

DOI: 10.13718/j.cnki.xdzk.2024.12.005

洪吉超, 裴佳琦, 梁峰伟, 等. 基于麻雀搜索优化 LSTM 的实车动力电池 SOC 估计研究 [J]. 西南大学学报(自然科学版), 2024, 46(12): 41-50.

基于麻雀搜索优化 LSTM 的 实车动力电池 SOC 估计研究

洪吉超^{1,2}, 裴佳琦^{1,2}, 梁峰伟^{1,2},
李萌^{1,2}, 邱余龙^{1,2}, 张磊^{1,2}

1. 北京科技大学 机械工程学院, 北京 100083; 2. 北京科技大学 顺德创新学院, 广东 佛山 528000

摘要: 随着电动汽车技术的迅猛发展, 准确评估电池的荷电状态(State of Charge, SOC)对于保障车辆性能和安全至关重要. 针对现有 SOC 估计方法的不足, 提出了基于麻雀搜索算法进行参数优化的长短期记忆(Long and Short-Term Memory, LSTM)神经网络模型. 首先通过实车数据采集与预处理, 构建了包含多种实车运行参数的数据库, 并利用信息熵和互信息理论对数据进行特征筛选, 以识别与 SOC 高度相关的特征. 然后将筛选出的特征输入到长短期记忆神经网络模型中, 并使用麻雀搜索算法对模型参数进行优化. 研究表明: 该模型在多种驾驶工况和不同的充放电环境下均能实现高精度的 SOC 估计, 验证了 SOC 估计的准确性和鲁棒性, 为电池管理系统的发展提供了有力的技术支持.

关键词: 电动汽车; 荷电状态估计; 数据驱动; 神经网络;
优化算法

中图分类号: TK01

文献标志码: A

开放科学(资源服务)标识码(OSID):



文章编号: 1673-9868(2024)12-0041-10

Research on Real Vehicle Power Battery SOC Estimation Based on Sparrow Search Optimized LSTM

HONG Jichao^{1,2}, PEI Jiaqi^{1,2}, LIANG Fengwei^{1,2},
LI Meng^{1,2}, QIU Yulong^{1,2}, ZHANG Lei^{1,2}

1. School of Mechanical Engineering, University of Science and Technology Beijing, Beijing 100083, China;

2. Shunde Innovation School, University of Science and Technology Beijing, Foshan Guangdong 528000, China

Abstract: With the rapid development of electric vehicle technology, accurately assessing the state of

收稿日期: 2024-09-30

基金项目: 国家自然科学基金项目(52107220); 广东省自然科学基金项目(2024A1515012804).

作者简介: 洪吉超, 博士, 副教授, 主要从事新能源动力与储能系统集成设计、大数据分析应用与全寿命周期智能管理研究.

charge (SOC) of the battery is crucial for ensuring vehicle performance and safety. In response to the shortcomings of existing SOC estimation methods, this study proposes a long and short-term memory (LSTM) neural network model based on the sparrow search algorithm (SSA) for optimization of the parameters. The research first constructed a database that included a variety of vehicle operation parameters through real vehicle data collection and preprocessing. Then, the data was feature-filtered using information entropy and mutual information theory to identify features highly related to SOC. Next, the selected features were input into the LSTM neural network model, and the sparrow search algorithm was used to optimize the model parameters. The results show that the model can achieve high-precision SOC estimation under various driving conditions and different charging and discharging environments. Therefore, the proposed method verifies the accuracy and robustness of SOC estimation, providing strong technical support for the development of battery management system.

