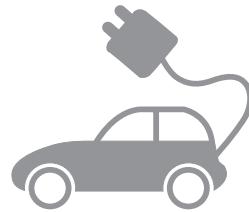


动力电池剩余寿命预测



锂离子动力电池的内部机理十分复杂，导致其性能衰退的原因众多，而且多种因素相互耦合，最终形成了极具挑战性的工程问题。动力电池的性能衰退问题贯穿于使用和维护的全过程，随着动力电池充放电循环次数的增加，动力电池内部往往会发生一些不可逆转的化学反应，导致内阻增大，最大可用容量、能量以及峰值功率能力衰减，从而大大地削减了电动汽车的续驶里程，甚至带来了一些安全隐患。可靠的 RUL 预测可以充分解决用户对剩余续驶里程不明的焦虑以及对安全问题的担忧，保障动力电池组安全高效运行，还能在很大程度上确保电动汽车在运行过程中的安全性和可靠性，降低故障率和运行成本，提升用户体验，避免事故发生。因此，动力电池 RUL 预测是动力电池管理的核心内容之一。本章首先将介绍动力电池 RUL 预测的相关概念，再对当前主流的 RUL 预测方法进行总结与分类，最后从原理和实践层面详细介绍两种具有代表性的动力电池 RUL 预测方法，指导动力电池系统 RUL 的精确预测。

6.1 剩余寿命预测的概述

6.1.1 问题描述

动力电池的 RUL 是指在一定的充放电制度下，动力电池的最大可用容量衰减退化到某一规定的失效阈值所需要经历的循环周期数量。RUL 预测是一个基于动力电池历史数据运用一定的数学手段对其残值寿命进行预测计算的过程。随着动力电池在各领域上的广泛应用，动力电池 RUL 预测技术得到了广泛的关注和研究。

目前，数据驱动是动力电池 RUL 预测的主要手段，其核心在于对容量衰减轨迹和历史数据的挖掘、提炼和推广。应用数据驱动的手段进行动力电池的 RUL 预测，首先需要获取动力电池老化实验的容量数据或容量衰减轨迹，从中挖掘和提炼动力电池寿命衰减的内在规律，进而对容量数据进行推广和延伸，最终实现

动力电池未来寿命轨迹的预测。一般来说，基于数据驱动的动力电池 RUL 预测方法具有过程简单、计算量少且无需考虑动力电池复杂机理等优势，能够有效减轻 BMS 的运行负担，适用于实车的运行环境。

6.1.2 方法分类

根据预测思路的不同，基于数据驱动的动力电池 RUL 预测方法又可细分为三大类型：经验预测法、滤波预测法和时序预测法，见表 6-1。下面分别对每一类预测方法进行详细介绍。

表 6-1 动力电池 RUL 预测方法的分类

方法名称	方法思路	常用的模型或算法
经验预测法	基于数据拟合的思想	单指数模型，双指数模型，线性模型，多项式模型，Verhulst 模型
滤波预测法	基于状态估计的思想	卡尔曼滤波，扩展卡尔曼滤波，无迹卡尔曼滤波，粒子滤波，无迹粒子滤波，球形容积粒子滤波
时序预测法	基于时序预测的思想	灰色预测，自回归移动平均法，神经网络，支持向量机，相关向量机

1. 经验预测法

该方法认为动力电池的容量衰减轨迹遵循某种固有的数学关系。因此，只需找出能够合理描述动力电池老化规律的数学模型，即可解决动力电池的 RUL 预测问题。从数据拟合的思想出发，构造以循环次数为输入、最大可用容量为输出的数学表达式有助于描述动力电池的老化规律。为了获取合理的数学模型，通常需要试探性地采用不同结构的数学表达式对动力电池的容量衰减轨迹进行反复的拟合，选择拟合效果最佳的数学表达式作为动力电池的寿命经验模型。常用作动力电池寿命经验模型的数学表达形式见表 6-2。其中， n 表示动力电池的循环次数， C_0 表示动力电池的出厂容量。

表 6-2 常用作动力电池寿命经验模型的数学表达形式

名称	数学表达形式	模型参数
单指数模型	$C_{\max} = a_1 e^{a_2 n} + a_3$	a_1, a_2, a_3
双指数模型	$C_{\max} = b_1 e^{b_2 n} + b_3 e^{b_4 n}$	b_1, b_2, b_3, b_4
线性模型	$C_{\max} = c_1 n + c_2$	c_1, c_2
多项式模型	$C_{\max} = d_1 n^2 + d_2 n + d_3$	d_1, d_2, d_3
Verhulst 模型	$C_{\max} = \frac{e_1 / e_2}{1 + (e_1 / (e_2 C_0) - 1) e^{-e_1 n}}$	e_1, e_2

