要通过学习来确定。传统的 ANFIS 使用的梯度下降法虽然可以有效地减小误差函数,但由于它不具有凸性,因此很容易导致局部最优解的出现。为了解决这一挑战,本文采用粒子滤波(particle filter, PF)算法自适应地优化模糊聚类中心,进一步提高估计精度。

PF 依靠蒙特卡罗模拟来近似状态的统计分布,根据观测值不断调整粒子的权重和位置,不断修正系统的经验条件分布。本文中系统的动态状态空间模型和测量模型分别可以写作:

$$m_j = f(c_j, u_k) \quad (10)$$

$$Y_k = h_k(m_j, v_k) \quad (11)$$

其中, m_j 是待估计隐藏状态,即聚类中心 c_j 的最优位置, Y_k 是真实输出。 h_k 函数为本文提出的模糊系统, u_k 和 v_k 指随机噪声。随着样本的输入,PF 对系统输入空间的分布进行估计,并据此确定模糊聚类中心的最优位置。

但在标准的 PF 算法中,由于样本退化,难以正确表征估计的后验概率密度函数的高似然区域。而重采样技术的计算量较大,并且会造成粒子的匮乏。因此本文选择了一个自适应的 PF^[16] 来优化系统。为了减少计算量,系统中在每个训练周期中更新使用频率较高的规则中心,并且从后验概率密度函数的高概率区域导出粒子。

状态的后验概率密度函数可以用 T 个粒子 $\{m_j^1, m_j^2, \dots\}$ 表示。关联的权重 $\{\pi_i^1, \pi_i^2, \dots\}$ 将根据每个粒子相对于目标输出的条件似然计算, k 时刻的后验密度可以近似为:

$$P(m_j | Y_k) \approx \sum_{i=1}^T \pi_i^k \delta(m_j - m_j^i) \quad (12)$$

粒子可以导出为:

$$m_j^i = c_{best} + \lambda \quad (13)$$

其中, λ 为粒子的取值范围,它将在每个循环中以指数方式收缩,从而确定最终的规则中心。计算出粒子的权重 π_j^i 后,如果 $\pi_j^i > \pi_{best}$, 则使用权重最高的粒子值更新模糊聚类中心。这样的调整方式可以确保模型进行的更新是必要的,能够实现更好的性能,保证较高的计算效率。

2) 优化后件参数

模糊规则的函数计算参数和衰减系数可分别使用递归最小二乘法和梯度下降法进行更新。系统的输出的误差可以表示为:

$$f(\alpha, \theta) = \frac{1}{2} \alpha \|X\theta - Y\|^2 \quad (14)$$

其中, α 为衰减系数, θ 为规则的线性参数向量, X 为模糊推理运算的结果矩阵, Y 为系统参考输出。

规则的线性参数递归更新如下:

$$\hat{\theta}_k = \hat{\theta}_{k-1} + C_k X^T (y_k - \alpha X \hat{\theta}_{k-1}) \quad (15)$$

$$C_k = C_{k-1} - \frac{C_{k-1} X^T X C_{k-1}}{1 + X C_{k-1} X^T} \quad (16)$$

衰减系数沿梯度更新为:

$$\frac{\partial f(\alpha, \theta)}{\partial \alpha} = \alpha \theta^T X^T X \theta - \frac{1}{2} \theta^T X^T Y - \frac{1}{2} Y^T X \theta \quad (17)$$

$$\alpha' = \alpha - \eta \frac{\partial f(\alpha, \theta)}{\partial \alpha} \quad (18)$$

其中, η 为学习率, 本文取 $\eta = 0.05$ 。对于每个输入样本, 规则的线性参数都进行更新。而对于衰减系数, 为了避免梯度时变, 无法收敛的问题, 对于每个电池单体, 每批使用 20% 的样本对衰减系数进行更新。

2.4 系统框架

将数据集分为训练集和测试集, 根据训练集中提取特征的相关系数确定系统输入的个数, 并对 ANFIS 内部的模糊规则参数进行更新。测试时从随机工况下的运行数据中提取相应特征, 并通过初期(前 20%)的数据自适

