

基于混合核函数相关向量机的铅酸蓄电池 SOH估计方法研究

丁一¹, 刘盛终¹, 王旭东², 戚艳¹, 霍现旭¹, 胡志刚³

(1. 国网天津市电力公司电力科学研究院, 天津 300384; 2. 国网天津市电力公司, 天津 300010; 3. 国网天津市电力公司城东供电分公司, 天津 300250)

摘要:通过对铅酸蓄电池充电阶段特征与电池容量的分析,提出了一种基于相关向量机(RVM)的铅酸蓄电池在线健康状态估计方法。RVM的核函数选取泛化能力较强的混合核函数,用变概率遗传算法(VPGA)对核函数进行参数优化,建立了RVM回归模型。实验结果表明该方法可以实现对铅酸蓄电池健康状态的精准估计与在线监测。

关键词:铅酸蓄电池;健康状态;相关向量机;在线估计

中图分类号:TM28 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqed21888

The SOH Estimate Method Research on Lead-acid Battery Based on Mixture Kernels Function RVM

DING Yi¹, LIU Shengzhong¹, WANG Xudong², QI Yan¹, HUO Xianxu¹, HU Zhigang³

(1. Electric Power Research Institute of State Grid Tianjin Electric Power Company, Tianjin 300384, China;
2. State Grid Tianjin Electric Power Company, Tianjin 300010, China; 3. Chengdong Power Supply Branch of State Grid Tianjin Electric Power Company, Tianjin 300250, China)

Abstract: Through the analysis of the characteristics of charging stage and the capacity of lead-acid battery, the state of health (SOH) estimation method based on relevance vector machine (RVM) was proposed. The mixture kernels function was adopted so as to enhance the generalization of the RVM model. The variable probability genetic algorithm (VPGA) was used to optimize the relevant parameters of the kernels function, and then, the RVM regression model was established. The experiment results verify that the proposed method can realize accurate estimation and online monitoring of the SOH of the lead-acid battery.

Key words: lead-acid battery; state of health (SOH); relevance vector machine (RVM); online estimate

铅酸电池储能系统在电动汽车工业具有广泛的用途。它价格低廉、比功率大、技术相对成熟,目前仍广泛应用于供电系统的不间断电源和大型光伏电站中,是供电持续性和稳定性的重要保障。

储能用铅酸电池的日常维护一般是人工检查和修理,电源中的蓄电池长期使用不当,如过充电、过放电、长时间搁置等因素,会使电池的寿命大大缩短,同时,劣化的电池也会严重影响整个储能系统的效率和可靠性,可能导致安全事故的发生。为了延长电池组的循环使用寿命,提高安全性,电池管理系统(battery management sys-

tem, BMS)应运而生,它负责系统监控电池的状态,合理安排电池的使用,进而延长电池的寿命,优化系统的运行。许多因素需要纳入BMS的运维中。电池健康状态(state of health, SOH)可以反应电池的老化程度,是BMS重点考察和规划的对象。通常电池在出厂时SOH被认为是100%,随着充放电循环次数以及损耗的增加,SOH逐渐降低。SOH指标可以用电池当前状态的最大容量与电池标称容量的比值来确定:

$$SOH(\%) = \frac{Q_m}{Q_{nom}} \times 100\% \quad (1)$$

式中: Q_m 为当前状态电池的最大容量; Q_{nom} 为电

基金项目:国网天津市电力公司科技项目(KJ19-1-14)

作者简介:丁一(1990—),男,硕士,高级工程师,Email:dy_cqu@163.com

池的标称容量,即SOH值为100%时的容量。

相比于目前对铅酸电池荷电状态(state of charge, SOC)的估计研究,对其SOH估计的研究成果较少。文献[1]基于二阶等效电路模型,采用卡尔曼滤波算法来估计电池的SOH值。文献[2]采用支持向量机(support vector machine, SVM),对微分容量曲线特征进行了提取,产生了基于峰值的SOH估计方法。文献[3]考察了电池的电化学机理,推导出容量损失随循环次数变化的递推关系,建立了容量衰减模型。文献[4]考察了变电站中使用的铅酸电池,发现其电压变化率和内阻与SOH之间具有显著关系,据此提出健康状态的方案。文献[5]基于铅酸电池的Randles模型,用卡尔曼滤波的方法进行模型参数辨识,并离线估计其SOH值。