采用经验预测法的动力电池 RUL 预测流程如图 6-1 所示。

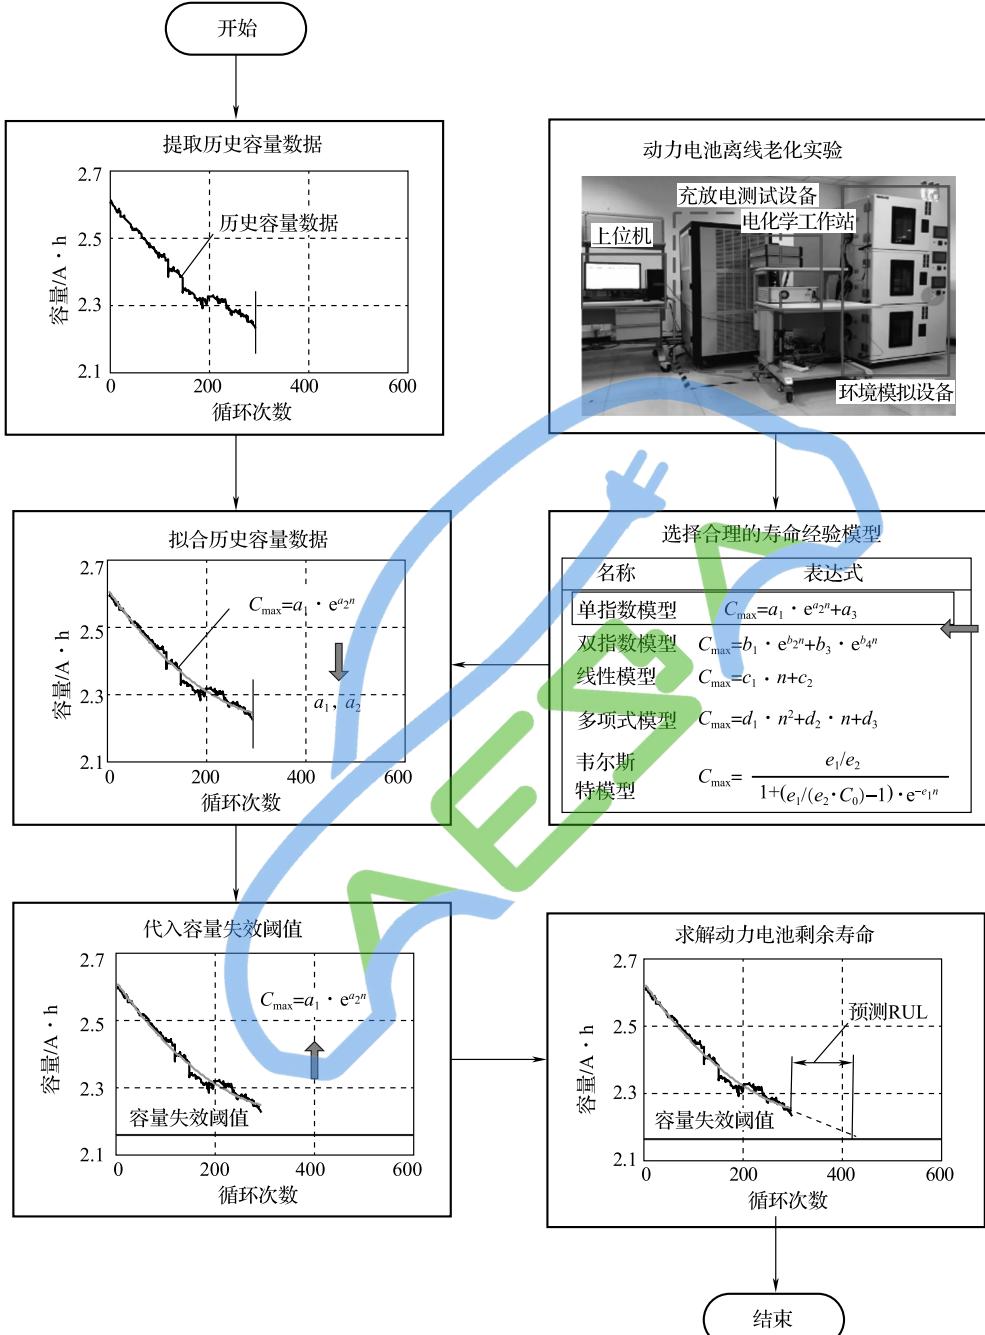


图 6-1 采用经验预测法的动力电池 RUL 预测流程（见彩插）

当 RUL 预测程序启动时，BMS 开始提取储存器中的动力电池历史容量数据。为了采用合理的寿命经验模型，通常需要对同一型号的动力电池进行离线老化实验，并根据实验结果将合适的寿命经验模型存入 BMS。值得注意的是，动力电池在不同的充放电制度或不同的老化阶段下可能适用不同的数学模型，因此往往需要录入多个寿命经验模型。为了捕捉动力电池的寿命衰减轨迹，BMS 会根据实际情况调用相应的寿命经验模型并对历史容量数据进行拟合逼近，获得寿命经验模型的参数。数据拟合样本可以采用全部的历史容量数据或部分的历史容量数据。在完成数据拟合后，将规定的容量失效阈值代入寿命经验模型，即可完成动力电池 RUL 的求解。需要说明的是，寿命经验模型不仅可以求解动力电池的 RUL，还可对未来的寿命轨迹进行预测。一般来说，经验预测法的优点是过程简单，计算量少，但由于数据拟合对样本数据的波动敏感，其预测结果也容易发散。

2. 滤波预测法

该方法是目前最为常用的一种动力电池 RUL 预测方法。从状态估计的思想出发，可通过观测数据实时地对寿命经验模型进行更新校正，有效解决了经验预测法中单纯的数据拟合所引起的预测不稳定问题。因此，这类方法同样需要寿命经验模型，并可看作是经验预测法的改进方法。

采用滤波预测法的动力电池 RUL 预测流程如图 6-2 所示。

当 RUL 预测程序启动时，BMS 需要提取储存器中的动力电池历史容量数据。与经验预测法不同的是，该方法在调出合理的寿命经验模型后，并不是直接进行数据拟合，而是根据模型建立相应状态空间方程，以便滤波算法的后续运行。以表 6-2 中的双指数模型为例，相应状态方程为

$$\begin{aligned} \mathbf{x}_n &= [b_{1,n} \ b_{2,n} \ b_{3,n} \ b_{4,n}]^T \\ \left\{ \begin{array}{l} b_{1,n+1} = b_{1,n} + w_{b1,n}, \quad w_{b1,n} \sim N(0, \sigma_{b1}) \\ b_{2,n+1} = b_{2,n} + w_{b2,n}, \quad w_{b2,n} \sim N(0, \sigma_{b2}) \\ b_{3,n+1} = b_{3,n} + w_{b3,n}, \quad w_{b3,n} \sim N(0, \sigma_{b3}) \\ b_{4,n+1} = b_{4,n} + w_{b4,n}, \quad w_{b4,n} \sim N(0, \sigma_{b4}) \end{array} \right. \end{aligned} \quad (6-1)$$

式中， \mathbf{x} 为状态向量； $w_{b1} \sim w_{b4}$ 为均值为 0 的噪声； $\sigma_{b1} \sim \sigma_{b4}$ 为参数噪声的方差。相应的观测方程为

$$C_{\max,n} = b_{1,n} e^{b_{2,n} n} + b_{3,n} e^{b_{4,n} n} + v_n, \quad v_n \sim N(0, \sigma_v) \quad (6-2)$$

式中， v_n 为均值为 0 的观测噪声； σ_v 为观测噪声的方差。在完成状态空间方程的建立后，BMS 基于历史容量数据利用滤波算法对状态向量进行更新校正，从而获得寿命经验模型的参数。详细的滤波计算过程可参考本书的第 4 章内容。

