

# 基于置信规则库的锂离子电池健康状态预测

谭俐岩, 马宁\*

哈尔滨师范大学计算机科学与信息工程学院, 黑龙江 哈尔滨

收稿日期: 2024年9月20日; 录用日期: 2024年11月7日; 发布日期: 2024年11月19日

## 摘要

电池以其卓越的储能能力, 成为现代科技与生活不可或缺的能源核心, 因此对电池老化状态精准诊断和预测是非常重要的。对于一般预测方法而言, 电化学模型依赖电池内部机制进行预测, 但高度敏感于材料、结构及工作条件变化。机器学习模型依赖高质量大数据与先进算法估算电池健康, 但受限于数据质量和算法选择。鉴于上述模型的不足, 本文提出了一种创新的电池健康预测模型——基于置信规则库的预测模型。通过构建一系列基于不确定性和模糊性处理的规则, 有效应对电池内部状态的复杂性和外部环境的多变性。经实验验证该模型能够提高预测的准确性和可靠性, 为锂离子电池健康状态估计及寿命预测领域提供了新的思路和方法, 有望在未来能源管理和电池维护中发挥重要作用。

## 关键词

置信规则库, 机器学习, 电池, 健康预测

# Prediction of Lithium-Ion Battery Health State Based on Belief Rule Base

Liyan Tan, Ning Ma\*

School of Computer Science and Information Engineering, Harbin Normal University, Harbin Heilongjiang

Received: Sep. 20<sup>th</sup>, 2024; accepted: Nov. 7<sup>th</sup>, 2024; published: Nov. 19<sup>th</sup>, 2024

## Abstract

Batteries, with their exceptional energy storage capabilities, have emerged as an indispensable energy core in modern technology and daily life. Consequently, accurate diagnosis and prediction of battery aging status are of paramount importance. Traditional prediction methods, such as electrochemical models, rely on the internal mechanisms of batteries for prediction but are highly sensitive to changes in materials, structures, and operating conditions. On the other hand, machine

\*通讯作者。

learning models estimate battery health based on high-quality big data and advanced algorithms, yet they are constrained by data quality and algorithm selection. Given the limitations of these models, this paper introduces an innovative battery health prediction model—a prediction model based on a Belief Rule Base. By constructing a series of rules that address uncertainty and fuzziness, it effectively tackles the complexity of the battery's internal state and the variability of the external environment. Experimental validation demonstrates that this model enhances prediction accuracy and reliability, offering new insights and methodologies for lithium-ion battery health state estimation and lifetime prediction. It is anticipated to play a pivotal role in future energy management and battery maintenance.

## Keywords

Belief Rule Base, Machine Learning, Battery, Health Prediction

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

锂离子电池因其高能量密度, 在全球能源结构中扮演重要角色。随着电气化的不断发展, 动力电池和储能电池的需求激增[1]。因此, 电池老化状态的精准诊断和预测是一大重要且面临巨大挑战的研究领域[2]。

近年来, 随着人工智能的快速发展, 锂离子电池健康状态估计及寿命预测研究取得显著进展。研究者通过多种方式, 不断探索新的方法和路径[3]。挖掘电池运行数据中的有效信息、融合多种技术手段提升预测精度等方式大致分为三类: 电化学模型、机器学习模型和半定量方法模型。在基于电化学模型方面: Luo [4]等人通过 EIS 测试和等效电路模型, 显著缩短了测试时间并提高了预测精度。Du [5]通过对比选择一阶戴维南等效电路模型, 利用递推最小二乘法进行了电池参数的辨识。并且提出了基于电池内阻与容量的双滑模观测器系统, 实现了健康情况高精度观测。Li [6]选择二阶 RC 电路作为锂离子电池的等效模型。采用含遗忘因子的递推最小二乘法在线辨识模型参数, 提出了一种 SOC 估算的方法。在机器学习模型方面: Zhao [7]等人通过灰色关联分析、模糊信息粒化和最小二乘支持向量机等技术, 实现了带有上下限的 RUL 区间预测。Wei [8]等人提出了一种基于健康因子和灰色神经网络模型的锂离子电池健康状态在线估算方法。Liu [9]等人提出了一种结合自适应法和列文伯格-马夸尔特算法优化 BP 神经网络的 VLLM 动态模型预测退役动力锂电池的荷电状态。在半定量模型方面: Su [10]等人提出了一种结合数据驱动和机理模型预测方法, 通过测量电化学阻抗谱和电池输出电压来评估其健康状态。Zhao [11]基于电池特征, 采用了卡尔曼滤波与 LSSVM 的融合策略进行预测。Zhang [12]等人提出通过简化双指数退化模型并利用粒子滤波算法结合自回归模型修正预测锂离子电池剩余寿命预测方法。

