

控制与决策

Control and Decision

基于灰色扩展卡尔曼滤波模型的锂电池健康状态估计

徐志存, 谢乃明

引用本文:

徐志存, 谢乃明. 基于灰色扩展卡尔曼滤波模型的锂电池健康状态估计[J]. *控制与决策*, 2026, 41(5): 1392–1402.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0537>

您可能感兴趣的其他文章

Articles you may be interested in

[孤岛微电网异构电池储能系统的分布式有限时间次级控制](#)

Distributed finite-time secondary control for heterogeneous battery energy storage systems in an islanded microgrid

控制与决策. 2021, 36(8): 2034–2041 <https://doi.org/10.13195/j.kzyjc.2020.0012>

[含混合储能的互联电力系统传感器容错负荷频率控制](#)

Sensor fault-tolerant load frequency control for multi-area interconnected power system with hybrid energy storage system

控制与决策. 2021, 36(5): 1069–1077 <https://doi.org/10.13195/j.kzyjc.2019.1432>

[基于指数趋近律的车载复合储能系统全局滑模控制](#)

Global sliding mode control of vehicle-mounted hybrid energy storage system based on exponential reaching law

控制与决策. 2021, 36(4): 885–892 <https://doi.org/10.13195/j.kzyjc.2019.0478>

[基于HI-DD-AdaBoost.RT的锂离子动力电池SOH预测](#)

Prediction of Li-ion battery SOH based on HI-DD-AdaBoost.RT

控制与决策. 2021, 36(3): 686–692 <https://doi.org/10.13195/j.kzyjc.2019.0764>

[数据驱动的综合能源系统运行优化方法研究综述](#)

Review of research of data-driven methods on operational optimization of integrated energy systems

控制与决策. 2021, 36(2): 283–294 <https://doi.org/10.13195/j.kzyjc.2020.0725>

基于灰色扩展卡尔曼滤波模型的锂电池健康状态估计

徐志存, 谢乃明[†]

(南京航空航天大学 经济与管理学院, 南京 211106)

摘要: 锂电池健康状态估计作为现代能源存储技术的核心, 广泛应用于电动汽车、移动设备等领域. 随着使用时间的增长, 其性能衰减问题逐渐显现, 这不仅会影响电池的存储能力, 还可能引发安全隐患, 因此, 准确估计锂电池的健康状态显得尤为重要. 经验模型是锂电池退化理论中常用的解决方法, 其中的双指数模型可演化推导出幂指数驱动的灰色 GM(1,1,e^{λt}) 模型. 在 GM(1,1,e^{λt}) 模型的基础上建立状态空间模型, 融合扩展卡尔曼滤波模型形成灰色扩展卡尔曼滤波模型. 将所提出的灰色扩展卡尔曼滤波模型用于锂电池健康状态非线性退化估计问题. 采用牛津大学公开的单体电池数据进行验证, 在单个电池的基础上将所提出模型用于估计 20 辆电动汽车的锂电池健康状态, 以进一步验证所提出模型在实际场景中的适用性.

关键词: 灰色模型; 锂电池; 滤波; 状态估计; 健康管理; 电动汽车

中图分类号: TP18 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2025.0537

引用格式: 徐志存, 谢乃明. 基于灰色扩展卡尔曼滤波模型的锂电池健康状态估计 [J]. 控制与决策, 2026, 41(5): 1392-1402.

Lithium battery state of health estimation based on grey extended Kalman filter model

XU Zhi-cun, XIE Nai-ming[†]

(College of Economics and Management, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

Abstract: As the core of modern energy storage technology, lithium battery health state estimation is widely used in electric vehicles, mobile devices and other fields. With the growth of the use time its performance degradation problem gradually appears, which not only affects the storage capacity of the battery, but also may lead to safety hazards, so it is particularly important to accurately estimate the health state of lithium batteries. Empirical modeling is a common solution in the theory of lithium battery degradation. The double-exponential model in the empirical model can be evolved to derive the power-exponential driven GM(1,1,e^{λt}) model. A state-space model is built on the basis of the GM(1,1,e^{λt}) model, and the extended Kalman filter model is integrated to form the grey extended Kalman filter model. The proposed grey extended Kalman filter model is applied to the problem of nonlinear degradation estimation of the health state of lithium batteries. Publicly available data from the University of Oxford is adopted for single cell batteries. On the basis of a single cell, we use the proposed model in the estimation of lithium battery health state of 20 electric vehicles to further validate the applicability of the proposed model in real-world scenarios.

Keywords: grey model; lithium battery; filtering; state estimation; health management; electric vehicle

0 引言

近年来, 锂电池在电动汽车、航空、卫星、移动设备上广泛运用. 锂电池的健康状态会随着使用时间的逐渐增长而逐步出现问题, 因此有必要对锂电池的健康状态进行研究. 锂电池的健康状态指的是电池在使用过程中的老化程度, 一般用 SOH 表示.

电池健康状态的定义分为多种, 可以基于内阻、功率、自放电、容量等多个不同的层面定义锂电池的健康状态^[1]. 在锂电池健康状态估计的研究中主要分为两类: 一是根据实验分析法, 二是基于模型的方法^[2].

实验分析法可以通过直接采集的实验数据对电池健康状态进行表征, 也可以在实验数据的基础上

收稿日期: 2025-05-25; 录用日期: 2025-11-05.

基金项目: 国家自然科学基金项目 (92367301, 72171116, 72571138, T2441003); 南京航空航天大学中央高校基本科研业务费项目 (NK2023001, NP2024203); 江苏省 333 高层次人才培养计划项目.

责任编委: 张丹.

[†]通信作者. E-mail: xienaiming@nuaa.edu.com.

采用间接的方法, 例如容量增量曲线^[3]或者差分电压曲线等间接表征锂电池的健康状态^[4]. 间接分析法是通过测量能够反映电池容量或内阻的过程参数来标定健康状态, 过程参数也称作健康因子. Wen 等^[5]结合容量增量法 (ICA) 建立在线实时校正的预测模型, 并不断更正特征数据, 保证了不同老化状态下的 SOH 的预测精度. 针对 ICA 在卫星电池健康状态估计中存在的问题, 陈景龙等^[6]提出一种带平滑处理并使用放电数据的容量增量分析法来估计电池的健康状态. Wang 等^[7]提出一种利用电压差分曲线的两个拐点之间的位置间隔或变换参数来估计电池健康状态的新方法. Pastor-Fernández 等^[8]将电化学阻抗谱和容量增量-差分电压作为锂离子诊断技术来识别和量化电池管理系统中退化模型的影响. 容量增量法和差分电压分析法是研究电池健康状态的常用方法.

基于模型的方法可划分为自适应算法和数据驱动的方法. 自适应算法需要借助电化学模型或等效电路模型, 通过对模型参数的辨识完成 SOH 的标定, 主要包括联合估计法、协同估计法等. 吴忠强等^[9]提出自适应滤波算法对锂电池的荷电状态和健康状态进行联合估计; 谭泽富等^[10]提出改进的双自适应卡尔曼滤波算法用于联合估计锂电池的荷电状态和健康状态; 王若琦等^[11]将双自适应无迹卡尔曼滤波算法用于锂电池荷电状态和健康状态的联合估计. 从这些研究中可以看出, 卡尔曼类滤波算法一般用来对锂电池状态进行估计.

