

基于 SAE-VMD 的锂离子电池健康因子提取方法

王竹晴, 郭阳明, 徐聪

(西北工业大学 计算机学院, 陕西 西安 710072)

摘要: 电池退化信号具有非平稳、非线性特性, 为自适应提取能准确表达电池退化特性的健康因子 (HI), 提高锂离子电池剩余寿命 (RUL) 的预测精度, 提出一种基于堆叠稀疏自编码 (SAE) 和变分模态分解 (VMD) 的 HI 构建方法。首先利用 SAE 深度神经网络对多个电池参数去噪、降维, 提取出一个集中包含电池退化特性的融合 HI; 然后利用 VMD 将融合 HI 的全局衰减、局部再生和其他噪声 3 种模态进行有效分离, 将被分离的 3 个分量作为电池 HI, 以此消除 HI 不同尺度上波动之间的相互干扰, 提高 RUL 预测精度。锂离子电池 RUL 的预测结果表明, 使用该方法所提 HI 得到的 RUL 预测精度最高, 说明所提 HI 品质最高。

关键词: 锂离子电池; 剩余使用寿命; 健康因子; 稀疏自编码; 变分模态分解

中图分类号: TP206+.3

文献标志码: A

文章编号: 1000-2758(2020)04-0814-08

在以锂离子电池为能源部件的系统设备中, 电池寿命失效威胁到整个系统设备的安全运行。实现电池剩余寿命 (remaining useful life, RUL) 的准确预测, 对减少事故发生和经济损失具有重要意义^[1]。电池容量与内部电化学反应密切相关, 因此在 RUL 预测中, 常使用容量作为直接健康因子 (health indicator, HI)^[2]。然而, 容量衰减并不是单调平稳的过程, 其总体呈递减趋势, 局部出现多次震荡, 这种局部波动是由电池静置阶段的容量再生现象造成^[3]。局部容量再生是一种暂态的、虚假的现象, 也是退化信号出现剧烈波动和 RUL 预测偏差的主要原因。另外, 使用容量作为 HI 还存在一个根本问题, 即容量常采用侵入性的测量方式, 对电池具有破坏性, 难以在线应用。

目前, 构建基于易测参数的间接 HI 方法取得一定进展, 如电池充电电压采样^[4]、放电电压样本熵^[5]、等放电电压间隔的时间差^[6], 以及文献^[7]中使用电荷量、放电功率、放电深度和温度共同作为间接 HI。间接 HI 解决了容量难以在线获取的问题, 然而仍存在以下缺陷: ①间接 HI 对电池退化特性的表达能力参差不齐。现有间接 HI 提取主要由人工

实现, 需要研究者积累一定的先验知识进行反复修改调整, 不但耗费人力、物力, 且无法保证间接 HI 对电池退化特性的全面覆盖。②缺少对 HI 不同尺度上变化特性的考量。可知电池退化至少包含全局衰减、局部再生和其他噪声 3 种现象, 而文献^[4-7]主要集中在对宏观混合信号的分析, 忽视了局部波动对整体趋势的干扰问题。

近年来, 深度学习相关方法在多个领域取得显著成果, 在锂离子电池寿命预测方面也取得一定进展。在最新的锂离子电池健康状态评估和 RUL 预测研究成果中, Lu 等^[8]和 Park 等^[9]利用长短时记忆神经网络模型 (long short-term memory, LSTM), 实现了锂离子电池 RUL 的精确预测。类似的, 文献^[10]提出了一种新的变长短时记忆神经网络模型 (variant LSTM, VLSTM), 实现了锂离子电池在线健康状态管理。然而, 该领域前期的研究重点一直集中于锂离子电池状态评估模型和寿命模型的精确构建。直到近年来, 以锂离子电池为能源供给的电动汽车、航天电源等产业的兴起, 基于在线测量参数的电池间接健康因子构建研究逐渐引起关注。目前基于复杂深度神经网络的健康因子构建的研究成果较

