DOI：10.13234/j.issn.2095-2805.2025.7.136 **中图分类号**：TP18 **文献标志码**：A

基于 AC 强化学习的光伏发电系统 MPPT 控制

于来宝[1,2]，谢兴旺[3]

(1.武汉城市职业学院机电工程学院，武汉 430070；2.中国地质大学地球物理与空间信息学院，武汉 430074；3.武昌理工学院人工智能学院，武汉 430223)

摘要：光伏发电系统中，当出现太阳辐照度变化快、局部遮阴或者辐照度较差等特殊情况时，采用传统方法会导致光伏发电系统在最大功率点附近振荡，跟踪速度变慢，严重时光伏发电系统会出现功率剧烈波动、难以收敛的现象。针对该问题，提出1种基于强化学习RL(reinforcement learning)的光伏发电系统最大功率点追踪MPPT(maximum power point tracking)控制方法，通过在线实时调节强化学习中径向基函数RBF(radial basis function)神经网络权值系数来自适应输出控制信号，让光伏发电输出的有功功率快速跟踪到最大功率点。在MATLAB/Simulink环境下搭建光伏发电系统，采用所提强化学习控制方法与常规RBF神经网络控制方法进行对比，结果验证了采用强化学习控制能够在更短时间内使得光伏发电系统快速、稳定、准确地收敛到最大功率点，以实现光伏发电输出功率的最大化。

关键词：光伏发电；最大功率点追踪；强化学习；RBF神经网络

MPPT Control of Photovoltaic Power Generation System Based on AC Reinforcement Learning

YU Laibao[1,2], XIE Xingwang[3]

(1. College of Electromechanical Engineering, Wuhan City Polytechnic, Wuhan 430070, China; 2. School of Geophysics and Geomatics, China University of Geosciences, Wuhan 430074, China; 3. School of Artificial Intelligence, Wuchang University of Technology, Wuhan 430223, China)

Abstract: Under special conditions such as rapid changes in solar irradiance, local shading or poor solar irradiance, the traditional method will cause a photovoltaic (PV) power generation system to oscillate near the maximum power point (MPP), and the tracking speed will be slow. In serious cases, the PV power generation system will exhibit severe power fluctuations, which will lead to divergence. To solve this problem, a maximum power point tracking (MPPT) control method for PV power generation systems based on reinforcement learning (RL) is proposed in this paper. The RBF neural network weight coefficient in RL is adjusted online and in real time to adapt to the output control signal, so that the active power output from PV power generation can be quickly tracked to the MPP. A PV power generation system was constructed in MATLAB/Simulink, and a comparison with the conventional RBF neural network control method was performed. Results show that the RL control can make the PV power generation system converge to the MPP stably and accurately in a shorter time. At the same time, the PV power generation system can output the maximum active power.

Keywords: Photovoltaic (PV) power generation; maximum power point tracking (MPPT); reinforcement learning; RBF neural network

收稿日期：2022-08-23；**修回日期**：2023-01-06，2023-02-20；**录用日期**：2023-03-01；**网络首发日期**：2023-04-10

基金项目：国家自然科学基金资助项目(51228701)；2022年度湖北省教育厅科学研究计划指导性项目(B2022605)；武汉市教育局2022市属高校产学研项目(CXY202223)；武城职硕博士专项课题支持项目(2022whcvcB02)

This work is supported by National Natural Science Foundation of China under the grant 51228701; Scientific Research Project of Education Department of Hubei Province under the grant B2022605; Industry-University-Research Project of Colleges and Universities in Wuhan City under the grant CXY202223; Special Project for Masters and Doctors of Wuhan City Polytechnic under the grant 2022whcvcB02

随着全球经济和社会的发展与进步，各国对能源的需求量逐年增加，以石油、煤炭和天然气为代表的化石能源不断减少。燃烧化石能源导致环境污染日益严重，当前能源与生态环境问题凸显，大规模开发利用可再生能源是当务之急。2020 年 9 月，中国政府明确提出，中国力争 2030 年前二氧化碳排放达到峰值，努力争取 2060 年前实现碳中和[1]。

