

基于改进 BPNN-MPF 算法的 锂离子电池 SoE 估计

马彦^{1,2}, 郭则宣¹

(1. 吉林大学通信工程学院, 长春 130012; 2. 吉林大学汽车仿真与控制国家重点实验室, 长春 130022)

摘要: 为了提高锂离子电池能量状态 (SoE) 估计的准确性, 考虑到电流或电压传感器噪声会累积误差, 提出了一种基于改进反向传播神经网络 (BPNN) 与模型预测滤波 (MPF) 相结合的 SoE 估计方法。基于一阶 RC 等效电路模型, 采用 MPF 算法估计电池的 SoE, 并使用改进 BPNN 对 MPF 算法的估计结果进行误差补偿。在 NEDC 工况下验证了本文方法的准确性。结果表明, 与传统 MPF 算法和 BPNN-MPF 算法相比, 本文方法的 SoE 估计值能较好地收敛到真实值, 且最大绝对误差和均方根误差均在 1% 以内。

关键词: 控制理论与控制工程; 锂离子电池; 能量状态估计; 改进 BP 神经网络; 模型预测滤波

中图分类号: U463.63 **文献标志码:** A **文章编号:** 1671-5497(2023)01-0263-10

DOI: 10.13229/j.cnki.jdxbgxb20210556

SoE estimation of lithium-ion batteries based on improved BPNN-MPF algorithm

MA Yan^{1,2}, GUO Ze-xuan¹

(1. College of Communication Engineering, Jilin University, Changchun 130012, China; 2. State Key Laboratory of Automotive Simulation and Control, Jilin University, Changchun 130022, China)

Abstract: The State of Energy (SoE) of lithium-ion battery is an important evaluation index for the energy optimization and management of electric vehicles. In order to improve the accuracy and reliability of battery SoE estimation, a SoE estimation method based on the combination of improved Back Propagation Neural Network (BPNN) and Model Predictive Filtering (MPF) was proposed in this paper. Considering the accumulated errors of current or voltage sensor noise, a first-order RC equivalent circuit model was established in this paper. Based on this model, the MPF algorithm was used to estimate the battery SoE. In order to make the estimated results more accurate, the improved BPNN was used to compensate the errors of the estimated results of MPF algorithm. Finally, the accuracy of the proposed method was verified under New European Driving Conditions (NEDC). The results show that the SoE estimate based on the improved BPNN-MPF algorithm well converges to the real SoE value, compared with traditional MPF algorithm and BPNN-MPF algorithm. The Maximum Absolute Error (MAE) and Root-Mean-Square Error (RMSE) of the estimated values are all within 1%.

收稿日期: 2021-04-28.

基金项目: 国家自然科学基金项目 (61520106008, U1864201); 吉林省高校共建项目 (SXGJSF2017-2-1-1).

作者简介: 马彦 (1970-), 女, 教授, 博士. 研究方向: 自动控制算法设计. E-mail: mayan_maria@163.com

Key words: control theory and control engineering; lithium-ion batteries; state of energy; improved bp neural network; model predictive filtering

0 引言

在能源危机问题亟需解决的大环境下,电动汽车逐渐进入人们的视野。锂离子电池由于比能量大、循环寿命长、自放电率小等特点,被选为电动汽车最主要的动力源^[1]。为了保证电动汽车行驶安全且能持续运行,驾驶员需要准确把握电动汽车电池的能量状态(State of energy, SoE)。准确的 SoE 估计可以提高电池剩余能量预测的可靠性,由于剩余能量与电动汽车续航里程存在对应关系,准确的 SoE 可以预测电动汽车的续航里程^[2]。此外,准确得知 SoE 值是实现整车能量最优化的基础,从而增大电动汽车的续航里程,提高电池能量利用效率,对提高电动汽车的经济性具有重要意义。

传统上,常将 SoE 估计建立在荷电状态(State of charge, SoC)估计的基础上,可以通过 SoC 值及两者间的映射关系得到 SoE 值,但 SoC 体现的是电池的容量状态,而不是电池应用条件所依赖的能量状态,且在短时间的估计中,SoC 随工作电流线性变化,而电池的能量是容量和端电压的乘积。此外,SoC 估计中没有考虑内阻能量损失、电化学反应和开路电压降低的影响,且车辆根据道路状况的改变也会产生一定差异的能量损耗,因此由映射关系间接得到的 SoE 估计值并不准确^[3]。

在 SoE 估计方法中,安时积分法是最常见的一种,它简单且成本低,但估计精度容易受到噪声、初始 SoE 值不确定和电流漂移等因素的影响。功率积分法也是一种被大量使用的方法,可以直接测量电池的可使用能量^[5],但该方法容易受到测量噪声和电流漂移的影响。随着研究者们对 SoE 估计越来越关注,出现的估计方法也逐渐丰富。例如,Liu 等^[4]提出了一种在动态电流和温度条件下基于改进反向传播神经网络(Back propagation neural network, BPNN)的直接 SoE 估计方法,但该方法属于开环估计,由于电池参数测量值不正确,估计精度较差。He 等^[5]提出了一种新的高斯模型反映电池行为,并采用中心差分卡尔曼滤波进行 SoE 实时预测。Wang 等^[6]使用粒子