收稿日期: 2019-10-08

基金项目: 国防基础科研计划项目、国网浙江省电力有限公司科技项目与陕西省创新能力支撑计划项目 (2019PT-03) 资助

作者简介: 王竹晴 (1992—), 女, 西北工业大学博士研究生, 主要从事计算机测量与控制技术、预测与健康研究。

少。最主要的原因是卷积神经网络、循环神经网络这类深度学习模型参数较多,结构十分复杂,网络训练时间长,且需要大量训练数据。然而,能在线获取的电池数据是有限的,很难满足深度网络的训练需求。为应对上述问题,将堆叠自编码(stacked auto encoder, SAE)引入锂离子电池健康因子构建中。该方法可通过自学习生成高阶抽象的复杂函数,自适应将复杂多维的初始寿命参数转化成能集中表达系统特征的融合参数,且在电压暂降特征^[11]、齿轮箱振动特征^[12]、轴承故障特征^[13]提取中取得成功应用。与传统深度学习模型相比,该模型体量更轻,参数较少,摆脱了传统特征提取对专家经验的过度依赖,是一种行之有效的无监督特征提取网络,十分适用于锂离子电池健康因子自适应、在线提取^[14]。

另外,考虑到电池容量退化至少包含全局衰减、局部再生和其他噪声3种现象混叠,为进一步刻画这种退化特性,文献[15-16]提出利用经验模态分解(empirical mode decomposition, EMD)方法对容量衰减的主趋势和波动进行分离,再分别建立主趋势和波动的预测模型。EMD一定程度上可以降低局部再生对整体趋势的干扰,但是存在分量模态混叠、分量较多等问题,导致信息遗漏和预测模型过多。

综上所述,本文结合SAE和变分模态分解(variational mode decomposition, VMD)技术,提出一种考虑局部再生问题的自适应锂离子电池HI构建方案,所提方法在已有成果的基础上,实现了如下创新:①提出了一种锂离子电池间接HI自适应构建策略,解决现有间接HI品质较低,提取过程依赖专家经验的问题;②利用VMD将电池健康因子中的局部回升现象和全局衰减趋势分离,解决了因HI局部不平稳震荡造成预测偏差的问题,同时克服了传统EMD模态混叠和分量过多导致电池状态评估和寿命预测模型复杂的问题。

1 基于SAE-VMD的电池HI提取

1.1 基于栈式SAE的参数融合

SAE是一种基于逐层贪婪的无监督学习方法,能够对样本特征进行自适应、深层次学习。SAE的深度特征提取思想是通过无限堆叠构成深度网络,将上一层输出作为下一层的输入,然后最小化输入和输出信号的重构误差,以此完成对输入数据的层层压缩,基本结构如图1a)所示。

根据文献[17]所述电池放电能量、放电深度、放电功率、平均温度、放电电压初始骤降值、平台期放电时长、平台期电压变化率与电池容量具有显著线性相关,可作为电池初始退化参数。然后利用2个SAE堆叠构成一个栈式自编码器进行二阶参数融合,结构如图1b)所示。融合过程如下:

一阶融合:将初始参数作为图1a)所示网络结构的输入和输出,隐含层节点数小于网络输入,进行网络编码和解码,得到输入层到 $h^{(1)}$ 层的网络参数。训练完成后去除解码层,只留下图1b)所示的输入层至 $h^{(1)}$ 层,隐藏层输出为一阶融合结果。

二阶融合:将一阶融合的结果作为图1a)所示网络结构的输入和输出,隐层节点数设定为1,即最终融合为一个序列。融合过程与一阶相似,去除解码层后的隐藏层输出即为二阶融合HI。另外,网络每次训练隐藏层个数通过反复试验确定。




图1 栈式SAE

图中 $\mathbf{x} = [x_1, \dots, x_n]$ 和 $\hat{\mathbf{x}} = [\hat{x}_1, \dots, \hat{x}_n]$, \mathbf{x} 和 $\hat{\mathbf{x}}$ 分别表示网络的输入和输出; w_{ij} 和 w_{jk} 表示连接权值。隐藏层节点输出 h_j 和输出层节点 \hat{x}_k 为

$$h_j = f\left(\sum_{i=1}^m x_i w_{ij} + b_1\right), \quad \hat{x}_k = f\left(\sum_{j=1}^n h_j w_{jk} + b_2\right) \quad (1)$$

