第 52 卷 第 7 期：3109-3122 高电压技术 Vol.52, No.7: 3109-3122
2026 年 7 月 31 日 High Voltage Engineering July 31, 2026
DOI: 10.13336/j.1003-6520.hve.20260456

从辅助优化到自适应控制：人工智能赋能并网变流器的研究进展与展望

李　明[1]，刘明昊[1]，陈　劲[1]，项智宏[1]，罗尧杰[1]，张舰航[1]，张　兴[1]，耿　华[2]，何秀强[2]，杨　耕[2]

（1. 可再生能源接入电网技术国家地方联合工程实验室(合肥工业大学)，合肥 230009；
2. 清华大学自动化系，北京 100084）

摘　要：随着可再生能源的大规模并网，电力电子变流器作为能量转换与并网接口的核心设备，正面临着前所未有的技术挑战。传统基于精确数学模型和线性化假设的控制策略，在应对现代电力电子系统高度非线性、强耦合、多时间尺度动态以及复杂运行不确定性时，其有效性与鲁棒性受到显著制约。近年来，人工智能(artificial intelligence, AI)技术凭借其强大的非线性映射能力、自适应学习特性与全局优化决策优势，为突破传统控制理论的固有局限、解决变流器复杂工况下的控制难题带来了革命性的新思路。该文首先对电力电子领域主流的人工智能算法进行系统性简述，明确其技术原理与适用边界。随后，从设计优化、闭环控制与自主推理 3 个递进维度，全面梳理人工智能技术在并网变流器领域的研究进展与应用实践。在优化层面，深入分析 AI 在变流器拓扑智能推演、高精度数据驱动建模、控制器参数自适应整定以及多目标多约束协同优化中的核心作用；在控制层面，系统讨论其在微电网能量管理与功率控制、电网电压频率主动支撑、电能质量精细化治理以及大规模多变流器集群协同控制中的应用成效；在推理层面，阐述 AI 如何通过多源异构数据融合实现全工况环境感知，并基于感知结果完成控制策略的自主选择与动态调整。最后，针对当前 AI 技术在电力电子工程化应用中面临的可解释性、实时性、安全性与泛化性等关键挑战进行深入剖析，并对未来发展趋势进行前瞻性展望，以期为该领域的后续研究与工程实践提供有价值的参考。

关键词：人工智能；并网变流器；数据驱动控制；深度学习；强化学习；参数优化；新型电力系统

From Auxiliary Optimization to Adaptive Control: Research Progress and Prospects of AI-empowered Grid-connected Converters

LI Ming[1], LIU Minghao[1], CHEN Jin[1], XIANG Zhihong[1], LUO Yaojie[1], ZHANG Jianhang[1], ZHANG Xing[1], GENG Hua[2], HE Xiuqiang[2], YANG Geng[2]

(1. National and Local Joint Engineering Laboratory for Renewable Energy Access to Grid Technology(Hefei University of Technology), Hefei 230009, China;
2. Department of Automation, Tsinghua University, Beijing 100084, China)

Abstract: With the large-scale integration of renewable energy sources, power electronic converters, as the core equipment for energy conversion and grid connection, are facing unprecedented technical challenges. Traditional control strategies based on precise mathematical models and linearization assumptions exhibit significantly limited effectiveness and robustness when dealing with modern power electronic systems characterized by high nonlinearity, strong coupling, multiple time-scale dynamics, and complex operational uncertainties. In recent years, artificial intelligence (AI) technology, leveraging its powerful nonlinear mapping capability, adaptive learning characteristics, and global optimization decision-making advantages, has brought revolutionary new ideas to break through the inherent limitations of traditional control theory and solve the control problems of converters under complex operating conditions. This paper first system-

基金资助项目：国家自然科学基金(52577189；U24B2085；U23A20655)；台达电力电子科教发展计划(弱联网下基于多模型融合的并网变流器控制及其协同趋优策略研究)(DREK2025003)。
Project supported by National Natural Science Foundation of China (52577189, U24B2085, U23A20655), Delta Power Electronics Science and Technology Educational Development Program of Delta Group (Research on Multi-model Fusion-based Grid-connected Converter Control and Cooperative Optimization Strategies Under Weak Grid Conditions)(DREK2025003).

atically summarizes the mainstream AI algorithms in the field of power electronics, clarifying their technical principles and applicable boundaries. Subsequently, the research progress and application practices of AI technology in grid-connected converters are comprehensively reviewed from three progressive dimensions, namely,design optimization, closed-loop control, and autonomous reasoning. At the optimization level, the core roles of AI in intelligent topology deduction, high-precision data-driven modeling, adaptive controller parameter tuning, and multi-objective multi-constraint collaborative optimization are deeply analyzed. At the control level, its application effects in microgrid energy management and power control, active grid voltage and frequency support, refined power quality governance, and coordinated control of large-scale multi-converter clusters are systematically discussed. At the reasoning level, this paper elaborates how AI realizes environmental perception in full-operating-condition through multi-source heterogeneous data fusion, and completes autonomous selection and dynamic adjustment of control strategies based on perception results. Finally, the key challenges faced by current AI technology in the engineering application of power electronics, such as interpretability, real-time performance, safety, and generalization, are deeply analyzed. Moreover, forward-looking prospects in future development trends are presented, aiming to provide valuable references for subsequent research and engineering practice in this field.

Key words：artificial intelligence (AI); grid-connected converter; data-driven control; deep learning (DL); reinforcement learning (RL); parameter optimization; new power system

0 引言

能源结构的深刻变革是 21 世纪全球发展的核心议题之一。以风能、太阳能为代表的分布式可再生能源(distributed renewable energy sources, DRES)正以前所未有的速度渗透到电力系统中[1-2]。这些能源本质上通过电力电子变流器接口接入电网，使得现代电网正从一个以同步发电机为主导的“集中式发电系统”,快速演变为一个以电力电子变流器为核心枢纽的“分布式发电系统”[3]。据国际能源署(international energy agency, IEA)预测，到 2030 年，全球新增发电装机容量中将有超过 80%来自可再生能源，而这些能源几乎全部依赖变流器实现并网。

这一根本性转变给变流器控制带来了全新的、复杂的挑战。首先，系统动态特性发生了本质性变化。同步发电机凭借其巨大的转动惯量和天然的电压/频率调节能力，为传统电网提供了稳定的惯性支撑与阻尼特性。而变流器作为即插即用的静态电力电子设备，缺乏内在的机械惯性[4]，其动态响应完全依赖于外加的数字控制算法，导致系统整体惯量水平大幅下降，抗扰动能力显著减弱，宽频振荡风险凸显。其次，运行工况呈现高度不确定性与强时变性。可再生能源出力具有天然的间歇性和波动性，负荷需求也呈现出显著的时空随机性，这使得变流器需要在宽范围、快变的运行工况下保持稳定高效运行[5-7]。再次，控制目标日益多元化且存在内在冲突。现代变流器不仅要保证基本的电能质量(如电压稳定、频率稳定和谐波抑制)，还需主动参与电网的辅助服务(如一次调频、无功支撑、虚拟惯量提供)、实现经济最优的能量调度，并确保自身设备的安全可靠运行。这些目标之间往往存在强耦合甚至相互冲突，难以通过单一的传统控制器同时满足[8-10]。

传统的变流器控制方法，如 PI 控制、状态反馈控制、滑模控制和模型预测控制(model predictive control, MPC)等，虽然在工况稳定、模型精确的条件下能够表现出良好的控制性能，但在面对上述新型电力系统的复杂挑战时，普遍暴露出以下固有局限性：(1)对精确数学模型的高度依赖。当系统参数发生漂移、电网阻抗变化或模型存在失配时，控制性能会显著下降，甚至引发系统失稳；(2)鲁棒性与动态性能难以兼顾。为保证系统稳定性，控制器往往需要进行保守设计，这不可避免地牺牲了部分动态响应性能；(3)在线计算负担沉重。特别是 MPC 等先进控制策略，其滚动优化过程计算量大，难以在低成本嵌入式平台上实现微秒级的实时控制；(4)缺乏自适应与自学习能力。控制器一旦部署完成，其参数和结构通常是固定的，无法根据运行环境的变化进行自主进化与调整。

在此背景下，人工智能技术的引入为解决上述传统控制难题提供了强有力的工具。目前在电力电子领域中，常用的 AI 算法主要包括深度学习(deep learning, DL)、强化学习(reinforcement learning, RL)等。这些方法能够通过数据驱动的方式自主学习系统的运行规律，从而在复杂非线性系统中实现高效地决策与控制[11]。目前，AI 技术已经在新能源功率预测、电力系统负荷预测等领域得到了广泛应用并

取得了显著成效[12-13]。本文从优化、控制与推理 3 个维度系统梳理 AI 在变流器控制领域的应用与研究进展，并通过实际案例分析展示 AI 在解决复杂问题方面的应用优势。同时，深入讨论 AI 技术在电力电子应用中面临的关键挑战。最后，展望了未来 AI 在变流器控制与分析应用的发展趋势。