光伏PV(photovoltaic)发电具有安全清洁、持续可用、噪音小、安装方便以及环境友好等特点，成为可再生能源的重要来源之一。光伏电池的输出具有较强非线性，光伏电池的功率输出与太阳辐照度、电池面板与太阳光线之间角度及环境温度等外部因素有关，采用最大功率点追踪 MPPT(maximum power point tracking)技术能够追踪光伏电池最大功率输出，从而提高光伏发电系统的能量转换效率，充分利用太阳能，增加光伏发电企业的经济效益。为此，国内外学者进行了一系列研究，如采用扰动观察法[2-3]、电导增量法[4-5]，但是这些方法很难对太阳辐照度快速变化和局部遮阴的情况进行 MPPT 控制。近年来，随着机器学习和人工智能技术的快速发展，有学者尝试将机器学习用于光伏发电系统的 MPPT 控制，并且取得了一定的进展。文献[6]提出了 1 种预测模型法与扰动观察法相结合的控制方法，能够在复杂多变环境下，快速准确实现 MPPT 的目的，但是预测模型法需要知道被控系统的数学模型，很难实现；文献[7]根据 Boost 电路平均状态方程设计相应的滑模控制器，来实现对光伏 MPPT 快速跟踪，不足之处是滑模控制对被控系统结构和参数变化过于敏感，实际系统中应用受到限制；文献[8-9]分别采用自适应变异粒子群和人工神经网络 ANN(artificial neural network)设计了一款 MPPT 控制器，提高跟踪光伏 MPPT 的精度，由于神经网络控制效果受到网络权值的影响，这也限制了神经网络的应用领域；文献[10]提出了 1 种功率差变步长扰动观察法来实现 MPPT 控制，只是功率差变步长设计中凭借经验确定步长，光伏 MPPT 控制存在局限；文献[11]将改进人工鱼群算法用于光伏 MPPT 控制中，通过合理设置该人工鱼群算法的结构以实现快速光伏的 MPPT，但是该方法对参数的设置较多；文献[12]采用基于模糊控制的爬山法，来实现光伏系统的 MPPT 控制，但是模糊控制参数配置困难。

针对上述问题，本文采用 AC 强化学习 RL(reinforcement learning)设计一款光伏发电 MPPT 控制器，以实现在光照辐射度快速变化和局部遮阴的情况下，能够快速准确跟踪到最大功率点。AC 强化学习采用 RBF 神经网络[13]来实现 Actor 网络和 Critic 网络，通过在线更新网络的权值系数，输出自适应的控制信号，来实现光伏 MPPT 的目的。仿真实验结果表明，该方法具有不需要被控系统精确数学模型，收敛速度快、鲁棒性强等特点。

1　典型光伏电池模型

光伏发电系统由光伏电池面板、DC/DC 转换电路、DC/AC 逆变电路、逆变控制器以及变压器等组成，光伏发电系统原理如图 1 所示。图中：U_{sref} 为逆变器输出参考电压，U_{s} 为逆变器输出电压，$I_{d\mathrm{ref}}$ 和 $I_{q\mathrm{ref}}$ 分别为 d、q 轴参考电流。

