考虑锂电池老化与热效应的电动汽车SAC能量管理策略

王 春 申渝秦* 曾权宏 唐 滔
四川轻化工大学机械工程学院,宜宾,644000

摘要:针对电动汽车混合动力储能系统在复杂动态工况下的多目标协调带来的实时决策与鲁棒性挑战,提出了一种基于软动作-评价(SAC)的能量管理策略。该策略融合专家先验约束以抑制非理性探索,加速在高维连续动作空间中的学习并增强稳定性。显式引入锂离子电池的热效应与老化模型,在充放电与功率分配上实现多目标协同优化,兼顾系统效率与电池寿命。在混合工况的10 ℃、25 ℃、40 ℃条件下,所提策略的能量损失性能分别达到动态规划方法的97.0%、98.2%和97.3%,展现出在复杂动态环境中更优的能效表现与可靠性。研究表明,结合物理特性建模与强化学习的混合方法为混合动力储能系统的智能调度提供了一条有效路径。

关键词:电动汽车;混合动力储能系统;能量管理;深度强化学习
中图分类号:U462.3
DOI:10.3969/j.issn.1004-132X.2026.10.013 **开放科学(资源服务)标识码(OSID)**:

SAC-based Energy Management Strategy for Electric Vehicles Considering Lithium Battery Aging and Thermal Effects

WANG Chun SHEN Yuqin* ZENG Quanhong TANG Tao
School of Mechanical Engineering, Sichuan University of Science and Engineering, Yibin, Sichuan, 644000

Abstract: A soft actor-critic (SAC)-based energy management strategy was proposed to address the real-time decision-making and robustness challenges arising from multi-objective coordination of HESS for electric vehicles under complex dynamic operating conditions. Expert prior constraints were integrated into the proposed strategy to curb erratic exploration, accelerate learning in high-dimensional continuous action spaces, and improve system stability. Meanwhile, thermal dynamics and aging models of lithium-ion batteries were explicitly incorporated, and multi-objective collaborative optimization of charging-discharging processes and power split was realized to balance system efficiency and battery lifetime. Under the mixed driving cycle at 10°C, 25°C, and 40°C, the energy-loss performance of the proposed strategy reaches 97.0%, 98.2%, and 97.3% of that achieved by the dynamic programming method, which demonstrates superior energy performance and reliability under varying thermal conditions. The results suggest that integrating physics-informed models with reinforcement learning is an effective route for adaptive HESS scheduling.

Key words: electric vehicles; hybrid energy storage system (HESS); energy management; deep reinforcement learning

0 引言

随着全球气候变化加剧,各国加快了推广绿色可持续交通方式的进程[1]。电动汽车(EV)作为减少化石燃料消耗与改善空气质量的关键技术,在续航、能量密度和电池性能上的进展被广泛关注[2-3]。当前,行驶过程中的高频、大倍率充放电等随机负载对锂电池热管理与寿命造成显著冲击,影响系统的安全性与稳定性[4]。

为缓解电池在动态工况下的应力,混合动力储能系统(hybrid energy storage system,HESS)成为研究热点,尤其是电池与超级电容器组合。超级电容器以其高功率密度和长循环寿命在瞬态高功率需求下分担电池负荷,从而减缓电池老化并提高系统性能。高效能量管理是实现HESS在续航、动力和经济性之间权衡的关键,但复杂动态工况下如何实现精确、实时的能量分配仍具挑战性[5]。

收稿日期:2025-08-10
基金项目:四川省自然科学基金(2024NSFSC0145,2026NSFSC1314);过程装备与控制工程四川省高校重点实验室开放基金(GK202405);四川轻化工大学科研创新团队计划(SUSE652A004)

当前HESS能量管理策略主要分为基于规则与基于优化两类[6-7]。前者因计算简便、响应快被广泛采用，但高度依赖专家经验，在多变工况下鲁棒性和全局最优性受限；后者如动态规划(DP)与模型预测控制虽能取得较好性能，却依赖准确预测且计算量大，难以满足在线实时需求。随着人工智能方法的发展，强化学习与深度强化学习(deep reinforcement learning，DRL)等数据驱动方法在复杂决策与连续控制问题中得到广泛应用[8-9]。这类方法能够通过与环境交互实现端到端策略学习，在不依赖精确预测模型的情况下具备一定自适应能力，同时也更容易在复杂工况下进行策略迭代与更新。然而，DRL在能量管理场景中仍面临训练过程不稳定、对环境不确定性等问题，容易出现策略可行但不够稳健或难以长期保持最优的情况。围绕上述挑战，国内外研究从层次化结构、奖励设计与训练机制等方面推动了DRL在能量管理中的应用，如采用分层框架以实现跟车控制与能量分配的协同[10]，或通过层次化与稀疏奖励处理提高收敛速度与决策质量[11]，同时也有研究将温度等物理量纳入状态表征以增强策略的稳定性[12]。这些研究表明，DRL为HESS能量管理提供了新的技术路径，但仅依赖纯数据驱动的策略学习仍难以在工程约束、连续高精度控制与泛化性之间取得理想平衡。

电池老化与温度变化会显著改变电池的可用能量与可用功率边界，从而影响能量管理策略在约束条件下的最优分配结果。电池老化通常表现为容量衰减与内阻增加，容量衰减直接降低单次循环可释放的能量，内阻增加会提高欧姆损耗并限制瞬时功率输出能力，因此在相同功率需求下更容易触发电压与功率约束，长期运行中也可能加速性能进一步衰退[13]。电池温度同样会影响开路电压与动力学过程，温度降低会使极化与内阻上升并显著降低可提取容量与功率，高温条件虽可能改善短时动力学表现，但会带来更高的副反应活性与安全风险，进而收紧可允许的工作边界并影响能量管理的收益评估[14]。因此，有必要将温度与老化相关的约束机制纳入能量管理框架。

