

矿用场景下采用深度学习-安时积分 云边协同的锂电池荷电状态估计

申勇^{1,2} 杨雨康² 邹奇艺² 王成龙³ 熊良潜² 刘东² 曹凤金² 章
翔峰¹

(1.新疆大学智能制造现代产业学院,830047,乌鲁木齐;2.长沙矿山研究院有限责任公司
金属矿山安全技术国家重点实验室,410012,长沙;3.厦门理工学院机械与汽车工程
学院,361021,福建厦门)

摘要: 为提升矿用新能源车辆的安全性能,进一步提高锂电池荷电状态(SOC)估计精度,面向矿用场景提出了一种融合深度学习的云边协同SOC估计框架及算法。首先,在边端通过电池管理系统进行参数采集,通过安时积分法实现本地SOC估算;其次,在云端构建双向长短期记忆网络与多头注意力机制的混合神经网络模型,并引入蜣螂优化算法优化模型超参数组合;最后,通过自适应无迹卡尔曼滤波融合云边数据校正SOC估计。模型通过US06、FUDS、DST工况对其有效性及性能进行测评。研究结果表明:云端模型性能较为良好,可有效实现SOC估算,FUDS工况下平均绝对误差为0.36%,均方根误差为0.50%,DST工况下平均绝对误差为0.40%,均方根误差为0.57%;云边融合模型进一步实现了SOC校正,FUDS工况下,较云端算法平均绝对误差和均方根误差分别降低了28.5%和37.9%,在DST工况下分别降低了26.9%和39.4%,模型具备一定的泛化性及鲁棒性。云边框架可为矿用场景下,锂电池SOC估计的工程应用提供理论参考,云边融合模型为提升矿用锂电池SOC预测精度提供实践路径。

关键词: 锂电池; 荷电状态; 安时积分法; 双向长短期记忆网络; 自适应无迹卡尔曼滤波

中图分类号: TM912.9;TD63 **文献标志码:** AA

文章编号: 0253-987X(XXXX)XX-0001-18

A Cloud-Edge Collaborative State of Charge Estimation Method for Lithium-Ion Batteries in Mining Environments Integrating Deep Learning and Ampere-Hour Integration

SHEN Yong^{1,2}, YANG Yukang², ZOU Keyi², WANG Chenglong³, XIONG Liangqian², LIU
Dong², CAO Fengjin², ZHANG Xiangfeng¹

(1. School of Intelligent Manufacturing and Modern Industry, Xinjiang University, Urumqi
830047, China;

2. State Key Laboratory of Safety Technology of Metal Mines, Changsha Institute of Mining
Research Co. Ltd., Changsha 410012, China;

3. School of Mechanical and Automotive Engineering, Xiamen University of Technology,
Xiamen, Fujian 361021, China)

收稿日期:2026-03-04。

Abstract: To enhance the safety performance of mining new energy vehicles and further improve the estimation accuracy of lithium battery state of charge (SOC), this study proposes a cloud-edge collaborative SOC estimation framework and algorithm integrating deep learning for mining scenarios. At the edge end, parameters are collected through the battery management system, and local SOC estimation is performed using the ampere-hour integration method. In the cloud, a hybrid neural network model combining a bidirectional long short-term memory network and a multi-head attention mechanism is constructed, and the dung beetle optimization algorithm is introduced to optimize the hyperparameter combination of the model. Finally, adaptive unscented Kalman filtering is used to fuse cloud and edge data for SOC estimation correction. The effectiveness and performance of the model are evaluated under US06, FUDS, and DST operating conditions. The results show that the cloud-based model performs well and can effectively estimate SOC. Under FUDS conditions, the mean absolute error is 0.36% and the root mean square error is 0.50%; under DST conditions, the mean absolute error is 0.40% and the root mean square error is 0.57%. The cloud-edge fusion model further achieves SOC correction. Compared with the cloud-based algorithm, the mean absolute error and root mean square error are reduced by 28.5% and 37.9%, respectively, under FUDS conditions, and by 26.9% and 39.4%, respectively, under DST conditions. The model demonstrates a certain degree of generalization ability and robustness. The proposed cloud-edge framework can provide theoretical reference for the engineering application of lithium battery SOC estimation in mining scenarios, while the cloud-edge fusion model offers a practical approach for improving SOC prediction accuracy of mining lithium batteries.

Keywords: lithium-ion batteries; state of charge; Ampere-hour integration method; bidirectional long short-term memory; adaptive unscented Kalman filter

随着“双碳”目标持续推进及新质生产力的蓬勃发展,智能化新能源装备在矿山应用日益广泛。锂电池具备能量密度高、无记忆效应等优势^[1],已成为新能源矿山装备首选动力源。然而,矿山井下空间受限、通风条件有限,锂离子电池风险防控在装备运行中更是处于首要地位^[2]。高精度的SOC估计可有效避免锂电池过充、过放、一致性差等引发的事故发生。因此,提高锂离子SOC估计精度对矿用新能源装备可靠运行具有重要意义。

目前,SOC估计常用方法有安时

积分法(AHI)^[3]、基于模型的方法^[4-5]以及数据驱动法^[6]。AHI属于一种开环估计方法,其精度受累积误差影响。学者们为充分发挥安时积分法轻便化优势,提出了多种优化思想。陈继永等^[7]采用分段开路电压对SOC进行周期性校正,以提高矿用机车电池管理系统(BMS)的SOC估算精度。罗勇等^[8]考虑充放电倍率、库伦效率、温度等对锂电池容量的影响,提出了一种基于容量修正的安时积分SOC估算方法。丁镇涛等^[9]提出了一种安时积分法结合无迹卡尔曼滤波联合估算方法,弥补了90%

