

DOI: 10.19650/j.cnki.cjsi.J2210748

基于局部模型网络的锂电池 SOC 估计方法 *

张振强¹, 马思乐¹, 姜向远¹, 陈纪旸^{1,2}, 马晓静¹

(1. 山东大学海洋研究院 青岛 266237; 2. 山东正中信息技术股份有限公司 济南 250014)

摘要:锂电池的荷电状态(SOC)是电池管理最重要的参数,准确的SOC估计对保证电池运作的安全性至关重要。传统基于数据驱动的SOC估计法,如神经网络,在可解释性、参数整定方面表现不足。本文提出一种基于局部模型网络和天牛须搜索优化组合的SOC估计法。首先,借助局部模型网络描述复杂非线性系统的能力和其作为灰箱模型的可解释性,将模型的工况空间分解为多个可以用简单模型表示的局部子区间,再用调度函数组合为最终的模型。其次,在网络的训练过程中,采用天牛须搜索优化算法确定分裂空间上的最佳分裂方位,很好的兼顾了模型辨识的精度和运算复杂度。最后,在锂电池动态特性数据集上与已有文献中的SOC估计法进行了对比试验,本文所提出的方法在简单工况的训练集上的RMSE误差小于0.4%,在复杂工况的测试集上的RMSE误差小于0.9%,在不同温度上的表现也相对平稳,总体展现出较高的辨识精度及泛化能力。这一特点在实测的数据集上也得到了进一步验证。

关键词:锂电池; SOC 估计; 局部模型网络; 天牛须搜索优化

中图分类号: TH89 文献标识码: A 国家标准学科分类代码: 520. 20

State of charge estimation of lithium-ion batteries using local model network

Zhang Zhenqiang¹, Ma Sile¹, Jiang Xiangyuan¹, Chen Jiyang^{1,2}, Ma Xiaojing¹

(1. Institute of Marine Science and Technology, Shandong University, Qingdao 266237, China;
2. Shandong Zhengzhong Information Technology Co., Ltd., Jinan 250014, China)

Abstract: State of charge (SOC) is the key parameter of the lithium-ion battery management system, which needs to be estimated accurately to ensure the battery's safe operation. The traditionally used data-driven SOC estimation methods (e.g., neuro-network) have limitations on interpretability and parameter tuning. This article proposes a novel method by combining the local model network (LMN) and the beetle antenna search (BAS) algorithm. Firstly, LMN, known as a grey-box model that can model complex non-linear systems with some extent of interpretability, is employed to partition the working condition space into some sub-regions that can be represented by simple models. Then, they are combined by validation function. Secondly, during the training of LMN, BAS optimization is utilized to find the optimal splitting location and orientation globally, which reaches a good trade-off between the model identification accuracy and the computation complexity. Finally, the proposed SOC estimation method is compared with two existing methods on a lithium-ion battery dynamic characteristic dataset. The RMSE is less than 0.4% on the training set under simple test driving cycle, and less than 0.9% on the testing set under complex test driving cycles. The performance on different temperatures is relatively stable too. Therefore, it shows an excellent identification accuracy and generalization capability of the method. The advantage of the proposed method is verified on real measured dataset too.

Keywords: lithium-ion batteries; SOC estimation; local model network; BAS optimization

0 引言

锂电池的荷电状态(state of charge, SOC)是指电池的剩余可用电量,是电池管理中最重要的参数^[1-2]。SOC

在数值上定义为剩余电量占电池容量的比值,由于不可直接测量,在工程中常用估计的方法得到。尽管锂电池管理技术的发展已日趋成熟,但在SOC的准确估计方面仍存在挑战,例如传统的安-时积分法依赖对初始SOC的准确估计且容易引入积分误差^[2]、经典的等效电路和

卡尔滤波法组合法^[3-4]对模型的线性度依赖大等。近年来随着人工智能技术的发展,数据驱动的方法开始引入到 SOC 估计中^[5-6]。文献[7]总结了当前数据驱动的 SOC 估计法,这类方法无需建立电池的物理模型,依靠大量的样本数据,可以拟合出电池的非线性特性,但缺点是可解释性差,特别是复杂网络的调参困难,训练时容易陷入局部极小点或过拟合而影响 SOC 估计的精度。在数据驱动的 SOC 估计法中,文献[8]提出了一种基于自编码神经网络和长短期记忆 (long short-term memory, LSTM) 网络组合的 SOC 估计法,自编码神经网络用来提取合适的特征,而长短时记忆网络用来预测数据的发展趋势,文中将网络结构的 LSTM 块的数量设置为 100,由于网络结构过于复杂,算法部署在 GPU 上来加速训练的速度。网络的输入为电流、端电压和电池温度,输出为 SOC,训练后模型在各个工况下的估计精度介于 0.52% ~ 0.93% 之间。文献[5]用回溯搜索算法 (backtracking search algorithm, BSA) 改进了反向传播神经网络 (back-propagation neural network, BPNN),在两种不同测试循环工况和 3 个不同温度下,对网络进行了训练,BPNN-BSA 网络的输入为端电压、电流和电池温度,输出为 SOC,测试结果显示该方法的估计精度为 0.48% ~ 1.74%,文中还进一步将该方法与传统的 RBFNN、GRNN、ELM 法进行了对比,发现 BPNN-BSA 法分别提高了 59%、58%、61%。

一般来说,数据驱动的方法都是一种黑箱模型,虽然可以反应输入输出之间的映射关系,但是不具备可解释性,网络中的各项参数无法与实际的物理过程产生关联。而现实中的物理过程,大部分又很难用精确的物理方程进行建模。这就导致了灰箱模型的发展。灰箱模型虽然也是从大量的样本数据中获取信息,但不同之处在于,它的模型结构中可以融入用规则形式表达的关于实际物理过程的先验知识,这样做好处是一方面降低了模型的复杂度,同时还有一定程度的可解释性^[9]。典型的灰箱模型如模糊逻辑系统。但这类模型的缺点也显而易见,就是规则的确定主观性较强,这给模型的建立带来一定困难,不恰当的规则设定也可能降低建模的精度。

局部模型网络 (local model network, LMN) 也是一种灰箱模型,是汽车工业中逐渐开展使用的一种非线性模型辨识方法^[10-14],近年来在工业控制^[15-16]、动态系统辨识^[17]等方面也取得一定进展。它的基本思想是将复杂模型分解为多个在特定子区间上有效的局部模型,局部模型可以用简单多项式或线性模型表示,多个局部模型再通过调度函数最终组合为非线性模型^[9]。子区间可以理解为局部工况区间,而局部模型是系统在该区间上的行为特性。这一模型结构十分符合工程思想,所以局部模型网络是一种灰箱模型。局部模型网络的构建过程是渐进式的,其核心算法是循环将所有局部模型中误差表