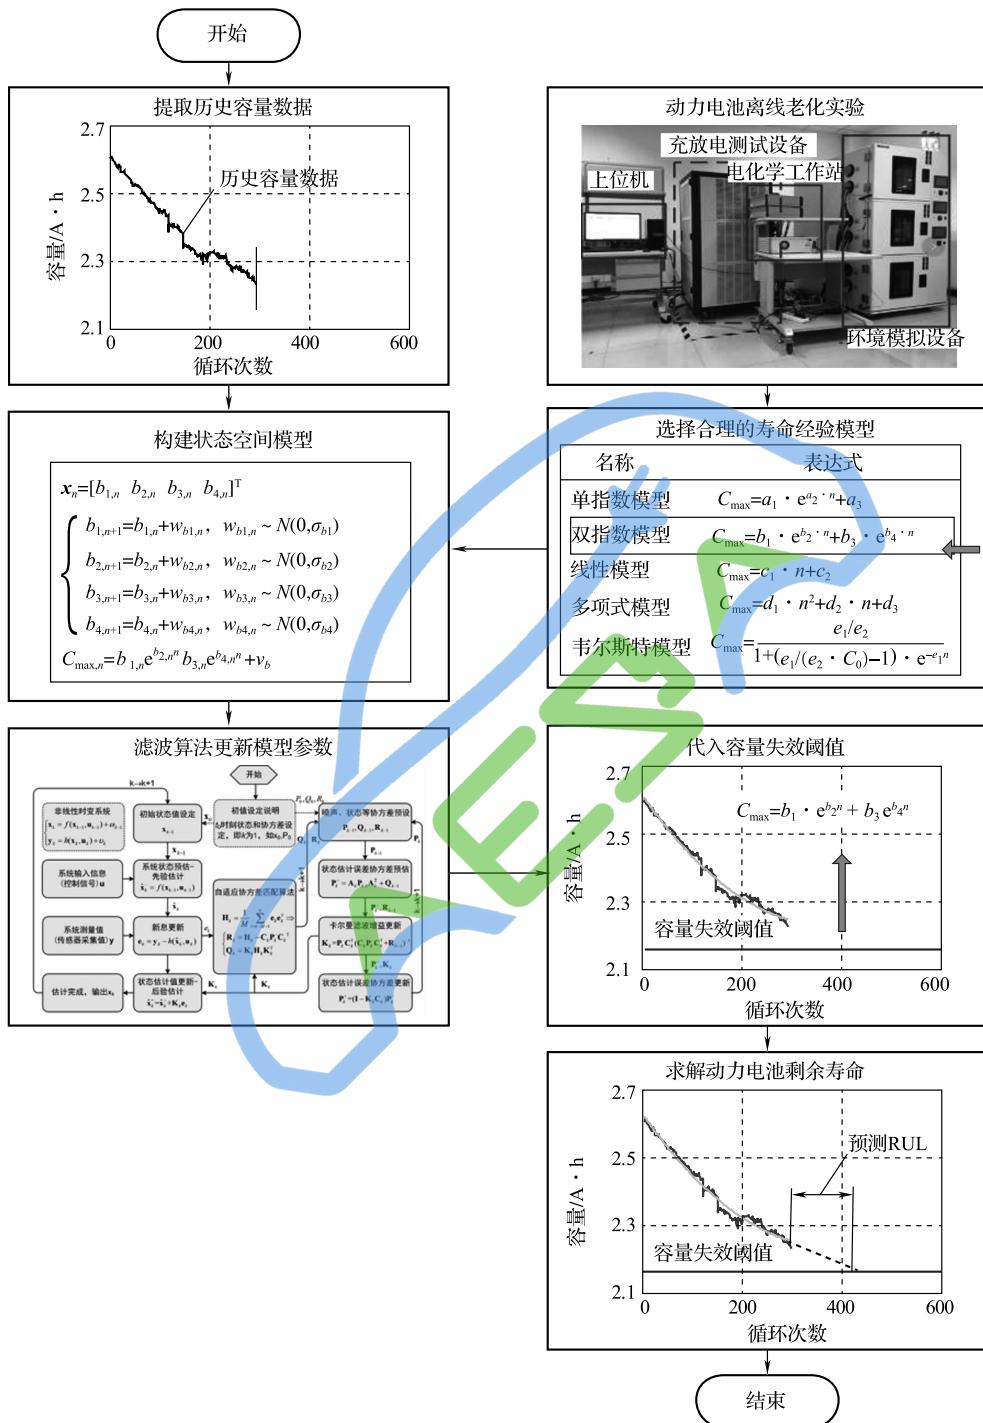


图 6-2 采用滤波预测法的动力电池 RUL 预测流程

在完成参数的更新和校正后，将规定的容量失效阈值代入寿命经验模型，即可完成动力电池 RUL 的求解。一般来说，该方法大大改善了寿命经验模型的外推收敛性能，提高了 RUL 预测精度，但算法性能过于依赖寿命经验模型的精度。常用于预测动力电池 RUL 的滤波方法有卡尔曼滤波、扩展卡尔曼滤波、无迹卡尔曼滤波、粒子滤波、无迹粒子滤波以及球形容积粒子滤波等。

3. 时序预测法

与上述两类方法不同，该方法不依赖于寿命经验模型，而是从时间序列预测的角度出发，将动力电池的 RUL 预测视为时间序列预测问题，具体的数学表达式为

$$C_{\max,n+1} = f(C_{\max,n}, C_{\max,n-1}, \dots, C_{\max,n-m}), \quad m < n \quad (6-3)$$

式中，函数 $f(\cdot)$ 为时间序列模型。

时间序列模型通常用于处理未来数值的预测问题，其核心思想承认事物在时间轴上的延续性，可运用过去时间序列的发展规律定量推测未来的发展趋势。对动力电池而言，老化引起的容量衰减轨迹本质上是一个长期的时间序列，RUL 的预测相当于对时间序列的拓展和延伸，因此可以应用时间序列模型来处理 RUL 的预测问题。

从式 (6-3) 可见，基于时间序列模型 $f(\cdot)$ ，可利用 $n - m$ 次到 n 次循环之间的历史容量观测序列预测第 $n + 1$ 次循环后的动力电池容量。这说明递推使用式 (6-3) 即可依次预测任意次循环后的动力电池容量值。因此，获得合理的时间序列模型是该方法的关键。目前，常用作 RUL 预测的序列模型有灰色预测、自回归移动平均法、神经网络、支持向量机以及相关向量机等。

