

综述文章

氢电耦合储能系统：模型、应用和深度强化学习算法

郑杰辉, 苏盈盈, 王文浩, 李志刚*, 吴青华

电力学院, 华南理工大学, 广州市 510640, 广东省, 中国

* 通讯作者: 李志刚, lizg16@scut.edu.cn

引用格式

郑杰辉, 苏盈盈, 王文浩, 等. 氢电耦合储能系统: 模型、应用和深度强化学习算法. 清洁能源科学与技术. 2024; 2(1): 146.

<https://doi.org/10.18686/cncest.v2i1.146>

Zheng J, Su Y, Wang W, et al. Hydrogen-electricity coupling energy storage systems: Models, applications, and deep reinforcement learning algorithms (Chinese). Journal of Clean Energy Science and Technology. 2024; 2(1): 146. <https://doi.org/10.18686/cncest.v2i1.146>

文章信息

收稿日期: 2023-12-07

录用日期: 2024-01-16

发表日期: 2024-03-05

版权信息



版权 © 2024 作者。

《清洁能源科学与技术》由 Universe Scientific Publishing 出版。本作品采用知识共享署名 (CC BY) 许可协议进行许可。
<https://creativecommons.org/licenses/by/4.0/>

English edition of this article is available online at <https://cae.usp-pl.com/index.php/cest/article/view/96>

摘要: 随着氢储能技术的成熟, 绿色电力和绿色氢气模式的氢电耦合储能将成为理想的能源系统。氢电耦合储能系统 (hydrogen-electricity coupling energy storage systems, HECESs) 建设是能源供应和深度脱碳的重要技术途径之一。在 HECESs 中, 氢储能可以维持能源供需平衡, 提高能源利用效率。但其在电力系统建立中的场景模型及相应的解决方法仍需深入研究。为加快 HECESs 建设, 首先从制氢、氢气发电、储氢三个方面阐述了氢储能技术的应用现状。其次, 基于氢能和电能的互补协同机制, 描述了 HECESs 的结构和运行模式。为了更深入地研究 HECESs 的工程应用, 综述了国内外 HECESs 在电源侧、电网侧和负荷侧场景的最新进展。对于源-网-荷侧氢储能应用模型来说, 求解方法的合理选择将影响模型的最优解和求解效率。传统的优化方法难以解决复杂的多能耦合模型, 因此本文探讨了深度强化学习 (deep reinforcement learning, DRL) 算法的优势及其在 HECESs 中的应用。最后对 HECESs 支撑的新型电力系统建设中的技术应用进行了展望, 旨在为氢储能在电力系统中的应用研究提供参考。

关键词: 氢储能; 电力系统; 深度强化学习; 应用场景

1. 引言

为积极应对全球气候变化, 各国纷纷进行能源结构低碳转型。为了实现可持续发展目标, 全球能源体系需要进行实质性变革 [1], 重点是氢能、太阳能、风能和核能等绿色清洁能源。随着双碳战略的出台, 可再生能源渗透率提高和传统化石能源机组退出带来的电力长期充裕问题亟待解决。传统电力系统主要以集中式发电为主, 依靠大型火电厂、核电站等发电设施来供应大规模的电力需求。而新型电力系统则更加注重分布式发电, 如光伏发电、风力发电、水力发电等。新型电力系统供电侧逐步转变为以新能源为主的高不确定性供能体系 [2]。与传统电力系统相比, 新型电力系统在一次能源特征、负荷结构特征、电网平衡模式等方面都发生了深刻变化 [3]。它面临以下挑战:

- 1) 在极端气候条件下, 新能源最小出力处于较低水平。可能会出现连续几天出力小, 系统功率难以平衡, 供电保障支撑能力不足的情况;
- 2) 新能源发电与用电的季节性不匹配导致季节性平衡困难;
- 3) 弃风弃光现象普遍, 新能源消纳问题占比高。

因此, 储能作为一种灵活的调节装置, 可以在系统用电负荷高峰期提供电力支持。而当用电负荷处于低谷时, 则可以消纳过剩的可再生能源。其目的是帮助平衡能源供需差, 提高能源利用效率。电力系统的合理配置有望解决可再生能源发电的随机性、波动性和季节性所带来的系统平衡问题。因此, 新的电

力系统也逐渐从源、网、荷三要素转变为源、网、荷、储四要素。储能资源种类丰富，其中氢能是一种绿色、清洁、低碳的能源，具有能量密度高、易于储存和运输等特点 [4]。氢储能的最大特点是能够长时间、大容量、跨季节储存，这是其他方式所不具备的。配置储电系统和储氢系统进行集成和控制，以实现与电网的有效互动，进一步加强了氢电耦合的必要性。

氢电耦合储能系统（hydrogen-electricity coupling energy storage system, HECCESS）是以电能和氢能为能源载体，以高比例可再生能源消费为目标，满足用电侧多种能源需求的低碳可持续新能源系统 [5]。电氢协同发展的 HECCESS 是指氢能与电能相互转化、高效协同的能源系统。这是新型电力系统的发展方向和重要特征。建设“氢电联产”，可以促进氢能与电能的协同发展，实现氢能与电能的相互转化和高效协同。

在氢储能技术中，一方面为电网和电力系统提供调峰调频能力，另一方面可以保障电力生产的稳定运行。因此，基于电制氢、储氢、制氢发电的氢储能技术作为一种灵活的调度手段，可以通过电-氢-电的转换模式为电力系统提供电量支撑，促进风、光等可再生能源的消纳。储氢可满足从短期系统频率控制到季节性能源供需平衡等大时间尺度范围内的储能需求。氢能可实现全领域减排，并将广泛应用于深度去碳化政策背景下的能源侧、电网侧和负荷侧 [6]。目前，该领域的学者一直在探索氢储能技术、氢储能系统运行和氢储能系统控制，并取得了一些进展 [7,8]。

许多研究从数学模型、技术特点和发展现状等方面对氢储能进行了探讨。Razzhivin 等 [9]考虑了储能装置在电力系统中的应用。对于所提出的氢储能系统，阐述了详细数学模型的实现原理和控制系统的原理。氢的生产、储存、输送和利用是氢储能的关键环节。Moradi 等 [10]对氢气储存和输送方案进行了深入探讨，并对相关技术风险和可靠性分析等未来研究课题进行了展望。Pei 等 [11]从氢储能系统的静态和动态特性、HECESS 功率分配、氢储能效率优化等方面对储能系统的运行和控制策略进行了分类和分析。Eriksen 等 [12]综述了氢基系统的最新发展和当前最先进的技术，分析了氢储能技术的优势和挑战。在此基础上，一些学者全面梳理了制氢和储氢研究的特点和趋势，并结合氢储能技术的最新研究成果，展望了这些领域未来的研究趋势 [13]。上述参考文献主要研究了氢储能的技术发展，探讨了储能的功能特点及其应用进展。但对于氢储能在电力系统源-网-负载侧的应用分析还很少，也没有相对有效的解决方法。

在当前的研究背景下，本文分析了氢储能与电力系统的耦合作用，全面介绍了 HECCESS。在 HECCESS 中，氢储能通过生产、存储、发电三个阶段灵活调节资源，实现电-氢-电模式的转换。它高度消纳富余的可再生能源，保证系统的电力供应，并能解决季节性电力平衡问题。随后，全面总结了 HECCESS 在源-网-负载侧不同场景下的应用。同时，还深入探讨了深度强化学习（deep reinforcement learning, DRL）算法在 HECCESS 模型求解中的有效性。如何在更大的时间尺度和空间范围内聚合协调和优化配置氢储能资源，构建源-网-荷-储

一体化参与的电力平衡模型，是本文亟待解决的核心问题之一。氢储能的相关研究有待进一步深入。

本文接下来的内容安排如下：第 2 节概述了氢储能技术的应用现状、未决问题以及氢储能技术的前景。第 3 节概述了氢储能技术的模型。第 4 节总结并分析了氢储能技术在源-网-荷侧场景中的不同应用。第 5 节指出了不同场景下的模型 DRL 求解算法。第 6 节介绍了氢储能未来技术发展面临的挑战和有待解决的研究问题。第 7 节总结本论文。

2. 氢储能技术的未决问题和前景

在 HECCESS 中，氢储能通过电-氢-电能量转换实现资源的灵活调节。它通过电能和氢能的互变性，将电能转化为氢能，实现能量的长期储存。当用电需求增加时，它将氢能转化为电能，实现能源的高效利用。图 1 比较了多种不同储能技术的适用规模和储存时间。区别于其他储能方式，氢储能在储能时间和储能容量方面都具有更好的长期储能性能。它具有储能容量大、储能时间长、灵活性好等优点。

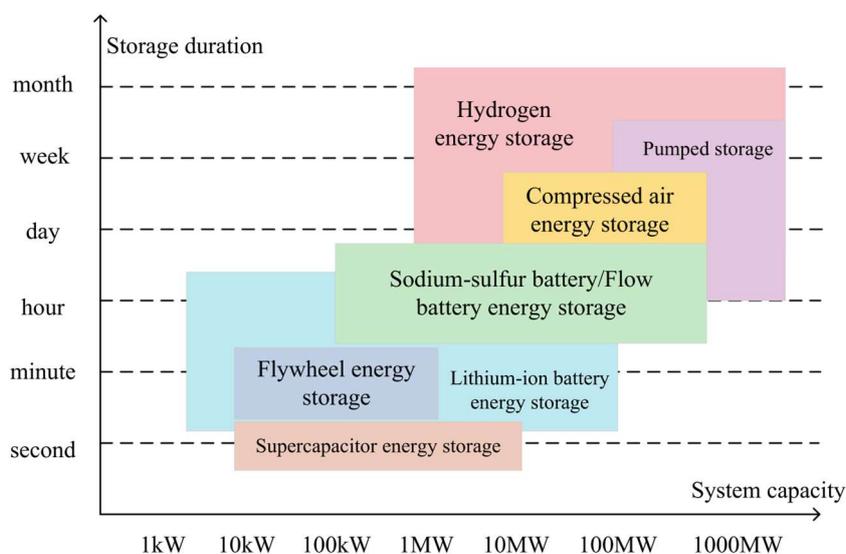


图 1. 不同储能技术的适用规模和储存时间。

Figure 1. Applicable scale and storage duration of different energy storage technologies.