~100%SOC时的估算缺陷。李昆等^[10]提出了一种基于频繁项统计流-AHI的SOC估算方法,以此削弱了AHI的电量累积误差。

随着数据规模及复杂程度的增加,近年来国内外学者围绕数据驱动法开展了大量研究。考虑SOC估算属于典型时间序列预测,Yang等^[11]采用循环神经网络进行了不同温度下的SOC估计。Chemali等^[12]通过长短期记忆网络(LSTM)模型解决了锂电池SOC的长时序预测问题。Bian等^[13]提出了一种堆叠双向的长短期记忆网络(BiLSTM)模型,并通过实验验证了该模型的预测精度。陈继斌等^[14]提出了一种将卷积神经网络(CNN)与BiLSTM模型联合的SOC估算方法,验证了双向结构对预测性能的贡献。虽然基于时间序列的SOC预测方法可以捕获数据连续变化关系,但面对高维数据输入仍难以筛选出关键输入特征^[15]。因此,丁伟等^[16]采用将CNN、BiLSTM模型及注意力机制(AM)相结合的方法实现了电动装载机电池SOC估计。张林等^[17]提出了一种用一维卷积神经网络与门控循环单元相结合的全生命周期锂电池SOC估计方法。高俊东等^[18]为提升模型特征提取能力,在LSTM基础上融合了多头自注意力机制,验证了复杂非线性关系影响下方法的有效性。数据驱动方法在锂电池SOC估计应用日益广泛,且预测精度也不断提升。然而,矿山新能源车辆受BMS算力约束,数据驱动法在边端

应用层面存在实时性差等问题;同时,矿用装备作业场所广、通信条件恶劣,以此仅依靠云端估算存在可靠性弱等问题。以上均限制了数据驱动法在矿用场景高效应用。

综上所述,为提高SOC实时估算精度,防止井下通信异常预警失效,充分发挥矿用装备BMS边端优势,有机结合云端计算资源,搭建云边协同框架。首先,在边端以BMS为硬件基础,布置AHI对锂电池SOC进行实时估算,确保边端预警的实时性、可靠性;其次,在云端布置混合神经网络模型,构建蜣螂优化(DBO)算法-BiLSTM-多头注意力机制(MHA)的模型框架,融合BiLSTM模型时序的依赖建模与MHA算法的关键信息提取优势,通过算法的全超参数优化,提高SOC估算精度,建立自适应无迹卡尔曼滤波(AUKF)融合模型校正SOC精度;最后,通过校正值反馈修正边端初始值,抑制累计误差,形成云边协同SOC闭环估算模型框架。

1 AHI-混合神经网络-AUKF模型

1.1 基于安时积分法的边端SOC估算

AHI具备成本低廉、实现简单、可操作性高等优点,被广泛应用于BMS中。同时,由于其计算量小,亦符合边端计算轻量化要求,其核心遵循电荷守

恒定律,即通过对比锂电池在充放电过程中累积充进与放出电量。假设锂电池初始状态为 S_n , t 时刻荷电状态 S_{soc} 计算过程的表达式为

$$S_{\text{soc}} = S_n - \frac{1}{C_n} \int_0^t i(t) dt \quad (1)$$

式中: C_n 为锂电池额定容量; $i(t)$ 为 t 时刻的充、放电电流。

1.2 云端 DBO-BiLSTM-MHA 混合深度学习的

SOC 估算

1.2.1 双向长短期记忆神经网络

LSTM模型可有效解决循环神经网络计算中梯度爆炸及消失的现象^[19]。BiLSTM在其基础上引入双向处理机制,以提高其结果准确性,其模型结构如图1所示。图中, $\vec{h}$ 、 $\overleftarrow{h}$ 分别为向前传播、向后传播LSTM的状态量; h' 为隐藏层的状态量; Y 为BiLSTM输出量; X 为正向和反向输入量。




图1 BiLSTM结构示意图

Fig. 1 Schematic diagram of the BiLSTM structure

LSTM为BiLSTM的基本单元之一,由遗忘门、输入门以及输出门3部分构成。

遗忘门可过滤SOC估算的弱相关信息,决定特征通过量的表达式为

$$f_t = \sigma[W_f(h_{t-1}, x_t) + b_f] \quad (2)$$

式中: f_t 为 t 时刻遗忘门的输出量; σ 为Sigmoid函数; W_f 为遗忘门权重矩阵; h_{t-1} 为 $t-1$ 时刻(即上一时刻)的输出状态量; x_t 为 t 时刻的输入特征, b_f 为遗忘门的偏置向量。

输入门将新特征信息输入至当前记忆细胞中,并更新记忆细胞信息,此过程可表达为

$$C_t = f_t C_{t-1} + \sigma \tanh[W_c(h_{t-1}, x_t) + b_c] \quad (3)$$

式中: C_t 、 C_{t-1} 分别为 t 、 $t-1$ 时刻,记忆单元保留的SOC重要特征信息; W_c 为输入门权重矩阵; b_c 为输入门的偏置向量。

输出门控制当前时刻信息输出的表达式为

$$h_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \tanh(C_t) \quad (4)$$

式中: h_t 为 t 时刻的状态量, W_o 为输出门权重矩阵; b_o 为输出门的偏置向量。

2 个时序相反的LSTM模块通过隐藏层的双向LSTM模块实现连接,其变换过程可表

示为

$$\begin{cases} \vec{h}_t = \vec{f}(\mathbf{W}_{a1}x_t + \mathbf{W}_{a2}\vec{h}_{t-1}) \\ \vec{h}_t = \vec{f}(\mathbf{W}_{b1}x_t + \mathbf{W}_{b2}\vec{h}_{t-1}) \\ h'_t = f'(\mathbf{W}_{c1}\vec{h}_t + \mathbf{W}_{c2}\vec{h}_t) \end{cases} \quad (5)$$

式中: $\vec{f}$ 、 $\vec{f}$ 、 f' 分别为向前、向后、隐藏层的激活向量; $\mathbf{W}_{a1}$ 、 $\mathbf{W}_{a2}$ 分别为向前传播过程中,输入特征权重矩阵及上一时刻输出状态值权重矩阵; $\mathbf{W}_{b1}$ 、 $\mathbf{W}_{b1}$ 分别为向后传播过程中,输入特征权重矩阵及上一时刻输出状态值权重矩阵; $\mathbf{W}_{c1}$ 、 $\mathbf{W}_{c2}$ 分别为隐藏层,输入特征权重矩阵及上一时刻输出状态值权重矩阵。

则 t 时刻的 BiLSTM 输出量可表示为

$$\mathbf{Y}_t = \mathbf{w}_t h'_t \quad (6)$$

式中: $\mathbf{w}_t$ 为 t 时刻的状态值权重矩阵;