现有HESS能量管理研究多集中于离散空间的能耗优化，往往忽略了电池物理特性(热与老化)对决策的深层影响。为应对上述挑战，本文提出一种融合专家经验、综合考虑锂电池热效应与老化的基于软动作-评价(soft actor-critic，SAC)的多目标协同优化能量管理框架，解决了纯数据驱动方法在物理约束下探索效率低的问题。

1　系统建模

1.1　HESS拓扑结构

本文构建了图1所示的混合储能系统模型，包含电池、超级电容器与双向DC-DC变换器[15]。系统中，超级电容与母线直接相连，负责承担瞬时高功率需求，电池串联DC-DC变换器，负责提供稳定的长期能量。二者通过DC-DC变换器协同，为DC/AC变换器供能，进而实现对外输出。

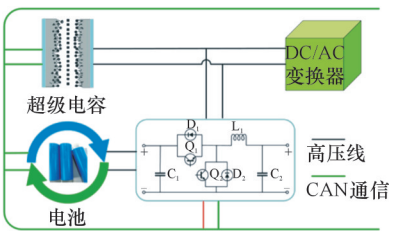

图1　HESS拓扑结构

Fig.1　Topological structure diagram of the HESS

1.2　电动汽车模型和参数配置

整车纵向动力学方程可表示为

$$F = mgf\cos\gamma + mg\sin\gamma + \frac{C_D A}{21.15}v_a^2 + \delta m\frac{\mathrm{d}v_a}{\mathrm{d}t} \quad (1)$$

式中：F为牵引力；v_a为行驶速度；m为整车质量；f为汽车滚动阻力系数；g为重力加速度；γ为坡度夹角；C_D为空气阻力系数；A为迎风面积；δ为旋转质量转化系数。

电动汽车的参数取值如表1所示[16]。

表1　电动汽车主要参数

Tab.1　Main parameter of electric vehicle

名称	取值	名称	取值
整车质量	1845 kg	滚动阻力系数	0.025
重力加速度	0.98 m/s^2	空气阻力系数	0.360
传动效率	82.1%	旋转质量转换系数	1.030
迎风面积	2.530 m^2		

为构建精确的电池与超级电容器模型，本文开展了混合动力脉冲特性(HPPC)测试，选用3.6 V 2 A·h 18650三元锂电池和2.7 V 1500 F超级电容器，在不同环境温度下采集其充放电响应，用于后续模型辨识与参数拟合。电池和超级电容器模型均采用更加准确的Thevenin模型[17]。图2展示了两者的等效电路模型，其中，U_{ocvb}和U_{ocvc}分别为锂电池和超级电容的开路电压，R_0为欧姆内阻，极化内阻和极化电容采用R_d和C_d表示，i_L是工

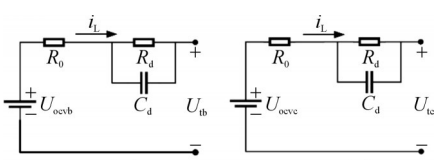

图2　等效电路模型

Fig.2　Equivalent circuit model

作电路的端电流，U_{tb}和U_{tc}分别是电池和超级电容的端电压。

锂电池Thevenin模型的离散电路方程为

$$\left.\begin{aligned}U_d(k)&=U_d(k-1)e^{-\Delta t/\tau}+i_L(k)R_d(1-e^{-\Delta t/\tau})\\U_{tb}(k)&=U_{ocvb}(k)-U_d(k)-i_L(k)R_d\end{aligned}\right\}\quad(2)$$

$$C_{SOC}(t)=C_{SOC}(t_0)-\frac{\int_{t_0}^{t}\eta_L i_L\mathrm{d}t}{C_a}\quad(3)$$

式中：U_d为RC网络两端的极化电压；k、Δt、τ分别为采样时间、采样间隔和时间常数；$C_{SOC}(t)$为第t时刻锂电池的荷电状态(state of charge，SOC)估计值；$C_{SOC}(t_0)$为初始时刻的SOC值；η_L为锂电池充放电的效率；C_a为锂电池在当前环境中的实际最大可用容量。

超级电容Thevenin模型的离散电路方程为

$$\left.\begin{aligned}U_d(k)&=U_d(k-1)e^{-\frac{\Delta t}{\tau(k-1)}}+(1-e^{-\frac{\Delta t}{\tau(k-1)}})i_L(k)\cdot R_d(k-1)\\U_{tc}(k)&=U_{ocvc}(k)-U_d(k)-i_L(k)R_d(k)\end{aligned}\right\}\quad(4)$$

$$C_{SOC}(t)=C_{SOC}(t_0)-\frac{\int_{t_0}^{t}\eta_L i_L\mathrm{d}t}{Q_{max}}\quad(5)$$

式中：Q_{max}为超级电容的可用容量。

锂电池的老化由循环老化和日历老化两部分叠加组成，其量化计算过程如图3所示[18]。循环老化是指锂电池在使用过程中容量因充放电循环而不断衰减的过程；日历老化则描述容量随时间变化的衰减过程，该过程受到温度的显著影响。

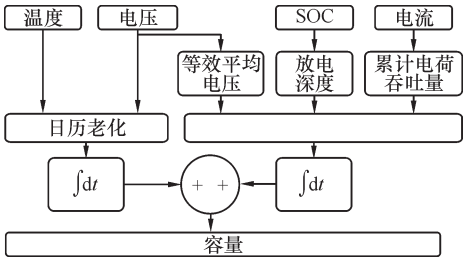

图3 锂电池老化量化计算过程

Fig.3 Lithium battery aging calculation process

锂电池老化模型表示为

$$H_{SOH}=1-\alpha_{cap}t^{0.75}-\beta_{cap}\sqrt{Q}\quad(6)$$

式中：H_{SOH}为健康状态(state of health，SOH)；α_{cap}为日历老化依赖系数；β_{cap}为循环充放电深度和二次平均电压的依赖情况；Q为累计电荷吞吐量。

