DOI：10.13234/j.issn.2095-2805.2026.9.214 **中图分类号**：TM911 **文献标志码**：A

混合驾驶循环工况下的燃料电池电堆水热管理策略研究

范一兴，田国富，吴子尧(中国电源学会会员)
(沈阳工业大学机械工程学院，沈阳 110870)

摘要：工作湿度和温度是影响质子交换膜燃料电池 PEMFC(proton exchange membrane fuel cell)电堆性能和使用寿命的关键因素。针对现有水热管理策略存在控制精度低和鲁棒性差的缺点，提出一种基于双延迟深度确定性策略梯度 TD3 (twin-delayed deep deterministic policy gradient)的水热管理策略。该策略基于水热管理系统模型，对传统的泵、散热器和阴极加湿器独立控制的框架进行改进，实现了对温度和湿度的同步控制。以 375 片电池的 PEMFC 电堆的水热管理工作为例，将所提出的策略与基于深度确定性策略梯度 DDPG (the deep deterministic policy gradient)的水热管理策略在混合驾驶循环工况下进行仿真实验对比。基于 TD3 策略下的电堆入口温度和电堆温度与理想温度的最大偏差比基于 DDPG 策略下的最大偏差分别减小了 0.10 K 和 0.07 K；基于 TD3 策略下的电堆阴极入口湿度维持在 25%~62%，而基于 DDPG 策略下的电堆阴极入口湿度维持在 0~98%。结果表明，所提策略比基于 DDPG 的策略性能更好，能够有效减小电堆的温度最大偏差和湿度变化范围。

关键词：质子交换膜燃料电池；双延迟深度确定性策略梯度；水热管理策略；混合驾驶循环工况

Research on Water and Thermal Management Strategy of PEMFC Stacks under the Mixed Driving Cycle Condition

FAN Yixing, TIAN Guofu, WU Ziyao, *Member, CPSS*
(School of Mechanical Engineering, Shenyang University of Technology, Shenyang 110870, China)

Abstract: Operating temperature and humidity are key factors affecting the performance and lifetime of proton exchange membrane fuel cell (PEMFC) stacks. Aiming at the shortcomings of low control accuracy and poor robustness in existing water and thermal management strategies, a water and thermal management strategy based on the twin-delayed deep deterministic policy gradient (TD3) is proposed. The strategy was based on a water and thermal management system model, which improved the traditional control framework of independent control of the water pump, the radiator, and the cathode humidifier, and achieved synchronous control of temperature and humidity. Taking the water and thermal management of a PEMFC stack with 375 cells as an example, the proposed strategy is compared with the water and thermal management strategy based on the deep deterministic policy gradient (DDPG) through simulation experiments under the mixed driving cycle condition. The maximum deviations of the inlet temperature of the stack and the temperature of the stack from the ideal temperature under the TD3-based strategy are reduced by 0.10 K and 0.07 K, respectively, compared with the maximum deviations under the DDPG-based strategy; the TD3-based strategy maintains the cathode inlet humidity between 25% and 62%, while the DDPG-based strategy maintains the cathode inlet humidity between 0 and 98%. The results show that, compared with the DDPG-based strategy, the proposed strategy performs better, effectively reducing the maximum temperature deviation and the range of humidity changes of the stack.

Keywords: Proton exchange membrane fuel cell (PEMFC); twin-delayed deep deterministic policy gradient (TD3); water and thermal management strategy; mixed driving cycle condition

收稿日期：2024-11-19；**修回日期**：2025-01-10；**录用日期**：2025-03-10；**网络首发日期**：2025-03-26
基金项目：国家自然科学基金资助项目(52375258)
This work is supported by National Natural Science Foundation of China under the grant 52375258

质子交换膜燃料电池 PEMFC (proton exchange membrane fuel cell)因具有高效、零排放的优势，近年来受到人们的关注，具有广阔的应用前景。PEMFC 电堆的工作温度和湿度是影响其性能的重要因素，它们对催化层的催化特性、电堆的工作寿命都有不同程度的影响[1]。因此，为了实现 PEMFC 电堆的高效运行，需要进行有效的水热管理。

在现有的研究中，大多数 PEMFC 电堆都采用水冷却[2]。比例积分微分 PID(proportional integral derivative)控制[3]、模型预测控制[4]和模糊逻辑控制[5]等方法被广泛用于 PEMFC 电堆热管理策略的研究。除热管理外，PEMFC 电堆的水管理也是一个研究热点[6]。Wang 等[7]探讨了质子交换膜 PEM (proton exchange membrane)含水量对电压输出性能的影响。结果表明，PEM 含水量对动态负载下 PEM 的性能影响较大。然而，目前关于 PEMFC 的同步温、湿度控制的研究较少，最佳 PEM 含水率是通过热管理策略控制电堆的温度来实现的，不是直接控制湿度，这将导致 PEM 在恶劣的工作条件下出现膜干和水淹现象。Xiong 等[8]和 Chen 等[9]均采用多输入多输出的模糊控制方法来控制 PEMFC 电堆的温度和湿度。上述方法均具有较好的控制效果，但也存在计算资源需求大、理论分析难度大等缺点。

随着人工智能的快速发展，学习算法已被应用于各行各业。作为人工智能的重要分支，机器学习可从复杂数据集中挖掘出有价值的潜在规律，以较高的精度拟合高度非线性系统中输入变量与输出目标之间的关系。Fu 等[10]将极限梯度提升 XGBoost (eXtreme Gradient Boosting)算法应用于 PEMFC 电堆的热管理策略，对电堆冷却水进出口温度进行控制，使 PEM 的含水率保持在合理水平。Misbahuddin 等[11]设计了一种反向传播神经网络 BNN(backpropagation neural network)来控制 PEMFC 电堆的温度。结果表明，尽管功率需求有显著波动，但 BNN 控制器仍可将电堆温度维持在所需的设定点上。近年来，深度强化学习 DRL(deep reinforcement learning)算法在 PEMFC 电堆领域得到应用。Wei 等[12]将深度确定性策略梯度 DDPG(deep deterministic policy gradient)算法应用于电堆的热管理中，通过互相更新的 Actor-Critic 框架处理多维耦合冷却系统中复杂的热管理策略问题。在 DDPG 算法的基础上，也有学者在热管理策略算法中应用分类回放双延迟贝叶斯深度确定性策略梯度 CTDB-DDPG (classified replay twin-delayed Bayesian-deep deterministic policy gradient)算法[13]来解决水泵与散热器的协调控制问题。然而，尽管上述基于 DRL 的热管理策略可以达到理想的控制效果，但未考虑电堆湿度。

