

基于门控循环神经网络的电池健康状态估算

王春辉

(中汽数据(天津)有限公司,天津 300380)

【欢迎引用】王春辉. 基于门控循环神经网络的电池健康状态估算[J]. 汽车文摘, 2025(7): 25-30.

【Cite this paper】WANG C H. SOH Estimation of Power Battery Based on Gated Recurrent Unit[J]. Automotive Digest (Chinese), 2025(7): 25-30.

【摘要】针对新能源汽车动力电池健康状态(SOH)估算精度低的问题,提出一种基于门控循环神经网络(GRU)的电池SOH估算方法,基于电池充电数据提取多维输入特征,对特征进行数据清洗和归一化处理,训练GRU网络构建电池SOH估算模型。结果表明:所提出的方法可实现电池SOH估算的平均绝对误差为0.26%,相较于传统计算方法绝对误差降低了1.04%,该方法可实现对电池SOH较准确估算,可用于电动汽车的老化状态评估。

关键词:动力电池;电池健康状态;Adam算法;门控循环神经网络

中图分类号:U469.72

文献标志码:A

DOI: 10.19822/j.cnki.1671-6329.20250009

SOH Estimation of Power Battery Based on Gated Recurrent Unit

Wang Chunhui

(China Automotive Data (Tianjin) Co. Ltd., Tianjin 300380)

【Abstract】A battery State of Health (SOH) estimation method based on Gated Recurrent Unit (GRU) neural network is proposed to address the issue of low accuracy in estimating the SOH of new energy vehicle power batteries. This method extracts multidimensional input features based on battery charging data, performs data cleaning and normalization on the features, and trains a GRU network to construct a battery SOH estimation model. The results indicate that the proposed method can achieve an average absolute error of 0.26% in estimating battery SOH, which is 1.04% lower than traditional calculation methods. This method can achieve a more accurate estimation of battery SOH and can be used for evaluating the aging status of electric vehicles.

Key words: Power battery, State of Health (SOH), Adam algorithm, Gated Recurrent Unit (GRU)

0 引言

随着新能源汽车市场占有率的迅速提升,车辆使用过程中的电池性能及老化程度成为用户关注的焦点。电池健康状态(State of Health, SOH)可反映电池的老化程度及剩余使用寿命情况,对其精准估测能够为用户了解电池老化状态提供依据,对于跟踪车辆电池状态具有重要意义。目前,电池SOH估算方法主要包括基于经验计算的方法、基于模型的方法和基于数据驱动的方法。基于经验计算电池SOH,主要利用当前电池容量、电池内阻和出厂时电池容量、电池内阻,对比计算得到表征电池老化水平的电池健康状态结果。模型法主要依托电池机理使用电阻电容等器件

搭建等效电路模型、电化学模型等,通过参数辨识得到电池SOH的估计值。数据驱动法不考虑电池内部反应原理,而是利用大量电池数据,基于智能方法搭建电池SOH预测模型,挖掘依靠经验无法发现的规律,一定程度上可以提高估算准确度。王燕^[1]搭建了二阶RC电路模型,将无迹卡尔曼滤波的后验分布作为粒子滤波的分布函数,使用无迹卡尔曼滤波算法辨识模型参数,实现了电池SOH估算。Liu等^[2]结合了复合多尺度方法、香农熵理论和离散正弦变换,从不同尺度和水平的电流和电压信号中提取了电池健康特征,构建了一种改进的复合多尺度离散正弦熵算法。廖力等^[3]从电池充电曲线中提取了与容量衰退关联的健康因子,采用引力搜索算法优化了支持向量回归模

型,建立了多形式回归模型预测健康因子随充放电循环次数增加的变化趋势。雷奥等^[4]利用改进的带有自适应噪声的互补集合经验模态分解算法分解容量信号,然后分别利用支持向量回归(Support Vector Regression, SVR)、长短时记忆网络(Long Short-Term Memory, LSTM)算法对高频、低频信号进行预测,最后将各分量预测信号重组作为预测结果。Sun^[5]从IC曲线中提取峰值信息等与电池老化相关的特征,训练了BPINN神经网络模型,提高了SOH预测的准确性。周仁等^[6]利用BP-AdaBoost算法对国家大数据平台采集的实车运行数据进行了电池SOH估计。莫易敏^[7-9]等均从电池充放电数据中提取了健康因子作为模型输入,采用门控循环单元(Gated Recurrent Unit, GRU)或LSTM模型开展电池SOH估算模型的训练,其中训练数据均为基于实验室理想的恒流或恒压充放电工况获取的电池数据,模型迁移到实车的适用性和可靠性难以保证。本文所训练的GRU模型,所用数据为基于GB/T 32960《电动汽车远程服务与管理系统技术规范》采集的实车运行过程中的监控数据,并且基于运行监控数据的特点挖掘模型输入特征,提高了模型的实车应用价值。