采用时序预测法的动力电池 RUL 预测流程如图 6-3 所示。

当 RUL 预测程序启动时，BMS 需要提取储存器中的动力电池历史容量数据。随后，BMS 将开始构建时序模型，具体包括两个步骤：根据历史容量数据构建时序模型的输入和输出样本，并初始化时序模型的基本架构及其具体参数；然后，基于输入和输出样本对时序模型进行训练和学习。在完成模型构建后，BMS 将基于时序模型预测未来一次循环后的动力电池容量值。因为该步骤只执行了一步向前预测，所以又称为单步向前预测。在完成一次单步向前预测后，BMS 需要对预测结果进行判断：若预测结果小于规定的容量失效阈值，则终止预测，统计单步向前预测的次数并以此作为 RUL 值输出；否则，算法继续执行单步向前预测。

由上述步骤可见，时序预测法并不需要考虑寿命经验模型选取的合理性问题，只需根据 BMS 储存器中的历史容量数据即可完成动力电池的 RUL 预测。

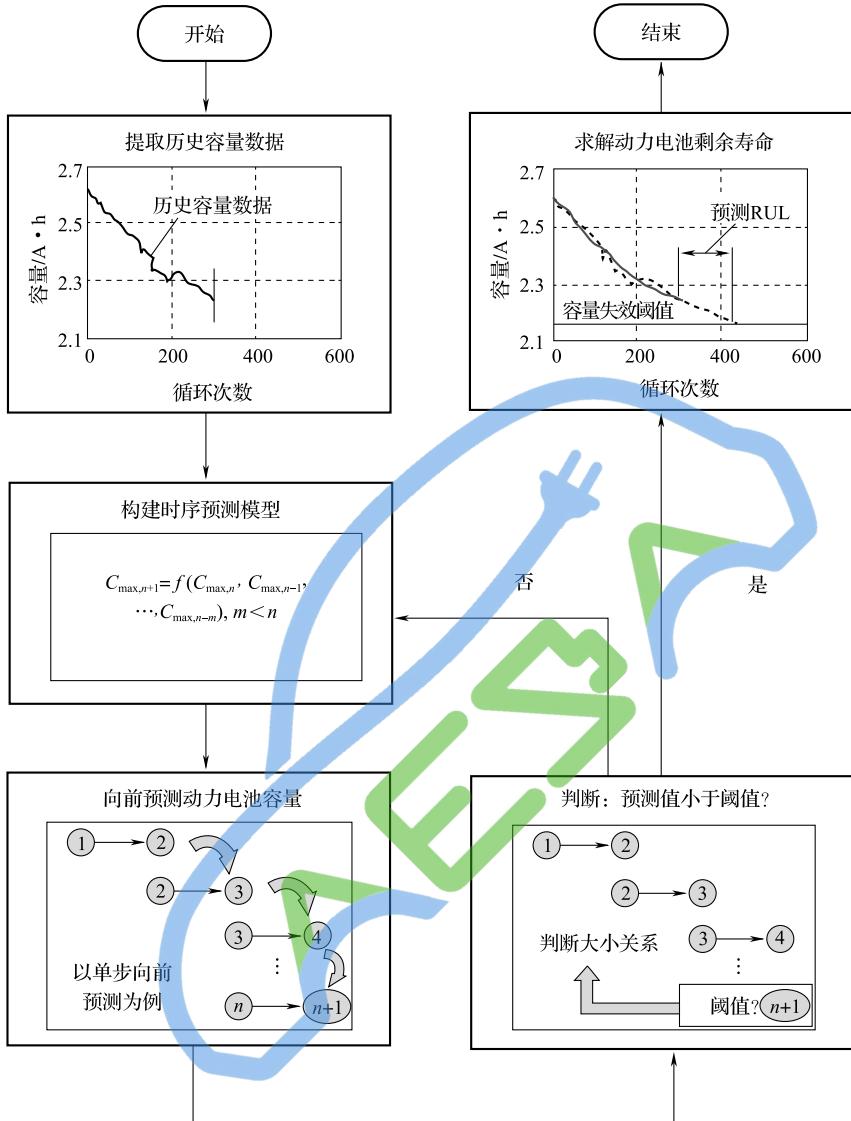


图 6-3 时序预测法的动力电池 RUL 预测流程图（见彩插）

6.1.3 概率分布

任何预测方法都会存在一定的误差。RUL 预测中的模型误差来源于数学建模与实际问题之间的偏离，由预测方法的本身和预测问题的本质所致，往往难以避免和估计。而在完成预测方法的数学建模后，动力电池数据对模型的作用也同样会给系统带来一定的误差，通常为测量误差或截断误差。这些误差所带来的不确

定性将伴随着预测算法的推进而扩散，并最终作用在算法的 RUL 预测结果当中。因此，尽可能描述动力电池 RUL 预测结果的不确定性具有十分重要的意义。

动力电池 RUL 预测的概率分布是指在既定的预测方法下动力电池 RUL 预测结果的不确定性分布规律，通常用 RUL 的概率密度函数来描述。一般来说，动力电池 RUL 的概率密度函数比 RUL 本身更具有工程价值。因为动力电池 RUL 的概率密度函数不仅可以计算 RUL 预测的置信度，还可以获知 RUL 预测的分布规律和置信区间，为电动汽车动力电池的检修、维护以及回收利用提供极大的帮助。

蒙特卡洛（Monte Carlo，MC）方法常用于结合不同的预测方法计算动力电池 RUL 的概率密度函数。该方法的核心思想是以概率为基础，通过重复随机试验的方式来计算复杂过程的数值结果。下面详细介绍应用 MC 方法计算动力电池 RUL 概率密度函数的基本步骤：

① 确定动力电池 RUL 预测方法的主要不确定性来源。一般来说，计算动力电池 RUL 的概率密度函数需要抓住不确定性的主要产生环节。表 6-3 列出了经验预测法、滤波预测法和时序预测法的主要不确定性产生环节。

表 6-3 不确定性产生环节

方法名称	主要不确定性的产生环节
经验预测法	基于寿命经验模型对历史容量数据的拟合环节
滤波预测法	状态空间方程的状态向量初始化环节
时序预测法	动力电池 RUL 预测起点的时序模型输入环节