基于电化学模型和数据驱动模型在预测电池健康时, 虽有优势, 但也存在一些不足之处。电化学模型会受到电池材料、结构、工况等因素的影响。数据驱动模型预测结果往往受到数据质量以及所选模型算法的限制。因此, 在实际应用中, 需要选择更综合的预测方法以提高预测精度和可靠性。在电池健康预测领域, 半定量方法通常依赖于对电池性能退化的部分理解, 而不是完全依赖于复杂的物理或化学模型。置信规则库(Belief Rule Base, BRB)作为半定量预测方法的一个分支, 特别适合于处理包含不确定性

和模糊性的复杂情况。BRB 通过构建一系列基于专家知识和经验的规则以预测其性能。BRB 能够充分利用领域专家的深入理解和实践经验, 从而提高预测的准确性和可靠性。

因此, 本文提出一种基于 BRB 模型的电池健康预测模型。相信随着对锂离子电池内部结构和性能衰减机理的深入理解, 选择置信规则库进行电池健康预测可以为多方面提供更为坚实的基础。

## 2. 置信规则库介绍

在人工智能领域, 专家系统作为核心研究方向之一[13], 其应用广泛且深入, 特别是在处理复杂决策与推理问题时展现出独特优势。其中, 2006 年 Yang [14]提出的置信规则库理论, 为不确定性推理提供了严谨且高效的方法论基础。BRB 是一种基于概率论提出不确定性推理方法, 可有效整合专家知识。其核心在于, 利用证据推理机制处理信息中的模糊性和不确定性。具体而言, BRB 通过构建一系列规则, 灵活表达各种相互作用和反馈机制。在推理过程中, BRB 通过综合评估所有相关规则的影响, 保证了结果的全面性和准确性。此外, BRB 还具有较强的灵活性。它可以根据具体问题的需求进行适应性调整和优化, 以适应不同领域和场景的应用需求。BRB 建立模型的基本原理如图 1 所示。

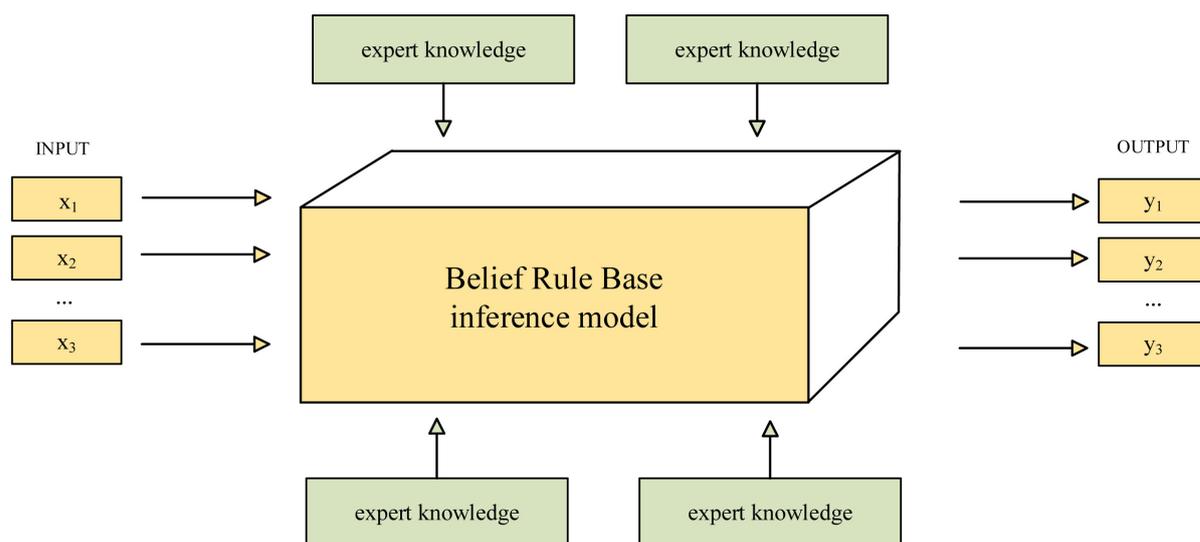


Figure 1. BRB basic schematic diagram

图 1. BRB 基本原理图

置信规则库中的第  $q$  条置信规则的描述如式(1)表示:

$$\begin{aligned}
 R_q : & \text{If } a_1 \text{ is } A_1^q \text{ and } a_2 \text{ is } A_2^q \text{ and } \dots \text{ and } a_N \text{ is } A_N^q, \\
 & \text{Then } \left\{ (D_1, \beta_{1,q}), (D_2, \beta_{2,q}), \dots, (D_M, \beta_{M,q}) \right\} \left( \sum_{m=1}^M \beta_{m,q} \leq 1 \right) \\
 & \text{with rule weight } \theta_q (q = 1, 2, \dots, L) \text{ and attribute weight } \delta_{1,q}, \delta_{2,q}, \dots, \delta_{N,q}
 \end{aligned} \quad (1)$$