1　人工智能算法简述

在深入探讨 AI 应用于变流器控制的具体应用之前，有必要对常用的 AI 算法进行简要梳理。本章旨在为非 AI 专业背景的电力电子工程师提供一个清晰的技术概览，重点介绍在该领域研究与实践中最为活跃和有效的几类 AI 方法，包括深度学习、强化学习和深度强化学习的基本原理、典型模型及其适用场景。

1.1　深度学习基础

深度学习[14](DL)是一类以人工神经网络(artificial neural network, ANN)为核心的机器学习方法[15]，其基本思想是通过构建多层非线性映射结构，从海量数据中自动学习输入与输出之间的复杂函数关系。神经网络由大量相互连接的“神经元”节点构成，每个神经元对输入信号进行加权求和并通过非线性激活函数产生输出，通过多层堆叠形成对复杂系统特征的强大表达能力。通过最小化预设的损失函数并利用反向传播算法进行梯度下降优化，网络参数可在训练过程中不断调整，使模型逐步逼近目标函数关系。人工神经网络的基本结构如图 1 所示。

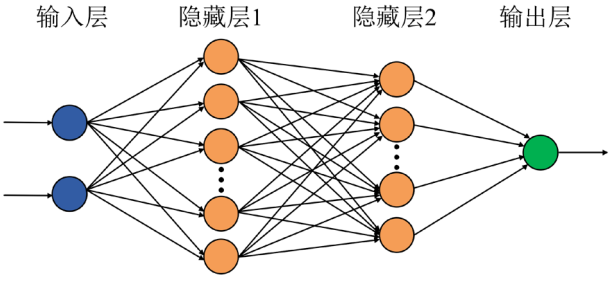


图 1　人工神经网络结构

Fig.1　Structure of artificial neural network

深度学习对系统精确数学模型依赖较小，具有鲁棒性好、参数依赖性低、动态性能优异、适应性强以及对复杂非线性关系的通用逼近等显著优势。在电力电子领域，典型的深度学习模型主要包括 BP 神经网络[16](back propagation neural network, BPNN)、卷积神经网络[17-18](convolutional neural network, CNN)以及循环神经网络[19](recurrent neural network, RNN)等。BP 神经网络作为最基础的前馈神经网络，通过反向传播算法实现参数更新，广泛应用于系统建模、参数拟合与故障诊断；CNN 利用局部连接与权值共享机制能够高效提取空间特征，在图像处理、模式识别与故障特征提取等领域得到广泛应用；RNN 及其改进结构长短期记忆网络[20](long short-term memory, LSTM)则能够有效捕捉具有时间依赖性的序列数据特征，适用于时间序列预测、阻抗辨识与动态过程建模等问题。总体而言，深度学习适用于模式识别、函数逼近、系统建模以及复杂非线性关系学习等问题。然而，这类方法通常依赖一定规模的高质量数据集进行离线学习与训练，其知识获取主要集中在训练阶段，因此在在线持续学习与实时自适应能力方面仍存在一定局限性。

1.2　强化学习基础

强化学习(RL)是一种通过智能体与环境交互并依赖试错机制学习最优决策策略的机器学习方法[21-22]。与深度学习的监督学习范式不同，强化学习不需要预先标注的训练数据，而是通过智能体在环境中执行动作、获得奖励反馈，并根据奖励信号调整自身策略，最终实现累积奖励最大化的目标。RL 问题通常被建模为马尔可夫决策过程(Markov decision process, MDP)[23-24]，包含状态(State)、动作(Action)、奖励(Reward)、状态转移概率(Transition probability)和折扣因子 γ 5 个要素。图 2 展示了典型 MDP 中环境与智能体交互的基本框架。

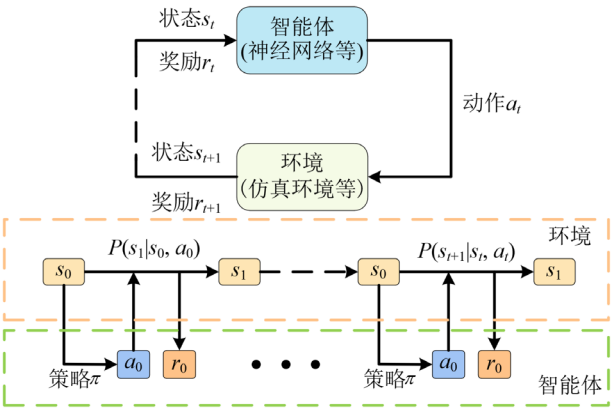


图 2　MDP 框架

Fig.2　MDP framework

在时刻 t，智能体获取当前环境状态 s_t，并根据自身策略 π 生成动作 a_t。在下一个时刻 $t+1$，环

境根据智能体执行的动作 a_t 提供即时奖励值 r_{t+1}，并转移到新状态 s_{t+1}。智能体根据接收到的奖励值 r_{t+1} 来调整策略 π。通常 MDP 问题的目标是获得最大长期累积奖励 R_t，如式(1)所示。

$$R_t = r_{t+1} + \gamma r_{t+2} + \gamma^2 r_{t+3} + \cdots = \sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \tag{1}$$

为评估不同状态或动作在长期决策过程中的优劣，引入状态价值函数 $V_\pi(s)$ 与动作价值函数 $Q_\pi(s,a)$，用于刻画在给定策略 π 下的期望累计回报，如式(2)所示。

$$\begin{cases} V_\pi(s) = E\left(r_{t+1} + \gamma V_\pi(s_{t+1}) \middle| s_t = s\right) \\ Q_\pi(s,a) = E\left(r_{t+1} + \gamma Q_\pi(s_{t+1}, a_{t+1}) \middle| s_t = s, a_t = a\right) \end{cases} \tag{2}$$

式中：E 是期望算子，代表对数据取平均。

在电力电子领域，由于控制问题通常具有连续的状态空间与动作空间，强化学习方法多以深度强化学习(deep reinforcement learning, DRL)为主。它利用深度神经网络(deep neural networks, DNN)强大的函数逼近和特征提取能力，来解决经典强化学习中难以处理的高维状态空间和连续动作空间等问题[25-26]。

目前在电力电子控制中应用最为广泛的深度强化学习算法主要包括深度 Q 网络(deep Q network, DQN)、近端策略优化(proximal policy optimization, PPO)、深度确定性策略梯度[27](deep deterministic policy gradient, DDPG)以及多智能体强化学习(multi-agent reinforcement learning, MARL)等。其中，DQN 通过 DNN 对状态–动作价值函数进行逼近，使强化学习能够处理高维状态空间问题；PPO 通过限制策略更新幅度显著提高了训练稳定性与收敛效率，在连续控制与复杂决策问题中具有良好的鲁棒性；DDPG 则结合 DNN 与确定性策略梯度方法，能够高效处理连续动作空间控制问题，在控制参数优化、电压电流调节等场景中得到了广泛应用[28]；MARL 研究如何使多个智能体协同学习以达成共同或各自的目标[29]，例如，MARL 在多变流器协同场景下通过分布式学习达成全局电压支撑、功率优化分配等协同目标[30]。

RL 具有自学习能力强、适应性好以及能够处理复杂决策优化问题等优势。然而，该类方法通常需要大量环境交互数据进行训练，且算法性能在较大程度上依赖于奖励函数的精心设计，因此在实际应用中仍需结合具体电力电子问题进行针对性优化。

2 基于人工智能的变流器系统优化

变流器的整体性能在很大程度上取决于其硬件拓扑结构、关键电路参数以及控制策略的合理设计与优化。传统设计方法主要依赖工程师的经验积累与反复的仿真迭代，在复杂且高维的设计空间中不仅设计效率低下，而且难以获得全局最优解。AI 技术的发展为解决上述问题提供了全新的思路。本章重点从拓扑设计与控制建模优化、控制器参数自适应整定以及多目标协同优化等 3 个方面，系统探讨人工智能在电力电子系统优化中的应用进展。

2.1 拓扑设计与控制建模优化

在电力电子电路的设计与控制中，精确的系统建模是实现高性能控制的基础。然而，随着变流器拓扑日益复杂、运行工况不断拓展，传统基于物理机理的建模方法面临着建模难度大、精度不足、难以处理非线性与不确定性等挑战。

针对 LCL 型并网逆变器中 LCL 滤波器对电网阻抗波动高度敏感、存在难以处理的高阶建模动态及谐振抑制难题，早期研究尝试将递归神经网络(RNN)[31-32]与人工神经网络(ANN)[33]引入控制建模环节。这些研究利用自适应动态规划(adaptive dynamic programming, ADP)算法训练 AI 模型，直接建立系统状态与最优控制动作之间的映射关系，实现了无阻尼、无解耦设计的数据驱动控制，有效提升了弱电网下系统的稳定性与鲁棒性。

针对 DC-DC 变换器对负载工况敏感且非线性特征明显的建模与控制难题，归一化优势函数(normalized advantage function, NAF)与 DQN 算法被相继应用于 Buck 变换器，实现了无模型的电压调节与实时控制[34-35]。针对 Buck-Boost 变换器中右半平面零点导致的非最小相位特性及主动负载不稳定性问题，数据驱动模型预测控制(data-driven model predictive control, DDMPC)方法被提出，通过数据驱动的预测模型替代传统解析模型，提升了系统在复杂工况下的控制性能[36]。为进一步实现连续动作空间的高精度控制，深度确定性策略梯度(DDPG)与双延迟深度确定性策略梯度(twin delayed deep deterministic policy gradient, TD3)算法被引入，通过引入双评论家机制有效克服了 Q 值过估计问题，显著提升了变换器在负载突变与参考电压阶跃下的动态响应速度与稳态抗干扰能力[37-38]。