本研究提出了基于双延迟深度确定性策略梯度 TD3(twin-delayed deep deterministic policy gradient)的水热管理策略，实现了对电堆温度和湿度的同步控制。将该策略与基于 DDPG 的水热管理策略在混合驾驶循环工况下进行仿真实验，验证了所提策略的可行性。

1　PEMFC 电堆水热管理系统模型

图 1 为 PEMFC 电堆水热管理系统，该系统由水泵、散热器、加湿器、水箱、控制器和传感器等组成。水泵和散热器分别通过调节冷却水流量和空气流量来控制电堆温度，空气由阴极进入电堆之前，空气加湿器对其进行加湿以保证电堆阴极的相对湿度，进而实现燃料电池内部水含量的平衡。电

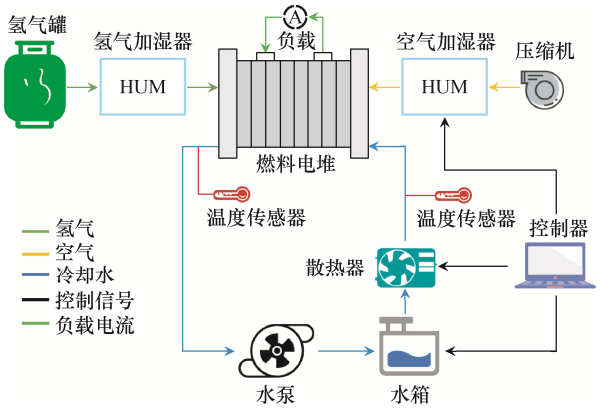


图 1　PEMFC 电堆水热管理系统

Fig. 1 Water and thermal management system of the PEMFC stack

堆产生的热量则首先由冷却水通过水泵输送到水箱，使电堆冷却水出口温度达到理想值；然后通过散热器散发到环境中，使重新进入电堆的冷却水的温度趋近理想温度。在本研究中，将电堆冷却水入口温度作为 PEMFC 电堆入口温度，将电堆冷却水出口温度作为 PEMFC 电堆温度，将电堆阴极气体出口湿度作为 PEMFC 电堆阴极的相对湿度。

1.1 热管理系统模型

图 2 为 PEMFC 电堆热管理系统建模方程流程。其中，PEMFC 电堆的热平衡方程根据能量守恒定律[14]可表示为

$$m_{\mathrm{st}}C_{\mathrm{st}}\frac{\mathrm{d}T_{\mathrm{st}}}{\mathrm{d}t}=Q_{\mathrm{react}}-Q_{\mathrm{cool}}-P_{\mathrm{st}}-Q_{\mathrm{dis}} \tag{1}$$

式中：m_{st} 和 C_{st} 分别为 PEMFC 电堆的质量和比热容；T_{st} 为电堆温度；Q_{react} 为电化学反应释放的热量；Q_{cool} 为电堆冷却水排出的热量；P_{st} 为电堆功率；Q_{dis} 为辐射热量。相应的计算公式为

$$Q_{\mathrm{react}}=\frac{nI\Delta H}{2F} \tag{2}$$

$$Q_{\mathrm{cool}}=W_{\mathrm{cl}}C_{\mathrm{cl}}(T_{\mathrm{st}}-T_{\mathrm{st,in}}) \tag{3}$$

$$P_{\mathrm{st}}=U_{\mathrm{st}}I \tag{4}$$

$$Q_{\mathrm{dis}}=KA_{\mathrm{st}}(T_{\mathrm{st}}-T_{\mathrm{amb}}) \tag{5}$$

式中：n、I、ΔH、F 和 U_{st} 分别为电池节数、电堆工作电流、反应气体供给的总焓、法拉第常数和电堆输出电压；W_{cl} 和 C_{cl} 分别为冷却水质量流量和冷却水比热容；$T_{\mathrm{st,in}}$ 为电堆入口温度；K 和 A_{st} 分别为传热系数和 PEMFC 电堆各片膜电极总表面积；T_{amb} 为环境温度。

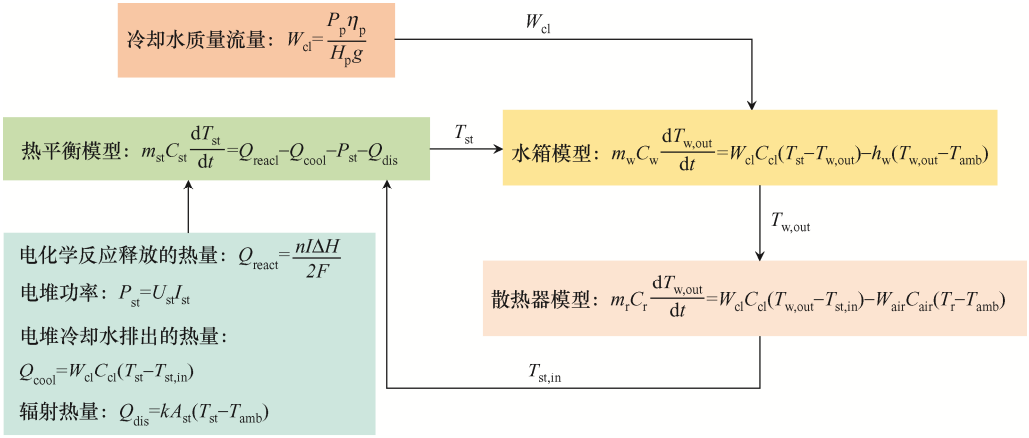


图 2 PEMFC 电堆热管理系统建模方程流程

Fig. 2 Flow chart of the modeling equations for the PEMFC stack thermal management system