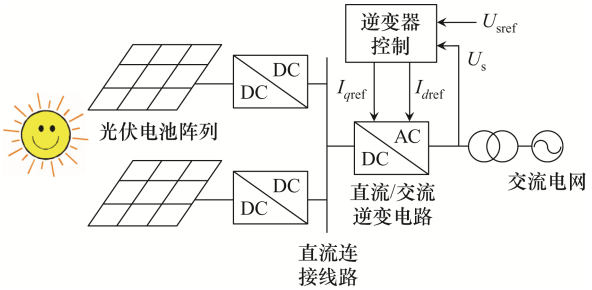


图 1　光伏发电系统的原理

Fig. 1 Schematic of PV power generation system

通常外界温度变化对光伏电池有功输出影响不大，故在常温 T=25 ℃条件下，以光照强度 S 为变量，采用工程模型描述光伏阵列输出特性。光伏电池的模型为

$$I'_{\mathrm{sc}} = I_{\mathrm{sc}} \frac{S}{S_{\mathrm{ref}}} \tag{1}$$

$$I'_{\mathrm{m}} = I_{\mathrm{m}} \frac{S}{S_{\mathrm{ref}}} \tag{2}$$

$$U'_{\mathrm{oc}} = U_{\mathrm{oc}} \ln\left[\mathrm{e} + 0.5\left(\frac{S}{S_{\mathrm{ref}}} - 1\right)\right] \tag{3}$$

$$U'_{\mathrm{m}} = U_{\mathrm{m}} \ln\left[\mathrm{e} + 0.5\left(\frac{S}{S_{\mathrm{ref}}} - 1\right)\right] \tag{4}$$

式中：I'_{sc} 为光伏电池的短路电流；I'_{m} 为最大功率点电流；U'_{oc} 为开路电压；U'_{m} 为最大功率点电压；S_{ref} 为参考光照强度；I_{sc}、U_{oc}、I_{m}、U_{m} 分别为由厂家提供的光伏电池板的短路电流、开路电压、最大功率点电流、最大功率点电压。

修正系数 C_1 和 C_2 的计算式为

$$C_1 = \left(1 - \frac{I'_{\mathrm{m}}}{I'_{\mathrm{sc}}}\right)\exp\left(\frac{-U'_{\mathrm{m}}}{C_2 U'_{\mathrm{oc}}}\right) \tag{5}$$

$$C_2 = \left(\frac{U'_{\mathrm{m}}}{U'_{\mathrm{oc}}} - 1\right)\left[\ln\left(1 - \frac{I'_{\mathrm{m}}}{I'_{\mathrm{sc}}}\right)\right]^{-1} \tag{6}$$

光伏阵列输出电流 I_{PV} 为

$$I_{\mathrm{PV}} = N_{\mathrm{P}} I'_{\mathrm{sc}}\left\{1 - C_1\left[\exp\left(\frac{U_{\mathrm{PV}}}{C_2 U'_{\mathrm{oc}} N_{\mathrm{S}}}\right) - 1\right]\right\} \tag{7}$$

式中：N_{P} 和 N_{S} 分别为串、并联光伏电池板的数目；U_{PV} 为光伏阵列输出电压。

则光伏阵列输出功率 P_{PV} 为

$$P_{\mathrm{PV}} = I_{\mathrm{PV}} U_{\mathrm{PV}} \tag{8}$$

2 强化学习的原理

在 AC 学习中，Actor 网络和 Critic 网络的输入均为外部环境的状态变量，只是它们的输出不同。为了简化系统的设计，提高学习效率，本文采用径向基函数 RBF(radical basis function)网络同时完成 Actor 网络的策略函数和 Critic 网络的值函数功能，其结构如图 2 所示。

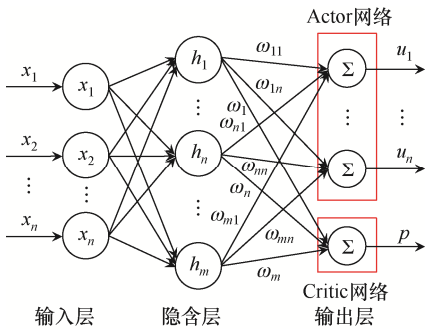


图 2 采用 RBF 神经网的 AC 强化学习原理

Fig. 2 Schematic of AC reinforcement learning using RBF neural network

RBF 神经网络 t 时刻的输入 $\boldsymbol{x}(t)$ 为

$$\boldsymbol{x}(t) = [x_1(t), x_2(t), \cdots, x_n(t)]^{\mathrm{T}} \tag{9}$$

隐含层采用高斯核函数 $h_j(t)$，即

$$h_j(t) = \exp\left(-\frac{\left\|x_j(t) - \boldsymbol{\mu}_j(t)\right\|^2}{2\sigma_j^2(t)}\right) \quad j = 1, 2, \cdots, m \tag{10}$$