锂电池在使用过程中会产生热量，使电池及其周围温度变化[19]。温度升高时，频繁充放电会促使固体电解质界面膜(SEI)反复生长与破裂，从而加速局部老化、引起容量与性能衰减。而在低温、大电流充放电条件下则更容易发生析锂现象，同样加剧老化并影响安全性。锂电池的热耦合遵循能量守恒定律，它产生的热量由欧姆热、极化热和不可逆熵热组成。锂电池的热量变化可表示为如下热平衡方程：

$$m_b c_p\frac{\mathrm{d}T(t)}{\mathrm{d}t}=(i(t))^2R_0+\frac{U_d^2}{R_d}-h_c A_b(T(t)-T_a)\quad(7)$$

式中：m_b为电池的质量；c_p为电池质量定压热容；$T(t)$为第t时刻的电池温度；$i(t)$为t时刻电池的充放电电流；h_c为传热系数；A_b为电池外表面面积；T_a为电池工作状态的环境温度。

DC-DC变换器的效率η_{DC}与输入电流i_{DC}和输出功率P_{DC}密切相关。将效率的变化特性绘制为三维响应曲面图，见图4。图中清晰呈现了效率随输入电流和输出功率变化的非线性关系，为后续能量管理策略的优化提供了数据支持。

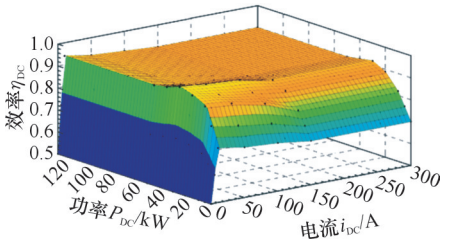

图4 DC/DC变换器效率响应曲面

Fig.4 The efficiency response surface of DC/DC converter

2 基于SAC算法的能量管理策略

2.1 算法原理

SAC是一种面向高维连续动作空间的深度强化学习算法。与针对离散化动作空间的DDQN相比，SAC通过引入熵正则化和“软”策略更新，在最大化累积奖励的同时鼓励策略保留一定随机性，从而提高探索能力并缓解策略评估不稳定、动作空间离散化带来的限制与样本利用效率低的问题。SAC优化目标在保留高回报的前提下加入熵项以平衡收益与随机性，表示为

$$J(\pi)=\sum_{t=0}^{T}E_{(S_t,A_t)\sim\rho_\pi}[r(S_t,A_t)+\alpha H(\pi(\cdot|S_t))]\quad(8)$$

式中：$J(\pi)$表示策略π的优化目标函数；T为终止时刻；S_t为智能体在时间步t观测到的环境状态信息；A_t为在时间步t做出的执行动作；ρ_π为π采样产生的轨迹分布；$E[\cdot]$表述针对“状态-动作对”计算的数学期望函数；r为动作在对应环境中的奖励；温度系数α控制奖励和熵之间的平衡；$H(\pi(\cdot|S_t))$为策略熵，用来衡量策略π在状态S_t下动作选择的随机程度。

为了适应不同的任务需求，SAC还引入了动态温度系数调整机制[20]，通过优化以下目标函数实现对温度系数α的自适应调节：

$$J(\alpha)=E_{A\sim\pi}[-\alpha\ln\pi(A_t|S_t)-\alpha\mathcal{H}_{tar}]\quad(9)$$

其中，$A\sim\pi$表示动作A服从策略π的分布采样；$\mathcal{H}_{tar}$为目标熵，用于定义策略的随机性水平。动态调整α使得SAC在探索和利用之间始终保持

最优的平衡，从而适应不同复杂度的任务场景。

2.2　基于SAC算法的能量管理框架

通过构建合理的状态空间、动作空间与奖励函数，使基于SAC的能量管理策略能够在复杂运行条件下实现高效且稳定的复合电源系统调控。

2.2.1　状态空间

在混合储能系统的能量分配决策中，综合考虑超级电容与锂离子电池的剩余容量以及电动汽车的瞬时负载功率，对提高能量管理策略性能至关重要，因此，系统的状态空间定义为

$$S=\{C_{\mathrm{SOC,Bat}},C_{\mathrm{SOC,UC}},P_{\mathrm{req}}\} \tag{10}$$

式中：下标Bat、UC分别表示锂离子电池、超级电容；P_{req}为电动汽车的瞬时负载功率。

2.2.2　动作空间

如图1所示，在电动汽车的复合电源拓扑中，电能由电池组和超级电容组共同提供。在已知负载功率需求的前提下，智能体通过动作决定两者的功率分配。由于SAC输出的是连续动作，故将动作定义为

$$action=\{I_{\mathrm{Bat}}|I_{\mathrm{Bat}}\in[-100\mathrm{A},100\mathrm{A}]\} \tag{11}$$