1.2 2 双多头注意力机制

注意力机制可有效捕捉时间序列中,长距离依赖关系,并能自适应聚焦输入序列的有效信息^[20]。MHA 作为注意力机制的一种改进,可多维度捕捉序列信息^[21],因此获得的信息更加全面,其基本结构如图2所示。图中, r 为查询、键、值的组数。

基于上阶段输入生成 r 组查询 Q_i 、键 K_i 以及值 V_i ,采用点积法计算 Q_i 与 K_i 的相关性,以此得到每组向量的注意力得分 S_i 的表达式为

$$S_i = Q_i K_i \quad (7)$$

在此基础上,通过 softmax 激活函数得到注意力权重矩阵 $\mathbf{a}_i$,即




图2 多头注意力机制结构示意图

Fig. 2 Schematic diagram of the multi-head attention structure

$$\mathbf{a}_i = \text{softmax}(s_i) \quad (8)$$

将注意力权重矩阵 $\mathbf{a}_i$ 与值 V_i 相乘,并进行加权求和,加权和 Z_i 的表达式为

$$Z_i = \sum \mathbf{a}_i V_i \quad (9)$$

将 r 组 Z_i 拼接后进行线性变换得到输出 Z 的表达式为

$$Z = \text{concat}(Z_1, Z_2, \dots, Z_r) \quad (10)$$

式中: $\text{concat}(\cdot)$ 为拼接函数,用于将各组注意力输出 Z_i 在特征维度上进行拼接。

1.2 3 蜚螂优化算法

Xue 等^[22]提出了一种模拟蜚螂生物行为(包括滚球、舞蹈、觅食、窃取及繁殖)的群体智能算法,以实现非线性解空间的快速寻优,其优化过程如图3所示,主要包括以下5个步骤^[23]。

(1) 初始化蜚螂种群,分配滚球蜚螂、繁殖蜚螂、小蜚螂、小偷蜚螂的比例、最大迭代次数及位置边界;




图3 蜣螂优化算法流程图

Fig. 3 Flowchart of dung beetle optimizer algorithm

- (2) 计算每种蜣螂的适应度值;
- (3) 按照4种蜣螂行为进行位置更新;
- (4) 判断更新后个体是否存在越界行为;
- (5) 判断是否满足迭代条件, 并输出结果。

其中, 步骤(3)的位置更新通过以下行为进行更新。

(1) 滚球行为

蜣螂滚球时通过天线搜索方式进行位置更新, 可表示为

$$\begin{cases} p_j(m+1) = p_j(m) + \alpha k p_j(m-1) + b \Delta p \\ \Delta p = |p_j(m) - w| \end{cases} \quad (11)$$

式中: m 为当前位置的迭代次数; $p_j(m)$ 为 j 号蜣螂在第 m 次迭代时的位置更

新; α 为1或-1 (1表示原始方向, -1表示偏离原始方向); $k \in (0, 0.2]$, 为位置偏移因子; $b \in (0, 1]$ 为自然系数; Δp 为与全局最差位置 w 的距离差, 以反应光强变化, Δp 值越大即光强越弱, 刺激蜣螂避开该位置。

(2) 舞蹈行为

当蜣螂遇到障碍物时, 将通过跳舞获得新路线, 此过程可表示为

$$p_j(m+1) = p_j(m) + \tan \theta |p_j(m) - p_j(m-1)| \quad (12)$$

式中: $\theta \in (0, \pi]$ 为蜣螂舞蹈方向偏转角; $|p_j(m) - p_j(m-1)|$ 为 j 号蜣螂在第 m 次迭代与上次迭代之间的差异。

(3) 繁殖行为

DBO算法采用边界选择策略模拟繁殖蜣螂产卵区域, 其下边界 L_b 与上边界 U_b 表示为

$$\begin{cases} L_b = \max(x^*(1-R), L) \\ U_b = \min(x^*(1+R), U) \end{cases} \quad (13)$$

$$R = 1 - \frac{m}{T_{\max}} \quad (14)$$

式中: x^* 为局部最优解; R 为惯性权值; $T_{\max}$ 为最大迭代次数; L 、 U 分别为优化问题的下界与上界。

卵球在产卵区域可表示为

$$B_j(m+1) = x^* + b_1 \odot (B_j(m) - L_b) + b_2 \odot (B_j(m) - U_b) \quad (15)$$

式中: $B_j(m)$ 为第 j 个卵球在第 m 次迭代的位置信息; b_1 、 b_2 为2个取值在 $(0, 1)$ 的 D 维随机向量, $\odot$ 为 Hadamard 积符号, 表示对应元素逐一相乘的运算。

(4) 觅食行为

小蛻螂逐渐搜索各觅食区域, 以此构建最优觅食区, 觅食边界定义式为

$$\begin{cases} \mathbf{L}_f = \max(\mathbf{x}_f(1-R), \mathbf{L}) \\ \mathbf{U}_f = \min(\mathbf{x}_f(1+R), \mathbf{U}) \end{cases} \quad (16)$$

式中: $\mathbf{L}_f$ 、 $\mathbf{U}_f$ 分别为最优觅食区下边界、上边界; $\mathbf{x}_f$ 为觅食区全局最优解。基于此, 更新后的觅食位置可表示为

$$\mathbf{F}_j(m+1) = \mathbf{F}_j(m) + \mathbf{d}_1 \odot (\mathbf{F}_j(m) - \mathbf{L}_f) + \mathbf{d}_2 \odot (\mathbf{F}_j(m) - \mathbf{U}_f) \quad (17)$$

式中: $\mathbf{F}_j(m)$ 为第 j 个小蛻螂在 m 次迭代的觅食位置信息, $\mathbf{d}_1$ 、 $\mathbf{d}_2$ 为 2 个取值在 $(0, 1)$ 的 D 维随机向量, 并服从正态分布。

(5) 窃取行动

部分蛻螂存在窃取行为, 其个体位置可表示为

$$\mathbf{Q}_j(m+1) = \mathbf{x}_f + \mathbf{g} \odot (|\mathbf{Q}_j(m) - \mathbf{x}^*| + |\mathbf{Q}_i(m) - \mathbf{x}_f|) \quad (18)$$