$$\boldsymbol{\mu}_j = [\mu_{1j}, \mu_{2j}, \mu_{3j}]^{\mathrm{T}} \tag{11}$$

式中：$\boldsymbol{\mu}_j$ 为第 j 个节点的中心向量；σ_j 为第 j 个节点的宽度函数；m 为隐含层节点的数量。

Actor 网络和 Critic 网络的输出 $u_n(t)$ 和 $p(t)$ 分别为

$$u_n(t) = \sum_{j=1}^{n} \omega_{nj} h_j(t) \quad n = 1, 2, \cdots, m \tag{12}$$

$$p(t) = \sum_{j=1}^{m} \omega_j h_j(t) \tag{13}$$

式中，ω_{nj} 和 ω_j 分别为 Actor 网络、Critic 网络的权值系数。实际的控制信号 u 等于 Actor 网络输出 u_n 加上一个高斯扰动项 η_m，有

$$u(t) = u_n(t) + \eta_m(0, \rho(t)) \tag{14}$$

式中，$\rho(t)$ 为方差信号，表示为

$$\rho(t) = \{1 + \exp[2n(t)]\}^{-1} \tag{15}$$

在 AC 强化学习算法中，时序差分函数 δ_{TD} 为

$$\delta_{\mathrm{TD}} = r(t) + \lambda n(t+1) - n(t) \tag{16}$$

式中：λ 为折扣系数，$0<\lambda<1$；$r(t)$为误差的强化学习信号，定义为

$$r(t) = \begin{cases} 0 & |e(t)| < \varepsilon \\ 1 & |e(t)| \geqslant \varepsilon \end{cases} \tag{17}$$

式中：ε 为大于 0 的常数；$e(t)$ 为 t 时刻的偏差，$e(t) = p(t+1) - p(t)$。

性能指标函数 $E(t)$定义为

$$E(t) = \frac{1}{2}\delta_{\mathrm{TD}}^2(t) \tag{18}$$

Actor 网络和 Critic 网络的权值系数更新公式为

$$\omega_{nj}(t+1) = \omega_{nj}(t) + \eta_{\mathrm{a}} \frac{\partial E(t)}{\partial \omega(t)} = \omega_{nj}(t) + \eta_{\mathrm{a}} \delta_{\mathrm{TD}} \frac{\eta_{\mathrm{m}}(t)}{\rho(t)} h(t) \tag{19}$$

$$\omega_j(t+1) = \omega_j(t) + \eta_{\mathrm{c}} \delta_{\mathrm{TD}} h(t) \tag{20}$$

式中：$\eta_m(t)$ 为高斯扰动项；$h(t)$ 为隐含层采用的高斯核函数；η_a、η_c 分别为 Actor 网络和 Critic 网络学习速率。隐含层节点中心函数 $c(t)$和宽度函数 $\sigma(t)$的更新公式为

$$c(t+1)=c(t)+\beta_1\delta_{TD}n(t)\frac{x(t)-c(t)}{\sigma^2(t)} \tag{21}$$

$$\sigma(t+1)=\sigma(t)+\beta_2\delta_{TD}n(t)\frac{\|x(t)-c(t)\|^2}{\sigma^3(t)} \tag{22}$$

式中，β_1、β_2 分别为中心函数、宽度函数的学习速率。η_a、η_c、β_1、β_2 设置不同数值，程序调节会更加灵活方便。

AC 强化学习控制器内部由状态转换器、Actor 网络和 Critic 网络构成，其原理如图 3 所示。图中，$\boldsymbol{w}(t)$ 为系统的输入向量。