水箱是电堆热管理系统中的冷却水贮存装置。本文假设水箱入口冷却水温度与 T_{st} 近似相等，水箱出口冷却水温度为 $T_{\mathrm{w,out}}$，则水箱模型[10]为

$$m_{\mathrm{w}}C_{\mathrm{w}}\frac{\mathrm{d}T_{\mathrm{w,out}}}{\mathrm{d}t}=W_{\mathrm{cl}}C_{\mathrm{cl}}(T_{\mathrm{st}}-T_{\mathrm{w,out}})-h_{\mathrm{w}}(T_{\mathrm{w,out}}-T_{\mathrm{amb}}) \tag{6}$$

式中，m_{w}、C_{w} 和 h_{w} 分别为水箱的质量、比热容和传热系数。

散热器模型为

$$m_{\mathrm{r}}C_{\mathrm{r}}\frac{\mathrm{d}T_{\mathrm{st,in}}}{\mathrm{d}t}=W_{\mathrm{cl}}C_{\mathrm{cl}}(T_{\mathrm{w,out}}-T_{\mathrm{st,in}})-W_{\mathrm{air}}C_{\mathrm{air}}(T_{\mathrm{r}}-T_{\mathrm{amb}}) \tag{7}$$

式中：m_{r} 和 C_{r} 分别为散热器的质量和比热容；W_{air} 和 C_{air} 分别为散热器空气质量流量和空气比热容；T_{r} 为散热器冷却后的空气温度。$T_{\mathrm{w,out}}$ 近似等于散热器入口温度，散热器出口温度被认为与 $T_{\mathrm{st,in}}$ 相同。

在电堆热管理系统中，可以通过调节水泵的功率来控制冷却水流量，使电堆的温度降低。冷却水质量流量和水泵的关系为

$$W_{\mathrm{cl}}=\frac{P_{\mathrm{p}}\eta_{\mathrm{p}}}{H_{\mathrm{p}}g} \tag{8}$$

式中：P_{p}、H_{p} 和 η_{p} 分别为水泵的功率、扬程和效率；g 为重力加速度。

1.2 水管理系统模型

通过对阴极和阳极水传递过程的研究，建立了水管理模型。阴极和阳极的水平衡方程为

$$\frac{\mathrm{d}m_{\mathrm{H_2O,ca}}}{\mathrm{d}t}=W_{\mathrm{v,ca,in}}-W_{\mathrm{v,ca,out}}+W_{\mathrm{v,ca,gen}}+W_{\mathrm{v,membr}} \tag{9}$$

$$\frac{\mathrm{d}m_{\mathrm{H_2O,an}}}{\mathrm{d}t}=W_{\mathrm{v,an,in}}-W_{\mathrm{v,an,out}}-W_{\mathrm{v,membr}} \tag{10}$$

式中：$m_{\mathrm{H_2O,ca}}$ 和 $m_{\mathrm{H_2O,an}}$ 分别为阴极和阳极水的质量；$W_{\mathrm{v,ca,in}}$ 和 $W_{\mathrm{v,an,in}}$ 分别为进入阴极和阳极的蒸汽的质量流量；$W_{\mathrm{v,ca,out}}$ 和 $W_{\mathrm{v,an,out}}$ 分别为离开阴极和阳极的蒸汽的质量流量；$W_{\mathrm{v,ca,gen}}$ 为电化学反应产生的蒸汽的质量流量；$W_{\mathrm{v,membr}}$ 为水跨膜传输的质量流量，其公式为

$$W_{\mathrm{v,membr}}=M_{\mathrm{v}}A_{\mathrm{fc}}n\left[\frac{n_{\mathrm{d}}I}{F}-\frac{D_{\mathrm{w}}(c_{\mathrm{v,ca}}-c_{\mathrm{v,an}})}{t_{\mathrm{m}}}\right] \tag{11}$$

式中：M_{v} 为蒸汽的摩尔质量；A_{fc} 为电池活化面积；n 为电池数量；n_{d} 为电渗透阻力系数；D_{w} 为自扩散系数，为膜含水量 λ_{m} 的函数[9]；$c_{\mathrm{v,ca}}$ 和 $c_{\mathrm{v,an}}$ 分别为电堆阴极和阳极侧膜表面的水浓度；t_{m} 为膜厚度。具体表达式为

$$n_{\mathrm{d}}=0.002\,9\lambda_{\mathrm{m}}^{\ 2}+0.05\lambda_{\mathrm{m}}-3.4\times10^{-19} \tag{12}$$

$$D_{\mathrm{w}}=D_{\lambda}\exp\left[2\,416\left(\frac{1}{303}-\frac{1}{T_{\mathrm{st}}}\right)\right] \tag{13}$$

$$D_{\lambda}=\begin{cases}10^{-6} & \lambda_{\mathrm{m}}<2\\ [1+2(\lambda_{\mathrm{m}}-2)]\times10^{-6} & 2\leqslant\lambda_{\mathrm{m}}\leqslant3\\ [3-1.67(\lambda_{\mathrm{m}}-3)]\times10^{-6} & 3<\lambda_{\mathrm{m}}<4.5\\ 1.25\times10^{-6} & \lambda_{\mathrm{m}}\geqslant4.5\end{cases} \tag{14}$$

$$\lambda_{\mathrm{m}}=\begin{cases}0.043+17.81a_{\mathrm{m}}-39.85a_{\mathrm{m}}^{2}+36a_{\mathrm{m}}^{3}\\ \qquad 0<a_{\mathrm{m}}\leqslant1\\ 14+1.4(a_{\mathrm{m}}-1)\\ \qquad 1<a_{\mathrm{m}}\leqslant3\end{cases} \tag{15}$$

式中：D_{λ} 为化学扩散系数；a_{m} 为膜水活度，由阳极水活度 a_{an} 和阴极水活度 a_{ca} 的平均值表示。其中，a_{an} 和 a_{ca} 可表示为

$$a_j=\frac{P_{\mathrm{v},j}}{P_{\mathrm{sat},j}}\qquad j=\mathrm{an,ca} \tag{16}$$