在变流器拓扑创新方面，深度 Q 网络(DQN)被

创新性地引入非隔离单电感多端口变流器的拓扑自动推导过程。该方法将电路组件的连接方式定义为智能体的动作空间，使智能体在与环境的试错交互中自主积累拓扑设计经验。该方法无需人工干预即可根据预设的性能奖励自动锁定最优拓扑结构，实现了从设计规格到硬件结构的端到端智能推演[39]。图 3 展示了 DQN 算法的逻辑框架。

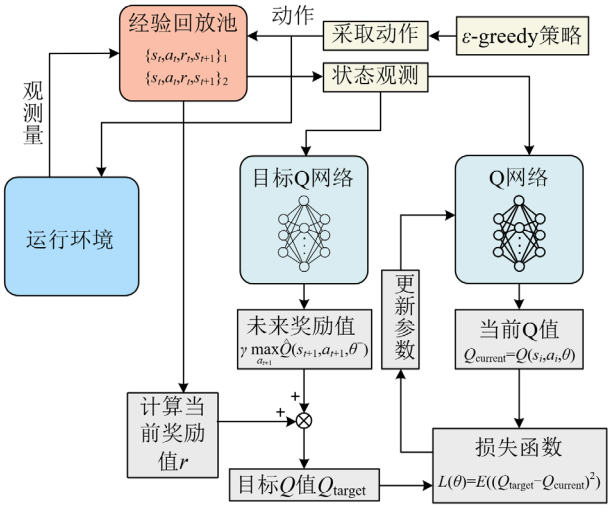


图 3　DQN 算法逻辑框架

Fig.3　Logical framework of the DQN algorithm

在并网逆变器的建模与控制优化方面，自适应动态规划(ADP)算法被应用于有限控制集模型预测控制(finite control-set model predictive control, FCS-MPC)，分别实现了强鲁棒性、低计算负荷的智能预测模型和抗扰动、自适应的控制模型[40-41]。

针对传统物理模型无法精准描述逆变器极短时间内非线性动态行为的难题，基于波形测量单元(waveform measurement units, WMU)高频数据的数据驱动建模框架被提出。该框架通过结合模态分析与时间序列回归等数据驱动建模方法，从真实的高频波形数据中自动提取并构建逆变器的暂态特征模型，有效解决了逆变器亚周期动态建模难题[42]。

针对有源配电网中大量分布式电源接入导致的系统动态复杂、难以精确建模的问题，基于无监督学习的动态建模框架被提出。该方法通过 3 阶段数据处理流程，从海量实测数据中自动剔除干扰项，并利用 K 均值聚类算法(K-means clustering, K-Means)将复杂的系统动态划分为有限的典型运行群组。这种方法将原本难以解析的复杂配电网拓扑简化为多个精确的非线性代理模型，在大幅降低计算维度的同时，确保了电力电子化配电网在不同运行工况下的仿真精度与控制有效性[43]。

2.2　控制器参数自适应整定

控制器参数的合理整定是保证变流器控制性能的关键环节。传统的参数整定方法如 Ziegler-Nichols 法、临界比例度法等，主要依赖工程师的工程经验，且整定出的参数通常仅适用于特定的运行工况，当系统工况发生变化时，控制性能会显著下降。目前，基于强化学习的在线参数整定方法成为该领域的研究热点。该类方法将控制器参数视为智能体的动作空间，并以系统的动态与稳态性能指标(如超调量、调节时间、稳态误差)及鲁棒性指标构建奖励函数。通过与变流器环境的持续交互，智能体能够在数据驱动的框架下不断更新自身策略，从而逐步学习到最优的参数调整策略。与传统依赖工程经验或固定整定规则的方法相比，强化学习能够在更广阔的参数空间内进行自适应探索与优化，有效减少了人工调试过程中的主观性和局限性。特别是在多变量、强非线性或模型不精确的复杂电力电子系统中，该方法能够根据系统运行状态实现在线学习与动态调整，从而显著提升控制系统的综合性能。

一些学者利用深度强化学习算法(如 DDPG、PPO)直接对变换器的硬件设计参数或控制量进行端到端的自动化寻优，以实现系统效率最大化或动态响应性能的最优。例如，将 DDPG 算法应用于有源中点钳位逆变器的参数设计，该方法以运行工况为状态输入，通过 DRL 智能体与效率模型的持续交互，实现了开关频率等关键参数在连续空间内的自动寻优，有效提升了逆变器的运行效率[44]。采用 PPO 算法建立变流器状态与最优控制动作之间的映射关系，实现了负载波动下控制策略的实时优化，显著提升了系统的动态响应速度[45]。

为了在多变工况下同时兼顾稳态精度与动态性能，一系列基于混合增强与策略优化的方法被相继提出。基于混合专家系统(mixture of experts, MoE)的在线自适应控制方法被提出，该方法利用多个神经网络分别捕捉反馈控制与 MPC 在不同工况下的特征优势，通过门控网络动态融合不同控制器的输出，实现了复杂工况下 DC-DC 变流器稳态精度与动态鲁棒性的协同提升[46]。

随着应用场景从单一变流器拓展至复杂的电网环境，基于数据驱动的多参数协同整定策略成为研究重点。利用 LSTM 与 ANN 融合模型提取电流

特征，实现了弱电网下跟网型逆变器电流环与锁相环增益的实时重构，有效提升了系统在弱电网下的稳定性[47]。构建基于 PPO 算法的控制增益优化框架，将级联 PI 控制器的所有增益参数转化为动作网络的输出，有效提升了组网型及跟网型逆变器在次同步振荡等暂态工况下的阻尼特性与稳定性[48]。

为了解决 DRL 在实际微电网部署中训练效率低和仿真-实测环境不匹配的问题，基于迁移学习的控制知识跨场景复用方法被提出。其核心思想是通过在高保真仿真平台或一个“源”变流器上训练得到的 AI 调参模型，利用迁移学习技术，快速适配到新的“目标”变流器上，并利用域自适应机制消除源环境与目标环境之间的差异影响，从而大幅减少现场调试时间和成本。针对直流微电网中恒功率负载引起的电压失稳难题，以微电网运行状态作为输入，利用双深度 Q 网络(double deep Q-network, DDQN)算法、迁移学习技术和域自适应机制捕捉源环境与目标环境间的特征映射，实现了控制策略在不同拓扑参数下的快速迁移与自适应整定，在显著提升电压稳定性的同时，增强了 AI 控制器在未知工况下的泛化能力[49]。

2.3 多目标协同优化

随着应用场景的不断复杂化和性能要求的持续提升，现代变流器的设计逐渐呈现出多目标优化的发展趋势。在实际工程中，变流器不仅需要满足高效率和高功率密度等核心性能指标，还需兼顾功率因数、电磁兼容、制造成本以及运行可靠性等多方面要求。因此，变流器设计本质上可以视为一个典型的多目标优化问题，各性能指标之间往往存在一定的权衡关系，难以同时达到最优。针对这一特点，人工智能技术，尤其是多目标协同训练(multi-objective collaborative training, MOCT)为复杂多目标设计问题提供了有效的求解工具。

针对三相三电平 NPC 逆变器在 MPC 中难以兼顾多种控制目标的难题，基于紧凑格式动态线性化(compact form dynamic linearization, CFDL)的数据驱动控制方法被提出。该方法将 MPC 中的权重因子作为输入，将开关频率与中性点电压波动作为目标输出，通过构建系统动态等效数据模型，实时解耦并在线整定多个约束目标，有效提升了复杂拓扑变流器在多约束工况下的综合运行性能[50]。针对风电功率预测中数值天气预报(numerical weather prediction, NWP)数据偏差和两步法导致的误差累积问题，基于 MOCT 的隐式修正算法被提出。该方案通过 AI 建立从设计变量(如电感值、电容值)到性能表现(如可靠性、成本)的直接映射模型，实现了整体预测精度与局部波动跟踪之间的参数协同优化[51]。如表 1 所示，对本章节所用文献进行了汇总。

表 1 AI 在优化领域应用的文献汇总

Table 1 Summary of literature on AI applications in optimization

领域	算法	文献	解决问题
LCL 滤波器	RNN、ANN	[31-33]	谐振和强耦合问题
DC-DC 变换器	NAF、DQN、DDMPC、DDPG、TD3	[34-39]	Buck 变换器带恒功率负载的系统稳定性与建模、有源负载下的非线性失稳、负载变化敏感
并网逆变器	ADP、Actor-Critic	[40-42]	高频暂态响应、模型参数失配、传统 FCS-MPC 开关频率过高
有源配电网	K-Means	[43]	物理建模困难
离线参数寻优	LSTM	[47]	离线寻找最优 PI 参数
在线参数寻优	DDPG、PPO、MoE	[44-46, 48]	PI/PID 参数寻优、将硬件参数设计转化为参数寻优问题、次同步振荡
跨域/复杂环境参数寻优	DDQN	[49]	训练环境与实际运行环境参数不匹配
多目标协同	CFDL	[50]	对系统精确参数的依赖
	MOCT	[51]	NWP 数据偏差和两步法导致的误差

