DOI: 10.19783/j.cnki.pspc.201086

阴影条件下基于集体智慧的光伏系统最大功率跟踪

胡依林[1]，成 奎[2]，杨 博[3]

(1. 宜宾学院中德工程学院，四川 宜宾 644000；2. 宜宾学院三江人工智能与机器人研究院，四川 宜宾 644000；
3. 昆明理工大学电力工程学院，云南 昆明 650500)

摘要：光伏阵列通常受局部阴影的影响，导致系统输出功率较低。这主要归咎于光伏阵列的功率-电压特性曲线在阴影条件下具有多个功率峰值，而常规最大功率跟踪算法易陷入局部最优。设计了一种新颖的 MPPT 算法，即基于动态领导的集体智慧。与传统启发式算法不同，该算法由多个子优化器组成，每个优化器同时进行全局寻优，并选择适应度函数最小(最优解)的子优化器作为其他子优化器的领导者进行后续引导。三种算例(恒定气候条件、时变气候条件和大型光伏电站)下的 Matlab/Simulink 仿真结果显示，所提算法与导纳增量控制法和其余五种经典的启发式算法相比，DLCI 能在 PSC 下实现最快速与稳定的全局最大功率跟踪。最后，基于 dSpace 的硬件在环实验验证了所提算法的硬件实施可行性。

关键词：光伏系统；基于动态领导的集体智慧；阴影条件；最大功率跟踪；硬件在环实验

Collective intelligence-based maximum power point tracking of PV systems under partial shading condition

HU Yilin[1], CHENG Kui[2], YANG Bo[3]

(1. Sino German Institute of Engineering, Yibin University, Yibin 644000, China;
2. Sanjiang Institute of Artificial Intelligence and Robotics, Yibin University, Yibin 644000, China;
3. Faculty of Electric Power Engineering, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: PV arrays are usually affected by a partial shading condition, which leads to a relatively low power production. This is because the power-voltage curve of a PV system contains multiple peaks while the traditional Maximum Power Point Tracking (MPPT) algorithm is easily trapped at the Local Maximum Power Point (LMPP). Hence, a novel MPPT approach is provided, i.e., Dynamic Leader-based Collective Intelligence (DLCI). Unlike traditional meta-heuristic algorithms, this algorithm has a multiple sub-optimizer which seeks the optimum independently. Then, the current best optimum will be chosen as the dynamic leader to guide the other sub-optimizers thereafter. Three case studies are carried out, i.e., constant climate conditions, varying climate conditions, and a large-scale photovoltaic station. Simulation outcomes of Matlab/Simulink prove that DLCI outperforms the traditional Incremental Conductance (INC) and five other typical meta-heuristic algorithms. It can achieve the fastest and most stable global MPPT. Lastly, a dSpace based Hardware-In-the-Loop (HIL) test is carried out to validate the implementation feasibility of the DLCI algorithm.

This work is supported by the National Natural Science Foundation of China (No. 61963020).

Key words: PV systems; dynamic leader based collective intelligence; partial shading condition; maximum power point tracking; hardware-in-loop

0 引言

随着时代的发展，环境污染和能源危机日益加剧。自 21 世纪以来，优化能源结构、提高能源效率、发展可再生能源已成为世界各国可持续发展的关键[1-3]。其中，太阳能以其无噪声、无污染、分布广泛等优点越来越受到重视。光伏板作为光伏系统的重要组成部分，是整个光伏系统的能量来源，但光伏板的功率输出主要由外界温度与光照强度决定[4-6]。有效的最大功率跟踪(Maximum Power Point Tracking, MPPT)策略，可提高光伏系统的发电效率[7-10]。目前，爬山法[11]和导纳增量控制法(Incremental

基金项目：国家自然科学基金项目资助(61963020)

Conductance, INC)[12]是传统的MPPT算法，具有结构简单、易于实现等优点，在均匀光照强度下可获得满意的控制性能。

但是，由于周围房屋、云层或是鸟类活动遮挡等因素，光伏系统受到的光照强度往往不均匀。这种情况下，易出现“热斑效应”现象，影响光伏系统的安全运行[13-14]。为减小此现象的危害，常在光伏系统中加入旁路二极管，但这也使得整个输出伏安特性曲线呈阶梯状，相应的功率-电压曲线则产生多个局部峰值[15]。上述传统MPPT算法无法有效地识别局部最大功率点与全局最大功率点，因此，难以在PSC下获得满意的功率输出性能。