数据驱动的方法往往具有更强的非线性逼近能力, 并且对不同电池与工况具有较强的适用性. 这种方法将电池实际运行的历史和实时数据与深度学习^[12]、长短期记忆神经网络 (LSTM)^[13]、支持向量机^[14]等智能算法相结合来估计电池的健康状态. Zhu 等^[15]从端到端深度学习的视角预测锂电池的健康状态. 机器学习等智能算法的预测精度依赖于提取的老化特征, 且需要大量的数据来进行训练和学习. 以上学者对锂电池的健康状态进行了研究, 锂电池的存储能力和快速充放电能力会随着老化而不断下降, 而 SOH 正是用于评价锂电池老化程度的量化指标. 以上文献研究属于对锂电池健康管理中非常常用的研究方法.

近些年, 逐渐有学者采用灰色系统理论的方法研究锂电池的相关问题. 灰色系统理论随着近些年的发展, 模型形式日渐复杂, 对于应用领域也逐渐广泛. 在航空领域, 刘小峰等^[16]利用灰色理论预测了航空发动机的剩余寿命; 在复杂装备领域, 吴利丰等^[17]

采用 GM(0, N) 模型预测复杂装备研制费用; 杨璐等^[18]提出可解释非线性灰色 Bernoulli 模型应用于结构疲劳寿命预测. 在最新的研究中, 有学者开始采用灰色系统理论在锂电池领域做一些相关的研究. 例如, 刘连义等^[19]采用递归离散灰色模型用于航空锂电池寿命预测; 涂乐平等^[20]将含分数阶微积分的非等间距灰色模型用于锂电池的容量退化; 于仲安等^[21]采用灰色多变量模型预测锂电池的荷电状态 (SOC); 韦海燕等^[22]采用灰色神经网络技术在线估计锂电池的健康状态 SOH. 这些研究中学者采用灰色系统理论解决实践中存在的问题, 使得研究具有非常重要的价值, 但是并没有学者去解释为什么采用灰色系统理论可以解决这一问题. 在电池管理系统中的相关研究中, 经验模型是非常常用的一种方法. 经验模型主要依赖于电池的物理和化学特性, 通过使用经验或半经验公式来估计电池的健康状态. 这些公式通常根据实验数据或历史数据得出, 可以反映电池的老化程度. 但是, 对不同电池和工况的适用性有限, 经验模型一般会与滤波算法进行组合使用. 下面总结一些经验模型与滤波算法结合使用的案例以供参考, 见表 1.

表1 经验模型与滤波算法结合使用的文献总结

经验模型	滤波算法	文献
单指数模型	粒子滤波	[23-25]
单指数模型	无迹粒子滤波	[26]
双指数模型	扩展卡尔曼滤波	[27]
双指数模型	粒子滤波	[28-29]
多项式模型	卡尔曼滤波	[30]
多项式模型	双粒子滤波	[31]

Xu 等^[24]指出了经验模型与灰色模型之间的关系, 其中单指数模型与 GM(1,1) 模型的本质相同. 灰色模型能够将锂电池的非线性退化趋势处理成近似指数增长的形式, 更便于对锂电池的退化趋势进行预测. 研究中发现, 双指数模型与幂指数驱动的灰色 GM(1,1, $e^{\lambda t}$) 模型存在密切联系, 后文将给出推导过程. 本文旨在建立灰色系统理论与锂电池健康管理理论之间的桥梁, 更好地采用灰色系统理论解决锂电池健康管理理论中存在的问题.

本文首先构建灰色扩展卡尔曼滤波模型, 进行模型对比及收敛性能分析; 然后根据实验室数据估计锂电池健康状态, 并采用电动汽车数据估计锂电池健康状态; 最后给出结论.

1 灰色扩展卡尔曼滤波模型

本节将含有幂指数驱动的灰色模型与扩展卡尔

曼滤波模型相结合,形成灰色扩展卡尔曼滤波模型,用于解决锂电池健康状态估计问题.下面将对双指数模型与幂指数驱动模型关系、幂指数驱动灰色预测模型、扩展卡尔曼滤波模型、灰色扩展卡尔曼滤波模型分别展开介绍.

1.1 经验模型与 GM(1,1,e^{λt}) 模型的关系

锂电池经验模型是电池管理系统(BMS)中常用的模型,在经验模型中包含单指数模型、双指数模型等.根据经验模型的表达式,双指数模型的基本形式为

$$C_{n+1} = b_1 e^{b_2 n} + b_3 e^{b_4 n}, \quad (1)$$

其中 b_1, b_2, b_3, b_4 分别为双指数模型中的参数.对双指数模型进行一阶求导可以得到

$$\frac{dC_{n+1}}{dn} = b_2 b_1 e^{b_2 n} + b_4 b_3 e^{b_4 n} = b_4 C_{n+1} + e^{b_2 n} (b_1 b_2 - b_1 b_4), \quad (2)$$

则有

$$\frac{dC_{n+1}}{dn} - b_4 C_{n+1} = e^{b_2 n} (b_1 b_2 - b_1 b_4). \quad (3)$$

令 $-b_4 = a, b_1 b_2 - b_1 b_4 = b, b_2 = \lambda$, 有

$$\frac{dC_{n+1}}{dn} + a C_{n+1} = b e^{\lambda n}. \quad (4)$$

此时,式(4)与幂指数驱动灰色模型的微分方程形式极为类似,它是幂指数驱动灰色模型的一种退化形式,当幂指数驱动灰色模型中 $c = 0$ 时,则退化为锂电池经验模型中的双指数模型.灰色模型主要用来预测时间序列,需对 t 求导,而锂电池中是对锂电池的循环次数进行求导,因此用 n 代替,这里可以将锂电池的循环次数类比为时间序列.式(4)中,容量 C 指锂电池的原始容量数据.在灰色预测模型中存在累加算子,因此在幂指数驱动的灰色模型中 $\text{soh}^{(1)}$ 是对健康状态数据的一阶累加,这便是采用灰色模型与直接采用锂电池经验模型中的双指数模型的不同之处之一.在锂电池健康管理的相关文献中,双指数模型经常被拿来与滤波算法联合使用.幂指数灰色模型中含有可调节的非线性参数,同时扩展卡尔曼滤波算法对处理非线性估计问题具有良好的能力,因此本文采用幂指数驱动的灰色模型建立状态空间表达式,联合扩展卡尔曼滤波算法估计锂电池的健康状态SOH.

1.2 幂指数驱动灰色模型

1.2.1 幂指数驱动灰色模型构建

设 $\text{soh}^{(0)}$ 为锂电池健康状态的原始数据, $\text{soh}^{(1)}$ 为 $\text{soh}^{(0)}$ 的一阶累加序列, $Z^{(1)}$ 为 $\text{soh}^{(1)}$ 的紧邻均值生成序列.幂指数驱动的灰色预测模型的白化方程

为

$$\frac{d \text{soh}^{(1)}(t)}{dt} + a \text{soh}^{(1)}(t) = b e^{\lambda t} + c. \quad (5)$$

该模型记作 GM(1,1,e^{λt}) 模型.其中: a 为发展系数, $b e^{\lambda t} + c$ 为幂指数驱动的灰色作用量,参数 λ 为可调非线性参数.差分方程

$$\text{soh}^{(0)}(k) + a z^{(1)}(k) = b \left(\frac{e^\lambda - 1}{\lambda} \right) e^{\lambda(k-1)} + c \quad (6)$$

为 GM(1,1,e^{λt}) 模型的基本形式.