其中,  $a_n$  为样本中第  $n$  个前提属性,  $A_n^q$  为第  $q$  条规则第  $n$  个前提属性参考值,  $N$  为第  $q$  条规则中前提属性的数量,  $\theta_{n,q}$  为第  $q$  条规则第  $n$  个前提属性的属性权重,  $D_m (m = 1, 2, \dots, M)$  表示第  $m$  个结果,  $\beta_{m,q}$  为第  $q$  条规则中第  $m$  个结果的置信度,  $L$  为总规则数,  $\theta_n$  为第  $n$  个前提属性的权重。

## 3. 实验数据

本文使用的数据集源自 NASA。该数据集是从精密电池系统中连续采集的时间序列数据, 并伴随详

尽的电池状态标签。特别地, 本文聚焦于 FY08Q4 模块中的实验数据, 这些数据在严格控制的室温环境下采集, 通过标准化的充电与放电循环流程获取。充电过程遵循 1.5 A 恒定电流模式直至电压达到 4.2 V, 随后转入恒定电压模式直至充电电流减至 20 mA 以下; 放电过程则以 2 A 恒定电流进行, 直至特定电池的电压分别降至预设阈值, 以模拟实际使用中的负载变化。

为精确分析电池性能演变, 本文选取了 B0006 号与 B0007 号电池组作为研究对象, 利用 MATLAB 提取两组电池在测试周期内的容量数据。经过处理, 每组电池成功获取了 166 组高质量数据点, 这些数据反映了电池容量的变化趋势, 为下文构建预测模型、验证理论假设奠定了坚实的基础。

#### 4. 基于置信规则库的锂离子电池模型搭建

通过 BRB 模型预测离子电池的容量和健康状态, 不仅符合离子电池性能变化的复杂性和不确定性特点, 还能够充分利用专家经验和相关数据的优势, 提高预测的准确性和可靠性, 为锂离子电池的维护、管理和优化提供有力支持。

##### 4.1. 电池健康预测模型

基于第二章提取出的容量数据, 将前一时刻离子电池容量和当前时刻离子电池容量数据作为模型的输入, 采用 BRB 建模进行分析, 基于 BRB 的健康状态预测模型描述如公式(2)所示。

$$\begin{aligned}
 R_q : & \text{If } LB(t-1) \text{ is } A_1^q \text{ and } LB(t) \text{ is } A_2^q, \\
 \text{Then } & LB(t+1) \text{ is } \{(D_1, \beta_{1,q}), (D_2, \beta_{2,q}), \dots, (D_M, \beta_{M,q})\} \\
 & \text{with rule weight } \theta_q (q = 1, 2, \dots, L) \text{ and attribute weight } \delta_{1,q}, \delta_{2,q}
 \end{aligned}
 \tag{2}$$

锂离子电池健康预测流程图如图 2 所示。

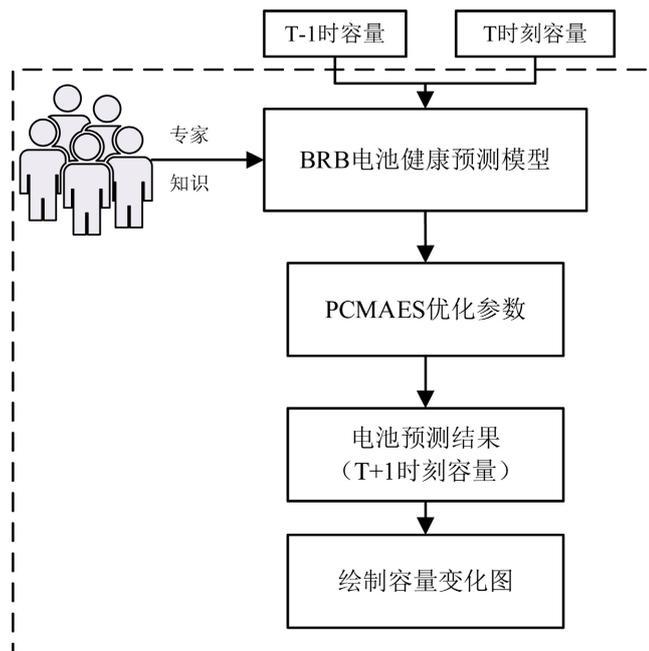


Figure 2. Model flow chart  
图 2. 模型流程图

在 BRB 建模推理过程中使用 ER 解析算法对规则激活权重和评价置信度进行推理计算得到锂离子电

池健康预测的结果[15]。其预测具体步骤如下所示:

步骤一: 置信规则库参数集的初始化

初始化前提条件、结果属性参考数值以及相应的置信度。

步骤二: 输入样本与规则匹配度的计算

接下来, 计算输入样本数据与 BRB 中每一条规则的匹配度。与第  $q$  条规则的匹配度如公式(3)表示。

$$\Lambda_n^{q'} = \begin{cases} \frac{A_n^{q'+1} - LB_n(t)}{A_n^{q'+1} - A_n^l} & q' = q (A_n^q \leq LB_q(t) \leq A_n^{l+1}) \\ \frac{LB_n(t) - A_n^q}{A_n^{q+1} - A_n^l} & q' = q + 1 \\ 0 & q' = 1, \dots, L (q' \neq q \text{ and } q \neq q + 1) \end{cases} \quad (3)$$

步骤三: 基于证据推理(ER)算法的规则匹配度聚合与结果生成

在获取了所有规则的匹配度之后, 使用 ER 算法对这些匹配度进行聚合, 以生成最终的预测结果[16]。

第  $q$  条的规则激活权重  $Z_q$  如公式(4)所示。

$$Z_q = \frac{\theta_q \Lambda_q}{\sum_{i=1}^L \theta_i \Lambda_i} \quad (4)$$

第  $r$  健康状态预测等级置信度如公式(5)所示。

$$\beta_m = \frac{\frac{1}{\sum_{m=1}^M \prod_{q=1}^L \left( Z_q \beta_{m,q} + 1 - Z_q \sum_{m=1}^M \beta_{m,q} \right)} - (R-1) \prod_{q=1}^L \left( 1 - Z_q \sum_{m=1}^M \beta_{m,q} \right)}{\prod_{q=1}^L (1 - \Lambda_l)} \left[ \prod_{q=1}^L \left( Z_q \beta_{m,q} + 1 - Z_q \sum_{m=1}^M \beta_{m,q} \right) - \prod_{q=1}^L \left( 1 - \sum_{m=1}^M \beta_{m,q} \right) \right] \quad (5)$$

$$1 - \frac{\sum_{m=1}^M \prod_{l=1}^L \left( Z_q \beta_{m,q} + 1 - Z_q \sum_{m=1}^M \beta_{m,q} \right) - (R-1) \prod_{q=1}^L \left( 1 - Z_q \sum_{m=1}^M \beta_{m,q} \right)}{\prod_{q=1}^L (1 - \Lambda_l)}$$

最终获得的预测结果如公式(6)所示。

$$LB(t+1) = \sum_{m=1}^M U(D_m) \beta_m \quad (6)$$

通过上述步骤, 可以利用置信规则库模型对电池容量进行准确预测, 并基于预测结果制定相应的维护和管理策略。

## 4.2. 电池健康预测模型优化

依据专家知识建立的模型还不够精确, 因此为了提高 BRB 模型的预测精度, 采用投影协方差矩阵自适应进化策略(PCMAES) [17]对模型进行优化, 进而使每个规则的参数进行优化和调整。BRB 模型的目标优化函数描述如公式(7)表示。

$$\begin{aligned} & \min \text{MSE}(v) \\ & v = \{ \beta_{m,q}, \theta_q, \delta_n \} \\ & \text{s.t. } \sum_{m=1}^M \beta_{m,q} = 1, q = 1, 2, \dots, L; \\ & 0 \leq \beta_{m,q} \leq 1, 0 \leq \theta_q \leq 1, 0 \leq \delta_n \leq 1 \end{aligned} \quad (7)$$