近年来，各国学者提出了各类先进的MPPT算法来解决阴影条件下(Partial Shading Condition, PSC)的全局最大功率跟踪问题。文献[16]设计了模糊逻辑控制器(Fuzzy Logic Controller, FLC)以实现MPPT，通过遗传算法(Genetic Algorithm, GA)对其函数和控制策略进行优化设计；文献[17]提出了粒子群优化算法(Particle Swarm Optimization, PSO)来有效地实现全局最大功率点(Global Maximum Power Point, GMPP)的跟踪；文献[18]设计了一种蚁群优化算法(Ant Colony Optimization, ACO)，其算法参数少且收敛迅速；文献[19]采用布谷鸟搜索算法(Cuckoo Search Algorithm, CSA)，通过Lévy飞行加速收敛，从而快速寻找GMPP；文献[20]中，利用鲸鱼优化算法(Whale Optimization Algorithm, WOA)的快速收敛性和无振荡等优点在PSC下实现MPPT，所需调节的算法参数少且计算量较小；在文献[21]中，采用蛙跳算法(Shuffled Frog Leap Algorithm, SFLA)有效地识别了PSC下的GMPP；另外，文献[22]应用了灰狼算法(Grey Wolf Optimizer, GWO)在PSC下的光伏系统，其具有快速的GMPP识别速度。但是上述启发式算法的功率波动较大、寻优速度较低。

集体智慧(Collective Intelligence, CI)[23]是一种群体智能。它的主要优势在于通过全局智能行为(合作或竞争)，得到各个个体间最优的协调与合作。本文提出一种新颖的MPPT算法，即基于动态领导的集体智慧(Dynamic Leader based Collective Intelligence, DLCI)，该算法用于PSC下光伏系统的MPPT。DLCI结合了多个子优化器的搜索机制并同时进行寻优搜索，选择适应度函数最小的子优化器作为领导者，对其他子优化器进行后续引导。因此，DLCI具有收敛速度快、振荡小等优点。最后，基于Matlab/Simulink的仿真实验对DLCI与其他经典MPPT算法进行了三种算例下的对比，并在dSpace的硬件在环实验(Hardware-in-Loop, HIL)中对所提算法的硬件实施可行性进行了验证。

1　基于阴影条件下光伏系统模型

1.1　光伏电池模型

图 1 为常见的光伏系统示意图，输出电流和电压的数学表达式为

$$I_{\mathrm{PV}} = N_{\mathrm{P}} I_{\mathrm{g}} - N_{\mathrm{P}} I_{\mathrm{s}} \left(\exp\left[\frac{q}{AKT_{\mathrm{c}}} \left(\frac{V_{\mathrm{PV}}}{N_{\mathrm{s}}} + \frac{R_{\mathrm{s}} I_{\mathrm{PV}}}{N_{\mathrm{P}}} \right) \right] - 1 \right) \tag{1}$$

其中，光生电流 I_{g} 为

$$I_{\mathrm{g}} = \left(I_{\mathrm{SC}} + k_i \left(T_{\mathrm{C}} - T_{\mathrm{ref}} \right) \right) \frac{s}{1000} \tag{2}$$

饱和电流 I_{s} 为

$$I_{\mathrm{s}} = I_{\mathrm{RS}} \left[\frac{T_{\mathrm{C}}}{T_{\mathrm{ref}}} \right]^3 \exp\left[\frac{qE_{\mathrm{g}}}{Ak} \left(\frac{1}{T_{\mathrm{ref}}} - \frac{1}{T_{\mathrm{C}}} \right) \right] \tag{3}$$

式(1)—式(3)中各变量命名见参考文献[24]。

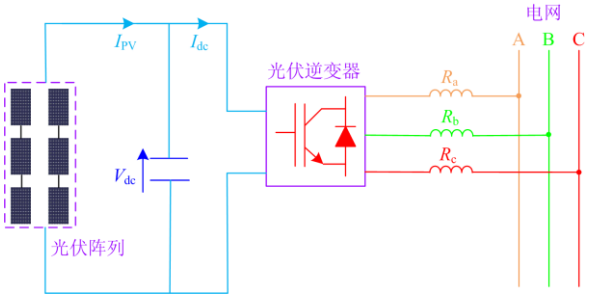

图 1　光伏系统示意图

Fig. 1 Configuration of PV system

1.2　阴影现象

光伏系统常因房屋、云层或鸟类活动的遮挡从而使光伏阵列受到光照强度不均匀产生局部阴影现象，导致功率失配问题[25]。为此，需在光伏系统结构中加入旁路二极管以削弱功率失配导致的“热斑效应”。图2(a)为光伏阵列未遮挡运行图，图2(b)为光伏阵列遮挡后不同光照强度下的运行图，特别地，受阴影影响的光伏电池上的电压由式(4)决定：