滤波(Particle filtering, PF)联合估计电池的 SoC 和 SoE,并在恒流和动态电流条件下验证了结果,然而,该方法的 SoE 估计精度由 SoC 估计精度决定。由此可见,SoE 估计的研究方法虽然多样,估计精度却有待提高。

因此,本文提出一种将改进 BP 神经网络与模型预测滤波相结合的电池 SoE 估计方法。首先,建立一阶 RC 模型并进行参数辨识,采用模型预测滤波算法估计 SoE;然后,利用训练完成的改进 BP 神经网络对 MPF 算法得到的 SoE 估计值进行优化;最后,验证了本文方法的准确性并进行结果分析。

1 电池模型

1.1 集中参数电池模型

SoE 提供了锂离子电池剩余可用能量的信息,是电池系统能量优化和管理的关键指标^[7],其定义为电池剩余能量与总可用能量的比值,是关于电池负载电流和端电压的函数,可表示为:

$$\text{SoE}(t) = \text{SoE}(t_0) + \frac{\int_{t_0}^t \eta_k \cdot P(\tau) d\tau}{E_N} \quad (1)$$

式中: E_N 为电池的最大可用能量; η_k 为电池充放电效率; $P(\tau)$ 为电池的功率; t 为当前工作时间; t_0 为初始采样时间。

根据式(1),对其进行离散化可得:

$$z_{k+1} = z_k - \frac{\eta_k \Delta E_k}{E_N} = z_k - \frac{\eta_k I_{L,k} U_{t,k} \Delta t}{E_N} \quad (2)$$

式中: z 为电池的 SoE; z_{k+1} 和 z_k 分别为 $k+1$ 和 k 采样时刻的 SoE; ΔE_k 为 k 时刻消耗的能量; $I_{L,k}$ 为 k 时刻电池的负载电流(假设充电为正,放电为负); $U_{t,k}$ 为 k 时刻电池的端电压; Δt 为采样间隔。

准确模拟电池动态特性的电池模型是进行动态电池状态估计的关键^[8]。因此,研究者们提出了许多电池模型,其中最常用的是等效电路模型。为在模型精度和计算复杂度之间取得平衡,本文采用一阶 RC 模型,如图 1 所示。

一阶 RC 模型的电学行为可表示为:

$$\begin{cases} \dot{U}_D = -\frac{1}{R_D C_D} U_D + \frac{1}{C_D} I_L \\ U_t = U_{oc} - U_D - I_L R_o \end{cases} \quad (3)$$




图 1 一阶 RC 电路模型原理图

Fig. 1 Schematic diagram of first order RC circuit

式中: U_{oc} 为开路电压(可以表示为关于 SoE 的函数); R_o 为欧姆内阻; R_D 和 C_D 分别为极化电阻和极化电容; U_D 为 RC 环节的极化电压; I_L 为负载电流; U_t 为端电压。

令 $\tau = R_D C_D$, 通过线性微分方程的通解, 可得:

$$U_D = C_1 e^{-\frac{t}{\tau}} - e^{-\frac{t}{\tau}} \int \frac{I_L}{C_D} e^{-\frac{1}{\tau} dt} dt \quad (4)$$

式中: C_1 为方程中的常数项。

假设 $U_{D,k+1}|_{\Delta t=0} = U_{D,k}$, 式(4)可简化为:

$$U_{D,k+1} = -U_{D,k} e^{-\frac{\Delta t}{\tau}} + (1 - e^{-\frac{\Delta t}{\tau}}) R_D I_{L,k} \quad (5)$$

式中: $U_{D,k+1}$ 和 $U_{D,k}$ 分别表示为 t_{k+1} 和 t_k 时刻的极化电压。

最后, 可以得到集中参数电池模型的离散化关系式为:

$$\begin{cases} U_{D,k+1} = -e^{-\frac{\Delta t}{\tau}} U_{D,k} + (1 - e^{-\frac{\Delta t}{\tau}}) R_D I_{L,k} \\ U_{t,k+1} = U_{oc,k+1} + U_{D,k+1} + R_o I_{L,k+1} \end{cases} \quad (6)$$

1.2 模型参数辨识

为准确获得电池 U_{oc} 与 SoE 的对应关系, 本文采用长时间静置标定法。实验采用 18650 型磷酸铁锂电池, 额定电压为 3.7 V, 充放电截止电压分别为 4.2 V 和 2.75 V, 额定容量为 2.1 Ah, 实验在室温 22.5 °C (± 2.5 °C) 的环境下进行。实验步骤为:

- (1) 将激活后的电池静置 1 h;
- (2) 对电池进行恒流 1 C/3 (700 mA) 充电, 当电池 SoC 达到 0.9 时, 换成恒压充电, 当充电电流小于 1 C/100 (21 mA) 时, 停止充电, 电池 SoC 达到 1;
- (3) 将电池静置 1 h;
- (4) 对电池进行恒流 1 C/3 (700 mA) 放电, 当电池 SoC 达到 0.1 时, 停止放电;
- (5) 将电池静置 0.5 h;
- (6) 对电池进行恒流 1 C/100 (21 mA) 放电, 当电池 SoC 达到 0 时, 停止放电, 电池放出的容量

为电池室温下的放电容量。

(7) 重复上述步骤 5 次, 取平均值。

由于电池的 U_{oc} 可以表示为关于 SoC 的函数, 可以先得到 SoC 与开路电压的关系, 计算充入和放出的能量, 然后进行 SoE 与开路电压的关系标定, 开路电压与 SoC 及 SoE 的关系曲线如图 2 所示。采用多项式拟合将开路电压与 SoE 拟合成函数关系, 拟合曲线如图 3 所示。拟合多项式为:

$$U_{oc} = 2.738 + 11.91 \cdot \text{SoE} - 63.02 \cdot \text{SoE}^2 + 163.1 \cdot \text{SoE}^3 - 217.3 \cdot \text{SoE}^4 + 145.1 \cdot \text{SoE}^5 - 38.39 \cdot \text{SoE}^6 \quad (7)$$




图 2 开路电压与 SoC 及 SoE 的关系曲线

Fig. 2 Relation curves of open circuit voltage with SoC and SoE




图 3 开路电压与 SoE 的拟合曲线

Fig. 3 Fitting curve of open circuit voltage with SoE

本文选用对端电压进行指数拟合的方式辨识模型中的欧姆内阻、极化电阻和极化电容。首先, 分析电池输出方程以确定指数拟合函数的形式。在一阶 RC 模型中, 输入为电流, 则输出端电压为:

$$U_t = U_{oc} + R_o I_L + R_D I_L (1 - e^{-t/\tau}) \quad (8)$$

对式(8)进行拟合, 指数拟合函数为:

$$\hat{U}_t = k_0 + k_1 e^{-\lambda_1 t} \quad (9)$$

式中: k_0 、 k_1 为常数; λ_1 是时间常数, 均为待拟合变

量; \hat{U}_i 为拟合函数式中的输出值。

图 4 为用于参数辨识的电流电压曲线,对静置后电压恢复阶段的端电压进行拟合,得到结果如图 5 所示。由图可知,拟合曲线能够很好地跟踪测量曲线的变化,表明辨识得到的参数可以反映电池的实际特性。

通过指数拟合,可以得到式(9)中的参数 $k_0 = 3.76299$ 、 $k_1 = -0.06014$ 和 $\lambda_1 = 0.02668$ 。然后根据拟合参数与电阻 R_D 、电容 C_D 之间的关系,得到模型中的极化电阻和极化电容,关系式为:

$$R_D = \frac{k_1}{I_L} \quad (10)$$

$$C_D = \frac{1}{\lambda_1 R_D} \quad (11)$$

$$R_o \approx \frac{\Delta V}{I_L} \quad (12)$$

式中: ΔV 为电流消失瞬间电压的上升值。




图 4 500 mA 放电静置瞬间电流电压曲线

Fig. 4 Instant current and voltage curves of 500 mA discharge standing




图 5 拟合前后端电压对比曲线

Fig. 5 Voltage contrast curve before and after fitting

从图 4 中电压曲线可得 $\Delta V = 0.08019$, 由于 $I_L = 0.5 \text{ A}$, 于是经过计算可得 $R_o = 0.16038 \Omega$, $R_D = 0.12028 \Omega$, $C_D = 311.6167 \text{ F}$ 。

1.3 等效电路模型验证

通过对比模型输出和端电压测量值验证辨识得到的参数值是否准确。用于模型验证的电流曲线如图 6 所示。对电池以 0.5 A 进行恒流放电, 放电 360 s 后静置 120 s, 然后循环一次。

图 7 为模型输出电压曲线与实测电压曲线, 图 8 为误差曲线。

由图 8 可知, 模型验证得到的电压误差均不超过 3 mV。因此, 本文所采用的电池模型可以较准确地描述电池特性。




图 6 用于模型验证的电流曲线

Fig. 6 Current curve for model validation




图 7 模型验证的端电压曲线

Fig. 7 Terminal voltage curves for model validation




图 8 模型验证端电压误差曲线

Fig. 8 Terminal voltage error curve for model validation

2 基于改进 BPNN-MPF 的 SoE 估计

2.1 改进 BPNN 算法

在结构上, BPNN 包含输入层、隐含层和输出层。在内容上, 它包含输入正向传播和误差反向传播。在原理上, 它通过训练结果与预测结果进行误差分析, 从而修正每一层神经元对应的权值和阈值, 使得输出逼近预想的结果。