现最差的一个局部模型,分裂为两个新的局部模型,使得模型误差不断缩小。这一构建过程基于数据训练,主观性介入低。模型空间的分裂方式可分为正交轴和倾斜轴分裂两种方式^[9]。文献[18]系统论述了倾斜轴分裂方法,指出倾斜轴分裂可以大大降低局部模型的数目,避免维度爆炸问题,并给出了有效的模型构建步骤,算法的难点是确定最佳的分裂方向和位置。文献[19-20]比较了期望最大化 (expectation-maximization, EM) 和粒子群 (particle swarm optimization, PSO) 两种分裂优化算法,并在实测的柴油机和燃气轮机的 NO_x 排放数据上进行了试验验证,均得出 PSO 优化的模型误差更小,且避免了陷入局部最优点的问题。

因此本文将使用局部模型网络来构建锂电池的 SOC 估计模型,同时为了提高全局优化的效率,引入一种新的优化算法:天牛须搜索 (beetle antenna search, BAS) 优化算法^[21],来确定局部模型网络构建时分裂空间上最佳的分裂方向和位置。这一算法的突出优点是只需要一个搜索智能体,全局搜索能力强,鲁棒性高、计算资源消耗低,便于布置到嵌入式设备中。使用这一算法的目的,是为将来的在线建模应用提供一种可靠的途径。

本文的主要贡献是:

1) 采用局部模型网络构建锂电池的 SOC 估计模型,有效缩短了训练时间、提升了模型的估计精度,同时工况空间的分裂和局部线性模型,使得局部模型网络符合工程思维,具有一定的可解释性。

2) 设计了天牛须搜索优化算法,来确定局部模型网络分裂空间上最佳的分裂方位,提高全局寻优能力,降低对计算资源的要求。

1 局部模型网络

1.1 模型结构

局部模型网络的基本思想是将模型的工况空间划分为多个可以用简单模型描述的子区间,然后用模糊推理的思想给每个子区间赋予权重,称为调度函数,最后综合为系统的输出^[9]。子区间上的模型就称为局部模型 (local model, LM),通常表示为线性模型或简单多项式模型。

局部模型网络的结构如图 1 所示,该模型由 M 个 LM 组成,输入向量 $\mathbf{u}(k) = [u_1(k), u_2(k), \dots, u_p(k)]$, p 是输入向量的维度,输出为 $\hat{y}(k)$ 。局部模型 LM_i 和它所对应的调度函数 Φ_i 构成一个非线性神经元,整个模型的输出为:

$$\hat{y}(k) = \sum_{i=1}^M \Phi_i(k) \hat{y}_i(k) \quad (1)$$

其中, $\hat{y}_i(k)$ 是输入向量在第 i 个局部模型上的输出

出, $\Phi_i(k)$ 为调度函数, 取值范围为 0 ~ 1, 代表第 i 个局部模型的权重, 决定该 LM 对最终输出的贡献。可以看出, 式(1)所表示的 LMN 与具有 M 个模糊规则的 Takagi-Sugeno 模糊推理模型是类似的, $\Phi_i(\cdot)$ 是规则前件, $\hat{y}_i(\cdot)$ 是规则后件^[18]。

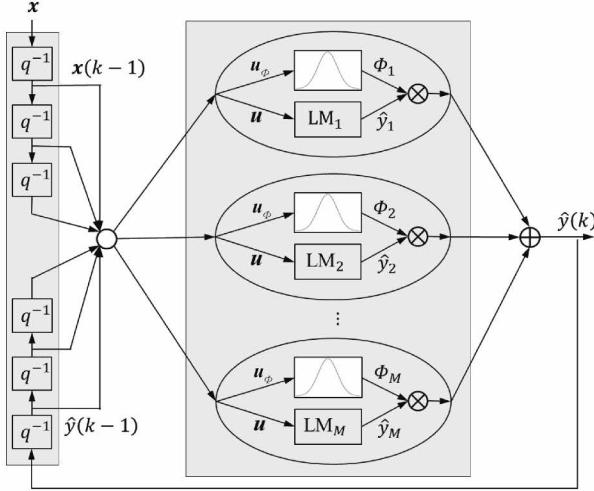


图 1 LMN 的结构, 图示由 M 个局部模型组成

Fig. 1 Network architecture of LMN, the example consisted of M LMs

调度函数 $\Phi_i(\cdot)$ 必须满足以下两个约束条件:

- 1) 调度函数是平滑的, 且取值处于 0~1 之间。
- 2) 所有调度函数的和满足同一性, 即:

$$\sum_{i=1}^M \Phi_i[u_\phi(k)] = 1.$$

局部模型在理论上可以是任意形式, 最常用的是局部线性模型(local linear model, LLM), 它在局部模型的复杂度和局部模型数目之间取得了很好的均衡, 也为将成熟的线性理论移植到非线性领域创造了可能。如果选择 LLM, 则局部模型上的输出可写为:

$$\hat{y}_i(k) = \mathbf{u}_e(k)\boldsymbol{\theta}_i = \theta_{i,0} + \theta_{i,1}u_1(k) + \cdots + \theta_{i,p}u_p(k) \quad (2)$$

其中, $\boldsymbol{\theta}_i = [\theta_{i,0}, \theta_{i,1}, \dots, \theta_{i,p}]^\top$ 是第 i 个局部线性模型上的参数向量, $\mathbf{u}_e(k) = [1, u_1(k), \dots, u_p(k)]$ 是增广的输入向量。

1.2 局部模型参数估计

局部模型网络的一大特点是局部模型间几乎是相互独立的, 也就是说局部模型上的估计误差独立的影响全局误差。为了估计局部模型 LM_i 上的参数, 构建局部损失函数:

$$J(\boldsymbol{\theta}_i) = \sum_{k=1}^N \Phi_i(k) \| y(k) - \hat{y}_i(k) \|^2 = (\mathbf{Y} - \hat{\mathbf{Y}}_i)^\top \mathbf{Q}_i (\mathbf{Y} - \hat{\mathbf{Y}}_i) \quad (3)$$

式中: $\mathbf{Y} = [y(1), \dots, y(N)]^\top$, $\hat{\mathbf{Y}} = [\hat{y}(1), \dots, \hat{y}(N)]^\top$, $\mathbf{Q}_i = \text{diag}[\Phi_i(1), \dots, \Phi_i(N)]$, N 是训练样本数。对于 LLM_i , 式(3)进一步写为:

$$J(\boldsymbol{\theta}_i) = (\mathbf{Y} - \mathbf{U}_e \boldsymbol{\theta}_i)^\top \mathbf{Q}_i (\mathbf{Y} - \mathbf{U}_e \boldsymbol{\theta}_i) \quad (4)$$

式中: $\mathbf{U}_e = [\mathbf{u}_e(1), \dots, \mathbf{u}_e(N)]^\top$ 。最优的局部模型参数是使损失函数最小化的参数, 即:

$$\boldsymbol{\theta}_i^* = \underset{\boldsymbol{\theta}_i}{\operatorname{argmin}} J(\boldsymbol{\theta}_i) \quad (5)$$

由式(4)和(5)可以看出, 这实际是加权最小二乘法 (weighted least square, WLS) 求解线性回归问题, 其解可以由下式给出:

$$\boldsymbol{\theta}_i^* = (\mathbf{U}_e^\top \mathbf{Q}_i \mathbf{U}_e)^{-1} \mathbf{U}_e^\top \mathbf{Q}_i \mathbf{Y} \quad (6)$$