$$V_{\text{反向}} = nV_{\mathrm{OC}} + V_{\text{二极管}} \tag{4}$$

式中，n 代表未被旁路二极管屏蔽的光伏电池数量。

通常来说，旁路二极管可以保护光伏电池，同时也会减少获得的太阳能。此外，光伏板短路电流低于被二极管分流后的串电流，因此功率-电压特性曲线中将会出现多个局部最大功率点，如图2(c)所示。因此，需控制光伏系统在全局最大功率点处运行以获取最多的太阳能。

2　基于动态领导的集体智慧

2.1　子优化器选取

DLCI 由多个子优化器组成，其优化框架如图 3 所示，每个子优化器可以选择任意算法，而子优化器的数量及参数则根据特定的优化问题来决定。通常，由于搜寻的多样性，子优化器数量越多，获得的最优解的质量也越高，同时也会相应地增加计算时间。为了平衡最优解质量与搜索效率，本文选取了五个群体智能算法，包括 GWO[26]、WOA[27]、飞蛾扑火算法(Moth-Flame Optimization, MFO)[28]、人工蜂群算法(Artificial Bee Colony, ABC)[29]和 PSO[30]作为 PSC 下 DLCI 的子优化器以实现光伏系统的 MPPT。每个子优化器的主要运行机制介绍如下。

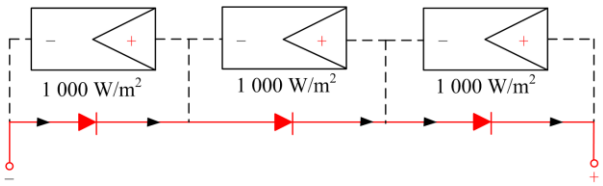

(a) 无阴影情况下光伏阵列示意图

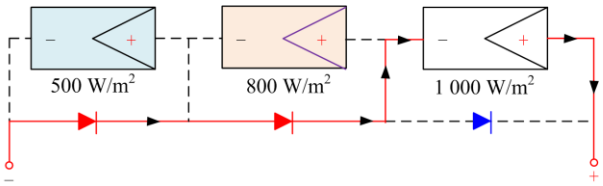

(b) 有阴影情况下光伏阵列示意图

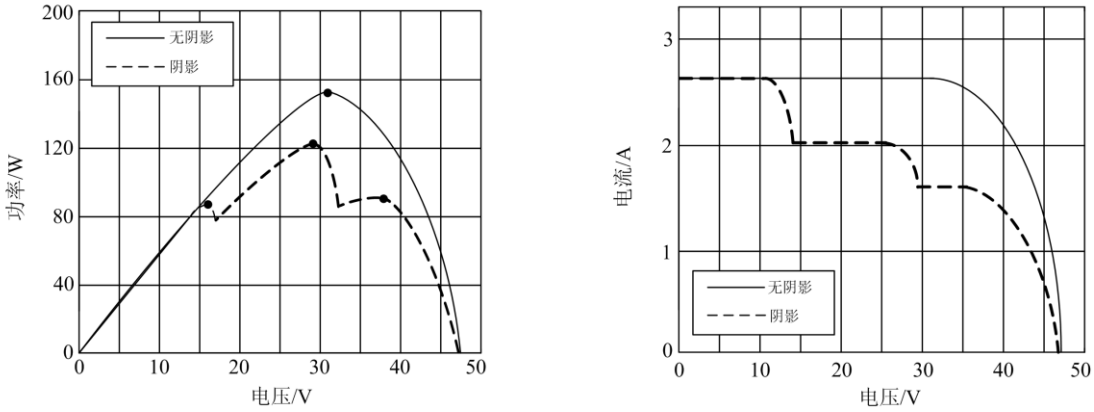

(c) 阴影条件下光伏阵列输出特性图

图 2　正常条件和阴影条件下光伏阵列示意图及输出特性曲线

Fig. 2 Output curve and schematic diagram of the PV array under uniform and PSC conditions