需要上述公式中,  $MSE(\bullet)$  为结果计算均方误差。MSE 计算如式(8)表示。

$$MSE(\beta) = \frac{1}{Num} \sum_{t=1}^{Num} (LB(t+1) - Lb(t+1))^2 \quad (8)$$

其中,  $Num$  为训练数据的总量,  $Lb(t+1)$  为  $t+1$  时刻电池容量预测值。本文模型优化框架图如图 3 所示。

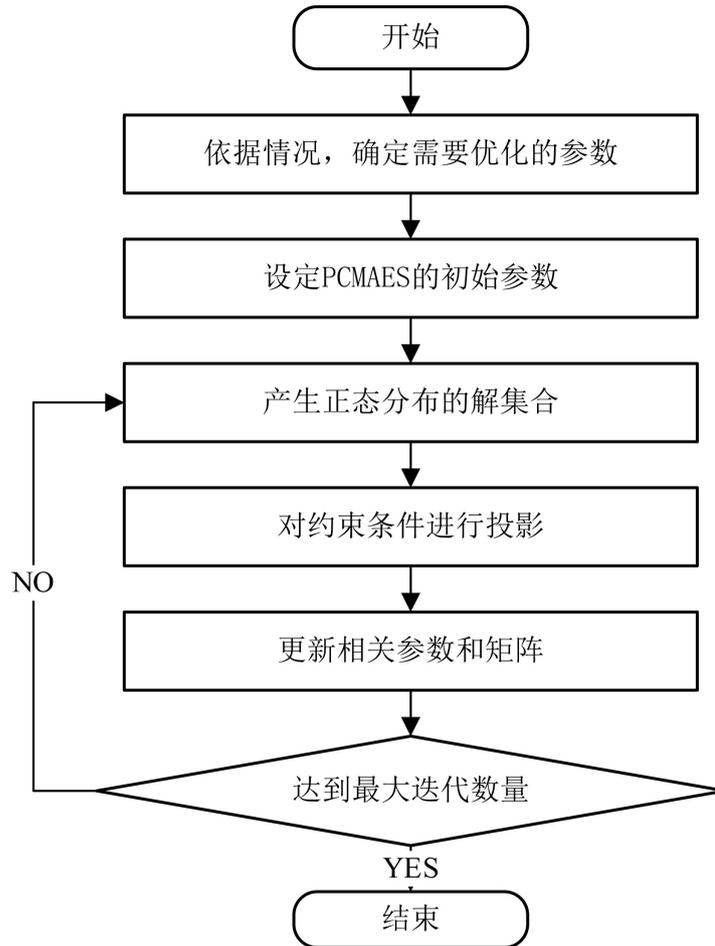


Figure 3. Optimization algorithm frame diagram  
图 3. 优化算法框架图

## 5. 实验分析与验证

本章节实验采用数据集为 B0006 和 B0007 数据, 选取使用 75%左右的数据作为训练样本, 其余数据用作测试数据集。

### 5.1. B0006 实验样本分析

根据专家知识的指导, 定义电池健康状态的相关信息, 包括优秀(A)、良好(B)、中等(C)、不佳(D)。属性数据以及结果数据参考点和参考值的确定如表 1 所示。

接下来定义 BRB 预测模型基本参数, 将属性权重初始设置为 1, 所建立的初始置信规则库如表 2 所示。

**Table 1.** Attribute data and result data reference point and reference value settings  
**表 1.** 属性数据及结果数据参考点和参考值设置

参考点	优秀	良好	中等	不佳
$T-1$ 时参考值	2.04	1.84	1.37	1.15
$T$ 时参考值	2.03	1.84	1.37	1.15
$T+1$ 时参考值	2.02	1.83	1.37	1.15

**Table 2.** Initial belief table  
**表 2.** 初始置信表

	$\theta_q$	$A_1^q$ & $A_2^q$	$\{(A, \beta_{1,q}), (B, \beta_{2,q}), (C, \beta_{3,q}), (D, \beta_{4,q})\}$
1	1	A & A	$\{(A, 0.6), (B, 0), (C, 0.3), (D, 0.1)\}$
2	1	A & B	$\{(A, 0.6), (B, 0.3), (C, 0.1), (D, 0)\}$
3	1	A & C	$\{(A, 0.5), (B, 0.2), (C, 0.3), (D, 0)\}$
4	1	A & D	$\{(A, 0.5), (B, 0.1), (C, 0.4), (D, 0)\}$
5	1	B & A	$\{(A, 0.3), (B, 0), (C, 0.2), (D, 0.5)\}$
6	1	B & B	$\{(A, 0.3), (B, 0.4), (C, 0.2), (D, 0.1)\}$
7	1	B & C	$\{(A, 0.3), (B, 0.5), (C, 0), (D, 0.2)\}$
8	1	B & D	$\{(A, 0.3), (B, 0), (C, 0.2), (D, 0.5)\}$
9	1	C & A	$\{(A, 0.2), (B, 0.5), (C, 0.3), (D, 0)\}$
10	1	C & B	$\{(A, 0.1), (B, 0.5), (C, 0.4), (D, 0)\}$
11	1	C & C	$\{(A, 0.1), (B, 0.4), (C, 0.5), (D, 0)\}$
12	1	C & D	$\{(A, 0.1), (B, 0), (C, 0.3), (D, 0.6)\}$
13	1	D & A	$\{(A, 0), (B, 0.2), (C, 0.3), (D, 0.5)\}$
14	1	D & B	$\{(A, 0), (B, 0.1), (C, 0.6), (D, 0.3)\}$
15	1	D & C	$\{(A, 0), (B, 0.2), (C, 0.1), (D, 0.7)\}$
16	1	D & D	$\{(A, 0), (B, 0), (C, 0), (D, 1)\}$