3 基于人工智能的变流器闭环控制

AI 在变流器领域的应用已从早期的离线设计优化逐步走向在线闭环控制，通过与传统控制策略的深度融合，形成了“模型+数据”的混合控制架构，在能量管理、电压频率支撑、电能质量治理与多机协同控制等方面取得了重要进展。

3.1 能量管理与功率控制

在孤岛或并网模式下的微电网中，变流器是连接分布式电源、储能系统和负荷的关键接口节点。在这一应用场景中，AI 技术起到了能量管理专家的作用，通过对分布式电源出力、负荷需求以及电网状态的智能感知与预测，为各个变流器节点提供最优的运行基准指令，实现微电网的经济高效运行。

例如，基于多任务学习与多门控混合专家模型(multi-gate mixture-of-experts, MMoE)框架的在线功率预测方法被提出，该方法采用神经网络建立时空特征与多个风电场出力之间的映射关系，作为一个高精度的信息感知代理，能够在风速波动与时空耦合的复杂环境下实时预测风电集群的动态出力，从

而为电力系统的经济调度与备用容量安排提供精准的决策支撑[52]。MMoE 算法的逻辑框架如图 4 所示。

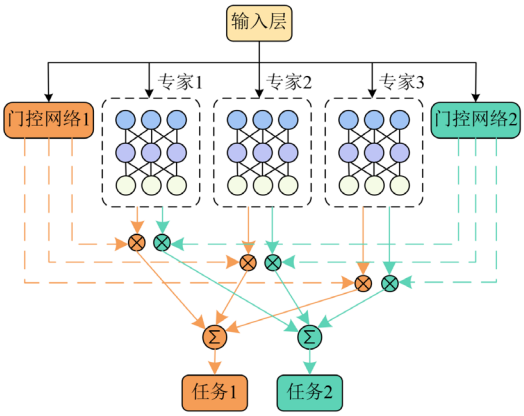


图 4　MMoE 算法逻辑框架

Fig.4　Logical framework of the MMoE algorithm

基于在线强化学习的微电网能量管理策略被提出，采用时序差分强化学习算法(state-action-reward-state-action, SARSA)建立微电网多源状态与最优功率分配动作之间的关系，作为一个智能化的能量管理代理，能够在可再生能源出力高度波动的环境下实时优化储能充放电计划与分布式能源出力，显著提升了微电网的计划跟踪精度与运行经济性[53]。针对风光制氢系统的能量管理问题，基于状态识别的能量管理优化策略被提出。该方案利用改进强度帕累托进化算法(strength Pareto evolutionary algorithm 2, SPEA2)与遗传算法(genetic algorithm, GA)相结合的智能优化框架，在上层实时感知电解槽的运行工况(启动、待机、运行)，并据此协同优化风光吸纳率与系统整体收益，从而优化前端并网变流器集群的功率控制策略[54]。

在光伏并网系统中，并网变流器不仅承担着并网控制任务，还需要通过最大功率点跟踪(maximum power point tracking, MPPT)实现光伏阵列的最大功率提取，并通过功率控制实现并网功率的稳定输出。早期的 MPPT 研究将遗传算法(GA)和粒子群算法(PSO)整合到 MPPT 控制中，通过牺牲一定的计算复杂度，换取了在复杂光照条件下更高的能量转换效率和系统稳定性[55-56]。为了进一步平衡寻优精度与动态响应速度，强化学习逐渐成为 MPPT 领域的研究热点，Q 学习(Q-learning, QL)算法被广泛应用于光伏系统的 MPPT 控制。其中，有研究侧重于算法的通用性，通过在电压和电流基础上引入反映工作点位置的辅助状态变量，并设计 $2n-1$ 种占空比动作幅值以及基于功率导数的奖励函数，有效提升了最大功率点的跟踪速度并消除了稳态振荡[57]；也有研究针对复杂环境下的控制稳定性，利用玻耳兹曼探索策略和时变学习率参数优化 QL 算法，显著提升了光伏系统在负载扰动及局部遮阴条件下的发电效率与动态响应性能[58]。

3.2　电压与频率调控

随着现代电力系统逐渐由传统的同步发电机主导结构向以电力电子变流器为核心的电力电子化系统演变，系统惯量与阻尼水平大幅降低，电压与频率稳定问题成为保障电力系统安全稳定运行的关键问题之一。传统控制方法在动态性能、自适应能力以及多变流器协同控制方面逐渐暴露出一定局限。AI 凭借其强大的数据学习与非线性建模能力，使得将 AI 引入电压与频率调控领域成为一个重要的研究方向。

在频率调控方面，AI 常被用于优化虚拟同步机(virtual synchronous generator, VSG)的控制参数，主要通过调节有功-频率控制环路的动力学特性来维持系统频率稳定。例如，针对 VSG 在并网及多机系统中引发的低频振荡问题，基于 DDPG 算法的自适应转动惯量与阻尼匹配控制方法被提出，该方法能够根据系统频率偏差实时调整 VSG 的惯量与阻尼参数，有效抑制了微电网在功率波动下的低频振荡现象[59]。基于物理模型引导的 DDQN 频率控制方法被提出，利用 DDQN 的端到端学习能力赋予控制参数动态演化特性，并引入神经网络重构与迁移学习机制，实现了从单机频率控制到多机功率均衡的平滑扩展[60]。利用 QL 算法在线监测系统频率偏差并实时计算微电网功率缺额，结合拉格朗日乘子法实现了多台光储设备间发电成本最小化的功率动态分配，完成了微电网频率的二次协调控制[61]。此外，基于模糊逻辑控制(fuzzy logic control, FLC)的动态下垂频率控制方法被提出，利用 FLC 算法赋予下垂系数随风机预留功率及频率变化率动态变化的特性，并引入备用功率评估机制，实现了在不同风速工况下频率调节压力的自适应分配，在不依赖固定下垂曲线的前提下显著提升了含高比例风电系统的一次频率稳定性[62]。

在电压调控方面，主要是通过优化无功-电压控制环路的响应特性来保障系统电压的稳定。例如，针对高比例光伏接入的配电网电压控制难题，基于多智能体软行动家-评论家算法(multi-agent soft ac-

tor-critic, MASAC)的去中心化控制框架被提出。通过 MASAC 算法使各逆变器智能体在仅依赖局部感知和有限通信的条件下，实现对有功与无功出力的协同调度。相较于传统的集中式控制方法，该方案显著提升了电压调节的精度与响应速度[63]。物理信息神经网络(physics-informed neural networks, PINN)算法被引入变流器电压控制，由于电压源型变流器的开关状态与输出电压之间的关系直接受基尔霍夫微分方程控制，可以通过 PINN 将物理控制方程整合到神经网络的训练过程中，在使用最少训练数据的同时实现高控制精度。该方法有效解决了在不同有功/无功设定点和电网电压变化下的非线性控制问题，确保了变流器在低电压穿越等极端工况下的可靠运行[64]。基于数据驱动与传统虚拟同步机(VSG)相结合的电压调节方法被提出，利用 TD3 算法赋予逆变器控制环路动态调整电压参考值的能力，并引入多目标奖励函数机制，实现了在维持输出电压处于安全边界的同时最小化各单元间的无功功率分配误差，在不依赖精确线路阻抗信息的前提下显著提升了孤岛微电网的电能质量与运行稳定性[65]。

3.3 电能质量与多变流器协同控制

在电力电子系统中，变流器数量不断增加，系统结构日趋复杂，电能质量问题与多变流器之间的交互耦合问题逐渐成为电力电子并网系统中的关键研究问题。

在电能质量治理中，谐波抑制是最为核心的问题之一。将 BP 神经网络与传统 PI 或 PID 控制深度融合的策略被广泛研究，其中有研究采用 BP 神经网络学习零序环流误差与 PI 控制参数之间的映射关系，实现了 PI 参数的在线自适应调整[66]；也有研究采用 PSO 算法优化的 BP 神经网络来调整 PID 控制参数，均能够在电网电压突变或负载波动时实时调整控制参数，显著增强了零序环流和谐波抑制能力[67]。BP 神经网络控制结构如图 5 所示。

基于 DDPG 算法的变流器谐波优化控制方案被相继提出，一种方案将 DDPG 用于直接产生逆变器的 PWM 控制信号以替代传统 PID 控制器，另一种方案则将 DDPG 用于在连续空间内选择改进选择性谐波消除调制(improved selected harmonic elimination, iSHE)所需的最优开关角。两种方案均有效降低了输出电流的谐波失真度，并显著增强了系统对动态工况的适应能力[68-69]。DDPG 变流器控制架构如图 6 所示。此外，QL 算法被用于优化选择性谐波电流抑制脉宽调制(selective harmonic current mitigation-PWM, SHCM-PWM)的触发角，通过智能选择开关状态来满足严格的电网电流谐波标准[70]。