② 确定主要不确定性的分布规律。对于经验预测法，不确定性的分布规律可由寿命经验模型拟合过程中的参数均值和方差确定。滤波预测法的初始状态向量通常由寿命经验模型对历史容量数据的拟合确定。因此，其不确定性分布规律的确定方法与经验预测法相同。对于时序预测法，不确定性的分布规律可由预测起点附近的历史容量分布规律确定。

③ MC 模拟。首先基于主要不确定性的分布规律随机生成若干个样本。上述三种方法所生成的样本类型分别为寿命经验模型参数样本、初始状态向量样本和时序模型的初始输入向量样本。在完成样本的随机生成后，根据所选预测方法分别基于每一组样本进行模拟预测，最终获得若干个 RUL 模拟预测结果。

④ 计算 RUL 预测的概率密度函数。基于上一步骤的所有模拟预测结果，RUL 预测的概率密度函数可根据下式计算：

$$\hat{f}_h(c_{\max}) = \sum_{i=1}^N \left[K_p \left(\frac{c_{\max} - c_{\max,i}^-}{h_p} \right) + K_p \left(\frac{c_{\max} - c_{\max,i}}{h_p} \right) + K_p \left(\frac{c_{\max} - c_{\max,i}^+}{h_p} \right) \right] \quad (6-4)$$

式中, $\hat{f}_h(c_{\max})$ 为 RUL 预测的概率密度函数; $K_p(\cdot)$ 为高斯核函数; h_p 为带宽; $c_{\max,j}^-$ 和 $c_{\max,i}^+$ 的计算公式为

$$\begin{cases} c_{\max,i}^- = 2L_e - c_{\max,i} \\ c_{\max,i}^+ = 2U_e - c_{\max,i} \end{cases} \quad (6-5)$$

式中, U_e 和 L_e 分别为 MC 模拟结果的上下界; $c_{\max,i}$ 为第 i 个 RUL 模拟预测结果。

6.2 基于 Box-Cox 变换的剩余寿命预测

经验预测法具有良好的在线运算能力, 但较差的预测性能难以满足电动汽车的实际需求。从状态估计的角度出发可以改善该方法的精度和收敛性, 但又增加了算法对模型的依赖性和计算的复杂程度。此外, 为了确保寿命经验模型的适应性, 经验预测法和滤波预测法往往都需要对大量的动力电池离线老化实验数据进行分析, 耗费大量的资源和时间。因此, 本节将详细介绍一种能够有效解决上述问题的新型经验预测法——基于 Box-Cox 变换的动力电池 RUL 预测方法。该方法不仅可以改善 RUL 的预测精度和收敛性能, 还可以免去大量的动力电池离线老化实验, 提高了传统经验预测法的工程适用性。

6.2.1 Box-Cox 变换技术

由表 6-1 可见, 除了线性模型以外, 其他寿命经验模型都具有较强的非线性和复杂的表达形式。因此, 传统的经验预测法在对动力电池历史容量数据进行拟合时, 极易受到数据波动的影响 (特别是历史末端数据波动的影响), 进而产生发散的 RUL 预测结果。线性模型的拟合性能最为稳定, 且参数最少, 但由于动力电池的容量衰减轨迹通常呈非线性, 直接采用线性模型难以实现准确的 RUL 预测。为此, Box-Cox 变换可提供一种有效的解决途径。

Box-Cox 变换是由 George Box 和 Sir David Cox 在 1964 年提出的一种参数化广义幂变换方法。该方法建立在线性、正态以及同方差性的基本假设之上, 常用于减少数据在统计建模中的非相加性、非正态性和异方差性等不规则现象。

自最初提出以来, Box-Cox 变换技术就得到了广泛关注和应用, 特别是各领域的经验函数确定过程。Box-Cox 变换的核心思想是通过引入参数来创建一个数据单调变换的函数族, 从而达到降低样本偏离正态特性的目的。对于动力电池的 RUL 预测, Box-Cox 变换可利用一个简单的变换系数将非线性的动力电池容量衰减轨迹线性化, 有效降低 RUL 预测的难度, 为精准化的线性模型预测提供了可能性。下面详细介绍基于 Box-Cox 变换的动力电池 RUL 预测过程。

6.2.2 应用流程

基于 Box-Cox 变换的动力电池 RUL 预测流程如图 6-4 所示。

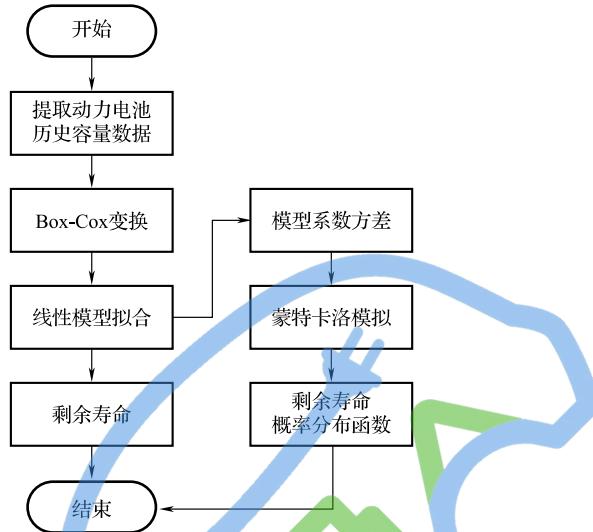


图 6-4 基于 Box-Cox 变换的动力电池 RUL 预测流程图

该方法首先需要对动力电池的历史容量数据进行 Box-Cox 变换，将非线性的容量衰减轨迹线性化，从而获取 Box-Cox 变换系数以及 Box-Cox 变换后的历史容量观测值。Box-Cox 变换的数学表达式为

$$\tilde{C}_{\max} = \begin{cases} \frac{(C_{\max})^{\lambda_{bc}} - 1}{\lambda_{bc}}, & \lambda_{bc} \neq 0 \\ \log C_{\max}, & \lambda_{bc} = 0 \end{cases} \quad (6-6)$$

