

基于 CDPSO-EBRB 的锂离子电池健康状态估计

文斌成¹, 肖明清¹, 杨 召², 张 磊³, 陈 鑫¹

(1. 空军工程大学航空工程学院, 西安, 710051; 2. 中国空气动力研究与发展中心, 四川绵阳, 621000;
3. 国防大学联合勤务学院, 北京, 100858)

摘要 锂离子电池在武器系统中广泛应用, 对其健康状态的评估对于保证武器系统作战效能具有重要意义。但构建锂离子电池退化过程的物理模型难度较大, 同时由于数据的不确定性与不完整性影响, 使用纯数据驱动的方式也不能准确描述此过程。扩展置信规则库模型结合了知识结构和证据推理的特性, 可对数据的不确定性与不完整性进行定量描述, 但原始模型的参数选择对其性能影响较大, 针对以上问题, 提出了一种中心离散粒子群算法(CDPSO)优化的扩展置信规则库(EBRB)模型, 并将该模型应用于锂离子电池的健康状态评估中, 使用数据驱动方式将规则集转化为规则, 采用 CDPSO 对初始参数进行训练, 最后使用测试数据集来测试模型的有效性, 通过与传统的方法进行对比, 验证了所提出方法的有效性。

关键词 锂电池; 健康状态估计; 扩展置信规则库; 中心-离散粒子群

DOI 10.3969/j.issn.1009-3516.2021.02.005

中图分类号 TJ760 **文献标志码** A **文章编号** 1009-3516(2021)02-0027-07

An Estimation for the Health Status to Lithium Ion Batteries Based on CDPSO-EBRB

WEN Bingcheng¹, XIAO Mingqing¹, YANG Zhao², ZHANG Lei³, CHEN Xin¹

(1. Aeronautics Engineering College, Air Force Engineering University, Xi'an 710051, China;
2. China Aerodynamics Research and Development Center, Mianyang 621000, Sichuan, China;
3. Joint Logistics Academy, National Defense University, Beijing 100858, China)

Abstract Lithium ion battery is widely used in weapon systems. The evaluation for its health status to lithium ion is of great significance to ensure the operational effectiveness of weapon systems. Aimed at the problems that building a physical model is comparatively difficult in the degradation process of lithium ion battery, simultaneously the process is very hard to be described accurately due to the uncertainty and incomplete data by the pure data-driven method. Being the extended belief rule base model combined with the characteristics of the knowledge structure and evidence reasoning, the uncertainty and incompleteness of data may be quantitatively described, but the parameters of the original model had a greater influence on the choice of its performance. In view of the mentioned above problems, an extended belief rule base (EBRB) model of center de-center particle swarm optimization is proposed, and the model is applied in the lithium ion battery health status evaluation. The EBRB based on the optimization of the CDPSO converts the rule set into rules in a data-driven way, the initial parameters with CDPSO are trained, and finally, the

收稿日期: 2020-10-27

作者简介: 文斌成(1997—), 男, 湖南湘潭人, 硕士生, 主要从事航空武器故障诊断研究。E-mail: 1255292204@qq.com

引用格式: 文斌成, 肖明清, 杨召, 等. 基于 CDPSO-EBRB 的锂离子电池健康状态估计[J]. 空军工程大学学报(自然科学版), 2021, 22(2): 27-33. WEN Bingcheng, XIAO Mingqing, YANG Zhao, et al. An Estimation for the Health Status to Lithium Ion Batteries Based on CDPSO-EBRB[J]. Journal of Air Force Engineering University (Natural Science Edition), 2021, 22(2): 27-33.

validity of the model with the test data set is tested. By comparing with the traditional method, the validity of the proposed method is verified.

