

DOI: 10.19650/j.cnki.cjsi.J2514181

基于记忆增强注意力网络的电动汽车能耗预测模型*

彭自然, 杨肖阳, 吴岳忠, 潘长宁

(湖南工业大学交通与电气工程学院 株洲 412007)

摘要:针对电动汽车(EVs)长序列能耗预测中普遍存在的记忆衰减、注意力计算复杂度高以及动态工况适应能力不足等关键问题,提出一种基于记忆增强注意力网络的能耗预测模型(DQN-AMAG)。该模型以记忆驱动智能网络(AMAG)为核心架构,构建短期记忆、长期神经记忆与持久记忆三级协同机制,通过惊喜因子驱动的衰减策略强化对电池衰减与工况突变等关键事件的建模能力,从而有效捕获长时序能耗特征的多尺度依赖关系。在此基础上,提出自适应Nyström低秩注意力(ANSA)机制,基于Nyström方法对注意力矩阵进行低秩近似,并引入自适应采样维度调节策略,将计算复杂度由 $O(T^2)$ 降低至 $O(T \cdot r)$,显著提升长序列场景下的计算效率与实时性能。同时,引入自适应多尺度时空注意力机制(AMSTA)及超网络动态调参前向模型,实现路况图像与电池管理系统(BMS)时序数据的深度跨模态融合,增强模型对复杂环境变化的感知能力。进一步地,将AMAG嵌入强化学习框架,利用时间差分学习构建时序一致性正则,实现预测参数的自校准式优化。基于两类车型、五年实车运行数据的实验结果表明,在不同健康状态(SOH)条件下模型平均绝对误差(MAE)低于0.2%、均方根误差(RMSE)低于0.3%、决定系数(R^2)高于99.5%,在长序列与电池衰减场景中均表现出优异的稳定性与泛化能力,整体性能显著优于Transformer、Informer、Mamba和LSTM等主流模型。

关键词:电动汽车能耗预测;记忆驱动智能网络;自适应Nyström低秩注意力;多尺度时空注意力;时序一致性正则;超网络

中图分类号: TH7 TM912 TN713 **文献标识码:** A **国家标准学科分类代码:** 470.4017

Energy consumption prediction model for electric vehicles based on memory-augmented attention network

Peng Ziran, Yang Xiaoyang, Wu Yuezhong, Pan Changning

(School of Transportation and Electrical Engineering, Hunan University of Technology, Zhuzhou 412007, China)

Abstract: To address critical challenges in long-sequence energy consumption prediction for electric vehicles (EVs), including memory decay, high computational complexity of attention mechanisms, and insufficient adaptability to dynamic driving conditions, this paper proposes a memory-augmented attention-based prediction model termed deep Q network-adaptive memory augmented gating (DQN-AMAG). The model is built upon an adaptive memory-augmented gating (AMAG) network that incorporates a three-level collaborative memory architecture consisting of short-term memory, long-term neural memory, and persistent memory. A surprise-driven decay mechanism is introduced to enhance the modeling of battery degradation and abrupt operating condition variations, enabling effective capture of multi-scale temporal dependencies in long-horizon energy consumption sequences. Furthermore, an adaptive Nyström attention (ANSA) mechanism is developed to perform low-rank approximation of the attention matrix via the Nyström method with adaptive sampling dimension adjustment. This reduces the computational complexity from $O(T^2)$ to $O(T \cdot r)$, significantly improving efficiency and real-time performance in long-sequence scenarios. An adaptive multi-scale spatiotemporal attention mechanism (AMSTA) mechanism and a hypernetwork-based dynamic forward model are additionally introduced to enhance deep cross-modal fusion between road condition images and battery management system (BMS) time-series data, strengthening environmental perception capability. Moreover, the AMAG network is embedded into a reinforcement learning framework, where temporal difference learning provides temporal-consistency regularization and enables self-calibrated parameter optimization. Experimental results based on five years of real-

收稿日期: 2025-06-20 Received Date: 2025-06-20

* 基金项目: 湖南省自然科学基金项目(2025JJ70057)、湖南工业大学研究生科研创新项目资助

vehicle operational data from two vehicle types demonstrate that the proposed model achieves a mean absolute error (MAE) below 0.2%, a root mean square error (RMSE) below 0.3%, and R-squared (R^2) above 99.5% under different state-of-health (SOH) conditions. The model exhibits superior stability and generalization performance in long-sequence prediction and battery degradation scenarios, significantly outperforming mainstream models such as Transformer, Informer, Mamba, and LSTM.

Keywords: electric vehicle energy consumption prediction; memory-driven intelligent network; adaptive Nyström attention; adaptive multi-scale spatiotemporal attention mechanism; temporal consistency regularization; HyperNetwork

0 引言

电动汽车 (electric vehicles, EVs) 作为当前和未来交通领域的重要发展方向,是应对环境污染和能源危机的重要途径。随着其普及率的不断提高,如何精准地预测其能耗成为了提升用户体验、提高电动汽车使用效率的关键问题之一^[1-2]。电动汽车的实时能耗预测是车主决策充电和出行规划的关键指标,但因受驾驶习惯、天气、路况和负载等多因素影响,准确预测面临挑战^[3]。因此,研究高效、准确的实时能耗预测模型对于推动电动汽车技术的普及和发展具有重要意义^[4]。