Key words: electric vehicle; SOC estimation; data-driven; neural network; optimization algorithm

随着全球能源危机的加剧以及环境污染问题的日益严峻,电动汽车(Electric Vehicle, EV)作为减少温室气体排放和实现可持续交通的重要解决方案,其市场渗透率在近年来显著提升.作为电动汽车核心组件的动力电池,其性能和寿命直接决定了电动汽车的整体性能和使用寿命.荷电状态(State of Charge, SOC)作为评估电池当前电量的关键指标,对于电池管理系统(Battery Management System, BMS)以及电动汽车的安全性和可靠性起到至关重要的作用.近年来,全球电动汽车市场呈现爆炸式增长,根据国际能源署(International Energy Agency, IEA)的数据显示,2021年全球电动汽车销量超过660万辆,较2020年增长了约100%^[1].预计该增长趋势在未来几年将持续,电动汽车的普及对电池技术提出了更高的要求.在电池技术领域,研究人员正积极致力于提升电池的能量密度、循环寿命和安全性,以满足电动汽车对长续航和高可靠性的需求.同时,BMS的智能化也成为当前研究的热点,其中SOC的准确估计对BMS的功能至关重要.SOC作为衡量电池当前电量的重要指标,直接影响电动汽车的续航能力和电池使用寿命,其公式如式(1)所示:

$$S_{\text{SOC}} = \frac{Q_{\text{remain}}}{Q_{\text{rated}}} \quad (1)$$

式中: Q_{remain} 表示剩余电量; Q_{rated} 表示额定容量; S_{SOC} 表示当前电池 SOC 的具体值,通常以百分比的形式表示.

电池 SOC 是 BMS 中核心参数之一,其准确性对电动汽车的续航里程、性能表现、安全性以及电池的使用寿命具有显著影响.准确监测和估计 SOC 对于优化电池使用、延长电池寿命以及防止电池发生过充和过放现象至关重要.目前,电池 SOC 估计和预测的研究主要集中在传统 SOC 预测方法、基于模型的方法、数据驱动的方法以及混合方法等方面.传统 SOC 预测方法主要有安时积分法、开路电压法和电流积分结合开路电压法.安时积分法是通过电池的充放电电流进行积分来计算 SOC 的方法,是电池研究中最常用的 SOC 估计方法^[2],其公式如式(2)所示:

$$S_{\text{SOC}}(t) = S_{\text{SOC}}(t_0) + \frac{1}{Q_n} \int_{t_0}^t i(\tau) d\tau \quad (2)$$

式中: $S_{\text{SOC}}(t)$ 为 t 时刻的 SOC 估计值; $S_{\text{SOC}}(t_0)$ 为初始 SOC 值; Q_n 为电池的额定容量; $i(\tau)$ 为 τ 时刻的电池电流.

安时积分法因其操作简单和易于实现而被广泛使用,但该方法对电流测量精度高度依赖^[3],且未能充分考虑电池自放电和环境因素,导致在快速充放电过程中动态响应滞后,限制了其在复杂应用场景中的准确性和可靠性^[4].开路电压法(Open Circuit Voltage, OCV)是一种通过测量电池的开路电压与 SOC 之间

的对应关系估算 SOC 的方法^[5]. 该方法的优点在于操作简单, 但需要电池在无负载状态下进行测量, 故在实际应用中较为不便^[6]. 因此, 为了提高 SOC 估算的准确性, 研究者们提出了一种结合安时积分法和开路电压法的混合方法, 该方法通过加权 2 种方法的 SOC 读数提高估算的准确性, 克服了单一方法的局限性, 提高了 SOC 估算的精度.

基于模型的方法主要采用等效电路模型(Equivalent Circuit Model, ECM)、电化学模型等, 通过模拟电池电化学过程进行 SOC 预测, 此类方法在理论上具有较高的准确性, 但对模型参数的依赖性较强, 且计算复杂^[7-8]. 常用的基于模型的方法有卡尔曼滤波法, 该方法结合了安时积分法和开路电压法的优点, 通过递推方法得到 SOC 的最小方差估计. 卡尔曼滤波法能够根据电池的电压和电流输入, 实时修正 SOC 估算值, 适用于在线估算. Peng 等^[9]提出了一种改进的容积卡尔曼滤波, 在没有初始 SOC 值的情况下使用改进的容积卡尔曼滤波进行 SOC 估计, 实验证明该方法相较于扩展卡尔曼滤波有更好的效果.