参数列 $\mu = [a, b, c]^T$ 的最小二乘参数估计为

$$\mu = (B^T B)^{-1} B^T Y. \quad (7)$$

其中

$$Y = \begin{bmatrix} \text{soh}^{(0)}(2) \\ \text{soh}^{(0)}(3) \\ \vdots \\ \text{soh}^{(0)}(n) \end{bmatrix}, \quad (8)$$

$$B = \begin{bmatrix} -z^{(1)}(2) & \frac{e^\lambda - 1}{\lambda} e^\lambda & 1 \\ -z^{(1)}(3) & \frac{e^\lambda - 1}{\lambda} e^{2\lambda} & 1 \\ \vdots & \vdots & \vdots \\ -z^{(1)}(n) & \frac{e^\lambda - 1}{\lambda} e^{\lambda(n-1)} & 1 \end{bmatrix}, \quad (9)$$

$$\hat{\mu} = \begin{bmatrix} \hat{a} \\ \hat{b} \\ \hat{c} \end{bmatrix}. \quad (10)$$

GM(1,1,e^{λt}) 模型的时间响应序列为

$$\hat{\text{soh}}^{(1)}(k) = \left(\text{soh}^{(0)}(1) - \frac{b}{a + \lambda} e^\lambda - \frac{c}{a} \right) e^{-a(k-1)} + \frac{b}{a + \lambda} e^{a k} + \frac{c}{a}, \quad (11)$$

累减还原序列为

$$\hat{\text{soh}}(k) = (1 - e^a) \left(\text{soh}^{(0)}(1) - \frac{b}{a + \lambda} e^\lambda - \frac{c}{a} \right) e^{-a(k-1)} + \frac{b(1 - e^\lambda)}{a + \lambda} e^{\lambda k}. \quad (12)$$

根据 $\hat{\text{soh}}(k)$ 的表达式,可以推导出第 k 项与第 $k + 1$ 项之间的关系表达式为

$$\text{soh}(k) = e^{-a} \text{soh}(k-1) + \frac{b(1 - e^\lambda)}{a + \lambda} e^{\lambda k} (1 - e^{-(\lambda+a)}). \quad (13)$$

1.2.2 参数λ取值对 GM(1,1,e^{λt}) 模型的影响

本节中,参数 λ 的取值范围设定为 $0 \sim 3$ 之间,设置依据如下:

1) 当参数 $\lambda = 0$ 时,由式(11)可以看出,模型退化为 GM(1,1) 模型.

2) 当参数 $\lambda = 1$ 时,有

$$\text{soh}^{(0)}(k) = e^{-a}\text{soh}^{(0)}(k-1) + \frac{b(1-e)}{a+1}e^k(1-e^{-(1+a)}). \quad (14)$$

式(14)可以简化为 $\text{soh}^{(0)} = \Psi e^k + \zeta$.

3) 当参数 $\lambda = 2$ 时, 有

$$\text{soh}^{(0)}(k) = e^{-a}\text{soh}^{(0)}(k-1) + \frac{b(1-e^2)}{a+2}e^{2k}(1-e^{-(2+a)}). \quad (15)$$

式(15)可简化为 $\text{soh}^{(0)} = \Psi e^{2k} + \zeta$.

4) 当参数 $\lambda = 3$ 时, 同样地, 可以简化为 $\text{soh}^{(0)} = \Psi e^{3k} + \zeta$.

该模型以指数形式增长, 因此参数一般设置为 0 ~ 3 之间, 超过 3 的参数设置会导致序列增长过快, 不符合实际需求.

1.3 扩展卡尔曼滤波模型

扩展卡尔曼滤波模型是卡尔曼滤波模型的扩展形式, 该模型可以处理非线性系统的状态估计问题. 其基本思想是对非线性系统进行一阶泰勒展开, 将非线性系统转化为线性系统, 即可应用卡尔曼滤波模型对锂电池进行状态估计.

假设一个非线性系统的状态方程为

$$x_{k+1} = f(x_k, u_k) + w_k, \quad (16)$$

观测方程为

$$y_k = h(x_k) + v_k. \quad (17)$$

其中: x_k 为状态变量, u_k 为系统输入变量, y_k 为观测变量, w_k 为状态误差, v_k 为观测误差. 通常假设状态误差和观测误差为零均值的高斯白噪声, 协方差为 Q_k 和 R_k . 扩展卡尔曼滤波模型与卡尔曼滤波模型一样, 都分为预测和更新两个步骤实现滤波过程.

预测阶段: 通过系统的非线性状态方程预测下一个时刻的状态为

$$\hat{x}_k = f(x_{k-1}, u_{k-1}), \quad (18)$$

协方差预测为

$$\hat{P}_k = A_k P_{k-1} A_k^T + Q_k, \quad (19)$$

其中 A_k 为状态预测函数 $f(\cdot)$ 的雅可比矩阵, 计算为

$$A_k = \left. \frac{\partial f}{\partial x} \right|_{\hat{x}_{k-1}, u_{k-1}}. \quad (20)$$

更新阶段: 计算卡尔曼增益为

$$K_k = \hat{P}_k H_k^T (H_k \hat{P}_k H_k^T + R_k)^{-1}, \quad (21)$$

状态更新为

$$x_k = \hat{x}_k + K_k (y_k - h(x_k)), \quad (22)$$

协方差更新为

$$P_k = (I - K_k H_k) \hat{P}_k, \quad (23)$$

其中 H_k 为测量方程的 $h(\cdot)$ 的雅可比矩阵, 计算为

$$H_k = \left. \frac{\partial h}{\partial x} \right|_{\hat{x}_k}. \quad (24)$$

至此对扩展卡尔曼滤波介绍完毕. 扩展卡尔曼滤波器是对非线性函数进行一阶泰勒级数展开, 忽略高阶项, 从而将非线性问题转化为线性问题. 扩展卡尔曼滤波器与卡尔曼滤波器模型求解方法相似, 但相比卡尔曼滤波器, 扩展卡尔曼滤波器可以处理一些非线性问题. 本节采用扩展卡尔曼滤波器融合幂指数驱动的灰色预测模型形成灰色扩展卡尔曼滤波器, 估计锂电池健康状态问题.

1.4 灰色扩展卡尔曼滤波模型

由式(13)可以得到灰色扩展卡尔曼滤波模型的状态空间表达式为

$$\text{soh}(k) = e^{-a}\text{soh}(k-1) + \frac{b(1-e^\lambda)}{a+\lambda}e^{\lambda k}(1-e^{-(\lambda+a)}) + \omega_k, \quad (25)$$

观测方程为

$$y_k = \text{soh}^{(0)}(k) + v_k, \quad (26)$$

求解状态预测函数的雅可比矩阵为

$$A_k = e^{-a}, \quad (27)$$

预测阶段的协方差为

$$\hat{P}_k = A_k P_{k-1} A_k^T + Q_k, \quad (28)$$

测量方程的雅可比矩阵为

$$H_k = I, \quad (29)$$

计算更新阶段的卡尔曼增益为

$$K_k = \hat{P}_k H_k^T (H_k \hat{P}_k H_k^T + R_k)^{-1}. \quad (30)$$

状态更新如下:

$$\text{soh}_k = \hat{\text{soh}}_k + K_k (y_k - \hat{\text{soh}}_k), \quad (31)$$

协方差更新如下:

$$P_k = (I - K_k H_k) \hat{P}_k. \quad (32)$$

1.5 模型评价标准

本文使用的模型评价标准是平均绝对百分比误差 (MAPE), 即

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|\text{soh}^{(0)}(i) - \hat{\text{soh}}^{(0)}(i)|}{\text{soh}^{(0)}(i)}. \quad (33)$$

评价标准的值越小, 表示性能越好. 具体而言, MAPE 值通常低于 10%, 在模型可接受的评估范围内.