式中：I_{Bat}为电池充放电电流。

2.2.3　奖励函数

为实现多目标权衡，SAC奖励函数构造为

$$r(S_t,A_t)=-\alpha_s L_{0t}+L_{\mathrm{E}}+b \tag{12}$$

式中：α_s为成本函数的缩放系数；L_{0t}为复合电源消耗成本；L_{E}为专家经验；b为奖励函数值的偏差补偿。

2.2.4　基于SAC算法的整体框架

为实现HESS中电池与超级电容的高效能量分配，提出基于SAC的控制框架，如图5所示，描绘了从环境感知到能量分配执行的完整流程。

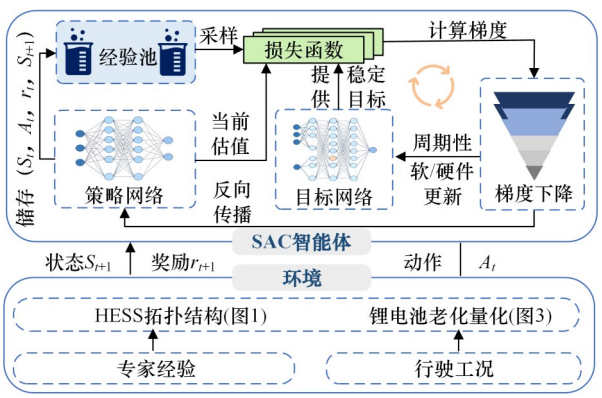

图5　基于SAC-DRL的能量管理框架

Fig.5　EMS framework based on SAC-DRL algorithm

智能体通过与环境的交互，在给定当前状态和奖励信号的条件下，利用软Q网络、策略网络与价值网络协同学习，逐步优化能量管理策略，并输出电池与超容的功率调度指令，通过DC-DC变换器执行。为抑制因过强的探索引发的违反物理约束或低效的非理想动作，引入基于领域知识的专家经验(LE)规则集，对动作进行约束与修正，不满足要求的动作会被惩罚，从而引导策略向合理动作空间聚拢。为验证方法有效性，本文在典型车辆工况下进行了仿真，智能体借助经验回放与策略更新在动态环境中不断提高性能。

2.2.5　超参数设置

本文结合SAC算法特点与能量管理需求，对超参数进行了精细配置，见表2。为了在表达能力与过拟合风险之间取得平衡，批评者和行动者网络均采用两层、每层32个神经元的全连接结构。学习率分别设为0.0002和0.0001，适度更新步长，避免收敛过慢或振荡。为抑制过拟合，二者引入了L2正则化，系数分别为0.0001和0.0002。折扣因子取0.999，体现对长期回报的重视，促使策略对未来能源利用保持敏感。经验回放池容量为1 000 000，配合批量大小128，既保证了样本多样性，又兼顾训练效率。目标网络的平滑系数设为0.001，通过平滑目标值的变动，增强了学习的稳定性并有助于智能体收敛到更优策略。

表2　SAC-DRL算法的超参数设置

Tab.2　hyperparameters for SAC-DRL algorithm

参数	设置或值
批评者网络	Fully-connected Layer 32-32
批评者网络学习率	0.0002
批评者网络L2正则化系数	0.0001
行动者网络	Fully-connected Layer 32-32
行动者网络学习率	0.0001
行动者网络L2正则化系数	0.0002
折扣系数	0.999
经验池缓存大小	1 000 000
随机体验最小批量	128
平滑系数	0.001

3　结果与分析

3.1　训练环境

本文采用典型城市道路循环工况(UDDS)作为训练场景对智能体进行训练。实验中，电池的初始荷电状态在0.4～0.9之间取值，超级电容的初始荷电状态在0.8～0.9之间取值，二者均按照均匀分布采样。为了反映实际复杂运行条件下的影响，分别在常温和40℃两种温度环境下运行锂电池，以便系统地评估高温条件对电池热响应与老化行为的影响。

3.2　训练结果分析

本文中基于SAC算法的能量管理策略在各温度工况下性能均显著优于DDQN算法，且引入专家经验后性能进一步提高。定量结果如图6和

图7所示，在未引入专家经验的条件下，SAC在10 ℃、25 ℃与40℃下的能量损失分别为5406.1、5048.8、4904.2 kJ，比对应的DDQN能量损失（7423.7、6693.8、6642.9 kJ）分别降低了27.2%、24.6%和26.2%。该优势主要来源于SAC在连续动作空间中对锂电池与超级电容充放电行为的精细化策略优化能力，有效抑制了能量损耗。通过在奖励函数中显式引入专家规则约束，对非理性探索进行惩罚，SAC在三种温度下的能量损失进一步降至5237.2、4870.6、4717.4 kJ，较未引入专家经验分别降低3.1%、3.5%和3.8%，显示出专家先验对探索效率和策略收敛性的正向增强。与同样融合专家经验的DDQN相比，SAC在40℃时能量损失从4837.1 kJ下降到4717.4 kJ，进一步降低2.4%，证实了专家经验在“冷启动”阶段有效加速了策略收敛，并在稳态阶段显著增强了系统的鲁棒性与寿命保护能力。SAC算法支持连续动作输出，能够实现精细功率调节。此外，本文利