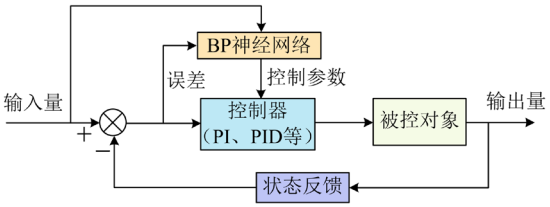


图 5 BP 神经网络控制结构

Fig.5 Control structure of the BP neural network

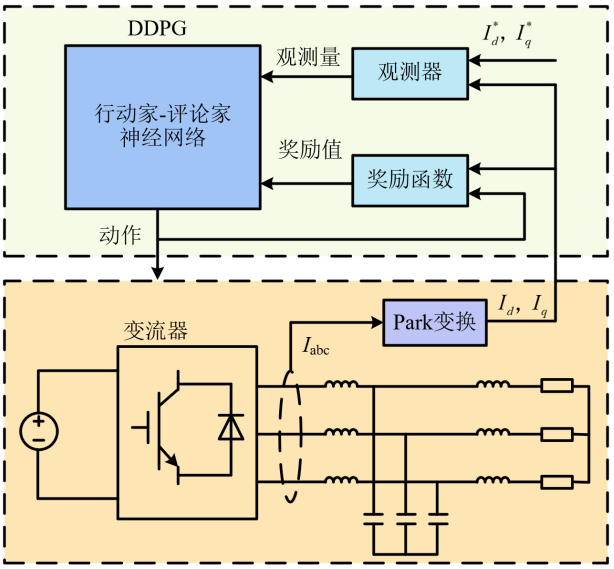


图 6 DDPG 变流器控制结构

Fig.6 Control structure of DDPG-based converter

当多个变流器通过公共母线互联时，它们之间的动态交互可能会相互产生负面影响，甚至引发系统振荡，因此多变流器协同控制是一个亟待解决的关键问题。针对交直流混合配电网中多电力电子接口交互耦合导致的电压越限与低频振荡难题，基于 DDPG 算法的广域阻尼协同控制框架被提出。该方案构建了具备有界探索特性的智能化代理，能够实时感知多机系统的动态响应信号，在无需预知系统精确物理模型与参数的前提下，自主生成多类阻尼控制器的协调指令，显著提升了跨区互联电网对低频振荡的抑制效果与运行稳定性[71]。

针对含有高比例光伏接入的配电网电压越限与波动问题，基于 DQN 算法的逆变器无功功率与电压协调控制方法被提出。通过训练智能体实时优化多台光伏逆变器的无功输出，有效维持了系统电压在安全范围内，降低了网络损耗并增强了对随机

性负载和光照波动的适应能力。仿真验证表明，该方法相比于传统的自适应下垂控制具有更快的响应速度和更高的稳态精度，能够实现复杂配电网络下的分散式电压优化管理[72]。对本章节所用文献总结如表 2 所示。

表 2　AI 在控制领域应用的文献汇总

Table 2　Summary of literature on AI applications in control

领域	算法	文献	解决问题
能量管理	MMoE、SARSA、SPEA2+GA	[52-54]	同步功率预测、能量调度、功率分配
MPPT	GA、PSO	[55-56]	复杂工况适应、控制参数优化、多目标控制
	QL	[57-58]	MPPT“通用性”问题、局部遮阴导致的“多峰值”问题
频率调控	DDPG、DDQN、QL、FLC	[59-62]	功率震荡、孤岛频率稳定、二次调频、一次调频支撑
电压调控	MASAC、PINN、TD3	[63-65]	多设备协调电压控制、低电压穿越、无功功率分配
谐波	BP	[66-67]	多逆变器 3 次谐波环流、谐振现象以及电网电压突变
	DDPG	[68-69]	谐波失真、开关角优化
	QL	[70]	兼顾高效率与低谐波
多变流器	DDPG	[71]	多种设备的低频振荡
	DQN	[72]	多逆变器无功/电压控制

4　基于人工智能的状态感知与自主推理

AI 技术的发展正深刻改变着变流器的功能定位，使其从传统的被动式电能转换执行单元，逐步演变为具备环境感知、状态理解与自主决策能力的智能体。传统变流器控制依赖精确数学模型与固定参数策略，在弱电网、参数不确定性与多目标冲突等复杂工况下适应性受限。而 AI 技术的引入，通过深度学习等手段，使变流器能够融合多源异构数据(包括高频电气量、温度振动以及通信信息)，构建起对自身状态、电网环境与运行态势的实时感知，并基于感知结果进行自主推理与决策，实现控制策略的自适应调整。

4.1　全工况状态感知

状态感知是变流器实现自适应控制的基础与前提。通过对自身运行状态与外部电网环境的精准感知，变流器能够及时发现潜在的安全隐患，并为后续的控制决策提供可靠依据。

目前，阻抗辨识与稳定性评估是状态感知领域的研究热点，许多学者将 AI 技术引入阻抗辨识中[73-74]。基于数据与物理模型融合驱动的方法被提出，实现了新能源场站宽频阻抗的在线辨识。借由人工神经网络对工况与阻抗特性的强大建模能力，系统能够作为智能代理实时推断宽频阻抗特性并评估系统稳定性，从而显著提升了电力电子化电力系统对宽频振荡风险的感知与预警能力[75]。针对黑箱逆变器难以精确建模的挑战，全数据驱动的阻抗识别与稳定性评测方案被提出。该方案以 AI 算法为核心，建立起测量数据至宽频阻抗的非线性映射桥梁，实现了系统特性的在线重构。这种智能化推理机制有效提升了变流器在多变电网工况下的环境适应性，使其具备了快速识别振荡风险并辅助决策的能力[76]。

在设备健康状态感知方面，基于大数据与深度学习的逆变器温度异常检测方法被提出，采用 CNN 及随机森林算法让 AI 学习环境气象、运行功率与变流器内部温度之间的对应关系，作为一个智能化的健康诊断代理，能够在复杂工况下实时推理设备的运行状态并预警温度异常，从而提升了光伏变流器系统的安全感知能力与预测性维护水平[77]。随机森林算法的基本框架如图 7 所示。

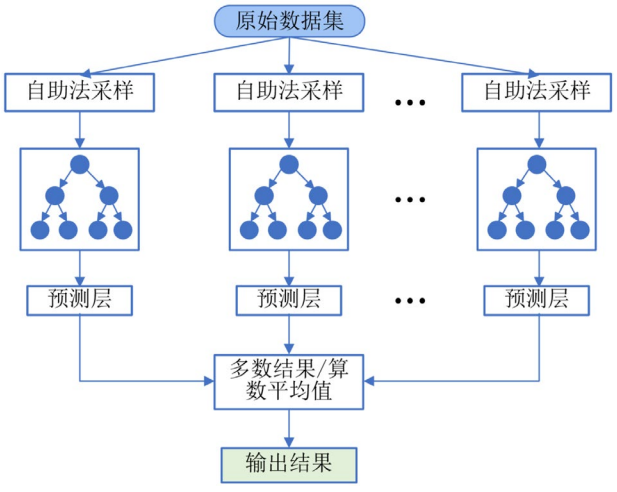


图 7　随机森林算法框架

Fig.7　Framework of the random forest algorithm

在电网运行态势感知方面，基于 DNN 的电网风险态势感知方法被提出，利用深度学习的特征提取能力赋予评估模型对多种环境影响因子的拟合能力，并引入层次分析法(analytic hierarchy process, AHP)确定各风险指标的权重，实现了从态势理解到态势预测的演变，在综合考虑气象与设备状态等多维因素的前提下，显著提升了复杂电网运行风险的辨识精度[78]。

在并网变流器的参数辨识与状态感知领域，纯数据驱动的方法往往受限于训练样本的完备性。针对这一问题，一种基于物理信息机器学习(physics-informed machine learning, PIML)的变流器异常检测方法被提出，旨在利用物理信息约束 AI 以应对零样本挑战。通过将变流器的动态微分方程嵌入深度神经网络的损失函数中，实现了仅依赖电感电流和输出电压数据的高精度参数估计，有效解决了传统纯数据驱动方法在小样本下泛化性差、物理一致性缺失的问题[79]。

4.2 智能控制决策

AI 不仅能够理解系统状态，还能基于这些感知信息主动进行决策，实现对变流器运行的智能调节。与传统依赖固定参数或经验规则的控制方法不同，AI 通过在线推理和自适应决策，使变流器能够在多变工况下灵活选择控制策略、动态调整控制参数，并有效应对系统不确定性和多目标约束。这种决策层面的智能化能力是连接感知与控制执行的关键环节。

在控制策略的自主选择方面，基于 MoE 架构的 DC-DC 升压变换器控制方法被提出，利用强化学习构建的门控网络赋予系统在不同运行工况下动态加权融合 PID 与 LQR 控制器输出的能力，并引入 DQN 实现了对控制行为的实时决策，在保证稳态精度的同时显著提升了变换器在负载突变与输入扰动下的暂态响应速度与抗扰动能力[80]。针对传统 MPC 在线计算负担重、难以在嵌入式平台实时实现的难题，基于 MoE 架构的决策替代方式被提出。该方法的核心逻辑在于利用门控网络实现对系统输入空间的分域决策，通过动态协调多个局部专家模型的控制权重，将复杂的非线性在线寻优过程转化为高效的权值分配决策。此外，该决策框架通过引入稳定性约束验证机制，确保了 AI 生成的控制序列在闭环运行下的物理安全性，为高性能控制策略在嵌入式硬件中的实时决策提供了有力保障[81]。