式中: $\mathbf{Q}_j(m)$ 为第 j 个蛻螂在 m 次迭代窃取过程的位置; $\mathbf{g}$ 为正态分布的 D 维随机向量。

1.2 4 DBO-BiLSTM-MHA 云端混合模型构建

构建 DBO-BiLSTM-MHA 云端混合模型, 提高 SOC 估算精度, 模型架构如图 4 所示。




图 4 DBO-BiLSTM-MHA 云端混合模型架构

Fig. 4 DBO-BiLSTM-MHA cloud-hybrid algorithm architecture

模型以锂电池电流、电压以及温度时序信号作为输入。首先, 利用 BiLSTM 层双向循环机制, 深度挖掘 SOC 动态依赖关系; 其次, 通过 MHA 层对关键信息进行进一步自适应聚焦, 增强特性表达能力; 最后, 通过全连接层进行 SOC 估算值的输出, 估算结果计为 Z_{SOC} 。与此同时, 引入 DBO 优化

算法对 BiLSTM-MHA 超参数组合 (学习率, 神经元数, 注意力头数, 正则化系数) 进行搜索优化, 以提升估算稳定性。

1.3 AUKF 云端信息融合的 SOC 校正

云端将边端安时积分法估算结果

O_{SOC} 及云端混合神经网络估计结果 Z_{SOC} , 通过 AUKF 融合处理, 实现 SOC 校正, 计算过程有如下步骤。

(1) 将 O_{SOC} 视为状态量, 则状态方程为

$$\mathbf{x}_k = \mathbf{x}_{k-1} + \mathbf{q} \quad (19)$$

式中: $\mathbf{x}_k$ 、 $\mathbf{x}_{k-1}$ 分别为 k 、 $k-1$ 时刻的 O_{SOC} 值, $\mathbf{q}$ 为过程噪声。

将 Z_{SOC} 视为观测值, 则观测方程为

$$\mathbf{z}_k = \mathbf{z}_{k-1} + \mathbf{v} \quad (20)$$

式中: $\mathbf{z}_k$ 、 $\mathbf{z}_{k-1}$ 分别为 k 、 $k-1$ 时刻的 Z_{SOC} 值, $\mathbf{v}$ 为观测噪声。

(2) 误差变量 $\hat{\mathbf{x}}_0$ 及初始状态协方差矩阵 $\mathbf{P}_0$ 表达式为

$$\begin{cases} \hat{\mathbf{x}}_0 = E[\mathbf{x}_0] \\ \mathbf{P}_0 = E[(\mathbf{x}_0 - \hat{\mathbf{x}}_0)(\mathbf{x}_0 - \hat{\mathbf{x}}_0)^T] \end{cases} \quad (21)$$

式中: $\mathbf{x}_0$ 为初始时刻的 O_{SOC} 值; $E[\cdot]$ 为数学期望算子。

$$\begin{cases} \mathbf{P}_{k+1|k} = \sum_{i=0}^{2n} w_c^{(i)} (\mathbf{x}_{k+1|k}^{(i)} - \hat{\mathbf{x}}_{k+1|k})(\mathbf{x}_{k+1|k}^{(i)} - \hat{\mathbf{x}}_{k+1|k})^T + \mathbf{Q}_k \\ \mathbf{Q}_k = \mathbf{K}_k \mathbf{H}_k \mathbf{K}_k^T \\ \mathbf{H}_k = \frac{1}{M} \sum_{i=k-M+1}^k \mathbf{e}_i \mathbf{e}_i^T \end{cases} \quad (24)$$

式中: $w_c^{(i)}$ 为第 i 个 Sigma 点对应的协方差权重; $\mathbf{Q}_k$ 过程噪声协方差矩阵; $\mathbf{K}_k$ 为 k 时刻卡尔曼增益矩阵; $\mathbf{H}_k$ 为基于误差序列估计得到的噪声协方差矩阵; $\mathbf{e}_k$ 为 k 时刻的预测误差向量; M 为累计新息数量。

(6) 观测变量更新

$$\begin{cases} \mathbf{z}_{k+1|k}^{(i)} = s(\mathbf{x}_{k+1|k}^{(i)}, \mathbf{u}_{k+1}) \\ \hat{\mathbf{z}}_{k+1|k} = \sum_{i=0}^{2n} w_m^{(i)} \mathbf{z}_{k+1|k}^{(i)} \end{cases} \quad (25)$$

(3) 计算 Sigma 点

$$\begin{cases} \mathbf{x}_k^{(i)} = \hat{\mathbf{x}}_k, i=0 \\ \mathbf{x}_k^{(i)} = \hat{\mathbf{x}}_k + \sqrt{(n+\lambda)\mathbf{P}_k}, i=1, 2, \dots, 2n \\ \mathbf{x}_k^{(i)} = \hat{\mathbf{x}}_k - \sqrt{(n+\lambda)\mathbf{P}_k}, i=n+1, \dots, 2n \end{cases} \quad (22)$$

式中: 上标 (i) 为第 i 个 Sigma 点; $\lambda = \delta^2 / (n+l-n)$, n 为状态变量维度, δ 和 l 用于控制 Sigma 点集的分布范围。

(4) 时间更新

$$\begin{cases} \mathbf{x}_{k+1|k}^{(i)} = f(\mathbf{x}_k^{(i)}, \mathbf{u}_k) \\ \hat{\mathbf{x}}_{k+1|k} = \sum_{i=0}^{2n} w_m^{(i)} \mathbf{x}_{k+1|k}^{(i)} \end{cases} \quad (23)$$

式中: $\mathbf{u}_k$ 为 k 时刻的控制输入; $\mathbf{x}_{k+1|k}^{(i)}$ 为第 i 个 Sigma 点经状态方程预测后得到的状态向量; $\hat{\mathbf{x}}_{k+1|k}$ 为 $k+1$ 时刻状态变量预测值; $w_m^{(i)}$ 为第 i 个 Sigma 点对应的均值权重。