传统 BPNN 由梯度下降法直接得出的解不能保证是全局最优解, 很可能是局部极值, 导致算法精度下降。且梯度下降法所要优化的目标函数非常复杂, 必然会出现“锯齿形现象”, 算法效率较低。因此, 本文考虑加入动量项, 使其滑过误差表面的最小值^[14]。将动量项引入 BPNN 后, 当误差值逐渐稳定, 较大的动量项可能导致一定权值过度调整, 这可能会导致整个网络跳出收敛区间并进入连续振荡阶段, 从而增加学习时长, 甚至导致不收敛。因此, 需要一个较小的动量项。当误差继续减小时, 说明此权值的变化方向与上一个权值的变化方向相同。为了加速收敛, 需要一个更大的动量项。因此, 为自适应调整动量项系数 mc , 本文通过估计网络输出值的均方误差 MSE 动态调整 mc 的值。

设输入向量为 \mathbf{a} , 输出向量为 \mathbf{b} , 输入层与隐含层之间的权值为 w_{ij} , 隐含层与输出层之间的权值为 w_{jk} 。在 m 个输入样本的作用下, 隐含层中第 i 个神经元的输入为:

$$N_i^m = \sum_{j=1}^M w_{ij} o_j^m - \theta_i = \sum_{j=1}^M w_{ij} x_j^m - \theta_i \quad (13)$$

$$i = 1, 2, \dots, m$$

式中: N_i 为隐含层中第 i 个神经元的输入; w_{ij} 为输入层与隐含层之间的权值; x_j 为第 j 个输入神经元的输出; θ 为阈值。

神经网络的输出为:

$$o_i^m = g(N_i^m) \quad (14)$$

式中: g 为隐含层的激活函数。

输出层第 i 个神经元的输出为:

$$N_k^m = \sum_{i=1}^q w_{ki} o_i^m - \theta_k \quad (15)$$

$$o_k^m = g(N_k^m) \quad (16)$$

在正向传播过程中, 若输出层的输出结果 o_k^m 与本文给出的结果误差相同, 网络从输出层将该输出进行正向反馈, 并在反馈过程中不断修正层

间权值。

输出的成本函数如下:

$$J_m = \frac{1}{2} \sum_{k=1}^L (t_k^m - o_k^m)^2 \quad (17)$$

式中: o_k^m 为网络的估计值; t_k^m 为样本给定的实际值。

传统的 BP 神经网络以梯度下降法为核心, 并沿着代价函数梯度变化的相反方向调整权值, 以减少总体误差。经过多次迭代, 得到了设计误差允许范围内的估计网络。权值更新公式为:

$$w(k+1) = w(k) + \Delta w(k) \quad (18)$$

$$\Delta w(k) = -Lr \cdot \frac{\partial J(k)}{\partial w(k)} \quad (19)$$

式中: Lr 为学习率; $\Delta w(k)$ 为二次误差函数对权值 w 的偏导数。

加入动量项后, 权值调整公式为:

$$w(k+1) = w(k) + mc \cdot \Delta w(k-1) + \Delta w'(k) \quad (20)$$

$$\Delta w'(k) = -Lr \cdot \frac{\partial J(k)}{\partial w(k)} \quad (21)$$

加入动量项后, BP 神经网络增加了 $k-1$ 时刻权值修正方向的影响因子, $k+1$ 时刻校正权值的修正量为 $k-1$ 和 k 时刻的总和。若 $k-1$ 和 k 时刻权值修正向量的方向相同, 则权值修正量将强化加快算法的收敛速度。另一方面, 它会减缓权值的变化速度, 有利于算法的收敛。

为自适应调整动量项系数, 估计网络输出值的均方误差 MSE 定义如下:

$$\text{MSE}(k) = E[(t_k - o_k)^2] \quad (22)$$

式中: t_k 为估计网络的实际输出; o_k 为样本给定的实际输出。

自适应调整动量项的系数定义为:

$$mc(k) = \gamma [1 - e^{-\rho \cdot \text{MSE}(k)}] \quad (23)$$

式中: γ 为控制 $mc(k)$ 大小的常数; ρ 为控制 $mc(k)$ 幅度变化的常数。

综上可知, 引入自适应动量项系数可以避免某一权值的调整速度与学习时长之间的矛盾, 加快了网络训练的收敛。

2.2 改进 BPNN-MPF 算法

本文算法的结构如图 9 所示, 下面具体介绍。

在传统滤波算法中, 通常将系统方程中存在的模型误差当作过程噪声, 并且是协方差已知的零均值高斯白噪声。然而, 这样处理降低了状态估计的准确性, 使滤波性能变差^[9]; 且在实际应用