应地拟合衰减系数, 从而实现锂电池容量的估计, 系统框架如图 5 所示。

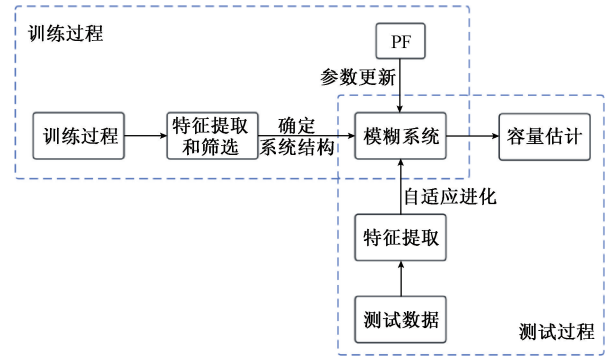


图5 容量估计流程

Fig. 5 Process of capacity estimation

3 实验结果及讨论

3.1 NASA 随机工况数据集

艾姆斯研究中心发布了 NASA 随机工况数据集, 该数据集被广泛应用于电池容量退化的研究。数据集中包含 28 个 LiFePO₄ 电池, 并根据随机条件分为 7 组。每组之间在温度、随机电流工况和容量测量间隔等方面各有差异。各组具体情况如表 1 所示, 随机电流工况样例如图 6 所示。

表 1 NASA 随机数据集不同组别的加载工况

Table 1 Loading conditions of NASA random dataset

组别	电池	温度	随机电流	容量测量间隔
1	RW1, RW2, RW7, RW8	25℃	0.5~4 A 随机放电	50 次循环
2	RW3, RW4, RW5, RW6	25℃	0.5~4 A 随机放电, 随机充电时长	50 次循环
3	RW9, RW10, RW11, RW12	25℃	-4.5~4.5 A 随机放电	1 500 次循环
4	RW13, RW14, RW15, RW16	25℃	0.5~5 A 随机放电(概率偏向小电流)	50 次循环
5	RW17, RW18, RW19, RW20	25℃	0.5~5 A 随机放电(概率偏向大电流)	50 次循环
6	RW21, RW22, RW23, RW24	40℃	0.5~5 A 随机放电(概率偏向小电流)	50 次循环
7	RW25, RW26, RW27, RW28	40℃	0.5~5 A 随机放电(概率偏向大电流)	50 次循环

3.2 特征提取

对于 NASA 数据集, 提取放电电流平均值、放电电流方差、充电电流平均值、充电电流方差、温度平均值、温度方差、温度范围、容量测量时间间隔、吞吐量、累计时间作为特征 HI1~HI10。为了消除不同特征之间量纲的影响, 将提取到的特征进行归一化, 使特征值映射到 [0, 1] 之

间, 转换函数为:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (19)$$

需要注意的是, 对于测试时间间隔这个特性, 考虑到锂电池内部充放电反应后短时间内才会有较大的容量回升, 回升一定程度之后静置过长时间容量不再有明显提




图 6 NASA 随机数据集电流加载工况

Fig. 6 Current loading conditions of NASA random dataset

表 2 NASA 随机数据集的特征及其相关系数


Table 2 Features and correlation coefficients of NASA random dataset

特征	HI1	HI2	HI3	HI4	HI5	HI6	HI7	HI8	HI9	HI10
相关系数	-0.309 5	-0.180 2	-0.046 1	-0.112 3	-0.159 8	-0.349 2	-0.411 9	-0.401 1	-0.464 9	-0.370 1


3.3 容量估计

NASA 随机工况数据集中包含来自多个电池的数据,将每个组别中的一半电池用于训练,其余用于测试。数据集中每一组测试样例的估计结果如图 7 所示。

结果表明,在不同组别中不同的循环工况下,本文提出的改进的 ANFIS 都能较好地跟踪容量退化的趋势,并能捕捉到容量再生点。其中图 7(b)和(f)中的容量估计误差与其他组别相比较,这是因为这两个组别中数据点十分有限,使得其在测试过程中无法很好地拟合衰减系数,造成锂电池容量估计的整体偏移,这也证明了本文简化系统结构的必要性。



(a)组别1中RW8的估计结果
(a)Estimated results of RW8 in Group 1




(b)组别2中RW6的估计结果
(b)Estimated results of RW6 in Group 2


升,因此使用双曲正切函数对其归一化为:

$$t'_{rest} = \tanh(t_{rest}) = \frac{e^{t_{rest}} - e^{-t_{rest}}}{e^{t_{rest}} + e^{-t_{rest}}} \quad (20)$$


每个特征与系统输出之间的相关性如表 2 所示。选取 Spearman 相关系数绝对值大于 0.35 的特征,即选取时间间隔、温度范围、吞吐量和累积时间作为系统输入,其相关系数绝对值分别为 0.464 9、0.411 9、0.401 1 和 0.370 1。