式中，$P_{\mathrm{v},j}$ 和 $P_{\mathrm{sat},j}$ 分别为蒸汽的分压和饱和压力。其中饱和压力通过拟合 PEMFC 温度获得[10]，公式为

$$\lg P_{\mathrm{sat}}=-1.69\times10^{-10}T_{\mathrm{st}}^{\ 4}+3.85\times10^{-7}T_{\mathrm{st}}^{\ 3}-3.39\times10^{-4}T_{\mathrm{st}}^{\ 2}+0.143T_{\mathrm{st}}-20.92 \tag{17}$$

表 1 为电堆水热管理系统的模型参数。

表 1　水热管理系统模型参数

Tab. 1 Model parameters of water and thermal management system

符号	数值
环境温度 T_{amb} /K	298
大气压力 P_{atm} /kPa	101
电池数量 n	375
电堆质量 m_{st} /kg	80
膜厚度 t_{m} /cm	0.012 75
电池活化面积 A_{fc} /cm^2	280
电堆比热容 C_{st} /J·kg^{-1}·K^{-1}	1 260
冷却水比热容 C_{cl} /J·kg^{-1}·K^{-1}	4 200
空气比热容 C_{air} /J·kg^{-1}·K^{-1}	1 004

2　TD3 算法

2.1 TD3 算法原理

TD3 算法采用 Actor-Critic 算法网络框架，其整体网络结构如图 3[15]所示。

采用确定性策略梯度算法对图 3 中的策略函数 Actor 进行更新[15]，表示为

$$\nabla_{\phi}T(\phi)=E_{s\sim p_{\pi}}[\nabla_{a}Q^{\pi}(s,a)\big|_{a=\pi(s)}\nabla_{\phi}\pi_{\phi}(s)] \tag{18}$$

式中：$\nabla_{\phi}T(\phi)$ 为梯度函数，来源于 Actor 网络，$T(\phi)=E_{s_i\sim p_{\pi},a_i\sim\pi}(R_1)$ (i 为训练次数)为策略通过奖励函数进行估值，计算了采用该策略后的期望奖励 R_1；$E_{s\sim p_{\pi}}$ 为期望奖励在状态 s 下遵循策略 π 作出动作 a 的预期奖励；$\nabla_{a}Q^{\pi}(s,a)\big|_{a=\pi(s)}$ 为动作 a 遵循策略 $\pi(s)$ 时的 Q 值函数梯度；$Q^{\pi}(s,a)$ 为估值函数；$\pi_{\phi}(s)$ 表示参数为 ϕ 时，状态 s 下的最优策略。

图 3 中 Critic 网络和 Critic 目标策略网络的评

估函数是在 Belman 方程的基础上进行延迟学习，则有

$$Q^{\pi}(s,a)=r+\gamma E_{s'\sim a'}[Q^{\pi}(s',a')] \tag{19}$$

式中：r 为当前时刻的奖励值；γ 为折扣因子；(s',a') 为下一时刻的状态和动作。

对于 Q_1 和 Q_2 网络，定义损失函数 L_Q 为

$$L_Q=\frac{1}{J}\sum_{k=1}^{J}[Y_i-Q_i(s_i,a_i)]^2 \tag{20}$$

式中：Y_i 为第 i 次训练时的目标 Q 值；s_i 为第 i 次训练时的状态；a_i 为第 i 次训练时采取的运动。

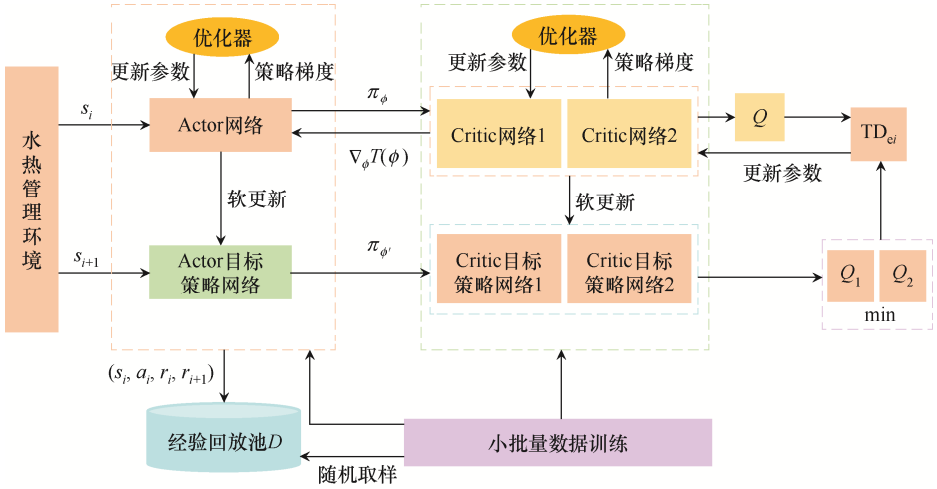


图 3 TD3 网络结构

Fig. 3 Network structure of TD3

第 i 个 Critic 网络的时间差分 TD(temporal different)的误差 $E_{\mathrm{TD},ei}$ 为，

$$E_{\mathrm{TD},ei}=Y_i-Q_{\varphi_i}(s_i,a_i|x_i) \tag{21}$$

式中，Q_{φ_i} 为第 i 个 Critic 网络。

为了减小估计误差，采用软更新策略，则有

$$\begin{cases}\varphi_i=\beta\varphi_i+(1-\beta)\varphi_i'\\ \phi'=\beta\phi+(1-\beta)\phi'\end{cases} \tag{22}$$

式中：φ_i 和 φ_i' 分别为第 i 个 Critic 网络参数和 Critic 目标策略网络参数；β 为软更新率；ϕ 和 ϕ' 分为 Actor 策略网络参数和 Actor 目标策略网络参数。

TD3 算法的流程如下。

(1)初始化策略网络 π_ϕ、经验回放池 D，以及 Critic 网络 1 和网络 2，并对目标策略网络 $\pi_{\phi'}$ 和 Critic 目标策略网络 1、网络 2 进行参数赋值。