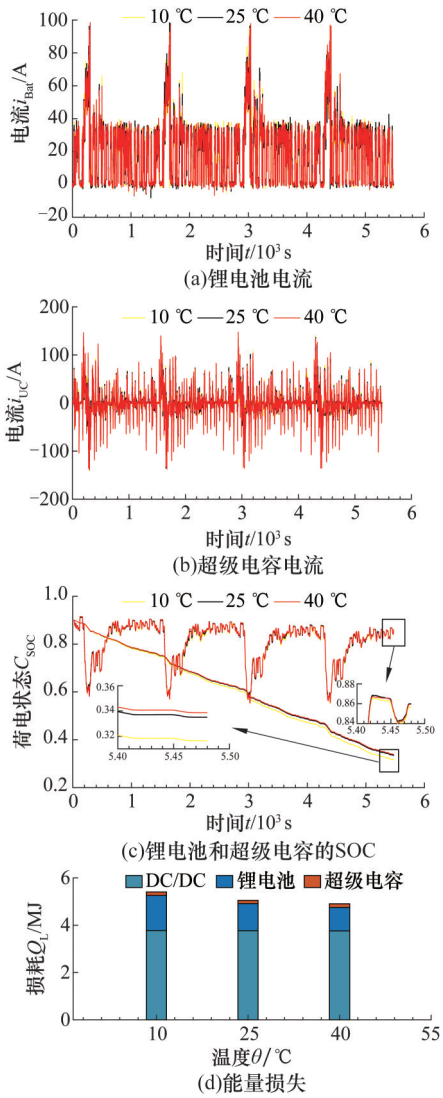

图6 SAC测试结果

Fig.6 Test results of SAC

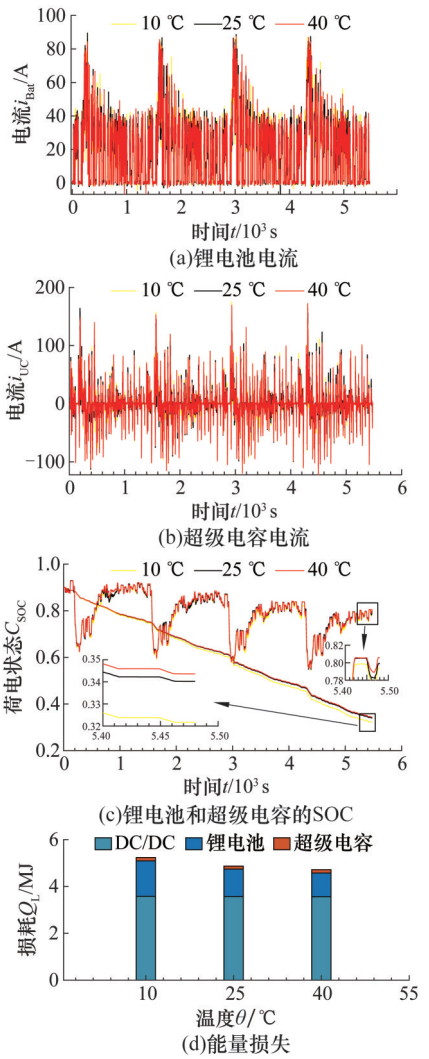

图7 SAC测试结果（专家经验）

Fig.7 Test results of SAC（expertise）

用SAC独特的最大熵正则化机制，在奖励函数中平衡了利用与探索，有效避免了在复杂动态工况下陷入局部最优。其SOC轨迹，尤其是超级电容部分，呈现更平滑的变化，强化了削峰填谷效应并降低对锂电池的瞬态应力，有助于延缓电池劣化、延长系统寿命。综合来看，SAC在复杂工况下展现出更强的适应性、策略优化能力与鲁棒性，且在专家经验引导下学习效率和管理性能进一步增强，表明该组合策略在实际能量管理任务中具有更高的可靠性与应用价值。

3.3 考虑老化和热的优化结果

本文提出基于SAC的多种能量管理策略，即Tag1～Tag8，并在环境温度为40℃下进行性能评估与对比。Tag1为基础SAC策略，Tag2至Tag4分别在Tag1基础上引入了老化、热效应及两者的耦合因素，Tag5至Tag8则在前述策略的基础上进一步结合专家经验。

如图8所示，在40℃条件下的对比分析揭示，

引入老化与热效应的SAC策略通过协同调节放电电流与充放电频率，有效抑制了温度的上升趋势，从而缓解了热衰退对电池性能的不利影响。这种策略建模实现了温控与退化抑制之间的合理平衡。进一步融合专家经验后，智能体在高维决策空间中的探索效率显著提高，促使内部化学反应更为高效。尽管末端温度有所上升，具体表现为Tag6在4个循环工况中的最高温度达到50.27 ℃，仅比未引入专家经验的对应策略增高约0.26%，整体能量利用率却获得了实质性的提高。由此可见，专家先验有效弥补了纯数据驱动策略在收敛性与探索能力上的不足，在可控的热代价范围内实现了性能的进一步优化，充分体现了高温复杂工况下热管理与能量效益之间的细腻权衡与潜在优化空间。

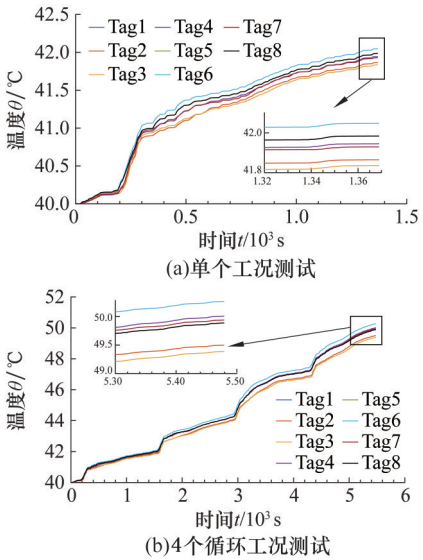

图8　锂电池温度变化曲线

Fig.8　Lithium battery temperature curve

锂电池SOH的变化情况如图9所示，可以看出，Tag8策略在减缓电池老化速度方面表现出显著优势。该策略不仅使SOH损失幅度达到最小且波动最小，约为0.000 004，且明显优于其他策略。相比之下，Tag1策略的SOH损失接近Tag8的两倍，显示出较快的老化趋势。结果表明，经过专家经验优化后的智能体在高温复杂工况下展现出更强的学习能力和适应能力，有效提高了电池的健康维护效果。

不同策略下锂电池和超级电容SOC变化情况如图10所示，对比结果验证了Tag8策略的优越性。该策略的SOC水平仅次于DP，锂电池剩余SOC为0.3458，超级电容剩余SOC为0.7624。结果表明，结合专家经验的SAC策略显著提高了能量分配效率与系统运行的稳定性，体现出良好的能量管理能力。