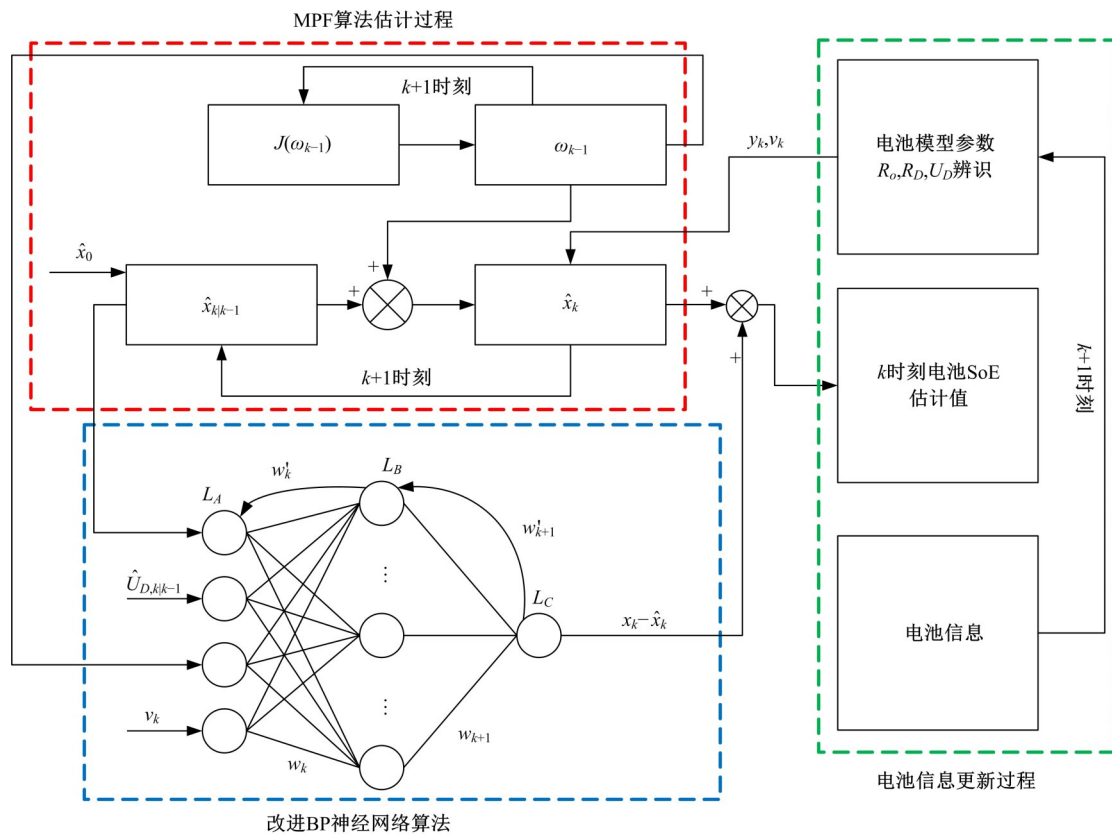


图9 改进BPNN-MPF算法流程图

Fig. 9 Flow chart of improved BPNN-MPF algorithm

中,待解决的通常是非线性系统问题,误差也不是绝对的高斯白噪声,还会受到复杂应用环境和噪声不可预知性的影响,因此传统滤波算法的估计效果不佳。为解决上述问题,Mook等^[10]基于最小模型误差准则,提出了一种实时的非线性滤波算法,即模型预测滤波^[11]。由于电池SoE估计是非线性系统状态估计,且存在显著模型误差,而该算法可以有效解决此问题,因此本文选择模型预测滤波算法估计SoE,并把模型误差中的过程噪声处理成估计变量。

根据一阶RC电路模型原理,系统的离散时间状态方程为:

$$\begin{cases} x_{k+1} = Ax_k + Bu_k + \omega_k \\ y_k = Cx_k + Du_k + v_k \end{cases} \quad (24)$$

式中: $x_k = [\text{SoE}_k \ U_{D,k}]^T$; $u_k = I_{L,k}$; $A = \begin{pmatrix} 1 & 0 \\ 0 & e^{-\frac{\Delta t}{\tau}} \end{pmatrix}$; $C = \begin{pmatrix} \frac{\partial U_{oc,k}}{\partial \text{SoE}_k} & -1 \end{pmatrix}$; $D = -R_o$; ω_k 和 v_k 分别为过程噪声和测量噪声,且测量噪声为零均值高斯白噪声。

根据算法是利用预测输出跟踪测量输出从而得到系统模型误差的原理^[12],定义算法的性能指

标函数为:

$$J(\omega_k) = \frac{1}{2} [\tilde{y}_k - \hat{y}_k]^T R^{-1} \cdot [\tilde{y}_k - \hat{y}_k] + \frac{1}{2} \omega_k^T A \omega_k \quad (25)$$