用局部估计误差代表全局误差的学习方法称为局部学习^[13], 该方法的优势是: 数值稳定性高(求解较小规模矩阵的逆)、运算速度快、局部可解释性强(局部模型为超平面)。

1.3 分裂空间

如 2.1 节所述, LMN 将模型的工况空间分解为多个相互独立的子区间。需要说明的是, 分裂空间和工况空间并不必须是完全一致的, 分裂空间可以视情况选择为工况空间的一部分或做过一定处理后的工况空间, 这更符合实际情况, 还可以大大降低运算负荷, 避免维度爆炸, 这是 LMN 区别于其他神经网络的一大特点^[9]。为方便起见, 记分裂空间的输入向量为 \mathbf{u}_ϕ 。而如何在分裂空间中确定合理的分裂方向和位置是构建局部模型网络的关键所在。

与神经网络不同, LMN 采用渐进式的构建策略, 如图 2 所示^[18]。图 2 中的 ψ_d 称为分裂函数, 在每次分裂时选取 $\{LM_i\}$ 中误差表现最差的一个局部模型(记为 LM_{wst}), 将其分裂为两个新的局部模型, 其调度函数分别为:

$$\begin{cases} \Phi_l = \Phi_{wst}\psi_d \\ \Phi_M = \Phi_{wst}(1 - \psi_d) \end{cases} \quad (7)$$

其中, Φ_{wst} 是误差表现最差的局部模型上的调度函数, Φ_l 、 Φ_M 分别是两个新局部模型上的调度函数。这样做的好处是自动保证了调度函数的同一性, 避免了类似神经网络中繁琐的归一化操作。 M 是局部模型的数目,

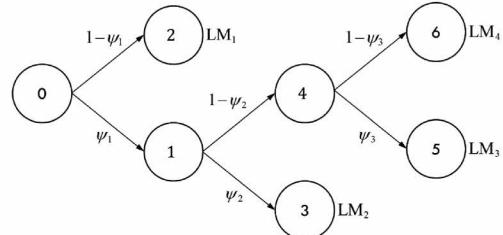


图 2 局部模型分裂示意图

Fig. 2 An example of LM split

决定了局部模型网络分辨工况空间中工况突变的能力, M 值越大意味着模型对微小的工况突变越敏感, 相应的模型辨识精度也越高。由于分裂时只是对误差表现最差的局部模型进行操作, 而所有已存在的其他局部模型保持不变, 所以训练过程的运算量小, 这一渐进特性也使得局部模型网络被众多的在线建模应用场景^[12-13]所采用。

分裂函数的一般形式为 logistic sigmoid 函数^[13,19,22-23]:

$$\psi_d(\mathbf{u}_\Phi) = \frac{1}{1 + e^{-s_d \alpha_d(\mathbf{u}_\Phi)}} \quad (8)$$

式中:

$$\alpha_d(\mathbf{u}_\Phi) = [1 \quad \mathbf{u}_\Phi^\top] \begin{bmatrix} \psi_{d0} \\ \boldsymbol{\Psi}_d \end{bmatrix} \quad (9)$$

其中, $\boldsymbol{\Psi}_d$ 表示分裂的方向, ψ_{d0} 表示分裂的位置, s_d 控制着分裂处的平滑程度, s_d 越小分裂越平滑但同时也意味着捕捉工况突变的能力减弱。

在分裂方向和位置的选择方法上存在正交轴分裂^[24-27]和倾斜轴分裂^[18-19,22-23]两种形式。正交轴分裂严格的在维度轴上进行分裂, 算法简单、训练负荷低, 但达到需要的精度所需要的局部模型数目多, 造成网络结构复杂; 倾斜轴分裂仅在需要的方向和位置上进行分裂, 灵活性高, 与常见的工程问题较吻合, 最终训练得到的局部模型数目少, 模型复杂度与输入空间的维度无关, 避免了维度爆炸的问题^[13]。因此本文以倾斜轴分裂方式为研究对象。

倾斜轴分裂的方向和位置的确定可以看作是一个最优化问题, 优化变量为:

$$\boldsymbol{\Psi} = \begin{bmatrix} \psi_{d0} \\ \boldsymbol{\Psi}_d \end{bmatrix} \quad (10)$$

优化的目标是使分裂得到的两个新局部模型的局部回归精度最高, 因而构建损失函数:

$$J(\boldsymbol{\Psi}) = \sum_{k=1}^N \Phi_l \|y(k) - \hat{y}_l(k)\|^2 + \Phi_M \|y(k) - \hat{y}_M(k)\|^2 = \sum_{k=1}^N e_l^2 + e_M^2 \quad (11)$$

根据具体问题的不同, 式(11)的求解可以使用非线性局部或全局优化算法。文献[19]比较了 EM 和 PSO 两种分裂优化算法, EM 算法基于梯度求解, 运算速度快, 而 PSO 算法则实现了全局优化。显然 PSO 这一类全局优化算法更适合一般问题的求解。但对于在线建模应用, 对鲁棒性和计算资源的要求更加严苛, 因此有必要探寻一种更加高效的全局优化算法。

2 基于 BAS 的 LMN 分裂优化

2.1 BAS 搜索优化算法

天牛须搜索(b beetle antenna search, BAS)是 2017 年提出的元启发式全局优化算法^[21], 近年来在非线性系统

优化^[28]、机器人轨迹规划^[29]、医学影像诊断^[30]等领域有所应用。相比于其他常见的优化算法如遗传算法、PSO、模拟退火等, 它的计算负荷更小。BAS 的基本思想是模拟自然界昆虫的觅食行为, 只用两个探测器(如图 3 所示)和简单的 Monte-Carlo 法则, 在搜索空间中按照一定的规则搜索, 最终收敛到全局最优解。以下简单回顾 BAS 算法的步骤。

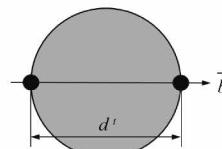


图 3 BAS 搜索智能体简图

Fig. 3 A schematic diagram of BAS agent

首先, 随机初始化 BAS 智能体的触须方向:

$$\mathbf{b} = \frac{\text{rnd}(p, 1)}{\|\text{rnd}(p, 1)\|} \quad (12)$$

其中, p 是搜索空间的维度, 计算得到左右两须(以下称为探测器)的位置:

$$\mathbf{x}_l = \mathbf{x}^t - \frac{1}{2} d' \mathbf{b} \quad (13)$$

$$\mathbf{x}_r = \mathbf{x}^t + \frac{1}{2} d' \mathbf{b} \quad (14)$$

其中, d' 是第 t 次迭代时探测器的间距, 该值决定了智能体的搜索范围, 初始化时应尽量取较大值。

然后, 比较两探测器上的适应度, 根据以下规则移动智能体到新的位置上:

$$\mathbf{x}' = \mathbf{x}^{t-1} + \delta' \mathbf{b} \text{sign}[f(\mathbf{x}_r) - f(\mathbf{x}_l)] \quad (15)$$