然而,经验方法受电池温度、SOC误差等因素影响,模型方法又受特定工况的数据质量和所建模型的效果限制,数据驱动方法依赖大量先验数据且迁移能力差,上述原因导致实车电池SOH估算精度不高。针对上述问题,本文提出一种经验计算和GRU数据驱动模型相结合的估算方法,发挥经验方法计算的简便可行性优势,同时借助GRU网络解决SOC误差、温度等因素对计算结果的干扰,旨在有效提升电池SOH估算的准确度。

1 门控循环单元神经网络

1.1 门控循环控制单元

GRU模型是一种循环神经网络,由门控循环单元组成,每个门控循环单元包含重置门、候选隐藏状态、更新门、隐藏状态,其中重置门控制历史状态信息的保留程度,候选隐藏状态融合了历史信息和当前的输入信息,更新门控制候选隐藏状态对隐藏状态的信息贡献度,隐藏状态融合了前一步的隐藏状态信息和候选隐藏状态信息。GRU适用于处理序列数据,且通过门结构解决了传统循环神经网络梯度消失和梯度爆炸的问题。图1为门控循环单元的结构,其各部分计算逻辑如式(1)~式(6)所示。

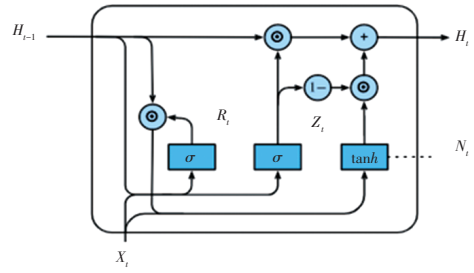


图1 门控循环单元结构

$$R_t = \sigma(W_{ir}x_t + b_{ir} + W_{hr}H_{t-1} + b_{hr}) \quad (1)$$

$$Z_t = \sigma(W_{iz}x_t + b_{iz} + W_{hz}H_{t-1} + b_{hz}) \quad (2)$$

$$N_t = \tan h(W_{in}x_t + b_{in} + R_t \odot (W_{hn}H_{t-1} + b_{hn})) \quad (3)$$

$$H_t = (1 - Z_t) \odot N_t + Z_t \odot H_{t-1} \quad (4)$$

$$\tan h(j) = \frac{e^j - e^{-j}}{e^j + e^{-j}} \quad (5)$$

$$\sigma(j) = \frac{1}{1 + e^{-j}} \quad (6)$$

式中: R_t 为重置门状态, x_t 为模型输入, Z_t 为更新门状态, N_t 为候选隐藏状态, H_t, H_{t-1} 为异常状态, $W_{ir}, W_{hr}, W_{iz}, W_{hz}, W_{in}, W_{hn}$ 为权重参数, $b_{ir}, b_{hr}, b_{iz}, b_{hz}, b_{in}, b_{hn}$ 为偏置参数, \odot 表示逐元素乘积, $\tan h$ 为双曲正切函数, σ 为激活函数^[10]。

1.2 GRU网络架构

本文基于GRU搭建的神经网络架构如图2所示。模型包括输入层、门控循环单元、线性层、Sigmoid层、输出层5部分,其中每个GRU模块包含若干个门控循环控制单元,GRU模块内循环控制单元的数目等于隐含层的神经元数目。为发挥GRU网络的历史记忆功能,设置6个历史输入状态对应一个当前输出。

1.3 Adam优化算法

Adam算法是一种自适应学习率的优化算法,基于动量梯度下降和自适应学习率思想形成的算法,在优化过程中通过为各梯度赋予差异化权重,保证模型能快速、平稳地优化到最优点。该算法需更新各权重的一阶梯度平均值和二阶梯度平均值的指数加权移动平均数,其计算过程如下。

(1)初始化各参数的一阶梯度的指数加权平均数 $m_0 = 0$ 、二阶梯度的指数加权平均数 $v_0 = 0$,偏差校正系数 $\hat{m}_0 = \hat{v}_0 = 0$;

(2)计算 t 时刻的小批量样本 B_t 的梯度 g_t ;