基于数据驱动的方法主要有支持向量机(Support Vector Machine, SVM)、人工神经网络(Artificial Neural Network, ANN)、长短期记忆(Long and Short-Term Memory, LSTM)网络等, 该方法的共性是利用历史数据进行模型的训练, 具有较好的适应性和灵活性, 但需要大量的数据支持, 且对数据质量要求较高^[10-11]. 张越^[12]提出一种利用灰狼优化算法对 SVM 惩罚参数和高斯核函数宽度系数进行优化的方法, 提升了 SVM 在 SOC 估计中的估计速度和精度, 该方法的优势在于灰狼优化算法的群体智能特性能够有效地搜索全局最优解, 同时通过模拟灰狼的社会等级和狩猎行为, 能够实现对 SVM 参数的精确调整, 提高模型的泛化能力和预测精度, 但该方法存在的不足是灰狼优化算法在某些情况下会陷入局部最优解, 且对于参数的依赖性较强, 需要适当调整以避免早熟收敛.

混合方法结合了模型方法和数据驱动方法的优点, 旨在提高 SOC 估计的准确性和鲁棒性^[13]. 近年来, 随着深度学习技术的发展, 基于深度学习的方法在 SOC 估计中显示出了巨大的潜力. 深度学习模型能够自动提取电池数据中的复杂特征, 无需依赖复杂的物理模型, 在某种程度上简化了 SOC 估计过程. 此外, 一些研究者还尝试将深度学习与基于模型的方法相结合, 以进一步提高 SOC 估计的准确性. Jia 等^[14]提出了一种基于改进 Borges 分形导数的 LSTM 网络优化算法, 用于电池 SOC 估计, 该算法将传统 Adam 算法中的整数阶导数扩展为改进的 Borges 分数阶导数, 以提高 SOC 估计的准确性. 实验结果表明, 在不同工作条件下, 与标准 Adam 算法相比, 提出的 Adam-IB 算法在 SOC 估计方面具有显著的优越性. 但该算法在处理极端或非典型工作条件下的数据时存在局限性, 且对参数的依赖性较强, 需要针对特定电池特性进行调整.

鉴于现有 SOC 估计方法的局限性, 本研究提出了一种基于麻雀搜索算法(Sparrow Search Algorithm, SSA)优化的 LSTM 神经网络模型, 用于提高电动汽车动力电池 SOC 的估计精度. SSA 作为一种新兴的群体智能优化算法, 模拟了麻雀的觅食行为, 展现出优异的全局搜索与局部搜索能力^[15]. 通过将 SSA 与 LSTM 结合, 提升了模型的优化效率, 显著增强了模型对电动汽车复杂工况的适应性. 此外, SSA 优化的 LSTM 模型在应对电池老化和环境变化方面表现出色, 有效提高了 SOC 估计的实用性和鲁棒性, 对于提升电动汽车的性能和安全性具有重要的实际应用价值. 本研究为 SOC 估计的理论发展提供了新的视角, 丰富了 BMS 的研究内容, SSA 与 LSTM 的结合为解决 SOC 估计中的优化问题提供了新的解决方案, 具有显著的理论探索意义和应用潜力.

1 数据描述与预处理

1.1 数据描述

为实现对动力电池 SOC 的准确估计, 本研究收集了涵盖多种驾驶工况和环境条件的实车运行数据, 其中初始实车电压、电流数据如图 1 所示. 数据集包括的关键参数有: 电压、电流、温度、车速、加速度、驾

驶模式(包括城市道路、高速公路和乡村道路等不同驾驶模式,每种模式下电池的工作状态有所不同)、充电状态(记录电池的充电次数和充电周期)和环境条件(大气压力、湿度等环境因素)。数据通过车载诊断系统(On-Board Diagnostics, OBD)和 BMS 实时采集,并通过无线通信模块传输至中央数据库。数据采集的频率为每次 10 s,确保了数据的时效性和连续性。