目前,电动汽车能耗预测方法主要分为基于物理模型的方法和基于数据驱动模型两类^[5]。基于物理模型的方法通常依赖于对电池特性的建模,如电池电压、电流、温度等信息,通过公式计算电动汽车能耗^[6],但因假设简化,预测精度有限^[7-9]。基于数据驱动的方法通过大量的历史数据训练模型,能够自动捕捉车辆行驶过程中的各种影响因素,提升能耗预测的准确性^[10-11]。早期研究多依赖传统机器学习算法^[12-13],文献[14]采用梯度提升决策树算法有效提升了预测性能,文献[15]提出融合驾驶工况预测的机器学习框架使精度较传统方法提升了30%,但存在计算复杂度高、对数据质量依赖性强等问题^[16]。

近年来,深度学习技术的突破性进展为电动汽车能耗预测开辟了新途径^[17],如循环神经网络 (recurrent neural network, RNN)^[18]、长短期记忆网络 (long-and short-term memory networks, LSTM)^[19] 和门控循环单元 (gated circulation unit, GRU)^[20] 等模型凭借自动特征提取能力显著提升了预测精度。文献[21]结合多尺度线性回归和神经网络利用实时路况动态预测能耗,文献[22]融合轻量级梯度提升机 (light gradient boosting machine, LightGBM) 和改进时序卷积网络 (temporal convolutional network, TCN)-GRU 有效提高了预测性能。然而,这些模型受梯度消失、计算复杂度高等问题制约^[23]。文献[24]提出 LSTM-深度神经网络 (deep neural network, DNN) 混合模型提升了续航预测精度,文献[25]提出基于 LSTM 和 Transformer 的能耗预测框架有效解决了长期依赖性问题。

在长序列时序建模方面,近年来涌现了多种新型架构。Mamba^[26] 基于选择性状态空间模型实现了线性复杂度的序列建模,在多项任务中展现出与 Transformer 相当的性能;扩展型长短期记忆网络 (extended long short term memory, xLSTM)^[27] 通过指数门控与矩阵记忆等改进增强了传统 LSTM 的长序列处理能力。然而,这些方法在电动汽车能耗预测场景中仍面临两方面局限:一方面缺乏对多尺度时空特征,路况图像与电池管理系统 (battery management system, BMS) 时序数据的跨模态融合能力,无法有效利用环境感知信息;另一方面缺少与预测目标深度耦合的自校准机制,在非平稳工况下的适应性不足。

本课题组前期工作在 CARLA 仿真平台上提出了环境感知强化学习框架用于能耗预测,通过对比学习与耦合深度 Q 网络 (deep Q network, DQN) 训练编码器,并引入多尺度特征融合与场景感知优先采样策略,验证了环境感知与强化学习结合用于能耗预测的可行性^[28]。然而,该方法采用标准 DQN 作为预测网络,缺乏对长序列时序依赖的深度建模能力,在处理长时间跨度的能耗数据时存在记忆衰减问题;同时其注意力计算复杂度为 $O(T^2)$,难以兼顾实时性与预测精度。

综上所述,现有方法仍存在3处不足:1)长序列能耗预测中记忆衰减问题突出,现有模型难以有效建模电池衰减与工况变化的长期累积效应;2)注意力计算复杂度过高,制约了长序列场景下的实时预测能力;3)多源异构数据的跨模态融合深度不足,环境感知对能耗预测的贡献有限。

针对上述问题,本文在前期环境感知强化学习框架^[28]基础上,提出基于记忆增强注意力网络的能耗预测模型 (DQN-adaptive memory augmented gating, DQN-AMAG),重点解决长序列建模能力与计算效率的瓶颈。本文的主要创新点为:

提出自适应 Nyström 低秩注意力 (adaptive Nyström attention, ANSA),基于 Nyström 方法对注意力矩阵进行低秩近似并结合自适应采样维度调整策略,将计算复杂度从 $O(T^2)$ 降至 $O(T \cdot r)$,在 1 200 步长序列下 MAE 仅增至 0.262%,远优于标准 Transformer 的 0.761%。

构建记忆驱动智能网络 (adaptive memory-augmented gating, AMAG),通过短期记忆、长期神经记忆 (含惊喜因子驱动的衰减机制) 与持久记忆的三级协同,增强对电池

衰减与工况变化等长时序累积效应的捕获能力,使模型在 SOH 从 100% 衰减至 80% 时 R^2 仍保持 99.5% 以上。

引入自适应多尺度时空注意力机制 (adaptive multi-scale spatiotemporal attention mechanism, AMSTA) 与超网络动态调参前向模型,增强路况图像与 BMS 时序数据的跨模态融合能力,并将 AMAG 嵌入强化学习框架实现参数自校准,提升模型在非平稳工况下的动态适应性。

1 基于记忆增强网络的能耗预测框架

1.1 框架概述

本文构建的 AMAG 预测框架如图 1 所示,由感知编码模块、记忆驱动预测网络和强化学习自校准模块 3 部分组成。




图 1 网络整体框架

Fig. 1 Overall network framework

在感知编码阶段,路况环境与行车状态等多模态高维观测信息 o_t 经过编码器 ϕ_{enc} 编码为低维表征。本文采用文献[28]提出的对比学习与耦合强化学习联合训练范式作为感知编码器的基础训练方法,该方法通过最小化预测潜在状态与真实潜在状态间的差异实现编码器参数优化,并通过强化学习损失的梯度回传实现编码器与决策网络的协同优化(详见文献[28])。在此基础上,本文进一步提出多尺度时空注意力机制 AMSTA 与超网络动态调参前向模型(详见第 2 章),以增强跨模态融合深度。