氢储能技术可以消除能源的不稳定性和不确定性，特别是通过吸收多余的可再生能源发电。它可以解决电力供需缺口，提供可靠的能源供应。氢储能技术及应用结构如图 2 所示。具体来说，氢储能技术是利用清洁能源电力电解制氢，并将氢储存在储氢装置中。电解制氢设备和燃料电池分别实现了从电到氢和从氢到电的转换。当电力需求增加或电力供应不足时，利用储存的氢气通过燃料电池或其他反应设备回馈电网。要实现氢储能的全面应用，需要建立完整的氢能转换链。这包括制氢、储氢、发电三个环节，以及这三个环节的关键技术突破。

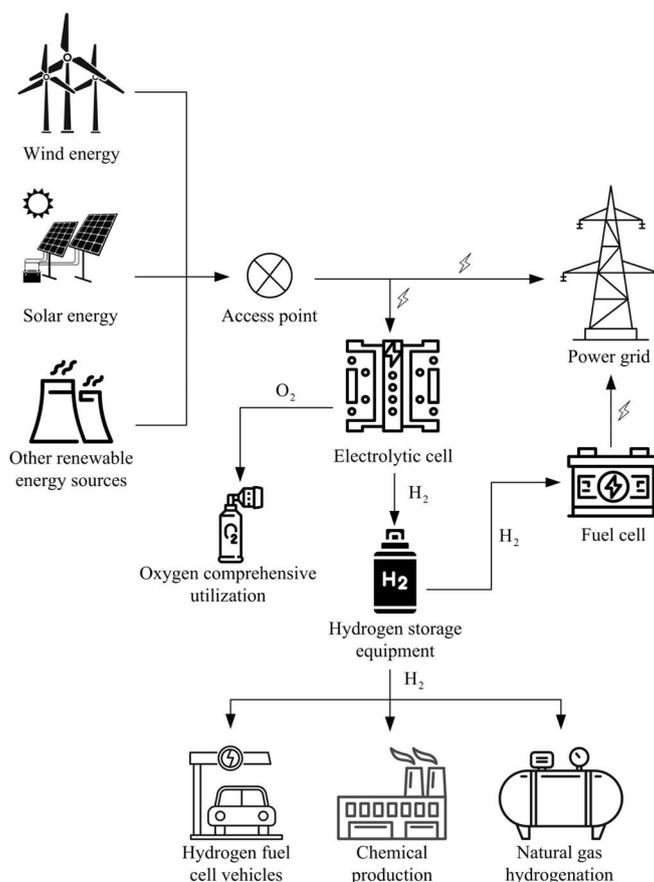


图 2. 氢储能技术结构及应用。

Figure 2. Structure of hydrogen storage technology and applications.

2.1. 制氢技术

制氢的方法有很多，如电解水制氢、煤制氢等。其中，电解水制氢是一种完全清洁的制氢方法，技术成本低，产品纯度高，是氢储能的基础。目前，制氢可分为碱性电解槽（alkaline electrolysis cells, AECs）、质子交换膜电解槽（proton exchange membrane electrolysis cells, PEMECs）、固体氧化物电解槽（solid oxide electrolysis cells, SOECs）和阴离子交换膜电解槽（anion exchange membrane electrolysis cells, AEMECs）。这四种技术的示意图如图 3 所示。

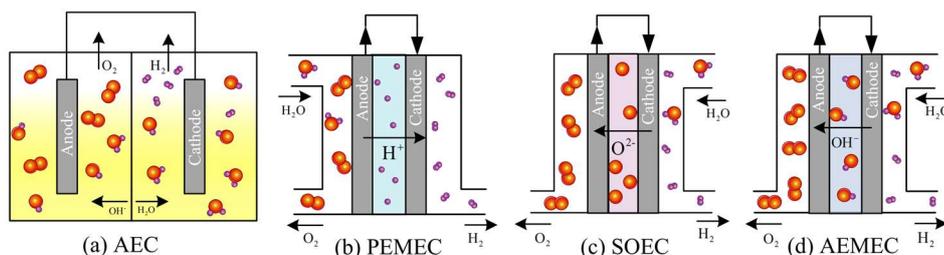


图 3. 不同电解水的制氢示意图。

Figure 3. Diagrams of hydrogen production from different processes of electrolyzing water.

AEC 是最成熟、应用最广泛的电解技术，具有成本低、操作简单等优点。但 AEC 制氢也存在一些问题，如电流密度低、电解液污染等。在电解过程中，如果氢气和氧气穿过隔膜，很容易引起爆炸。此外，如果需要分离高纯度氢气，还需要其他设备，这将增加设备的成本和复杂性。

PEMEC 电解槽采用质子交换膜传导质子，隔离氢氧析出电极，结构紧凑。它具有电流密度高、氢气纯度高、转换效率高等优点。尤其是高灵活性和优异的功率调节功能，非常适合风、光、水等可再生能源的随机性。AEC 和 PEMEC 的动态响应时间在秒-毫秒量级，可根据可再生能源的不确定性进行快速灵活的调节，为电力系统的稳定运行提供支持。与 AEC 相比，PEMEC 在波动适应性方面有较大提高。它更适合面向 HECCESS 应用的灵活调节方案。不过，它也有不足之处，如成本相对较高，耐用性较差。

AEMEC 利用阴离子交换隔膜防止气体穿过隔膜。它具有成本低、启动快和灵活性强等优点。AEMEC 结合了 AEC 和 PEMEC 的优点。不过，由于存在化学和机械稳定性问题以及技术成熟度较低，该技术仍处于研发阶段。

SOEC 是近年来发展起来的一种高温水电解技术，具有很高的能量转换效率。它适合应用于核电余热制氢和氨气余热制氢等场景。但其结构复杂、性能衰减较快、高温运行引起的气体交叉污染等问题仍有待解决，目前仍处于研发阶段 [14]。

目前电解制氢的主要问题是能耗高、效率低。关键技术的突破应集中在降低设备成本、提高电解槽能效以及如何建立集中式大规模生产系统等方面。

2.2. 氢能发电技术

燃料电池将氢的化学能直接转化为电能，可以避免转化过程中的中间能量损失。因此，氢能发电技术可以实现更高的发电效率，更加高效和环保，实用性更强。燃料电池技术按工作温度可分为高温和低温两类。低温燃料电池技术包括碱性燃料电池（alkaline fuel cells, AFCs）、质子交换膜燃料电池（proton exchange membrane fuel cells, PEMFCs）和磷酸燃料电池（phosphoric acid fuel cells, PAFC）。高温燃料电池发电技术包括固体氧化物燃料电池（solid oxide fuel cells, SOFCs）和熔融碳酸盐燃料电池（molten carbonate fuel cells, MCFCs）。

在可再生能源的氢储能应用中，重点是以纯氢为燃料的固体聚合物型 PEMFC，它具有功率密度高、能量转换效率高、低温启动和环保等优点。它适用于分布式发电、可移动电源和应急电源等场景。不同类型燃料电池的特性比较见表 1 [15]。

表 1. 不同燃料电池特性的比较。

Table 1. Comparison of characteristics of different fuel cells.

Type	Operating temperature	Application field	Advantage	Disadvantage
AFC	<80 °C	Backup power/transportation	Good current response	Mainly used for space applications
PEMFC	80–100 °C	Backup power/distributed generation	Fast starting speed/high energy conversion efficiency	Expensive catalyst
PAFC	150–200 °C	Distributed generation/cogeneration	High efficiency of cogeneration	Low current density and expensive catalyst
SOFC	800–1000 °C	Stationary power station/cogeneration	The electrolyte is reusable and low-cost	Metal corrodes easily
MCFC	600–700 °C	Carbon capture power generation system/cogeneration	Good electrical conductivity and high current density	Slow start

根据卡诺循环，燃料电池的最大效率与其工作温度有关。然而，实际燃料电池的效率受到多种因素的影响，例如电池的设计和材料、运行条件、负载需求以及燃料和氧气的纯度。不同类型的燃料电池具有不同的工作温度和反应特性，这会影响其最大效率的范围。将燃料电池的电流密度降低到其最大功率密度值以下有助于减少电池电压损失，从而提高其效率。燃料电池系统的净效率方程如下：

$$\eta_{FC} = \frac{W_{out} - W_{con}}{HHV \times m_{con}} \quad (1)$$

其中 W_{out} 是堆栈输出能量。 η_{out} 是功率输出效率。 W_{con} 是辅助消耗能量。HHV 代表燃料电池的高热值。 m_{con} 是消耗的氢气质量。

其中，PEMFC 和 AFC 启停速度快，适用于氢燃料电池汽车和电力系统中的备用发电机。PAFC、MCFC 和 SOFC 的工作温度较高，适用于分布式发电和热电联产。在转换效率方面，PEMFC、AFC、MCFC 和 SOFC 的电力转换效率约为 60%。当 PAFC、MCFC 和 SOFC 作为热电联产运行时，其效率可达 85%。

2.3. 储氢技术

经济、高效、安全的储氢技术是推动氢储能在电力系统中规模化应用的关键。发展储氢技术是 HECES 的基本前提。与其他燃料相比，氢的质量能量密度高，但体积能量密度低。因此，建立氢能系统的一个重要前提是以较高的体积能量密度储存和运输氢气。储氢技术按物理状态分类，如图 4 所示，主要包括高压气态储氢、液态储氢和固态储氢。目前，高压气态储氢技术是最常用的储氢技术 [16]。

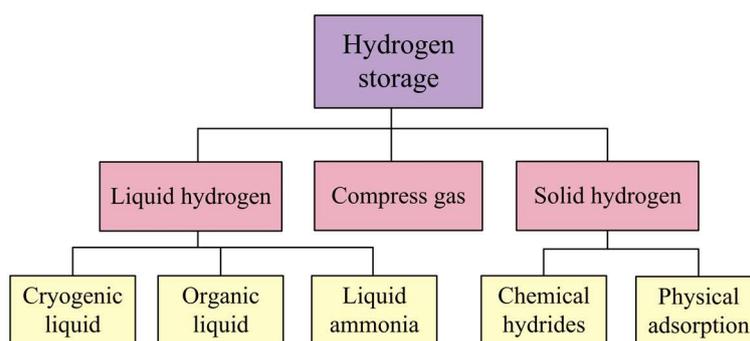


图 4. 不同的氢气储存技术。

Figure 4. Different hydrogen storage technologies.