式中: m 为特征融合个数; n 为输入输出节点个数; $f(\cdot)$ 为节点激励函数; b_1, b_2 为权值。

编码阶段指通过编码激励函数将 n 维输入样本 x_i 映射成 m 维的 h_j ,解码阶段指将 h_j 重新映射为 n 维的 \hat{x}_k 。

1.2 变分模态分解

VMD是Dragomiretskiy等^[18]于2013年提出的一种新的非递归信号变分分解方法,VMD将信号分解转化为对变分约束模型求最优解的过程,自适应将信号分解成一系列固定模态分量,克服了EMD模态混叠、虚假分量、数学基础差等问题^[19]。

VMD设定原始信号 f 为有限个模态分量 $u_k(t)$ 复合而成,通过Hibert变换计算每个 $u_k(t)$ 单边频

谱,然后通过混合中心频率 w_k ,将 $u_k(t)$ 的频谱调制基带宽,最后求解使 $u_k(t)$ 之和最小带约束条件的变分模型,如公式(2)所示

$$\begin{cases} \min_{\{u_k\}, \{w_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 \right\} \\ \text{s.t.} \quad \sum_k u_k(t) = f \end{cases} \quad (2)$$

式中, $\delta(t)$ 为狄克拉函数, ∂_t 为梯度运算, $*$ 表示卷积运算。

上述变分模型求解思路是:

1) 引入二次惩罚因子 α 和拉格朗日算子 $\lambda(t)$, 将约束问题转化成非约束问题

$$L(\{u_k\}, \{w_k\}, \lambda) =$$

$$\langle \lambda(t), x(t) - \sum_k u_k(t) \rangle + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 \quad (3)$$

式中, $\langle \rangle$ 表示内积运算。

2) 引入乘法算子交替方向法迭代更新 u_k, w_k 和 λ , 寻找(3)式的鞍点, 即为约束变分方程的最优解。利用 Parseval/Plancherel Fourier 理论得到 u_k^{n+1} 在频域的表达 $\hat{u}_k^{n+1}(\omega)$, n 表示迭代次数。

初始化 $\{u_k^1(\omega)\}$, $\{\hat{w}_k^1(\omega)\}$ 和 $\hat{\lambda}^1(\omega)$, 然后根据(4)~(6)式更新 $u_k^{n+1}(\omega)$, $\hat{w}_k^{n+1}(\omega)$ 和 $\hat{\lambda}^{n+1}(\omega)$

$$\frac{f(\omega) - \sum_{i < k} \hat{u}_i^{n+1}(\omega) - \sum_{i < k} \hat{u}_i^{n+1}(\omega) + \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (4)$$

$$\hat{\omega}_k^{n+1}(\omega) \leftarrow \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (5)$$

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau(\hat{f}(\omega)) - \sum_k \hat{u}_k^{n+1}(\omega) \quad (6)$$

式中, τ 表示带宽。

迭代终止条件为

$$\sum_k \frac{\|\hat{u}_k^{n+1}(\omega) - \hat{u}_k^n(\omega)\|_2^2}{\|\hat{u}_k^{n+1}(\omega)\|_2^2} < \varepsilon \quad (7)$$

式中, ε 为判别精度且大于 0。

令 SAE 二阶融合 HI 的数据为 $H(t)$, 其 VMD 分解结果可表示为

$$H(t) = \sum_{k=1}^N u_k \quad (8)$$

式中, N 为模态分量个数, 本文仅考虑将电池全局衰减、局部再生和其他噪声的分离, 因此 N 设置为 3。根据经验, 将凸优化参数 τ 设置为 0、中心频率初始化为 1、终止条件 ε 设置为 10^{-6} 、惩罚因子 α 对结果影响较大则通过试验确定。

1.3 基于 SAE-VMD 的健康因子提取和 RUL 预测

为了验证所提方法效果, 利用相关向量机 (relevance vector machine, RVM) 和人工神经网络 (artificial neural networks, ANN) 方法进行 RUL 预测建模。图 2 为整体预测流程, 具体步骤如下:

1) 基于 SAE 的电池参数融合和评估。利用 SAE 从电池多个初始测量参数中提取出一个融合 HI。然后计算 Spearman 秩相关系数及显著性检验, 验证融合 HI 与容量的相关关系。

2) 基于 VMD 的健康因子多尺度分解。利用 VMD 将 HI 从 3 种尺度进行分解, 得到全局分量 u_{k1} , 和局部分量 u_{k2}, u_{k3} 。