图 1 初始实车电压、电流数据

1.2 数据预处理

数据集质量对 SOC 的估计至关重要,故需通过预理解决数据集中出现的空值、缺失值与异常值等问题。缺失值的出现源于传感器故障或数据记录流程的不完善,通常采用插值方法,如线性插值法及邻近数据点均值填补策略,以有效弥补数据缺口,确保数据的连贯性与完整性。异常值的产生则可能归因于传感器误差或外部环境的异常干扰。为精准识别并妥善处理异常值,通常采用设定阈值结合统计方法(如标准差分析及箱型图技术)的综合策略,针对识别出的异常值,根据实际情况灵活采取替换或删除措施,以维护数据集的质量。鉴于电动汽车运行参数间量纲差异大且数值范围广泛,本研究实施了标准化处理,使各特征均遵循均值为 0、标准差为 1 的标准正态分布,该方法显著提升了模型训练的稳定性与收敛效率。

2 方法描述

2.1 LSTM 神经网络方法介绍

LSTM 神经网络是一种特殊的循环神经网络(Recurrent Neural Network, RNN),旨在解决传统 RNN 在处理长期依赖问题时的不足^[16]。LSTM 在时间序列数据处理中的优势主要体现在其能够有效捕捉长期依赖关系,避免了梯度消失或梯度爆炸的问题^[17]。传统 RNN 在处理时间序列数据时,由于梯度消失或爆炸的问题,导致模型在学习长序列中的长期依赖关系时表现不佳,而 LSTM 通过引入门控机制,即输入门、遗忘门和输出门,提供了有效的解决方案。

1) 输入门:输入门由 2 部分组成,分别是更新门和输入调制候选向量。更新门决定新的信息更新的程度,而输入调制候选向量则生成新的细胞状态候选值。式(3)、式(4)可分别表示更新门和输入调制候选向量的计算:

$$i_t = \sigma(\mathbf{W}_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$\tilde{C}_t = \tan h(\mathbf{W}_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

其中: i_t 是更新门的输出; σ 是 Sigmoid 激活函数; h_{t-1} 是前一时间步的隐状态; x_t 是当前时间步的输入; $\tilde{C}_t$ 是输入门的新增记忆部分; $\mathbf{W}_i$ 和 $\mathbf{W}_c$ 分别为更新门和输入调制候选向量的权重矩阵。

2) 遗忘门:遗忘门的作用是决定在新的信息流入之前,哪些旧信息需要被遗忘或丢弃。它通过 Sigmoid

函数来实现, 确保输出值在 0 到 1 之间, 其中 1 表示完全保留信息, 而 0 表示完全遗忘信息. 遗忘门的计算公式如式(5)所示:

$$f_t = \sigma(\mathbf{W}_f \cdot [h_{t-1}, x_t] + b_f) \tag{5}$$

式中: $\mathbf{W}_f$ 是遗忘门的权重矩阵; b_f 是遗忘门的偏置项; 其他符号与之前的门相同.

3) 输出门: 输出门决定将存储单元中的哪些信息传递给下一个隐状态, 同样使用 Sigmoid 函数确定信息的重要程度. 输出门的计算公式如式(6)所示:

$$o_t = \sigma(\mathbf{W}_o \cdot [h_{t-1}, x_t] + b_o) \tag{6}$$

式中: o_t 为输出门的输出; $\mathbf{W}_o$ 是输出门的权重矩阵; 其他符号与之前的门相同.

LSTM 神经网络的设计使得其在处理复杂的时间序列数据时, 比传统 RNN 更具优势. 通过精确控制信息的流动和更新, LSTM 能够有效地学习序列中的长期依赖关系, 提高模型的预测准确性和鲁棒性. 在电动汽车的 SOC 估计中, LSTM 能够捕捉电池运行数据中的时序特性, 从而提高对电池 SOC 的预测精度. 通过对车辆的历史数据进行训练, LSTM 可以学习到电池在不同驾驶工况下的动态特性, 并在实际应用中提供准确的 SOC 估计^[18], LSTM 的结构框架如图 2 所示.