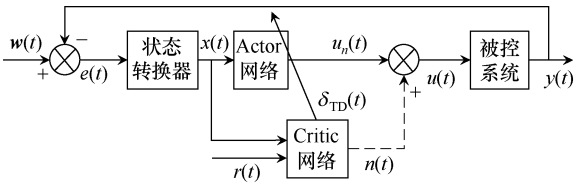


图 3　AC 强化学习控制器原理

Fig. 3 Schematic of AC reinforcement learning controller

3　基于强化学习的光伏 MPPT 设计

由于光伏发电具有明显的随机性、波动性的特点，为了解决太阳辐照度变化快、局部遮阴的问题，同时确保光伏 MPPT 控制过程中收敛速度快、跟踪精度高，本文提出了基于 AC 强化学习的 MPPT 控制器，其控制原理如图 4 所示。

图 4 中，Zeta 斩波器采用电压外环 PI、电流内环 PI 的双闭环控制。首先由测量电路将光伏电池的 U_{PV} 和 I_{PV} 作为 RL-MPPT 控制器的输入信号，该控制器输出自适应控制电压 U_{ref} 作用于电压外环 PI 控制器，电流内环 PI 控制器在 I_{ref} 作用下，输出脉宽调制 PWM (pulse width modulation)信号来控制开关器件 K 的关断。则斩波器输出电压 U_0 为

$$U_0=\frac{D}{1-D}U_{PV} \tag{23}$$

式中，D 为占空比。由式(23)可见，通过 RL-MPPT 自适应控制，自适应调节占空比 D 的大小，进而实现最优的电压 U_0，从而实现光伏 MPPT 跟踪。

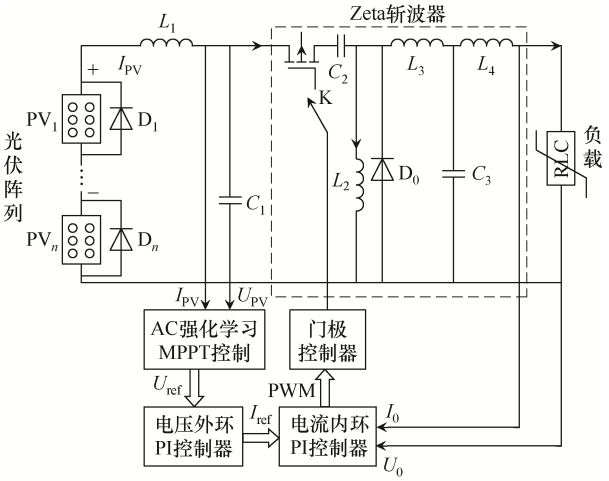


图 4　光伏发电系统拓扑结构及采用 AC 强化学习的 MPPT 控制电路

Fig. 4 Topology of PV power generation system, and MPPT control circuit using AC reinforcement learning