经编码后的低维表征输入 AMAG 记忆驱动智能网络,该网络作为强化学习框架中 Q 值网络的核心架构,通过三级记忆协同与 ANSA 低秩注意力实现长序列能耗预测(详见第 3 章)。强化学习模块通过时间差分算法交替更新当前 Q 网络与目标 Q 网络参数,实现预测模型的自校准式优化。

状态信息 $S_t = \{\text{天气, 路况, } d_t, v_t, \text{电池状态, 车辆}$

信息 $\}$,均来自 BMS。考虑到加速度 a_t 直接影响车辆的瞬时速度 v_t ,而速度与能耗呈非线性关系(如空气阻力与速度平方成正比),具体如式(1)所示。

$$P_t = \frac{1}{2} \rho C_d A v_t^3 + \mu m g v_t + m v_t a_t + P_{aux} \quad (1)$$

其中, P_t 为车辆瞬时功率, ρ 为空气密度, C_d 为阻力系数, A 为迎风面积, m 为车重, μ 为滚动摩擦系数, P_{aux} 为空调等附件功耗。

奖励函数 R 为状态转移 S_t 到 S_{t+1} 的实际电能消耗的值,如式(2)所示。

$$R_{t+1} = - \int_t^{t+\Delta t} P(\tau) d\tau \quad (2)$$

其中, $P(\tau)$ 为瞬时功率,由 BMS 直接测量。奖励取负值以使 Q 函数的最大化方向与能耗最小化方向一致。

状态 $S_{t+1} = \Gamma(S_t, a_t)$, 电池效率 η 随温度变化的建模如式(3)所示。

$$\eta(T) = \eta_0 \cdot \exp(-\alpha |T - T_{ref}|) \quad (3)$$

其中, η_0 表示常温参考效率, T_{ref} 为电池参考温度, α 为温度敏感系数。根据实验与文献[5,7]统计结果, η 的取值区间约为 $[0.85, 1]$ 。

1.2 强化学习自校准机制

本文将 AMAG 的记忆驱动网络嵌入 DQN 框架以实现预测参数的自校准式优化。需要强调的是,本文任务为能耗点预测,引入 DQN 的目的并非学习最优控制策略,而是利用时间差分(temporal difference, TD)学习在折扣未来累积量建模方面的优势,为预测网络提供时序一致性正则约束[28]。

具体而言,当前状态 S_t 与动作 a_t 共同输入 AMAG 网络,生成能耗评估值 $Q(S_t, a_t; \theta) = \text{AMAG}(S_t, a_t; \theta)$ 。目标 Q 值由目标网络计算,如式(4)所示。

$$y_t = R_{t+1} + \gamma \max_{a'} Q(S_{t+1}, a'; \theta^-) \quad (4)$$

模型以目标 Q 值与当前 Q 值之间的均方误差作为损失函数,参数更新如式(5)所示。目标网络参数 θ^- 则通过软更新方式从主网络同步调整即: $\theta^- \leftarrow \tau \theta + (1 - \tau) \theta^-$, 其中 τ 为软更新系数 ($0 < \tau \ll 1$), 用于控制更新速度。

$$\theta \leftarrow \theta - \alpha \nabla_{\theta} [(y_t - Q(S_t, a_t; \theta))^2] \quad (5)$$

该框架的收敛性已在文献[28]中给出严格证明。本文进一步分析 AMAG 记忆网络嵌入 DQN 后对收敛性的影响;由于 AMAG 的三级记忆模块引入了额外的隐状态(短期记忆 h_t 、长期记忆 J_t 、持久记忆 M_p),梯度在反向传播过程中需经过更长的计算路径。为此,本文在 AMAG 中采用门控残差连接策略,确保梯度流的畅通性。实验中观测到,AMAG 的训练损失在 5 000 轮左右即可稳定收敛,收敛速度较标准 DQN 提升约 30% (详见 4.2 节),验证了 AMAG 嵌入 DQN 框架的稳定性。

1.3 总框架算法复杂度与实时性分析

本文中的“实时性”指模型在车辆运行过程中可在秒级或亚秒级完成感知与预测。推理阶段的时间复杂度如式(6)所示。

$$O(T_{\text{infer}}) = O(L_{\text{enc}}) + O(L_{\text{AMAG}}) + O(L_H) \quad (6)$$

其中, $O(L_{\text{enc}})$ 为编码器处理高维观测数据的计算复杂度; L_{AMAG} 为 AMAG 网络(含 ANSA 机制)的前向传播复杂度, 由于 ANSA 将注意力计算从 $O(T^2)$ 降至 $O(T \cdot r)$, 该项相比标准 Transformer 显著降低; L_H 为超网络的复杂度。空间复杂度如式(7)所示。

$$O(S) = O(|\theta_{\text{enc}}|) + O(|\theta_{\text{AMAG}}|) + O(|\theta^-|) \quad (7)$$

推理阶段仅需一次前向传播与注意力融合, 延迟控制在百毫秒量级, 满足软实时需求; 训练阶段可离线完成, 不影响部署实时性。

2 多尺度时空感知与前向模型优化

本章介绍论文在感知编码层面的两项改进: AMSTA 多尺度时空注意力机制与超网络动态调参前向模型。这两项改进构建于文献[28]提出的对比学习编码器之上, 旨在增强跨模态融合深度与前向模型的动态适应性。