1.6 灰色扩展卡尔曼滤波模型算法步骤

在建立上述模型的基础上形成灰色扩展卡尔曼滤波模型估计锂电池健康状态, 步骤如下.

step 1: 通过幂指数驱动的灰色 GM(1,1,e^{λt}) 模

型建立第 $k-1$ 项与第 k 项之间的递推关系式.

step 2: 给出状态方程和观测方程, 搭建状态空间模型.

step 3: 结合扩展卡尔曼相关理论, 形成灰色扩展卡尔曼滤波模型.

step 4: 根据公开数据集估计锂电池健康状态 SOH.

step 5: 模型算法精度比较.

2 模型对比及收敛性能分析

2.1 模型对比

为保证模型在不同数据集上的有效性, 同时与其他非线性方法进行对比, 本节采用 NASA 数据集进行模型对比, 结果见表 2. 表 2 前 3 列数据来自文献 [32]. VMD-LSTM 为变分模态分解-长短时记忆神经网络, HI-GPR 为基于间接健康指标的高斯过程回归, MGM-TCN-PF 为代谢灰色模型-时间卷积网络-粒子滤波. 评判指标来源于文献 [32], 包含均方误差 MSE、均方根误差 RMSE、平均绝对误差 MAE、平均绝对百分比误差. 数据源为 NASA 公开锂电池数据集 B18. 文献 [32] 采用一半数据进行训练, 为保证对比的公平性, 本节内容设置与对比文献相同. 灰色扩展卡尔曼滤波模型的健康状态估计结果如图 1 所示. 其中: $a=0.0027$, $b=0.0002$, $c=0.9213$, $\lambda=0.06$.

表2 锂电池模型对比结果 %

	VMD-LSTM	HI-GPR	MGM-TCN-PF	GMEKF
MAE	3.12	3.4	2.86	2.41
RMSE	3.82	4.13	3.21	3.03
MSE	0.15	0.17	0.1	0.09
MAPE	2.21	2.45	4.06	3.42





图1 锂电池 B18 健康状态估计结果


从表 2 中可以看出, 所提出的灰色扩展卡尔曼滤波模型在 MAE、RMSE、MSE 中的精度均高于文献 [32] 模型, 在 MAPE 指标下, 灰色扩展卡尔曼滤波模型的精度高于文献 [32] MGM-TCN-PF 模型, 略差于另外两种模型. 整体来看, 所提出灰色扩展卡尔曼滤波模型性能较好.

以锂电池 B29 为例展开非线性对比实验估计精

度和计算耗时的比较. 非线性方法采用粒子滤波与灰色扩展卡尔曼滤波模型进行对比. 在灰色卡尔曼滤波模型中, $a=0.003125$, $b=5.19e-10$, $c=1.840983$, $\lambda=0.78$, 其估计误差 MAPE 为 1.00%, 运行时间 0.22 s. 粒子滤波模型估计误差 MAPE 为 2.79%, 历时 2.84 s. 运行结果见图 2 非线性滤波对比实验. 从估计精度和计算耗时两方面看, 所提出灰色扩展卡尔曼滤波模型优于粒子滤波.



(a) 灰色扩展卡尔曼滤波



(b) 粒子滤波

图2 非线性滤波对比实验

2.2 收敛性能分析

在上述对比模型的基础上对模型的收敛性能进行实验分析. B18 的训练数据为 66, 为保证模型性能的稳定, 依据文献 [32] 分别采用 66、86、106 个循环数据进行训练, 剩余循环数据用于锂电池健康状态估计. 不同循环数据下的健康状态估计结果见图 3. 起始点为 86 个周期的参数 $a=0.0029$, $b=2.14e-114$, $c=0.9270$, $\lambda=3$. 起始点为 106 个周期的参数 $a=0.0029$, $b=1.65e-27$, $c=0.9284$, $\lambda=0.55$. 3 个不同起始周期的健康状态 MAPE 估计结果为 3.42%、3.18%、2.23%. 可以看出, 随着训练长度的增长, 模型的稳定性能有所增长, 表明该模型有较强的鲁棒性.

3 实验室锂电池数据健康状态估计

数据集由智能电池实验室公开发布^[33]. 测试对象是 8 块 Kokam 公司生产的 SLPB533459H4 电池, 额定容量为 740 mAh. 实验采用 8 通道 Bio-Logic MPG-205 测试仪器, 在 40 °C 温室中进行. 数据集共包含两部分: ExampleDC_C1.mat 仅包含第 1 次充放

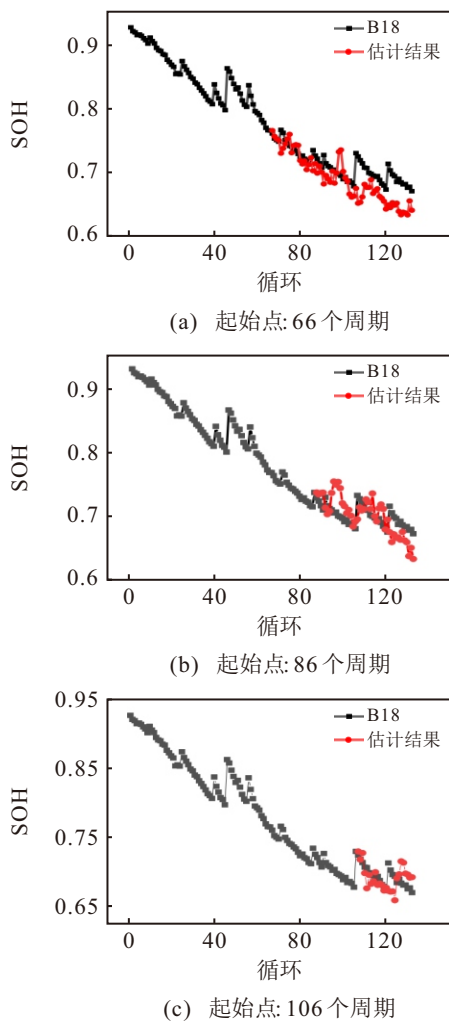


图3 不同循环训练数据的实验结果

电周期记录的电压、电流和温度数据; Oxford_Battery_Degradation_Dataset_1.mat 包含 8 个小型锂离子电池的电池老化数据测量, 每 100 个循环记录表征测试的结果直到电池寿命终止. 实验记录了充放电过程中的电流 (740 mA)、时间 (t , 单位: s)、电压 (v , 单位: volts)、电荷 (q , 单位: mAh), 温度 (T , 单位: $^{\circ}\text{C}$). 经过对牛津大学锂电池退化数据集 1 的放电数据进行提取及处理可以获得牛津大学锂电池数据集的健康状态 SOH. 图 4 为提取的牛津大学锂电池健康状态 SOH 的原始数据. 在实际生活中, 大量数据都是近似线性数据, 而不是真正意义上的线性数据. 由图 4 中放大部分可以看出, 牛津大学锂电池的健康状态数据也存在明显的非线性数据特征, 因此锂电池的健康状态退化问题可以考虑采用非线性方法进行解决.