(5) 协方差预测值 $\mathbf{P}_{k+1|k}$ 计算

式中: $\mathbf{z}_{k+1|k}^{(i)}$ 为预测观测值; $\hat{\mathbf{z}}_{k+1|k}$ 为预测观测值均值。

(7) 卡尔曼增益及误差协方差更新

$$\begin{cases} \mathbf{K}_{k+1} = \mathbf{P}_{xz} \mathbf{P}_{zz}^{-1} \\ \mathbf{P}_{xz} = \sum_{i=0}^{2n} w_c^{(i)} (\mathbf{x}_{k+1|k}^{(i)} - \hat{\mathbf{x}}_{k+1|k})(\mathbf{x}_{k+1|k}^{(i)} - \hat{\mathbf{x}}_{k+1|k})^T \\ \mathbf{P}_{zz} = \sum_{i=0}^{2n} w_c^{(i)} (\mathbf{z}_{k+1|k}^{(i)} - \hat{\mathbf{z}}_{k+1|k})(\mathbf{z}_{k+1|k}^{(i)} - \hat{\mathbf{z}}_{k+1|k})^T + \mathbf{R}_k \end{cases} \quad (26)$$

式中: $\mathbf{P}_{xz}$ 为预测观测协方差; $\mathbf{P}_{zz}$ 为预

测观测方差; $\mathbf{K}_{k+1}$ 为 $k+1$ 时刻卡尔曼增益; $\mathbf{R}_k$ 为 k 时刻测量噪声协方差, 表达式为

$$\mathbf{R}_k = \mathbf{H}_k - \mathbf{C}_k \mathbf{P}_k \mathbf{C}_k^T \quad (27)$$

其中, $\mathbf{C}_k$ 为 k 时刻的观测矩阵, $\mathbf{P}_k$ 为 k 时刻的状态误差协方差矩阵。

(8) 状态变量及协方差矩阵更新

$$\begin{cases} \hat{\mathbf{x}}_{k+1|k} = \hat{\mathbf{x}}_{k+1|k} + \mathbf{K}_{k+1} (\mathbf{z}_{k+1} - \hat{\mathbf{z}}_{k+1|k}) \\ \mathbf{P}_{k+1|k} = \mathbf{P}_{k+1|k} - \mathbf{K}_{k+1} \mathbf{P}_{k+1|k} \mathbf{K}_{k+1}^T \end{cases} \quad (28)$$

联立式 (24)、式 (26)、式 (28) 实现无迹卡尔曼滤波的自适应估计。

1.4 AHI-混合神经网络-AUKF 的云边协同模型构建

面向矿用场景, 结合矿用新能源车辆 (NEVs) 的 BMS 特征构, 构建云边协同框架, 基本框架有如下流程。

(1) 边端布置于矿用 NEVs 的 BMS。BMS 采集从板实现锂电池端电压、温度等参数的实时采集。BMS 主板具备预警、控制等轻量处理功能, 主板通过安时积分法对原始信号 SOC 进行估算, 估算值计为 O_{soc} , 以满足电池及时预警。

(2) 云端布置于算力中心。首先, 基于混合深度神经网络对边端采集的原始电压、电流参数进行 SOC 估算, 得到云端估算值 Z_{soc} , 并将其作为观测量的输入; 其次, 将边端估算值 O_{soc} , 用于构建状态预测过程; 最后, 结合状态预测与观测更新机制, 建立 AUKF 融合模型, 最终输出校正值 F_{soc} 。

3) 边端数据通过 NEVs 车载系统

将原始参数以及 O_{soc} 传输至云端进行 SOC 校准; 云端将 SOC 最终校正值 F_{soc} 返回至车载系统, 以更新 BMS 安时积分法的初始值, 从而抑制累积误差, 提升实时预警精度。

在算法执行层面, 将数据集划分为验证集、训练集以及测试集。在云端, 通过 DBO 算法对验证集进行超参数优化, 得到的最优参数组合赋予训练集的 BiLSTM-MHA 模型。达到最大训练轮次后, 输出并保持 BiLSTM-MHA 模型, 并通过测试集进行预测输出及评价。此后, 通过 AUKF 算法将边端 AHI 的 SOC 估计值共同融合校正, 此后将校正值反馈至边端, 模型计算流程如图 5 所示。




图5 AHI-混合神经网络-AUKF 的云边协同模型计算流程

Fig. 5 Calculation process of AHI-hybrid neural network-AUKF cloud edge collaboration model

2 实验与评价

2.1 数据集描述及评价

为强化工况验证效果并提升模型在矿用NEVs常规场景下的适用性,实验选取US06、FUDS和DST三种工况进行性能测试。其中,US06工况具有高动态和大电流波动特征,可表征重载、加速及坡道等运行状态;FUDS工况以低速、频繁启停为特点,适用于模拟矿用NEVs典型运行模式;DST工况可反映脉冲负载下的动态响应过程,用于验证算法对复杂电流变化的适应能力。模拟过程将10℃、25℃的US06工况按8:2的比例划分为训练集与验证集,将0℃的FUDS工况及DST工况作为测试集,测试集电池状态参数变化曲线如图6所示。


为客观评价模型性能,引入平均绝对误差 E_{MAE} 、均方误差 E_{EMSE} 、均方根误差 E_{ERMSE} 以及决定系数 R^2 这4个评价指标对模型进行综合衡量。

2.2 云端混合神经网络模型对比实验


为验证云端混合神经网络模型主要架构(BiLSTM-MHA)估算性能,将其与Transformer, LSTM, BiLSTM进行性能对比,性能表征如表1、表2所示。

由表1, 2可知,在FUDS工况和DST工况下对比各模型的估算性能,BiLSTM模型整体表现优于Transformer

和LSTM模型;在此基础上,引入MHA后BiLSTM-MHA模型进一步增强了特征表征能力,表现出更高的估算精度和更优的模型性。



(a) 0℃ FUDS 工况



(b) 0℃ DST 工况

图6 测试集电池状态参数变化曲线

Fig. 6 Variation curves of battery state parameters in the test set

表1 FUDS 工况下模型性能对比

Table 1 Comparison of model performance under the FUDS operating condition

模型	$E_{MAE}/\%$	$E_{MSE}/\%$	$E_{RMSE}/\%$	R^2
Transformer	0.91	0.0158	1.26	0.998 12
LSTM	0.62	0.0071	0.85	0.999 15
BiLSTM	0.51	0.0052	0.72	0.999 38
BiLSTM-MHA	0.46	0.0041	0.64	0.999 51

表2 DST工况下模型性能对比

Table 2 Comparison of model performance under the DST operating condition

模型	$E_{MAE}/\%$	$E_{MSE}/\%$	$E_{RMSE}/\%$	R^2
Transformer	0.87	0.0161	1.27	0.998 10
LSTM	0.68	0.0090	0.95	0.998 93
BiLSTM	0.58	0.0069	0.83	0.999 18
BiLSTM-MHA	0.52	0.0055	0.74	0.999 34