## 5.2. 模型优化

使用 P-CMA-ES 算法对 BRB 故障预测模型参数优化。迭代次数为 400。确定基于 BRB 的锂离子电池健康状态预测模型的参数, 经优化后的 BRB 置信分布如表 3 所示。

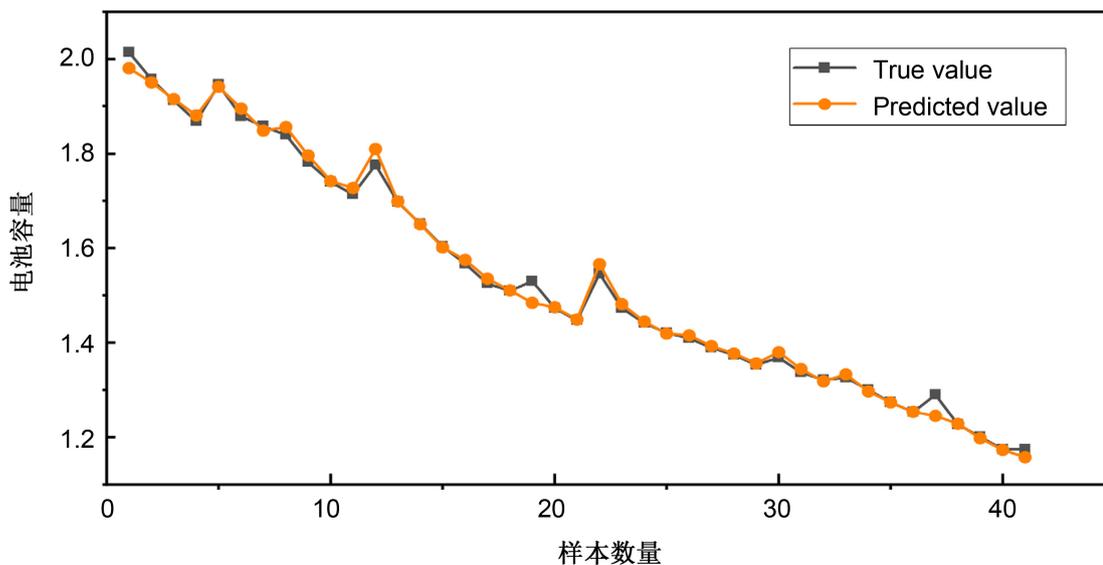
最后, 得到锂离子电池健康预测结果如图 4 所示。

## 5.3. B0007 实验样本分析

为验证本文提出方法的有效性, 对 B0007 数据进行实验。优化算法的迭代次数为 400。最后计算模型的均方误差。实验结果如图 5 所示。

**Table 3.** Optimized belief table  
**表 3.** 优化后置信表

	$\theta_q$	$A_1^q$ & $A_2^q$	$\{(A, \beta_{1,q}), (B, \beta_{2,q}), (C, \beta_{3,q}), (D, \beta_{4,q})\}$
1	1.00	A & A	{(A, 1), (B, 0), (C, 0), (D, 0)}
2	0.88	A & B	{(A, 0.6), (B, 0.25), (C, 0.15), (D, 0)}
3	0.25	A & C	{(A, 0.5), (B, 0.3), (C, 0.2), (D, 0)}
4	0.10	A & D	{(A, 0.3), (B, 0.7), (C, 0), (D, 0)}
5	0.60	B & A	{(A, 0.5), (B, 0.4), (C, 0.1), (D, 0)}
6	0.48	B & B	{(A, 0.5), (B, 0.3), (C, 0), (D, 0.2)}
7	0.32	B & C	{(A, 0.3), (B, 0.5), (C, 0.2), (D, 0)}
8	0.15	B & D	{(A, 0.2), (B, 0.5), (C, 0), (D, 0.3)}
9	0.83	C & A	{(A, 0.2), (B, 0.7), (C, 0), (D, 0.1)}
10	0.42	C & B	{(A, 0.2), (B, 0.1), (C, 0.3), (D, 0.4)}
11	0.52	C & C	{(A, 0.15), (B, 0), (C, 0.25), (D, 0.6)}
12	0.20	C & D	{(A, 0), (B, 0.25), (C, 0.65), (D, 0.1)}
13	0.60	D & A	{(A, 0), (B, 0.1), (C, 0.6), (D, 0.3)}
14	0.40	D & B	{(A, 0), (B, 0), (C, 0.3), (D, 0.7)}
15	0.48	D & C	{(A, 0), (B, 0), (C, 0), (D, 1)}
16	0.52	D & D	{(A, 0), (B, 0), (C, 0), (D, 1)}



**Figure 4.** B0006 Prediction chart  
**图 4.** B0006 预测图

### 5.4. 评价指标

离子电池健康状态预测的结果可以形成多种性能指标, 比如: Mean Squared Error (MSE)、Mean Squared Error (MAE)、Root Mean Squared Error (RMSE)等。本文构建模型使用的评价指标为 MSE, 在后文对比实