本节采用幂指数驱动的灰色扩展卡尔曼滤波模型估计锂电池健康状态. 该模型是由经验模型中的双指数模型推导出幂指数驱动的灰色模型的一种特殊形式. 采用幂指数灰色预测模型建立状态空间模型, 融合扩展卡尔曼滤波算法形成灰色扩展卡尔曼

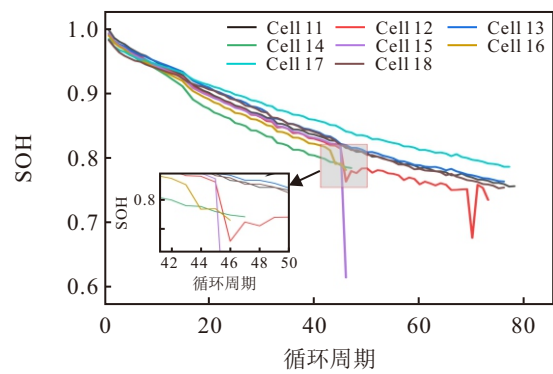


图4 牛津大学锂电池健康状态原始数据

滤波算法估计锂电池健康状态. 通过利用牛津大学锂电池健康状态数据对所提出的灰色扩展卡尔曼滤波模型的有效性进行验证.

灰色扩展卡尔曼滤波算法中的参数估计以平均绝对百分比误差的最小值作为目标函数, 主要采用最小二乘法对参数 a, b, c 进行估计, 同时采用网格法对非线性参数 λ 进行参数估计, 参数 λ 的在 $0 \sim 3$ 范围内进行搜索. 表 3 为牛津大学锂电池健康状态估计的参数值.

表3 牛津大学锂电池参数

参数	Cell 1	Cell 2	Cell 3	Cell 4
a	0.0041	0.0045	0.0040	0.0057
b	7.429 27e-74	-5.691 16e-11	1.747 32e-71	1.537 05e-45
c	0.9839	0.9860	0.9858	0.9875
λ	3	0.38	3	3
参数	Cell 5	Cell 6	Cell 7	Cell 8
a	0.0046	0.0049	0.0032	0.0038
b	4.284 05e-44	4.019 28e-44	5.995 18e-73	-7.654 25e-11
c	0.9853	0.9841	0.9740	0.9747
λ	3	3	3	0.32

在参数估计的基础上, 以 Cell 1 为例对采用灰色扩展卡尔曼滤波进行健康状态估计的步骤进行阐述. Cell 1 原始数据长度为 78, 采用 70% 的数据长度进行参数求解. 为了便于了解数据长度对健康状态估计结果的影响, 以 Cell 1 为例通过增减数据训练长度进行比较, 比较结果见表 4. 由表 4 可以看出, 随着训练数据长度的增加, Cell 1 的健康状态估计结果精度也在增加. 但不能一味追求估计结果精度的增加, 训练数据长度从 60% 增加到 70%, 估计误差降低 0.30%, 而 SOH 的估计长度减少 8. 当训练长度从 70% 增长到 80% 时, 估计误差降低 0.25%, 误差降低速度变缓, 而健康状态 SOH 的估计长度减少一半. 需要强调的是, 锂电池健康状态估计的核心目标是对电池整体衰退过程进行宏观监测, 而非单纯追求误差最小化. 因此, 在确保估计误差处于合理范围

内的前提下, 还需综合考虑可估计的 SOH 长度等关键因素. 基于上述分析, 本文最终选择 70% 的训练数据长度作为最优折中方案.

表4 数据训练长度对健康状态估计精度的影响

	60%	70%	80%
训练长度	47	55	62
预测长度	31	23	16
<i>a</i>	0.0043	0.0041	0.0040
<i>b</i>	1.36e-23	7.43e-74	1.58e-34
<i>c</i>	0.9868	0.9839	0.9813
λ	1.03	3	1.2
MAPE/%	2.79	2.49	2.24

对 Cell 1 进行一阶累加, 并求得紧邻均值 Z , 根据所给公式列出参数估计所需要的 B 和 Y . 由此根据最小二乘参数估计 (7) 计算出参数 a 、 b 、 c , 同时根据目标函数值的最小化搜索出非线性参数 λ , 此时可以得到 Cell 1 参数为 $a = 0.0041$, $b = 7.429\ 27e-74$, $\lambda = 3$. 在式 (25) 的基础上得到状态方程

$$\text{soh}(k) = e^{-0.0041} \text{soh}(k-1) + \frac{7.429\ 27e-74 \cdot (1 - e^3)}{0.0041 + 3} e^{3k} (1 - e^{-(3+0.0041)}) + \omega_k.$$

观测方程为 $y = \text{soh}(k) + v_k$. 在此基础上不断迭代, 得到 Cell1 的健康状态估计结果. 其他锂电池健康状

态估计步骤与此一致.

以牛津大学 8 组锂电池健康状态数据进行案例研究, 锂电池 Cell 1 ~ Cell 8 的原始数据长度不一, 因此展示的估计结果也并不是一样的数据长度. 8 组锂电池健康状态数据均采用 70% 进行参数估计. 表 5 展示了 Cell 1 ~ Cell 3 的健康状态估计结果, 表 6 展示了锂电池 Cell 4 ~ Cell 6 的健康状态估计结果, 表 7 展示了 Cell 7 和 Cell 8 的健康状态估计结果. 估计结果误差以 MAPE 作为衡量标准, 其值越小表明误差值越低, 模型的估计效果也越好. 从表 5 ~ 表 7 健康状态估计结果的 MAPE 误差看, 误差值均远低于 10%. Cell 5 的估计误差最高为 2.84%, Cell 6 的估计误差最小为 0.87%, 可见, 所提出灰色扩展卡尔曼滤波算法能够较好地对锂电池的健康状态进行估计.

4 电动汽车的锂电池健康状态估计

牛津大学的数据集基于在实验室中收集的单个锂电池的健康状态指标数据, 为了进一步验证模型在实际应用中的适应性, 有必要将所提出模型应用于实际驾驶车辆. 本节将提出的灰色扩展卡尔曼滤波模型应用于电动汽车锂电池健康状态的估计, 该数据集不同于其他来自实验室测量的锂电池数据集, 而是来自电动汽车的实际数据. 数据集包含共 20 辆

表5 牛津大学锂电池 Cell 1 ~ Cell 3 健康状态估计结果

循环周期	Cell 1	估计结果	循环周期	Cell 2	估计结果	循环周期	Cell 3	估计结果
56	0.7948	0.7966	52	0.7823	0.7783	54	0.8029	0.8049
57	0.7913	0.8073	53	0.7811	0.7825	55	0.8004	0.8118
58	0.7915	0.7856	54	0.7774	0.7644	56	0.7964	0.8082
59	0.7894	0.7822	55	0.7766	0.7581	57	0.7957	0.8351
60	0.7855	0.7713	56	0.7743	0.7589	58	0.7935	0.8091
61	0.7860	0.7582	57	0.7668	0.7593	59	0.7904	0.8174
62	0.7838	0.7419	58	0.7709	0.7456	60	0.7900	0.8090
63	0.7806	0.7466	59	0.7687	0.7576	61	0.7878	0.8110
64	0.7805	0.7530	60	0.7604	0.7589	62	0.7871	0.7941
65	0.7789	0.7656	61	0.7646	0.7690	63	0.7874	0.7790
66	0.7745	0.7503	62	0.7619	0.7438	64	0.7853	0.7714
67	0.7745	0.7523	63	0.7587	0.7392	65	0.7820	0.7644
68	0.7770	0.7749	64	0.7622	0.7290	66	0.7841	0.7641
69	0.7730	0.7609	65	0.7596	0.7216	67	0.7806	0.7642
70	0.7709	0.7526	66	0.7516	0.7247	68	0.7784	0.7575
71	0.7679	0.7560	67	0.7518	0.7305	69	0.7758	0.7551
72	0.7673	0.7305	68	0.7526	0.7586	70	0.7744	0.7429
73	0.7659	0.7429	69	0.7529	0.7476	71	0.7724	0.7559
74	0.7625	0.7448	70	0.6776	0.7345	72	0.7701	0.7662
75	0.7626	0.7507	71	0.7598	0.7570	73	0.7693	0.7583
76	0.7609	0.7482	72	0.7549	0.7523	74	0.7674	0.7482
77	0.7568	0.7260	73	0.7364	0.7239	75	0.7655	0.7376
78	0.7576	0.7286				76	0.7647	0.7460
MAPE/%		2.49			2.10			2.24