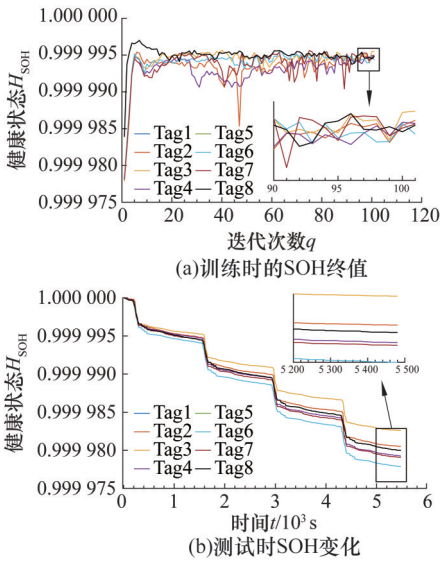

图9　锂电池SOH变化曲线

Fig.9　SOH curve of lithium battery

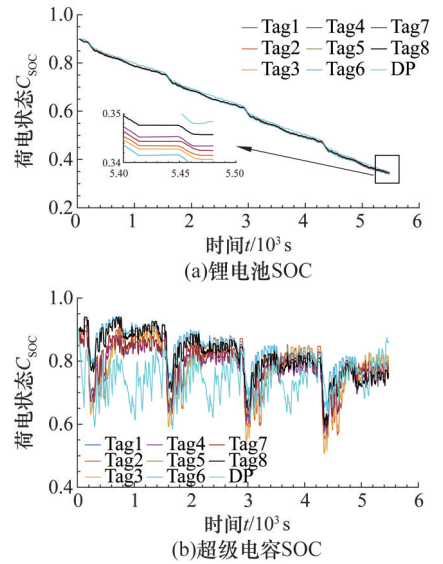

图10　在不同策略下锂电池和超级电容的SOC

Fig.10　Lithium battery and ultracapacitor SOC under different strategies

3.4　能量损失对比

电动汽车复合电源系统的能量损失是影响整体运行效率的关键因素，尤其在锂电池温度维持于合理范围内时更为显著。为了评估不同能量管理策略在多种温度条件下的运行成本，本文对锂电池、超级电容及DC-DC变换器的能量损失进行了系统分析。图11与表3分别展示了各策略在不同温度工况下，各主要部件引起的能量损失统计结果。

DC/DC变换器是能量损失的主要来源，其次为锂电池的内阻损失和极化损失。Tag8策略综合考虑了锂电池老化与热效应，并通过专家经验进行了优化，代表了一种基于SAC深度强化学习的能量管理方法。测试结果显示，在10 ℃、25 ℃

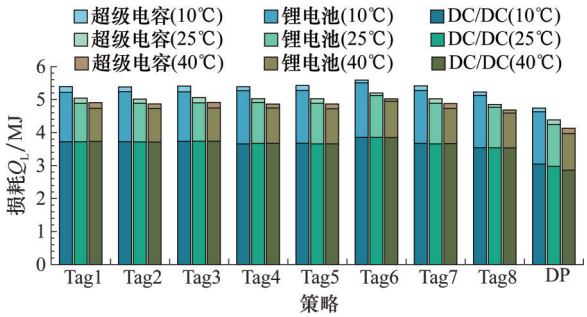

图11 策略能量损失的比较

Fig.11 Comparison of energy loss of strategy

和40 ℃工况下，Tag8策略相比基础策略Tag1的能量损失分别降低了3.1%、3.7%和4.5%，相较于Tag4则降低了3.0%、3.4%和3.7%。值得注意的是，部分策略在引入专家经验后能量损失反而有所增加，表明不合理的专家经验可能对锂电池老化和热效应的优化产生负面影响，因此，合理设计和引入专家经验对提高智能体在复杂环境中的探索效率和学习能力具有重要意义。总体而言，Tag8策略的能量损失更接近全局最优的DP策略，体现出其在总成本优化方面的优越性能。

表3 策略能量损失统计

Tab.3 Energy loss statistics of strategy kJ

温度	Tag1	Tag2	Tag3	Tag4	Tag5	Tag6	Tag7	Tag8	DP
10℃	5394.3	5381.4	5408.9	5389.3	5424.4	5587.8	5416.2	5227.1	4740.2
25℃	5044.1	5014.2	5059.7	5026.8	5026.2	5198.1	5024.7	4853.1	4384.6
40℃	4907.6	4866.9	4913.9	4863.9	4864.9	5020.3	4877.1	4683.9	4133.3

仅在UDDS工况下测试不足以反映所提策略在不同环境和工况下的适应性与泛化性，因此构造混合工况在不同温度下进行测试。所选择的工况分别为印度高速工况India-HWY、sample-WUVINTER工况和UDDS循环工况。混合工况速度如图12所示，该混合工况速度分布较为贴合郊区、高速及市区的典型行驶模式。基于此工况，本文在10 ℃、25 ℃和40 ℃条件下测试了复合电源各部件的能量损失，见图13和表4。

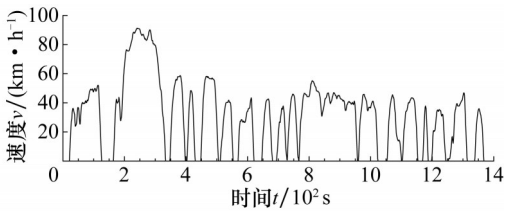

图12 混合工况速度

Fig.12 The speed of the mixed cycle condition

对比分析发现，本文提出的Tag8策略在10 ℃条件下实现了最低的能量损失，与基础策略Tag1相比降低了1.5%。在25 ℃和40 ℃条件下，Tag8相较于Tag1的能量损失分别降低了1.8%和2.2%。此外，将Tag1～Tag4与Tag5～Tag8所对应的能量管理策略进行比较，发现引入专家经验有助于智能体更好地解耦复杂环境中的多重因素，提高策略表现。值得注意的是，Tag8在

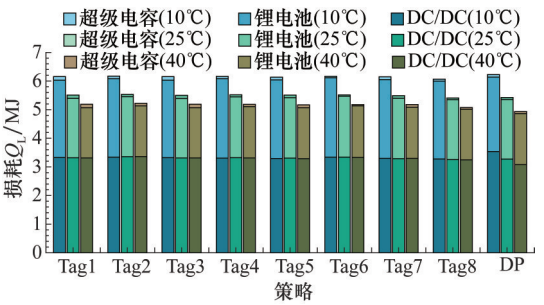

图13 策略能量损失的比较(混合工况测试)