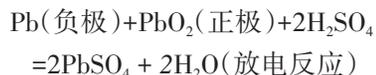
本文采用相关向量机(relevance vector machine, RVM)对铅酸蓄电池的SOH进行在线估计和监测。首先提取充电阶段放电特征,然后由灰色关联度结果建立RVM回归模型,进而可以对新数据点进行预测,最终实现对电池健康状态的在线监测。

1 充电阶段特征分析

1.1 铅酸电池工作原理

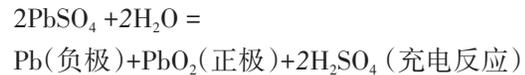
铅酸电池属于二次电池,具有可逆的正负极化学反应。二氧化铅、海绵铅和稀硫酸分别是其正负极材料和电解溶液,充放电反应遵循“双硫酸盐化理论”,既正负极都会产生 PbSO_4 。

放电时,二氧化铅和海绵铅以及电解液反应生成硫酸铅和水。方程式为



放电初,正负极活性物质上的 H_2SO_4 浓度首先被消耗,浓度下降较快,而电解液中的硫酸不能及时向电极表面扩散以补偿反应消耗,导致正负极物质表面的 H_2SO_4 浓度降低。电极表面的硫酸浓度是电压的重要影响因素,故电池端电压下降迅速。电解液中的硫酸逐渐扩散到电极表面以补偿反应消耗,放慢了电压的下降速度。放电一段时间后,生成物硫酸铅扩散至活性物质里面,降低其孔隙率,造成硫酸越来越难以进入活性物质内。且电解液中的硫酸铅不易导电,造成其电阻增加,电池输出的能量降低。

充电时化学反应如下:



充电初,附着在活性物质上的硫酸由于生成物中的硫酸而得到快速补充,电池端电压迅速恢复,当活性物质内外的硫酸浓度达到饱和状态时,端电压的增长放缓。随着正负极极化反应加剧,正负极的电势差加大,正负极分别有氧气和氢气析出,抬高了充电输出电压。

铅酸电池放电阶段具有不确定性和随机性,而充电阶段的特征较为分明,故本文提取该阶段的典型特征来分析和建模。电池充电方式主要有恒压、恒流和阶段充电^[6]。恒压充电是整个充电过程都对电池施加恒压,刚开始充电电流较大,容易对电池造成冲击;恒流充电则是在充电过程中对电池施加恒定电流,适用于电池串联较多的场合,容易造成较多气体溢出,充电效率不高。而阶段充电法将两者结合。一般采取先恒流再恒压的方式,这种充电方式较为“温和”,可以减弱对电池的冲击,并保证较高的充电效率。

1.2 充电阶段特性分析

实验所用电池与文献[7]中的电池同型号,常温下的电池基本参数如下:额定容量 $200\text{ A}\cdot\text{h}$,循环充电电压 $(14.70\pm 0.18)\text{ V}$,最大充电电流 50 A 。

电池容量衰减实验的实验步骤如下:1) 20 A 恒流充电;2)当端电压达到 14.4 V 时,转为恒压充电,当充电电流降到 2.4 A 时,充电过程结束;3) 40 A 恒流放电,放电过程用传感器记录放电电流和时间数据,用安时计量法计算实际容量;4)端电压达到截止电压 1.6 V 时,一个充放电循环结束;5)重复步骤1)~步骤4)55次。电池容量退化趋势如图1所示。