最常见、最直接的储氢方法是高压气态储氢。高压气态储氢具有成本低、充放电速度快等优点。因此，它在 HECCESS 中得到了广泛应用。但它也有密度低、安全性差的缺点。低温液态储氢将氢气液化并储存在低温真空绝热装置中。它的储氢体积密度高，液化氢纯度高，但液化过程耗能大。有机液态氢储存弥补了高压气态氢储存密度低的缺陷，而且可以多次循环使用。但是，储存过程成本高，操作条件苛刻。液氨储氢是一种新兴的化学储氢方法，氢气质量容量高，这使得液氨储氢具有更好的储氢潜力。然而，液氨储氢技术也存在一些挑战和局限性，如液氨的蒸发损失、氢气释放和回收等。此外，液氨的制备和处理过程也需要考虑环境和能源消耗问题。

以物理吸附的形式，氢被吸附在碳基材料的固体表面上。被吸附的氢可以高速吸附和解吸。然而，碳基材料的技术尚未成熟 [14]。在化学氢化物储氢形式中，氢与金属或金属合金通过化学反应结合成金属氢化物。其储氢体积密度大、安全性高，具有较大的发展潜力。

未来的发展方向在于 HECCESS 领域，保持氢储能的灵活性和经济性。加强纯氢、纯氨内燃机等技术的规模化应用 [17]。同时，还要建立电氢协同机制，促进两个系统更好地互补和协同。

3. 氢电耦合储能系统模型

氢具有能源和资源的双重属性，是连接各类能源的桥梁和纽带。在常见的二次能源中，绿色电力和绿色氢能是最佳选择。氢电耦合可以减少或平衡新能源随机性和波动性对电力系统的影响，这是新型电力系统的发展方向和重要特征。目前，国内外专家学者已针对氢电耦合开展了一系列前瞻性研究工作。

3.1. HECCESS 的耦合特性

HECESS 基于氢储能相关技术，将化石能源和可再生能源转化为电力和氢能两种二次能源。如图 5 所示，在分析 HECCESS 的耦合机制时，电力系统和氢能系统具有互补潜力。在系统运行层面，电力系统可基于系统中富余的可再生能源实现灵活制氢，为氢气供应链中的压缩机等关键设备供电，提供多样化的氢气应用。考虑到电力系统需要满足实时供需平衡，氢能源系统在生产、存储、发电等各个环节都具有一定的缓冲能力。因此，氢能源系统可以灵活高效

地为电力系统提供备用发电、长期储能等辅助服务。HECESS 的建立有利于缓解低电压电网的输电和运输压力。同时，可再生能源渗透率较高的电力系统可通过电制氢技术生产高纯度、低碳的氢能。然后，氢能系统基于制氢技术为电力系统提供负荷管理服务，从而提高电能质量和可靠性。

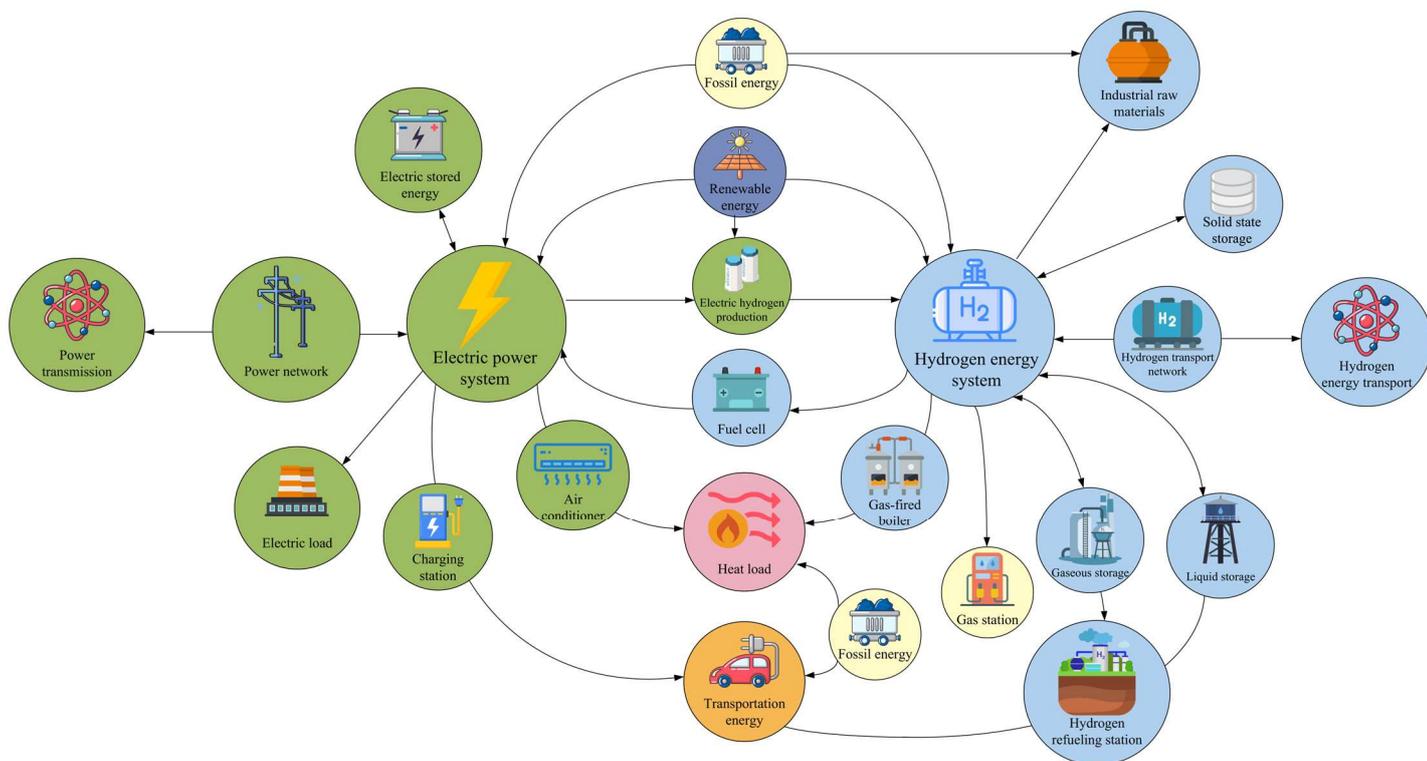


图 5. HECESS 示意图。

Figure 5. Schematic diagram of HECESSs.

3.2. HECESS 模型

考虑到电解槽的快速动态响应，在 HECESS 的优化研究中，通常使用简单的线性模型来描述电制氢技术 [18]。线性效率常数通常用于描述输入功率和输出功率之间的关系 [19]。电解槽可将水分解成氢气和氧气，其输出功率可表示为 [20]：

$$M_{el}(t) = \eta_{el}P_{el}(t) \quad (2)$$

其中， P_{el} 、 η_{el} 分别为输入功率和 AEC 的转换系数。

燃料电池以氢和氧为燃料，将化学能转化为电能储存起来，其输出功率可表示为：

$$P_{fc}(t) = \eta_{fc}M_{fc}(t) \quad (3)$$

其中， M_{fc} 、 η_{fc} 分别为从储氢罐输入燃料电池的功率和 PEMFC 的转换系数。

根据热力学特性，简单线性模型的能量守恒方程为：

$$H_{el}(t) = (1 - \eta_{el})P_{el}(t)\eta_{heat} \quad (4)$$

$$H_{fc}(t) = (1 - \eta_{fc})P_{fc}(t)\eta_{heat} \quad (5)$$

其中, H_{el} 和 H_{fc} 分别为 AEC 和 PEMFC 产生的供热管网循环水的加热吸收功率。 η_{heat} 是加热转换系数。

储氢罐用于储存 AEC 电解产生的氢气, 同时也为 PEMFC 的化学反应提供氢气。储氢罐在 t 时刻储能的数学模型可表示为 [21]:

$$E_{\text{tank}}(t) = E_{\text{tank}}(t-1) + (P_{el}(t-1) \eta_{el} \eta'_{el} - \frac{P_{fc}(t-1)}{\eta_{fc} \eta_{\text{tank}} \eta'_{fc}}) \Delta t \quad (6)$$

其中, $E_{\text{tank}}(t)$ 是储氢罐在时间 t 时储存的能量; η'_{el} 、 η'_{fc} 分别是电解槽和燃料电池的效率。 η_{tank} 是储氢罐的工作效率。

在此基础上, 在制氢方面, Li 等 [22] 考虑了电热和电氢的耦合过程, 建立了一个电制氢模型。该模型通过电-热-氢调度, 应用于主动配电网和区域供热网络的协调系统。Pan 等 [23] 进一步建立了计及电制氢启停特性的热氢联产模型和季节性储氢模型。Lin 等 [24] 通过考虑堆栈寿命衰减率、辅助设备能耗等多种因素, 建立了一个更为复杂的非线性电制氢系统模型, 并采用分段线性方法将其处理为线性模型。上述模型有助于优化电解制氢设施的调度和储氢方案, 从而提高系统效率和可持续性。

在氢能发电方面, 有学者构建了含电转气的区域 HECCESS 的日前优化调度模型 [25]。燃料电池的发电和制热效率被表征为输出功率标幺值的五次函数。Tao 等 [26] 进一步建立了一个氢燃料电池模型, 该模型考虑了负载-燃料消耗的变化, 使燃料电池汽车的能耗最小化。上述文献中模型的建立为 HECCESS 和氢燃料电池汽车的优化调度提供了参考和指导。通过考虑能源消耗和效率等各种因素, 实现更动态、更有效的能源调度策略。

在氢气存储方面, Li 等 [27] 提出了具有季节性储存的氢气供应链-电力网络概念。建立了考虑充放电约束和储氢约束的日间储氢模型。以解决区域性和季节性不平衡问题, 保证氢能供应。在考虑模型充放电约束和储氢约束的基础上, Taweel 等 [28] 建立了基于需求响应的小时级储氢模型, 进一步考虑最小储氢约束参与优化调度。要实现大规划、长时间尺度的储能, 就需要储氢。为了解决跨季节储氢的难题, Pan 等 [29] 提出了一种电氢一体化能源系统的双层混合整数规划模型。双层模型中考虑了季节性储氢的运行状态, 突出了氢气在可再生能源渗透和季节互补中的作用。这些研究为氢储能领域提供了重要的理论和方法见解, 有助于解决长期储能和跨季节储能的供需平衡难题。

上述分析表明, 研究人员采用了不同的方法和模型来解决氢供应的平衡问题。一方面, 重点建设制氢设施, 满足当地需求, 降低跨区域输氢成本和能耗。另一方面, 他们考虑采用大规模长期储氢技术, 以便在需求高峰时释放氢气供应。此外, 他们对跨季节储氢进行了建模, 为氢气供应的平衡性和可靠性做出了重要努力和贡献。

3.3. HECCESS 的优化规划和运营

与电气耦合综合能源系统的电气转换模型相比, HECCESS 省略了氢转气的环节, 在电解制氢过程后将氢气直接输送至氢燃料电池。节省了转换过程中能量的损失, 能量转换效率更高。因此, 许多学者进一步开展了以下研究: 考虑不同能源之间多能互补的优势, Zheng 等 [30] 发展了用于多层次

能源开发的储氢装置。他们建立了相应的优化设计问题，确定了系统的最优容量配置和相应的运行策略。Cheng 等 [31]提出了多能源耦合系统的两层分散规划方法和考虑分散排放约束的多能源耦合系统的两层扩展规划模型。上层规划计及电气网络的多区域 HECCESS 的最优方案，下层规划研究了考虑碳排放约束的区域电力 HECCESS 的最优供能配置方法。Jiang 等 [32]提出了一种考虑交通流捕获的风-氢-电耦合网络规划方法，解决了耦合网络下制氢加氢站和风电场的选址定容问题。

系统优化的基本流程如下。首先，建立场景规划模型，然后结合设备选型和场地条件对可再生能源出力进行预测，综合考虑负荷与功率的关系来选择模型的优化变量。根据电网功率平衡情况和各发电主体的实际物理限制，构建系统约束定容优化模型。它通常是一组包含组件特性和系统运行特性的方程。优化目标一般需要考虑技术、经济和环境指标 [33]，以实现优化的高效性、可行性和可持续性。经济指标包括能源成本、全生命周期成本和弃电损失成本。技术指标包括设备性能退化和响应时间。环境指标包括储能效率、环境友好性等。最后通过优化模型求解确定氢储能配置。优化方法的合理选择也会影响模型的最优解和求解效率。