在并网变流器的智能化进程中，如何结合专家经验与数据驱动方法是当前的研究热点。例如，针对大规模电力电子设备接入电网后，局部利益冲突导致的协同决策难及配电网电压越限问题，利用大语言模型构建专家工作流，辅助 MARL 进行实时能源调度，在满足电网电压约束的同时显著提升了系统的经济性与自主化水平[82]。针对高比例分布式电力电子设备接入电网后，局部调节与系统全局电压/损耗目标之间的耦合冲突难题，一种集成时空 Transformer(spatio-temporal transformer, ST-Transformer)与 MARL 的协调控制框架被提出，利用 ST-Transformer 精确捕捉分布式资源间的时序依赖与空间关联以提升预测精度，并配合基于 PPO 算法的智能体策略，在复杂的拓扑约束下实现了有功与无功功率的实时协同调度，有效解决了大规模设备接入导致的“各自为政”与电压违规问题[83]。

针对缺乏历史数据的极端失稳风险，一种名为 MARL2GRID-TR 的多智能体强化学习基准框架被提出。通过高保真环境生成极端故障样本，并结合物理约束与专家规则引导，AI 能够在电力电子化电网的规划与运行中，在缺乏先验经验的情况下，自主探索出具备安全边界的稳控策略，有效解决了大规模复杂电网在应对线路过载和突发故障时缺乏协同决策工具的难题[84]。在表 3 中对 AI 在推理领域应用的文献进行了汇总。

表 3 AI 在推理领域应用的文献汇总

Table 3 Summary of literature on AI applications in reasoning

领域	算法	文献	解决问题
状态感知	ANN、BP	[73-76]	阻抗辨识
	CNN	[77]	光伏系统故障预警
	DNN	[78]	电网态势感知与风险评估
	PIML	[79]	变流器异常检测
控制决策	MoE	[80]	控制器场景自适应问题
		[81]	MPC 在线计算负担重
	MARL	[82]	能源调度，电网电压越限
		[83]	局部调节与系统全局电压目标之间的耦合冲突
		[84]	线路过载和突发故障

5 总结与展望

尽管 AI 赋能智能变流器已在设计优化、闭环控制与状态感知等多个方面取得了显著进展，但面向大规模工程化应用，仍面临着安全性、可解释性、实时性、泛化性与标准化等多重挑战[85-86]。

电力电子系统对控制失效的容忍度极低，而深

度学习模型存在对抗性攻击与外输入误判的潜在风险，亟需发展安全强化学习与形式化验证方法以构建可靠的安全保障体系。此外，变流器微秒级的控制响应要求与复杂 AI 模型巨大的计算开销之间的矛盾日益突出，推动着轻量化网络结构设计与边缘 AI 芯片的协同发展。在标准化方面，当前缺乏统一的感知模型定义、决策接口规范与测试验证标准，未来需借鉴工业 4.0 的资产管理壳与数字孪生互操作框架，构建面向智能变流器的通用技术体系。

当前研究正致力于开发物理信息神经网络，将已知的物理定律(如基尔霍夫定律、开关函数、电路微分方程)嵌入神经网络的结构与训练过程中，形成“灰箱”模型，以增强模型的物理一致性和外推能力。未来，随着可信 AI、持续学习与能源系统数字孪生技术的深度融合，具备高阶感知、自主决策与自进化能力的智能变流器将成为新型电力系统的核心智能节点，推动能源装备从“电力电子化”全面迈向“智能化”的新阶段。

参考文献　References

[1] 张源. 我国新能源发电技术现状与发展[J]. 中国能源，1997(7)：1-4，17.
ZHANG Yuan. Current status and development of new energy power generation technology in China[J]. Energy of China, 1997(7): 1-4, 17.

[2] 蒋明华，李丁，孔德祯，等. 面向高比例新能源送端系统频率稳定的多源协同控制及参数优化方法[J]. 电力建设，2025，46(5)：36-46.
JIANG Minghua, LI Ding, KONG Dezhen, et al. Multi-source coordinated control and parameter optimization methods for frequency stability in high-proportion new energy sending-end systems[J]. Electric Power Construction, 2025, 46(5): 36-46.

[3] MAROT A, KELLY A, NAGLIC M, et al. Perspectives on future power system control centers for energy transition[J]. Journal of Modern Power Systems and Clean Energy, 2022, 10(2): 328-344.

[4] 谢小荣，贺静波，毛航银，等. “双高”电力系统稳定性的新问题及分类探讨[J]. 中国电机工程学报，2021，41(2)：461-474.
XIE Xiaorong, HE Jingbo, MAO Hangyin, et al. New issues and classification of power system stability with high shares of renewables and power electronics[J]. Proceedings of the CSEE, 2021, 41(2): 461-474.

[5] 栗峰，丁杰，周才期，等. 新型电力系统下分布式光伏规模化并网运行关键技术探讨[J]. 电网技术，2024，48(1)：184-196.
LI Feng, DING Jie, ZHOU Caiqi, et al. Key technologies of large-scale grid-connected operation of distributed photovoltaic under new-type power system[J]. Power System Technology, 2024, 48(1): 184-196.

[6] 董昱，孙大雁，许丹，等. 新型电力系统电力电量平衡的挑战、应对与展望[J]. 中国电机工程学报，2025，45(6)：2039-2056.
DONG Yu, SUN Dayan, XU Dan, et al. Challenges, response and prospects for power balance in new power systems[J]. Proceedings of the CSEE, 2025, 45(6): 2039-2056.

[7] 赵兵，吴萍，蒋彦翊，等. 响应驱动的新型电力系统暂态稳定判别方法综述[J]. 电网技术，2025，49(7)：2633-2642.
ZHAO Bing, WU Ping, JIANG Yanhong, et al. A survey on response-driven transient stability determination of new generation of power system[J]. Power System Technology, 2025, 49(7): 2633-2642.

[8] 袁小明，张美清，迟永宁，等. 电力电子化电力系统动态问题的基本挑战和技术路线[J]. 中国电机工程学报，2022，42(5)：1904-1916.
YUAN Xiaoming, ZHANG Meiqing, CHI Yongning, et al. Basic challenges of and technical roadmap to power-electronized power system dynamics issues[J]. Proceedings of the CSEE, 2022, 42(5): 1904-1916.

[9] 陈国平，董昱，梁志峰. 能源转型中的中国特色新能源高质量发展分析与思考[J]. 中国电机工程学报，2020，40(17)：5493-5505.
CHEN Guoping, DONG Yu, LIANG Zhifeng. Analysis and reflection on high-quality development of new energy with Chinese characteristics in energy transition[J]. Proceedings of the CSEE, 2020, 40(17): 5493-5505.

[10] 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[J]. 中国电机工程学报，2022，42(8)：2806-2818.
ZHANG Zhigang, KANG Chongqing. Challenges and prospects for constructing the new-type power system towards a carbon neutrality future[J]. Proceedings of the CSEE, 2022, 42(8): 2806-2818.

[11] LI Y Z, ZHAO Y, WU L, et al. Artificial intelligence enabled computational methods for smart grid forecast and dispatch[M]. Singapore, Singapore: Springer Nature, 2023.

[12] 韩富佳，王晓辉，乔骥，等. 基于人工智能技术的新型电力系统负荷预测研究综述[J]. 中国电机工程学报，2023，43(22)：8569-8591.
HAN Fujia, WANG Xiaohui, QIAO Ji, et al. Review on artificial intelligence based load forecasting research for the new-type power system[J]. Proceedings of the CSEE, 2023, 43(22): 8569-8591.

[13] 蔡瑞天，姚丽娟，武昕. 面向分布式光伏群调群控的数字孪生方法[J]. 电网技术，2025，49(2)：593-603.
CAI Ruitian, YAO Lijuan, WU Xin. A digital twin approach for distributed photovoltaic group regulation and group control[J]. Power System Technology, 2025, 49(2): 593-603.

[14] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.

[15] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.

[16] BANA P R, AMIN M, MOLINAS M. ANN-based surrogate PI and MPC controllers for grid-connected VSC system: small-signal analysis and comparative evaluation[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2024, 12(1): 566-578.

[17] KIRANYAZ S, GASTLI A, BEN-BRAHIM L, et al. Real-time fault detection and identification for MMC using 1-D convolutional neural networks[J]. IEEE Transactions on Industrial Electronics, 2019, 66(11): 8760-8771.

[18] QIN C Y, GAO F, ZHOU K J. Data-driven online stability monitoring of grid-following inverters in weak grid[J]. IEEE Transactions on Industrial Informatics, 2025, 21(6): 4554-4564.

[19] XIAO P, VENAYAGAMOORTHY G K, CORZINE K A, et al. Recurrent neural networks based impedance measurement technique for power electronic systems[J]. IEEE Transactions on Power Electronics, 2010, 25(2): 382-390.

[20] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.

[21] ZHAO S, BLAABJERG F, WANG H. An overview of artificial intelligence applications for power electronics[J]. IEEE Transactions on Power Electronics, 2021, 36(4): 4633-4658.