表6 牛津大学锂电池 Cell 4 ~ Cell 6 健康状态估计结果

循环周期	Cell 4	估计结果	循环周期	Cell 5	估计结果	循环周期	Cell 6	估计结果
34	0.8231	0.8243	33	0.8502	0.8589	33	0.8418	0.8501
35	0.8201	0.8365	34	0.8494	0.8754	34	0.8412	0.8664
36	0.8137	0.8410	35	0.8466	0.8438	35	0.8383	0.8346
37	0.8139	0.8336	36	0.8415	0.8492	36	0.8327	0.8399
38	0.8119	0.8456	37	0.8408	0.8441	37	0.8324	0.8346
39	0.8062	0.8363	38	0.8379	0.8195	38	0.8291	0.8098
40	0.8049	0.8145	39	0.8338	0.8331	39	0.8238	0.8232
41	0.8023	0.8248	40	0.8324	0.8307	40	0.8230	0.8206
42	0.7999	0.8068	41	0.8303	0.8371	41	0.8208	0.8268
43	0.7950	0.7948	42	0.8276	0.8276	42	0.8184	0.8172
44	0.7943	0.7850	43	0.8237	0.8202	43	0.8129	0.8095
45	0.7899	0.7767	44	0.8229	0.8158	44	0.7920	0.8050
46	0.7869	0.7544	45	0.8180	0.8048	45	0.7924	0.7939
47	0.7855	0.7882	46	0.6164	0.7876	46	0.7825	0.7765
MAPE/%	2.00		2.84			0.87		

表7 牛津大学锂电池 Cell 7 ~ Cell 8 健康状态估计结果

循环周期	Cell 7	估计结果	循环周期	Cell 8	估计结果
55	0.8244	0.8261	54	0.7980	0.8000
56	0.8227	0.8229	55	0.7954	0.7956
57	0.8190	0.8432	56	0.7909	0.7853
58	0.8188	0.8458	57	0.7907	0.8033
59	0.8171	0.8406	58	0.7881	0.8057
60	0.8133	0.8281	59	0.7836	0.8081
61	0.8135	0.8084	60	0.7842	0.7874
62	0.8118	0.7937	61	0.7818	0.7886
63	0.8091	0.8028	62	0.7811	0.7769
64	0.8095	0.8121	63	0.7807	0.7711
65	0.8079	0.8010	64	0.7789	0.7708
66	0.8040	0.8123	65	0.7744	0.7650
67	0.8070	0.8001	66	0.7765	0.7656
68	0.8027	0.8086	67	0.7722	0.7750
69	0.8010	0.8030	68	0.7700	0.7754
70	0.7982	0.7856	69	0.7670	0.7568
71	0.7973	0.7981	70	0.7658	0.7561
72	0.7954	0.8079	71	0.7640	0.7775
73	0.7926	0.8146	72	0.7608	0.7615
74	0.7920	0.8156	73	0.7603	0.7575
75	0.7905	0.7884	74	0.7583	0.7508
76	0.7876	0.7779	75	0.7543	0.7397
77	0.7876	0.7718	76	0.7553	0.7531
MAPE/%	1.36		1.03		

电动汽车的电池组充电数据, 其中每个 x 代表一辆电动汽车的数据. 数据跨度超过两年, 约 29 个月. 在对 20 辆电动汽车的数据集进行处理后, 可获得容量平均值数据. 电池额定容量为 145 Ah, 20 辆电动汽车均具有相同额定容量的锂电池, 因此可以根据容量来定义锂电池的健康状态.

在电动汽车数据集中, 经过处理后可获得容量平均值数据. 在额定容量已知的情况下, 根据容量定义锂电池健康状态的方法可以得到锂电池的 SOH

值. 利用 70% 数据对 SOH 原始数据进行参数训练, 训练后的参数用于锂电池健康状态结果的估算. 表 8 给出了 20 辆电动汽车的训练参数值.

表8 电动汽车 SOH 参数估计

车辆序号	a	b	c	λ
#1	0.0068	3.61e-28	0.9356	3
#2	0.0059	-3.18e-06	0.9230	0.26
#3	0.0065	-8.93e-11	0.9192	0.87
#4	0.0057	3.80e-28	0.9194	3
#5	0.0060	6.20e-29	0.9212	3
#6	0.0079	7.54e-10	0.9357	0.86
#7	0.0059	1.75e-05	0.9251	0.22
#8	0.0078	3.33e-28	0.9405	3
#9	0.0072	-1.89e-16	0.9347	1.67
#10	0.0045	5.83e-05	0.9174	0.2
#11	0.0071	2.08e-28	0.9385	3
#12	0.0059	-0.000103492	0.9379	0.05
#13	0.0061	-6.89e-09	0.9295	0.67
#14	0.0069	6.15e-28	0.9257	3
#15	0.0067	1.59e-25	0.9186	3
#16	0.0071	1.36e-09	0.9285	0.8
#17	0.0064	4.42e-28	0.9280	3
#18	0.0060	-3.28e-08	0.9085	0.47
#19	0.0065	4.58e-12	0.9244	1.05
#20	0.0066	5.07e-29	0.9299	3

参数估计结束后, 将估算出的参数代入灰色扩展卡尔曼滤波模型, 对锂电池的健康状态进行估算. 20 辆电动汽车锂电池健康状态的轨迹跟踪过程如图 5 所示. 图 5 中横轴为时间, 纵轴为锂电池 SOH 值. 从图 5 中可以更清楚地看到, 在这 20 辆车中, 灰色扩展卡尔曼滤波模型能较好地估计锂电池的健康状态, 只有个别点没有被完全跟踪, 整体健康状态估计较好.