图 2 LSTM 的结构框架

2.2 相关性分析方法

SOC 估计通常依赖于大量电池参数, 然而并非所有参数都对 SOC 的估计有显著影响. 因此, 识别与 SOC 高度相关的特征, 并进行有效的降维处理, 是提高 SOC 估计精度和效率的关键步骤. 本研究采用信息熵和互信息理论进行与 SOC 高度相关特征的分析 and 选择, 衡量标准如表 1 所示.

表 1 互信息值的衡量标准

互信息值范围	解释	互信息值范围	解释
[0, 0.2]	非常弱的相关性	(0.6, 0.8]	强相关性
(0.2, 0.4]	弱相关性	(0.8, 1]	非常强的相关性
(0.4, 0.6]	中等相关性	(1, +∞]	极强相关性, 可能存在因果关系

信息熵是度量数据不确定性的常用方法, 可用于评估单个参数或参数组合对 SOC 估计的贡献度, 量化了随机变量的不确定性或信息的混乱程度^[19]. 互信息是衡量 2 个随机变量之间相互依赖性的量度, 描述了已知一个随机变量的信息后, 对另一个随机变量不确定性减少的程度. 互信息是非负的, 当 2 个随机变量相互独立时, 它们的互信息为 0. 互信息用于评估特定参数与 SOC 之间的相关性, 通过计算电池参数与 SOC 之间的互信息, 可识别出对 SOC 估计最有价值的特征, 信息熵和互信息的定

义方程如式(7)、式(8)所示:

$$H(X) = - \sum_{i=1}^n P(x_i) \log_b(P(x_i)) \quad (7)$$

$$I(X; Y) = \sum_{x \in X} \sum_{y \in Y} P(x, y) \log_b \left(\frac{P(x, y)}{P(x)P(y)} \right) \quad (8)$$

其中: X 是离散随机变量; x_i 是 X 的可能取值; $P(x_i)$ 是 x_i 发生的概率; b 是对数的底数, 通常取 2.

在本研究中, 对收集的电池数据进行标准化预处理, 以消除量纲影响并确保数据一致性, 随后计算单体电池参数(例如电压、电流、温度等)的信息熵进而评估其内在的不确定性, 之后通过计算参数与 SOC 之间的互信息确定参数与 SOC 的相关性, 并根据互信息评分选择与 SOC 高度相关的特征, 最终对选定特征实施降维处理, 以此降低模型复杂度提升计算效率.

2.3 优化方法

为了进一步优化 LSTM 神经网络模型的参数, 提高电动汽车电池 SOC 的估计精度, 研究采用了 SSA 算法, 其核心思想是模拟麻雀群体在寻找食物时的行为模式. 研究结合 SSA 算法搜索最优的 LSTM 参数配置, 将 LSTM 模型的超参数(如隐藏层节点数、学习率、Dropout 率等)作为 SSA 算法的优化目标. 初始化一群随机配置的麻雀代表参数解, 经过觅食和跟随行为策略不断更新位置以搜索更优解, 随后迭代更新直至适应度收敛或达到迭代上限, 最终从群体中挑选出适应度最高的麻雀, 即最优参数配置, 从而有效克服了传统随机初始化方法的局限, 实现了参数空间的高效探索和 SOC 估计精度的显著提升.

2.4 评价指标

为了评估基于 SSA 优化的 LSTM 神经网络模型在电动汽车电池 SOC 估计中的性能, 研究采用了几种常用的评价指标, 即平均绝对误差(Mean Absolute Error, MAE)、均方误差(Mean Squared Error, MSE)和决定系数(R^2)^[20].

1) 平均绝对误差: E_{MAE} 是预测值与实际值之间差的绝对值的平均值, 它直观地反映了预测误差的大小. E_{MAE} 越小, 表示模型的预测精度越高, 计算公式如式(9)所示:

$$E_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (9)$$

式中: n 是样本数量; y_i 是第 i 个实际值; y'_i 是第 i 个预测值.