Key words lithium ion battery; health status estimation; EBRB; CDPSO

锂离子电池具有能量密度大、寿命长、安全可靠的优点,目前已经广泛应用于航空航天、特种工程、军事领域。锂离子电池健康状态评估成为了目前研究的重点问题之一。对于锂离子电池 RUL 预测可以分为基于经验与基于性能^[1-2]两类方法,基于经验的方法通过电池使用过程中所积累的经验知识来对电池的寿命作出粗略的估计,主要包括循环周期数法、安时法与加权安时法及面向事件的老化累计法。这些方法必须基于充分的经验知识,适合对于一类产品的寿命进行估计,对于个体适合性较差。基于性能的方法是一种间接的预测方法,即通过电池的运行状态信息,状态监测信息等,估计电池的性能退化状态。基于性能的方法主要可以分为基于模型、数据驱动及融合型方法,由于大多数系统建模过程较为复杂与困难,基于模型的方法往往难以实现^[3],而数据驱动的方法则不用考虑其内部的失效机理,直接从性能测试数据和状态监测数据挖掘出其内部的演化规律,简单实用,但是纯数据驱动的方式受数据本身的影响较大,鲁棒性与适应性较差^[4]。

专家系统^[5]是一种结合知识结构与历史数据的方式,初始的专家系统规则主要由人来给定,存在较大的主观性。同时,如何对构建的扩展置信规则库进行参数与结构的优化也是研究的一个重点问题^[6-7],目前对扩展置信规则库的参数优化研究仍然较少。针对上述问题,本文提出了一种基于中心离散粒子群算法的扩展置信规则库参数优化模型,通过数据驱动方式构建原始置信规则库,综合经验知识与历史数据的优势,同时使用该算法进行参数的优化,提高了模型的推理效果。

1 扩展置信规则库与参数优化

1.1 扩展置信规则库的表示

扩展置信规则库由 Liu^[8]等在 BRB 的基础上,将置信分布加入到规则的前件属性部分,提供了一种更加灵活、方便的方式来描述不确定性。扩展置信规则库可以表示为 $R = (R_1, R_2, \dots, R_L)$, L 表示扩展置信规则库中规则数量,其中第 k 条规则可以表示为:

$R^k: \text{IF}\{A^k, \alpha^k\},$
 THEN $\{(D_1, \beta_{1,k}), (D_2, \beta_{2,k}), \dots, (D_N, \beta_{N,k})\}$
 with a rule weight θ_k

and attribute weight $\delta_{1,k}, \delta_{2,k}, \dots, \delta_{e_k,k}$

区别于人为给定规则数量的方式,本文所使用的扩展置信规则库直接由样本数据转化而来,不需要额外的信息。EBRB 的规则生成机制属于数据驱动型,把样本数据转化成规则之前,需要先把样本数据的输入转化为置信分布的形式,同时因样本数据分为数值型、语义型等许多种类型,对于不同类型的输入信息转化的方式在文献[8]中已给出,本文所使用的是基于效用的输入信息转化方式。

1.2 扩展置信规则库的推理机制

EBRB 采用的推理方式与传统的 BRB 相同,即 RIMER^[9]。二者在使用 RIMER 推理时的主要区别是个体匹配度的计算方式不同,RIMER 方法主要由 2 个步骤组成:一是规则激活权重的计算,二是激活规则的合成。

假设输入数据中第 i 个前提属性 X_i 的取值 x_i 已经表示为置信分布的形式,则 x_i 相对于第 k 条规则的第 i 个前提属性的个体匹配度 S_i^k 可以用两个置信分布之间的相信性来度量,因为 EBRB 前件部分的置信分布实际上是概率分布,帮 S_i^k 可借助如下欧式距离来进行计算:

$$d_i^k = d^k(A_i, X_i) = \sqrt{\sum_{j=1}^{J_i} (\alpha_{i,j} - \alpha_{i,j}^k)^2} \quad (1)$$