2.1 自适应多尺度时空注意力机制

传统编码器在处理多模态混合数据时往往独立建模, 难以捕捉模态间关联。为此, 本文在编码器中引入多尺度特征提取与 AMSTA 机制, 实现跨模态动态加权融合, 获得更精准的潜在状态表示 z_t 。

x_{img} 经 AMSTA 提取道路坡度、交通密度等可量化指标, 其中坡度直接映射至动力学方程的阻力项 $F_{\text{slope}} = mgsin\theta$, 而交通密度通过影响加速度决策 a_t 进而改变瞬时功率 P_t 。与此同时, 序列特征 x_{seq} 用于刻画电池状态的动态演化, 其可形式化为: $x_{\text{seq}}(t) = \{\text{SOC}(t-\Delta t), \text{SOC}(t-2\Delta t), \text{SOH}(t)\}$, 通过 Q 网络对其长期依赖进行建模。其中 SOC(state of charge) 为荷电状态, SOH(state of health) 为与健康状态。

首先, 计算图像特征的空间注意力权重, 并对多尺度特征自适应加权以获得最终表征, 计算如式(8)所示。

$$\begin{cases} \alpha_{\text{img}} = \sigma(W_{\text{img}} \cdot x_{\text{img}} + b_{\text{img}}) \\ \hat{x}_{\text{img}} = \alpha_{\text{img}} \odot x_{\text{img}} \end{cases} \quad (8)$$

其中, α_{img} 为图像每个空间位置的注意力分数; W_{img} 表示可学习的权重矩阵; b_{img} 表示可学习的偏置; $\sigma(\cdot)$ 为激活函数; $\odot$ 表示逐元素相乘(hadamard 乘积)。

其次, 对连续 k 帧图像及其对应的时序特征计算时间注意力权重, 并据此获取最终的时间融合表征, 计算如式(9)所示。

$$h_{\text{fused}} = \sum_{i=1}^k \beta_i \cdot [\hat{x}_{\text{img}}^{(i)}; \hat{x}_{\text{ts}}^{(i)}] \quad (9)$$

最后, 将两种特征进行融合, 并通过全连接层获得最终的潜在状态表征, 计算如式(10)。

$$z_t = FC(h_{\text{fused}}) \quad (10)$$

2.2 超网络动态调参前向模型

传统前向模型 T 往往依赖固定参数对状态 z_t 与动作 a_t 进行预测, 难以适应复杂环境下的不确定性。为此, 本文引入超网络(hypernetwork), 以动作 a_t 为输入, 通过 $H(\cdot; \phi)$ 生成融合权重 $w_t = H_t(a_t; \phi)$, 并与 z_t 结合, 构建自适应状态更新机制。

利用生成的权重 w_t 对当前状态 z_t 进行逐元素加权融合, 得到预测状态, 计算如式(11)所示。

$$\tilde{z}_{t+1} = f(w_t \odot z_t + b) \quad (11)$$

其中, $f(\cdot)$ 为激活函数, b 为偏置向量。通过反向传播算法优化超网络的参数 ϕ , 利用链式法则分解损失函数 L 对 ϕ 的梯度, 计算如式(12)所示。

$$\nabla_{\phi} L = \frac{\partial L}{\partial \tilde{z}_{t+1}} \cdot \frac{\partial \tilde{z}_{t+1}}{\partial w_t} \cdot \frac{\partial w_t}{\partial \phi} \quad (12)$$

随后, 通过梯度下降更新超网络参数 $\phi \leftarrow \phi - \eta \nabla_{\phi} L$, 其中, η 为学习率。超网络仅以动作为输入生成少量融合参数, 结构简洁且推理高效, 实测中每帧预测耗时控制在 100~200 ms, 满足亚秒级实时响应要求。

3 记忆增强型值函数网络架构

传统能耗预测模型在处理长时序数据时, 由于短期记忆受限, 难以准确捕捉复杂动态特征, 影响实时预测精度。本文提出的 AMAG 记忆驱动智能网络是 AMAG 模型的核心差异化贡献, 通过三级记忆协同与 ANSA 低秩注意力的联合设计, 有效应对电动汽车能耗预测中多因素长期耦合与环境动态变化的复杂性:

3.1 记忆驱动网络架构的应用

记忆驱动网络由短时记忆模块、长期神经记忆模块、持久记忆模块及 ANSA 机制组成, 结构如图 2 所示。测试阶段, 网络通过动态调用历史驾驶数据增强实时能耗预测精度, 尤其适用于电动汽车场景——其能耗受当前状态、历史加速度、电池状态及环境因素共同影响。训练阶段, 结合短时与长期神经记忆模块, 捕捉长期驾驶能耗变化趋势, 使预测框架能够聚焦关键历史状态。

长期神经记忆模块通过引入衰减机制和惊喜因子, 使其能够在测试阶段动态调整数据的记忆与遗忘策略, 具体计算如式(13)所示。

$$\begin{cases} M_t = M_{t-1} + S_t \\ S_t = h_t S_{t-1} + q_t J_t \\ J_t = -\nabla \ell(M_{t-1}; x_t) \end{cases} \quad (13)$$

其中, J_t 表示过去惊喜; $\nabla \ell(M_{t-1}; x_t)$ 表示瞬时惊

表 1 数据集统计信息
Table 1 Dataset Statistics

属性	A 车型	B 车型
车辆数量	5	5
电池容量/kWh	60	75
整车质量/kg	1 600	1 850
采集周期/年	5	5
BMS 采样频率/Hz	1	1
图像采样频率/fps	1	1
图像分辨率	128×128	128×128
总记录数	60 万	60 万