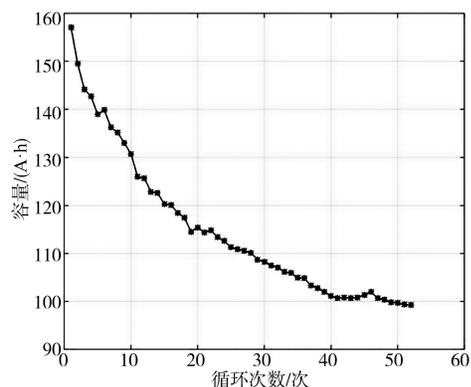


图1 电池容量退化趋势

Fig.1 The degeneration trend of battery capacity

图2为两阶段充电的电压电流变化曲线,恒

流过程开始时,电压迅速增大,当电压达到14.5 V左右时,转为恒压阶段,此后电流衰减,降至2.4 A,然后进行涓流充电以保护电池,此时充电过程基本结束。

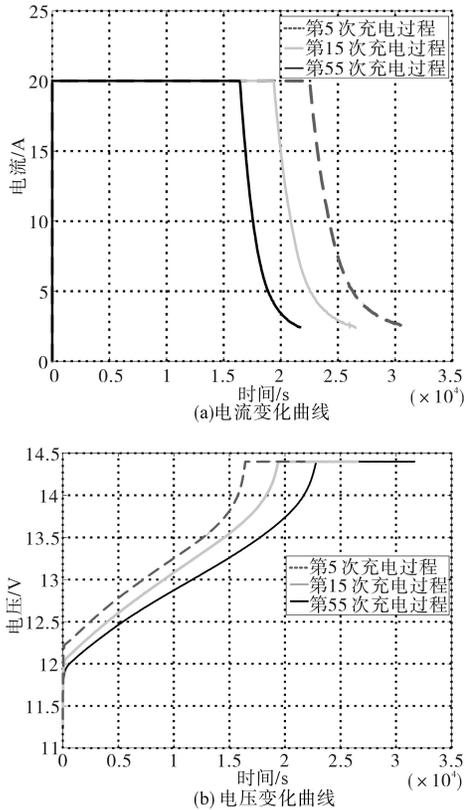


图2 阶段充电的电压电流变化曲线
Fig.2 The curves of current and voltage for stage charging

实验分别记录了单个电池第5次、第15次以及第55次充电循环的充电过程。值得注意的是,随着实验循环次数的增大,由于电池的容量的不断衰减,两阶段的放电时间逐渐减小。

由图2知,各阶段的充电时间都随着电池容量的损失而变短,表现出良好相关性。分别考察每次循环后的充放电时间同容量和循环次数的变化趋势,得到图3。

由图3易知,恒压、恒流充电阶段时间和充电总时间随容量衰减而变化显著。将恒流充电时间与恒压充电时间的比值作为第4个充电特征。恒流恒压两阶段充电时间和总时间分别为 T_1 、 T_2 和 T 。下面定量刻画 T_1 、 T_2 、 T 、 T_1/T_2 对容量衰减变化的敏感程度,即灰色关联度。

将蓄电池容量序列为回归模型输出, T_1 、 T_2 、 T_3 、 T_1/T_2 序列: $\{x_i(k)\}, i = 1, 2, 3, 4$ 为回归输入,用下式计算各比较序列同参考序列间的关联性:

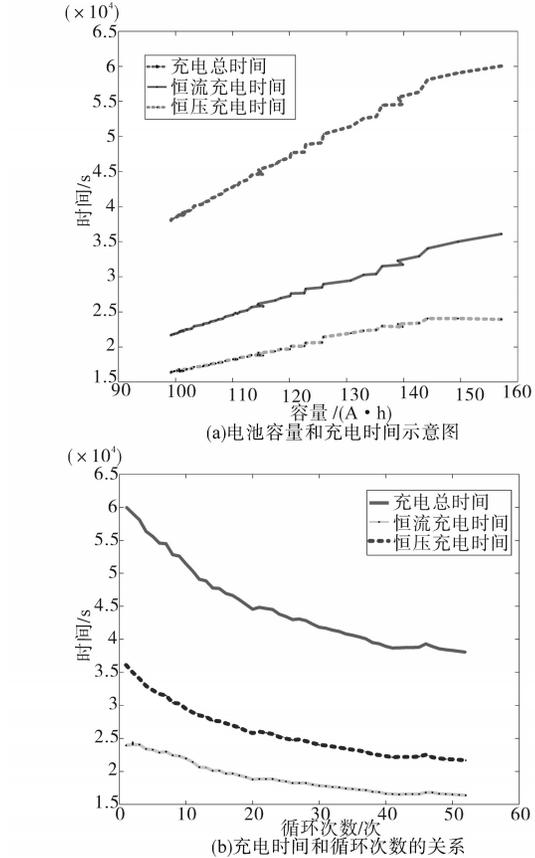


图3 充电时间的变化趋势
Fig.3 The changing trend of charging time

$$\xi_i(k) = \frac{\min_{V_i} \min_{V_k} |x_0(k) - x_i(k)| + \rho \max_{V_i} \max_{V_k} |x_0(k) - x_i(k)|}{|x_0(k) - x_i(k)| + \rho \max_{V_i} \max_{V_k} |x_0(k) - x_i(k)|} \quad (2)$$