则 S_i^k 的计算方法为:

$$S_i^k = S^k(A_i, x_i) = 1 - d_i^k \quad (2)$$

已知个体匹配度,则第 k 条规则的激活权重可计算为:

$$\omega_k = \frac{\theta_k \prod_{i=1}^{T_k} (S_i^k)^{\delta_i}}{\sum_{l=1}^L [\theta_l \prod_{i=1}^{T_l} (S_i^l)^{\delta_i}]}, \delta_i = \frac{\delta_i}{\max} \quad (3)$$

式中, $0 \leq \omega_k \leq 1 (k = 1, 2, \dots, L)$, $\sum_{k=1}^L \omega_k = 1$ 。如果 $\omega_k = 0$,则说明第 k 条规则未被激活。

根据计算得到的规则激活权重,本文使用证据推理方法得到结果的置信分布,证据推理的规则合成公式为:

$$\beta_j(x) = \left(\prod_{j=1}^L (\omega_j(x) \beta_{ij} + 1 - \omega_j(x)) - \prod_{j=1}^L (1 - \omega_j(x)) \right) \left(\sum_{s=1}^N \left[\prod_{j=1}^L (\omega_j(x) \beta_{ij} + 1 - \omega_j(x)) \right] \right)^{-1}$$

$$\omega_j(X) - N \prod_{j=1}^L (1 - \omega_j(x)) \Big]^{-1} \quad (4)$$

EBRB 的最终输出 $S(x)$ 为:

$$S(x) = \{(D_j, \beta_j), j=1, 2, \dots, N\} \quad (5)$$

假设单个评价结果 D_j 的效用值为 $\mu(D_j)$, 则 $S(x)$ 的期望效用为:

$$\mu(S(x)) = \sum_{j=1}^N \mu(D_j) \beta_j \quad (6)$$

1.3 扩展置信规则库优化

目前对于扩展置信规则库的优化主要分为参数优化与结构优化两类,在结构优化方面降低激活规则不一致性与确定规则库规则数量是目前研究的重点^[10-12]。在参数优化方面,主要集中在置信规则库的参数优化^[13-16],对于扩展置信规则库的参数优化研究仍然较少,但在实际应用过程中,EBRB 推理效果很大程度上也受到参数的影响,特别是对于由数据驱动方式构建的 EBRB 而言,规则数量少则几十条多则几百条,如果全由人为来设置初始规则权重主观性较大,因此有必要对 EBRB,特别是数据驱动方式构建的 EBRB 进行参数的优化。本文提出了基于中心-离散粒子群算法的扩展置信规则库参数优化模型。首先通过数据驱动的方式构建原始置信规则库,然后使用证据推理结合群智能算法提出新的参数学习模型,将规则权重与前提属性权重作为待优化参数,实现 EBRB 参数优化,同时针对规则之间不一致性问题通过设置激活规则阈值来进行筛选,降低了激活规则的不一致性。通过参数优化与结构优化,较好地提高了 EBRB 的推理效果。

2 中心离散粒子群扩展置信规则库参数训练方法

2.1 中心离散粒子群算法

粒子群算法是一种群智能优化算法^[17],它由美国社会心理学博士 Kennedy 与电气工学博士 Eberhart 所提出,具有收敛速度快、强鲁棒性等特点,适合用来解决数值型问题的优化。在标准粒子群算法基础上,出现了许多改进的方法,例如自适应参数优化方法、动态与静态拓扑结构、强化种群多样性与全局收敛性的新学习策略等。本文所采用的是对学习策略进行优化的中心-离散粒子群算法(center-discrete particle swarm optimization, CDPSO),该算法的基本流程如下。