(3)计算一阶梯度、二阶梯度的指数加权均值,计算公式如下:

$$m_t = \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t \quad (7)$$

$$v_t = \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2 \quad (8)$$

式中： m_t 、 m_{t-1} 为 t 时刻、 $t-1$ 时刻的一阶梯度的指数加权平均数； v_t 、 v_{t-1} 为 t 时刻、 $t-1$ 时刻的二阶梯度的指数加权平均数； g_t 为梯度； β_1 、 β_2 为平均系数，可设为0.999。

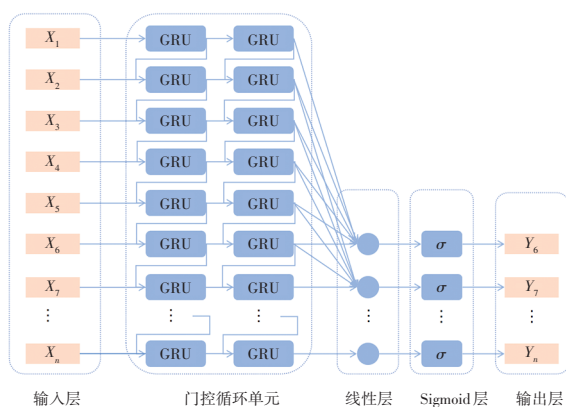


图2 基于GRU的神经网络模型架构

(4)计算偏差校正后梯度的估计值为：

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (9)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (10)$$

式中： \hat{m}_t 、 \hat{v}_t 为 t 时刻一阶梯度和二阶梯度的偏差校正系数。

(5)更新权重为：

$$\theta_t = \theta_{t-1} - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t \quad (11)$$

式中： θ_t 、 θ_{t-1} 为 t 时刻、 $t-1$ 时刻的权重； η 为学习率； ϵ 为常数，常取 10^{-8} 。

Adam算法通过计算一阶和二阶矩估计为每个参数自适应地调整学习率，通过偏差校正可以加速初期的学习速率，该算法对众多模型的迭代优化具有很强的适用性。为对比分析Adam算法性能，本文采用随机梯度下降(Stochastic Gradient Descent, SGD)算法作为对照，SGD以最小化损失函数为训练目标，沿着梯度方向更新模型参数，其迭代流程如图3所示。

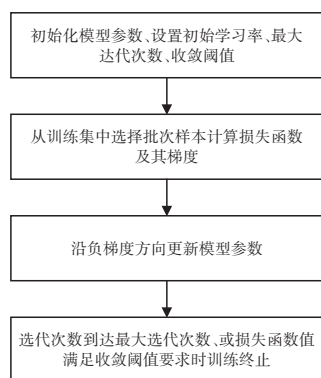


图3 SGD方法迭代训练流程

1.4 GRU算法应用

工程上常用安时积分法来计算电池充电容量，再根据定义估算SOH，但该方法受表显SOC和真实SOC存在误差、充电温度、充电倍率的影响^[11,12]，导致SOH估算精度不高。本文将上述影响SOH精度的因素提取成特征输入到GRU模型中，利用GRU模型捕捉序列数据变化趋势的能力，搭建基于GRU的动力电池SOH衰减变化估算模型。

GRU算法应用的技术路线包括4部分，依次为电池数据获取及清洗、数据特征工程构建、GRU估算SOH模型的训练、GRU估算SOH模型的测试及优化。电池数据获取方式包括企业新能源汽车大数据监控云平台或充电运营商监控平台等，采集的数据包括电流、SOC、数据采集时间、电池探针温度等，并制定清洗策略删除脏数据。数据特征工程构建的目的在于挖掘电池SOH相关的特征，即影响电池健康度的电池信息，如充电倍率、充电温度等，上述特征作为GRU模型的输入量。根据实车SOH状态为电池数据打上SOH标签并作为GRU模型的输出，构建并训练GRU模型学习电池特征和SOH间的复杂映射关系，获取模型参数。采用测试电池数据验证GRU模型的估算准确度，当误差较大难以满足应用时需优化模型参数，并重新进行模型训练直至预测误差满足工程应用要求。

模型搭建过程如图4所示。首先，对电流、探针温度、SOC等实车数据进行预处理，去除原始数据中的异常值、缺失值和重复值，并进行归一化处理。然后，截取电池充电数据，将每个恒流充电片段划分成一个估算工况，各工况提取4维特征因子作为GRU模型的输入，包括安时积分获取的当前容量与标况下额定容量的比值、最高温度、充电倍率、充电结束时刻距本次充电开始时刻的SOC变化量，真实电池SOH作为模型输出。最后，利用收集的实车数据搭建GRU模型，调整模型参数完成SOH估算模型训练，采用实车数据验证模型效果。