结果如表1所示,通过对比发现, T_2 的作用最为显著,因此本文用 T_2 时间序列和铅酸电池的容量序列来建立RVM模型,用于SOH估计。

表1 灰色关联度分析结果

充电特征	T	T_1	T_2	T_1/T_2
关联度	0.790 1	0.696 9	0.871 7	0.821 5

2 RVM模型的建立

前文已经对铅酸电池充电特征进行灰色关联度分析,并提取出恒压充电时间作为健康特征进行分析。本节基于健康特征和容量数据关系建立相关向量机^[8]回归模型,实现对SOH的在线估计。

相关向量机(RVM)是一种基于贝叶斯框架的新颖的监督学习方法,与支持向量机(SVM)^[9]相比,在RVM计算中,只考察非零权重构成的向量既相关向量,因而减小了计算负担,且核函数

的选取更为自由。由于它具有许多SVM的优良特征,同时又避免了SVM主要的局限性,在回归分析中占有重要的位置。

针对一个数据集 $\{x_i, t_i\}_{i=1}^N$, 其中 N 为待训练样本的个数, x_i 为模型输入值, t_i 为模型输出值, 不同 i 的数据间相互独立, 其映射关系如下:

$$t_i = y(x_i, \mathbf{w}) + \epsilon_i \quad (3)$$

其中 $\mathbf{w} = (w_1, w_2, \dots, w_N)^T$ $\epsilon_i \sim N(0, \sigma^2)$

式中: \mathbf{w} 为权重向量。

RVM模型输出为

$$y(\mathbf{x}, \mathbf{w}) = \sum_{i=1}^N w_i K(\mathbf{x}, \mathbf{x}_i) + w_0$$

式中: $K(\mathbf{x}, \mathbf{x}_i)$ 称为核函数^[10]; w_0 为权重偏值。

在RVM中,核函数是沟通低维变量间的非线性关系和相应高维变量的简洁映射的桥梁,核函数的选取是RVM建模的关键一环。高斯核函数和多项式核函数在RVM建模中较为常见,它们的性质如表2所示。

表2 两种核函数的性质比较

Tab.2 Comparisons of two kernel functions

核函数	优点	缺点
Gaussian	局部性好,能够适应于复杂的非线性逼近	全局能力弱,在全空间(远离样本点)拟合性能差
polynomial	全局能力强,在全空间的拟合性能好	局部性差,对于局部复杂的映射的适应能力差

两种核函数的表达式分别如下所示:

$$K_{\text{Gaussian}}(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|/r^2) \quad (4)$$

$$K_{\text{polynomial}}(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i \cdot \mathbf{x}_j^T + 1)^2 \quad (5)$$

式中: r 为 Gaussian 核宽度。

鉴于两类核函数具有互补的优势和特点,引入权值 w ($0 \leq w \leq 1$) 将它们组合成混合核函数,将高斯核函数的局部优势和多项式核函数的全局能力相结合,使模型具有更强的泛化能力。混合核函数的表达式如下:

$$K = wK_{\text{polynomial}} + (1 - w)K_{\text{Gaussian}} \quad (6)$$

选好核函数后,通过拟合输入数据和输出数据的非线性映射关系来训练核函数参数,建立RVM回归模型。当有新数据输入时,可以据此计算目标输出值的均值和方差,既预测目标输出。RVM回归过程的详细数学推导参见文献[6]。

3 模型参数优化

核函数的带宽参数 r 和权重系数 w 显著影响RVM的效果,直接决定了分类和回归的准确性。

为了提高RVM的回归能力,获得更好的估计结果,需要优化 r 和 w 以减小训练误差,本文采用一种变概率遗传算法(variable probability genetic algorithm, VPGA)对多核函数的参数进行优化。