目前常用的优化方法主要包括概率方法、线性或非线性规划方法等经典优化方法 [34]。此类方法适用于求解单峰函数，但其缺点是在具有多个局部最优的优化问题中容易陷入局部最优解。随机优化方法包括遗传算法 [35]、粒子群算法 [36]和许多其他算法。随机优化方法与经典优化方法相比，可以通过优化获得全局最优解，对初始值的依赖程度较高。但其搜索效率较低，且难以在多次优化中获得相同的优化解。近年来，机器学习技术已被集成到元启发法中来解决组合优化问题 [37]，目的是提高算法在求解质量、收敛速度和鲁棒性方面的性能。其中，DRL 因其在高不确定性运行问题上的优异表现而备受关注。为此，本文对 DRL 及其在 HECCESS 中的应用进行了全面的文献综述，如第 5 节所示。

值得注意的是，当前国内外专家学者对 HECCESS 的规划和运行高度关注。现有的研究和实践主要集中在既定优化目标下对单个或部分电氢耦合环节或技术进行优化规划和效益分析。HECESS 的潜在多维度价值尚未从系统建模、效益评估、投资规划、优化运营等角度进行全面分析。例如，目前尚缺乏针对各地区精细化的制氢、发电、储存和运输成本。在 HECCESS 的协同规划研究中，分析电力系统、氢能系统未来能源形态架构的研究相对较少。

4. HECCESS 在电力系统中的应用

HECESS 在电力系统中的定位与其他储能方式不同，主要体现在作用周期长、跨季节、规模大等方面。氢储能与电力系统应用概况如图 6 所示。本节根据 HECCESS 的应用，总结分析了 HECCESS 在电力系统源-网-荷侧的应用场景。

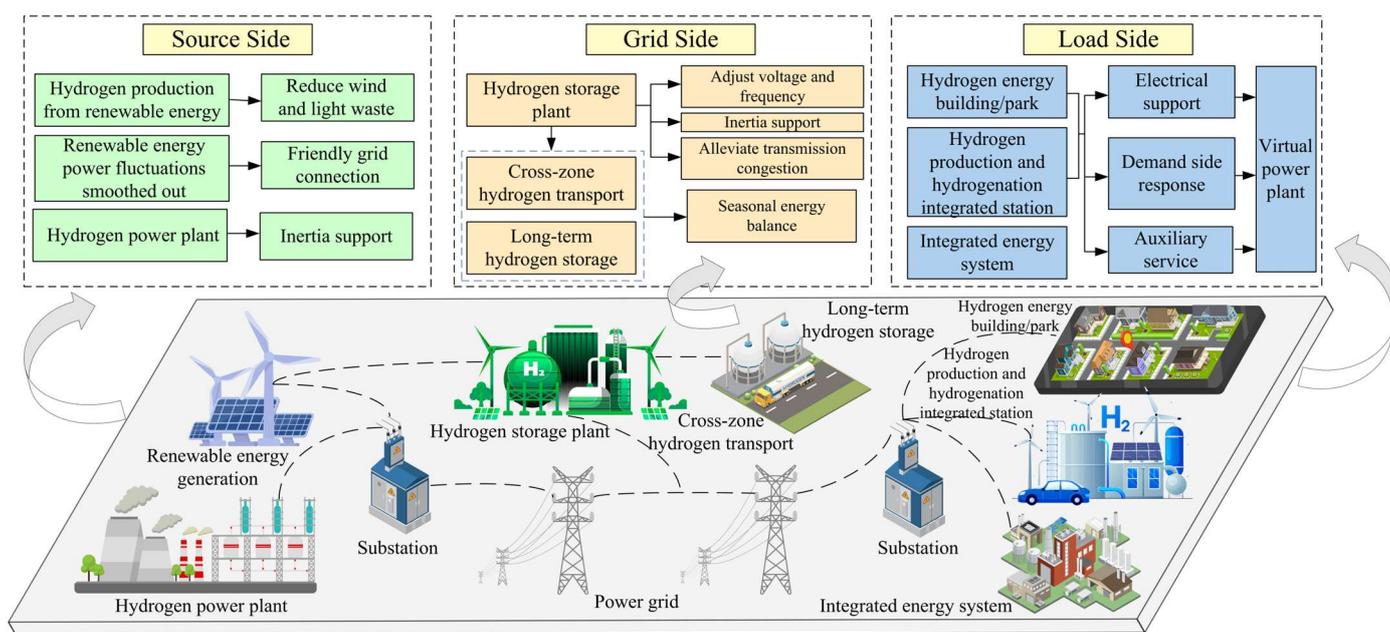


图 6. 氢储能及其在电力系统中的应用。

Figure 6. Hydrogen storage and applications in power systems.

4.1. HCESS 在电源侧的应用

电源侧，高比例风光直接并网对电力系统影响较大，出力表现出更强的随机性和波动性。这主要是由于天气条件和可再生能源供给的不确定性影响电力系统运行稳定。这种情况就会导致弃风弃光的情况发生。氢能作为跨季储能，消纳过剩能源制取的氢气保存在储氢装置中，也可以供应氢气负荷。当电力高峰需求或可再生能源供应不足时，储氢可以削峰填谷，平滑风、光等电源的出力曲线，增强可再生能源的深度消纳 [38]。氢储能技术可以实现可再生能源的平滑调度，延长供电时间。基于氢储能的快速响应能力对可再生能源波动的输出进行平抑，有助于解决可再生能源的波动性和间歇性 [39]。提高了电力系统的稳定性和可靠性，进而实现了风能、太阳能等清洁能源的友好并网。此外，基于富氢或纯氢燃气轮机技术建设氢燃料电池，可为新型电力系统提供惯量支撑。削减一部分柔性负荷，以增强系统在负荷波动和联络线中断情况下的频率稳定性 [40]。

4.2. HCESS 在电网侧的应用

在电网侧，新型电力系统呈现低惯量特性，使得电网运行稳定性恶化，容易引发振荡 [41]。一般而言，储氢电站合理部署在大规模新能源聚集、密集负荷接入等系统关键节点。储氢电站中的氢气燃气轮机可以为电网侧提供部分惯量支撑，减缓电网频率的波动。同时，氢储能电站还具备双向变速工况的能力，可以在短时间内快速进行电力输出或储能。这一能力使得储氢电厂能够为电网提供调峰服务。储氢电站采用电-氢-电转换方式，当电力供需不平衡时，储氢电站将接入输配电系统的阻塞线路末端。此时大容量氢储能可以充当虚拟

传输线。在低谷负载时间充电，高峰负载时间放电。这降低了输配电系统容量需求，减轻了系统阻塞输配电线路容量对电网功率的影响 [42]。

受气候因素影响，可再生能源出力在具有不确定性的同时呈现出季节特性 [43]。这将导致电力系统的电力供需在长期范围内出现不平衡。长时间氢储存的介入可以实现电力的季节性调整。因此，利用储氢电站制氢技术与储氢技术相结合，可以长期储存氢气，实现跨季节、跨区域的能源供应。同时，可利用氢能发电技术进行异地输送电力，保证电力供应均衡。此外，以电网作为能源转移的桥梁，采用季节性储氢技术，可以解决可再生能源制氢与氢负荷之间固有的时空不平衡问题。

4.3. HECCESS 在负荷侧的应用

在负荷侧，氢储能可以为电网提供多种类型的辅助服务，满足调峰、调频、旋转、备用等多样化需求。储氢建筑/园区大致可分为集中式储能和分布式储能。集中式储能结构主要是供多个建筑和能源中心共享电力。另一方面，分布式储能结构在建筑物之间共享电力。Fan 等 [44]利用电、氢的互补特性以及建筑物之间的能量交互，提出了一种基于多智能体 DRL 的智慧园区多楼宇分布式实时调度方法。利用 HECCESS 建设氢能建筑或园区，可以保证建筑电力的持续供应，同时可以辅助调峰调频，将多余的能量送回电网。

新型电力系统建设理念将从传统的“源随荷动”演进为“荷随源动”。在此背景下，挖掘负载侧的灵活性资源就显得非常重要。制氢和加氢站可以作为负荷侧重要的新型灵活调节资源，参与负荷需求响应。加氢站连接上游氢气制取并运输至下游应用，是氢能运输的重要枢纽。此外，将可再生能源接入电网、氢网、燃气网、热网可以加速能源转型进程。未来，建设电-氢等多能源 HECCESS 将成为负荷侧的典型场景之一。

5. HECCESS 的深度强化学习算法

由于 HECCESS 规划模型的复杂性，传统优化方法在求解质量、收敛速度、鲁棒性等方面表现并不突出。考虑电-氢-冷-热等多种能源的 HECCESS 对算法的求解效率和精度提出了更高的要求。传统的基于模型的方法很难为实际能源系统选择合适的模型 [45,46]，并且为简化模型而做出的许多假设使其不适用于实际情况 [47]。为了提高 HECCESS 模型求解的效率和精度，本文提出了 DRL 等基于无模型的算法。该算法通过学习智能体与环境交互的策略，显示出在线优化的巨大潜力 [48,49]。总体而言，本节首先介绍马尔可夫决策过程 (Markov Decision Process, MDP)、强化学习 (reinforcement learning, RL) 和深度学习 (deep learning, DL) 的基础知识。然后，描述 RL 和 DL 的组合，从而形成 DRL。最后，我们将回顾相关文献背后的 DRL 应用细节和动机。

5.1. 马尔可夫决策过程

RL 和 DRL 是将环境状态映射到动作的学习类型。通过环境的反馈，智能体感知自身行为的优缺点并不断修正，最终获得最大的累积奖励。这种学习问题一般用 MDP [50]来描述。

在随机动态系统中，如果智能体的下一个状态 S_{t+1} 只与当前状态 S_t 有关，而与之前的历史状态无关，则称该系统具有马尔可夫性质：

$$p(S_{t+1} | st) = p(S_{t+1} | st, S_{t-1}, \dots, S_1, S_0) \quad (7)$$

当智能体的环境状态具有马尔可夫性质时，智能体选择当前状态下的行为并将其转移到下一个状态。这样的顺序过程就是 MDP。MDP 一般可以用五元组来表示：

$$\text{MDP} \sim \{\mathbf{S}, \mathbf{A}, \mathbf{P}, r, \gamma\} \quad (8)$$

其中， S 是智能体的状态空间； A 表示智能体的行为策略空间； $\mathbf{P} : \mathbf{S} \times \mathbf{A} \times \mathbf{S} \rightarrow [0, 1]$ 为转移概率； $r : \mathbf{S} \times \mathbf{A} \rightarrow \mathbb{R}$ 是智能体从环境中获得的即时回报； $\gamma \in [0, 1]$ 为折扣因子，反映当前时刻未来奖励的价值比例；累计收益 $G_t = r_t + \gamma r_{t+1} + \gamma^2 r_{t+2} + \dots = \sum_{k=0}^{\infty} \gamma^k r_{t+k+1}$ 。