式中: \tilde{y}_k 为测量值; \hat{y}_k 为估计值; R^{-1} 为测量值与估计值之间的误差加权矩阵; A 为模型误差加权值。

令 $\frac{\partial J}{\partial \omega_k} = 0$, 可得模型误差估计 ω_k 为:

$$\omega_k = - \left\{ \left[\mathbf{A}(\Delta t) \mathbf{U}(\hat{x}_k) \right]^T R^{-1} \left[\mathbf{A}(\Delta t) \mathbf{U}(\hat{x}_k) \right] + \mathbf{A} \right\}^{-1} \cdot \left[\mathbf{A}(\Delta t) \mathbf{U}(\hat{x}_k) \right]^T R^{-1} \left[\mathbf{S}(\hat{x}_k, \Delta t) - \tilde{y}_k + \hat{y} \right] \quad (26)$$

式中: $\mathbf{A}(\Delta t)$ 、 $\mathbf{U}(\hat{x}_k)$ 和 $\mathbf{S}(\hat{x}_k, \Delta t)$ 为中间参数矩阵。

综上所述,模型预测滤波的算法流程^[13]可总结为:①根据式(24)由 t_k 时刻的状态估计值 \hat{x}_k 计算预测输出向量 \hat{y}_k ;②利用式(26)估计 $[t_k, t_{k+1}]$ 时间区间内的模型误差 ω_k ;③由 \hat{x}_k 和 ω_k , 利用式(24)估计 t_{k+1} 时刻的状态量 \hat{x}_{k+1} 。

在MPF算法估计过程中,考虑到噪声和误差的影响,本文提出通过改进BPNN算法对MPF

得到的 SoE 估计值进行补偿,以减小误差,这样对象模型问题就被转化为状态参数估计问题。其中,改进 BPNN 的权值、阈值为输入值,模型预测滤波器的状态值和改进 BPNN 的输出值为观测值^[14]。算法过程如下:

(1)改进BPNN算法的训练过程

首先根据选择的一阶 RC 模型,对容量为 2.1 Ah 的磷酸铁锂 18650 型号电池,进行恒流恒温脉冲放电实验,得到输入参数 $\hat{x}_{k|k-1}$ 和 ω_{k-1} 以及输出参数 $x_k - \hat{x}_k$ 用于训练改进 BPNN。然后训练改进 BPNN,直至误差达到期望值。

(2)改进BPNN优化MPF算法估计结果

如图 9 所示,本文算法原理为将训练完成的改进 BPNN 过程与 MPF 算法相结合。随着电池信息不断更新,通过参数辨识得到准确的模型参数后,采用 MPF 算法对电池 SoE 进行初步估计,将 t_k 时刻的初始估计值 $\hat{x}_{k|k-1}$ 以及由式(26)计算得到的模型误差 ω_{k-1} 输入到训练好的改进 BPNN 中,得到模型预测滤波算法的 SoE 估计误差补偿值 $x_k - \hat{x}_k$,最后得到改进 BPNN 结合 MPF 算法的 SoE 最优估计值。

3 仿真结果及分析

首先对训练完成的改进 BPNN 的误差补偿精度进行验证,结果如图 10 所示。由图 10 可知,改进 BPNN 误差补偿预测值可以较好地跟踪实测值。然后,根据训练完成的改进 BPNN 及图 9 所示的改进 BPNN-MPF 流程图,构建 Matlab 仿真平台对所提方法的效果进行验证。使用安时积分法对常温下的电流等数据进行计算,将得到的值作为 SoE 参考值,其中电流由高精度电流传感器测量得到,将 SoE 初始参考值设置为 0.8,在 NEDC(New-European-Driving-Cycle)工况下,对





图 10 改进 BP 神经网络对比曲线

Fig. 10 Contrast curve of improved BP neural network


初始 SoE 估计值误差为 0 和 0.2 两种情况分别采用改进 BPNN-MPF 算法、BPNN-MPF 算法和 MPF 算法进行 SoE 估计结果的对比。图 11(a)描述了参考端电压和估计端电压。图 11(b)描述了电压估计误差。图 11(c)描述了分别采用改进 BPNN-MPF 算法、BPNN-MPF 算法和 MPF 算法的 SoE 估计结果及参考值。图 11(d)描述了 SoE 估计误差。SoE 估计的统计结果如表 1 所示。从图 11(a)(b)可以看出,估计电压与参考电压基本相符,且由表 1 可得最大电压估计误差仅为 1.7 mV,平均误差和均方根误差分别为 1.4 mV 和 1.4 mV。由图 11(c)可知,使用改进 BPNN-MPF 算法得到的 SoE 估计值与参考值基本相同,使用该算法可以基本跟踪 SoE 的变化。从表 1 可以得知,使用 MPF 算法进行 SoE 估计的最大误差为 0.62%,其平均误差和均方根误差为 0.52% 和 0.52%;使用 BPNN-MPF 算法进行 SoE 估计的最大误差为 0.61%,其平均误差和均方根误差为 0.51% 和 0.51%;而使用改进 BPNN-MPF 算法进行 SoE 估计的最大误差仅为 0.1%,其平均误差和均方根误差也仅有 0.02% 和 0.02%。由此可见,与传统 MPF 算法相比,使用 BPNN-MPF 算法并没有明显改善 SoE 估计精度,而使用本文提出的改进 BPNN-MPF 算法则极大提高了 SoE 的估计精度。