遗传算法(genetic algorithm, GA)^[11] 是基于进化论的思想而产生的一种随机群优化算法,具有较好的全局搜索性能和局部调节能力,而且不要求提供目标函数的导数信息,适应于目标函数复杂、离散或难解析的情形。适应度函数选取RVM模型训练结果的平均相对误差,如下式所示:

$$fitness = \sum_{k=1}^N \frac{|\hat{x}(k) - x(k)|}{x(k)} \quad (7)$$

式中: $\hat{x}(k)$ 为第 k 个 SOH 估计值; $x(k)$ 为第 k 个 SOH 的真实值; N 为估计结果的个数。

在种群进化的过程中,交叉和变异操作决定了进化的方向,影响更优个体的产生。分别由交叉、变异概率 P_c, P_m 来控制,前者通过交换个体间染色体的一段编码来获取较优个体,保证算法的全局性,后者通过改变个体某一位的基因序列来获取新个体,进行局部微调。在进化前期,种群较分散,增加 P_c 同时减小 P_m , 能够扩大全局搜索的范围,同时避免由于随机变异而错失优秀个体;在进化后期,种群较集中,交叉操作的重复性增强,此时减小 P_c 同时增大 P_m , 有助于产生新个体以跳出局部最优解。传统GA一般设 P_c, P_m 为常数或线性自适应调整^[12]。常数不能满足上述变化的要求,线性调整无法及时响应种群多样性的变化速度。鉴于此,本文设计了下2式来自适应地计算交叉、变异概率:

$$P_c = \begin{cases} k_1 e^{\frac{f_{av} - f_{min}}{f_{max} - f_{min}} - 1} & \frac{f_{av} - f_{min}}{f_{max} - f_{min}} \leq 0.5 \\ k_1 (1 - e^{\frac{f_{av} - f_{min}}{f_{max} - f_{min}} - 1}) & \frac{f_{av} - f_{min}}{f_{max} - f_{min}} > 0.5 \end{cases} \quad (8)$$

$$P_m = \begin{cases} k_2 (1 - e^{\frac{f_{av} - f_{min}}{f_{max} - f_{min}} - 1}) & \frac{f_{av} - f_{min}}{f_{max} - f_{min}} \leq 0.5 \\ k_2 e^{\frac{f_{av} - f_{min}}{f_{max} - f_{min}} - 1} & \frac{f_{av} - f_{min}}{f_{max} - f_{min}} > 0.5 \end{cases} \quad (9)$$

其中 $k_1, k_2 \in (0, 1)$

式中: f_{av} 为所有个体的平均适应度; f_{max}, f_{min} 分别为最差个体和最优个体; k_1, k_2 为调节因子。

适应度的变化曲线选取指数形式可以满足快速响应的需要,即当 $(f_{av} - f_{min}) / (f_{max} - f_{min})$ 变化

时, $\exp[(f_{av} - f_{min}) / (f_{max} - f_{min})]$ 能够更快地变化。此外,选取每一代的最优个体,不参与下一代的交叉和变异操作,这是为了防止该个体被不当操作而破坏。然后将其复制 k 次,来替换下一代种群中表现最差的 k 个个体, k 值由下式确定:

$$k = \left[\frac{N}{3} \cdot \frac{f_{av} - f_{min}}{f_{max} - f_{min}} \right] \quad (10)$$