步骤 1 初始化种群,设定粒子的初始位置和速度,在约束条件下对粒子的速度随机地赋予初值,粒子的个体为需要训练的参数。

步骤 2 为种群设置初始的学习策略选择系数,设置公式如下:

$$S_i = i \% 2 + 1, i=1, 2, \dots, NP \quad (7)$$

式中: $i \% 2$ 表示对 2 取余数,以下类同; NP 为迭代次数。

步骤 3 粒子适应度值计算,定义个体适应度的计算公式,每个粒子适应度通过将每个种群代入目标函数依次计算,并选出种群的最优个体与全局最优解。

步骤 4 更新种群的学习策略,设置为每 τ 次迭代更新一次种群的学习策略。

$$S_i = 3 - S_i, \text{ if } t \% \tau = 0, i=1, 2, \dots, NP \quad (8)$$

步骤 5 更新粒子位置和速度,根据种群的不同学习策略代入数据计算得到粒子的新位置和速度。

中心学习策略:

$$v_i^j(t+1) =$$

$$\omega_1 v_i^j(t) + c_1 r(\text{Center}_i^j(t) - x_i^j(t)) \quad (9)$$

$$x_i^j(t+1) = x_i^j(t) + v_i^j(t+1) \quad (10)$$

$$\text{Center}_i^j(t) = \frac{1}{L} \sum_{l=1}^L p_{\text{best } l, j}^{(t)} \quad (11)$$

$$\text{if } S_i = 1, i=1:NP$$

离散学习策略:

$$v_i^j(t+1) = \omega_1 v_i^j(t) +$$

$$c_1 r(p_{\text{best } \gamma_i(j)}^j(t) - x_i^j(t)) \quad (12)$$

$$x_i^j(t+1) = x_i^j(t) + v_i^j(t+1) \quad (13)$$

$$\gamma_i(j) = \text{rand} \% N, \gamma_i(j) \in [1, N] \quad (14)$$

$$\text{if } S_i = 2, i=1:NP$$

步骤 6 若当前种群最优解满足收敛精度或者达到迭代次数的最大值,则视为最优解,算法结束,否则返回步骤 3。

2.2 固定数量规则激活方式

在初始的规则激活方式中,规则激活权重大于零的规则都会被激活,并且用于合成推理结果。但在实际情况中,不是所有规则都对结果推理起正作用,规则之间的不一致性反而会降低推理结果的准确性。文献^[18]通过设置规则激活权重阈值选择激活规则的数量,但对于不同的输入而言系统规则激活权重是变化的,给定一个固定的激活权重阈值只能确保大于该阈值的规则被激活,无法保证每一次激活规则的数量,对于不同输入可能存在激活规则过多或过少的情况,导致输出出现较大误差。鉴于此,本文通过设置激活规则阈值来固定激活规则数量,以此提高规则之间的一致性。本文中激活规则数量为系统规则数量 20% 左右输出结果较好。

2.3 参数的约束条件与优化模型

参数优化的实质实际上是利用输入与输出值来

矫正系统的初始参数,从而提高系统的性能,参数优化的基本模型见图1。




图1 扩展置信规则库优化模型

系统优化的目标是使系统的真实输出值 y'_m 与系统的推理输出值 y_m 之间的误差 $\xi(p)$ 最小,关于 $\xi(p)$ 有几种表示方式,例如平均绝对误差(MAE),均方误差(MSE),平均误差(MAP)等,这里我们选择平均绝对误差作为目标函数。

$$\xi(p) = \left(\frac{1}{M}\right) \sum_{m=1}^M (y_m - y'_m)^2 \quad (15)$$

在扩展置信规则库参数训练中,设置的参数约束条件为:

1)规则权重需要归一化:

$$0 \leq \theta_k \leq 1; \quad k=1,2,\dots,L \quad (16)$$

2)前提属性需要归一化:

$$0 \leq \delta_i \leq 1; \quad i=1,2,\dots,T \quad (17)$$

3 实例分析

本文以锂离子电池为研究对象,使用优化后的EBRB构建锂离子电池状态估计模型,并将本文提出的方法与BP神经网络及使用Fmincon优化的EBRB进行比较以验证该方法的有效性。

3.1 实验数据分析

本文选择了室温条件下得到的B05、B06、B07和B18共4组锂离子电池数据^[19]进行状态估计模型的验证。实验中电池的额定容量为2 A·h,进行充电、放电和阻抗测量实验。当电池剩余容量达到额定容量的70%(失效阈值)时就停止实验,实验数据的退化曲线见图2。