3) 组合预测电池 RUL。利用 RVM 建立全局退化趋势模型, 基于 ANN 分别建立局部再生和噪声的模型。将 3 个模型的预测结果累加, $\hat{u} = \hat{u}_{k1} + \hat{u}_{k2} + \hat{u}_{k3}$ 。由公式(9)计算得出当前时刻电池 RUL 预测值^[4]。

$$N_{\text{RUL}} = N_{\text{EOL}} - N_{\text{ECL}} \quad (9)$$

式中, N_{RUL} 表示电池 RUL; N_{EOL} 为当电池健康因子预测值到达失效阈值时对应电池循环放电次数, 通常电池失效阈值为额定容量的 70%~80%, 为方便计算, 将容量失效阈值的归一化值作为所提健康因子的失效阈值; N_{ECL} 表示预测起始点电池的循环充放电次数。

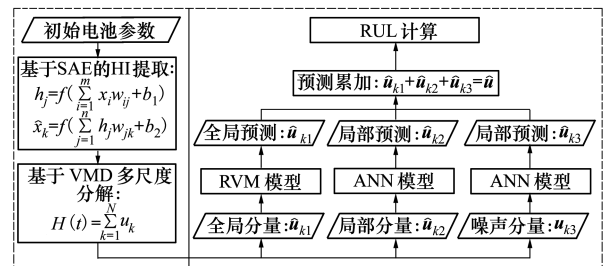


图 2 基于 SAE-VMD 健康因子提取的 RUL 预测流程

2 试验与验证

2.1 试验数据

本文试验数据来自于 NASA PCoE 研究中心提供的 Battery Data Set^[20]。包含一组 4 个 18650 型

号锂离子电池(B5,B6,B7和B18)在室温下的充放电试验数据。当电池的容量小于70%,即1.4 Ah时认为该电池寿命终止。由于该数据集电池一致性不是很好,B7容量退化没有达到1.4 Ah,将B7的失效阈值定为1.42 Ah。另外,所提HI与容量相关性极高,因此将容量归一化后的失效阈值等同于HI归一化后的失效阈值,最终RUL的预测结果由归一化后的HI退化趋势得到。

2.2 基于SAE参数融合和评估

为验证SAE相较于传统特征提取方法的优势,

与基于主成分分析方法(principal component analysis,PCA)^[21]、局部自适应保留投影法(locality adaptive preserving projections,LAPP)^[22]融合的HI进行对比,并计算3种融合HI与容量的Spearman秩相关系数。如表1所示,4组电池基于SAE得到的融合HI与容量相关系数明显高于PCA和LAPP方法得到的融合HI,且在置信度(双侧)为0.01时,双侧显著性检验P值都为0,说明该检验呈显著性相关。图3为3种方法提取的HI与容量经过归一化后在不同寿命周期的退化曲线。

表1 健康因子和容量的相关性分析表

Spearman 相关性	基于SAE融合HI				基于PCA融合HI				基于LAPP融合HI			
	B5	B6	B7	B18	B5	B6	B7	B18	B5	B6	B7	B18
B5容量	0.998**	-	-	-	0.951**	-	-	-	0.988**	-	-	-
B6容量	-	0.999**	-	-	-	0.993**	-	-	-	0.960**	-	-
B7容量	-	-	0.998**	-	-	-	0.959**	-	-	-	0.988**	-
B18容量	-	-	-	0.996**	-	-	-	0.993**	-	-	-	0.992**