式中: $[\cdot]$ 为取整函数。

当种群较分散时, k 较大,快速淘汰不良个体;当种群趋于一致时,采取较小的 k ,避免陷入局部最优。采取这种策略可以更好体现“优胜劣汰”的进化规则。

VPGA 的流程图如图 4 所示。

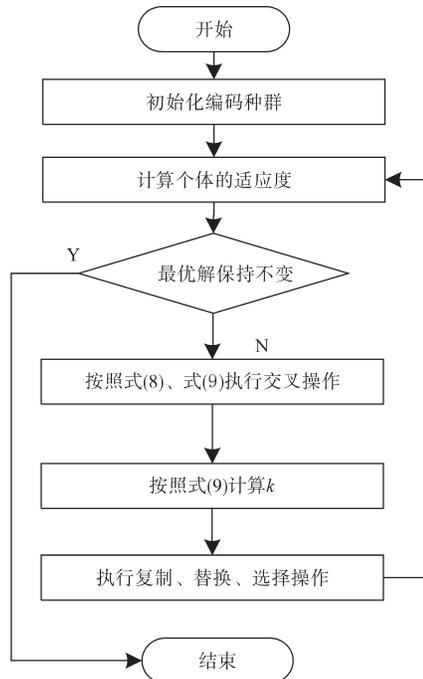


图4 VPGA算法流程图

Fig.4 The flow chart of VPGA

采用 VPGA 算法对 RVM 的混合核函数的参数进行优化,优化过程中适应度值的变化如图 5 所示。

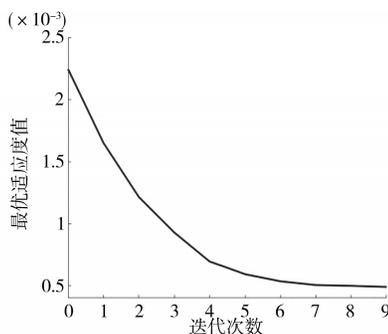


图5 适应度下降曲线

Fig.5 The decline curve of the fitness

在迭代过程中,适应度快速下降,在迭代 8 次左右以后,适应度的值稳定在一个极小的值附近,即核函数的参数收敛到最优取值附近。

最优参数值为: $r = 143.27, w = 0.87$, 此时平均相对误差 fitness 的最优值为 0.000 488。

4 在线 SOH 估计方法验证

为了验证所提出的 SOH 估计方法的有效性,本文使用恒压充电时间序列作为 RVM 的模型输入,容量序列作为输出,训练 RVM 模型,训练回归效果和拟合误差分别如图 6、图 7 所示。最大误差小于 0.4%。

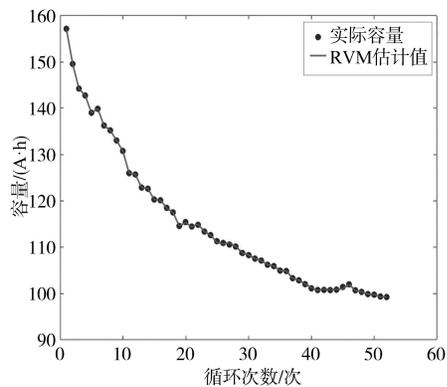


图6 模型回归曲线

Fig.6 The regression curve of the model

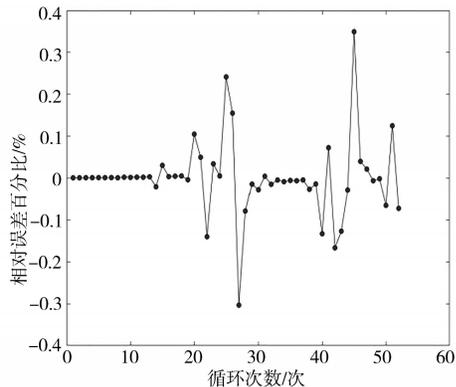


图7 模型回归误差

Fig.7 The regression error of the model

采用 k -重交叉验证法^[13](k -fold cross validation) 来验证回归模型的预测效果,实施过程如下:将充电阶段数据集随机分成 4 组,随机地抽取 3 组数据作为训练集训练模型参数 w 和 r ,用另外的一组数据作为测试集测试估计效果。共进行 4 次循环实验,对数据点进行训练和估计,各组预测及实测误差如图 8 ~ 图 11 所示,具体数值在表 3 中列出。从表 3 可以看出,训练好的 RVM 估计模型在对新数据进行预测时,估计结果仍具有很好的准确性,单个数据点的预测误差在 0.6% 以内。这

说明该模型具有较好的泛化能力和非线性拟合能力,能够实现对铅酸蓄电池健康状态的精准估计。

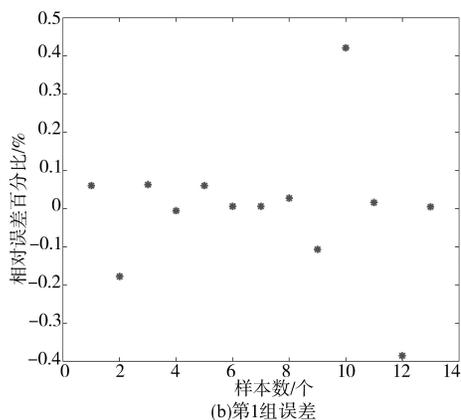
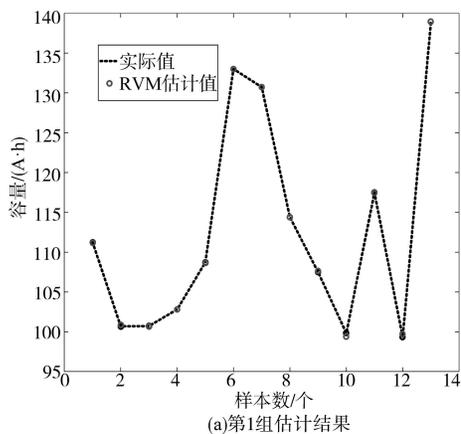