(c)组别3中RW10的估计结果
(c)Estimated results of RW10 in Group 3



(d)组别4中RW15的估计结果
(d)Estimated results of RW15 in Group 4



(e)组别5中RW19的估计结果
(e)Estimated results of RW19 in Group 5

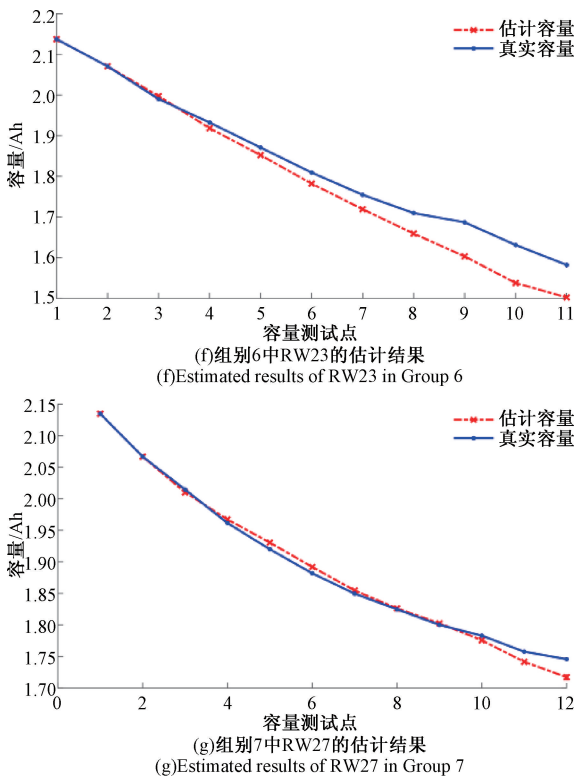


图7 NASA数据集中测试样例的容量估计结果

Fig. 7 Capacity estimation of test samples in the NASA dataset

在能够较好地跟踪锂电池容量退化趋势的基础上,本文提出的改进 ANFIS 也具有更好的可解释性。尽管目前对可解释性的评估仍然是一个待研究的问题,但研究者们一直认可可解释性中存在两个组成部分^[25],即语义和复杂性。一方面,语义可解释性主要表现为人类判断标准与语言变量之间的相似性。本文中提取的特征是可以被人类直接理解的,例如人类可以根据温度对电池容量衰减进行定性判断,认为温度过高或过低都会造成电池容量的大幅度退化,而这可以根据模糊规则的参数进行验证。另一方面,信息量限制了系统的可解释性。由于人类的记忆存储是有限的,大量的规则和同时考虑许多变量的规则都会对可解释性产生负面影响。本文通过相关系数提取了较少的输入特征,并采用规则激活机制避免产生大量规则,大大减少了计算量。因此,本系统对充放电条件特征进行模糊分类并对各聚类进行线性拟合,简单的结构和具有实际意义的输入特征使系统具有更好的可解释性。

为了说明本文方法的稳健性,将改进前后的 ANFIS 估计结果进行了比较,同时与应用广泛的数据驱动方法进行横向比较,包括改进核函数的 GPR 方法^[12]、局部优化的 ANN 方法^[22]、添加集成学习结构的 ELM 模型^[26]和 4 种数据驱动方法融合模型^[27]。采用均方根误差 (root

mean square error, RMSE) 和平均绝对误差 (mean absolute error, MAE) 来量化模型的性能,由测试集中所有数据点的真实测量容量 Q 和估计容量 Q_n 来计算,数学上定义为:

$$RMSE = \sqrt{\frac{1}{P} \frac{1}{N} \sum_{p=1}^P \sum_{n=1}^N (Q_{n,p} - \hat{Q}_{n,p})^2} \quad (21)$$

$$MAE = \frac{1}{P} \frac{1}{N} \sum_{p=1}^P \sum_{n=1}^N |Q_{n,p} - \hat{Q}_{n,p}| \quad (22)$$

其中, P 为测试集中的电池单体个数, N 为每个电池单体的容量测量点个数。由于系统输出为容量变化,因此估算容量递归计算为 $\hat{Q}_{n,p+1} = \hat{Q}_{n,p} + y_p$ 。

不同估算方法的对比结果如表 3 所示,本文所提方法在 NASA 随机数据集上的 RMSE 达到 3.73%, MAE 达到 2.57%。对比结果进一步验证了随机工况下改进的 ANFIS 在锂电池容量衰减估计方面的有效性能。与改进的单一方法相比,本文方法的精度显著提升,并且能与 4 种数据驱动方法融合下的方法精度相近。在保证估计精度的前提下,本文的方法具有简单的系统结构,能够获得更好的可解释性。在实际应用中,能够更好地满足锂电池容量衰减过程中的估计需求,缓解人们对于数据驱动模型应用可靠性的担忧。