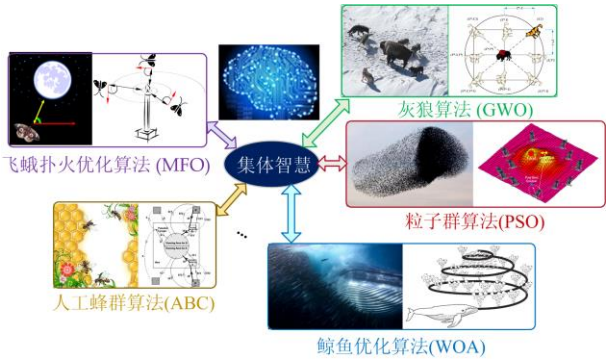

图 3　DLCI 的优化框架

Fig. 3 Optimization framework of DLCI

(1) 灰狼算法(GWO)：该算法模拟灰狼的捕食行为，根据领导层次将包围、追捕、攻击等捕食任务分配给不同等级的灰狼来完成。将灰狼划分成四个不同等级角色：α、β、δ 和 Ω。其中，前三个等级的狼是占统治地位的狼，Ω 代表随机搜索的狼。为了模拟灰狼的捕猎行为，我们假设最佳候选解 α、β、δ 对猎物的潜在位置有更好的了解，其他狼 Ω 将根据最佳候选解的位置更新其位置[26]，如式(5)—式(7)所示。

$$\begin{cases} \vec{D}_\alpha = \left|\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}\right| \\ \vec{D}_\beta = \left|\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}\right| \\ \vec{D}_\delta = \left|\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}\right| \end{cases} \tag{5}$$

$$\begin{cases} \vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot \left(\vec{D}_\alpha\right) \\ \vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot \left(\vec{D}_\beta\right) \\ \vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot \left(\vec{D}_\delta\right) \end{cases} \tag{6}$$

$$\vec{X}_\Omega(k+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \tag{7}$$

式中：k代表迭代次数；$\vec{A}_1$、$\vec{A}_2$、$\vec{A}_3$、$\vec{C}_1$、$\vec{C}_2$和$\vec{C}_3$均为系数矢量；$\vec{X}_\alpha$、$\vec{X}_\beta$、$\vec{X}_\delta$分别代表α狼、β狼和δ狼的位置矢量；$\vec{X}_\Omega$代表其他灰狼的位置矢量。

(2) 鲸鱼优化算法(WOA)：该算法模拟座头鲸在海洋中捕食行为，座头鲸围绕猎物沿螺旋路径移动，同时吐出气泡产生陷阱，即气幕捕鱼(bubble-net feeding)策略，在捕食过程中，座头鲸以 50%的概率选择收缩捕食圆圈和螺旋气泡方式更新个体位置，如式(8)、式(9)[27]。

$$\begin{cases}\vec{D}=\left|\vec{C}\cdot\overrightarrow{X^*}(k)-\vec{X}(k)\right|\\ \vec{D}'=\left|\overrightarrow{X^*}(k)-\vec{X}(k)\right|\end{cases}\tag{8}$$

$$\vec{X}(k+1)=\begin{cases}\overrightarrow{X^*}(k)-\vec{A}\cdot\vec{D}, & p<0.5\\ \vec{D}'\cdot e^{bl}\cdot\cos(2\pi l)+\overrightarrow{X^*}(k), & p\geqslant 0.5\end{cases}\tag{9}$$

式中：$\vec{A}$和$\vec{C}$为系数矢量；$\overrightarrow{X^*}(k)$为第 k 次迭代中最优鲸鱼位置矢量；$\vec{X}$ 代表第 k 次迭代中鲸鱼位置矢量；常数 b，用于定义螺旋线形状；l 为[−1, 1]之间的随机数；p 为[0, 1]之间的随机数。

(3) 飞蛾扑火优化算法(MFO)：该算法模拟飞蛾在趋向光源的飞行方式，即横向定位机制。飞蛾位置的更新机制选取为对数螺旋线，如式(10)、式(12)[28]。

$$N_{\mathrm{f}}(k)=\mathrm{round}\left(N_{\mathrm{f}}^{\max}-k\cdot\frac{N_{\mathrm{f}}^{\max}-1}{k_{\max}}\right)\tag{10}$$

$$\vec{D}_i=\left|\vec{F}_j(k)-\vec{X}_i(k)\right|\tag{11}$$

$$\vec{X}_i(k+1)=\vec{D}_i\cdot e^{bl}\cdot\cos(2\pi l)+\vec{F}_j(k)\tag{12}$$

式中：N_{f} 为火焰的数量；$N_{\mathrm{f}}^{\max}$ 代表火焰数量最大值；$k_{\max}$ 代表最大迭代次数；$\vec{F}_j$ 为第 j 个火焰的位置矢量；$\vec{X}_i$ 为第 i 个飞蛾的位置矢量。