2) 均方误差: E_{MSE} 是预测值与实际值之间差的平方的平均值, 它能够更加敏感地反映较大的预测误差. E_{MSE} 越小, 表示模型的预测精度越高, 计算公式如式(10)所示:

$$E_{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2 \quad (10)$$

式中: n 是样本数量; y_i 是第 i 个实际值; y'_i 是第 i 个预测值.

3) 决定系数: R^2 是衡量模型解释变量波动程度的指标, 其值在 0 到 1 之间. R^2 越接近 1, 表示模型的解释能力越强, 预测精度越高, 计算公式如式(11)所示:

$$R^2 = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} \quad (11)$$

式中: n 是样本数量; y_i 是第 i 个实际值; y'_i 是第 i 个预测值; $\bar{y}$ 是实际值的平均值.

2.5 研究框架

研究框架的核心聚焦于运用 SSA 的群体智能优化特性, 以调整 LSTM 模型的参数配置, 进而提升电池 SOC 估计的精确性和鲁棒性. 在实施过程中, 优化后的 LSTM 模型首先在训练数据集上进行训练, 随

后在验证数据集上进行测试，并通过 E_{MAE} 、 E_{MSE} 和 R^2 等关键性能指标对其性能进行全面评估。实验结果表明，与传统 SOC 估计方法相比，采用 SSA 优化的 LSTM 模型在多种驾驶工况下均表现出卓越的 SOC 估计精度，验证了 SSA 优化策略的有效性，整体研究框架如图 3 所示。




图 3 研究框架

3 实验结果与分析

采用 SSA 对 LSTM 神经网络模型进行优化，多种工况下电池 SOC 估计值与真实值的比较及其绝对误差分析如图 4 所示，其中真实值和估计值的平均绝对误差控制在 2% 以内。实验设计包括了对 LSTM 模型进行 SSA 优化，并在包含城市、高速和乡村驾驶场景的实车数据集上进行训练和测试，结果表明模型能够解释电池 SOC 变化的大部分变异性。

评价指标结果(图 5)表明，SSA 优化的 LSTM 模型(SSA-LSTM 模型)在测试数据集上的 E_{MAE} 为 1.13， E_{MSE} 为 2.11，模型的 R^2 高达 0.99，显示了其在解释电池 SOC 变化方面的能力较高。结果不仅验证了 SSA 优化策略的有效性，也展示了 LSTM 模型在实际电动汽车应用中的潜力。

在充电阶段，电池的 SOC 估计面临多重复杂因素的挑战，涵盖了充电电流大小、电压水平、环境温度波动以及电池的初始状态等。当变量的不确定性较高时，充电阶段的 SOC 估计便显得尤为复杂。然而，在本研究中，通过引入 SSA 进行优化，模型表现出了高估计精度。充电电流作为直接影响电池充电速度的关键因素，其大小间接决定了 SOC 的增长速率。该模型具备根据实时充电电流变化动态调整内部参数的能力，从而能够精准地适应充电过程中 SOC 的快速波动。此外，环境温度对充电过程的影响同样不容忽视。在低温环境下，电池的内阻会显著增大，导致充电效率降低，会使 SOC 的估计值偏低。相反，在高温条件下，虽然充电效率有所提升，但长期的高温充电却可能加速电池的老化进程，进而对 SOC 估计的长期稳定性构成影响。然而 SSA-LSTM 模型通过全面考虑环境温度的变化，能够实时地对充电过程中的 SOC 估计