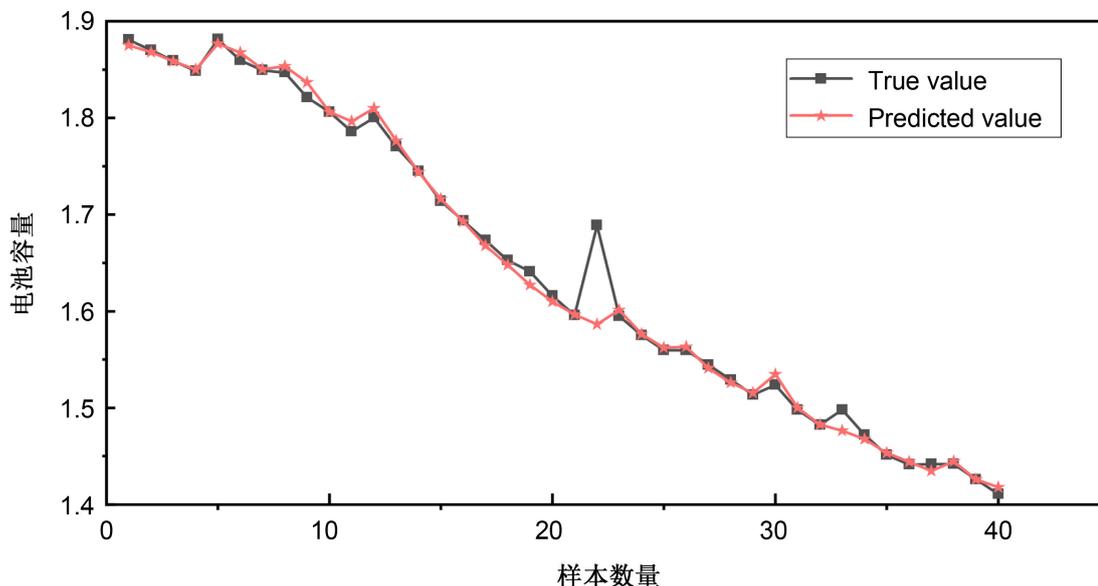


Figure 5. B0007 Prediction chart  
图 5. B0007 预测图

验中, 又增加了 MAE 和 RMSE 指标验证结论的有效性。具体计算公式如下:

MAE 计算的是所有观测值与预测值之差的绝对值的平均值。

$$\text{MAE}(\beta) = \frac{1}{\text{Num}} \sum_{t=1}^{\text{Num}} |LB(t+1) - Lb(t+1)| \quad (9)$$

MSE 是所有观测值与预测值之差的平方的平均值。

$$\text{MSE}(\beta) = \frac{1}{\text{Num}} \sum_{t=1}^{\text{Num}} (LB(t+1) - Lb(t+1))^2 \quad (10)$$

RMSE 是 MSE 的平方根, 它提供了与观测值相同的量纲的误差度量。

$$\text{RMSE}(\beta) = \sqrt{\frac{1}{\text{Num}} \sum_{t=1}^{\text{Num}} (LB(t+1) - Lb(t+1))^2} \quad (11)$$

### 5.5. 预测评价

在本小节中, 为了展示本文模型的先进性, 将基于 BRB 的电池预测结果与决策树(DF)、随机森林(RF)、径向基神经网络(BPNN)构建模型的结果进行比较, 对比试验与本文模型的预测误差如表 4 所示。

Table 4. Contrast test  
表 4. 对比实验

模型	MSE	MAE	RMSE
BRB	2.18E-4	9.46E-3	1.47E-2
BPNN	3.79E-04	1.28E-2	1.95E-2
RF	4.98E-4	1.69E-2	2.23E-2
DF	1.90E-3	3.29E-2	4.40E-2

可以看出, BRB 模型在预测性能上展现出了显著的优势, 其预测结果的稳定性和准确性更为突出。被认为是此次对比试验中的对电池容量预测效果最佳模型。随着电池进入老化阶段, 本文模型仍旧可以准确预测电池的后期行为。

## 6. 总结

本文创新性地引入了 BRB 模型作为核心分析工具, 在 NASA 提供的电池老化数据集上对所提出的基于 BRB 的预测方法进行了全面验证。实验结果表明, 与传统的及先进的对比模型相比, 该模型在预测精度、稳定性及泛化能力上均展现出显著优势, 从而验证了其在电池健康预测领域的高精度与高效性。本文的研究丰富了锂离子电池健康管理及预测技术的理论体系, 为构建更加智能、高效的电池驱动系统奠定基础。