(4) 人工蜂群算法(ABC)：该算法模拟蜂群采蜜行为，将蜂群分为三组，包括引领峰、跟随峰和侦察峰，搜索最优蜜源过程如下[29]。

首先，引领峰对领域蜜源(领域解)搜索，产生新蜜源(较优解)，如式(13)。

$$\vec{X}_{id}(k+1)=\vec{X}_{id}(k)+\Phi_{id}\left(\vec{X}_{id}(k)-\vec{X}_{hd}(k)\right)\tag{13}$$

式中：$\vec{X}_{id}$ 为第 i 只蜜蜂的第 d 维位置；d 为随机选择的维度；$h(h\neq i)$ 代表蜂群中随机选择的蜜蜂；Φ_{id} 代表[−1, 1]中均匀分布的随机数。

跟随峰根据引领峰分享的蜜源信息进行领域搜索，根据信息选择下一蜜源，第 i 只蜜蜂被选择的概率为

$$p_i(k)=0.9\times\frac{\max\limits_{j=1,2,\cdots,N}f_j(k)-f_i(k)}{\max\limits_{j=1,2,\cdots,N}f_j(k)-\min\limits_{j=1,2,\cdots,N}f_j(k)}+0.1\tag{14}$$

式中：f_i 代表第 i 只蜜蜂的适应度函数；N 代表种群数量。

在确定目标蜜源后，每只跟随蜂可以根据式(13)来更新自己的位置。此外，如果一只蜜蜂在预设的迭代次数中耗尽了一个蜜源，则相应的蜜蜂将被视为用于随机搜索的侦察蜂，侦察蜂搜索策略如式(15)。

$$\vec{X}_i(k+1)=\overrightarrow{X^{\min}}+r\cdot\left(\overrightarrow{X^{\max}}-\overrightarrow{X^{\min}}\right)\tag{15}$$

式中：$\overrightarrow{X^{\min}}$ 和 $\overrightarrow{X^{\max}}$ 分别是最小和最大位置矢量；r 是[0, 1]中的随机数。

(5) 粒子群算法(PSO)：本算法模拟鸟类寻找食物的过程，每只鸟都是粒子群中的一个粒子，每次迭代中，各粒子按照如下公式更新自己的速度和位置[24]。

$$\begin{aligned}\vec{V}_i(k+1)=\omega\vec{V}_i(k)+c_1r_1\left(\vec{P}_i(k)-\vec{X}_i(k)\right)+\\ c_2r_2\left(\vec{G}(k)-\vec{X}_i(k)\right)\end{aligned}\tag{16}$$

$$\vec{X}_i(k+1)=\vec{X}_i(k)+\vec{V}_i(k+1)\tag{17}$$

式中：$\vec{V}_i$ 为第 i 个粒子的速度矢量；ω 代表惯性权重；c_1 和 c_2 代表学习因子；r_1 和 r_2 代表[0,1]中的随机数；$\vec{P}_i$ 为第 i 个粒子的个体最佳位置；$\vec{G}$ 为整个群体的全局最佳位置。

2.2 基于动态领导的引导策略

为了提高 DLCI 的收敛性，引入基于动态领导的引导策略以实现各子优化器之间的有效合作。首先，选取当前拥有最优解的子优化器作为动态领导者，如式(18)所示。

$$L=\arg\max_{o=1,2,\cdots,n}f_o^{\mathrm{best}}(k)\tag{18}$$

式中：L 代表动态领导者；$f_o^{\mathrm{best}}(k)$ 为第 o 个子优化器在第 k 次迭代中得到最优解的适应度函数；n 代表子优化器的数量。