进行校正，从而确保了估计结果的准确性和可靠性。




图 4 电池 SOC 估计值与真实值的比较及其绝对误差分析

相较于充电阶段，放电阶段的 SOC 估计面临的影响因素相对更为稳定。放电过程主要受驾驶行为、路况以及电池自身状态的共同作用。在此阶段，该模型展现出了卓越的稳定性和准确性，能够依据车辆的实时行驶状态，包括车速、加速度等关键参数，精确地预测 SOC 的变化趋势。然而，急加速和急减速等激进驾驶行为会引发电流的剧烈波动，从而直接影响 SOC 的下降速率。但该模型通过深度学习历史驾驶数据，已经掌握了不同驾驶行为对 SOC 产生的具体影响，使得该模型能够在复杂多变的驾驶环境中实现更为精准的 SOC 估计。此外，路况信息也是影响放电阶段 SOC 估计的重要因素之一，如城市拥堵的复杂路况，高速公路上汽车的稳定巡航，均会对电池的放电模




图 5 评价指标汇总

SOC 估计的重要因素之一，如城市拥堵的复杂路况，高速公路上汽车的稳定巡航，均会对电池的放电模

式产生显著影响. 而 SSA-LSTM 模型凭借其强大的学习能力, 能够准确识别并适应不同路况下的电池工作模式. 通过动态调整内部参数, 该模型能够进一步提高 SOC 估计的准确性, 确保在各种路况下都能提供可靠的 SOC 预测结果.

SSA-LSTM 模型在充电阶段的优化核心在于对充电电流与环境温度的动态适应性调整. 通过模拟麻雀觅食行为的智能策略, 模型参数得以有效调整, 显著提升了其对充电过程中 SOC 变化的灵活应对能力. 进入放电阶段, 模型则聚焦于深度挖掘驾驶行为与路况信息的潜在价值, 借助长期的数据积淀与参数调优, 实现了对 SOC 变化趋势的高精度预测. 关于充放电过程中 SOC 估计值与真实值的对比以及相应的绝对误差分析如图 6 所示, 该图直观地展示了模型性能的优化结果.




图 6 充放电 SOC 估计值与真实值的比较及其绝对误差分析

4 结论

基于麻雀搜索优化 LSTM 神经网络的电池 SOC 估计的成功应用, 提高了预测的准确性, 增强了模型对不同驾驶行为的适应性. 通过综合分析和实验验证, 本研究得出以下结论:

- 1) SSA-LSTM 模型在城市拥堵、高速公路和乡村道路等不同驾驶工况下, 均表现出较低的 E_{MAE} 和 E_{MSE} , 以及接近 1 的 R^2 值, 表明模型在预测精度和数据解释能力方面均优于传统方法.
- 2) SSA-LSTM 模型能够适应不同的驾驶条件, 得益于 LSTM 神经网络对时间序列数据的处理能力和 SSA 算法在参数优化方面的高效性. 通过模拟麻雀群体的觅食行为, 有效地调整了 LSTM 模型的参数, 提高了模型对复杂工况的适应性.
- 3) 本研究的方法不仅提高了 SOC 估计的准确性, 还为电动汽车的性能和安全性提供了实际应用价值, 有助于优化电池使用、延长电池寿命以及防止过充和过放.
- 4) 在充电阶段, SSA-LSTM 模型能够动态调整内部参数, 以适应充电过程中 SOC 的快速变化. 在放电阶段, 模型则侧重于学习驾驶行为和路况信息, 通过长期的数据积累和参数优化, 实现了对 SOC 变化趋势的准确预测.

本研究的结果也为电动汽车 BMS 的发展提供了新的技术途径, 有助于提高电动汽车的性能和驾驶体验. 未来的研究也将基于此进一步优化完善实车上的 SOC 估计, 探索数据融合技术以增强 SOC 估计的准确性, 考量电池老化对估计精度的影响并建立补偿机制, 提高模型对不同环境条件的适应性, 加强面向实际工程应用的多熵融合故障诊断策略, 并在实际电动汽车中实施长期测试以确保模型的实用性和可靠性, 从而推动电动汽车 BMS 向更高效、更智能的方向发展.

参考文献：

[1] International Energy Agency. Global EV Outlook 2023 [R/OL]. (2023-04-30) [2024-09-15]. <https://www.iea.org/reports/global-ev-outlook-2023>.