式中， \tilde{C}_{\max} 为数据变换后的历史容量观测值； λ_{bc} 为 Box-Cox 变换系数。为了使上述变换得以进行，一般采用极大似然估计法对参数 λ_{bc} 进行求解，具体的求解过程等价于寻找能够最大化以下数学表达式的 λ_{bc} 作为最终的变换系数：

$$L^*(\lambda_{bc}) = \frac{n_s}{2} \log [\hat{\sigma}^2(\lambda_{bc})] + (\lambda_{bc} - 1) \sum_{i=1}^{n_s} \log(C_{\max,i}) \quad (6-7)$$

式中， $L^*(\lambda_{bc})$ 为对数自然函数； n_s 为历史容量观测值的样本规模； $\hat{\sigma}^2(\lambda_{bc})$ 的数学表达式为

$$\hat{\sigma}^2(\lambda_{bc}) = \frac{[\mathbf{C} - \mathbf{K}\hat{\beta}]^T [\mathbf{C} - \mathbf{K}\hat{\beta}]}{n_s} \quad (6-8)$$

式中， \mathbf{C} 为历史容量观测向量； \mathbf{K} 为历史容量所对应的循环次数向量；而 $\hat{\beta}$ 的数学表达式为

$$\hat{\beta} = (\mathbf{K}^T \mathbf{K})^{-1} \mathbf{K}^T \mathbf{C} \quad (6-9)$$

在完成 Box-Cox 变换后，动力电池的历史容量数据已经基本完成线性化。由于容量衰减轨迹的非线性程度减弱，RUL 预测难度降低，因此只需采用线性模型作为寿命经验模型即可满足精度要求。线性模型的拟合表达式为

$$\tilde{C}_{\max} = c_1 + n \cdot c_2 \quad (6-10)$$

式中，线性模型的系数可通过最小二乘法求解，具体的求解表达式为

$$\begin{cases} c_2 = \frac{\sum_{i=1}^{n_s} (n_i - \bar{n}) [\tilde{C}_{\max,i}(\lambda_{bc}) - \bar{\tilde{C}}(\lambda_{bc})]}{\sum_{i=1}^{n_s} (n_i - \bar{n})} \\ c_1 = \bar{\tilde{C}}(\lambda_{bc}) - c_2 \bar{n} \end{cases} \quad (6-11)$$

式中， $\bar{\tilde{C}}$ 为变换后历史容量数据的平均值； \bar{n} 为历史循环次数的平均值。

在完成线性模型系数的计算后，需要对规定的容量失效阈值进行 Box-Cox 变换，并将变换后的结果代入式 (6-10)，求解容量失效阈值所对应的循环次数。此时，通过当前循环次数的减法运算，即可获得动力电池的 RUL。

下面介绍利用 MC 方法计算 RUL 概率密度函数的详细过程。

经验预测法的预测不确定性主要来源于寿命经验模型的拟合过程。因此，BMS 首先需要根据拟合过程的不确定性随机生成若干个参数样本。为了求解线性模型系数 c_1 和 c_2 在拟合过程中的方差，需要求解以下的数学方程：

$$\begin{cases} \text{Var}(c_1) = \frac{s^2}{n_s} + \frac{s^2 \bar{n}^2}{\sum_{i=1}^{n_s} (n_i - \bar{n})^2} \\ \text{Var}(c_2) = \frac{s^2}{\sum_{i=1}^{n_s} (n_i - \bar{n})^2} \end{cases} \quad (6-12)$$

式中， $\text{Var}(c_1)$ 和 $\text{Var}(c_2)$ 分别为 c_1 和 c_2 的方差； s^2 为误差项方差的估计值，其数学表达式为

$$s^2 = \frac{SSR}{n_s - 2} \quad (6-13)$$

式中， SSR 为残差的平方和，其计算表达式为

$$SSR = \sum_{i=1}^{n_s} [C_{\max,i}(\lambda) - (\beta_0 + \beta_1 n_i)]^2 \quad (6-14)$$

基于 MC 方法的操作流程，以 c_1 和 c_2 为均值、 $\text{Var}(c_1)$ 和 $\text{Var}(c_2)$ 为方差随机生成 N 个线性模型系数样本，随后根据式 (6-10) 分别基于每一组样本开展 RUL 的

预测模拟，获得 N 个 RUL 预测结果。此时，根据式 (6-4) 和式 (6-5) 即可估计动力电池 RUL 的概率密度函数。需要指出的是，增大线性模型系数的样本规模有助于提高所求概率密度函数的可靠性，但同时也会显著增大了计算量。

6.2.3 算例分析

为了评价上述方法的性能表现，下面以动力电池 6- 单体 25 和 26 为例对该方法的预测效果进行详细分析。为了便于描述，下文将该方法简称为 Box-Cox 变换预测法。

1. 与传统经验预测法的对比

Box-Cox 预测变换法和传统经验预测法的 RUL 预测结果如图 6-5 所示。其中，传统经验预测法的 RUL 结果基于表 6-2 中的双指指数模型和多项式模型计算获得。