当选择一个子优化器作为动态领导后，它会把当前获得的最优解和对应的适应度函数传递给其他子优化器，如图 4 所示。随后，其他子优化器将会用该个最优解来代替其自身当前最优解并继续迭代。但是，过于频繁地执行引导策略会降低 DLCI 算法的效率与稳定性。因此，本文设置子优化器分别进行三次迭代后执行一次引导策略，即

$$\vec{X}_o^{\mathrm{worst}}(k)=\begin{cases}\vec{X}_{\mathrm{L}}^{\mathrm{best}}(k), & \dfrac{k}{3}\in Z\\ \vec{X}_o^{\mathrm{worst}}(k), & \text{其他}\end{cases}\tag{19}$$

式中：$\overline{X}_o^{\text{worst}}(k)$ 为第 k 次迭代中第 o 个子优化器得到的较差解；$\overline{X}_{\text{L}}^{\text{best}}(k)$ 为第 k 次迭代中动态领导者得到的最优解；Z 为所有整数的集合。

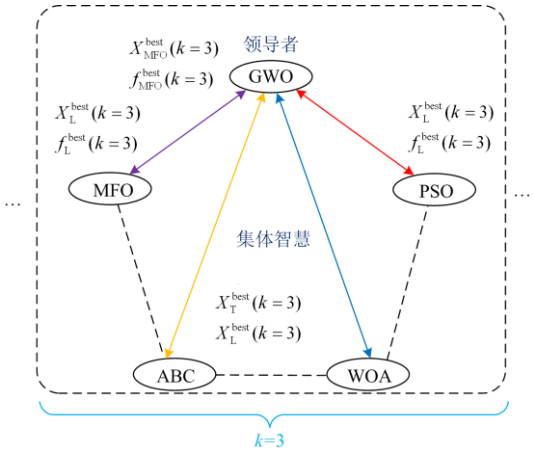

图 4 基于动态领导的引导策略示意图

Fig. 4 Dynamic leader based guidance strategy

3 阴影条件下基于 DLCI 的光伏系统 MPPT 设计

光伏系统的目标是实现有功功率最大化，PSC 下的 MPPT 优化模型可以描述为

$$\min f(V_{\text{PV}}) = -P_{\text{out}}(V_{\text{PV}}) = -V_{\text{PV}} \cdot I_{\text{PV}}(V_{\text{PV}}) \tag{20}$$

$$\text{s.t.}\quad V_{\text{PV}}^{\min} \leqslant V_{\text{PV}} \leqslant V_{\text{PV}}^{\max} \tag{21}$$

式中：P_{out} 为光伏系统有功功率；$V_{\text{PV}}^{\min}$ 和 $V_{\text{PV}}^{\max}$ 分别为光伏系统的最小和最大输出电压；I_{PV} 为光伏系统输出电流。PSC 下光伏系统 MPPT 的 DLCI 算法流程图如图 5 所示。值得注意的是，该方法不需要平衡多种决策结果，仅需将每次最好的个体筛选出来，返回到各个算法中进行迭代寻优即可，结构简单，易于实现。

4 算例分析

本章基于 Matlab/Simulink 软件，进行了恒定气候条件、时变气候条件和大型光伏电站三个算例，以评估 PSC 下 DLCI、INC[12]、PSO[30]、ABC[29]，MFO[28]、GWO[26]、WOA[27]的 MPPT 性能。将种群大小 $N=8$ 和最大迭代次数 $k_{\max}=10$ 设为一致，额定光照强度和温度分别设定为 1 000 W/m^2 和 25 ℃。此外，光伏系统参数见参考文献[31]。

4.1 恒定气候条件

为了模拟阴影效果，三个光伏阵列的光照强度分别选择为 1 000 W/m^2、200 W/m^2 和 300 W/m^2。图 6 是恒定气候条件下 7 种算法的优化结果。相比