基于强化学习的 MPPT 控制流程如图 5 所示。

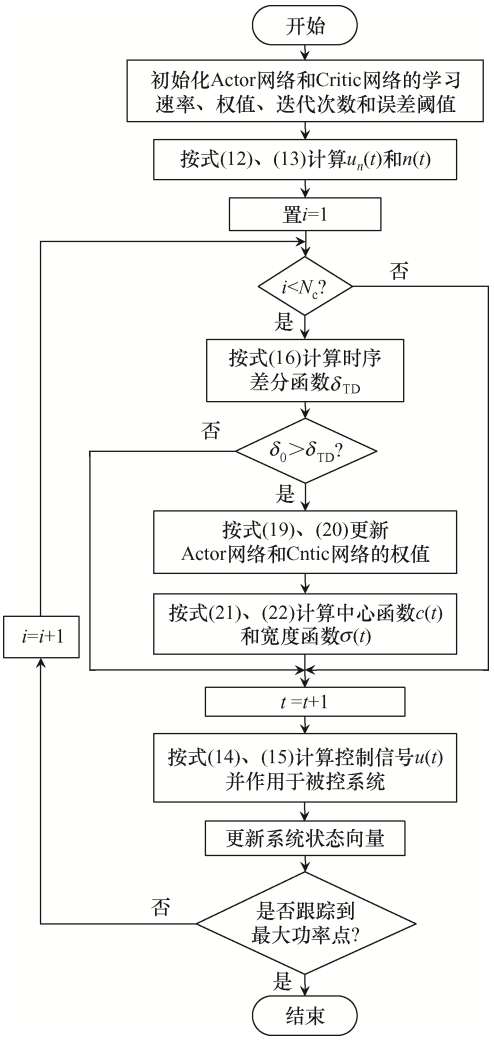


图 5　AC 强化学习的流程

Fig. 5 Flow chart of AC reinforcement learning

图 5 中：i 为计数器，从 1 开始；N_c 为循环的最大次数；δ_0 为一个 0~1 之间的正数，是可根据不同控制场景选择的常数，如 0.02 或 0.05。

4 仿真结果分析

为验证基于强化学习的 MPPT 控制策略的有效性，在 MATLAB/Simulink 建立了光伏 MPPT 仿真模型。选用 540 W 光伏组件，其光伏电池的参数配置见表 1。

表 1 光伏电池电气参数

Tab. 1 Electrical parameters of PV cells

光伏电池参数	数值
短路电流 I_{sc}/A	13.63
最大功率点电流 I_m/A	13.17
开路电压 U_{oc}/V	49.63
最大功率点电压 U_m/V	41.03
最大功率 P_m/W	540
光伏电池串联数量 N_S	25
光伏电池并联数量 N_P	20
参考光照强度 S_{ref}/(W/m^2)	1 000

RBF 神经网络的隐含层神经元个数为 6，Actor 网络中 η_a 为 0.05，Critic 网络中 η_c 为 0.05，隐含层节点中心函数初始值 $\boldsymbol{c}(t)$=[1 0 0 0 0 0]，宽度函数初始值 $\delta(t)$=[1 1 1 1]，$\boldsymbol{c}(t)$更新时 β_1 为 0.02，$\sigma(t)$更新时 β_2 为 0.02。

4.1 光照辐射度快速变化分析

在温度不变情况下，当 t=0.16 s 时，光照强度从 1 000 W/m^2 下降到 600 W/m^2；当 t=0.32 s 时，光照强度从 600 W/m^2 增加到 800 W/m^2。光照强度快速变化时基于 RBF 神经网络与 AC 强化学习的光伏电池阵列功率、端电压的输出响应曲线分别如图 6、图 7 所示。

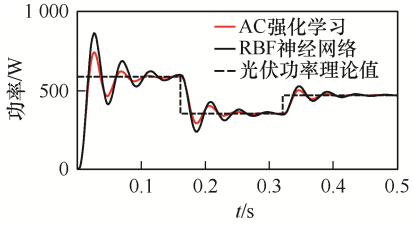


图 6 温度不变情况下光照强度快速变化时光伏电池阵列功率输出响应曲线

Fig. 6 Power output response curves for PV cell array under rapid changes in solar irradiance and constant temperature

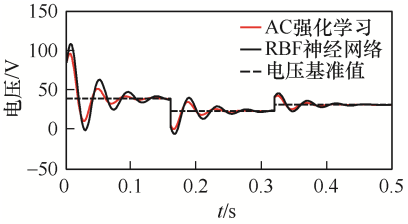


图 7 温度不变情况下光照强度快速变化时光伏电池阵列端电压输出响应曲线

Fig. 7 Voltage output response curves for PV cell array terminal under rapid changes in solar irradiance and constant temperature

由图 6 和图 7 可见，在 t=0.16 s 时光照强度从 1 000 W/m^2 下降到 600 W/m^2，采用 AC 强化学习 MPPT 使得光伏发电系统在 t=0.27 s 时跟踪到最大功率点，而采用 RBF 神经网络控制在 t=0.30 s 时才能够跟踪到最大功率点，并且前者控制的超调量明显更低。