在此基础上, 将 BiLSTM-MHA 的

超参数组合(学习率, 神经元数, 注意力头数, 正则化系数)进行优化处理, 分别将灰狼优化算法(GWO)^[24]、哈里斯鹰优化算法(HHO)^[25]与DBO算法与BiLSTM-MHA混合模型组合并进行性能对比, 迭代次数均设置为30, 将随机种子固定为0。FUDS工况下, 性能表征如表3所示。DST工况下, 性能表征如表4所示。

表3 FUDS工况下模型性能对比

Table 3 Comparison of model performance under the FUDS operating condition

模型	$E_{MAE}/\%$	$E_{MSE}/\%$	$E_{RMSE}/\%$	R^2
GWO-BiLSTM-MHA	0.39	0.003 9	0.58	0.999 600
HHO-BiLSTM-MHA	0.39	0.003 0	0.54	0.999 765
DBO-BiLSTM-MHA	0.36	0.002 5	0.50	0.999 700

表4 DST工况下模型性能对比

Table 4 Comparison of model performance under the DST operating condition

模型	$E_{MAE}/\%$	$E_{MSE}/\%$	$E_{RMSE}/\%$	R^2
GWO-BiLSTM-MHA	0.44	0.004 5	0.67	0.999 47
HHO-BiLSTM-MHA	0.43	0.003 7	0.61	0.999 57
DBO-BiLSTM-MHA	0.40	0.003 2	0.57	0.999 62

由表3、表4可知, 相较于GWO、HHO算法, DBO算法对BiLSTM-MHA超参数组合的寻优效果最佳。在FUDS工况下, 其性能指标 E_{MAE} 为0.36%; E_{MSE} 为0.002 5%; E_{RMSE} 为0.50%; R^2 为0.999 700。在DST工况下, 其性能指标 E_{MAE} 为0.40%; E_{MSE} 为0.003 2%; E_{RMSE} 为0.57%; R^2 为0.999 62, 各项指标均有不同程度提升。同时, 通过在不同工况下的测试验证, 结果表明, DBO-BiLSTM-MHA云端模型具有较佳

的鲁棒性和泛化性。

为验证温度对模型的影响, 以US06工况为例, 在将10℃、25℃的US06工况划分为训练集与验证集基础上, 通过0℃的US06工况进行模型测试, 测试结果如表5所示。

由表5可知, 在不同温度的US06工况下, DBO-BiLSTM-MHA模型的各项性能指标均优于其他两种模型, 表明该模型在不同温度条件下具有较强的鲁棒性。

表5 US06工况下模型性能对比

Table 5 Comparison of model performance under the US06 operating condition

模型	$E_{MAE}/\%$	$E_{MSE}/\%$	$E_{RMSE}/\%$	R^2
GWO-BiLSTM-MHA	0.35	0.002 4	0.49	0.999 71
HHO-BiLSTM-MHA	0.35	0.002 2	0.47	0.999 74
DBO-BiLSTM-MHA	0.33	0.001 9	0.44	0.999 77

2.3 DBO-BiLSTM-MHA 云端算法消融实验

为验证 DBO-BiLSTM-MHA 云端模型各模块的必要性,进行了消融实验。实验对比 LSTM、BiLSTM、BiLSTM-MHA 以及 DBO-BiLSTM-MHA 这 4 种模型的预测结果。在 FUDS 工况下和 DST 工况下,消融实验结果分别如图 7、图 8 所示。

由图 7、图 8 可知,使用 LSTM 模型进行 SOC 估算时,其计算性能较差。采用引入双向处理机制的 BiLSTM 模型可有效结合双向信息流,相较于 LSTM 模型,其计算性能大幅提升。在 FUDS 工况下,估算结果性能指标 E_{MAE} 、 E_{MSE} 、 E_{RMSE} 由 0.65%、0.008 1%、0.90%、分别降低至 0.51%、0.005 3%、0.73%; R^2 由 0.999 04 提升至 0.999 37。在 DST 工况下,估算结果性能指标 E_{MAE} 、 E_{MSE} 、 E_{RMSE} 由 0.71%、0.009 6%、0.098%、分别降低至 0.57%、0.006 9%、0.083%; R^2 由 0.999 04 提升至 0.999 19。当使用 DBO 算法对 BiLSTM-MHA 模型超参数组合进行寻优时,会得到最佳参数组合,由此进一步提升模型性能。

为验证模型的必要性及鲁棒性,进


一步分析模型在固定随机种子为 42 时的结果,各模型指标如表 6 所示。

由以上消融实验结果分析可得,云端混合神经网络模型中, BiLSTM、MHA 以及 DBO 在 SOC 估算中具有一定的必要性,且结果具有一定的鲁棒性。


2.4 基于 AHI-混合神经网络-AUKF 的云边协同估计实验结果分析

通过对比实验及消融实验,将性能较优的 DBO-BiLSTM-MHA 模型进行云边融合以实现 SOC 的校正。模型将边端 AHI 估算结果与云端混合神经网络模型通过 AUKF 进行融合校正。在 FUDS 工况下, SOC 估算误差如图 9 所示;在 DST 工况下, SOC 估算误差如图 10 所示, 2 种工况性能指标对比见表 7。

由图 9、图 10 可知,通过云边融合后的 SOC 校正,预测结果波动更小,绝对误差亦大幅降低,预测值与真实值更加贴合。由表 7 可知,在 FUDS 工况和 DST 工况下,其性能指标 E_{MAE} 、 E_{MSE} 、 E_{RMSE} 均有所下降, R^2 均有所提升。