注:表中所有相关系数对应P值都为0;**在置信度(双侧)为0.01时,显著性是相关的。

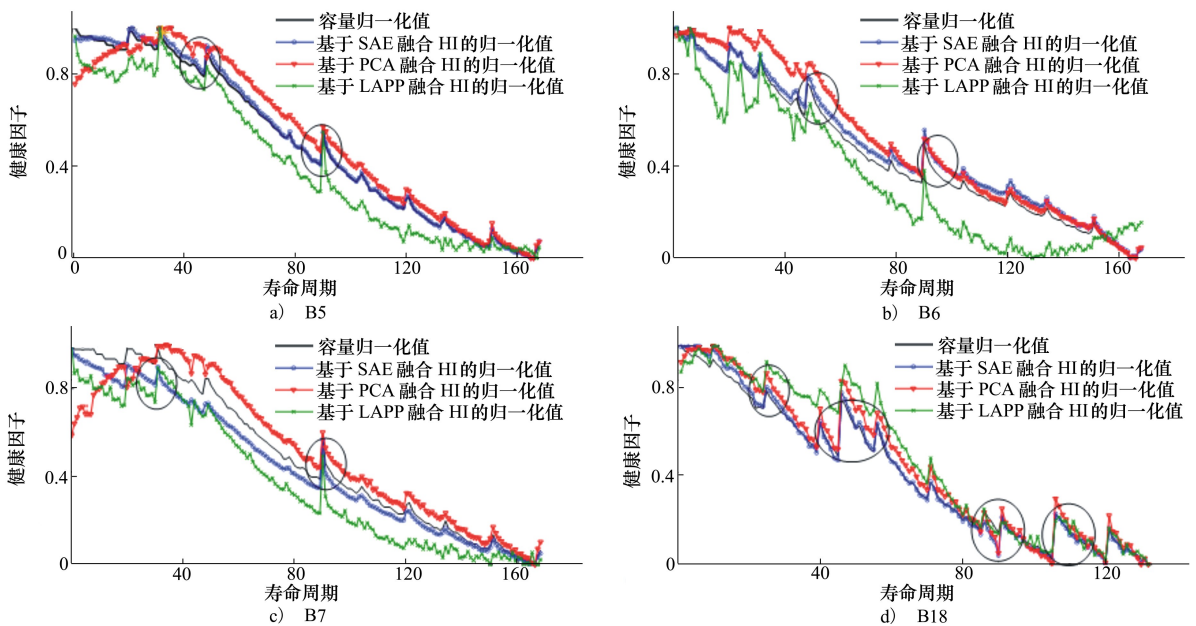


图3 归一化的容量与融合健康因子退化曲线

图中,基于SAE提取的HI与容量曲线变化一致,在全局衰减和局部突变阶段都能准确契合电池容量衰减趋势,能全面、准确地表达出电池退化特性。而基于PCA和LAPP提取的HI与容量变化趋

势相差较大,其中PCA在B5、B7电池的初期出现了相反趋势,如果用该阶段数据进行寿命预测,会导致预测结果偏差;而LAPP提取的HI局部波动过多且整体趋势偏差较大,也不利于RUL预测。综上,基

于 SAE 方法得到的融合 HI 与容量线性一致性更强,对电池退化特性表达能力最强。由于 PCA 和 LAPP 所提 HI 与容量相关性皆低于 SAE 方法所提取 HI,为避免累赘,本文仅选择 PCA 方法提取的 HI 参与 2.4 节 RUL 预测试验。

2.3 基于 VMD 的 HI 多尺度分解

为了避免局部波动对 RUL 预测结果造成干扰,利用 VMD 将融合 HI 的全局衰减、局部再生和其他噪声分离。以 B5 电池为例,图 4 为基于 EMD 和 VMD 2 种方法分解出的模态分量。图中,VMD 分解出了 3 个模态分量,模态 u_1, u_2 和 u_3 分别表示 HI 低频全局退化、高频局部再生和其它噪声;受分解机制所限,EMD 方法不能自定义分量个数,分解结果显示 EMD 将电池 HI 分解出了 5 个本征模函数 (intrinsic mode function, IMF)。其中 IMF5 是迭代分解后得到的表征全局退化趋势的余波,其余分量为包含局部再生现象的高频信号。由分析可知,3 种尺度即可刻画电池退化特性,过多的分量对预测精