表3 不同容量估算方法对比

Table 3 Comparison of different capacity prediction

参数	methods					%
	GPR	ANN	ELM	融合方法	ANFIS	
RMSE	7.00	5.08	4.64	3.65	6.97	3.73
MAE	5.65	3.64	3.14	2.52	5.32	2.57

4 结 论

本文考虑到锂电池在实际应用中运行工况的复杂性和随机性,提出了一种基于随机工况的改进 ANFIS 方法用于估计锂电池衰减过程中的容量变化。首先根据锂电池容量退化和再生的影响因素,基于随机工况数据提取并筛选相应的特征。然后使用改进的 ANFIS 进行特征与容量变化之间的非线性映射,在系统中添加模糊规则激活机制简化系统结构,并引入衰减系数对电池的不一致性进行描述,提高系统的泛化性。经过 NASA 随机工况电池数据集的验证,锂电池容量估算 RMSE 可以达到 3.73%,表明本系统具有较高的准确性和稳定性,并且模糊规则的使用使得系统具有一定的可解释性。本文的方法对现有锂电池容量衰减估算的研究有一定的借鉴意义。

参考文献

- [1] MASIAS A, MARCICKI J, PAXTON W A. Opportunities and challenges of lithium-ion batteries in automotive applications[J]. ACS Energy Letters, 2021, 6(2): 621-630.
- [2] ZHANG X, PENG H, WANG H, et al. Hybrid lithium iron phosphate battery and lithium titanate battery systems for electric buses[J]. IEEE Transactions on Vehicular Technology, 2018, 67(2): 956-965.
- [3] 刘大同, 周建宝, 郭力萌, 等. 锂离子电池健康评估和寿命预测综述[J]. 仪器仪表学报, 2015, 36(1): 1-16.
- LIU D T, ZHOU J B, GUO L M, et al. Survey on lithium-ion battery health assessment and cycle life estimation[J]. Chinese Journal of Scientific Instrument, 2015, 36(1): 1-16.
- [4] DONG G, CHEN Z, WEI J, et al. Battery health prognosis using brownian motion modeling and particle filtering [J]. IEEE Transactions on Industrial Electronics, 2018, 65(11): 8646-8655.
- [5] LYU C, LAI Q, GE T, et al. A lead-acid battery's remaining useful life prediction by using electrochemical model in the Particle Filtering framework[J]. Energy, 2017, 120(1): 975-984.
- [6] HUANG Z, BEST M, KNOWLES J, et al. Adaptive piecewise equivalent circuit model with SOC/SOH estimation based on extended kalman filter[J]. IEEE Transactions on Energy Conversion, 2022, 38(2): 959-970.
- [7] XU Z, WANG J, LUND P D, et al. Co-estimating the state of charge and health of lithium batteries through combining a minimalist electrochemical model and an equivalent circuit model[J]. Energy, 2022, 240(2): 1-14.
- [8] 徐佳宁, 倪裕隆, 朱春波. 基于改进支持向量回归的锂电池剩余寿命预测[J]. 电工技术学报, 2021, 36(17): 3693-3704.
- XU J N, NI Y L, ZHU CH B. Remaining useful life prediction for lithium-ion batteries based on improved support vector regression [J]. Transactions of China Electrotechnical Society, 2021, 36(17): 3693-3704.
- [9] LUO L, ZHANG C, TIAN Y, et al. State-of-health estimate for the lithium-ion battery based on constant voltage current entropy and charging duration[J]. World Electric Vehicle Journal, 2022, 13(8): 148-161.
- [10] 王冉, 后麒麟, 石如玉, 等. 基于变分模态分解与集成深度模型的锂电池剩余寿命预测方法[J]. 仪器仪表学报, 2021, 42(4): 111-120.
- WANG R, HOU Q L, SHI R Y, et al. Remaining useful life prediction method of lithium battery based on variational mode decomposition and integrated deep model[J]. Chinese Journal of Scientific Instrument, 2021, 42(4): 111-120.
- [11] ZHENG Y, HU J, CHEN J, et al. State of health estimation for lithium battery random charging process based on CNN-GRU method[J]. Energy Reports, 2023, 9(3): 1-10.
- [12] RICHARDSOM R R, OSBORNE M A, HOWEY D A. Battery health prediction under generalized conditions using a Gaussian process transition model[J]. Journal of Energy Storage, 2019, 23(6): 320-328.
- [13] ZENATI A, DESPREZ P, RAZIK H, et al. A methodology to assess the State of Health of lithium-ion batteries based on the battery's parameters and a Fuzzy Logic System [C]. 2012 IEEE International Electric Vehicle Conference, 2012: 1-6.
- [14] CHEN D H, HUA M, ZOU Z M, et al. Dynamic estimation of the health status of pure electric vehicle battery by optimized hierarchical T-S fuzzy control[J]. Beijing Inst. Technol, 2019, 39(6): 609-614.
- [15] HOU E, WANG Z, QIAO X, et al. Remaining useful cycle life prediction of lithium-ion battery based on TS fuzzy model[J]. Frontiers in Energy Research, 2022, 10(8): 1-11.
- [16] AHWIADI M, WANG W. An adaptive evolving fuzzy technique for prognosis of dynamic systems[J]. IEEE Transactions on Fuzzy Systems, 2021, 30(3): 841-849.
- [17] MENG H, GENG M, XING J, et al. A hybrid method for prognostics of lithium-ion batteries capacity considering regeneration phenomena [J]. Energy, 2022, 261(B): 1-13.
- [18] 王立新. 模糊系统: 挑战与机遇并存——十年研究之感悟[J]. 自动化学报, 2001, 27(4): 585-590.
- WANG L X. Fuzzy systems: Challenges and chance, my experiences and perspectives [J]. Acta Automatica Sinica, 2001, 27(4): 585-590.
- [19] TAKAGI T, SUGENO M. Fuzzy identification of systems and its applications to modeling and control[J]. IEEE Transactions on Systems Man and Cybernetics, 1985, 15(1): 116-132.