(2)通过 π_ϕ 得到动作，获取水热管理环境的初始状态 s。根据当前策略获得 a、r 和下一个状态 s'，将其作为策略网络的训练数据，并存储其状态转换序列到 D 中。

(3)根据式(18)计算样本策略梯度，并利用该梯度更新策略；依据式(22)更新 Actor 目标策略网络和 Critic 目标策略网络 1 与网络 2，最终输出最优策略。

2.2 基于 TD3 的 PEMFC 电堆水热管理策略设计

采用 TD3 算法控制 $T_{\mathrm{st,in}}$、T_{st} 和电堆阴极相对湿度 H_{ca}。这些控制量的取值通过 TD3 算法同时对水泵、散热器和阴极加湿器控制得到。将电堆入口和出口温度的理想控制值分别设置为 338 K 和 343 K[16]，湿度区间设置为(0, 100%)。

在强化学习中，智能体是进行决策的实体，通过与环境的不断交互试错来更新模型并习得策略。模拟中输入的状态空间参数有 8 个，分别为 I、$T_{\mathrm{st,in}}$、T_{st}、$T_{\mathrm{st,in}}$ 与理想入口温度的差值 u_1、T_{st} 与理想出口温度的差值 u_2、$T_{\mathrm{st,in}}$ 与 T_{st} 的差值 ΔT、$W_{\mathrm{v,membr}}$ 和 H_{ca}。具体可表示为

$$s=\{I,T_{\mathrm{st,in}},T_{\mathrm{st}},u_1,u_2,\Delta T,W_{\mathrm{v,membr}},H_{\mathrm{ca}}\} \tag{23}$$

动作空间参数包含 PEMFC 电堆的 W_{cl}、W_{air} 和阴极入口湿度 $H_{\mathrm{ca,in}}$，三者的联合调节实现了

PEMFC 电堆温度和湿度的协同控制，具体为

$$a=\{W_{\mathrm{cl}},W_{\mathrm{air}},H_{\mathrm{ca,in}}\} \tag{24}$$

奖励函数表示为

$$R_{\mathrm{Reward}}=-b\times(|u_1|-1)-b\times(|u_2|-1)-d\times(H_{\mathrm{ca}}-0.94) \tag{25}$$

式中，b 和 d 为尺度因子，根据奖励和惩罚的权重进行设置，本文设置 $b=5/9$，$d=0.01$。本文将奖励函数中温度的控制项设置为较高的权重，将湿度的控制项设置为略低的权重。实现电堆温度和湿度的同步控制具有一定的复杂性，不仅需要设置不同的权重，助于算法训练，得到最优策略，还需要在训练过程中进行尝试和修改。

通过 TD3 学习机制进行 PEMFC 电堆温度和湿度的主动控制，其水热管理控制框架如图 4 所示。

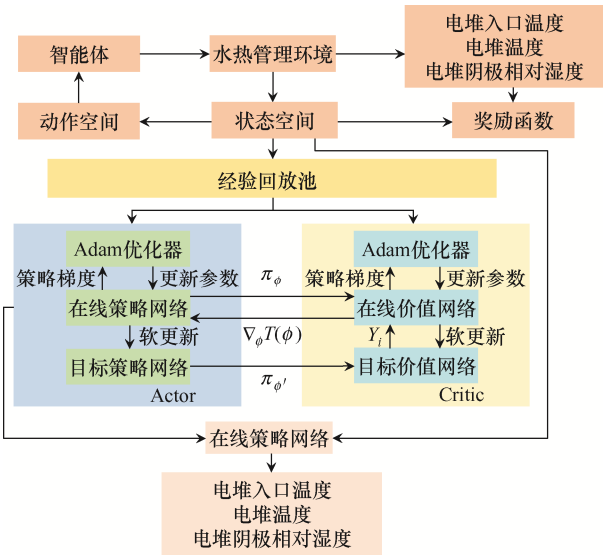


图 4　TD3 水热管理控制框架

Fig. 4 Control framework of TD3 water and thermal management

首先根据观测信息和电堆温湿度特性设计状态空间、动作空间和奖励函数；然后，结合强化学习要素，构成经验数组，利用 Adam 优化器更新神经网络参数 ϕ'，使得损失函数尽量减小，训练得到电堆水热管理网络模型；最后，根据水热管理网络模型得到合适的电堆阴极相对湿度、电堆入口温度和电堆温度，确保 PEMFC 电堆的工作温度和湿度保持在理想的区间内。

3　仿真及结果分析

3.1　不同策略的比较分析

为了比较 TD3 和 DDPG 2 种深度强化学习算法的性能，将 2 种算法设置相同的参数，见表 2，并对其训练结果进行分析。图 5 给出了 2 种算法的平均奖励值。

表 2　算法超参数设置

Tab. 2 Algorithm hyperparameter settings

参数	数值
策略网络学习率	0.001
评估网络学习率	0.001
折扣因子	0.99
目标平滑系数	0.05
经验缓冲区大小	50 000
目标策略平滑方差	0.2
批量批次大小	256

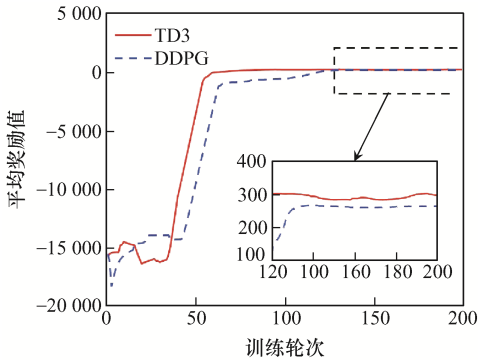


图 5　不同算法的平均奖励值

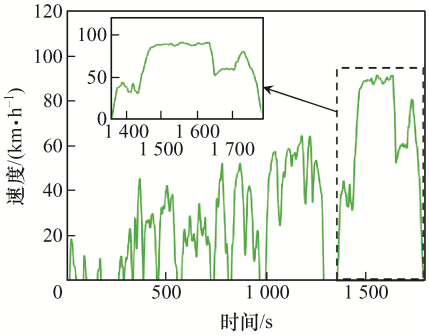
Fig. 5 Average reward values of different algorithms