上述 MDP 假设系统状态完全被代理观察到。然而，在大多数情况下，代理只能观察系统状态的一部分。因此，考虑到部分观测引入的不确定性，提出部分可观测马尔可夫决策过程（partially observable Markov decision process, POMDP）来建立决策模型。POMDP 是一个数学框架，用于对决策者仅掌握系统状态的部分信息的情况进行建模。POMDP 是 MDP 的扩展，它考虑了某些状态数据丢失或被认为不确定的情况。它可以被描述为六元组 $(\mathbf{S}, \mathbf{A}, \mathbf{P}, r, \Omega, \mathbf{O})$ ，其中 $(\mathbf{S}, \mathbf{A}, \mathbf{P}, r)$ 的表示方式与 MDP 中相同。 Ω 和 \mathbf{O} 分别表示观测值集合及其相应的观测概率。

在 MDP 下，Li 等 [51] 基于策略 π 定义了状态价值函数 $v_{\pi}(s)$ 和行为价值函数 $q_{\pi}(s)$ 。

5.2. 强化学习

强化学习主要关注智能体如何根据环境刺激做出决策，以最大化长期累积奖励，从而形成状态和行为之间的映射关系 [52]。强化学习中智能体与未知环境的交互如图 7 所示，主要包括以下步骤：

- 1) 在当前状态 s_t 下，智能体根据行为价值函数 Q 和行为策略 π_t 选择行为 a_t ；未知环境对智能体 a_t 采取行为的响应将转移到下一个状态 s_{t+1} ，并将奖励信号 r_t 反馈给智能体；
- 2) 智能体通过环境反馈 r_t 更新其行为价值函数 Q ；
- 3) 指导后续行为策略 π_t ；
- 4) 返回步骤 1，重复上述过程。

在这种学习机制中，智能体在某种状态下的行为将通过价值函数 Q 和行为策略 π_t 的作用被多次选择。因此，在环境时变的情况下，智能体可以通过与环境的持续交互来不断更新策略，寻求最大累积收益，从而使算法达到跟踪环境变化的目的 [53,54]。

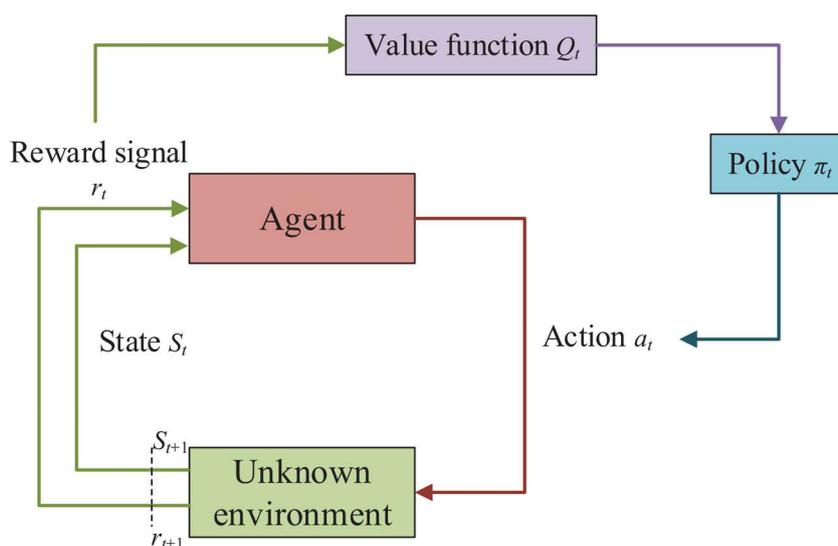


图 7. 强化学习框架。

Figure 7. Framework of reinforcement learning.

5.3. 深度学习

然而，在强化学习中，智能体通常使用表格或简单的函数来表示其策略或价值函数，这限制了智能体处理大规模环境和高不确定性的复杂问题的能力，从而进一步限制了其在 HECCESS 中的应用。因此，引入深度学习来协助强化学习应对这些挑战。DL 是基于深度神经网络（deep neural networks, DNNs)的机器学习的子集。它试图模拟人脑行为并从海量原始数据中提取重要特征。有两种经典的 DNN 模型，包括卷积神经网络（convolutional neural network, CNN）[55]和循环神经网络（recurrent neural network, RNN）[56]。

CNN 作为一种强大的特征提取结构，近年来引起了众多研究人员的高度关注。CNN-BiLSTM 模型中的 CNN 层函数执行 5.2 节中的步骤 1) 接受选定的变量作为输入层的输入，以及 5.2 节中的步骤 2) 将变量的特征提取到 BiLSTM 的输入层。CNN 的结构如图 8 所示。CNN 的核心是卷积层，降低了网络复杂度和参数数量。在这一层中，揭示了输入数据的特征，可以表示为

$$h_{ij}^m = f[(W^m * x) + b_m] \quad (9)$$

其中 f 是激活函数， W^m 和 b_m 分别表示内核对第 m 个特征图的权重和偏差。池化层减小了体积大小并提高了计算性能，从而使计算变得更容易，可以使用最大池化或平均池化。

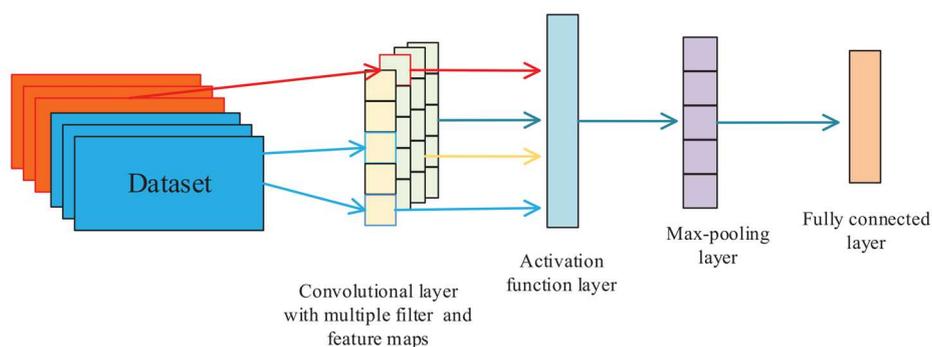


图 8. CNN 的主要结构。

Figure 8. Main structure of CNN.

与 CNN 不同，RNN 从先前的输入中提取信息来确定当前的输入和输出。作为典型的 RNN，LSTM 通过集成的记忆单元和不同的门控机制，在捕获和保留长期依赖关系方面具有出色能力，因而脱颖而出 [57,58]。LSTM 的主要架构如图 9 所示。LSTM 中的记忆单元允许网络长期存储和访问信息。此外，门控机制（包括输入门、遗忘门和输出门）控制信息流，使网络能够根据信息的相关性选择性地保留或遗忘信息。

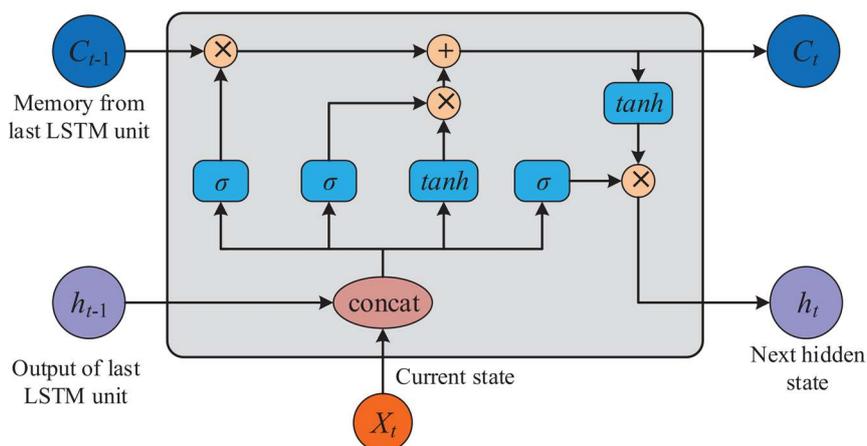


图 9. LSTM 块的基本架构。

Figure 9. Basic architecture of LSTM block.

5.4. 深度强化学习应用于 HECES

简单的表格结构限制了 RL 描述系统特征的能力，因此，DRL 结合了深度学习和强化学习，可以处理更复杂的任务，例如高维连续状态空间和高维动作空间设置下的决策优化 [59,60]。DRL 的总体框架如图 10 所示。根据策略优化，DRL 算法可以分为基于值的算法和基于策略的算法。

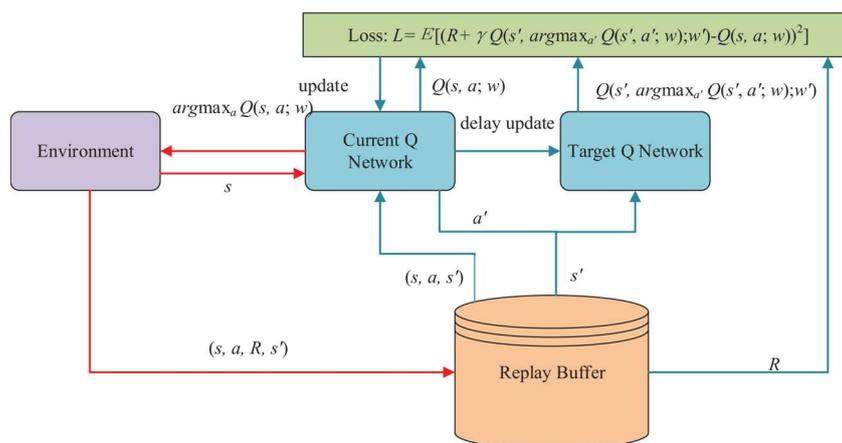


图 10. DRL 的基本架构。

Figure 10. Basic architecture of DRL.