## 基金项目

黑龙江省自然科学基金项目(LH2021F037)资助; 黑龙江省高等教育教学改革项目(SJGY20180259, SJGY20200368)资助; 哈尔滨市科技局科技创新人才研究专项项目(2017RAQXJ050)资助; 哈尔滨师范大学博士科研启动基金项目(XKB201901)资助; 哈尔滨师范大学研究生培养质量提升工程项目(HSDYJSJG2019006)资助; 哈尔滨师范大学教学改革项目(XJGRYK2022017, XJGYFW2022038); 哈尔滨师范大学计算机学院教学改革项目(JKYJGY202209); 装备智能运用教育部重点实验室开放基金课题资助(AAIE-2023-0102)。

## 参考文献

- [1] Guo, R., Wang, F., Akbar Rhamdhani, M., Xu, Y. and Shen, W. (2024) Managing the Surge: A Comprehensive Review of the Entire Disposal Framework for Retired Lithium-Ion Batteries from Electric Vehicles. *Journal of Energy Chemistry*, **92**, 648-680. <https://doi.org/10.1016/j.jechem.2024.01.055>
- [2] Song, K., Hu, D., Tong, Y. and Yue, X. (2023) Remaining Life Prediction of Lithium-Ion Batteries Based on Health Management: A Review. *Journal of Energy Storage*, **57**, Article ID: 106193. <https://doi.org/10.1016/j.est.2022.106193>
- [3] 熊庆, 邸振国, 汲胜昌. 锂离子电池健康状态估计及寿命预测研究进展综述[J]. 高电压技术, 2024, 50(3): 1182-1195.
- [4] 骆凡, 黄海宏, 王海欣. 基于电化学阻抗谱的退役动力电池荷电状态和健康状态快速预测[J]. 仪器仪表学报, 2021, 42(9): 172-180.
- [5] 杜嘉诚. 基于滑模观测器的锂离子电池荷电状态与健康状态估计算法研究[D]: [硕士学位论文]. 哈尔滨: 哈尔滨工业大学, 2018.
- [6] 李晓黔. 锂离子电池模型参数辨识及 SOC 预测仿真分析[D]: [硕士学位论文]. 兰州: 兰州交通大学, 2016.
- [7] 赵珍, 庞晓琼, 董渊昌. 多健康指标的锂电池剩余使用寿命区间预测[J]. 中北大学学报(自然科学版), 2023, 44(3): 263-271.
- [8] 韦海燕, 陈孝杰, 吕治强, 等. 灰色神经网络模型在线估算锂离子电池 SOH[J]. 电网技术, 2017, 41(12): 4038-4044.
- [9] 刘聪聪, 李珺凯, 刘凯文, 等. 基于人工智能的锂电池 SOC 预测建模与优化[J]. 无线电通信技术, 2019, 45(3): 237-242.
- [10] 苏雨临, 连冠, 张大骋. 等效电路模型法预测动态工况下微型直接甲醇燃料电池剩余使用寿命[J/OL]. 上海交通大学学报: 1-20. <https://doi.org/10.16183/j.cnki.jsjt.2023.072>, 2024-09-18.
- [11] 赵天意. 基于改进卡尔曼滤波的锂离子电池状态估计方法研究[D]: [硕士学位论文]. 哈尔滨: 哈尔滨工业大学, 2016.
- [12] 张凝, 徐皓冬, 王锴, 等. 基于粒子滤波算法的锂离子电池剩余寿命预测方法研究[J]. 高技术通讯, 2017, 27(8): 699-707.
- [13] 刘文剑, 苏宝华, 李振明. 半智能化组合夹具设计的研究[J]. 哈尔滨工业大学学报, 1994(4): 13-16.

- 
- [14] Yang, J.B., Liu, J., Wang, J., Sii, H.S. and Wang, H.W. (2006) Belief Rule-Base Inference Methodology Using the Evidential Reasoning Approach-rimer. *IEEE Transactions on Systems, Man, and Cybernetics—Part A: Systems and Humans*, **36**, 266-285. <https://doi.org/10.1109/tsmca.2005.851270>
- [15] 朱海龙, 贾如侠, 张亮, 等. 基于证据推理和置信规则库的涡扇发动机故障预测[J]. 系统仿真学报, 2022, 34(9): 2074-2086.
- [16] 戴嘉栋, 徐晓滨, 常雷雷, 等. 基于 C-BRB 模型的发动机运行状态监测方法[J]. 控制工程, 2022, 29(2): 214-222.
- [17] He, W., Cheng, X., Zhao, X., Zhou, G. and Zhu, H. (2022) An Interval Construction Belief Rule Base with Interpretability for Complex Systems. *SSRN Electronic Journal*, **229**, Article ID: 120485. <https://doi.org/10.2139/ssrn.4276309>