其中, δ' 是第 t 次迭代的步长, 决定了收敛过程的稳定性, 该值不宜取得过大, 为方便起见可以按照与 d' 成一定比例, 即 $\delta' = cd'$ 。根据经验, $c = 0.05 \sim 0.1$ 是比较合理的数值。 $\text{sign}(\cdot)$ 是取符号函数。

以上循环迭代, 为了使搜索收敛, 设置探测器的间距 d' 按指数规律衰减, 即:

$$d' = \alpha d'^{t-1} + e \quad (16)$$

其中, α 为衰减系数, e 为极小值。由于搜索步长 δ' 和 d' 之间的比例关系, 所以搜索步长也是自动衰减的。BAS 搜索收敛的准则可以是达到一定的迭代次数, 或探测器的间距缩小到某一数值以致智能体无法再移动为止。为了提高全局搜索能力, 建议 d^0 取最大搜索空间范围的 80% ~ 85%, 而 $\alpha > 95\%$ 。

2.2 BAS 优化 LM 的分裂方向和位置

BAS 优化的变量是 LM_{wst} 的分裂方向和位置, 如式(10)所示, 维度为 $1 + p$, 目标函数为式(11)。基于

BAS 优化构建 LMN 的算法步骤如下:

- 1) 初始化模型: 初始化局部模型数 $M = 1$, 初始化 BAS 优化器的参数, 随机初始化 BAS 搜索的位置, 如果按 2.1 节的推荐参数的话, 这一初始位置将在搜索空间的中央位置附近。
- 2) 寻找误差表现最差的局部模型: 评价指标为均方误差 $MSE_i = \sum_{k=1}^N \Phi_i(k) \|y(k) - \hat{y}_i(k)\|^2/N$, 找出最大均方误差对应的局部模型, 即为 LM_{wst} 。

3) 计算 BAS 两探测器所对应的分裂方向和位置: 根据式(12)~(14)、(10)计算两个变量向量 Ψ_l 和 Ψ_r 。

4) 分裂: 分别用 Ψ_l 和 Ψ_r 试分裂 LM_{wst} , 用式(7)计算两次分裂的调度函数, 用式(6)计算最优的局部模型参数, 用式(11)计算两次分裂的损失函数。

5) 更新 BAS 智能体的搜索位置: 根据步骤 4) 得到的损失函数, 用式(15)确定智能体新的搜索位置。

6) 找到最优的分裂方位: 根据式(16)更新 BAS 的搜索参数, 重复步骤 3)~5), 直到达到预定的收敛准则, 至此 LM_{wst} 被替换为两个新的 LM, 局部模型数目 $M=M+1$ 。

7) 得出最优的辨识结果: 重复步骤 2)~6), 直到达到设定的终止条件, 如达到一定的模型复杂度或全局辨识精度。

2.3 简单示例

使用与文献[19]中相同的示例函数:

$$y(x_1, x_2) = \exp\left(x_1 \sin \frac{\pi}{4} + x_2 \cos \frac{\pi}{4}\right) \quad (17)$$

在文献[19]中分别用 EM 和 PSO 两种算法对上述函数进行了局部模型网络模型辨识, 得出的结论是 PSO 在特定任务中的性能更优。这里使用第 2.2 节的 BAS 优化算法对上述函数进行局部模型网络模型辨识。BAS 优化器的参数设置如表 1 所示。

表 1 BAS 优化器的参数设置

Table 1 Parameters setting of the BAS optimizer

优化器	d^0	c	α	e
BAS	0.85	0.05	0.99	0.01

图 4 是 BAS 优化器在输入空间上的迭代过程, 可以看出 BAS 算法在 100 次迭代即可快速收敛到最优解, 优化得到的分裂方向和位置如图 4(a) 中粗实线所示, 与文献[19]一致。注意, 虽然基于 BAS 算法的迭代次数高于文献中的 PSO 算法, 但 BAS 在每次迭代中只计算 2 次适应度, 而 PSO 在每次迭代中计算适应度的次数是与粒子的群体数目正相关的。

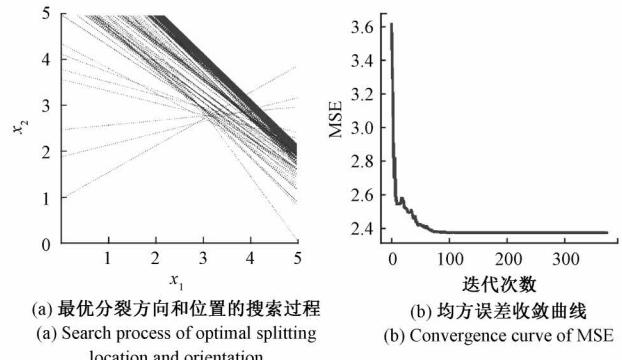


图 4 BAS 优化器在输入空间上的迭代过程

Fig. 4 BAS optimization process on the input space

3 基于 LMN-BAS 的锂电池 SOC 估计

基于第 1 节提出的 LMN 网络结构, 可以对锂电池 SOC 估计问题进行灰箱建模, 然后用第 2 章所提出的 BAS 算法求解工况区间上最优或近似最优的分裂方位, 循环迭代直到辨识得到的模型精度在预期范围内。

3.1 锂电池数据集

使用高级提升循环工程中心 (center of advanced lift cycle engineering, CALCE) University of Maryland 发布的锂电池动态特性数据集^[4], 该数据集包含了锂电池在 4 种常见的测试循环工况、3 种不同的温度下的动态数据。试验中所使用的电池的基本参数如表 2 所示, 所有数据的采集周期均为 1 s。

表 2 试验中所使用的电池的基本参数

Table 2 Basic parameters of the battery in the experiment

类型数	额定电压/V	额定容量/Ah	截止电压/V	温度/°C
18 650	3.6	2.0	4.2/2.5	0~50

在试验电池上加载的 4 种不同类型的测试循环工况, 分别是 DST、FUDS、US06 和 BJDST, 负荷曲线如图 5 所示。可以看出, DST 工况的形式最为简单, 试验代价最小。本文为了说明所提出 LMN-BAS 方法的有效性和泛化能力, 将使用 DST 工况作为模型的训练集, 辨识得到模型参数后再在其他 3 个测试循环工况上进行测试。

3.2 SOC 估计结果

局部模型网络的输入为电流、端电压、温度以及 SOC 的过去值, 输出为当前 SOC。通过对锂电池动态特性数据的先验知识, 在不过分增加运算量的前提下, 将局部模型的数目设置为 16, 动态模型的阶次设置为 2, BAS 优化器的参数设置同表 1。在计算机的配置为 Intel Core i9 8 核 CPU 和 16 G 内存的情况下, 训练时间小于 5 min。模