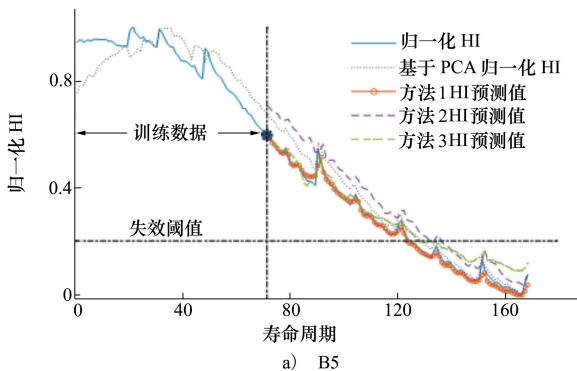


图 4 B5 电池 HI 的多尺度分解



度并无帮助,反而由于预测模型的数量增加,提升了预测复杂性。

2.4 基于 RVM 和 ANN 锂离子电池 RUL 预测试验

RVM 和 ANN 是锂离子电池 RUL 预测中常用的 2 种人工智能方法,本文基于 RVM 建立全局衰减预测模型,基于 ANN 建立局部再生和噪声预测模型,最后将 3 个模型预测结果相加得到 HI 的预测曲线。取前 70 个周期数据作为训练样本,预测起始点为第 71 个周期,B5、B6 和 B7 后 98 组作为预测样本,B18 后 62 个周期的数据作为预测样本。为了验证所提方法的有效性,设计以下预测对比方法:


方法 1 基于 SAE-VMD 健康因子提取和基于 RVM+ANN 组合预测;

方法 2 基于 PCA-VMD 健康因子提取和基于 RVM+ANN 预测;方法二与方法一关于 VMD 的参数设置相同;

方法 3 基于 SAE-EMD 健康因子提取和基于 RVM+ANN 预测。

其中,方法 1 为本文所提方法,将方法 1 与方法 2 的预测结果进行对比,可证明 SAE 的深度退化特征挖掘能力;将方法 1 和方法 3 的预测结果进行对比,可证明 VMD 多尺度分解的必要性和优越性。

图 5 为 3 种方法的预测结果,可看出方法 1 得到的 HI 预测曲线与原曲线几乎重叠,既能预测出整体退化趋势又能识别局部再生现象;方法 3 得到的 HI 预测曲线基本能反映出局部再生现象,但无法很好跟踪全局趋势,且随着预测寿命周期增加,误差也逐渐增大;由 2.2 节分析可知,基于 PCA 提取的 HI 品质不佳,因此方法 2 得到的 HI 预测结果与预期相差较大。



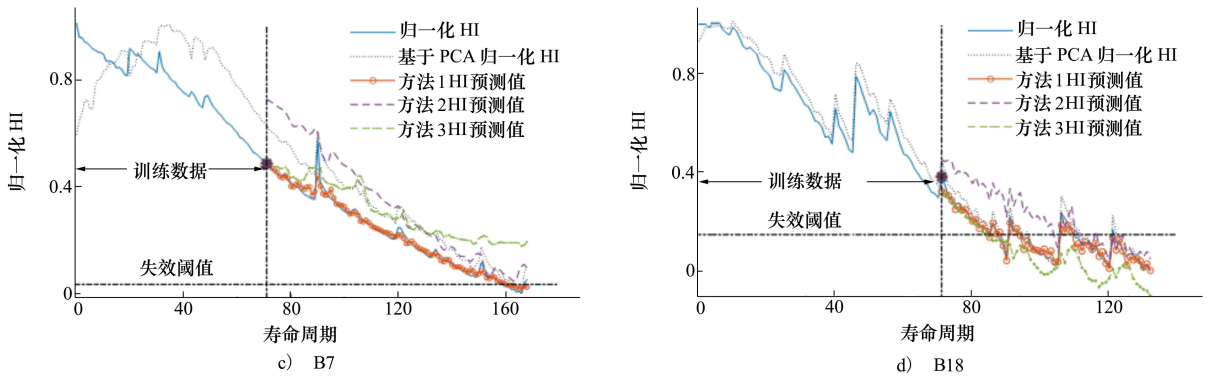


图 5 3 种方法预测结果对比

使用 3 种指标 RMSE、MAE、 R^2 评价 3 种方法的预测性能。4 组电池的 RUL 预测结果如表 2 所示,其中方法一 RMSE 的范围在 0.015 0~0.020 2 之间,而方法 2、方法 3 的 RMSE 最小值 0.065 3 和 0.040 1 皆大于方法 1 RMSE 的最大值;方法 1 MAE 的最大值也皆小于方法 2、方法 3 的最小值。方法 1 的 R^2 都在 0.99 之上,而方法 2、方法 3 的 R^2 皆小于此值。以上分析充分证明,所设计的基于 SAE-VMD 健康因子提取方法可以实现电池全局和局部趋势的精确捕捉,以及电池 RUL 的精确预测。图 6 为 3 种方法的 RUL 预测结果,可以看出所提方法的预测误差最小,预测精度最高。