- [20] LAJARA R, PEREZ-SOLANO J J, PELEGRI-SEBASTIA J. Predicting the batteries' state of health in wireless sensor networks applications [J]. IEEE Transactions on Industrial Electronics, 2018, 65(11): 8936-8945.
- [21] QIN T, ZENG S, GUO J, et al. A rest time-based prognostic framework for state of health estimation of lithium-ion batteries with regeneration phenomena [J]. Energies, 2016, 9(11): 896-913.
- [22] ZHANG Y, WIK T, BERGSTROM J, et al. A machine learning-based framework for online prediction of battery ageing trajectory and lifetime using histogram data [J]. Journal of Power Sources, 2022, 526(1): 1-13.
- [23] GREENBANK S, HOWEY D. Automated feature extraction and selection for data-driven models of rapid battery capacity fade and end of life [J]. IEEE Transactions on Industrial Informatics, 2022, 18(5): 2965-2973.
- [24] GU X, SHEN Q. A self-adaptive fuzzy learning system for streaming data prediction [J]. Information Sciences, 2021, 579(11): 623-647.
- [25] GACTO M J, ALCALA R, HERRERA F. Interpretability of linguistic fuzzy rule-based systems; An overview of interpretability measures [J]. Information Sciences, 2011, 181(20): 4340-4360.
- [26] GOU B, XU Y, FENG X. An ensemble learning-based data-driven method for online state-of-health estimation of

lithium-ion batteries [J]. IEEE Transactions on Transportation Electrification, 2021, 7(2): 422-436.

- [27] ZHANG Y Z, TORSTEN W, JOHN B, et al. Practical battery State of Health estimation using data-driven multi-model fusion [J]. IFAC-Papers OnLine, 2023, 56(2): 3776-3781.

作者简介



刘彤宇, 2021 年于复旦大学获得学士学位, 现为复旦大学硕士研究生, 主要研究方向为锂电池的健康管理。

E-mail: 21210720033@m.fudan.edu.cn

Liu Tongyu received her B. Sc. degree from Fudan University in 2021. She is currently pursuing her M. Sc degree at Fudan University. Her main research interest is the health management of lithium batteries.



陆起涌(通信作者), 分别在 1988 年和 1993 年于复旦大学获得学士学位和硕士学位, 现为复旦大学电子工程系主任技师, 主要研究方向为智能仪器仪表、物联网应用。

E-mail: lqyong@fudan.edu.cn

Lu Qiyong (Corresponding author) received his B. Sc. degree and M. Sc. degree both from Fudan University in 1988 and 1993, respectively. He is currently the chief technician of the department of electronic engineering at Fudan University. His main research interests include intelligent instruments and application of internet of things.