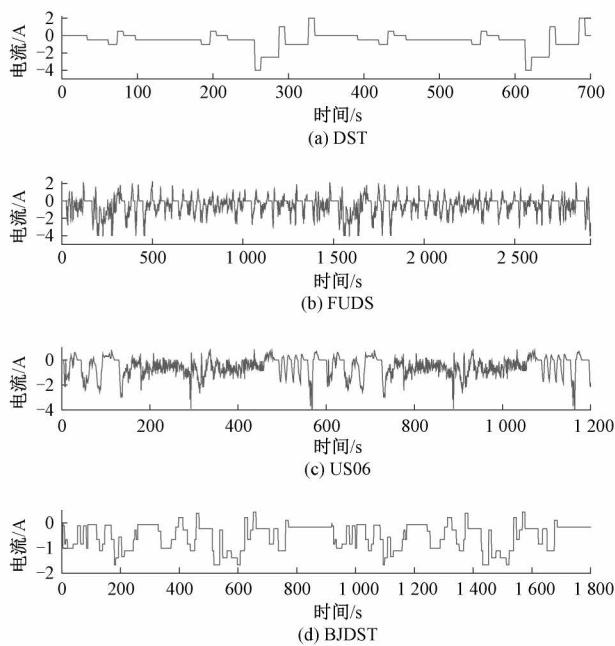
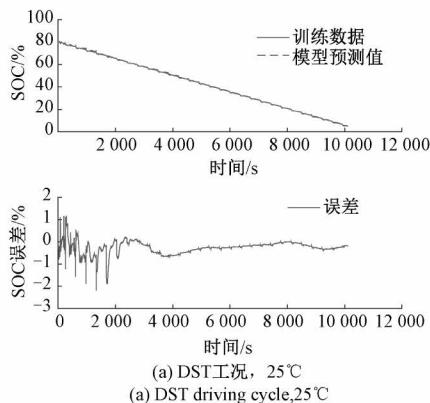


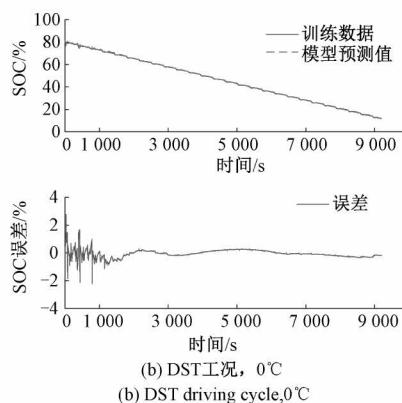
图 5 4 种不同类型的测试循环工况
Fig. 5 Four different test driving cycles

型的评价指标采用均方根误差(*RMSE*)、平均绝对误差(*MAE*)和平均绝对百分误差(*MAPE*)，定义如下：

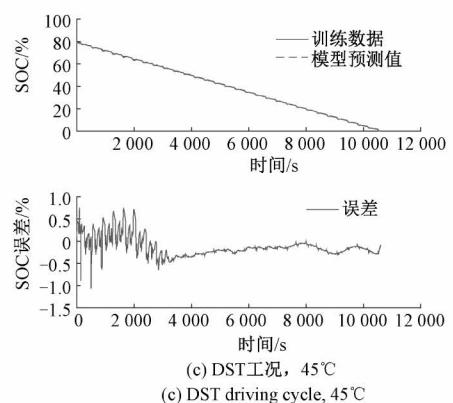
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (18)$$



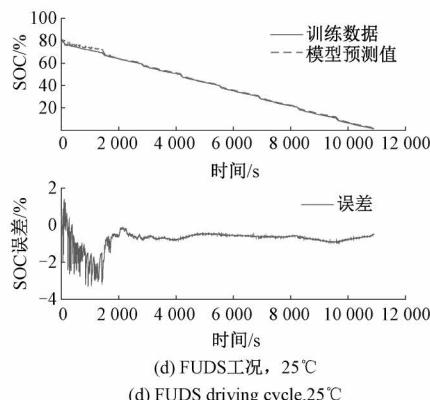
(a) DST 工况, 25°C
(a) DST driving cycle, 25°C



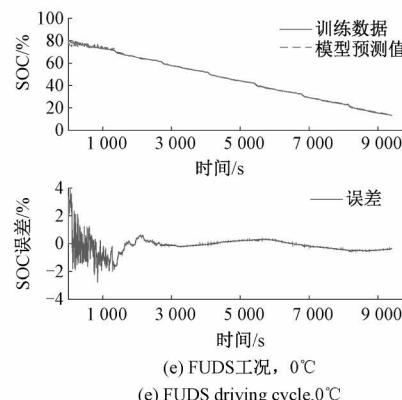
(b) DST 工况, 0°C
(b) DST driving cycle, 0°C



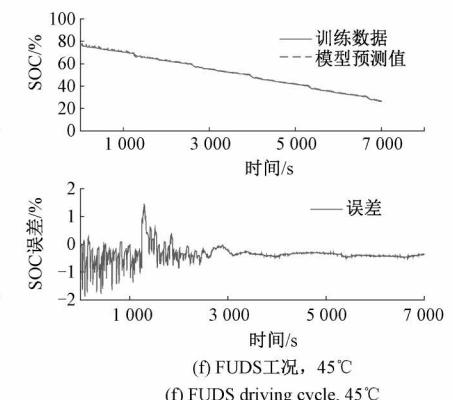
(c) DST 工况, 45°C
(c) DST driving cycle, 45°C



(d) FUDS 工况, 25°C
(d) FUDS driving cycle, 25°C



(e) FUDS 工况, 0°C
(e) FUDS driving cycle, 0°C



(f) FUDS 工况, 45°C
(f) FUDS driving cycle, 45°C

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (19)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (20)$$

得到模型在训练集和测试集上的表现如图 6 和表 3 所示。图 6 中对试验电池施加了 4 种不同的测试循环工况，其中图 6(a)~(c) 为 DST 工况、(d)~(f) 为 FUDS 工况、(g)~(i) 为 US06 工况、(j)~(l) 为 BJDST 工况。在负载的作用下 SOC 均从 80% 降为 0%，在此过程中用高精度库仑计记录同时用辨识得到的模型估计 SOC 值。可以看出，LMN-BAS 法的整体估计误差小，仅在负荷加载初期的误差波动较大，这是由动态模型的特性决定的，从初始 SOC 跃变到较高的 SOC 必然会经历一段时间的波动调整，即便如此本文 SOC 的估计误差仍在 $\pm 4\%$ 的范围以内。在全工况范围内，算法的误差表现较为平稳。另外，虽然 DST 工况的形式比较简单，但是辨识得到的模型在其他 3 个验证集上的表现仍然优异，说明本文提出的方法有较好的泛化能力。

表 3 比较了文献[4-5]在同样数据集上的表现，其中文献[5]所使用的方法为 BPNN-BSA，文献[4]所使用的方法为最小二乘法和无迹卡尔曼滤波器的组合(以下简称 LS-UKF)。从表 3 中可以看出：1) 本文所提出方法在