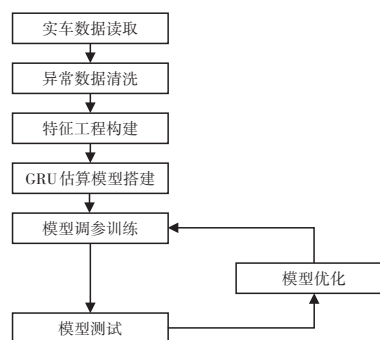


图4 基于GRU估算电池SOH

2 特征工程构建

2.1 特征提取

传统 SOH 估算方法基于安时积分法实现^[13], 计算公式如下:

$$C_{\text{current}} = \frac{\int_{t_1}^{t_2} Idt}{SOC_{\text{end}} - SOC_{\text{start}}} \quad (12)$$

$$SOH = \frac{C_{\text{current}}}{C_{\text{initial}}} \times 100\% \quad (13)$$

式中: C_{current} 为电池的当前最大可用容量, C_{initial} 为电池初始容量, I 为充电电流值, t_1 、 t_2 分别为充电开始与结束时刻, SOC_{start} 、 SOC_{end} 分别为充电开始和结束时的电池 SOC 值。

本文从传统 SOH 估算方法无法量化的温度、充电倍率等因素角度挖掘热失控特征, 共提取 4 维输入特征, 如表 1 所示。

表 1 特征列表

编号	特征
1	安时积分获取的当前容量与标况下额定容量的比值
2	最高温度
3	充电倍率
4	充电结束时刻距本次充电开始时刻的 SOC 变化量

特征 1: 安时积分获取的当前容量与标准工况下额定容量的比值, 代表不考虑充电温度、充电倍率、SOC 误差的原始 SOH。

特征 2: 最高温度, 该特征旨在让模型学习温度对真实 SOH 的影响。

特征 3: 恒流充电的充电倍率, 该特征旨在让模型学习倍率对真实 SOH 的影响。

特征 4: 充电结束时刻距本次充电开始时刻的 SOC 变化量, 该特征主要是考虑了充电过程表显 SOC 与真实 SOC 的误差随 SOC 变化量增加累积的影响。


利用 GRU 模型的智能学习能力, 拟合上述特征对真实 SOH 的影响程度, 挖掘特征因子和输出之间的非线性关系。某辆新能源汽车提取的 4 维特征如图 5 所示。

2.2 特征归一化


为避免各特征量纲不一致影响模型精度, 对每维输入特征进行特征内归一化, 采用最小最大归一化方法清洗提取的特征数据, 将全部特征转化到 [0, 1] 区间。归一化公式如下:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (14)$$


式中: x 为待归一化特征的原始数据, x_{\min} 为待归一化特征全部数据集的最小值, x_{\max} 为待归一化特征全部数据集的最大值, x' 为归一化后数据。




(a) 特征 1: 原始 SOH



(b) 特征 2: 最高温度



(c) 特征 3: 充电倍率



(d) 特征 4: 累计 SOC 变化量

图 5 某车辆样本的特征

3 模型构建与验证

3.1 模型训练


本文构建的 GRU 模型参数选择如下: 隐含层神经元数决定模型的记忆容量, 可根据任务复杂度和数据量调整, 本文模型输入维度较小数据量偏低, 故在适合简单任务的 64~128 中间遍历寻优, 最终确定隐含层神经元数为 126。隐含层数通常设置为 1~3 便可支持模型构建, 从 1 开始逐步增加至 3, 发现 2 是满足模

型复杂度不高且损失较高的隐含层数,故隐含层数设为2。输出维度较低,输出层选择1层。批处理大小 $batch_size=6$,此时输入数据覆盖动力电池1 min的状态变化,可全面体现特征变化特点,模型泛化能力强。为防止模型发生过拟合,根据经验设置 $dropout=0.3$,迭代次数设置为20,选择默认初始学习率为0.001,模型寻优采用Adam算法。模型训练效果采用均方误差(Mean Squared Error, MSE)评价,公式如下:


$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_i - y_i)^2 \quad (15)$$

式中: y_i 为真实输出值, Y_i 为模型预测输出, N 为输入输出样本数。

本文基于某纯电品牌多款车型的充电数据完成模型训练和模型验证。训练误差如图6所示,Adam算法训练误差为 2.3×10^{-6} ,可以发现本模型采用的Adam方法优化速度与SGD方法相比优化速度更快。Adam在SGD的基础上引入一阶矩估计,使得当连续多次迭代梯度方向相似时更新步长会增大,从而加快收敛速度;同时引入二阶矩估计,自适应调整每个参数的学习率,进一步加快了收敛速度。



(a) Adam优化算法迭代训练的MSE



(b) SGD优化算法迭代训练的MSE

图6 模型训练误差

3.2 模型验证

从训练数据的同款车型中随机挑选验证数据,使用均方误差MSE、平均绝对误差(Mean Absolute Error, MAE)、拟合优度参数 R^2 指标评价模型效果。

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_i - y_i)^2}{\sum_{i=1}^N (\bar{y} - y_i)^2} \quad (16)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_i - y_i| \quad (17)$$

式中: y_i 为真实输出值, Y_i 为模型预测输出, \bar{y} 为样本平均值, N 为输入输出样本数。

随机抽取的验证样本的预测效果如图7所示,预测值与真实值间的MSE为 9.6×10^{-5} , MAE为0.0026, R^2 为0.91。传统安时积分法估算SOH的MAE为0.013,对比可以发现GRU模型的估算效果良好。

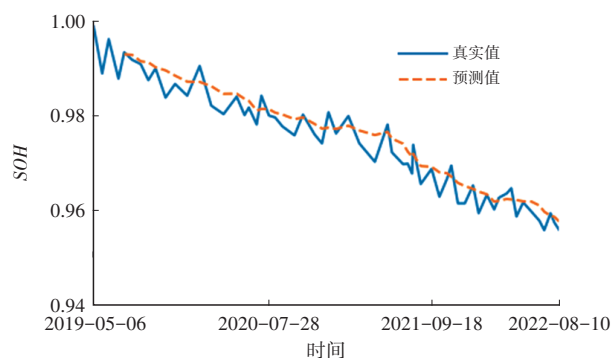


图7 GRU模型的SOH估算效果

4 结论

本文研究了基于GRU网络的动力电池SOH估算方法。首先,进行了电池充电数据处理,包括恒流片段截取、老化特征挖掘、特征归一化处理。然后,采用GRU网络搭建了电池SOH估算模型,使用均方误差MSE、平均绝对误差MAE、拟合优度参数 R^2 等指标量化评估了模型效果。通过多款纯电车型的实车数据验证,该模型SOH估算准确度与传统估算方法相比精度更高,适用于纯电汽车的老化状态评估,具有一定的工程应用价值。

参考文献

- [1] 王燕. 基于分数阶模型的锂离子电池SOC与SOH估算研究[D]. 长沙: 湖南大学, 2023.
- [2] LIU Y M, DING J X, CAI Y J, et al. A Battery SOH Estimation Method Based on Entropy Domain Features and Semi-Supervised Learning under Limited Sample Conditions[J]. Journal of Energy Storage, 2025, 106: 114822.
- [3] 廖力, 肖廷奕, 吴铁洲, 等. 基于多健康特征融合的锂电池SOH和RUL预测[J]. 电源技术, 2023, 47(2): 193-198.
- [4] 雷奥, 段文献, 刘铁鑫, 等. 基于SSA-SVR和LSTM相结合的混合模型预测锂电池的剩余寿命[J]. 时代汽车, 2024(22): 121-123.
- [5] SUN G Q, LIU Y F, LIU X W. A Method for Estimating Lithium-ion Battery State of Health Based on Physics-Informed Machine Learning[J]. Journal of Power Sources,

- 2025, 627: 235767.
- [6] 周仁, 张向文. 基于实车数据和BP-AdaBoost算法的电动汽车动力电池健康状态估计[J]. 科学技术与工程, 2022, 22(21): 9398-9406.
- [7] 戴彦文, 于艾清. 基于健康特征参数的CNN-LSTM&GRU组合锂电池SOH估计[J]. 储能科学与技术, 2022, 11(5): 1641-1649.
- [8] 毛百海, 覃昊, 肖显斌, 等. 基于LSTM&GRU-Attention多联合模型的锂离子电池SOH估计[J]. 储能科学与技术, 2023, 12(11): 3519-3527.
- [9] 莫易敏, 余自豪, 叶鹏, 等. 基于迁移学习与GRU神经网络结合的锂电池SOH估计[J]. 太阳能学报, 2024, 45(3): 233-239.
- [10] CHUNG J, GULCEHRE C, CHO K, et al. Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling[C]// 2020 5th International Conference on Computing, Communication and Security (ICCCS). Patna, India: IEEE, 2020.
- [11] 赵珈卉, 田立亭, 程林. 锂离子电池状态估计与剩余寿命预测方法综述[J]. 发电技术, 2023, 44(1): 1-17.
- [12] 王文博. 热-电耦合老化路径下动力电池的衰减机理研究[D]. 哈尔滨: 哈尔滨理工大学, 2020.
- [13] 田君, 高洪波, 张跃强, 等. 电动汽车动力锂离子电池寿命预测方法研究[J]. 电源技术, 2020, 44(5): 767-770.