集的路况图像(分辨率 128×128,采样频率 1 fps)。总数据量约 120 万条记录,涵盖城市道路、高速公路、乡村道路等多种典型工况。需要说明的是,本文实验基于实车运行数据独立完成,与文献[28]所采用的 CARLA 仿真数据为不同来源。

2) 数据预处理

通过 Z-Score 标准化将数据转换为均值为 0、标准差为 1 的分布,如式 (21) 所示。采用 7:2:1 的比例按时间顺序将数据划分为训练集、验证集和测试集,确保无数据泄露。




图 4 车型 A 剩余里程估计曲线
Fig. 4 Model A remaining mileage estimation curve

表 2 不同车型预测剩余里程的评价指标
Table 2 Evaluation metrics for estimating remaining range across different vehicle models (%)

车型	A			B		
评价指标	MAE	RMSE	R ²	MAE	RMSE	R ²
SOH=100%	0.191	0.267	99.58	0.187	0.261	99.61
SOH=90%	0.193	0.271	99.54	0.189	0.265	99.57
SOH=80%	0.198	0.279	99.51	0.186	0.264	99.59

其中, x_i 为原始数据点, μ 为均值, σ 为标准差。

3) 实验参数及评价标准

开发环境为 PyCharm, 深度学习框架为 PyTorch 1.12, 编程语言为 Python 3.9。训练硬件平台为 CPU (Intel Core i5-9300H @ 2.40 GHz) 与 GPU (NVIDIA GeForce GTX 1650, 4 GB 显存), 单次完整训练耗时约 8 h。推理时间测试条件为 batch size = 1, 开启 CUDA 加速。主要超参数: 学习率 0.001, 折扣因子 γ 为 0.9、软更新系数 τ 为 0.005、ANSA 机制头数为 6。本文选取平均绝对误差 (mean absolute error, MAE) 和均方根误差 (root mean square error, RMSE) 作为模型的评价指标, 具体计算如式 (22) 所示。

$$\begin{cases} MAE = \frac{1}{n} \sum_{i=1}^n (|y_i - \hat{y}_i|) \\ RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \end{cases}$$

(22)

其中, y_i 表示真实值, $\hat{y}_i$ 表示预测值, n 是数据点的数量。

4.2 预测效果及其对比实验

1) 实际预测效果

为全面评估 AMAG 的预测性能及在不同运行条件下的泛化能力, 本研究分别选取 A、B 两种典型车型进行实验验证。图 4 展示了当电池健康状态 SOH 变化时该网络在 A 车型上的预测效果, B 车型的定量结果如表 2 所示。表 2 中 R^2 为决定系数 (R-square)。

表 2 的定量分析结果显示, 模型在不同车型和 SOH 条件下的 MAE 始终低于 0.2%、RMSE 低于 0.3%, R^2 均超过 99.5%。值得注意的是, SOH 从 100% 衰减至 80% 时, A 车型 R^2 仅从 99.58% 降至 99.51% (变化不超过 0.07 个百分点), B 车型甚至在 SOH = 80% 时 R^2 略有回升 (99.59%), 这得益于 AMAG 的长期记忆模块能够有效建模电池衰减的累积效应, 随着衰减信息的积累, 记忆模块的预测优势更加突出。需要指出的是, 本文

实验基于实车 BMS 运行数据,相比仿真环境数据包含更多噪声与不确定性,因此整体 MAE 和 RMSE 略高于文献[28]在 CARLA 仿真平台上的结果,但 R^2 仍稳定保持在 99.5% 以上,验证了模型在真实工况下的可靠性。

表 3 不同输入方式在各 SOH 状态下预测性能与推理效率对比

输入类型	指标	MAE/%	RMSE/%	R^2 /%	参数量/M	推理时间/ms
传统输入(BMS)	SOH=100%	0.218	0.301	97.62	2.3	38
	SOH=90%	0.214	0.296	97.71		36
	SOH=80%	0.211	0.292	97.94		40
多源输入 (图像+BMS)	SOH=100%	0.187	0.261	99.61	3.8	63
	SOH=90%	0.189	0.265	99.57		65
	SOH=80%	0.186	0.264	99.59		62

结果显示,多源输入在各 SOH 水平下均显著优于仅 BMS 输入,尤其在 R^2 指标上提升约 2 个百分点。尽管参数量略增(2.3 M→3.8 M),推理时间仍控制在 65 ms 内,满足亚秒级实时性。

3) ANSA 注意力机制对比实验

为验证 ANSA 机制在长序列建模中的有效性,本文在不同序列长度下(500、1 000、1 200 步)与标准 Transformer 注意力和文献[3]中的改进注意力机制进行了对比(表 4)。

表 4 不同序列长度下不同注意力机制预测性能对比

Table 4 Comparison of prediction performance of different attention mechanisms at different sequence lengths

序列长度	模型	MAE/%	RMSE/%
500	ANSA	0.199	0.315
	文献[3]-KAIInformer	0.315	0.671
	Transformer	0.442	0.776
1 000	ANSA	0.201	0.318
	文献[3]-KAIInformer	0.336	0.694
	Transformer	0.535	0.893
1 200	ANSA	0.262	0.385
	文献[3]-KAIInformer	0.437	0.712
	Transformer	0.761	1.026

ANSA 在序列从 500 步增至 1 200 步时 MAE 仅从 0.199% 增至 0.262% (增幅 32%),而 Transformer 的 MAE 从 0.442% 增至 0.761% (增幅 72%),充分说明 ANSA 通过 Nyström 低秩近似有效缓解了长序列记忆衰减问题。在计算效率方面,ANSA 将原始 1 200×1 200 的全局注意