[2] 巩浩, 钟洪伟, 孙梦凯, 等. 新能源电动汽车节能减排效应及发展 [J]. 能源与节能, 2023(12): 80-84.

[3] 万广伟, 张强. 锂离子电池 SOC 评估方法研究进展 [J]. 电源技术, 2023, 47(9): 1122-1125.

[4] ZHANG S Z, GUO X, DOU X X, et al. A Data-Driven Coulomb Counting Method for State of Charge Calibration and Estimation of Lithium-Ion Battery [J]. Sustainable Energy Technologies and Assessments, 2020, 40: 100752.

[5] 王义军, 左雪. 锂离子电池荷电状态估算方法及其应用场景综述 [J]. 电力系统自动化, 2022, 46(14): 193-207.

[6] YU Q Q, WAN C J, LI J F, et al. An Open Circuit Voltage Model Fusion Method for State of Charge Estimation of Lithium-Ion Batteries [J]. Energies, 2021, 14(7): 1797.

[7] 李清波, 张懋慧, 罗英, 等. 基于等效电路模型融合电化学原理的锂离子电池荷电状态估计 [J]. 储能科学与技术, 2024, 13(9): 3072-3083.

[8] ZHAO H Y, ZHANG C Z, LIAO C L, et al. An Improved Electrochemical Equivalent Circuit Model and Precise State-of-Charge Estimation Comparative Study for Lithium-Rich Manganese-Based Battery [J]. Journal of Energy Storage, 2024, 94: 112354.

[9] PENG J K, LUO J Y, HE H W, et al. An Improved State of Charge Estimation Method Based on Cubature Kalman Filter for Lithium-Ion Batteries [J]. Applied Energy, 2019, 253: 113520.

[10] DOU J M, MA H Y, ZHANG Y D, et al. Extreme Learning Machine Model for State-of-Charge Estimation of Lithium-Ion Battery Using Salp Swarm Algorithm [J]. Journal of Energy Storage, 2022, 52: 104996.

[11] 于仲安, 邵昊晖, 陈可怡. 基于 IGWO-BP 神经网络的锂离子电池 SOC 估计 [J]. 电源技术, 2023, 47(9): 1153-1157.

[12] 张越. 基于 GWO-SVM 算法的锂动力电池状态在线联合估计方法研究 [D]. 哈尔滨: 哈尔滨理工大学, 2023.

[13] 郭鹏. 数据—模型联合驱动的锂电池 SOC 稳健估计方法研究 [D]. 西安: 西安理工大学, 2024.

[14] JIA K, GAO Z, MA R C, et al. An Adaptive Optimization Algorithm in LSTM for SOC Estimation Based on Improved Borges Derivative [J]. IEEE Transactions on Industrial Informatics, 2024, 20(2): 1907-1919.

[15] 王尔申, 王欢, 雷虹, 等. 基于麻雀搜索算法的 ARAIM 故障子集优化算法 [J]. 北京航空航天大学学报, 2024, 50(7): 2066-2073.

[16] EYAD A, SALEH A, EMAD A, et al. State of Charge Estimation for a Group of Lithium-Ion Batteries Using Long Short-Term Memory Neural Network [J]. Journal of Energy Storage, 2022, 52(PA): 104761.

[17] 潘思源, 张伟. 基于改进 LSTM 算法的锂电池 SOC 估计 [J]. 计算机与现代化, 2023(8): 25-30.

[18] YANG F F, ZHANG S H, LI W H, et al. State-of-Charge Estimation of Lithium-Ion Batteries Using LSTM and UKF [J]. Energy, 2020, 201: 117664.

[19] 洪吉超, 张昕阳, 徐晓明, 等. 基于多熵融合的动力电池故障诊断与应用研究 [J]. 机械工程学报, 2024, 60(12): 301-312.

[20] 雷亦鸣. 基于数据驱动的稳健 SOC 估计融合方法研究 [D]. 西安: 西安理工大学, 2024.

责任编辑 柳剑
崔玉洁