对于基于价值的 DRL，例如深度 Q 学习（deep Q learning, DQN），它倾向于优化动作价值函数 $Q(s, a)$ 以获得动作选择的偏好 [61,62]。因此，基于值的 DRL 具有更高的采样效率和更小的值函数估计方差，并且不易陷入局部优化。然而，基于值的 DRL 方法无法处理连续动作空间问题，这将限制该方法在 HECCESS 中的使用。与基于值的 DRL 不同，基于策略的 DRL（即近端策略优化）依赖于使用梯度下降来优化参数化策略，考虑到预期奖励，而不是优化动作价值函数，它可以处理高连续行动空间的问题 [63,64]。

近年来，HECESS 以其可持续发展和环境友好的特点受到了世界各国的广泛关注 [65]。然而，随着越来越多的可再生能源和灵活负荷并入电网，HECESS 已成为一个具有较强不确定性的复杂动态系统，这给 HECCESS 的安全经济运行带来了巨大挑战。此外，如上所述，当考虑强随机性时，传统的基于模型的方法不适合 HECCESS 优化问题。因此，DRL 作为一种无模型优化算法被引入来解决 HECCESS 的优化调度问题，并取得了一系列成功的应用。在本节的其余部分中，讨论了基于 DRL 的 HECCESS 的优化运行展望。

一方面，HECESS 中采用 DRL 方法来处理源端的最优调度问题。例如，Yi 等 [66] 开发了一个可扩展的计算框架，以促进考虑核资源的 HECCESS 优化 DRL 算法的研究。通过分析各种 DRL 算法的基准性能，证明了 DRL 算法相对于传统粒子群优化（particle swarm optimization, PSO）算法的优越性。Yang 等 [67] 提出了一种基于 DDPG 的改进算法来处理 HECCESS 的调度问题，同时考虑分布式发电、灵活负荷和热负荷的不确定性。数值模拟结果表明，该方法能够适应系统能源需求和光伏发电的不确定性，动态优化各能源单元的出力，降低系统的运行成本。Zhang 等 [68] 应用近端策略优化（proximal policy optimization, P-PO）来获得能源管理策略，该策略允许多个优化目标，包括运营成本、电池存储系统和污染成本。仿真结果表明，该系统每日总成本比其他方法可降低约 2.6%。此外，Zhang 等 [69] 针对 HECCESS 结合可再生能源提出了 PPO 解决的动态能源调度策略，同时考虑了负荷侧的不确定性、可再生能源的间歇性和上层电价的灵活性。Xu 等 [70] 研究了一种基于 DRL 的机组组合问题

优化模型, 该模型可以对冲风电的不确定性。结果表明, 在可再生能源高渗透率下, 所提出的方法可以有效地满足以计算效率高的方式解决机组组合问题这一日益迫切的需求。Tobi 等 [71]提出了一种自动超参数选择特征 DRL 来调度实时多能源系统, 与基于规则的调度相比取得了巨大的成功。这些文献主要集中于解决 HECCESS 中的电力调度问题。通过引入 DRL 算法, 这些方法可以有效处理不确定性和多目标优化的要求。它们在降低系统运行成本、提高效率、实现可持续能源管理等方面取得了良好的表现。

此外, 多智能体 DRL (multi-agent DRL, MADRL) 在 HECCESS 的优化问题上也显示出了巨大的潜力。例如, Monfaredi 等 [72]提出了一种基于 MADRL 的优化能源调度方法, 该方法集成了考虑分布式能源、储能系统以及热电负荷的天然气和电力系统。仿真结果表明, 运营利润得到显著优化, 实现了合理的运营成本, 保证了电力系统的安全。将多能源枢纽的能源管理问题转化为基于 MADRL 的多智能体协调优化问题, 在满足约束的前提下最小化系统运行成本和二氧化碳排放 [73]。Guo 等 [74]提出了一种基于 MADRL 的实时分散控制策略, 充分利用光伏逆变器的剩余容量, 在保证电压安全的前提下最大限度地减少功率损耗。总之, 这些研究提出了在 HECCESS 中使用 MADRL 的方法。这些方法通过考虑多个参与者的协调优化, 能够最大化电力系统的运行效益并降低运行成本。同时, 在满足约束条件的情况下, 这些方法还能够最大限度地减少二氧化碳排放和电力损失。

另一方面, 研究了 DRL 在 HECCESS 需求侧的应用 [75]。Zhong 等 [76]提出了一种基于 DQN 的深度强化学习框架, 实现了用户补贴价格的动态生成, 在促进需求响应的同时使负荷聚合商的利润最大化。数值研究表明, 用户节省供暖费用高达 8.7%, 电网公司节省投资 56.6%。Li 等 [77]构建了基于多智能体深度确定性策略梯度的协调电力调度框架, 将模仿学习与课程学习相结合。通过实例验证了该算法在可再生电力波动和随机负荷下的调度性能。Ye 等 [78]提出了一种基于优先深度确定策略梯度 (priority depth determination policy gradient, PDDPG) 方法的无模型数据驱动方法, 可以确定多能源系统的实时自主控制策略, 还可以显著降低日常能源成本。Zhou 等 [79]将热电联产系统的约束调度问题建立为 MDP。在此基础上, 提出了一种改进的策略梯度 DRL 算法。仿真结果表明, 该算法能够处理不同的运行场景, 并获得比其他方法更好的优化性能。鉴于可再生能源和需求响应 (demand response, DR) 带来的不确定性, Dong 等 [80]提出了一种基于软行为者-批评者的 DRL 算法和区间优化理论相结合的最优调度框架, 使得系统经济性得到显著改善。Yun 等 [81]提出了一种新的可解释的多智能体 DRL 方法, 以实现动态 DR 下制造系统的自动生产控制, 同时保持生产目标的约束。模拟结果表明, 该方法在一天和三天的生产周期内分别可节省 13.6%和 30.7%的能源成本。此外, Xie 等 [82]提出了一种 MADRL 方法, 该方法采用包含共享注意力机制的参与者批评算法, 以在网格响应架构中实现有效且可扩展的实时协调需求响应。与传统和最先进的强

化学习方法相比, MADRL 将净负载需求减少了 6%以上。这些研究表明, 与传统优化算法相比, DRL 在 HECCESS 需求侧的应用可以实现利润最大化、成本最小化、能源效率优化。引入 DRL 算法解决 HECCESS 的优化调度问题, 促进优化算法和调度策略的创新迭代, 使得 HECCESS 的应用前景更加广阔。

总体而言, 上述基于 DRL 的方法可以有效地处理具有不确定性的高维最优调度问题。无论是在 HECCESS 的源端还是需求端, 都能够获得比传统方法更好的性能。该方法的运用不仅提高了调度性能, 而且增强了系统的鲁棒性和适应性, 使得最优调度更加准确可靠。

6. HECCESS 的挑战和开放研究问题

HECESS 推动氢储能与电力系统多能融合的高效耦合, 增强电力系统的弹性和灵活性, 实现更高效、更高质量的电力供应。随着制氢、氢发电、储氢等技术的不断完善, HECCESS 以冷、热、电、氢等多种能源推动深度脱碳目标的实现。

但 HECCESS 的应用仍需要继续攻坚和突破。氢根据其产生来源分为灰氢、蓝氢、蓝绿氢和绿氢。绿氢是通过可再生能源经电解水方法生产的氢气, 制取过程不产生二氧化碳, 最适合实现可持续能源转型。积极推广太阳能制氢、生物质制氢等方式的应用, 促进多元化制氢方式发展。但目前绿氢生产成本较高, 降低成本是发展氢能绿色利用的主要目标。绿氢的经济优势可以通过协同降低制氢过程中的电力成本和设备成本来体现。未来 100 MW 及以上电解水制氢系统将成为主流规模。

随着可再生能源发电成本不断下降, 可再生能源发电将成为未来发电的主流形式。加之电网接纳能力有限, 离网可再生能源制氢将成为未来重要的绿色制氢场景。离网风/光伏制氢将在系统规划与运行、优化产能配置、经济稳定控制等方面不断发展。电网对灵活性的要求日益提高, 氢储能系统将深度参与需求侧响应服务。随着氢储能在电网调峰场景中的出现, 考虑氢或燃料电池启停和动态响应特性的调频策略将逐渐显现。不同类型氢储能多时相优化配置技术将逐步完善, 氢储能将作为多时间尺度储能支撑电网跨时态功率平衡。

考虑 HECCESS 将实现园区或建筑物的零碳能源供应。系统规划建模的高效求解技术将是发展氢储能大规模接入电力系统的关键。建立有效的 HECCESS 模型可以为电网提供决策支持并为系统运行规划布局。应用启发式、人工智能等多种算法对模型进行求解, 实现 HECCESS 的自学习最优配置。其中, 利用 DRL 算法求解 HECCESS 模型比传统优化算法具有更高的求解效率和精度。同时, DRL 算法对于需要大规模数据处理和复杂模型训练的复杂系统表现更好。

7. 结论

氢能面向新能源开发利用和实现深度脱碳目标, 是能够同时解决未来能源危机和环境污染问题的绿色能源。HECESS 将氢与电耦合, 可以推动更高比例的新能源发展, 实现氢与电的相互转化和高效协同。本文以 HECCESS 为研究对

象，从制氢、氢气发电、储氢等方面对电-氢-电转换的应用技术现状进行了深入的总结和分析。研究了氢储能与电能的协同机理，讨论了 HECESS 的结构模型、规划方法和优化调度。同时，以源-网-荷侧环节为主线，探索氢储能的应用场景。在模型求解方面，针对传统优化方法求解速度慢、易陷入局部最优等缺点，探索了 DRL 算法在多能 HECESS 中的应用。最后，提出了 HECESS 未来发展的挑战和突出的研究问题，以供研究人员参考。

利益冲突： 作者声明没有潜在的利益冲突。

缩略词：

AEC	alkaline electrolysis cell	MDP	Markov Decision Process
AEMEC	anion exchange membrane electrolysis cell	PAFC	phosphoric acid fuel cell
AFC	alkaline fuel cell	PDDPG	priority depth determination policy gradient
CNN	convolutional neural network	PEMEC	proton exchange membrane electrolysis cell
DL	deep learning	PEMFC	proton exchange membrane fuel cell
DNN	deep neural network	POMDP	partially observable Markov decision process
DQN	deep Q learning	PPO	proximal policy optimization
DR	demand response	PSO	particle swarm optimization
DRL	deep reinforcement learning	RL	reinforcement learning
HECESS	hydrogen-electricity coupling energy storage system	RNN	recurrent neural network
MADRL	multi-agent DRL	SOEC	solid oxide electrolysis cell
MCFC	molten carbonate fuel cell	SOFC	solid oxide fuel cell

参考文献

1. Fuso Nerini F, Tomei J, To LS, et al. Mapping synergies and trade-offs between energy and the Sustainable Development Goals. *Nature Energy*. 2017, 3(1): 10-15. doi: 10.1038/s41560-017-0036-5
2. Iqbal M, Benmouna A, Becherif M, Mekhilef S. Survey on battery technologies and modeling methods for electric vehicles. *Batteries*. 2023; 9(3):185. <https://doi.org/10.3390/batteries9030185>
3. 张智刚, 康重庆. 碳中和目标下构建新型电力系统的挑战与展望. *中国电机工程学报*. 2022; 42(8): 2806–2819. Zhang Z, Kang C. Challenges and prospects for constructing the new-type power system towards a carbon neutrality future (Chinese). *Proceedings of the CSEE*. 2022; 42(8): 2806–2819.
4. Cai G, Kong L, Xue Y, Sun B. Overview of research on wind power coupled with hydrogen production technology. *Automation of Electric Power Systems*. 2014; 38(21): 127–135.
5. Pan G, Gu W, Zhang H, Qiu Y. Electricity and hydrogen energy system towards accomodation of high proportion of renewable energy. *Automation of Electric Power Systems*. 2020; 44(23): 1–10. doi: 10.7500/AEPS20200202003
6. Hanley ES, Deane J, Gallachóir BÓ. The role of hydrogen in low carbon energy futures—A review of existing perspectives. *Renewable and Sustainable Energy Reviews*. 2018, 82: 3027-3045. doi: 10.1016/j.rser.2017.10.034
7. 李佳蓉, 林今, 邢学韬, 等. 主动配电网中基于统一运行模型的电制氢 (P2H) 模块组合选型与优化规划. *中国电机工程学报*. 2021: 1–13. doi: 10.13334/j.0258-8013.pcsee.201307
Li J, Lin J, Xing X, et al. Technology portfolio selection and optimal planning of power-to-hydrogen (p2h) modules in