图8 第1组估计结果及误差

Fig.8 Group1 estimation results and errors

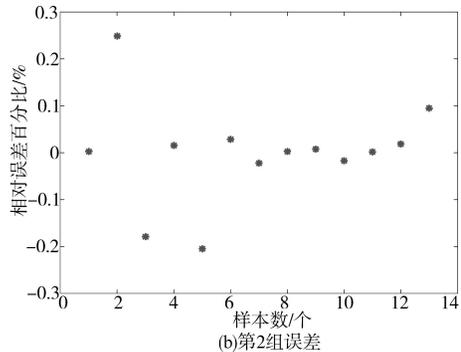
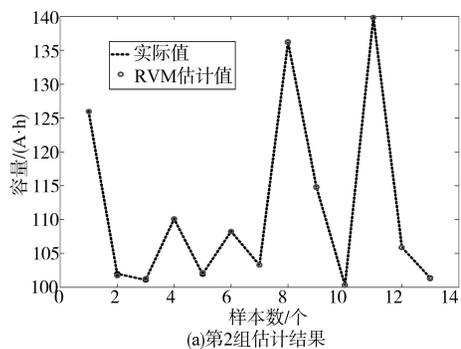


图9 第2组估计结果及误差

Fig.9 Group2 estimation results and errors

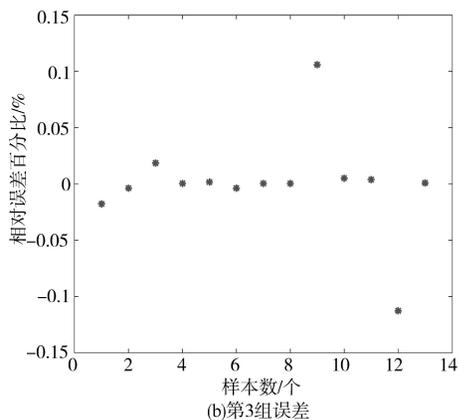
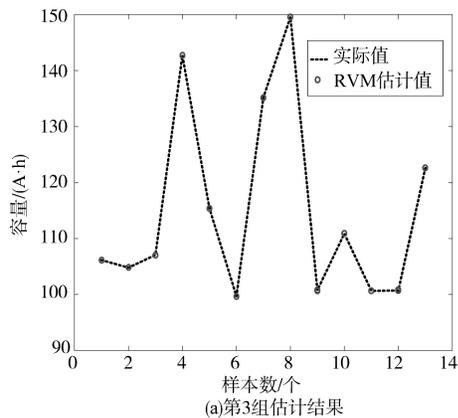


图10 第3组估计结果及误差

Fig.10 Group3 estimation results and errors

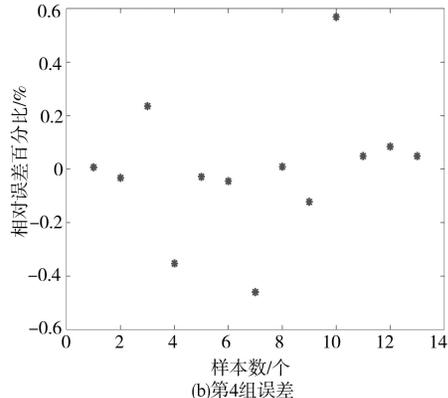
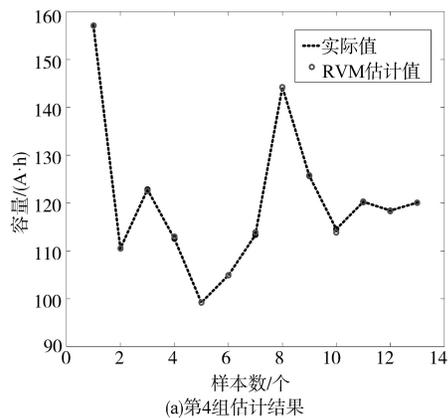