从图 5 可以看出，TD3 算法在 59 轮次后趋于收敛，而 DDPG 算法在 130 轮次后趋于收敛，且 TD3 算法的平均奖励最大值也高于 DDPG 算法。这表明 DDPG 算法的学习过程慢于 TD3 算法，而 TD3 算法的收敛速度更快，平均奖励最大值也更大。

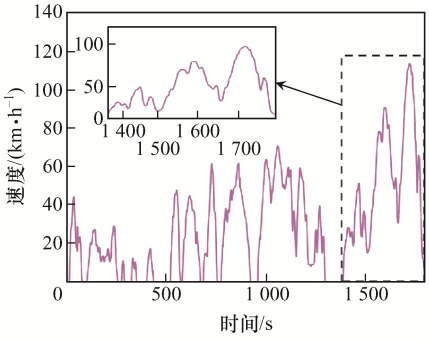
3.2　混合驾驶循环工况下的温度和湿度控制

对于 TD3 算法，神经网络的层数和每层神经元的数量会影响算法的性能。本节中使用的 Actor 和 Critic 网络包含 3 个隐藏层，每个隐藏层包含 256 个神经元。

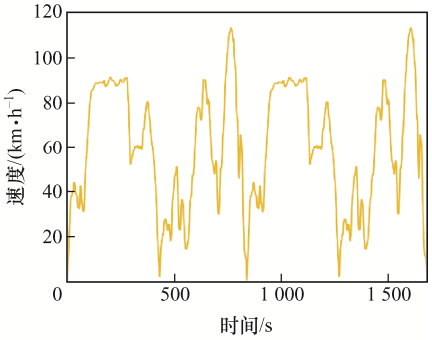
本研究分别截取中国轻型商用车测试工况和世界轻型汽车测试循环工况 2 个标准驾驶工况中的部分区域，截取部分如图 6(a)和图 6(b)中的子图所示，组成了一个 1 680 s 的混合驾驶循环工况如图 6(c)所示，其中高速区占比约 10.7%，中速区占比约 52.4%，低速区占比约 36.9%。训练结束后输出仿真结果，并与 DDPG 算法的仿真结果进行比较。



(a) 中国轻型商用车测试工况下



(b) 世界轻型汽车测试循环工况下

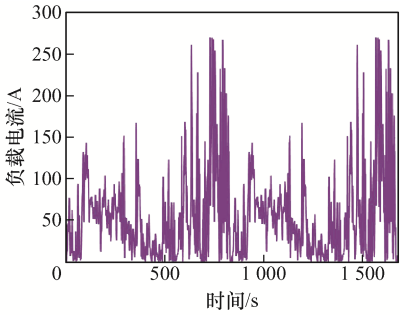


(c) 混合驾驶循环工况下

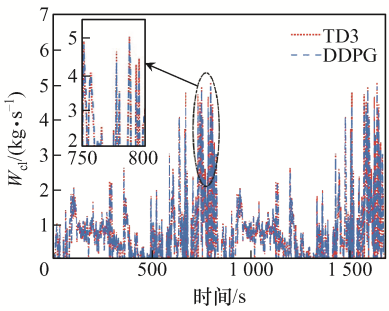
图 6 不同驾驶循环工况下的车速变化曲线

Fig. 6 Vehicle speed change curves under different driving cycle conditions

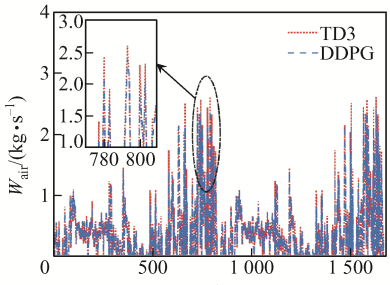
图 7 为混合驾驶循环工况下不同策略的比较结果。图 7(a)为 PEMFC 电堆负载电流在混合驾驶循环工况下随时间变化的曲线。如图 7(b)和图 7(c)所示，负荷上升时，基于 TD3 的水热管理策略控制水泵和散热器输出更大的 W_{cl} 和 W_{air}，从电堆中带走更多的热量，使 $T_{st,in}$ 和 T_{st} 更加接近理想温度。图 7(d)显示了相应的 $H_{ca,in}$，基于 DDPG 的水热管理策略下的 $H_{ca,in}$ 在低速区保持在 0~55%，在中速