- active distribution network (Chinese). *Proceedings of the CSEE*. 2021; 41(12): 4021–4033. doi: 10.13334/j.0258-8013.pcsee.201307
8. Abe JO, Popoola API, Ajenifuja E, et al. Hydrogen energy, economy and storage: Review and recommendation. *International Journal of Hydrogen Energy*. 2019, 44(29): 15072-15086. doi: 10.1016/j.ijhydene.2019.04.068
 9. Razzhivin IA, Suvorov AA, Ufa RA, et al. The energy storage mathematical models for simulation and comprehensive analysis of power system dynamics: A review. Part i. *International Journal of Hydrogen Energy*. 2023, 48(58): 22141-22160. doi: 10.1016/j.ijhydene.2023.03.070
 10. Moradi R, Groth KM. Hydrogen storage and delivery: Review of the state of the art technologies and risk and reliability analysis. *International Journal of Hydrogen Energy*. 2019, 44(23): 12254-12269. doi: 10.1016/j.ijhydene.2019.03.041
 11. Pei W, Zhang X, Deng W, et al. Review of operational control strategy for DC microgrids with electric-hydrogen hybrid storage systems. *CSEE Journal of Power and Energy Systems*. 2022; 8(2): 329–346. doi: 10.17775/CSEEJPES.2021.06960
 12. Egeland-Eriksen T, Hajizadeh A, Sartori S. Hydrogen-based systems for integration of renewable energy in power systems: Achievements and perspectives. *International Journal of Hydrogen Energy*. 2021, 46(63): 31963-31983. doi: 10.1016/j.ijhydene.2021.06.218
 13. Liu W, Sun L, Li Z, et al. Trends and future challenges in hydrogen production and storage research. *Environmental Science and Pollution Research*. 2020, 27(25): 31092-31104. doi: 10.1007/s11356-020-09470-0
 14. 王士博, 孔令国, 蔡国伟, 等. 电力系统氢储能关键应用技术现状、挑战及展望. *中国电机工程学报*. 2023; 43(17): 6660–6681. doi: 10.13334/j.0258-8013.pcsee.230170
Wang S, Kong L, Cai G, et al. Current status, challenges and prospects of key application technologies for hydrogen storage in power system (Chinese). *Proceedings of the CSEE*. 2023; 43(17): 6660–6681. doi: 10.13334/j.0258-8013.pcsee.230170
 15. Yue M, Lambert H, Pahon E, et al. Hydrogen energy systems: A critical review of technologies, applications, trends and challenges. *Renewable and Sustainable Energy Reviews*. 2021, 146: 111180. doi: 10.1016/j.rser.2021.111180
 16. 李亚楼, 王丹丹, 赵飞, 李芳. 电力多元转换 (Power-to-X) : 技术路径、应用与挑战. *电网技术*. 2023; 1–14. doi: 10.13335/j.1000-3673.pst.2023.1234
Li Y, Wang D, Zhao F, Li F. Path, application and challenge of power-to-x (Chinese). *Power System Technology*. 2023; 1–14. doi: 10.13335/j.1000-3673.pst.2023.1234
 17. Gao J, Song J, Wang JX, et al. Form and key technologies of integrated electricity-hydrogen system supporting energy security in China. *Automation of Electric Power Systems*. 2023; 47(19): 1–15.
 18. Wu X, Li H, Wang X, et al. Cooperative Operation for Wind Turbines and Hydrogen Fueling Stations With On-Site Hydrogen Production. *IEEE Transactions on Sustainable Energy*. 2020, 11(4): 2775-2789. doi: 10.1109/tste.2020.2975609
 19. Li Q, Zhao S, Pu Y, Chen W, Yu J. Capacity optimization of hybrid energy storage microgrid considering electricity-hydrogen coupling. *Transactions of China Electrotechnical Society* 2021;36(3):486–95.
 20. Xiong Y, Chen L, Zheng T, et al. Electricity-Heat-Hydrogen Modeling of Hydrogen Storage System Considering Off-Design Characteristics. *IEEE Access*. 2021, 9: 156768-156777. doi: 10.1109/access.2021.3130175
 21. Liu L, Zhai R, Hu Y. Multi-objective optimization with advanced exergy analysis of a wind-solar-hydrogen multi-energy supply system. *Applied Energy*. 2023, 348: 121512. doi: 10.1016/j.apenergy.2023.121512
 22. Li J, Lin J, Song Y, et al. Operation Optimization of Power to Hydrogen and Heat (P2HH) in ADN Coordinated With the District Heating Network. *IEEE Transactions on Sustainable Energy*. 2019, 10(4): 1672-1683. doi: 10.1109/tste.2018.2868827
 23. Pan G, Gu W, Lu Y, et al. Optimal Planning for Electricity-Hydrogen Integrated Energy System Considering Power to Hydrogen and Heat and Seasonal Storage. *IEEE Transactions on Sustainable Energy*. 2020, 11(4): 2662-2676. doi: 10.1109/tste.2020.2970078
 24. Lin H, Wu Q, Chen X, et al. Economic and technological feasibility of using power-to-hydrogen technology under higher wind penetration in China. *Renewable Energy*. 2021, 173: 569-580. doi: 10.1016/j.renene.2021.04.015
 25. Xiong J, Jiao Y, Wang M. A day-ahead optimal scheduling of regional integrated energy system considering power to gas. *Modern Electric Power*. 2022; 39(5): 554–561. doi: 10.19725/j.cnki.1007-2322.2021.0132
 26. Tao Y, Qiu J, Lai S, et al. Collaborative Planning for Electricity Distribution Network and Transportation System Considering Hydrogen Fuel Cell Vehicles. *IEEE Transactions on Transportation Electrification*. 2020, 6(3): 1211-1225. doi: 10.1109/tte.2020.2996755

27. Li J, Lin J, Zhang H, et al. Optimal Investment of Electrolyzers and Seasonal Storages in Hydrogen Supply Chains Incorporated With Renewable Electric Networks. *IEEE Transactions on Sustainable Energy*. 2020, 11(3): 1773-1784. doi: 10.1109/tste.2019.2940604
28. El-Taweel NA, Khani H, Farag HEZ. Hydrogen Storage Optimal Scheduling for Fuel Supply and Capacity-Based Demand Response Program Under Dynamic Hydrogen Pricing. *IEEE Transactions on Smart Grid*. 2019, 10(4): 4531-4542. doi: 10.1109/tsg.2018.2863247
29. Pan G, Gu W, Qiu H, et al. Bi-level mixed-integer planning for electricity-hydrogen integrated energy system considering leveled cost of hydrogen. *Applied Energy*. 2020, 270: 115176. doi: 10.1016/j.apenergy.2020.115176
30. Zheng JH, Guo JC, Li Z, et al. Optimal design for a multi-level energy exploitation unit based on hydrogen storage combining methane reactor and carbon capture, utilization and storage. *Journal of Energy Storage*. 2023, 62: 106929. doi: 10.1016/j.est.2023.106929
31. Cheng Y, Zhang N, Lu Z, et al. Planning Multiple Energy Systems Toward Low-Carbon Society: A Decentralized Approach. *IEEE Transactions on Smart Grid*. 2019, 10(5): 4859-4869. doi: 10.1109/tsg.2018.2870323
32. Jiang Y, Yang G, Zhu Z. Wind-hydrogen-electricity coupled network planning considering traffic flow capture. *Automation of Electric Power Systems*. 2021; 45(22): 19–28.
33. Yang Y, Ma C, Lian C, et al. Optimal power reallocation of large-scale grid-connected photovoltaic power station integrated with hydrogen production. *Journal of Cleaner Production*. 2021, 298: 126830. doi: 10.1016/j.jclepro.2021.126830
34. Zhang Y, Hua QS, Sun L, et al. Life Cycle Optimization of Renewable Energy Systems Configuration with Hybrid Battery/Hydrogen Storage: A Comparative Study. *Journal of Energy Storage*. 2020, 30: 101470. doi: 10.1016/j.est.2020.101470
35. Garg H. A hybrid GSA-GA algorithm for constrained optimization problems. *Information Sciences*. 2019, 478: 499-523. doi: 10.1016/j.ins.2018.11.041
36. Xie Y, Sheng Y, Qiu M, et al. An adaptive decoding biased random key genetic algorithm for cloud workflow scheduling. *Engineering Applications of Artificial Intelligence*. 2022, 112: 104879. doi: 10.1016/j.engappai.2022.104879
37. Karimi-Mamaghan M, Mohammadi M, Meyer P, et al. Machine learning at the service of meta-heuristics for solving combinatorial optimization problems: A state-of-the-art. *European Journal of Operational Research*. 2022, 296(2): 393-422. doi: 10.1016/j.ejor.2021.04.032
38. Sun H, Li Z, Chen A, et al. Current status and development trend of hydrogen production technology by wind power. *Transactions of China Electrotechnical Society*. 2019; 34(19): 4071–4083. doi: 10.19595/j.cnki.1000-6753.tces.180241
39. 彭生江, 杨淑霞, 袁铁江. 面向风煤富集区域的风-氢-煤耦合系统演化发展系统动力学. *高电压技术*. 2023; 49(8): 3478–3489.
Peng S, Yang S, Yuan T. System dynamics of the evolutionary development of coupled wind-hydrogen-coal system for wind-coal enriched areas (Chinese). *High Voltage Engineering*. 2023; 49(8): 3478–3489.
40. Fan H, Wang L, Xing M, et al. Coordinated scheduling of multiple buildings with electric-hydrogen complementary considering frequency stability constraints. *Journal of Shanghai Jiaotong University*. 2023; 57(12): 1559–1570. doi: 10.16183/j.cnki.jsjtu.2022.380
41. Xu S, Wang H, Cao Y, et al. Parameter tuning for self-synchronous voltage source doubly-fed wind turbines with stability boundary and multi-objective constraint. *Automation of Electric Power Systems*. 2023; 47(11): 18–28.
42. Wang F, Yang H, Li L, et al. Collaborative optimal method for electricity-hydrogen integrated energy system considering spatial-temporal characteristics of hydrogen transportation. *Automation of Electric Power Systems*. 2023; 47(19): 31–43.
43. Bai X, Fan Y, Liu Y, Song Y. Wind power storage virtual power plant considering reliability and flexibility tiered capacity configuration. *Power System Protection and Control*. 2022; 50(8): 11–24.
44. Fan H, Yu W, Liu L, Dou Z. Multi-building coordinated dispatch in smart park for carbon emission peak and carbon neutrality considering electricity and hydrogen complementary. *Automation of Electric Power Systems*. 2022; 46(21): 42–51.
45. Ernst D, Glavic M, Capitanescu F, et al. Reinforcement Learning Versus Model Predictive Control: A Comparison on a Power System Problem. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*. 2009, 39(2): 517-529. doi: 10.1109/tsmcb.2008.2007630
46. Sharma P, Dutt Mathur H, Mishra P, et al. A critical and comparative review of energy management strategies for