通过对实验数据分析可得,随着实验的次数增加,锂离子电池的放电时间越来越短,因此放电时间的长短与锂离子电池的状态关系十分紧密,文献^[20]提出了等压降放电时间(TIEDVD)这个指标来描述电池的状态。同时,放电过程中的温度也是对锂离子电池状态进行评估的另一个重要参数,当温度升高时,电池的放电效果可能会出现提升,但是此时电池可能已经接近失效阈值,本文将等压降放电过程中的平均温度(MT)也作为表征电池状态的关键特征。对于锂离子电池的健康状态,一般可以采用容量、功率及阻抗来表征,在电池数据集中容量已

经测得,因此本文选择电池的剩余容量作为表征电池状态的健康因子。

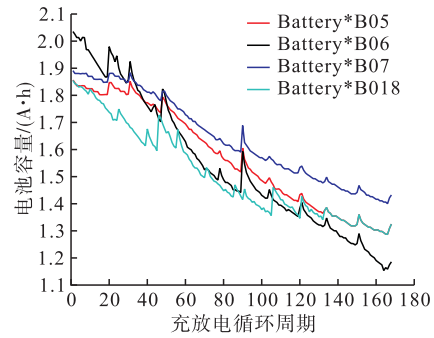


图2 锂电池退化曲线

3.2 数据集选择及扩展置信规则库构建

通过对实验数据分析,本文选择了电池等压降放电时间与放电过程中电池平均温度作为扩展置信规则库的前提属性,电池放电电压起始值为3.8 V,结束值为3.2 V。选择电池剩余容量作为扩展置信规则库输出部分。系统规则库数据集为B06,训练数据集为B07,测试数据集为B05与B18。将B06数据输入模型当中,以数据驱动方式构建初始规则库,规则数量为168条,初始规则权重与前提属性权重默认为1,并以此组成原始RBEBS系统,然后通过CDPSO算法对原始EBRB系统进行参数优化,模型的流程图见图3。