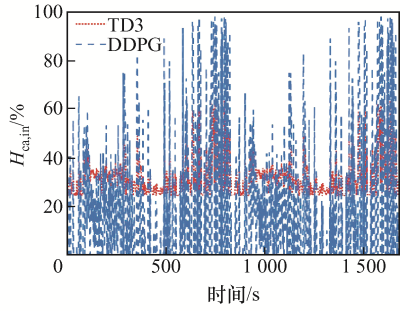
(a) 负载电流



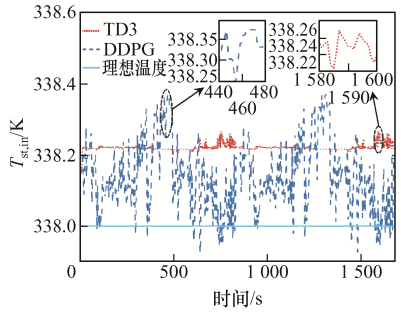
(b) 冷却水质量流量



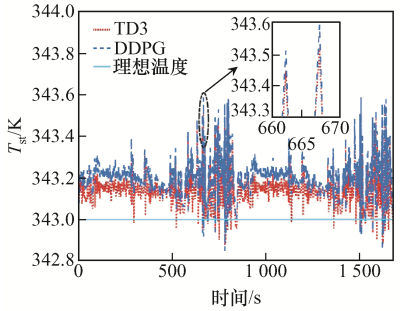
(c) 空气质量流量



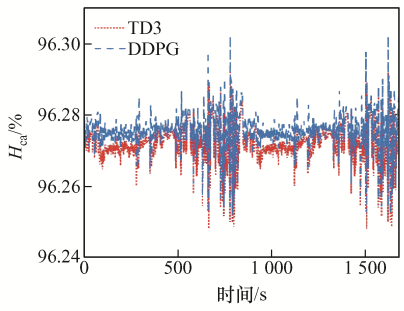
(d) 阴极入口湿度



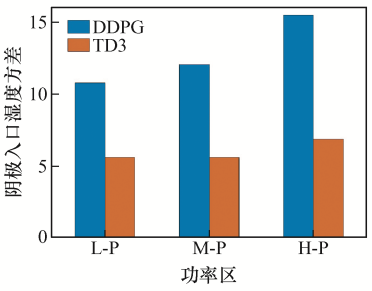
(e) 电堆入口温度



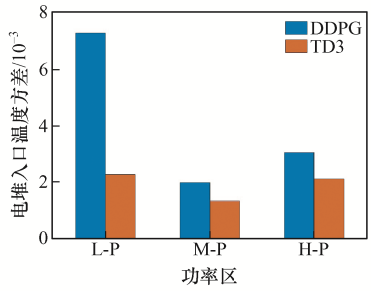
(f) 电堆温度



(g) 阴极相对湿度



(h) 阴极入口湿度方差



(i) 电推入口温度方差

图 7　混合驾驶循环工况下不同策略的比较结果

Fig. 7 Comparison results of different strategies under the mixed driving cycle condition

区保持在 0~88%，在高速区保持在 0~98%，增大了阴极出口处膜干和水淹的风险；而基于 TD3 的水热管理策略下的 $H_{ca,in}$ 在低速区保持在 25%~30%，在中速区保持在 25%~45%，在高速区保持在 25%~62%，降低了膜干和水淹的风险。结果表明，基于 TD3 的水热管理策略对 $H_{ca,in}$ 的控制具有更高的稳定性。

如图 7(e)和图 7(f)所示，基于 TD3 和 DDPG 的水热管理策略下的 $T_{st,in}$ 与理想入口温度的最大偏差分别约为 0.27 K 和 0.37 K，基于 TD3 的策略下的入口温度整体更接近理想入口温度；基于 TD3 和 DDPG 的水热管理策略下的 T_{st} 与理想出口温度的最大偏差分别约为 0.52 K 和 0.59 K，基于 TD3 的策略下的电堆温度整体更接近理想出口温度。这表明所提策略有效减小了温度动态误差，提高了控制精度。

图 7(g)为 2 种控制策略下的 H_{ca} 控制曲线。基于 TD3 和 DDPG 的水热管理策略在动态工况下的响应速度相近，且均将 H_{ca} 控制在 96.2%左右，但基于 TD3 的水热管理策略下的 H_{ca} 整体略小于基于 DDPG 的水热管理策略。可知，在动态工况下，两者对电堆 H_{ca} 的控制都达到了一个良好的效果。

图 7(h)和图 7(i)分别为阴极入口湿度方差和电堆入口温度方差。根据负载电流大小将电堆输出功率分为低功率区、中功率区和高功率区，并分别用 L-P、M-P 和 H-P 表示。可见，基于 TD3 的水热管理策略下的阴极入口湿度方差和电堆入口温度方差在 3 个功率区间内均小于基于 DDPG 的水热管理策略。结果表明，所提策略对电堆温度的控制更加精确，对电堆湿度的控制也更加稳定。

综上所述，相对于 DDPG 算法，TD3 算法具有更好的控制效果。

4　结论

针对现有水热管理策略存在控制精度低和鲁棒性差的缺点，提出了一种基于 TD3 的水热管理策略。本研究的主要结论如下。

(1)基于 TD3 的水热管理策略取代了传统的水泵、散热器和阴极加湿器独立控制的框架，采用一个智能体来控制 W_{cl} 、W_{air} 及 $H_{ca,in}$，实现电堆温度和湿度的同步控制。

(2)采用混合驾驶循环工况对所提出的水热管理策略进行了测试。基于 TD3 策略下的 $T_{st,in}$ 与理想入口温度的最大偏差比基于 DDPG 策略下的最大偏差减小了 0.10 K，基于 TD3 策略下的 $T_{st,in}$ 整体上更接近理想入口温度；基于 TD3 策略下的 T_{st} 与理想出口温度的最大偏差比基于 DDPG 策略下的最大偏差减小了 0.07 K，基于 TD3 策略下的电堆温度整体上更接近理想出口温度；基于 DDPG 策略下的 $H_{ca,in}$ 维持在 0~98%，增大了阴极出口处膜干和水淹的风险，而基于 TD3 策略下的 $H_{ca,in}$ 维持在 25%~62%，降低了膜干和水淹的风险；基于 TD3 策略下的阴极入口湿度方差和电堆入口温度方差在低、中、高 3 个功率区间内均小于基于 DDPG 策略。结果表明，基于 TD3 的水热管理策略对电堆温度的控制更加精确，对电堆湿度的控制也更加稳定，在混合驾驶循环工况下具有优越的控制性能和显著的鲁棒性。

参考文献：

[1] 高清振, 潘道远, 黄胜洲, 等. 氢燃料电池扩散层温度场演变研究[J]. 电源学报, 2025, 23(5): 130-140.
Gao Qingzhen, Pan Daoyuan, Huang Shengzhou, et al. Study on temperature field evolution in hydrogen fuel cell diffusion layer [J]. Journal of Power Supply, 2025, 23(5): 130-140. (in Chinese)

[2] Baroutaji A, Arjunan A, Ramadan M, et al. Advancements and prospects of thermal management and waste heat recovery of PEMFC [J]. International Journal of Thermofluids, 2021, 9: 100064.

[3] 姚东升, 周耀丹, 张志芸, 等. 大功率质子交换膜燃料电池系统热管理控制策略研究[J]. 汽车文摘, 2023(7): 36-39.
Yao Dongsheng, Zhou Yaodan, Zhang Zhiyun, et al. Research on thermal management control strategy of high power proton exchange membrane fuel cell system [J]. Automotive Digest, 2023(7): 36-39. (in Chinese)

[4] Zhang Bo, Lin Fei, Zhang Caizhi, et al. Design and implementation of model predictive control for an open-cathode fuel cell thermal management system [J]. Renewable Energy, 2020, 154: 1014-1024.