- microgrids. *Applied Energy*. 2022, 327: 120028. doi: 10.1016/j.apenergy.2022.120028
47. Ceusters G, Rodríguez RC, García AB, et al. Model-predictive control and reinforcement learning in multi-energy system case studies. *Applied Energy*. 2021, 303: 117634. doi: 10.1016/j.apenergy.2021.117634
 48. Sutton RS, Barto AG. *Reinforcement Learning: An Introduction*, 2nd ed. MIT Press; 2018.
 49. Du G, Zou Y, Zhang X, et al. Deep reinforcement learning based energy management for a hybrid electric vehicle. *Energy*. 2020, 201: 117591. doi: 10.1016/j.energy.2020.117591
 50. Ding T, Zeng Z, Bai J, et al. Optimal Electric Vehicle Charging Strategy With Markov Decision Process and Reinforcement Learning Technique. *IEEE Transactions on Industry Applications*. 2020, 56(5): 5811-5823. doi: 10.1109/tia.2020.2990096
 51. Li Y, Yu C, Shahidehpour M, et al. Deep Reinforcement Learning for Smart Grid Operations: Algorithms, Applications, and Prospects. *Proceedings of the IEEE*. 2023, 111(9): 1055-1096. doi: 10.1109/jproc.2023.3303358
 52. Zheng JH, Wang WH, Li Z, Wu QH. Multi-layer double deep Q network for active distribution network equivalent modeling with internal identification for EV loads. *Applied Soft Computing*. 2023; 147: 110834. doi: 10.1016/j.asoc.2023.110834
 53. Yang D, Wang L, Yu K, et al. A reinforcement learning-based energy management strategy for fuel cell hybrid vehicle considering real-time velocity prediction. *Energy Conversion and Management*. 2022, 274: 116453. doi: 10.1016/j.enconman.2022.116453
 54. Wu JJ, Song DF, Zhang XM, et al. Multi-objective reinforcement learning-based energy management for fuel cell vehicles considering lifecycle costs. *International Journal of Hydrogen Energy*. 2023, 48(95): 37385-37401. doi: 10.1016/j.ijhydene.2023.06.145
 55. Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*. 1998, 86(11): 2278-2324. doi: 10.1109/5.726791
 56. Ravanelli M, Brakel P, Omologo M, et al. Light Gated Recurrent Units for Speech Recognition. *IEEE Transactions on Emerging Topics in Computational Intelligence*. 2018, 2(2): 92-102. doi: 10.1109/tetci.2017.2762739
 57. Bao S, Tang S, Sun P, et al. LSTM-based energy management algorithm for a vehicle power-split hybrid powertrain. *Energy*. 2023, 284: 129267. doi: 10.1016/j.energy.2023.129267
 58. Zhang L, Zhang J, Gao T, et al. Improved LSTM based state of health estimation using random segments of the charging curves for lithium-ion batteries. *Journal of Energy Storage*. 2023, 74: 109370. doi: 10.1016/j.est.2023.109370
 59. Jin R, Zhou Y, Lu C, et al. Deep reinforcement learning-based strategy for charging station participating in demand response. *Applied Energy*. 2022, 328: 120140. doi: 10.1016/j.apenergy.2022.120140
 60. Lu S, Liu S, Zhu Y, et al. A DRL-Based Decentralized Computation Offloading Method: An Example of an Intelligent Manufacturing Scenario. *IEEE Transactions on Industrial Informatics*. 2023, 19(9): 9631-9641. doi: 10.1109/tii.2022.3227652
 61. Hwang HS, Lee M, Seok J. Deep reinforcement learning with a critic-value-based branch tree for the inverse design of two-dimensional optical devices. *Applied Soft Computing*. 2022, 127: 109386. doi: 10.1016/j.asoc.2022.109386
 62. Xiao H, Fu L, Shang C, et al. Ship energy scheduling with DQN-CE algorithm combining bi-directional LSTM and attention mechanism. *Applied Energy*. 2023, 347: 121378. doi: 10.1016/j.apenergy.2023.121378
 63. Huang R, He H, Zhao X, et al. Longevity-aware energy management for fuel cell hybrid electric bus based on a novel proximal policy optimization deep reinforcement learning framework. *Journal of Power Sources*. 2023, 561: 232717. doi: 10.1016/j.jpowsour.2023.232717
 64. Zeng S, Huang C, Wang F, et al. A Policy optimization-based Deep Reinforcement Learning method for data-driven output voltage control of grid connected solid oxide fuel cell considering operation constraints. *Energy Reports*. 2023, 10: 1161-1168. doi: 10.1016/j.egy.2023.07.036
 65. Martinez Cesena EA, Loukarakis E, Good N, et al. Integrated Electricity–Heat–Gas Systems: Techno–Economic Modeling, Optimization, and Application to Multienergy Districts. *Proceedings of the IEEE*. 2020, 108(9): 1392-1410. doi: 10.1109/jproc.2020.2989382
 66. Yi Z, Luo Y, Westover T, et al. Deep reinforcement learning based optimization for a tightly coupled nuclear renewable integrated energy system. *Applied Energy*. 2022, 328: 120113. doi: 10.1016/j.apenergy.2022.120113
 67. Yang T, Zhao L, Li W, et al. Dynamic energy dispatch strategy for integrated energy system based on improved deep reinforcement learning. *Energy*. 2021, 235: 121377. doi: 10.1016/j.energy.2021.121377
 68. Zhang G, Hu W, Cao D, et al. Data-driven optimal energy management for a wind-solar-diesel-battery-reverse osmosis

- hybrid energy system using a deep reinforcement learning approach. *Energy Conversion and Management*. 2021, 227: 113608. doi: 10.1016/j.enconman.2020.113608
69. Zhang B, Hu W, Cao D, et al. Deep reinforcement learning–based approach for optimizing energy conversion in integrated electrical and heating system with renewable energy. *Energy Conversion and Management*. 2019, 202: 112199. doi: 10.1016/j.enconman.2019.112199
 70. Xu G, Lin Z, Wu Q, et al. Deep reinforcement learning based model-free optimization for unit commitment against wind power uncertainty. *International Journal of Electrical Power & Energy Systems*. 2024, 155: 109526. doi: 10.1016/j.ijepes.2023.109526
 71. Alabi TM, Lawrence NP, Lu L, et al. Automated deep reinforcement learning for real-time scheduling strategy of multi-energy system integrated with post-carbon and direct-air carbon captured system. *Applied Energy*. 2023, 333: 120633. doi: 10.1016/j.apenergy.2022.120633
 72. Monfaredi F, Shayeghi H, Siano P. Multi-agent deep reinforcement learning-based optimal energy management for grid-connected multiple energy carrier microgrids. *International Journal of Electrical Power & Energy Systems*. 2023, 153: 109292. doi: 10.1016/j.ijepes.2023.109292
 73. Xiong K, Hu W, Cao D, et al. Coordinated energy management strategy for multi-energy hub with thermo-electrochemical effect based power-to-ammonia: A multi-agent deep reinforcement learning enabled approach. *Renewable Energy*. 2023, 214: 216-232. doi: 10.1016/j.renene.2023.05.067
 74. Guo G, Zhang M, Gong Y, et al. Safe multi-agent deep reinforcement learning for real-time decentralized control of inverter based renewable energy resources considering communication delay. *Applied Energy*. 2023, 349: 121648. doi: 10.1016/j.apenergy.2023.121648
 75. Li Y, Bu F, Li Y, et al. Optimal scheduling of island integrated energy systems considering multi-uncertainties and hydrothermal simultaneous transmission: A deep reinforcement learning approach. *Applied Energy*. 2023, 333: 120540. doi: 10.1016/j.apenergy.2022.120540
 76. Zhong S, Wang X, Zhao J, et al. Deep reinforcement learning framework for dynamic pricing demand response of regenerative electric heating. *Applied Energy*. 2021, 288: 116623. doi: 10.1016/j.apenergy.2021.116623
 77. Li J, Yu T, Zhang X. Coordinated load frequency control of multi-area integrated energy system using multi-agent deep reinforcement learning. *Applied Energy*. 2022, 306: 117900. doi: 10.1016/j.apenergy.2021.117900
 78. Ye Y, Qiu D, Wu X, et al. Model-Free Real-Time Autonomous Control for a Residential Multi-Energy System Using Deep Reinforcement Learning. *IEEE Transactions on Smart Grid*. 2020, 11(4): 3068-3082. doi: 10.1109/tsg.2020.2976771
 79. Zhou S, Hu Z, Gu W, et al. Combined heat and power system intelligent economic dispatch: A deep reinforcement learning approach. *International Journal of Electrical Power & Energy Systems*. 2020, 120: 106016. doi: 10.1016/j.ijepes.2020.106016
 80. Dong Y, Zhang H, Wang C, et al. Soft actor-critic DRL algorithm for interval optimal dispatch of integrated energy systems with uncertainty in demand response and renewable energy. *Engineering Applications of Artificial Intelligence*. 2024, 127: 107230. doi: 10.1016/j.engappai.2023.107230
 81. Yun L, Wang D, Li L. Explainable multi-agent deep reinforcement learning for real-time demand response towards sustainable manufacturing. *Applied Energy*. 2023, 347: 121324. doi: 10.1016/j.apenergy.2023.121324
 82. Xie J, Ajagekar A, You F. Multi-Agent attention-based deep reinforcement learning for demand response in grid-responsive buildings. *Applied Energy*. 2023, 342: 121162. doi: 10.1016/j.apenergy.2023.121162

Review

Hydrogen-electricity coupling energy storage systems: Models, applications, and deep reinforcement learning algorithms

Jiehui Zheng, Yingying Su, Wenhao Wang, Zhigang Li*, Qinghua Wu

School of Electric Power Engineering, South China University of Technology, Guangzhou 510640, Guangdong Province, China

* Corresponding author: Zhigang Li, lizg16@scut.edu.cn

Abstract: With the maturity of hydrogen storage technologies, hydrogen-electricity coupling energy storage in green electricity and green hydrogen modes is an ideal energy system. The construction of hydrogen-electricity coupling energy storage systems (HECESSs) is one of the important technological pathways for energy supply and deep decarbonization. In a HECESS, hydrogen storage can maintain the energy balance between supply and demand and increase the utilization efficiency of energy. However, its scenario models in power system establishment and the corresponding solution methods still need to be studied in depth. For accelerating the construction of HECESSs, firstly, this paper describes the current applications of hydrogen storage technologies from three aspects: hydrogen production, hydrogen power generation, and hydrogen storage. Secondly, based on the complementary synergistic mechanism of hydrogen energy and electric energy, the structure of the HECESS and its operation mode are described. To study the engineering applications of HECESSs more deeply, the recent progress of HECESS application at the source, grid, and load sides is reviewed. For the application of the models of hydrogen storage at the source/grid/load side, the selection of the solution method will affect the optimal solution of the model and solution efficiency. As solving complex multi-energy coupling models using traditional optimization methods is difficult, the paper therefore explored the advantages of deep reinforcement learning (DRL) algorithms and their applications in HECESSs. Finally, the technical application in the construction of new power systems supported by HECESSs is prospected. The study aims to provide a reference for the research on hydrogen storage in power systems.

Keywords: hydrogen storage; power systems; deep reinforcement learning; application scenarios