表 2 HI 预测精度对比

参数名	方法	B5	B6	B7	B18
RMSE	1	0.015 0	0.016 0	0.019 0	0.020 2
	2	0.069 1	0.065 3	0.078 9	0.095 6
	3	0.045 7	0.040 1	0.097 5	0.081 7
R^2	1	0.999 0	0.998 0	0.997 7	0.998 1
	2	0.974 7	0.975 2	0.961 7	0.958 3
	3	0.981 1	0.980 1	0.938 4	0.968 2
MAE	1	0.010 4	0.011 5	0.012 0	0.014 4
	2	0.066 5	0.058 0	0.063 0	0.080 4
	3	0.509 2	0.252 0	0.087 8	0.067 7




图 6 3 种方法 RUL 预测结

3 结 论

本文提出了一种基于 SAE-VMD 的锂离子电池健康因子提取方法,并利用 RVM+ANN 建立 RUL 预测模型验证了所提方法的优越性。主要体现在:

1) 提出了一种通用性更高的锂离子电池间接 HI 自适应提取策略。将传统人工 HI 构建转化成自动 HI 提取,减少了人工误差,提高了 HI 对电池退化特性的表达能力。

2) 将 HI 全局衰减、局部再生和其它噪声进行分离,极大降低了局部再生现象对预测结果的干扰,进一步提高了 RUL 预测精度。

参考文献:

[1] LIPU M H, HANNAN M, HUSSAIN A, et al. A Review of State of Health and Remaining Useful Life Estimation Methods for Lithium-Ion Battery in Electric Vehicles: Challenges and Recommendations[J]. Journal of Cleaner Production, 2018, 205:

115-133

- [2] YANG D, ZHANG X, PAN R, et al. A Novel Gaussian Process Regression Model for State-of-Health Estimation of Lithium-Ion Battery Using Charging Curve[J]. *Journal of Power Sources*, 2018, 384: 387-395
- [3] DENG L M, HSU Y C, LI H X. An Improved Model for Remaining Useful Life Prediction on Capacity Degradation and Regeneration of Lithium-Ion Battery[C]//*Proceedings of the Annual Conference of the Prognostics and Health Management Society*, Saint Petersburg, FL, USA, 2017: 2-7
- [4] WU J, ZHANG C, CHEN Z H. An Online Method for Lithium-Ion Battery Remaining Useful Life Estimation Using Importance Sampling and Neural Networks[J]. *Applied Energy*, 2016, 173: 134-140
- [5] WIDODO A, SHIM M C, CAESARENDRA W, et al. Intelligent Prognostics for Battery Health Monitoring Based on Sample Entropy[J]. *Expert Systems with Applications*, 2011, 38(9): 11763-11769
- [6] LIU D, WANG H, PENG Y, et al. Satellite Lithium-Ion Battery Remaining Cycle Life Prediction with Novel Indirect Health Indicator Extraction[J]. *Energies*, 2013, 6(8): 3654-3668
- [7] HUSSEIN A. Capacity Fade Estimation in Electric Vehicle Li-Ion Batteries Using Artificial Neural Networks[J]. *IEEE Trans on Industry Applications*, 2014, 51(3): 2321-2330
- [8] LU S, WANG F, PIAO C H, et al. Health State Prediction of Lithium-Ion Battery Based on Deep Learning Method[C]//*IOP Conference Series: Materials Science and Engineering*, 2020
- [9] PARK K, CHOI Y, WON J C, et al. LSTM-Based Battery Remaining Useful Life Prediction with Multi-Channel Charging Profiles[J]. *IEEE Access*, 2020(8), 20768-20798
- [10] LI P H, ZHANG Z J, XIONG Q Y, et al. State-of-Health Estimation and Remaining Useful Life Prediction for the Lithium-Ion Battery Based on a Variant Long Short Term Memory Neural Network[J]. *Journal of Power Sources*, 2020, 459: 1-12
- [11] 李丹奇, 梅飞, 张宸宇, 等. 基于深度置信网络的电压暂降特征提取及源辨识方法 [J]. *电力系统自动化*, 2019, 43: 1-9
LI Danqi, MEI Fei, ZHANG HuanYu, et al. Deep Belief Network Based Method for Feature Extraction and Source Identification of Voltage Sag[J]. *Automation of Electric Power Systems*, 2019, 43: 1-9 (in Chinese)
- [12] 金棋, 王友仁, 王俊. 基于深度学习多样性特征提取与信息融合的行星齿轮箱故障诊断方法 [J]. *中国机械工程*, 2019, 30(2): 196-204
JIN Qi, WANG Youren, WANG Jun. Planetary Gearbox Fault Diagnosis Based on Multiple Feature Extraction and Information Fusion Combined with Deep Learning[J]. *China Mechanical Engineering*, 2019, 20(2): 196-204 (in Chinese)
- [13] 赵春华, 胡恒星, 陈保家, 等. 基于深度学习特征提取和 WOA-SVM 状态识别的轴承故障诊断 [J]. *振动与冲击*, 2019, 38(10): 31-37
ZHAO Chunhua, HU Hengxing, CHEN Baojia, et al. Bearing Fault Diagnosis Based on the Deep Learning Feature Extraction and WOA SVM State Recognition[J]. *Journal of Vibration and Shock*, 2019, 38(10): 31-37 (in Chinese)
- [14] AYINDE B O, ZURADA J M. Deep Learning of Constrained Autoencoders for Enhanced Understanding of Data[J]. *IEEE Trans on Neural Networks Learning Systems*, 2017, 29(9): 3969-3979
- [15] HE Y J, SHEN J N, SHEN J F, et al. State of Health Estimation of Lithium-Ion Batteries: a Multiscale Gaussian Process Regression Modeling Approach[J]. *AIChE Journal*, 2015, 61(5): 1589-1600
- [16] YU J. State of Health Prediction of Lithium-Ion Batteries: Multiscale Logic Regression and Gaussian Process Regression Ensemble[J]. *Reliability Engineering System Safety*, 2018, 174: 82-95
- [17] 王竹晴. 基于神经网络的锂离子电池 RUL 预测方法研究 [D]. 太原: 中北大学, 2019
WANG Zhuqing. Research on RUL Prediction Method of Lithium-Ion Battery Based on Neural Network[D]. Taiyuan: North University of China, 2019 (in Chinese)
- [18] DRAGOMIRETSKIY K, ZOSSO D. Variational Mode Decomposition[J]. *IEEE Trans on Signal Processing*, 2013, 62(3): 531-544
- [19] LI J, WANG H, ZHANG J, et al. Impact Fault Detection of Gearbox Based on Variational Mode Decomposition and Coupled Underdamped Stochastic Resonance[J]. *ISA Transactions*, 2019, 95: 320-329
- [20] SAHA B, GOEBEL K. Modeling Li-ion Battery Capacity Depletion in a Particle Fitting Framework[C]//*Proceedings of the Annual Conference of the Prognostics and Health Management Society*, 2009
- [21] SONG Y, LIU D, PENG Y, et al. Self-Adaptive Indirect Health Indicators Extraction within Prognosis of Satellite Lithium-Ion

Battery[C]//Prognostics and System Health Management Conference. 2017:1-7

[22] WEN J, ZHONG Z F, ZHANG Z, et al. Adaptive Locality Preserving Regression[J]. IEEE Trans on Circuits and Systems for Video Technology, 2020,30(1): 75-88

An HI Extraction Framework for Lithium-Ion Battery Prognostics Based on SAE-VMD

WANG Zhuqing, GUO Yangming, XU Cong

(School of Computer Science and Engineering, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: The signals of lithium-ion battery degradation are non-stationary and nonlinear. To adaptively extract the health indicator(HI) that can accurately represent the battery degradation characters and improve the prediction precision of battery remaining useful life (RUL), a stacked auto encoder-variational mode decomposition(SAE-VMD) based HI construction framework is proposed. Firstly, the stacked auto encoder(SAE) is used to reduce the noises of battery parameters and lower the data dimensionality and construct a syncretic HI that contains the battery degradation characters. Then the variational mode decomposition(VMD) is employed for effectively separating the syncretic HI into three modalities: the global attenuation, the local regeneration and the noises. The three modalities are selected as HIs to eliminate the HI noises and improve the RUL prediction precision. The RUL prediction results of lithium-ion battery indicate that the HI extracted by using the present method can obtain a better RUL prediction precision and verify the high quality of the extracted HI.

Keywords: lithium-ion battery; remaining useful life; health indicator; stacked auto encoder; variational mode decomposition