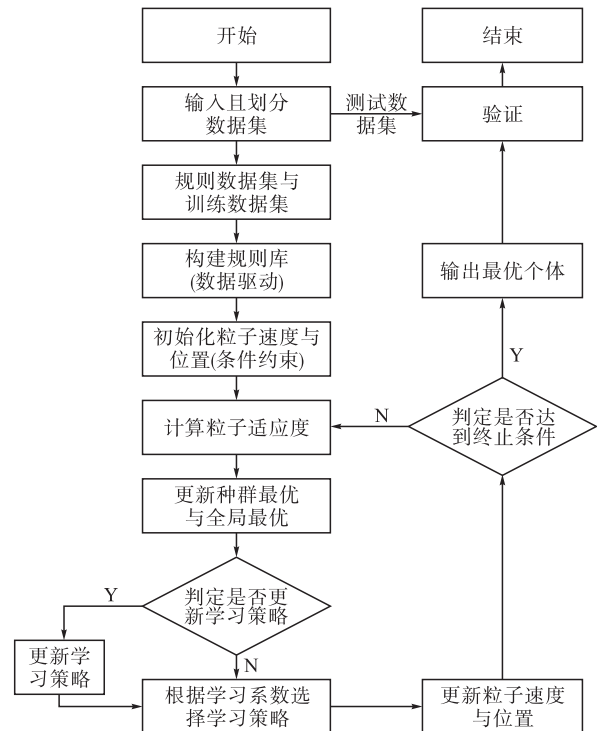


图3 基于CDPSO的EBRB参数优化模型

原始系统的拟合结果见图4与图5。

从图中可以看出,原始EBRB系统对于B05与B18数据集的拟合效果不佳,因此需要对原始EBRB系统进行参数优化,提高系统的准确性。在

模型优化过程中,设定粒子群迭代次数为 300 次,初始种群大小为 50,CDPSO 的其它初始参数为 $c_1 = 2.0$ 、 $c_2 = 1.0$ 、 $\omega_1 = 0.7$ 、 $\omega_2 = 0.6$,训练数据集选择 B07,EBRB 系统输入为 B07 的等压降放电时间与平均温度,输出为 B07 电池容量的预测值。优化后等压降放电时间前提属性权重为 0.614 5,平均温度前提属性权重为 0.018 3,优化后的规则权重数量较多,限于篇幅,在此不再列出。优化后的 EBRB 系统拟合见图 6 与图 7。

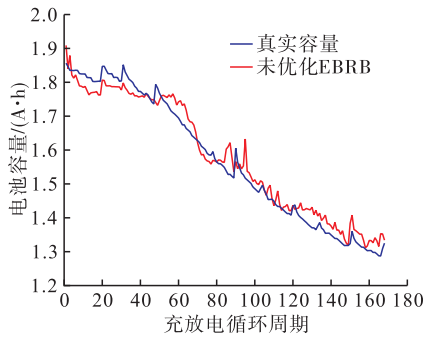


图 4 B05 原始系统推理结果

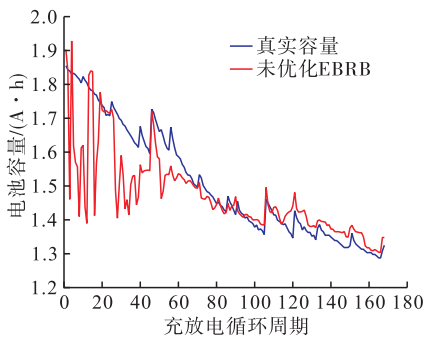


图 5 B18 原始系统推理结果

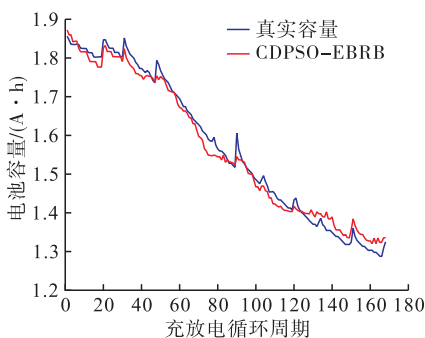


图 6 B05 优化后 EBRB 推理结果

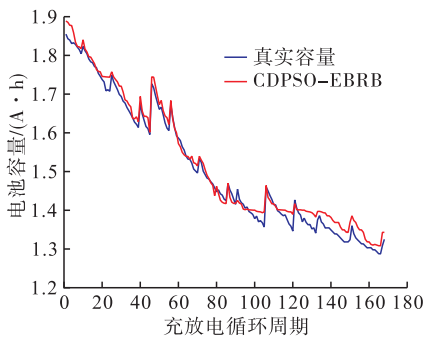


图 7 B18 优化后 EBRB 推理结果

从图中可以看出优化后的拟合效果有了明显地提升,相比于原始 EBRB 模型,能更加准确反映真实情况。

3.3 实验效果对比

3.3.1 BP 神经网络预测模型

本文选择 BP 神经网络作为对比方法之一。建立一个 5 层神经网络,其中输入层为 2 个节点,分别输入的是等压降放电时间与平均温度,输出层的节点为 1,输出电池容量,建立 3 个隐含层,节点数分别为 6,6,1。第 1 层与第 2 层隐含层采用了 Logsig 函数,第 3 层采用了 Purelin 函数,设置的最大迭代次数为 5 000,训练目标误差为 0.000 1,利用训练数据对网络进行训练。

3.3.2 Fmincon 函数优化

Fmincon 作为有约束最小化函数也经常用来求解参数优化问题,本文使用 Fmincon 构建另一个参数优化 EBRB 模型,用来与 CDPSO-EBRB 进行对比。