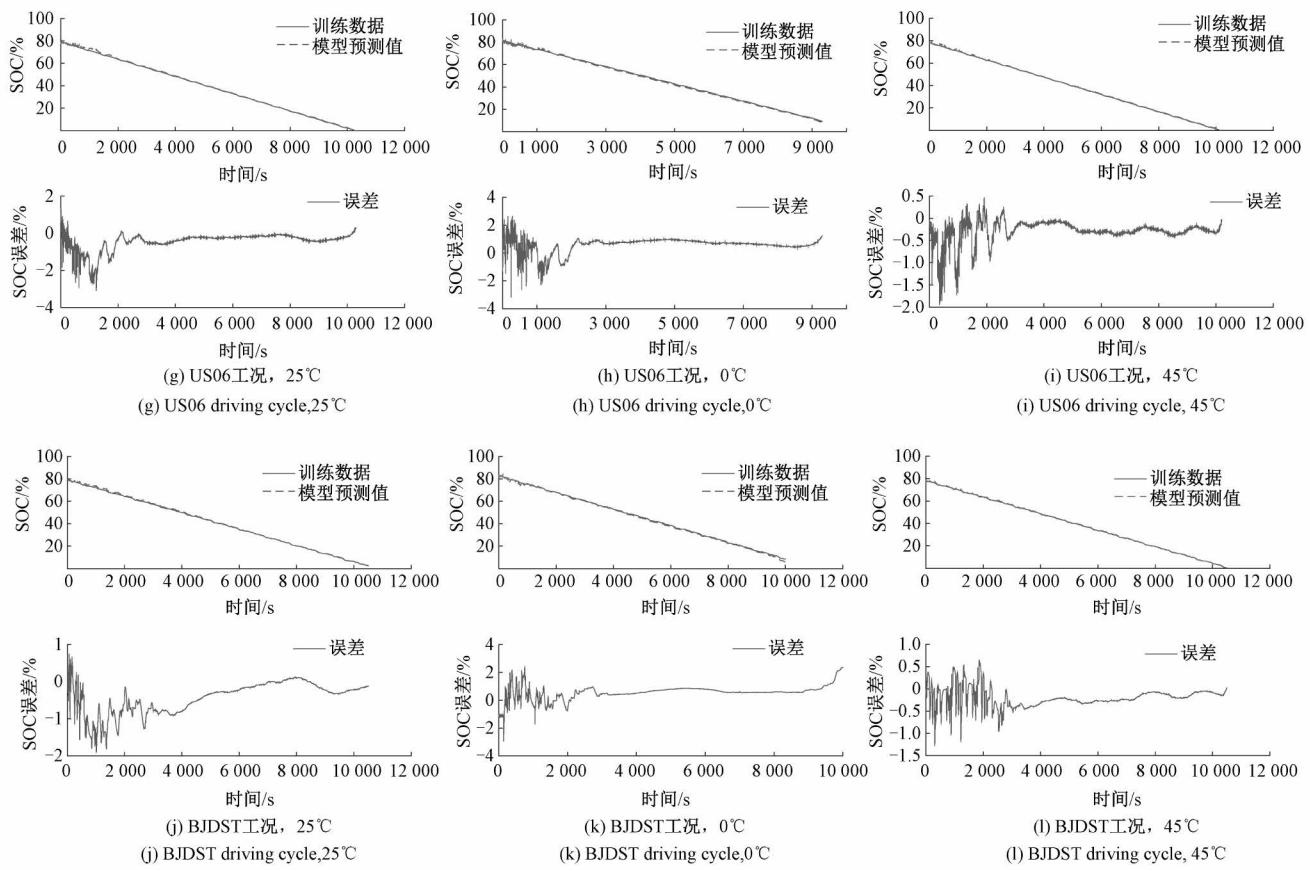


图 6 基于 LMN 模型的 SOC 估计结果(其中第 1 行 DST 工况是训练集,后 3 行 FUDS、US06、BJDST 工况是测试集)

Fig. 6 SOC estimation of the proposed model (the first line DST driving cycle (used as training set), the last three lines FUDS, US06, BJDST driving cycles respectively (used as testing sets))

表 3 模型在训练集和测试集上的误差,以及在与文献[4-5]中的结果对比

Table 3 The performance of the model, compared with the results in [4-5]

工况	温度/°C	均方根误差 RMSE/%			平均绝对值误差 MAE/%			平均绝对百分误差 MAPE/%		
		LMN-BAS	BPNN-BSA	LS-UKF	LMN-BAS	BPNN-BSA	LS-UKF	LMN-BAS	BPNN-BSA	LS-UKF
DST	25	0.39	0.81	-	0.30	0.48	-	0.93	7.15	-
	0	0.29	1.47	-	0.20	0.76	-	0.55	9.84	-
	45	0.25	0.48	-	0.22	0.32	-	4.85	5.07	-
FUDS	25	0.89	0.91	0.36	0.77	0.59	0.30	3.94	12.61	-
	0	0.56	1.74	2.78	0.36	0.87	2.58	0.95	20.09	-
	45	0.46	0.57	0.83	0.40	0.38	0.73	0.83	9.63	-
US06	25	0.64	-	0.50	0.45	-	0.39	5.26	-	-
	0	0.78	-	3.11	0.73	-	2.79	2.05	-	-
	45	0.38	-	0.64	0.29	-	0.56	6.93	-	-
BJDST	25	0.61	-	0.39	0.46	-	0.27	1.29	-	-
	0	0.75	-	2.34	0.66	-	2.02	2.46	-	-
	45	0.29	-	0.63	0.25	-	0.54	0.96	-	-

各个工况点下的 RMSE 误差和 MAE 误差均保持在 1% 的范围内,几乎全面优于 BPNN-BSA 和 LS-UKF。基于 BPNN 的方法是黑箱结构,网络参数调整不当则易陷入欠拟合或过拟合;而本文的方法属于灰箱结构,网络参数有一定的物理意义,调整方便,比如可以根据工况复杂度动态的增加局部模型数目 M 。2) 在与 LS-UKF 法的对比中,LS-UKF 在温度为 25℃ 时的表现优于本文提出的方法,而在低、高温时精度下降。如 FUDS 工况,25℃ 时 LS-UKF 的 RMSE 误差为 0.36%,本文提出的方法为 0.89%;而在 0℃ 和 45℃ 时 LS-UKF 的 RMSE 误差为 2.78%、0.83%,本文提出的方法则分别低至 0.56%、0.46%。即本文提出的方法,在各个温度上的表现都相对精准。可能的原因是,LS-UKF 是基于等效电路模型,容易陷入欠拟合,而基于 LMN-BAS 的模型辨识法,可以以更高精度拟合非线性系统。3) 同时可以看出,本文所提出的方法在训练集 DST 上的表现最好,RMSE 在 0.4% 以下;随着工况变得复杂误差略有增加,在最复杂的 FUDS 工况上,RMSE 达到 0.46%~0.89%。因此模型在测试集上的表现与训练样本的质量有一定关系,提升全工况上的性能的一个办法是增加训练集覆盖的范围。