Fig.13 Comparison of energy loss of strategy (composite cycle test)

10 ℃、25 ℃和40 ℃条件下分别达到DP方法的97.0%、98.2%和97.3%，表明该策略在混合工况下更接近DP的能量管理效果，具有一定的应用潜力。

为验证所提出的能量管理方法Tag8在不同工况下测试结果的可重复性，本文在新标欧洲循环测试的城市工况(NEDC)与高速工况(HWFET)下进行多次重复实验。在保持相同初始条件与参数设置不变的情况下，仅改变随机数种子(seed取1、50、100、150、200)重复运行，并统计总能量损耗。结果显示，Tag8在两类典型工况下均具有较好的稳定性，NEDC工况下的总能量损耗为(4731.12±5.09) kJ，HWFET工况下的总能量损耗为(14216.40±13.71) kJ。详细结果见表5。

表4 策略能量损失统计(混合工况测试)

Tab.4 Energy loss statistics of strategy (composite cycle test) kJ

温度	Tag1	Tag2	Tag3	Tag4	Tag5	Tag6	Tag7	Tag8	DP
10 ℃	6157.5	6171.3	6153.8	6161.8	6135.8	6164.6	6149.7	6064.9	5880.0
25 ℃	5507.5	5533.3	5500.1	5521.1	5508.7	5515.5	5488.2	5407.2	5308.7
40 ℃	5189.5	5222.1	5189.3	5185.4	5166.0	5177.9	5181.1	5074.6	4935.6

表5　不同随机种子下NEDC与HWFET工况的总能量损耗

Tab.5　Total energy consumption of NEDC and HWFET driving cycles with different random seeds　kJ

随机数种子	NEDC	HWFET
1	4728.60	14 208.48
50	4725.36	14 213.88
100	4738.32	14 235.84
150	4728.96	14 200.56
200	4733.64	14 223.24

3.5　决策时间分析

统计Tag8在仿真过程中的计算耗时。本文仿真采用离散时间步长dt=1 s，即每个控制步对应1 s的工况采样间隔。在UDDS、HWFET与NEDC三种典型工况下，记录每个仿真步的总计算耗时(step time)以及智能体策略网络输出动作的决策耗时(agent time)，并统计均值(mean)、最大值(max)与最小值(min)等指标，结果见表6。

表6　在不同工况下的单步计算耗时统计

Tab.6　Statistics of single-step computation time under different operating conditions　ms

工况	step mean	step max	step min	agent mean	agent max	总耗时
UDDS	3.0	37.29	1.7	1.3	35.73	16 587.0
HWFET	3.3	12.34	1.9	1.4	11.16	10 221.3
NEDC	3.1	12.53	1.9	1.3	11.24	14 608.8

由表6可见，Tag8在三种工况下的平均单步决策时间为1.3～1.4 ms，对应的平均单步总计算时间为3.0～3.3 ms。由于单步决策耗时与单步总耗时均显著小于控制步长dt=1 s(即远小于每秒一次的控制更新预算)，因此所提方法在仿真环境中具备良好的计算效率，能够满足在线控制的实时性需求。此外，单步耗时的最大值反映了少数时间步的偶发计算峰值，但其数量较少且不改变总体平均水平。

4　结论

本文所提出的框架充分融合了基于模型的优化方法与基于数据驱动的学习方法的优势，显著提高了能量分配策略的学习效率并有效降低了运行成本。具体而言，有以下结论：①提出的SAC深度强化学习算法结合了专家经验，弥补了DDQN算法有限动作空间的不足，显著提高了智能体在复杂环境中的探索和学习能力；②仿真结果表明，在引入专家经验(Tag8)的设置下，考虑锂电池老化和热效应的基于SAC的能量管理策略在10℃、25℃和40℃测试条件下能量损失分别降低1.5%、1.8%和2.2%，相比于传统的DDQN策略表现出更好的学习能力和适应性；③引入的锂电池老化模型和热模型显著提高了复合电源系统模型的精度与鲁棒性，为优化能量分配策略提供了可靠的理论依据。

未来的研究工作将重点从以下两方面展开：①引入多任务学习或迁移学习机制，提高能量管理策略在不同车型和复杂多变环境下的自适应能力；②开展硬件在环实验，针对计算资源受限的实际场景优化算法结构，以平衡控制精度与计算效率，推动研究成果向工程应用转化。

参考文献：

[1] 唐香蕉，高祖成，曾令全，等. 城市道路下混合动力汽车双层能量管理策略[J]. 中国机械工程，2022，33(16)：2008-2015.
TANG Xiangjiao，GAO Zucheng，ZENG Lingquan，et al. A Double-layer Energy Management Strategy for HEVs under Urban Traffics[J]. China Mechanical Engineering，2022，33(16)：2008-2015.

[2] 严正峰，蒋光宗，姚明尧. 驱动系统效率最优的并联混合动力商用车模式切换及换挡控制策略[J]. 中国机械工程，2024，35(2)：354-363.
YAN Zhengfeng，JIANG Guangzong，YAO Mingyao. Mode Transition and Gear Shifting Control Strategy for Parallel Hybrid Commercial Vehicles Based on Optimal Drive System Efficiency[J]. China Mechanical Engineering，2024，35(2)：354-363.

[3] 吴进军，颜丙杰，方继根，等. 插电式混合动力汽车的次优能量管理策略[J]. 中国机械工程，2019，30(11)：1336-1342.
WU Jinjun，YAN Bingjie，FANG Jigen，et al. Sub-optimal Energy Management Strategy for Plug-in Hybrid Electric Vehicles[J]. China Mechanical Engineering，2019，30(11)：1336-1342.