但在实际应用中,由于无法得到准确的 SoE 初始值,因此需要系统地研究在 SoE 初始估计值不准确的情况下算法对 SoE 估计的鲁棒性。


SoE 初始估计值不准确时的端电压估计结果及估计误差、SoE 估计结果及估计误差如图 12 所示,其中初始 SoE 估计值被设置为 0.6。从图 12 可以看出,为了纠正 SoE 估计的错误初始状态,估计的端电压和 SoE 在几秒钟后迅速收敛到参考轨迹,且采用改进 BPNN-MPF 算法的收敛速度更快。这是因为所提出的算法可以准确地估计电压和 SoE,并根据参考值与估计值之间的误差及时进行误差补偿。SoE 初始值不准确时的估计误差统计结果如表 2 所示。在估计收敛到参考值后,端电压的最大估计误差为 2.1 mV,使用 MPF 算法进行 SoE 估计的最大误差为 1.46%,其平均误差和均方根误差为 1.05% 和 1.05%;使用 BPNN-MPF 算法进行 SoE 估计的最大误差为 1.45%,其平均误差和均方根误差为 1.03% 和



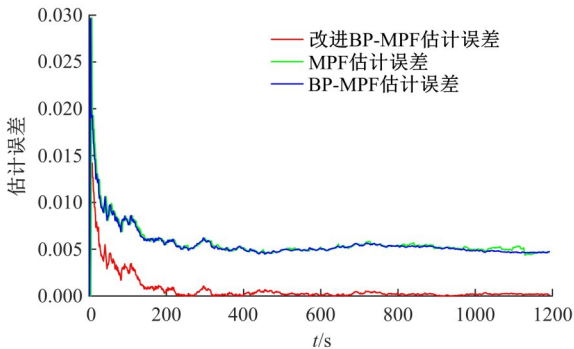
(a)端电压估计结果



(b)端电压估计误差




(c)SoE估计结果




(d)SoE估计误差


图 11 初始 SoE 误差为 0 时端电压和 SoE 估计结果
Fig. 11 Estimation results of terminal voltage and SoE when initial SoE error is 0



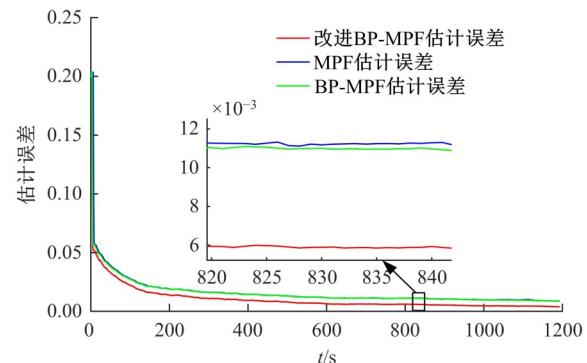
(a)端电压估计结果



(b)端电压估计误差



(c)SoE估计结果



(d)SoE估计误差

图 12 初始 SoE 误差为 0.2 时端电压和 SoE 估计结果
Fig. 12 Estimation results of terminal voltage and SoE when initial SoE error is 0.2

1.04%; 而使用改进 BPNN-MPF 算法进行 SoE 估计的最大误差仅为 0.95%, 其平均误差和均方根误差为 0.53% 和 0.54%。因此, 本文提出的基

于改进 BPNN-MPF 算法的 SoE 估计方法可以有效地跟踪参考 SoE 轨迹, 即使是在 SoE 初始估计值误差较大的情况下。

表 1 初始 SoE 误差为 0 时估计误差统计结果

Table 1 Statistical results of estimation error when initial SoE error is 0

估计对象	最大误差	平均误差(MAE)	均方根误差(RMSE)
电压/mV	1.7	1.4	1.4
SoE(MPF)/%	0.62	0.52	0.52
SoE(BPNN-MPF)/%	0.61	0.51	0.51
SoE(改进 BPNN-MPF)/%	0.1	0.02	0.02

表 2 初始 SoE 误差为 0.2 时估计误差统计结果

Table 2 Statistical results of estimation error when initial SoE error is 0.2

估计对象	最大误差	平均误差(MAE)	均方根误差(RMSE)
电压/mV	2.1	1.5	1.5
SoE(MPF)/%	1.46	1.05	1.05
SoE(BPNN-MPF)/%	1.45	1.03	1.04
SoE(改进 BPNN-MPF)/%	0.95	0.53	0.54