3.3 进一步测试

除 CALCE 数据集外,在电池性能测试仪上使用容量为 2 600 mAh 的锂电池进行了再次测试,测试仪如图 7 所示,环境温度恒定为 20℃。

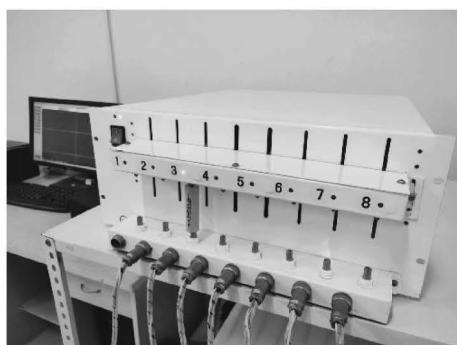


图 7 锂电池性能测试仪

Fig. 7 Li-ion battery performance testing instrument

图 8 对测得的 DST 工况和 BJDST 工况下的锂电池的特性进行了可视化,可见锂电池的特性呈现强非线性,因此对模型的表达能力提出了较高要求。同时,BJDST 工况较之 DST 工况更复杂一些,因而可以考验模型的泛化能力。

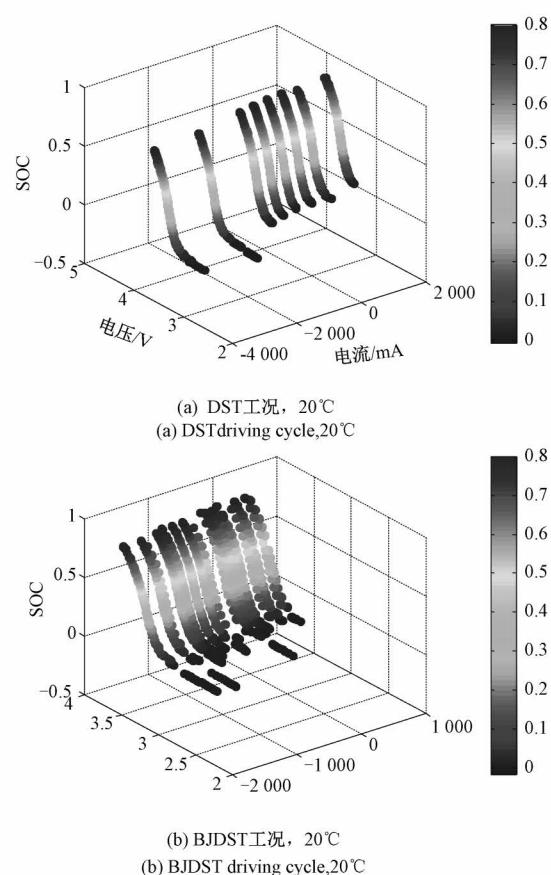
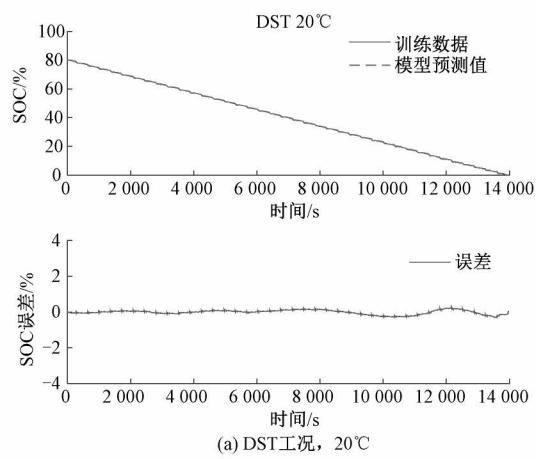


图 8 两种测试循环工况下锂电池特性的可视化

Fig. 8 Visualization of Li-ion battery characteristic under two different test driving cycles

运用本文所提出的 LMN-BAS 模型,对实测的数据集进行了训练和预测,结果如图 9 所示,模型的训练误差(RMSE)为 0.12%,预测误差(RMSE)为 0.43%。



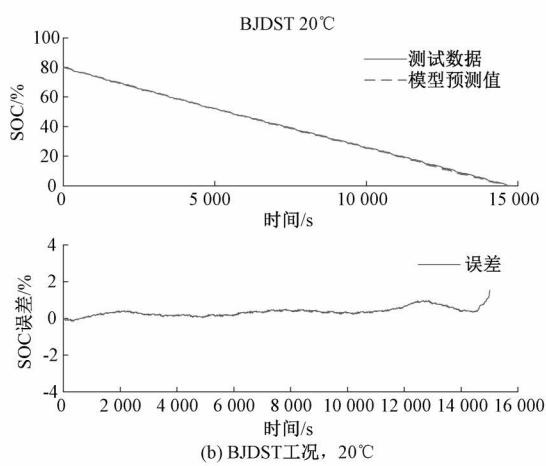


图9 模型的训练和预测结果

Fig. 9 The result of model training and testing

4 结 论

本文提出了一种基于 LMN-BAS 的估计锂电池 SOC 的新方法。局部模型网络是一种灰箱模型, 将复杂的模型表示为多个在特定子区间内有效的局部简单模型, 符合工程习惯, 网络的构建方式简单、运算速度快, 具有一定的可解释性。局部模型网络的训练步骤包括局部模型参数的估计和分裂方向和位置的确定, 而后者是构建的关键所在。基于 BAS 优化算法可以快速找到全局最优或次优的分裂方向和位置, 该优化算法全局搜索效率高、鲁棒性强、计算资源消耗低, 是在线建模比较好的选择。在 CALCE 发布的锂电池公开数据集上, 用 DST 工况作为训练集, 用 FUDS、US06、BJDST 工况作为测试集, 验证了本文所提出的 SOC 估计法的性能。与文献[4-5]中所使用的 BPNN-BSA 和 LS-UKF 法进行了对照, 本文所提出的方法展现出了较高的精度和较强的泛化能力。同时, 这一特点在实测的数据集上也得到了进一步验证。

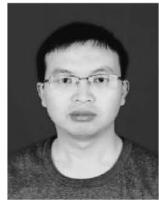
LMN 作为一种新的轻量化的模型表示方法, 其独特的渐进式构建机制使其自然具有在线建模的能力。本文后续将研究 LMN-BAS 在锂电池 SOC 在线标定中的应用, 提高 SOC 标定的效率。

参考文献

- [1] WANG Y J, TIAN J Q, SUN Z D, et al. A comprehensive review of battery modeling and state estimation approaches for advanced battery management systems [J]. Renewable and Sustainable Energy Reviews, 2020(131): 110015.
- [2] HU X S, FENG F, LIU K L, et al. State estimation for advanced battery management: Key challenges and future trends[J]. Renewable and Sustainable Energy Reviews, 2019(114): 109334.
- [3] 刘征宇, 朱诚诚, 尤勇, 等. 面向 SOC 估计的计及温度和循环次数的锂离子电池组合模型[J]. 仪器仪表学报, 2019, 40(11): 117-127.
- [4] LIU ZH Y, ZHU CH CH, YOU Y, et al. A Lithium-ion battery combined model considering temperature and cycle times for SOC estimation [J]. Chinese Journal of Scientific Instrument, 2019, 40(11): 117-127.
- [5] ZHENG F D, XING Y J, JIANG J C, et al. Influence of different open circuit voltage tests on state of charge online estimation for lithium-ion batteries [J]. Applied Energy, 2016(183): 513-525.
- [6] MAHAMMAD A H, MOLLA S H, AINI H, et al. Neural network approach for estimating state of charge of lithium-ion battery using backtracking search algorithm[J]. IEEE Access, 2018(6): 10069-10079.
- [7] CHEN J, OUYANG Q, XU C F, et al. Neural network-based state of charge observer design for lithium-ion batteries [J]. IEEE Transactions on Control Systems Technology, 2018, 26(1): 313-320.
- [8] MAHESHWARI A, NAGESWARI S. Modeling, state of charge estimation, and charging of lithium-ion battery in electric vehicle: A review [J]. International Journal of Energy Research, 2022, 46(3): 2141-2165.
- [9] MOHAMMAD F, MOHAMMAD M. State of charge estimation of lithium-ion batteries using hybrid autoencoder and Long Short Term Memory neural networks[J]. Journal of Power Sources, 2020(469): 228-375.
- [10] NELLES O. Nonlinear system identification: From classical approaches to neural networks, fuzzy models, and gaussian processes. Second edition [M]. Switzerland: Springer, 2021: 17-18.
- [11] NIKOLAUS E R, FERDINAND K, STEFAN J, et al. Automated synthesis of a local model network based nonlinear model predictive controller applied to the engine