灰色卡尔曼滤波模型对锂电池的 SOH 估计从

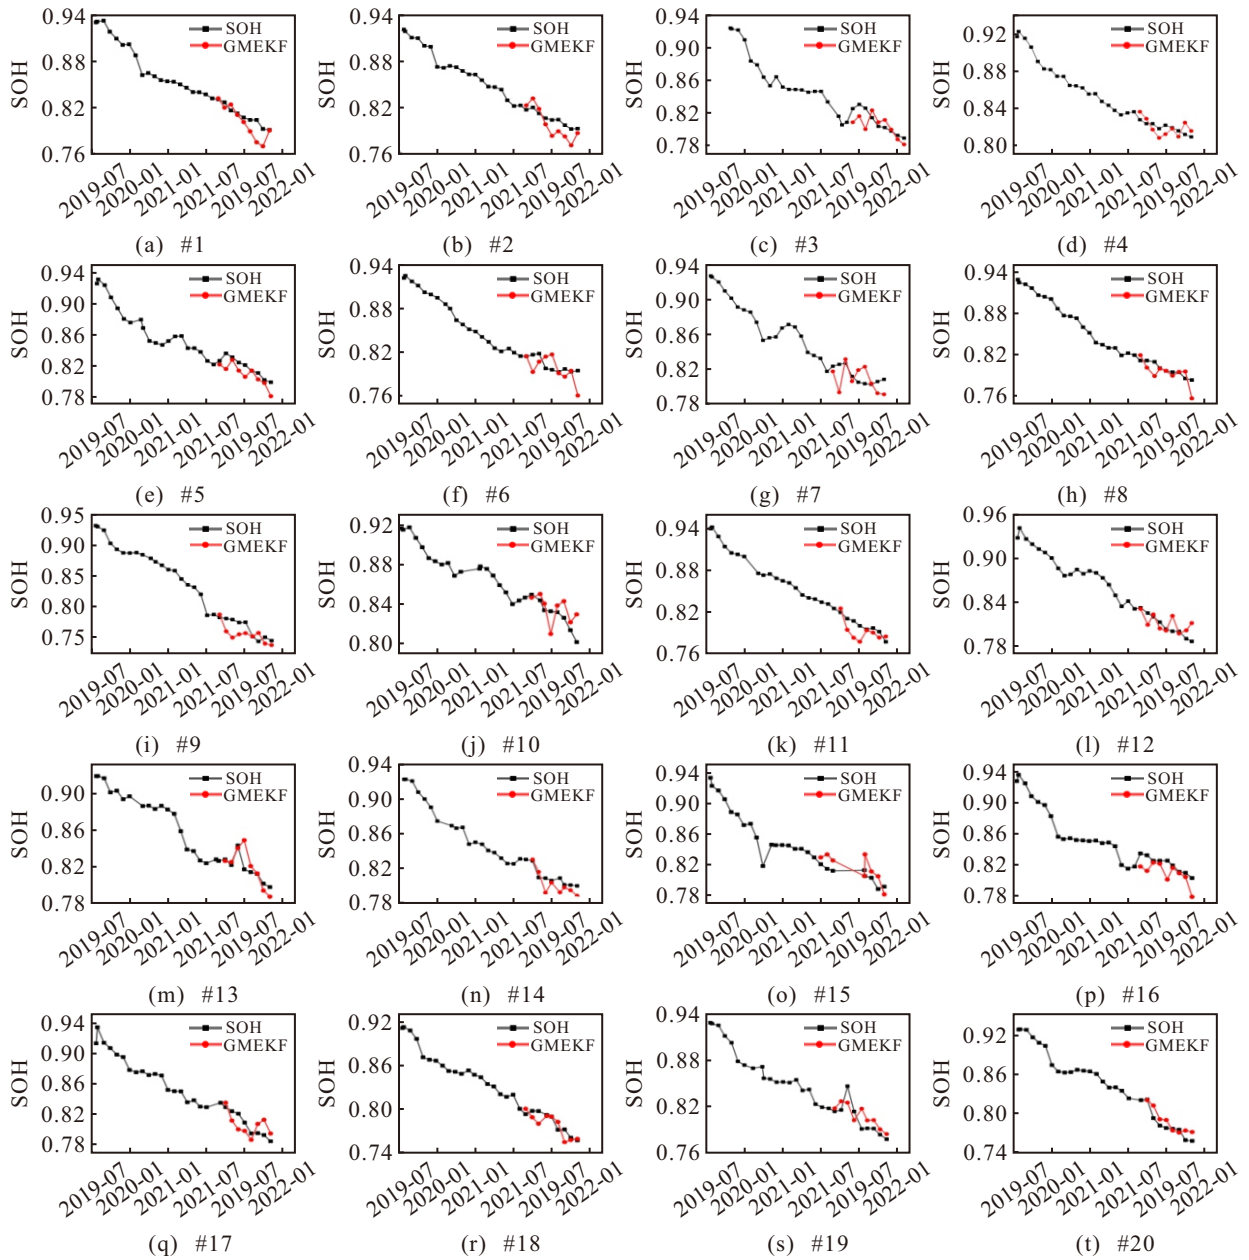


图5 20辆电动汽车健康状态估计结果

MAPE 角度得到进一步量化. 20 辆电动汽车估计误差如图 6 所示, #4 的估计精度最高, 误差仅为 0.91%. 误差最大的是第 9 辆电动汽车, 其 MAPE 值为 1.76%. 整体健康状态的 MAPE 误差值不超过 2%. 一般而言, MAPE 误差值在 10% 范围内, 表明所提出模型是有效的.




图6 电动汽车健康状态估计误差

由图 6 可以看出, 灰色扩展卡尔曼滤波模型可以更好地估计电动汽车中锂电池的健康状况. 本文在牛津大学锂电池数据集上验证了灰色扩展卡尔曼模型, 将其从单个电池的单一指标扩展到电动汽车电池组健康状态的监测, 进一步验证了所提出模型可应用于电池管理系统中的电池组健康状态监测过程.

5 结论

锂电池健康状态估计是确保电池安全、高效运行的关键技术. 以往数据对于近似线性数据往往会采用线性模型进行解决, 但这样往往不够精确. 本文针对锂电池非线性退化问题, 提出了灰色扩展卡尔曼滤波模型估计锂电池健康状态. 将所提出模型采用牛津大学 8 块锂电池进行案例研究, 研究结果表

明, 所提出模型具有良好的健康状态估计性能. 此外, 还将提出的模型应用于电动汽车锂电池健康状况的估计, 以验证模型的实用性. 与实验室环境测量数据相比, 进一步表明了模型在实际生活场景中的应用价值.

参考文献 (References)