[22] VAN HASSELT H, GUEZ A, SILVER D. Deep reinforcement learning with double Q-learning[C]//Proceedings of the 30th AAAI

Conference on Artificial Intelligence. Phoenix, USA: AAAI, 2016.

[23] SUTTON R S, BARTO A G. Reinforcement learning: an introduction[M]. Cambridge, USA: MIT Press, 1998.

[24] WIERING M, VAN OTTERLO M. Reinforcement learning[M]. Berlin Heidelberg, Germany: Springer, 2012.

[25] YANG T X, CUI C G, ZHANG C L. On the robustness enhancement of DRL controller for DC-DC converters in practical applications[C]//2022 IEEE 17th International Conference on Control & Automation. Naples, Italy: IEEE, 2022: 225-230.

[26] YANG T X, CUI C G, ZHANG C L, et al. Robustness enhancement of DRL controller for DC-DC buck converters fusing ESO[J]. Journal of Control and Decision, 2025, 12(1): 101-110.

[27] LILLICRAP T P, HUNT J J, PRITZEL A, et al. Continuous control with deep reinforcement learning: US Patent 10, 776, 692[P]. 2020-9-15.

[28] GHEISARNEJAD M, FARSIZADEH H, KHOOBAN M H. A novel nonlinear deep reinforcement learning controller for DC-DC power buck converters[J]. IEEE Transactions on Industrial Electronics, 2021, 68(8): 6849-6858.

[29] ZENG Y, POU J, SUN C J, et al. Multiagent deep reinforcement learning-aided output current sharing control for input-series output-parallel dual active bridge converter[J]. IEEE Transactions on Power Electronics, 2022, 37(11): 12955-12961.

[30] WANG H, ZHANG G Z, HU W B, et al. Artificial intelligence based approach to improve the frequency control in hybrid power system[J]. Energy Reports, 2020, 6: 174-181.

[31] FU X G, LI S H. Control of single-phase grid-connected converters with LCL filters using recurrent neural network and conventional control methods[J]. IEEE Transactions on Power Electronics, 2016, 31(7): 5354-5364.

[32] FU X G, LI S H, JAITHWA I. Implement optimal vector control for LCL-filter-based grid-connected converters by using recurrent neural networks[J]. IEEE Transactions on Industrial Electronics, 2015, 62(7): 4443-4454.

[33] SUN Y, LI S H, LIN B, et al. Artificial neural network for control and grid integration of residential solar photovoltaic systems[J]. IEEE Transactions on Sustainable Energy, 2017, 8(4): 1484-1495.

[34] WATANABE R, SUGIURA D, ITO R, et al. Implementation of real time normalized advantage function control for a buck converter[C]//2023 IEEE 14th International Conference on Power Electronics and Drive Systems (PEDS). Montreal, Canada: IEEE, 2023: 1-6.

[35] CUI C G, YAN N, HUANGFU B X, et al. Voltage regulation of DC-DC buck converters feeding CPLs via deep reinforcement learning[J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2022, 69(3): 1777-1781.

[36] PRAG K, WOOLWAY M, CELIK T. Data-driven model predictive control of DC-to-DC buck-boost converter[J]. IEEE Access, 2021, 9: 101902-101915.

[37] KISHORE P S V, JAYARAM N, RAJESH J. Performance enhancement of buck converter using reinforcement learning control[C]//2022 IEEE Delhi Section Conference (DELCON). New Delhi, India: IEEE, 2022: 1-5.

[38] YE J, GUO H Y, MEI S, et al. A TD3 algorithm based reinforcement learning controller for DC-DC switching converters[C]//2023 International Conference on Power Energy Systems and Applications (ICoPESA). Nanjing, China: IEEE, 2023: 358-363.

[39] CHEN Y, BAI J B, KANG Y. A nonisolated single-inductor multiport DC-DC topology deduction method based on reinforcement learning[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2022, 10(6): 6572-6585.

[40] LIU X, QIU L, FANG Y T, et al. Reinforcement learning-based event-triggered FCS-MPC for power converters[J]. IEEE Transactions on Industrial Electronics, 2023, 70(12): 11841-11852.

[41] LIU X, QIU L, FANG Y T, et al. Predictive control of voltage source inverter: an online reinforcement learning solution[J]. IEEE Transactions on Industrial Electronics, 2024, 71(7): 6591-6600.

[42] AHMADI-GORJAYI F, MOHSENIAN-RAD H. Data-driven models for sub-cycle dynamic response of inverter-based resources using WMU measurements[J]. IEEE Transactions on Smart Grid, 2023, 14(5): 4125-4128.

[43] MITRENTSIS G, LENS H. Data-driven dynamic models of active distribution networks using unsupervised learning techniques on field measurements[J]. IEEE Transactions on Smart Grid, 2021, 12(4): 2952-2965.

[44] 王佳宁，杨仁海，姚张浩，等. 基于深度强化学习的有源中点钳位逆变器效率优化设计[J]. 电子与信息学报，2023，45(9)：3311-3320.
WANG Jianing, YANG Renhai, YAO Zhanghao, et al. Efficiency optimized design of active neutral point clamped inverter based on deep reinforcement learning[J]. Journal of Electronics & Information Technology, 2023, 45(9): 3311-3320.

[45] SAHA U, JAWAD A, SHAHRIA S, et al. Proximal policy optimization-based reinforcement learning approach for DC-DC boost converter control: a comparative evaluation against traditional control techniques[J]. Heliyon, 2024, 10(18): e37823.

[46] MOHAMMADZADEH M, AKBARI E, SALAMEH A A, et al. Application of mixture of experts in machine learning-based controlling of DC-DC power electronics converter[J]. IEEE Access, 2022, 10: 117157-117169.

[47] QIN C Y, GAO F, WANG G X, et al. Data-driven multiparameter tuning for stabilizing grid-following inverters[J]. IEEE Transactions on Power Electronics, 2026, 41(5): 7871-7883.

[48] DAS S C, VU T, RAMASUBRAMANIAN D, et al. Deep reinforcement learning for optimizing inverter control with fixed and adaptive gain tuning strategies for power system stability[J]. IEEE Transactions on Smart Grid, 2025, 16(6): 5099-5110.

[49] CUI C G, FAN Z Y, YANG T X, et al. Domain adaptation-based transfer learning for DRL control implementation of DC microgrids[J]. IEEE Transactions on Industrial Electronics, 2025, 72(12): 14344-14355.

[50] ZHANG X, MA Z X, NIU H C, et al. Data-driven quantitative multi-objective finite-control-set model predictive control for three-phase three-level NPC inverters[J]. IEEE Transactions on Power Electronics, 2026, 41(6): 9667-9679.

[51] 宋家康，赵建勇，孙海霞，等. 基于多目标协同训练的风电功率预测提升算法[J]. 电力工程技术，2023，42(6)：232-240.
SONG Jiakang, ZHAO Jianyong, SUN Haixia, et al. Wind power prediction and improvement algorithm based on multi-objective collaborative training[J]. Electric Power Engineering Technology, 2023, 42(6): 232-240.

[52] WANG D, YANG M, ZHANG W. Wind power group prediction model based on multi-task learning[J]. Electronics, 2023, 12(17): 3683.

[53] MENG Q L, HUSSAIN S, LUO F Z, et al. An online reinforcement learning-based energy management strategy for microgrids with centralized control[J]. IEEE Transactions on Industry Applications, 2025, 61(1): 1501-1510.

[54] 年珩，陈磊磊，赵建勇，等. 基于电解槽状态识别的风光制氢系统能量管理优化[J]. 电测与仪表，2023，60(10)：10-16.
NIAN Heng, CHEN Leilei, ZHAO Jianyong, et al. Energy manage-

ment optimization of wind-solar hydrogen production system based on electrolytic cell state recognition[J]. Electrical Measurement & Instrumentation, 2023, 60(10): 10-16.

[55] MOHAMED A A S, BERZOY A, MOHAMMED O A. Design and hardware implementation of FL-MPPT control of PV systems based on GA and small-signal analysis[J]. IEEE Transactions on Sustainable Energy, 2017, 8(1): 279-290.

[56] PRIYADARSHI N, PADMANABAN S, HOLM-NIELSEN J B, et al. An experimental estimation of hybrid ANFIS-PSO-based MPPT for PV grid integration under fluctuating sun irradiance[J]. IEEE Systems Journal, 2020, 14(1): 1218-1229.

[57] KOFINAS P, DOLTSINIS S, DOUNIS A I, et al. A reinforcement learning approach for MPPT control method of photovoltaic sources[J]. Renewable Energy, 2017, 108: 461-473.

[58] ZEDDINI M A, TURKI M, MIMOUN M F. Optimization of PV energy conversion system using reinforcement learning algorithm[C]//2020 20th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA). Monastir, Tunisia: IEEE, 2020: 249-254.

[59] 张坤. 基于强化学习的虚拟同步发电机低频振荡抑制策略的研究[D]. 成都：电子科技大学，2021.
ZHANG Kun. Research on low frequency oscillation damping strategy of virtual synchronous generator based on reinforcement learning[D]. Chengdu, China: University of Electronic Science and Technology of China, 2021.