2) 多源数据输入对预测性能与实时性的影响分析
为验证多源输入对能耗预测性能与实时性的影响,本文设计对比实验,分别使用传统 BMS 时序数据与融合摄像头图像的多源数据作为输入(表 3)。所有对比方法均采用相同的 AMAG 网络架构和训练配置。

力矩阵使用 256 列抽样进行近似,计算复杂度从 $O(1\ 200^2)$ 降至 $O(1\ 200\times 256)$ 。

4) 不同算法预测效果对比

为全面评估 AMAG 的优势,本部分将其与 Transformer、Informer、Mamba 及 LSTM 进行对比。所有对比模型均采用相同的多源输入数据与数据划分方式,超参数经过网格搜索优化至各模型最优配置。结果如表 5 所示。AMAG 在所有 SOH 条件和车型下均取得最优结果。

值得关注的是其在 SOH 衰减条件下的稳定性:如图 5 中不同模型在 A 车上的预测曲线,结合表中数据分析可知当 SOH 从 100% 降至 80% 时,AMAG 的 A 车型 R^2 仅从 99.58% 降至 99.51% (变化 0.07%),而 LSTM 下降 15%、Transformer 下降 15%、Informer 下降 11%,即使表现最稳定的 Mamba 也下降了 1.25%,这一优势主要源于 AMAG 三级记忆模块对电池衰减长期趋势的有效建模。




图 5 SOH=80% 时的估计曲线

Fig. 5 Estimated curve at SOH=80%

表 5 不同算法关键性能指标

Table 5 Key performance indicators of different algorithms

(%)

算法	评价指标	A			B		
		MAE	RMSE	R2	MAE	RMSE	R ²
LSTM	SOH=100%	0.723	1.187	89.73	0.714	1.136	90.02
	SOH=90%	0.768	1.248	83.81	0.774	1.166	83.49
	SOH=80%	0.812	1.359	74.58	0.808	1.368	76.45
Transformer	SOH=100%	0.327	0.383	95.92	0.339	0.386	95.76
	SOH=90%	0.413	0.441	88.72	0.403	0.434	89.36
	SOH=80%	0.444	0.496	81.06	0.429	0.489	81.21
Informer	SOH=100%	0.302	0.374	97.51	0.296	0.371	97.55
	SOH=90%	0.317	0.406	89.78	0.312	0.391	91.18
	SOH=80%	0.393	0.426	86.41	0.373	0.411	86.78
Mamba	SOH=100%	0.289	0.342	98.04	0.291	0.344	97.95
	SOH=90%	0.298	0.376	97.74	0.301	0.383	97.46
	SOH=80%	0.306	0.379	96.79	0.316	0.414	96.08
DQN-AMAG	SOH=100%	0.191	0.267	99.58	0.187	0.261	99.61
	SOH=90%	0.193	0.271	99.54	0.189	0.265	99.57
	SOH=80%	0.198	0.279	99.51	0.186	0.264	99.59

4.3 消融实验

为验证 AMAG 各关键模块的有效性,本研究设计了消融实验(表 6)。消融实验中各对比网络说明:D-

AMAG 仅使用 DQN 嵌入 AMAG 网络;S-AMAG 仅引入 AMSTA 感知模块;A-AMAG 仅引入 ANSA 注意力机制;DS-AMAG 和 DA-AMAG 分别为两两组合。

表 6 消融实验结果

Table 6 Results of ablation experiments

(%)

改进网络	DQN	ERL	ANSA	评价指标	A			B		
					MAE	RMSE	R ²	MAE	RMSE	R ²
D-AMAG	√			SOH=100%	0.283	0.354	95.87	0.289	0.361	95.72
				SOH=90%	0.298	0.367	95.24	0.276	0.342	96.38
				SOH=80%	0.278	0.341	96.53	0.297	0.348	95.89
S-AMAG		√		SOH=100%	0.274	0.338	96.71	0.294	0.342	95.98
				SOH=90%	0.306	0.362	93.08	0.311	0.369	92.85
				SOH=80%	0.328	0.394	91.17	0.332	0.401	90.94
A-AMAG			√	SOH=100%	0.262	0.321	97.68	0.279	0.332	97.19
				SOH=90%	0.304	0.357	93.52	0.299	0.354	93.24
				SOH=80%	0.316	0.392	91.59	0.311	0.388	91.62
DS-AMAG	√	√		SOH=100%	0.268	0.331	97.48	0.233	0.271	97.94
				SOH=90%	0.284	0.342	96.72	0.281	0.334	97.37
				SOH=80%	0.249	0.314	97.51	0.222	0.263	98.04
DA-AMAG	√		√	SOH=100%	0.271	0.336	96.76	0.267	0.331	97.15
				SOH=90%	0.276	0.322	97.41	0.243	0.283	97.76
				SOH=80%	0.269	0.338	97.01	0.274	0.326	97.05
AMAG(本文)	√	√	√	SOH=100%	0.191	0.267	99.58	0.187	0.261	99.61
				SOH=90%	0.193	0.271	99.54	0.189	0.265	99.57
				SOH=80%	0.198	0.279	99.51	0.186	0.264	99.59

DQN 自校准机制的稳定性贡献: D-AMAG 在不同 SOH 条件下变化最小 (R^2 波动不超过 1.3%), 而 S-AMAG 和 A-AMAG 的 R^2 分别下降 5.5% 和 6.1%。这表明 DQN 的 TD 学习机制通过时序一致性约束, 使 AMAG 网络在电池衰减条件下能够自适应调整预测参数, 而非依赖固定映射。