[5] 赵振瑞, 欧阳惠颖, 田国富, 等. 基于模糊逻辑与遗传算法的燃料电池热管理方法研究[J]. 集成技术, 2021, 10(3): 35-46.
Zhao Zhenrui, Ouyang Huiying, Tian Guofu, et al. Research on thermal management method of fuel cell based on fuzzy logic and genetic algorithm [J]. Journal of Integration Technology, 2021, 10(3): 35-46. (in Chinese)

[6] 文陈, 冯磊, 王景润, 等. 空间燃料电池静态排水技术现状研究[J]. 电源学报, 2025, 23(7): 247-252.
Wen Chen, Feng Lei, Wang Jingrun, et al. Research status of non-flow through water management technology for space fuel cells [J]. Journal of Power Supply, 2025, 23(7): 247-252. (in Chinese)

[7] Wang Bohan, Lin Rui, Liu Dengcheng, et al. Investigation of the effect of humidity at both electrode on the performance of PEMFC using orthogonal test method [J]. International Journal of Hydrogen Energy, 2019, 44(26): 13737-13743.

[8] Xiong Shusheng, Wu Zhankuan, Li Wei, et al. Improvement of temperature and humidity control of proton exchange membrane fuel cells [J]. Sustainability, 2021, 13(19): 10578.

[9] Chen Xi, Xu Jianghai, Fang Ye, et al. Temperature and humidity management of PEM fuel cell power system using multi-input and multi-output fuzzy method [J]. Applied Thermal Engineering, 2022, 203: 117865.

[10] Fu Shengxiang, Zhang Dongfang, Cha S W, et al. An extreme gradient boosting-based thermal management strategy for proton exchange membrane fuel cell stacks [J]. Journal of Power Sources, 2023, 558: 232617.

[11] Misbahuddin S, El-Sharkh M Y, Palanki S. Neural network controller for regulation of a water-cooled fuel cell stack [C]// 2016 15th IEEE International Conference on Machine Learning and Applications (ICMLA). Anaheim, CA, USA, 2017: 1046-1049.

[12] Wei Zhongbao, Song Ruoyang, Ji Dongxu, et al. Hierarchical thermal management for PEM fuel cell with machine learning approach [J]. Applied Thermal Engineering, 2024, 236: 121544.

[13] 赵洪山，潘思潮，马利波，等. 基于分类回放双延迟贝叶斯深度确定性策略梯度的燃料电池温度控制[J]. 电工技术学报, 2024, 39(13): 4240-4256.
Zhao Hongshan, Pan Sichao, Ma Libo, et al. Control of fuel cell temperature based on classified replay twin delayed Bayesian deep deterministic policy gradient [J]. Transactions of China Electrotechnical Society, 2024, 39(13): 4240-4256. (in Chinese)

[14] Zou Wenjiang, Kim Y B. Temperature control for a 5 kW water-cooled PEM fuel cell system for a household application [J]. IEEE Access, 2019, 7: 144826-144835.

[15] 吴延波，韩志伟，王惠，等. 基于双延迟深度确定性策略梯度的受电弓主动控制[J]. 电工技术学报，2024, 39(14): 4547-4556.
Wu Yanbo, Han Zhiwei, Wang Hui, et al. Active pantograph control of deep reinforcement learning based on double delay depth deterministic strategy gradient [J]. Transactions of China Electrotechnical Society, 2024, 39(14): 4547-4556. (in Chinese)

[16] Rohendi D, Majlan E H, Mohamad A B, et al. Effects of temperature and backpressure on the performance degradation of MEA in PEMFC [J]. International Journal of Hydrogen Energy, 2015, 40(34): 10960-10968.



范一兴

作者简介：

范一兴(1994—)，男，硕士研究生。研究方向：燃料电池水热管理系统控制策略。E-mail：fanyixing2022@163.com。

田国富(1968—)，男，博士，教授。研究方向：工程车辆及装备的设计与分析技术。E-mail：tianguofu@126.com。

吴子尧(1986—)，男，中国电源学会会员，通信作者，博士。研究方向：氢燃料电池检测，水电解制氢。E-mail：wzy-1986520@163.com。

(责任编辑：孙美菊)

(上接第 174 页)

CNN-BiLSTM 模型的锂电池剩余寿命预测[J]. 电源技术, 2025, 49(5): 991-1005
Wang Xu, Hu Mingmao, Gong Aihong, et al. Remaining life prediction of lithium battery based on CEEMDAN-IGWO-CNN-BiLSTM models [J]. Chinese Journal of Power Sources, 2025, 49(5): 991-1005 (in Chinese)

[22] 宁雪峰，石正禄，许加柱. 基于健康因子和 PSO-LSTM 的锂离子电池健康状态估计[J]. 电源学报, 2026, 24(2): 223-232.
Ning Xuefeng, Shi Zhenglu, Xu Jiazhu. State-of-health estimation of lithium-ion batteries based on health factors and PSO-LSTM [J]. Journal of Power Supply, 2026, 24(2): 223-232. (in Chinese)

[23] 张梦迪，刘洋，陈健，等. 基于 ISSA-GPR 的锂离子电池健康状态估计[J]. 电源学报, 2026, 24(2): 233-243.
Zhang Mengdi, Liu Yang, Chen Jian, et al. Estimation of state-of-health of lithium-ion batteries based on ISSA-GPR [J]. Journal of Power Supply, 2026, 24(2): 233-243. (in Chinese)



李海军

作者简介：

李海军(2000—)，男，中国电源学会学生会员，硕士研究生。研究方向：退役车用动力电池寿命评估及梯次利用。E-mail：1278676376@qq.com。

吴子尧(1986—)，男，中国电源学会会员，通信作者，博士，讲师。研究方向：氢燃料电池检测，车用动力电池及储能电池检测，水电解制氢。E-mail：wzy-1986520@163.com。

王浩(1999—)，男，硕士研究生。研究方向：锂离子电池状态估计。E-mail：1264295639@qq.com。

(责任编辑：耿越)