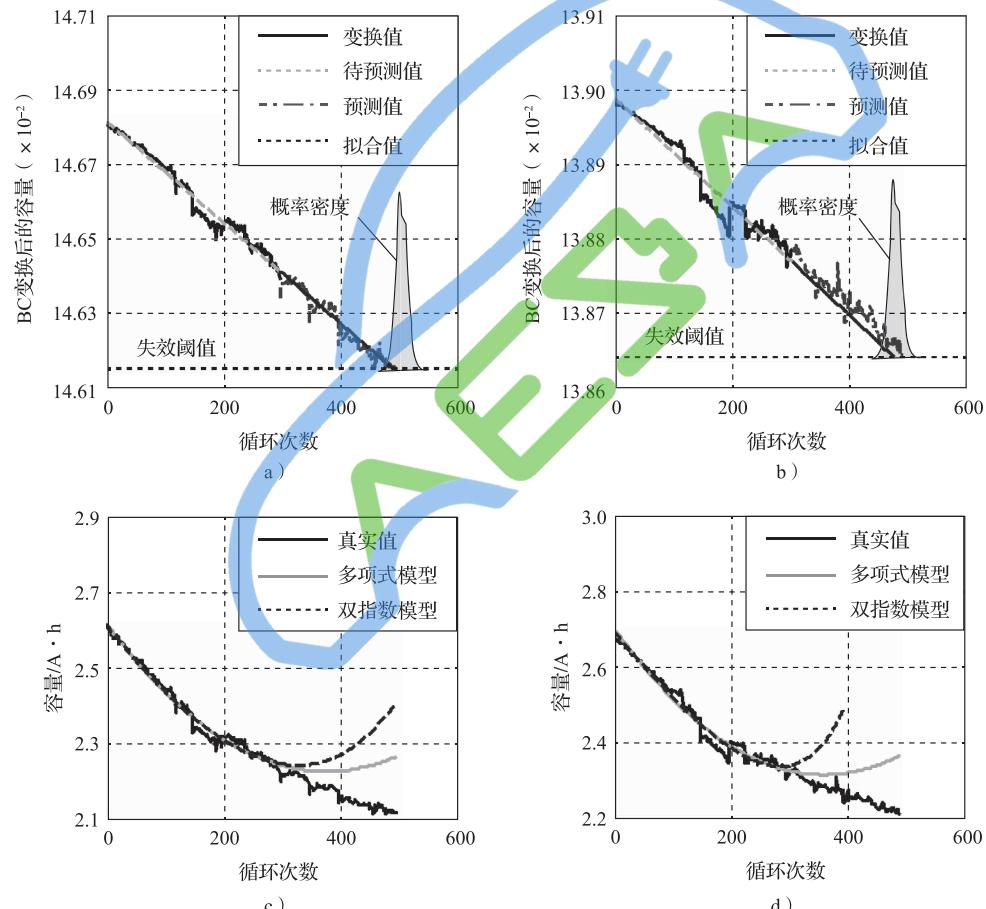


图 6-5 RUL 预测结果（见彩插）

- a) Box-Cox 变换预测法的结果（单体 25）
- b) Box-Cox 变换预测法的结果（单体 26）
- c) 传统经验预测法的结果（单体 25）
- d) 传统经验预测法的结果（单体 26）

图 6-5a 所示为单体 25 基于前 300 次循环数据的 RUL 预测结果。从图中可见, Box-Cox 变换能够有效地将非线性的容量衰减轨迹线性化。经计算, Box-Cox 变换后的容量与循环次数之间的皮尔森相关系数达到 -0.9888 , 呈现出强烈的线性关系。经过 MC 方法的模拟运算, Box-Cox 变换预测法得到该单体在到达寿命失效阈值点时将要经历 505 次循环, 仅比测试结果高出 5 次, 预测误差仅为 1%。此时, RUL 预测的 95% 置信区间为 [495, 515], 区间的跨度仅覆盖 20 次循环, 表明了 Box-Cox 变换预测法具有很高的可信度。

图 6-5b 所示为单体 26 基于前 310 次循环数据的 RUL 预测结果。经计算, 皮尔森相关系数达到 -0.9769 。与测试结果相比, Box-Cox 变换预测法的预测误差仅为 12 次循环, 即预测误差为 2.18%, 而 RUL 的 95% 置信区间为 [474, 502], 区间的跨度仅有 28 次循环。由此可见, Box-Cox 变换预测法在两个不同的动力电池单体上均能表现出优异的 RUL 预测性能。需要说明的是, 上述的 RUL 预测运算在 Intel Core i7-6700HQ 3.5GHz 处理器 MATLAB R2016b 运算环境下的仿真计算时间 $\leq 2.25\text{s}$ 。这说明 Box-Cox 变换预测法具备良好的在线运行能力。

图 6-5c 和 d 分别是以多项式模型和双指数模型作为寿命经验模型的传统经验预测法的 RUL 预测结果。从图中可见, 随着循环次数增多, 多项式模型和双指数模型的预测能力逐渐恶化, 甚至出现容量轨迹反常上升的现象。这说明传统的经验预测法在数据波动的影响下产生了发散的预测结果, 因此未能正常预测动力电池的容量衰减轨迹。

综上所述, Box-Cox 变换预测法能够有效降低动力电池 RUL 的预测难度, 大大提高了线性模型的预测精度, 改善了传统经验预测法的预测性能。

2. 在线预测的性能评价

Box-Cox 变换系数直接影响着容量衰退轨迹线性化的优劣程度。一般来说, 负变换系数误差将导致过于乐观的 RUL 预测, 而正变换系数误差将引起过于保守的 RUL 预测。因此, 评价 Box-Cox 变换系数的准确程度具有十分重要的意义。

图 6-6 所示为 Box-Cox 变换预测法 RUL 在线预测结果, 其中, 动力电池从第 50 次循环开始, 每隔 10 次循环运行一次 Box-Cox 变换法运算。

图 6-6a 和 b 所示为两个动力电池单体在不同循环下的 Box-Cox 变换系数预测结果。所示参考值均基于离线的全寿命实验数据获得, 上边界的设置比参考值高 2, 下边界的设置比参考值低 1。结果表明, Box-Cox 变换系数的估计值在动力电池的老化初期呈现波动的趋势, 在第 180 次循环后开始快速收敛到参考值。单体 25 和 26 的变换系数估计值分别在 250 次和 310 次循环后进入上下边界的范围内。

图 6-6c 和 d 中的 RUL 预测结果呈现出与 Box-Cox 变换系数相同的变化趋势。单体 25 的 RUL 预测大约在 60 次循环以后收敛到真实值。值得注意的是, 一

且收敛到真实值，动力电池 RUL 的误差大多数被控制在 10 次循环以内。而单体 26 的 RUL 预测结果在距离测试值 20 次循环附近呈现稳定的走势。图 6-6e 和 f 表明 Box-Cox 变换预测法能够有效地将 RUL 预测的标准差控制在 7 次循环以内，而预测标准差将随着历史老化数据的增多而下降。