(a) FUDS工况下SOC估算曲线



(b) FUDS工况下SOC估算性能指标

图7 FUDS工况下消融实验结果

Fig. 7 Results of algorithms under FUDS operating conditions

3 结论

为提高矿用场景下SOC的估算精度,提出了一种云边协同的SOC估计算法,并通过US06工况、FUDS工况及DST工况对算法进行验证,得到如下主要结论。


(1) 提出的云端 DBO-BiLSTM-

MHA混合神经网络模型,具备较优的性能,在FUDS工况下, R^2 达到了0.999 70;在DST工况下, R^2 达到了0.999 62。


(2) 提出的AHI-混合神经网络-AUKF的云边协同模型,进一步提高了SOC的估算精度,在FUDS和DST工况下, R^2 分别达到了0.999 89、

0.999 86。在 FUDS 和 DST 工况下， 26.9%和39.4%。

E_{MAE} 和 E_{RMSE} 分别降至 28.5% 和 37.9%、



(a) DST工况下SOC估算曲线



(b) DST工况下SOC估算性能指标

图8 DST工况下消融实验结果

Fig. 8 Results of algorithms under DST operating conditions

(3) 通过不同的工况对比，证明提出的云边协同模型具备泛化性及鲁棒性，云边融合框架可为提高矿用车辆SOC预测精度提供工程应用思路。

表6 随机种子为42时模型性能评价(单位: with random seed of 42)

Table 4 Models performance evaluation

测试工况	模型	$E_{MAE}/\%$	$E_{MSE}/\%$	$E_{RMSE}/\%$	R^2
FUDS 工况	LSTM	0.62	0.007 1	0.85	0.999 15
	BiLSTM	0.51	0.005 2	0.72	0.999 38
	BiLSTM-MHA	0.46	0.004 1	0.64	0.999 51
	DBO-BiLSTM-MHA	0.41	0.003 7	0.61	0.999 56
DST 工况	LSTM	0.68	0.009 0	0.95	0.998 93
	BiLSTM	0.58	0.006 9	0.83	0.999 18
	BiLSTM-MHA	0.52	0.005 5	0.74	0.999 34
	DBO-BiLSTM-MHA	0.28	0.001 6	0.39	0.999 82
US06 工况	LSTM	0.67	0.007 8	0.88	0.999 06
	BiLSTM	0.51	0.005 0	0.71	0.999 39
	BiLSTM-MHA	0.42	0.003 4	0.58	0.999 59
	DBO-BiLSTM-MHA	0.27	0.001 3	0.35	0.999 85




图9 FUDS 工况下模型误差对比结果
Fig. 9 Results of algorithms under FUDS operating conditions




图10 DST 工况下模型误差对比结果
Fig. 10 Results of algorithms under DST operating conditions

表7 2种工况下模型性能评价对比

Table 7 Models performance comparison evaluation under two operating conditions

测试 工况	模型	$E_{MAE}/\%$	$E_{MSE}/\%$	$E_{RMSE}/\%$	R^2
FUDS 工况	DBO-BILSTM-MHA	0.36	0.002 5	0.50	0.999 70
	云边协同模型	0.25	0.001 0	0.31	0.999 89
DST 工况	DBO-BILSTM-MHA	0.40	0.003 2	0.57	0.999 62
	云边协同模型	0.29	0.001 2	0.35	0.999 86

参考文献

[1] 胡循泉,耿莉敏,舒俊豪,等. 采用全局健康因子和残差模型的锂离子电池健康状态估计[J]. 西安交通大学学报,2025,59(04):105-117.
HU Xunquan1, GENG Limin1, SHU Junhao, et al. Esti- mation of Lithium-Ion Bat- tery State of Health Using Global Health Factorand Residual Model [J]. Journal of Xi’ an Jiaotong University, 2025, 59(04): 105-117.

[2] 姚勇征,王奕渊,周福宝. 煤矿井下锂离子蓄电池热失控燃爆风险防控技术研究现状与挑战[J]. 煤炭学报,2025,50(04):2158-2174.DOI:10.13225/j.cnki.jccs.2024.0825.
YAO Yongzheng, WANG Yiyuan, ZHOU Fubao. Research status & chal- lenges on prevention and control technol- ogy for thermal runaway combustion- explosion of lithium-ion battery in coal mines[J]. Journal of China Coal Society, 2025, 50(4): 2158–2174.

[3] 梁叶,蔡孟冶,姜岩峰,等. 基于修正安时积分法的锂电池荷电状态估算[J/OL]. 电 源 学 报 , 1-13 [2026-01-16]. <https://link.cnki.net/urlid/12.1420.TM.20250214.1637.004>.
LIANG Ye, CAI Mengye, JIANG Yanfeng, et al. State of charge estimation of lithium battery based on modified ampere-hour in-

tegral method[J/OL]. Journal of power supply, 1-13[2026-01-16]. <https://link.cnki.net/urlid/12.1420.TM.20250214.1637.004>.

[4] SUN D M. Yx WANG CM. et al State of charge estimation for Lithum-on batery basd on an Intelligent adaptive extended kalman filter with improved noise estima- tor[J]. Energy, 2021, 214:119025.

[5] LI X Y, WANG Z P, ZHANG L. Co- estimation of capacity and state-of-charge for lithium-ion batteries in electric vehicles [J]. Energy, 2019, 174: 33-44.

[6] 吴文进,吴晶,詹文法,等. 基于云端数据的AEKF-LSTM融合算法预测电池SOC [J/OL]. 电子测量与仪器学报, 1-9[2026-01-16]. <https://link.cnki.net/ urlid/ 11.2488. tn.20251224.1801.098>.
WU Wenjin, WU Jing, ZHAN Wenfa, et al. AEKF- LSTM fusion algorithm based on cloud data predicts battery SOC[J/OL]. Journal of Electronic Measurement and In- strumentation, 1-9[2026-01-16]. <https://link.cnki.net/ urlid/ 11.2488. tn.20251224.1801.098>.