4 结束语

锂离子电池的能量状态是电动汽车储能情况和剩余续驶里程预测的重要指标。由于传感器噪声无法避免, 测量电流或电压时会累积误差, 因此本文提出了一种基于改进 BP 神经网络与模型预测滤波算法相结合的 SoE 估计方法。在模型复杂度与预测精度之间的权衡下, 本文采用了一阶 RC 等效电路模型, 仿真结果表明, 模型的端电压误差在 3 mV 以内, 因此该模型能准确地模拟电池的特性。为实现 SoE 的精确估计, 本文提出了基于模型预测滤波算法的 SoE 估计, 并且采用改进的 BPNN 对初步估计结果进行误差补偿, 提高了电池 SoE 的估计精度。最后, 在 NEDC 工况下进行了仿真验证, 并将所提方法与传统 MPF 算法和 BPNN-MPF 算法在 SoE 估计方面的性能进行对比。结果表明, 所提方法保证了较高的 SoE 估计精度, 且估计值的最大绝对误差和均方根误差均在 1% 以内, 远小于基于 MPF 和 BPNN-MPF 方法的 SoE 估计误差。

参考文献:

- [1] Lin C, Mu H, Xiong R, et al. Multi-model probabilities based state fusion estimation method of lithium-ion battery for electric vehicles: state-of-energy[J]. Applied Energy, 2016, 194(15): 560-568.
- [2] Chang J Q, Chi M S, Shen T. Model based state-of-energy estimation for LiFePO₄ batteries using unscented particle filter[J]. Journal of Power Electronics, 2020(20): 624-633.
- [3] 刘伟龙, 王丽芳, 王立业. 基于电动汽车工况识别预测的锂离子电池 SOE 估计[J]. 电工技术学报, 2018, 33(1): 17-25.
Liu Wei-long, Wang Li-fang, Wang Li-ye. Estimation of state-of-energy for electric vehicles based on the identification and prediction of driving condition [J]. Transactions of China Electrotechnical Society, 2018, 33(1): 17-25.
- [4] Liu X T, Wu J, Zhang C B, et al. A method for state of energy estimation of lithium-ion batteries at dynamic currents and temperatures[J]. Journal of Power Sources, 2014(270): 151-157.
- [5] He H W, Zhang Y Z, Xiong R, et al. A novel gaussian model based battery state estimation approach: state-of-energy[J]. Applied Energy, 2015(151): 41-48.
- [6] Wang Y J, Zhang C B, Chen Z H. A method for joint estimation of state-of-charge and available energy of LiFePO₄ batteries[J]. Applied Energy, 2014 (135): 81-87.
- [7] Zhang W G, Shi W, Ma Z Y. Adaptive unscented kalman filter based state of energy and power capability estimation approach for lithium-ion battery[J]. Journal of Power Sources, 2015(289): 50-62.
- [8] Dong G Z, Chen Z H, Wei J W, et al. An online model-based method for state of energy estimation of lithium-ion batteries using dual filters[J]. Journal of Power Sources, 2016(301): 277-286.

- [9] 赵琳, 王小旭, 丁继成, 等. 组合导航系统非线性滤波算法综述[J]. 中国惯性技术学报, 2009, 17(1): 46-52.
Zhao Lin, Wang Xiao-xu, Ding Ji-cheng, et al. Overview of nonlinear filter methods applied in integrated navigation system[J]. Journal of Chinese Inertial Technology, 2009, 17(1): 46-52.
- [10] Mook D J, Junkins J L. Minimum model error estimation for poorly modeled dynamic systems[J]. Journal of Guidance, Control and Dynamics, 1988, 11(3): 256-261.
- [11] Crassidis J L, Markley F L. Predictive filtering for nonlinear systems[J]. Journal of Guidance, Control and Dynamics, 1997, 20(3): 566-572.
- [12] 杨一. 神经网络优化方法及其在组合导航中的应用研究[D]. 西安: 西北工业大学自动化学院, 2016.
Yang Yi. Research on the optimization of neural networks method and its application for integrated navigation[D]. Xi'an: College of Automation, Northwestern Polytechnical University, 2016.
- [13] 华寅, 许敏. 基于双非线性预测滤波法的锂离子电池 SOH 估计[J]. 电源技术, 2018, 42(9): 1321-1324.
Hua Yin, Xu Min. State of health estimation of lithium-ion battery by dual nonlinear predictive filter for electric vehicles[J]. Chinese Journal of Power Sources, 2018, 42(9): 1321-1324.
- [14] 田冬冬, 李立伟, 杨玉新. 基于改进 BP-EKF 算法的 SoC 估算[J]. 电源技术, 2020, 44(9): 1274-1278.
Tian Dong-dong, Li Li-wei, Yang Yu-xin. Research on SoC estimation based on improved BP-EKF algorithm[J]. Chinese Journal of Power Sources, 2020, 44(9): 1274-1278.