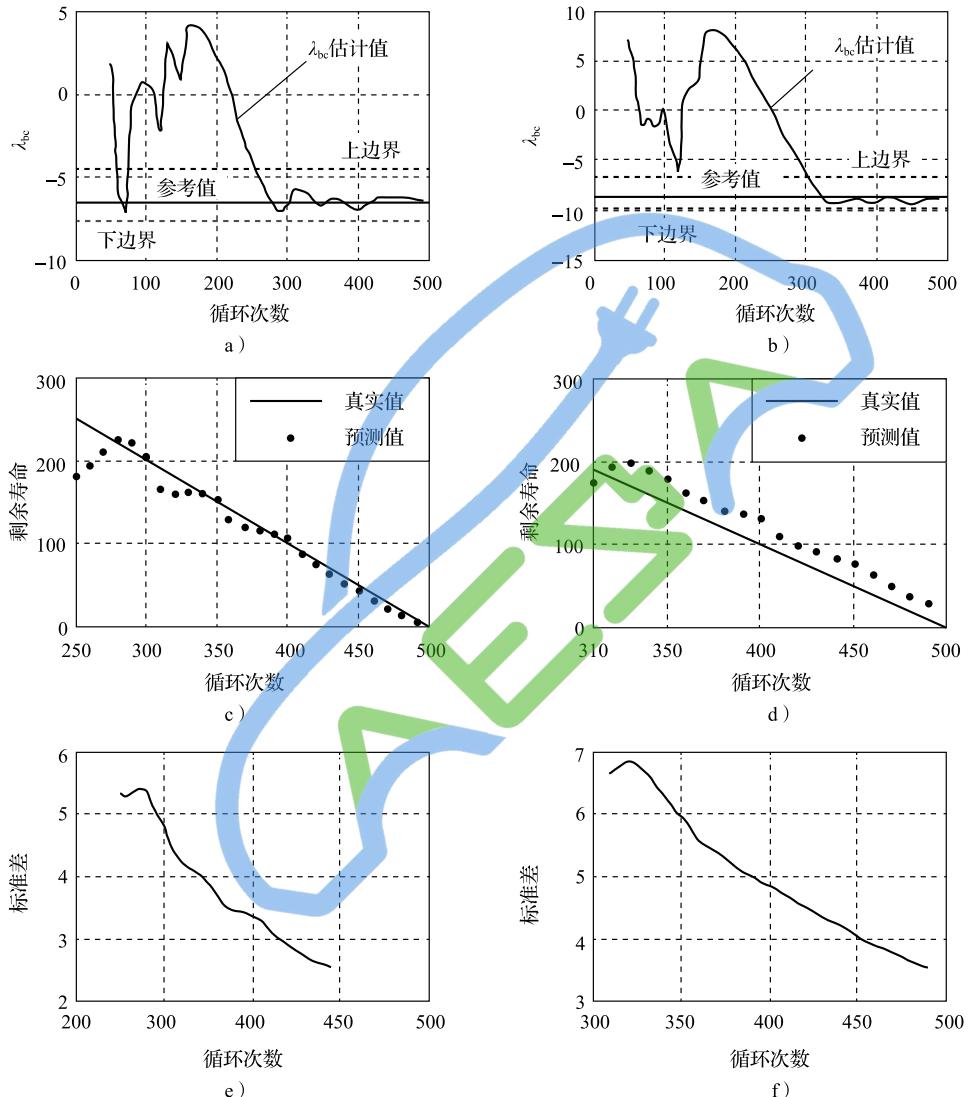


图 6-6 基于 Box-Cox 变换法的动力电池 RUL 在线预测结果（见彩插）

- a) λ 估计值 (单体 25)
- b) λ 估计值 (单体 26)
- c) 预测结果 (单体 25)
- d) 预测结果 (单体 26)
- e) 预测标准差 (单体 25)
- f) 预测标准差 (单体 26)

综上所述，Box-Cox 变换预测法具有稳定的在线预测性能，其预测结果具有

良好的精确度。

3. 与滤波预测法的对比

Box-Cox 变换预测法与滤波预测法均可视为在不同预测思路下对经验预测法的改进方案。因此，下面对两者进行对比评价。需要说明的是，滤波预测法采用最为常见的粒子滤波作为状态估计算法。为了方便讨论，将基于粒子滤波的动力电池 RUL 预测方法简称为粒子滤波法。图 6-7 所示为 Box-Cox 变换预测法与粒子滤波法分别对单体 25 的 RUL 预测结果。

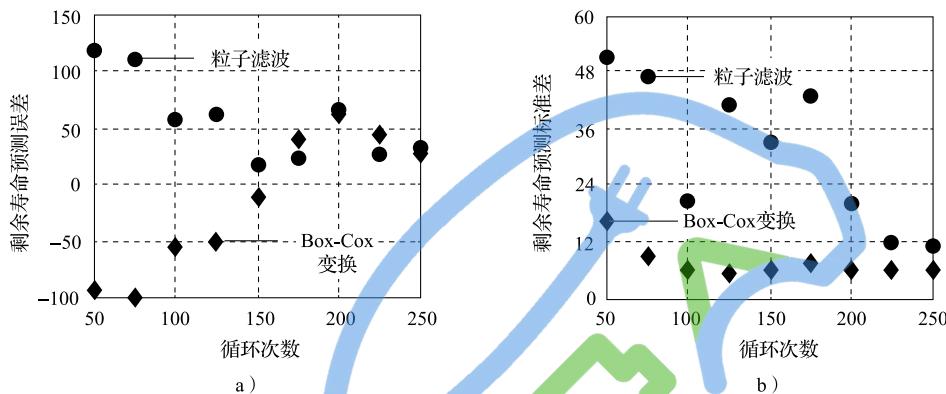


图 6-7 Box-Cox 变换预测法与粒子滤波法的 RUL 预测（单体 25）
a) 预测误差 b) 预测标准差

图 6-7a 表明，Box-Cox 变换预测法和粒子滤波法都需要经过约 130 次循环以后才能收敛到 RUL 的真实值附近。而在大多数情况下，Box-Cox 变换法的预测精度均略高于粒子滤波法。经计算，Box-Cox 变换法和粒子滤波法的平均预测误差分别为 53.7 次和 56.5 次（测试的 RUL 值为 500 次）。由此可见，Box-Cox 变换预测法在整体上的预测精度高于粒子滤波法。

图 6-7b 所示为两种方法的 RUL 预测标准差。从图中可见，两种方法的预测标准差都随着老化数据量的增多而降低，但 Box-Cox 变换法的预测标准差明显低于粒子滤波法，并且从预测初期到末期均能维持在较低的水平。经计算，Box-Cox 变换预测法和粒子滤波法的平均预测标准差分别为 7.2 次和 30.8 次。

综上所述，Box-Cox 变换法在准确度和精确度上都具有更优异的性能。

6.3 基于长短时记忆循环神经网络的剩余寿命预测

从时间序列的角度考虑，动力电池的老化通常经历较长时间，覆盖上千次循环，且循环之间的老化容量高度相关。尽管动力电池的容量衰减轨迹可以基于历