- [1] Xu Z C, Xie N M, Diao H K. Lithium-ion battery state of health monitoring based on an adaptive variable fractional order multivariate grey model[J]. *Energy*, 2023, 283: 129167.
- [2] 熊瑞. 动力电池管理系统核心算法[M]. 北京: 机械工业出版社, 2018.
(Xiong R. Core algorithm of battery management system for EVs[M]. Beijing: China Machine Press, 2018.)
- [3] Maures M, Capitaine A, Deléage J Y, et al. Lithium-ion battery SoH estimation based on incremental capacity peak tracking at several current levels for online application[J]. *Microelectronics Reliability*, 2020, 114: 113798.
- [4] Xia F, Wang K G, Chen J J. State of health and remaining useful life prediction of lithium-ion batteries based on a disturbance-free incremental capacity and differential voltage analysis method[J]. *Journal of Energy Storage*, 2023, 64: 107161.
- [5] Wen J P, Chen X, Li X H, et al. SOH prediction of lithium battery based on IC curve feature and BP neural network[J]. *Energy*, 2022, 261: 125234.
- [6] 陈景龙, 王日新, 李玉庆, 等. 一种基于 SD-ICA 的卫星电池健康状态估计方法[J]. 北京航空航天大学学报, 2021, 47(10): 2058-2067.
(Chen J L, Wang R X, Li Y Q, et al. A state of health estimation method for satellite battery based on smooth and discharge applicative increment capacity analysis[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2021, 47(10): 2058-2067.)
- [7] Wang L M, Pan C F, Liu L, et al. Onboard state of health estimation of LiFePO₄ battery pack through differential voltage analysis[J]. *Applied Energy*, 2016, 168: 465472.
- [8] Pastor-Fernández C, Uddin K, Chouchelamane G H, et al. A comparison between electrochemical impedance spectroscopy and incremental capacity-differential voltage as Li-ion diagnostic techniques to identify and quantify the effects of degradation modes within battery management systems[J]. *Journal of Power Sources*, 2017, 360: 301-318.
- [9] 吴忠强, 陈海佳. 基于自适应 H_2/H_∞ 滤波的锂电池 SOC 和 SOH 联合估计[J]. 计量学报, 2023, 44(11): 1719-1727.
(Wu Z Q, Chen H J. Joint SOC and SOH estimation for lithium batteries based on adaptive H_2/H_∞ filtering[J]. *Acta Metrologica Sinica*, 2023, 44(11): 1719-1727.)
- [10] 谭泽富, 彭涛, 代妮娜, 等. 基于改进 DAEKF 的锂电池 SOC 和 SOH 联合估计[J]. 重庆邮电大学学报: 自然科学版, 2023, 35(4): 760-766.
(Tan Z F, Peng T, Dai N N, et al. Joint estimation of lithium battery SOC and SOH based on improved DAEKF[J]. *Journal of Chongqing University of Posts and Telecommunications: Natural Science Edition*, 2023, 35(4): 760-766.)
- [11] 王若琦, 王晓佳, 杨淇, 等. 基于双自适应无迹卡尔曼滤波算法的锂电 SOC/SOH 联合估计[J]. 机械设计与制造, 2023(1): 1-4.
(Wang R Q, Wang X J, Yang Q, et al. Joint estimation of lithium battery SOC/SOH based on double adaptive untracked Kalman filtering algorithm[J]. *Machinery Design & Manufacture*, 2023(1): 1-4.)
- [12] Tian J P, Chen C, Shen W X, et al. Deep learning framework for lithium-ion battery state of charge estimation: Recent advances and future perspectives[J]. *Energy Storage Materials*, 2023, 61: 102883.
- [13] Lyu G Z, Zhang H, Miao Q. Parallel state fusion LSTM-based early-cycle stage lithium-ion battery RUL prediction under lebesgue sampling framework[J]. *Reliability Engineering & System Safety*, 2023, 236: 109315.
- [14] Meng J H, Cai L, Luo G Z, et al. Lithium-ion battery state of health estimation with short-term current pulse test and support vector machine[J]. *Microelectronics Reliability*, 2018, 88/89/90: 1216-1220.
- [15] Zhu C X, Gao M Y, He Z W, et al. State of health prediction for li-ion batteries with end-to-end deep learning[J]. *Journal of Energy Storage*, 2023, 65: 107218.
- [16] 刘小峰, 叶榕婷, 柏林, 等. 基于灰色理论的航空发动机剩余寿命预测[J]. 电子测量与仪器学报, 2021, 35(1): 74-81.
(Liu X F, Ye R T, Bai L, et al. Remaining useful life estimation for aero-engines based on grey theory[J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(1): 74-81.)
- [17] 吴利丰, 于亮, 文朝霞. 预测复杂装备研制费用的 GM(0, N) 模型[J]. 中国管理科学, 2019, 27(7): 203-207.
(Wu L F, Yu L, Wen Z X. GM(0, N) model for its application on forecasting the development cost of complicated equipment[J]. *Chinese Journal of Management Science*, 2019, 27(7): 203-207.)
- [18] 杨璐, 徐秋慧, 谢乃明. 可解释非线性灰色 Bernoulli 模型及其在结构疲劳寿命预测的应用[J]. 控制与决策, 2025, 40(9): 2833-2840.
(Yang L, Xu Q H, Xie N M. Physics-perserving nonlinear grey Bernoulli model and applications to fatigue life prediction[J]. *Control and Decision*, 2025, 40(9): 2833-2840.)
- [19] 刘连义, 刘思峰, 姜爱平. 递归离散灰色模型及应用示例[J]. 系统工程理论与实践, 2023, 43(10): 3058-3068.
(Liu L Y, Liu S F, Jiang A P. Recursive discrete grey model and application examples[J]. *Systems Engineering – Theory & Practice*, 2023, 43(10): 3058-3068.)

- [20] 涂乐平, 党耀国, 王俊杰. 含分数阶微积分的非等间距灰色模型及其应用[J]. 系统工程理论与实践, 2023, 43(12): 3636-3652.
(Tu L P, Dang Y G, Wang J J. Non-equigap grey model with fractional order calculus and its applications[J]. Systems Engineering – Theory & Practice, 2023, 43(12): 3636-3652.)
- [21] 于仲安, 赵凯贤. 基于灰色多变量模型锂离子电池荷电状态预测[J]. 计算机仿真, 2019, 36(1): 138-140.
(Yu Z A, Zhao K X. Lithium-ion battery SOC prediction based on gray multivariate model[J]. Computer Simulation, 2019, 36(1): 138-140.)
- [22] 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.
(Wei H Y, Chen X J, Lü Z Q, et al. Online estimation of lithium-ion battery state of health using grey neural network[J]. Power System Technology, 2017, 41(12): 4038-4044.)
- [23] Sun M, Guo K, Zhang D, et al. A novel exponential model for tool remaining useful life prediction[J]. Journal of Manufacturing Systems, 2024, 73: 223240.
- [24] Xu Z C, Xie N M, Li K L. Remaining useful life prediction for lithium-ion batteries with an improved grey particle filter model[J]. Journal of Energy Storage, 2024, 78: 110081.
- [25] 韦海燕, 陈静, 王惠民, 等. 新陈代谢灰色粒子滤波实现电池剩余寿命预测[J]. 电工技术学报, 2020, 35(6): 1181-1188.
(Wei H Y, Chen J, Wang H M, et al. Remaining useful life prediction of battery using metabolic grey particle filter[J]. Transactions of China Electrotechnical Society, 2020, 35(6): 1181-1188.)
- [26] Yang J S, Fang W G, Chen J Y, et al. A lithium-ion battery remaining useful life prediction method based on unscented particle filter and optimal combination strategy[J]. Journal of Energy Storage, 2022, 55: 105648.
- [27] 楼功茂, 林文文, 王宇作. 基于 DMM-EKF 的超级电容器剩余使用寿命预测[J]. 机械工程学报, 2024, 60(14): 306-316.
(Lou G M, Lin W W, Wang Y Z. Remaining useful life prediction of supercapacitors based on DMM-EKF[J]. Journal of Mechanical Engineering, 2024, 60(14): 306-316.)
- [28] 秦娅, 马军, 熊新, 等. 基于形态波动一致性偏移距离的滚动轴承剩余寿命预测方法[J]. 电子测量与仪器学报, 2024, 38(3): 32-44.
(Qin Y, Ma J, Xiong X, et al. Residual life prediction method of rolling bearing based on morphology fluctuation conformance deviation distance[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(3): 32-44.)
- [29] Pang H, Chen K Q, Geng Y F, et al. Accurate capacity and remaining useful life prediction of lithium-ion batteries based on improved particle swarm optimization and particle filter[J]. Energy, 2024, 293: 130555.
- [30] Meng J W, Yue M L, Diallo D. A degradation empirical-model-free battery end-of-life prediction framework based on Gaussian process regression and Kalman filter[J]. IEEE Transactions on Transportation Electrification, 2023, 9(4): 4898-4908.
- [31] Chen D, Meng J H, Huang H Y, et al. An empirical-data hybrid driven approach for remaining useful life prediction of lithium-ion batteries considering capacity diving[J]. Energy, 2022, 245: 123222.
- [32] 贺宁, 杨紫琦, 钱成. 基于非参数模型与粒子滤波的锂电池 SOH 估计[J]. 电子测量与仪器学报, 2024, 38(2): 148-159.
(He N, Yang Z Q, Qian C. SOH estimation of lithium-ion battery based on non-parametric model and particle filter[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(2): 148-159.)
- [33] Birkl C. Diagnosis and prognosis of degradation in lithiumion batteries[D]. Oxford: University of Oxford, 2017.

作者简介

徐志存 (1994–), 女, 博士生, 主要研究方向为灰色系统理论, E-mail: xzc0525@126.com;

谢乃明 (1981–), 男, 教授, 博士, 主要研究方向为灰色系统理论、复杂装备研制管理, E-mail: xienaiming@nuaa.edu.cn.