- air path [J]. Control Engineering Practice, 2021(110) : 104768.
- [11] CHRISTOPH H, CHRISTIAN M, STEFAN J. Dynamic NOx emission modelling using local model networks [J]. International Journal of Engine Research, 2014, 15(8) : 928-933.
- [12] CHRISTIAN M, NIKOLAUS E, MARTIN K, et al. Engine control unit PID controller calibration by means of local model networks [J]. Control Engineering Practice, 2014(33) : 125-135.
- [13] CHRISTOPH H, STEFAN J. Local model network identification for online engine modelling [J]. Information Sciences, 2013(220) : 210-225.
- [14] 杜倩颖, 倪计民, 陈沁青, 等. HILOMOT 模型在柴油机快速标定试验中的应用 [J]. 内燃机学报, 2018, 36(4) : 347-352.
DU Q Y, NI J M, CHEN Q Q, et al. Application of HILOMOT in rapid calibration test of diesel engine [J]. Transactions of CSICE, 2018, 36(4) : 347-352.
- [15] CHRISTIAN M. Stability analysis and controller design of local model networks [M]. Germany: Springer, 2021: 1-3.
- [16] ZHU H X, ZHAO G, SUN L. Local model network based multi-model predictive control for a boiler-turbine system [J]. IFAC-PapersOnLine, 2020, 53 (2) : 12530-12535.
- [17] BESSA J A, BARRETO G A, ROCHA-NETO A R. An outlier-robust growing local model network for recursive system identification [J]. Neural Processing Letters, 2022.
- [18] NELLES O. Axes-oblique partitioning strategies for local model networks [C]. IEEE International Symposium on Intelligent Control, Munich, Germany, 2006: 2378-2383.
- [19] CHRISTOPH H, STEFAN J. Comparison of EM algorithm and particle swarm optimisation for local model network training [C]. IEEE Conference on Cybernetics and Intelligent Systems, Singapore, 2010: 267-272.
- [20] MAHFUZ A, MOHAMMAD A M, MUYEEN S M. Enhancement of the HILOMOT algorithm with modified EM and modified PSO algorithms for nonlinear systems identification [J]. Electronics, 2022, 11(5) : 729.
- [21] JIANG X Y, LI S. BAS: Beetle antennae search algorithm for optimization problems [J]. International Journal of Robotics and Control, 2018, 1(1) : 1-5.
- [22] CHRISTOPH H, STEFAN J. Neuro-fuzzy modelling using a logistic discriminant tree [C]. American Control Conference, 2007: 864-869.
- [23] CHRISTOPH H, UNGER J, STEFAN J. Local model network based dynamic battery cell model identification [C]. 12th WSEAS International Conference on Robotics, Control and Manufacturing Technology, 2012: 116-123.
- [24] SCHAFFNIT J, NELLES O, ISERMANN R. Local liner model tree (lolimot) for nonliner system identification of a turbocharger with variable turbine charger (VTG) [C]. IFAC Proceedings Volumes, California, USA, 2000: 615-620.
- [25] JOHANNES U, CHRISTOPH H, STEFAN J, et al. A novel methodology for non-linear system identification of battery cells used in non-road hybrid electric vehicles [J]. Journal of Power Sources, 2014 (269) : 883-897.
- [26] POTTS D, SAMMUT C. Online nonlinear system identification using linear model trees [C]. 16th Triennial World Congress, Prague, Czech Republic, 2005: 202-207.
- [27] ABTAHI M. Intelligent identification of vehicle's dynamics based on local model network [J]. Journal of AI and Data Mining, 2019, 7(1) : 161-168.
- [28] KHAN A H, CAO X W, XU B, et al. A model-free approach for online optimization of nonlinear systems [J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2022, 69(1) : 109-113.
- [29] KHAN A H, LI S, ZHOU X F. Trajectory optimization of 5-link biped robot using beetle antennae search [J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2021, 68(10) : 3276-3280.
- [30] CHEN D C, LI X, LI S. A novel convolutional neural network model based on beetle antennae search optimization algorithm for computerized tomography diagnosis [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021: 1-12.

作者简介



张振强, 2006 年于山东交通学院获得学士学位, 2009 年于大连理工大学获得硕士学位, 现为山东大学博士研究生, 中级工程师, 主要研究方向为工业无人机电池管理系统和智能优化算法。

E-mail: zhangzq0307@163.com

Zhang Zhenqiang received his B. Sc. degree from Shandong Jiaotong University in 2006, and received his M. Sc. degree from Dalian University of Technology in 2009. He is currently a Ph. D. candidate at Shandong University, as well as an intermediate engineer. His main research interests include industrial UAV battery management system and intelligent optimization algorithms.



马思乐(通信作者), 1985 年于北京工商大学获得学士学位, 2004 年于山东大学获得硕士学位, 2011 年于山东大学获得博士学位, 现为山东大学海洋研究院教授, 主要研究方向为工业过程控制和自动化监测系统。

E-mail: masile@sdu.edu.cn

Ma Sile (Corresponding author) received his B. Sc. degree

from Beijing Technology and Business University in 1985, received his M. Sc. degree from Shandong University in 2004, and received his Ph. D. degree from Shandong University in 2011. He is currently a professor at Institute of Marine Science and Technology, Shandong University. His main research interests include industrial process control and automatic surveillance systems.



陈纪旸, 2013 年于山东大学获得学士学位, 2017 年于山东大学获得硕士学位, 现为山东大学博士研究生, 山东正中信息技术股份有限公司高级工程师, 主要研究方向为生产过程自动化、深度学习、计算机视觉等。

E-mail: chenjiyang@sdu.edu.cn

Chen Jiyang received his B. Sc. degree from Shandong University in 2013, and received his M. Sc. degree from Shandong university in 2017. He is currently a Ph. D. candidate at Institute of Marine Science and Technology, Shandong University, as well as the senior engineer of Shandong Zhengzhong Information Technology Co., Ltd. His main research interests include manufacturing process automation, deep learning, computer vision, etc.