[7] 陈继永,吴兆宏,李金喜. 矿用机车防爆锂 电池 SOC 估算算法[J]. 煤矿安全, 2019, 50(12): 102-105. DOI: 10.13347/ j. cnki. mkaq.2019.12.023.
CHEN Jiyong, WU Zhaohong, LI Jinxi. SOC Estimation Algorithm for Mine Loco-

- motive Explosion-proof Lithium Battery [J]. Safety in coal mines, 2019, 50(12): 102-105. DOI: 10.13347/j.cnki.mkaq.2019.12.023.
- [8] 罗勇,祁朋伟,黄欢,等. 基于容量修正的安时积分SOC估算方法研究[J]. 汽车工程, 2020, 42(05): 681-687. DOI: 10.19562/j.chinasae.qcgc.2020.05.017.
- Luo Yong, Qi Pengwei, Huang Huan, et al. Study on battery SOC estimation by ampere-hour integral method with capacity correction [J]. Automotive Engineering, 2020, 42(05): 681-687. DOI: 10.19562/j.chinasae.qcgc.2020.05.017.
- [9] 丁镇涛,邓涛,李志飞,等. 基于安时积分和无迹卡尔曼滤波的锂离子电池SOC估算方法研究[J]. 中国机械工程, 2020, 31(15): 1823-1830.
- DING Zhentao, DENG Tao, LI Zhifei, et al. SOC Estimation of Lithium-ion Battery Based on Ampere Hour Integral and Unscented Kalman Filter[J]. China mechanical engineering, 2020, 31(15): 1823-1830.
- [10] 李昆,赵理,赵博阳,等. 基于频繁项统计的流-安时积分SOC估计方法[J]. 重庆理工大学学报(自然科学), 2022, 36(03): 19-27.
- LI Kun, ZHAO Li, ZHAO Boyang, et al. SOC estimation method of flow-ampere-hour integral based on frequent item statistics [J]. Journal of Chongqing University of Technology (Natural Science), 2022, 36(3): 19-27.
- [11] Yang F, Li W, Li C, et al. State-of-charge estimation of lithium-ion batteries based on gated recurrent neural network[J]. Energy, 2019, 175(MAY 15): 66-75. DOI: 10.1016/j.energy.2019.03.059.
- [12] CHEMALI E, KOLLMEYER P J, PREINDL M, et al. Long short-term memory networks for accurate state-of-charge estimation of Li-ion batteries[J]. IEEE Transactions on Industrial Electronics, 2017, 65(8): 6730-6739.
- [13] BIAN Chong, HE Huoliang, YANG Shunkun. Stacked bidirectional long short-term memory networks for state-of-charge estimation of lithium-ion batteries [J]. Energy, 2020, 191: 116538.
- [14] 陈继斌,李雯雯,孙彦玺,等. 基于卷积-双向长短期记忆网络的电池SOC预测[J]. 电源技术, 2022, 46(05): 532-535.
- CHEN Jibin, LI Wenwen, SUN Yanxi, et al. Battery SOC prediction based on convolution bidirectional long term and short term memory network[J]. Chinese journal of power sources, 2022, 46(05): 532-535.
- [15] 杜伟,王圣,李健,等. 基于CNN-LSTM-AM模型的储能锂离子电池荷电状态预测[J]. 电工技术学报, 2025, 40(09): 2982-2995. DOI: 10.19595/j.cnki.1000-6753.tces.240706.
- Du Wei, Wang Sheng, Li Jian, et al. Prediction of State of Charge for Energy Storage Lithium-Ion Batteries Based on CNN-LSTM-AM Model. [J]. Transactions of China Electrotechnical Society, 2025, 40(09): 2982-2995. DOI: 10.19595/j.cnki.1000-6753.tces.240706.
- [16] 丁伟,邹复民,刘吉顺,等. 基于CNN-BiLSTM-Attention的电动装载机电池荷电状态预测[J/OL]. 电源学报, 1-12[2026-03-04]. <https://link.cnki.net/urlid/12.1420.TM.20240426.1024.024>
- DING Wei, ZOU Fumin, LIU Jishun, et al. State-of-charge prediction of electric loader battery based on CNN- BiLSTM-

- Attention[J/OL]. Journal of power supply, 1-12[2026-03-04]. <https://link.cnki.net/urlid/12.1420.TM.20240426.1024.024>.
- [17] 张林,巫春玲,黄鑫蓉,等.采用深度学习的全寿命周期锂电池荷电状态估计[J].西安交通大学学报,2024,58(10):36-43.
ZHANG Lin, WU Chunling, HUANG Xinrong, et al. Deep learning-based State-of-Charge estimation for Lithium-Ion batteries across the entire life cycle[J]. Journal of Xi'an Jiaotong University, 2024, 58(10):36-43.
- [18] 高俊东,马志强,刘广忱,等.融合MHSA的锂电池SOC估计[J].太阳能学报,2025, 46(3): 16-24. DOI: 10.19912/j.0254-0096.tynxb.2023-1759.
Gao Jundong, Ma Zhiqiang, Liu Guangchen, et al. Fusion of mhSA lithium battery soc estimates [J]. Acta Energaie Solaris Sinica, 2025, 46(3): 16-24. DOI: 10.19912/j.0254-0096.tynxb. 2023-1759.
- [19] Lu Wenjie, Li Jiazheng, Wang Jingyang, et al. A CNN-BiLSTM-AM method for stock price prediction[J]. Neural Computing and Applications, 2021, 33(10): 4741-4753
- [20] 刘自兵,崔双喜,刘庆庆.基于融合多尺度卷积与多头注意力机制的WGAN-GP新能源场景生成方法[J].电网技术,2026,50(01):272-283.DOI:10.13335/j.1000-3673.pst.2025.1065.
LIU Zibing, CUI Shuangxi, LIU Qingqing. New energy scenario generation method based on an improved WGAN-GP integrating multi-scale convolution and Multi-head Attention mechanisms [J]. Power system technology, 2026, 50(01): 272-283. DOI: 10.13335/j.1000-3673.pst.2025.1065.
- [21] 汪强,李清阳,席磊,等.融合多头注意力机制的LSTM冬小麦需水量预测[J].中国农业大学学报,2025,30(04):38-50.
Wang Qiang, Li Qingyang, Xi Lei, et al. LSTM winter wheat water demand prediction based on multihead attention mechanism [J]. Journal of China Agricultural University, 2025, 30(04):38-50.
- [22] XUE J K, SHEN B. Dung beetle optimizer: a new metaheuristic algorithm for global optimization[J]. The journal of supercomputing, 2023, 79 (7): 7305-7336.
- [23] Yang K, Wang B, Gong Z, et al. Temperature collaborative control strategy using dung beetle optimizer in proton exchange membrane fuel cell system[J]. Renewable Energy, 2026, 256(pa): 123946. DOI: 10.1016/j.renene.2025.123946.
- [24] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer[J]. Advances in engineering software, 2014, 69: 46-61.
- [25] Aaha B, Sm C, Hf D, et al. Harris hawks optimization: Algorithm and applications [J]. Future Generation Computer Systems, 2019, 97:849-872.