图11 第4组估计结果及误差

Fig.11 Group4 estimation results and errors

表3 电池容量预测偏差

Tab.3 The prediction error of capability of battery

误差	Group1	Group2	Group3	Group4
MAE	0.009 3	0.006 1	0.004 3	0.008 7
RMSE	3.382 0	1.147 3	0.869 6	1.922 7

实时性和快速性是在线估计的重要特征,下面考察本算法的运行时间。4次仿真实验的计算时间如表4所示。

表4 RVM 运算时间

Tab.4 The calculation time of RVM model

组别	训练时间/s	预测时间/s	总时间/s
Group1	2.42	0.31	2.73
Group2	1.68	0.35	2.03
Group3	2.12	0.26	2.38
Group4	2.63	0.22	2.85

由图6可知,遗传算法进行到10代左右就能可靠地收敛到较优水平,故模型的训练不需要太长时间。基于VPGA优化的RVM模型用于SOH估计的总时间在3s以内,计算速度较快,能够满足在线估计的需要。

5 结论

针对在铅酸蓄电池容量老化过程中,其SOH不易高效和精准测算的问题,本文提出了一种基于RVM回归模型的铅酸蓄电池在线健康状态估计方法。通过对电池容量衰退现象的观察,并结合灰色关联度计算,提取了蓄电池充电阶段时间的健康特征,选取关联度最高的电池恒压充电时间来反映电池容量的退化趋势。用VPGA对混合核函数的权重系数和带宽参数进行训练和优化,建立了基于相关向量机的容量退化模型。实验结果表明该模型可以有效建立起SOH值和充电阶段恒压充电时间的关系,实现了对铅酸蓄电池健康状态的精确快速在线估计。本文可

为今后电池管理系统的研究提供依据,有较大的参考价值。

参考文献

- [1] 程泽,杨磊,孙幸勉. 基于自适应平方无迹卡尔曼滤波算法的锂离子电池SOC和SOH估计[J]. 中国电机工程学报, 2018,38(8):2384-2393.
- [2] Weng C, Feng X, Sun J, et al. State of health monitoring of lithium-ion battery modules and packs via incremental capacity peak tracking[J]. Applied Energy, 2016, 180:360-368.
- [3] You G W, Park S, Oh D. Real-time state-of-health estimation for electric vehicle batteries: a data-driven approach[J]. Applied Energy, 2016, 176(1):92-103.
- [4] 钟国彬,刘新天,何耀,等. 变电站用铅酸蓄电池SOH估计[J]. 电源技术, 2016,40(12):2407-2410.
- [5] 王跃飞,黄磊,舒成才,等. 车载铅酸蓄电池SOC和SOH的在线估算[J]. 农业装备与车辆工程, 2017,55(10):19-24.
- [6] 洗丽红. 浅谈EPS应急电源装置的技术改造与引用[J]. 电气应用, 2016,12(7):41-45.
- [7] 谷明,孙绍国,周航. EPS电源在线健康状态估计[J]. 建筑电气, 2019,38(9):30-34.
- [8] 王春雷,赵琦,秦孝丽,等. 基于改进相关向量机的锂电池寿命预测方法[J]. 北京航空航天大学学报, 2018,44(9):1998-2003.
- [9] 安亚利,周水生,陈丽,等. 鲁棒支持向量机及其稀疏算法[J]. 西安电子科技大学学报, 2019,46(1):64-72.
- [10] 尹嘉鹏. 支持向量机核函数及其关键参数研究[D]. 哈尔滨: 哈尔滨工业大学, 2016.
- [11] 席裕庚,柴天佑,恽为民. 遗传算法综述[J]. 控制理论与应用, 1996,15(6):697-708.
- [12] Srinivas M, Patnaik L M. Adaptive probabilities of crossover and mutation in genetic algorithm[J]. IEEE Trans. on Systems, Man, and Cybernetics, 1994,24(4):656-667.
- [13] 王振武,何关瑶. 核函数的选择方法研究[J]. 湖南大学学报(自然科学版), 2018,45(10):155-160.

收稿日期:2020-05-11

修改稿日期:2020-06-16