AMSTA 感知模块的精度贡献: DS-AMAG 相比 D-AMAG 在 SOH = 80% 时 MAE 降低 10.4%、RMSE 降低 7.9%。这源于 AMSTA 机制能够自适应地为不同模态的关键帧与关键区域分配注意力权重, 使模型在工况变化时仍能有效提取路况特征。

ANSA 低秩注意力的效率贡献: A-AMAG (仅 ANSA) 在 SOH = 100% 时 R^2 达 97.68%, 是单模块中表现最优的变体。DA-AMAG (DQN+ANSA) 在 SOH = 90% 时相比 D-AMAG 网络 MAE 降低 7.4%、RMSE 降低 12.3%, 表明 ANSA 通过低秩近似压缩冗余注意力计算, 在保持长序列建模精度的同时有效降低了计算开销。值得注意的是, DA-AMAG 在 SOH = 100% 时 R^2 (96.76%) 略低于 A-AMAG (97.68%), 这是因为在高健康状态下工况相对平稳, DQN 的自校准机制带来的额外参数更新反而引入了轻微扰动; 但随着 SOH 衰减至 90% 时, DA-AMAG 的 R^2 (97.41%) 显著超过 A-AMAG (93.52%), 说明 DQN 的自校准优势在动态工况下才充分显现。

三模块协同增益: AMAG 在 SOH = 100% 时 R^2 较 DS-AMAG 和 DA-AMAG 分别提升 2.1% 和 2.8%, MAE 降幅超过 28%。3 个模块存在显著协同: DQN 提供自校准能力, AMSTA 增强环境感知深度, ANSA 优化计算效率, 联合优化方能达到最优性能。

5 结 论

针对电动汽车长序列能耗预测中记忆衰减、计算效率瓶颈与动态适应性不足等问题, 本文在前期环境感知强化学习框架基础上, 提出基于记忆增强注意力网络的能耗预测模型 DQN-AMAG。该模型的核心贡献在于: 1) ANSA 自适应 Nyström 低秩注意力将计算复杂度从 $O(T^2)$ 降至 $O(T \cdot r)$, 在 1 200 步序列下 MAE 仅为 0.262%, 显著优于 Transformer 的 0.761%; 2) AMAG 三级记忆协同网络使模型在 SOH 从 100% 衰减至 80% 时 R^2 变化不超过 0.07 个百分点, 远优于对比模型; 3) AMSTA 与超网络增强了跨模态融合能力, 多源输入使 R^2 提升约 2 个百分点。

基于实车运行数据的实验结果表明, AMAG 在多种工况下 MAE 低于 0.2%、RMSE 低于 0.3%、 R^2 高于 99.5%, 显著优于 Transformer、Informer、Mamba 和 LSTM 等主流模型, 为电动汽车能耗预测提供了高效可靠的解决方案。

未来研究可从以下方向进一步拓展: 引入联邦学习机制实现多车协同训练, 提升模型泛化能力; 在更多车型和更长时间跨度的数据上验证模型的适用性; 探索模型轻量化部署方案, 使其适配嵌入式车载计算平台。

参考文献

- [1] 金帅, 董静. 基于数据驱动的锂离子电池健康状态估计研究进展综述[J]. 仪器仪表学报, 2024, 45(3): 45-59.
JIN SH, DONG J. Review on progress of data-driven based health state estimation for lithium-ion batteries[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 45-59.
- [2] 骆凡, 黄海宏, 王海欣. 基于电化学阻抗谱的退役动力电池荷电状态和健康状态快速预测[J]. 仪器仪表学报, 2021, 42(9): 172-180.
LUO F, HUANG H H, WANG H X. Rapid prediction of the state of charge and state of health of decommissioned power batteries based on electrochemical impedance spectroscopy[J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 172-180.
- [3] 彭自然, 王顺豪, 肖仲平, 等. 基于 KA Informer 的电动汽车动力电池荷电状态和健康状态估算[J]. 电工技术学报, 2025, 40(19): 6378-6394.
PENG Z R, WANG SH H, XIAO SH P, et al. State of charge and state of health estimation of electric vehicle power battery based on KA Informer model[J]. Transactions of China Electrotechnical Society, 2025, 40(19): 6378-6394.
- [4] TIAN CH L, LIU Y CH, ZHANG G Q, et al. Transfer learning based hybrid model for power demand prediction of large-scale electric vehicles[J]. Energy, 2024, 300: 131461.
- [5] ARMENTA-DÉU C, BOUCHEIX B. Evaluation of lithium-ion battery performance under variable climatic conditions: Influence on the driving range of electric vehicles[J]. Future Transportation, 2023, 3(2): 535-551.
- [6] BANDA P, BHUIYAN M A, HASAN K N, et al. Assessment of hybrid transfer learning method for forecasting EV profile and system voltage using limited EV charging data[J]. Sustainable Energy, Grids and Networks, 2023, 36: 101191.
- [7] 侯文博, 杨平, 陈可, 等. 电动汽车驱动复用升压技