4.2 局部遮阴分析

假设温度为 25 ℃。在 t=0 s 时，光照强度从 0 W/m^2 上升到 1000 W/m^2；在 t=0.2 s 时，有部分光伏电池模板受到遮阴的影响。光伏电池阵列的功率和端电压输出响应曲线分别如图 8 和图 9 所示。

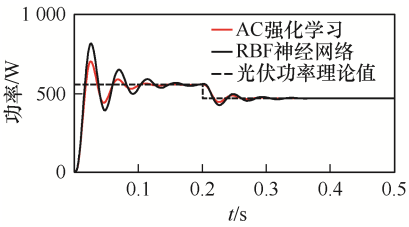


图 8 有遮阴时光伏电池阵列功率输出响应曲线

Fig. 8 Power output response curves for PV cell array with shading

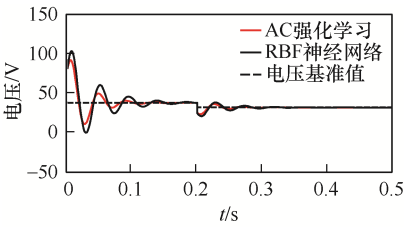


图 9 有遮阴时光伏电池阵列端电压输出响应曲线

Fig. 9 Voltage output response curves for PV cell array terminal with shading

由图 8 和图 9 可见，当部分光伏电池模板受到遮阴影响后，光伏电池输出的功率和端电压都会下

降；采用 AC 强化学习控制后，在 t=0.25 s 会跟踪到新的最大功率点，而采用 RBF 神经网络控制则需要在 t=0.30 s 跟踪到最大功率点；同时，前者控制的光伏发电系统功率响应的超调量更小一些。

总之，从光照强度快速变化和有遮阴 2 种仿真结果可见，采用 RL-MPPT 能够快速、准确地跟踪到最大功率点，并且功率和端电压响应的超调量更小，可以满足光伏发电系统 MPPT 控制的要求，在各种极端天气情况下有效减少光伏发电对电网的不利影响。

5　结语

由于传统的扰动观察法和电导增量法难以快速准确跟踪到光伏发电的最大功率点，本文提出采用强化学习的光伏发电系统 MPPT 控制器。通过光照辐射度快速变化和局部遮阴的仿真实验表明，所设计的 RL-MPPT 能够适应不同的天气状况，在较短时间内使得光伏发电系统稳定在最大功率点，具有收敛速度快、控制精度高以及鲁棒性强等特点。所提强化学习算法在光伏发电系统 MPPT 控制中具有较好的应用前景。

参考文献：

[1] 庄贵阳，窦晓铭. 新发展格局下碳排放达峰的政策内涵与实现路径[J]. 新疆师范大学学报(哲学社会科学版), 2021, 42(6): 124-133.
Zhuang Guiyang, Dou Xiaoming. Policies on peaking carbon emissions and their implementation in the new development pattern [J]. Journal of Xinjiang Normal University (Philosophy and Social Sciences), 2021, 42(6): 124-133. (in Chinese)

[2] 马昊，张庆超. 基于粒子群优化算法和变步长扰动观察法的局部阴影情况下 MPPT 控制[J]. 电源学报, 2016, 14(3): 94-101.
Ma Hao, Zhang Qingchao. MPPT control under partial shading condition based on PSO and variable step size P & O [J]. Journal of Power Supply, 2016, 14(3): 94-101. (in Chinese)

[3] 莫仕勋，蒋坤坪，杨皓，等. 基于旗鱼优化算法与扰动观察法复合控制的最大功率点跟踪策略[J]. 电源学报, 2024, 22(6): 110-121.
Mo Shixun, Jiang Kunping, Yang Hao, et al. Maximum power point tracking strategy based on hybrid control of sailfish optimization algorithm and perturbation and observation method [J]. Journal of Power Supply, 2024, 22(6): 110-121. (in Chinese)