[60] 赵后起，邓卫，崔承刚，等. 孤岛微电网环境下基于物理模型引导的深度强化学习 VSG 频率控制方法[J/OL]. 中国电机工程学报，2025：1-13[2026-03-29]. https://link.cnki.net/urlid/11.2107.tm.20250625.1631.002.
ZHAO Houqi, DENG Wei, CUI Chenggang, et al. Deep reinforcement learning based physical model guided VSG frequency control method in islanded microgrid environment[J/OL]. Proceedings of the CSEE, 2025: 1-13[2026-03-29]. https://link.cnki.net/urlid/11.2107.tm.20250625.1631.002.

[61] 张华强，牟晨东，赵玫，等. 基于强化学习的多光储虚拟同步机频率协调控制策略[J]. 电气传动，2021，51(19)：36-42.
ZHANG Huaqiang, MOU Chendong, ZHAO Mei, et al. Frequency coordination control strategy of multiple photovoltaic-battery virtual synchronous generators based on reinforcement learning[J]. Electric Drive, 2021, 51(19): 36-42.

[62] BUBSHAIT A, SIMÕES M G. Design of fuzzy logic-based dynamic droop controller of wind turbine system for primary frequency support[C]//2018 IEEE Industry Applications Society Annual Meeting (IAS). Portland, USA: IEEE, 2018: 1-7.

[63] CAO D, ZHAO J B, HU W H, et al. Data-driven multi-agent deep reinforcement learning for distribution system decentralized voltage control with high penetration of PVs[J]. IEEE Transactions on Smart Grid, 2021, 12(5): 4137-4150.

[64] SAHOO S. Physics-informed neural network-based control of power electronic converters[M]//BLAABJERG F. Control of Power Electronic Converters and Systems. London, UK: Academic Press, 2024: 309-331.

[65] OBOREH-SNAPPS O, STRATHMAN S A, SAELENS J, et al. Addressing reactive power sharing in parallel inverter islanded microgrid through deep reinforcement learning[C]//2024 IEEE Applied Power Electronics Conference and Exposition (APEC). Long Beach, USA: IEEE, 2024: 2946-2953.

[66] 孙旭，张继红，鲁晓艳，等. 基于 BP 神经网络 PI 和准 PR 控制的零序环流抑制策略[J]. 太阳能学报，2025，46(9)：632-641.
SUN Xu, ZHANG Jihong, LU Xiaoyan, et al. Zero sequence loop current suppression strategy based on BP neural network PI and quasi-PR control[J]. Acta Energiae Solaris Sinica, 2025, 46(9): 632-641.

[67] 韩然，凌霄，李祥新，等. 基于改进神经网络的弱电网逆变器谐波自动补偿方法[J]. 自动化与仪表，2025，40(4)：1-5.
HAN Ran, LING Xiao, LI Xiangxin, et al. Harmonic automatic compensation method for weak current grid inverter based on improved neural network[J]. Automation & Instrumentation, 2025, 40(4): 1-5.

[68] YE J, MEI S, GUO H Y, et al. A DDPG algorithm based reinforcement learning controller for three-phase DC-AC inverters[C]//2023 International Conference on Power Energy Systems and Applications (ICoPESA). Nanjing, China: IEEE, 2023: 429-434.

[69] QIN X X, HU W H, HAN Y B, et al. Level-increased iSHE modulation method for modular multilevel converters based on DDPG[J]. IEEE Transactions on Power Electronics, 2025, 40(2): 2874-2886.

[70] MOEINI A, DABBAGHJAMANESH M, KIMBALL J W. Q-learning-based smart selective harmonic current mitigation-PWM (S^2HCM-PWM) for grid-connected converters[C]//2020 IEEE Energy Conversion Congress and Exposition (ECCE). Detroit, USA: IEEE, 2020: 5068-5075.

[71] ZHAO Q Y, HAN Z Y, WANG S X, et al. Coordinated control of multiple converters in model-free AC/DC distribution networks based on reinforcement learning[J]. Frontiers in Energy Research, 2023, 11: 1202701.

[72] UR REHMAN A, ALI M, IQBAL S, et al. Artificial intelligence-based control and coordination of multiple PV inverters for reactive power/voltage control of power distribution networks[J]. Energies, 2022, 15(17): 6297.

[73] 赵子明，解鹏程，王众，等. 基于神经网络的可再生能源并网逆变器阻抗模型辨识方法[J]. 可再生能源，2022，40(12)：1630-1635.
ZHAO Ziming, XIE Pengcheng, WANG Zhong, et al. Neural network based impedance model identification method for renewable energy grid-tied inverter[J]. Renewable Energy Resources, 2022, 40(12): 1630-1635.

[74] MARDANI M M, LAZAR R D, MIJATOVIC N, et al. Artificial neural network-based constrained predictive real-time parameter adaptation controller for grid-tied VSCs[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2023, 11(2): 1507-1517.

[75] 饶仪明，吕敬，王众，等. 基于数据-模型融合驱动的新能源场站宽频阻抗在线辨识及稳定性评估[J]. 中国电机工程学报，2024，44(7)：2670-2684.
RAO Yiming, LÜ Jing, WANG Zhong, et al. Wideband impedance online identification and stability assessment of renewable power plants based on physics-informed data-driven method[J]. Proceedings of the CSEE, 2024, 44(7): 2670-2684.

[76] 吴滨源. 并网逆变器阻抗获取与系统稳定性分析方法研究[D]. 北京：华北电力大学(北京)，2024.
WU Binyuan. Research on impedance acquisition and system stability analysis methods for grid-connected inverters[D]. Beijing, China: North China Electric Power University (Beijing), 2024.

[77] 刘昊. 基于大数据的光伏逆变器温度异常检测方法研究与应用[D]. 西安：西安石油大学，2025.
LIU Hao. Research and application of temperature anomaly detection method for photovoltaic inverters based on big data[D]. Xi'an, China: Xi'an Shiyou University, 2025.

[78] ZHANG M Y, SONG J, TIAN Y J, et al. Risk situational awareness of power grid based on deep neural networks[C]//2024 IEEE 4th International Conference on Power, Electronics and Computer Applications (ICPECA). Shenyang, China: IEEE, 2024: 619-624.

[79] ZHAO S, PENG Y Z, ZHANG Y, et al. Parameter estimation of power electronic converters with physics-informed machine learning[J]. IEEE Transactions on Power Electronics, 2022, 37(10): 11567-11578.

[80] ZHAO R M, ALKHAYYAT A, KHAN M A. Reinforcement learning-enhanced expert mixture of LQR and PID for optimized control in DC-DC boost converters[J]. Electrical Engineering, 2025, 107(9): 11891-11910.

[81] AHRAZOĞLU M A. Learning a mixture of experts approximation of a model predictive controller with guarantees[C]//2025 IEEE 64th Conference on Decision and Control (CDC). Rio de Janeiro, Brazil: IEEE, 2025: 3708-3713.

[82] LOU C, JIN Z, TANG W, et al. LLM-enhanced multi-agent reinforcement learning with expert workflow for real-time P2P energy trading[J/OL]. IEEE Transactions on Smart Grid, 2026: 1-16. DOI:10.1109/TSG.2026.3684885.

[83] ZHAO J T, CHEN N, HAN X H, et al. Coordinated optimization of distributed energy resources based on spatio-temporal transformer and multi-agent reinforcement learning[J]. Processes, 2025, 13(10): 3372.

[84] MARCHESINI E, BOGUSLAWSKI E, LEITE A, et al. MARL-2Grid-TR: a multi-agent RL benchmark in power grid operations[C/OL]//The Fourteenth International Conference on Learning Representations. 2026[2026-06-23]. https://openreview.net/forum?id=mpAMH1OyMO.

[85] 严如强，周峥，杨远贵，等. 可解释人工智能在工业智能诊断中的挑战和机遇：归因解释[J]. 机械工程学报，2024，60(12)：21-40.
YAN Ruqiang, ZHOU Zheng, YANG Yuangui, et al. Challenges and opportunities of XAI in industrial intelligent diagnosis: attribution interpretation[J]. Journal of Mechanical Engineering, 2024, 60(12): 21-40.

[86] 严如强，商佐港，王志颖，等. 可解释人工智能在工业智能诊断中的挑战和机遇：先验赋能[J]. 机械工程学报，2024，60(12)：1-20.
YAN Ruqiang, SHANG Zuogang, WANG Zhiying, et al. Challenges and opportunities of XAI in industrial intelligent diagnosis: priori-empowered[J]. Journal of Mechanical Engineering, 2024, 60(12): 1-20.



李　明
1993—，男，博士，副教授，博导
主要从事大规模新能源发电场站跟网型与构网型混合模式控制技术、稳定性分析与控制、多逆变器电站分布式协同稳定控制技术、基于人工智能的并网变流器建模、分析与控制技术等方面的研究工作
E-mail: liming2021@tsinghua.org.cn

LI Ming
Ph.D.
Associate professor



耿　华(通信作者)
1981—，男，博士，教授
主要研究方向为可再生能源发电技术、新型电力系统稳定与控制等
E-mail: genghua@tsinghua.edu.cn

GENG Hua
Ph. D., Professor
Corresponding author

收稿日期　2026-04-08　修回日期　2026-06-01　　编辑　陈　蔓