[4] 尤国贵，卢剑伟，张国军，等. 插电式混合动力汽车能量管理策略研究综述[J]. 机械工程学报，2025，61(4)：195-218.
YOU Guogui，LU Jianwei，ZHANG Guojun，et al. Review of Research on Energy Management Strategy for Plug-in Hybrid Electric Vehicles[J]. Journal of Mechanical Engineering，2025，61(4)：195-218.

[5] WANG C，XIONG R，HE H，et al. Comparison of Decomposition Levels for Wavelet Transform Based Energy Management in a Plug-in Hybrid Electric Vehicle[J]. Journal of Cleaner Production，2019，210：1085-1097.

[6] 曾繁琦，袁晓静，王旭平，等. 基于荷电状态惩罚函数的能量管理策略优化方法[J]. 中国机械工程，2022，33(7)：852-857.
ZENG Fanqi，YUAN Xiaojing，WANG Xuping，et al. Energy Management Strategy Optimization Method Based on SOC Penalty Function[J]. China Mechanical Engineering，2022，33(7)：852-857.

[7] 曹延旭，魏中宝，宋若旸，等. 基于深度强化学习的跟驰场景中燃料电池混合动力汽车多目标能量管理研究[J]. 机械工程学报，2025，61(12)：191-203.
CAO Yanxu，WEI Zhongbao，SONG Ruoyang，et al. Research on Multi-objective EMS of Fuel Cell Hybrid Electric Vehicle under Car Following Scenario Based on Deep Reinforcement Learning[J]. Journal of Mechanical Engineering，2025，61(12)：191-203.

[8] WANG J, ZHOU J, ZHAO W. Deep Reinforcement Learning Based Energy Management Strategy for Fuel Cell/Battery/Supercapacitor Powered Electric Vehicle[J]. Green Energy and Intelligent Transportation, 2022, 1(2): 100028.

[9] MNIH V, KAVUKCUOGLU K, SILVER D, et al. Human-level Control through Deep Reinforcement Learning[J]. Nature, 2015, 518(7540): 529-533.

[10] 唐小林，陈佳信，刘腾，等. 基于深度强化学习的混合动力汽车智能跟车控制与能量管理策略研究[J]. 机械工程学报，2021，57(22)：237-246.
TANG Xiaolin, CHEN Jiaxin, LIU Teng, et al. Research on Deep Reinforcement Learning-based Intelligent Car-following Control and Energy Management Strategy for Hybrid Electric Vehicles[J]. Journal of Mechanical Engineering, 2021, 57(22): 237-246.

[11] QI C, ZHU Y, SONG C, et al. Hierarchical Reinforcement Learning Based Energy Management Strategy for Hybrid Electric Vehicle[J]. Energy, 2022, 238: 121703.

[12] LIU R, WANG C, TANG A, et al. A Twin Delayed Deep Deterministic Policy Gradient-based Energy Management Strategy for a Battery-ultracapacitor Electric Vehicle Considering Driving Condition Recognition with Learning Vector Quantization Neural Network[J]. Journal of Energy Storage, 2023, 71: 108147.

[13] BARCELLONA S, COLNAGO S, DOTELLI G, et al. Aging Effect on the Variation of Li-ion Battery Resistance as Function of Temperature and State of Charge[J]. Journal of Energy Storage, 2022, 50: 104658.

[14] MA S, JIANG M, TAO P, et al. Temperature Effect and Thermal Impact in Lithium-ion Batteries: a Review[J]. Progress in Natural Science: Materials International, 2018, 28(6): 653-666.

[15] WANG C, LIU R, TANG A, et al. A Reinforcement Learning-based Energy Management Strategy for a Batter-ultracapacitor Electric Vehicle Considering Temperature Effects[J]. International Journal of Circuit Theory and Applications, 2023, 51(10): 4690-4710.

[16] WANG C, LIU R, TANG A. Energy Management Strategy of Hybrid Energy Storage System for Electric Vehicles Based on Genetic Algorithm Optimization and Temperature Effect[J]. Journal of Energy Storage, 2022, 51: 104314.

[17] 郑悦，谢长君，黄亮，等. 锂电池与超级电容混合电动汽车系统在环综合测试[J]. 中国机械工程，2016，27(6)：821-826.
ZHENG Yue, XIE Changjun, HUANG Liang, et al. Powertrain in Loop Test System of Hybrid Electric Vehicles Combined Lithium Battery and Super Capacitor[J]. China Mechanical Engineering, 2016, 27(6): 821-826.

[18] STEIGER J, RICHTER G, WENK M, et al. Comparison of the Growth of Lithium Filaments and Dendrites under Different Conditions[J]. Electrochemistry Communications, 2015, 50: 11-14.

[19] GAO L, LIU S, DOUGAL R A. Dynamic Lithium-ion Battery Model for System Simulation[J]. IEEE Transactions on Components and Packaging Technologies, 2002, 25(3): 495-505.

[20] LI C, XU X, ZHU H, et al. Research on Car-following Control and Energy Management Strategy of Hybrid Electric Vehicles in Connected Scene[J]. Energy, 2024, 293: 130586.

（编辑　袁兴玲）

作者简介：王　春，男，1984年生，教授。研究方向为先进储能系统人工智能管理与控制。发表论文30余篇。E-mail：susewangchun@163.com。**申渝秦***（通信作者），女，1999年生，硕士研究生。研究方向为车用复合电源能量管理。E-mail：15191026912@163.com。

本文引用格式：

王春，申渝秦，曾权宏，等. 考虑锂电池老化与热效应的电动汽车SAC能量管理策略[J]. 中国机械工程，2026，37(10)：2502-2510.

WANG Chun, SHEN Yuqin, ZENG Quanhong, et al. SAC-based Energy Management Strategy for Electric Vehicles Considering Lithium Battery Aging and Thermal Effects[J]. China Mechanical Engineering, 2026, 37(10): 2502-2510.