3.3.3 结果估计

采用 BP 神经网络与 Fmincon 函数优化的 EBRB 模型输出结果见图 8 及图 9。




图 8 B05 的 BP 及 Fmincon-EBRB 输出




图 9 B18 的 BP 及 Fmincon-EBRB 输出

从图中可以看出 Fmincon-EBRB 与 BP 推理的效果相较于原始 EBRB 都有所提高,但是误差仍然较大。

3 种方法对测试数据的估计结果、累积误差及 MSE 大小见图 10~13 及表 1~2。从图中可以看出 CDPSO-EBRB 模型的输出结果最接近真实值,

其产生的累积误差值也比较小。Fmincom-EBRB在整个过程中误差值基本上都大于 CDPSO-EBRB,同时对于 B18 数据集而言,BP 神经网络在开始阶段的效果好于 CDPSO-EBRB,但是整个拟合过程效果仍然稍逊于 CDPSO-EBRB。

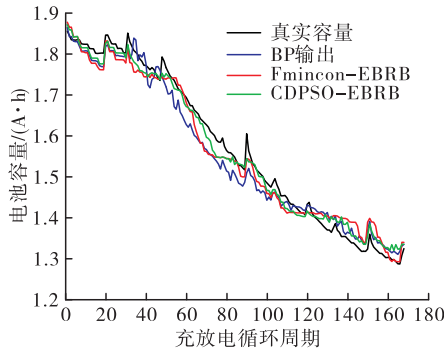


图 10 B05 测试数据效果对比




图 11 B18 测试数据效果对比

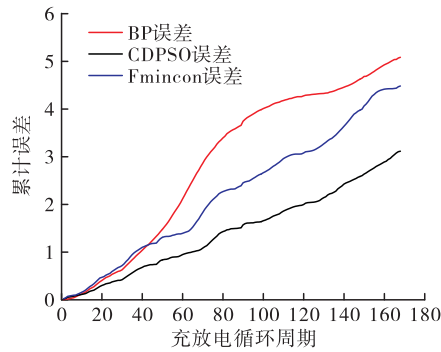


图 12 B05 累积误差

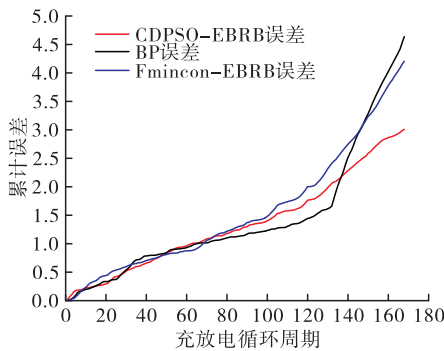


图 13 B18 累积误差

表 1 B05 MSE 对比

方法	CDPSO-EBRB	BP	Fmincon-EBRB	EBRB
MSE	4.68e-04	1.1e-03	9.82e-04	1.6e-03

表 2 B18 MSE 对比

方法	CDPSO-EBRB	BP	Fmincon-EBRB	EBRB
MSE	4.51e-04	1.7e-03	9.55e-04	1.1e-02

从图 12~13 与表 1~2 中可见 CDPSO-EBRB 的拟合效果最好。

4 结论

本文针对通过数据驱动方式构建的 EBRB 存在参数过多,拟合效果差的问题,提出了一种基于中心-离散粒子群算法的 EBRB 参数优化模型,并将其应用于锂离子电池健康状态估计中,验证了 CDPSO-EBRB 性能,同时与 BP 神经网络和 Fimcon-EBRB 进行了对比,实验结果显示:

1)EBRB 通过数据驱动构建规则库,通过历史数据进行参数的优化,优化后的 EBRB 相较于原始 EBRB 估计效果有了明显提升。

2)CDPSO-EBRB 与 BP 神经网络及 Fimcon-EBRB 进行对比,结果显示 CDPSO-EBRB 整体拟合效果较好,虽然在部分阶段效果差于 BP 神经网络,但与其它两种方法相比其累积误差与 MSE 最小。

3)CDPSO-EBRB 对于锂离子电池的状态估计具有较高的精度,且相较于传统的神经网络有着更高解释性,不仅可以克服神经网络存在的过拟合的问题,而且可较好说明结果的推理过程。

参考文献

[1] ZHANG J, LEE J. A Review on Prognostics and Health Monitoring of Li-ion Battery[J]. Journal of Power Sources, 2011, 196 (15): 6007-6014.