[4] 魏立明，吴扬昀. 基于改进电导增量法的光伏 MPPT 策略研究[J]. 电源技术, 2021, 45(6): 791-796.
Wei Liming, Wu Yangyun. Research on maximum power point tracking of photo-voltaic power system based on improved conductance increment method [J]. Chinese Journal of Power Sources, 2021, 45(6): 791-796. (in Chinese)

[5] 毛琳，任正云. 基于变步长不完全偏微分电导增量法的 MPPT 控制[J]. 电源学报, 2025, 23(2): 125-132, 187.
Mao Lin, Ren Zhengyun. MPPT control based on variable step size incomplete partial differential incremental conductance method [J]. Journal of Power Supply, 2025, 23(2): 125-132, 187. (in Chinese)

[6] 李恒杰，李治廷，陈伟，等. 基于改进 P&O 与 MPC 算法的光伏 MPPT 控制研究[J]. 电源技术, 2019, 43(11): 1843-1846.
Li Hengjie, Li Zhiting, Chen Wei, et al. MPPT control research based on an improved P & O and MPC algorithm [J]. Chinese Journal of Power Sources, 2019, 43(11): 1843-1846. (in Chinese)

[7] 郑启，王归新，李明浩，等. 基于改进滑模控制的光伏最大功率点跟踪技术[J]. 电气传动, 2020, 50(1): 72-76.
Zheng Qi, Wang Guixin, Li Minghao, et al. PV maximum power point tracking technology based on improved sliding mode control [J]. Electric Drive, 2020, 50(1): 72-76. (in Chinese)

[8] 花赟昊，朱武，靳一奇，等. 基于自适应变异粒子群算法的光伏 MPPT 控制研究[J]. 太阳能学报, 2022, 43(4): 219-225.
Hua Yunhao, Zhu Wu, Jin Yiqi, et al. Research on photovoltaic mppt control based on adaptive mutation particle swarm optimization algorithm [J]. Acta Energiae

Solaris Sinica, 2022, 43(4): 219-225. (in Chinese)

[9] Rai A K, Kaushika N D, Singh B, et al. Simulation model of ANN based maximum power point tracking controller for solar PV system [J]. Solar Energy Materials and Solar Cells, 2011, 95(2): 773-778.

[10] 刘秋华, 张秀锦, 樊陈. 基于功率差变步长扰动观察法的 MPPT 控制算法[J]. 电源技术, 2020, 44(7): 1035-1039.
Liu Qiuhua, Zhang Xiujin, Fan Chen. MPPT control algorithm based on power difference variable step-size disturbance observation method [J]. Chinese Journal of Power Sources, 2020, 44(7): 1035-1039. (in Chinese)

[11] 庞科旺, 刘维亭. 基于改进人工鱼群算法的光伏系统 MPPT 研究[J]. 太阳能学报, 2014, 35(10): 2009-2014.
Pang Kewang, Liu Weiting. MPPT study of solar PV power system based on improved artificial fish-swarm algorithm [J]. Acta Energiae Solaris Sinica, 2014, 35(10): 2009-2014. (in Chinese)

[12] Alajmi B N, Ahmed K H, Finney S J, et al. Fuzzy-logic-control approach of a modified hill-climbing method for maximum power point in microgrid standalone photovoltaic system [J]. IEEE Transactions on Power Electronics, 2011, 26(4): 1022-1030.

[13] 王福忠, 裴玉龙. 光伏阵列故障类型的改进型 RBF 神经网络识别算法[J]. 电源学报, 2019, 17(1): 73-79.
Wang Fuzhong, Pei Yulong. Photovoltaic array fault identification algorithm based on improved RBF neural network [J]. Journal of Power Supply, 2019, 17(1): 73-79. (in Chinese)



于来宝

作者简介：

于来宝(1984—)，男，通信作者，博士研究生，讲师。研究方向：电力系统自动控制。E-mail：328426165@qq.com。

谢兴旺(1973—)，男，博士，讲师。研究方向：人工智能。E-mail：sivan_xie@163.com。

(责任编辑：陈国珍)