(责任编辑 明慧)

2025年《汽车技术》专项征稿启事

尊敬的汽车及相关技术领域专家学者、研发工程师、高校师生：

随着汽车技术的飞速发展,2025年将见证多项关键技术的突破与应用。《汽车技术》杂志作为中国汽车行业的核心学术期刊,特此发布2025年专项征稿启事,聚焦以下十大技术征稿方向,以期推动汽车技术的创新与进步。

- 多模态大模型在自动驾驶感知决策中的应用:**研究多模态大模型技术推动自动驾驶感知决策能力的创新突破。
- 跨域融合智能芯片技术:**研究跨域融合智能芯片在汽车智能化控制系统中的应用,以及其对性能协同的影响。
- AI赋能的合成数据在自动驾驶研发中的应用:**研究利用AI技术生成合成数据,解决自动驾驶数据短缺问题。
- AI大模型在智能座舱中的多模态交互技术:**研究AI大模型如何整合视觉、听觉、触觉等多种感官信息,实现更加自然和直观的人机交互体验。
- C-V2X技术在车路云一体化中的应用:**研究C-V2X技术如何支持车路云一体化,包括车车通信(V2V)、车路通信(V2I)、车云通信(V2N)等关键技术的发展和应用。
- 智能底盘新构型及集成控制技术:**研究智能底盘线控化、分布式驱动、动底融合控制、智能底盘与自动驾驶融合控制等关键技术。
- 新能源乘用车百公里行驶电耗降低技术:**研究如何通过硬件创新和软件优化降低电耗,提升整车续航里程。
- 固态电池电解质材料创新与界面工程优化:**研究氧化物、硫化物、聚合物等固态电解质材料的最新研究进展,以及固态电池中电极与电解质之间的界面问题,提高电池的充放电效率和循环稳定性。
- 电池系统安全技术:**研究主被动一体化的热安全防护、热失控早期火灾探测预警、灭火装置等。
- 高效高密度电驱动总成技术:**研究具有更高转速、更高效率和更小型化的电驱动系统技术。

征稿要求:

- 投稿请注明“*****”技术方向专项征稿字样,本刊对符合征稿方向的稿件将优先审核,一经录用优先发表;
- 文章字数控制在6 000-8 000字范围之内;
- 请按科技论文要求撰写文章摘要,摘要中文字数控制在180字左右;
- 文章必须附有公开发表的、体现本领域最新研究成果的参考文献,并在文中标注文献引用处;
- 文章主要作者应提供其简介,包括出生年、性别、职称、学历、研究方向及技术成果等;
- 来稿的保密审查工作由作者单位负责,确保署名无争议,文责自负;
- 请勿一稿多投;
- 本刊使用网站投稿,详细投稿要求见本刊网站中“下载中心”栏的“作者指南”,网址:<http://qjcs.cbpt.cnki.net>。

这些技术方向反映了汽车技术领域的最新研究热点,《汽车技术》杂志诚邀广大科研人员围绕这些方向投稿,我们期待您的佳作,共同推动汽车技术的发展与创新。感谢您对《汽车技术》杂志的支持与贡献!

《汽车技术》杂志是中国第一汽车集团有限公司主办的国内外公开发行的汽车前瞻与应用技术类月刊,为我国高质量科技期刊分级目录入选期刊、中国科学引文数据库(CSCD)来源期刊、中文核心期刊、中国科技核心期刊、RCCSE中国核心学术期刊(A)、Scopus数据库收录期刊、俄罗斯《文摘杂志》(AJ)收录期刊、日本科学技术振兴机构数据库入选期刊、EBSCO学术数据库收录期刊、欧洲学术出版中心(EuroPub)数据库收录期刊。

《汽车技术》编辑部