[2] 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.

[3] 罗悦. 基于粒子滤波的锂离子电池剩余寿命预测方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2012.

[4] 罗伟林, 张立强, 吕超, 等. 锂离子电池寿命预测国外研究现状综述[J]. 电源学报, 2013, 1(1): 140-144.

[5] 周志杰, 杨剑波, 胡昌华, 等. 置信规则库专家系统与复杂系统建模[M]. 北京: 科学出版社, 2011.

[6] ZHU H Z, XIAO M Q, YANG L H, et al. A Minimum Centre Distance Rule Activation Method for Extended Belief Rule-Based Classification Systems[J]. Applied Soft Computing Journal, 2020, 91: 1568-4946.

[7] ZHU H Z, XIAO M Q, ZHAO X, et al. A Structure Optimization Method for eExtended Belief-Rule-Based Classification System[J]. Knowledge-Based Systems,

- 2020,203: 0950-7051.
- [8] LIU J, MARTINEZ L, CALZADA A, et al. A Novel Belief Rule Base Representation, Generation and Its Inference Methodology[J]. Knowledge-Based Systems, 2013, 53: 129-141.
- [9] YANG J B, LIU J, WANG J, et al. Belief Rule-Base Inference Methodology Using the Evidential Reasoning Approach-RIMER [J]. IEEE Transactions on Systems, Man and Cybernetics Part A: Systems and Humans, 2006, 36 (2): 266-285.
- [10] 刘莞玲, 肖承志, 傅仰耿. 哈希索引的扩展置信规则库推理方法[J]. 西安电子科技大学学报, 2019, 46 (2):145-151.
- [11] 林燕清, 傅仰耿. 基于 NSGA-II 的扩展置信规则库激活规则多目标优化方法[J]. 智能系统学报, 2018, 13(3): 422-430.
- [12] 张婕, 傅仰耿, 巩晓婷. 利用聚类分析构建基于析取范式的置信规则库[J]. 福州大学学报, 2019, 47 (4): 435-440.
- [13] 王韩杰, 杨隆浩, 傅仰耿, 等. 专家干预下置信规则库参数训练的差分进化算法[J]. 计算机科学, 2015, 42(5): 88-93.
- [14] TANG X L, WANG X Q, et al. Health Condition Estimation of Spacecraft Key Components Using Belief Rule Base[J]. Enterprise Information Systems, 2019,9(4): 1751-7575.
- [15] 刘莞玲, 王韩杰, 傅仰耿. 基于差分进化算法的置信规则库推理的分类方法[J]. 中国科学技术大学学报, 2016,46(9):764-773.
- [16] 吴伟昆, 杨隆浩, 傅仰耿, 等. 基于加速梯度求法的置信规则库参数训练方法[J]. 计算机科学与探索, 2014, 8(8): 989-1001.
- [17] 张庆科. 粒子群优化算法及差分进行算法研究[D]. 济南:山东大学, 2017.
- [18] 林燕清, 傅仰耿. 基于改进相似性度量的扩展置信规则库规则激活方法[J]. 中国科学技术大学学报, 2018, 48(1):20-27.
- [19] Lithium-ion Battery Data Set from NASA[DB/OL]. <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>.
- [20] LIU D T, WANG H, PENG Y. Satellite Lithium-Ion Battery Remaining Cycle Life Prediction with Novel Indirect Health Indicator Extraction [J]. Energies, 2013, 6(8): 3654-3668.

(编辑:徐敏)