- 术[J]. 电工技术学报, 2024, 39(S1):95-105.
- HOU W B, YANG P, CHEN K, et al. Multiplexing booster technology for electric vehicle drive[J]. Transactions of China Electrotechnical Society, 2024, 39(S1): 95-105.
- [8] ULLAH I, LIU K, YAMAMOTO T, et al. A comparative performance of machine learning algorithm to predict electric vehicles energy consumption: A path towards sustainability [J]. Energy & Environment, 2022, 33(8):1583-1612.
- [9] ACHARIYAVIRIYA W, WONGSAPEI W, JANPOOM K, et al. Estimating energy consumption of battery electric vehicles using vehicle sensor data and machine learning approaches [J]. Energies, 2023, 16(17): 6351.
- [10] SAUTERMEISTER S, FALK M, BÄKER B, et al. Influence of measurement and prediction uncertainties on range estimation for electric vehicles [J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(8):2615-2626.
- [11] ZHANG X F, ZHANG ZH, LIU Y, et al. A review of machine learning approaches for electric vehicle energy consumption modelling in urban transportation [J]. Renewable Energy, 2024, 234:121243.
- [12] 彭自然, 许怀顺, 肖伸平, 等. 深度优化的集成学习模型 EKSSA-CatBoost:实现光伏阵列故障高精度智能诊断[J]. 仪器仪表学报, 2025, 46(5):324-338.
- PENG Z R, XU H SH, XIAO SH P, et al. Deeply optimized integrated learning model EKSSA-CatBoost: Towards highly accurate intelligent diagnosis of PV array faults [J]. Chinese Journal of Scientific Instrument, 2025, 46(5):324-338.
- [13] 彭自然, 杨肖阳, 肖伸平. 基于 EKF-HInformer 模型估计汽车动力电池的 SOC&SOH[J]. 电子测量与仪器学报, 2025, 39(3):21-33.
- PENG Z R, YANG X Y, XIAO SH P. The SOC and SOH of the battery are estimated based on the EKF-HInformer model[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(3):21-33.
- [14] BI J, WANG Y X, SAI Q Y, et al. Estimating remaining driving range of battery electric vehicles based on real-world data: A case study of Beijing, China[J]. Energy, 2019, 169:833-843.
- [15] ZHANG J, WANG ZH P, LIU P, et al. Energy consumption analysis and prediction of electric vehicles based on real-world driving data[J]. Applied Energy, 2020, 275:115408.
- [16] SUN SH, ZHANG J, BI J, et al. A machine learning method for predicting driving range of battery electric vehicles[J]. Journal of Advanced Transportation, 2019, 2019(1):4109148.
- [17] LECUNC Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553):436-444.
- [18] CHEN J X, ZHANG Y, WU J, et al. SOC estimation for lithium-ion battery using the LSTM-RNN with extended input and constrained output[J]. Energy, 2023, 262: 125375.
- [19] HONG J CH, LIANG F W, YANG H X, et al. Multi-forward-step state of charge prediction for real-world electric vehicles battery systems using a novel LSTM-GRU hybrid neural network[J]. Etransportation, 2024, 20:100322.
- [20] 彭自然, 王顺豪, 肖伸平, 等. 一种精确估算电动汽车动力电池 SOC&SOH 的循环门控模型[J]. 电子测量与仪器学报, 2024, 38(9):11-23.
- PENG Z R, WANG SH H, XIAO SH P, et al. Cycle gating model for accurate estimation of SOC&SOH of power battery in electric vehicles[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(9): 11-23.
- [21] DE CAUWER C, VERBEKE W, COOSEMANS T, et al. A data-driven method for energy consumption prediction and energy-efficient routing of electric vehicles in real-world conditions[J]. Energies, 2017, 10(5):608.
- [22] WANG N, LYU Y L, ZHOU Y J, et al. A hybrid framework for remaining driving range prediction of electric taxis[J]. Sustainable Energy Technologies and Assessments, 2024, 67:103832.
- [23] PENG Z R, YANG X Y. Short-and medium-term power load forecasting model based on a hybrid attention mechanism in the time and frequency domains [J]. Expert Systems with Applications, 2025, 278:127329.
- [24] KIM D, SHIM H G, EO J S. A machine learning method for ev range prediction with updates on route information and traffic conditions [C]. 36th AAAI Conference on Artificial Intelligence, 2022, 36(11):12545-12551.

[25] FENG ZH Y, ZHANG J, JIANG H, et al. Energy consumption prediction strategy for electric vehicle based on LSTM-transformer framework [J]. Energy, 2024, 302:131780.

[26] GU A, DAO T. Mamba: Linear-time sequence modeling with selective state spaces [C]. First Conference on Language Modeling, 2024.

[27] BECK M, PÖPPEL K, SPANRING M, et al. xLSTM: Extended long short-term memory [J]. Advances in Neural Information Processing Systems, 2024, 37: 107547-107603.

[28] 彭自然, 杨肖阳, 舒中宾. 融合多源环境感知的强化学习能耗预测模型[J/OL]. 控制与决策, 1-12[2026-03-10].

PENG Z R, YANG X Y, SHU ZH B. Reinforcement learning-based energy consumption prediction model with

multi-source environmental perception [J/OL]. Control and Decision, 1-12[2026-03-10].

作者简介



彭自然 (通信作者), 2004 年于中南大学获得学士学位, 2008 年于中南大学获得硕士学位, 2017 年于中南大学获得博士学位, 现为湖南工业大学副教授, 主要研究方向为人工智能、智能检测仪表、智能移动终端等方面。

E-mail: pengziran@hut.edu.cn

Peng Ziran (Corresponding author) received his B. Sc. , M. Sc. , and Ph. D. degrees all from Central South University in 2004, 2008, and 2017, respectively. He is currently an associate professor at Hunan University of Technology. His main research interests include artificial intelligence, intelligent detection instruments, and intelligent mobile terminals.