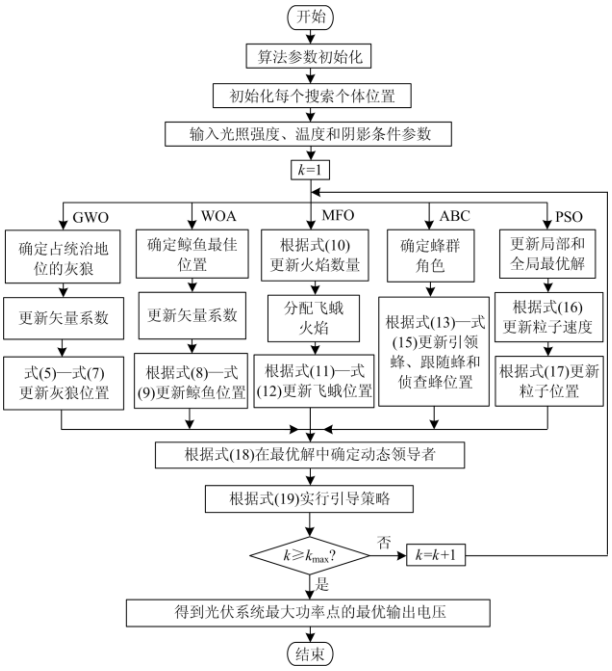

图 5 光伏系统 MPPT 的 DLCI 算法流程图

Fig. 5 Overall execution procedure of DLCI for MPPT of PV system

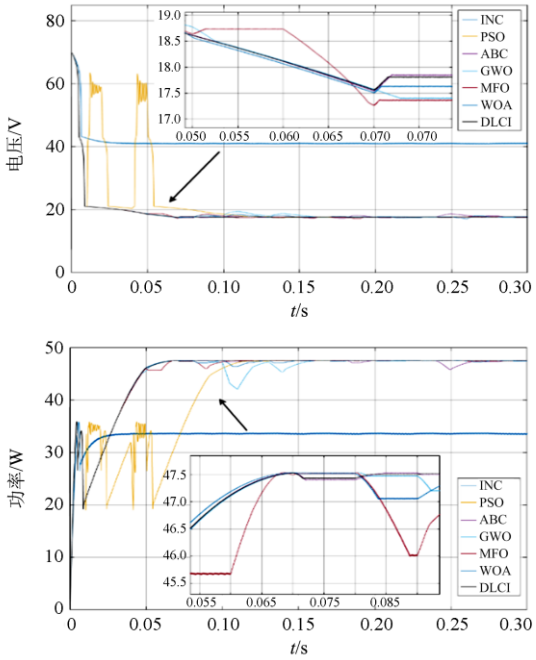

图 6 恒定气候条件下 7 种算法的优化结果

Fig. 6 Optimization outcomes of seven algorithms obtained under the constant climate conditions

其他算法，INC 能够在较短时间内收敛到稳定点。但是，它易陷入局部最优。其他启发式算法的光伏模块输出电压和功率均呈现振荡，相比之下，DLCI

具有最平稳的收敛效果。因此，它能更精确地跟踪 GMPP。这是由于集体智慧可极大地提高全局搜索能力和收敛稳定性，而基于动态领导的引导策略则可显著提高局部搜索能力。

4.2 时变气候条件

模拟光照强度和温度随机变化，如图 7 所示。图 8 为 7 种算法在时变气候条件下的优化结果。可以发现，DLCI 可以通过更广泛的全局搜索和更深度的局部探索来显著降低光伏系统的功率波动，并实现最快速的收敛。

4.3 大型光伏电站

本算例基于云南省红河州建水南庄并网光伏电站的实测数据进行了 7 种 MPPT 算法的仿真。建水南庄光伏电站位于建水县南庄镇坝埂脚村东侧，距离建水县约 17.5 km。该电站于 2016 年 6 月全部建成投产，占地 8 530 亩，装机容量 300 MW，系统效率 80.4%。

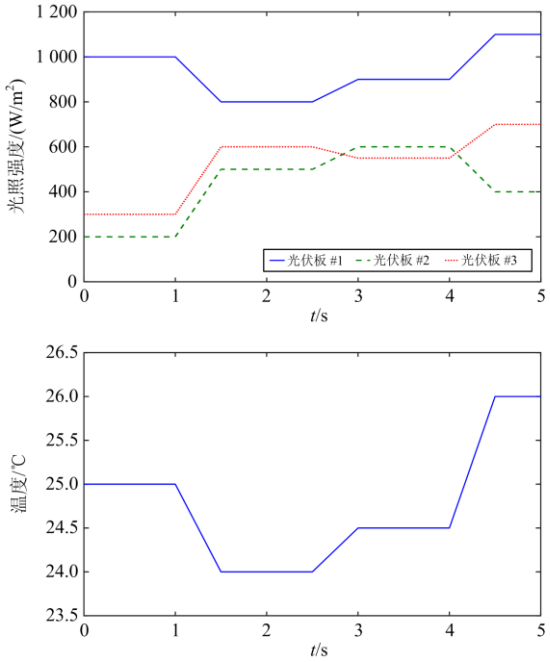

图 7 时变气候条件测试数据

Fig. 7 Testing data of varying climate conditions

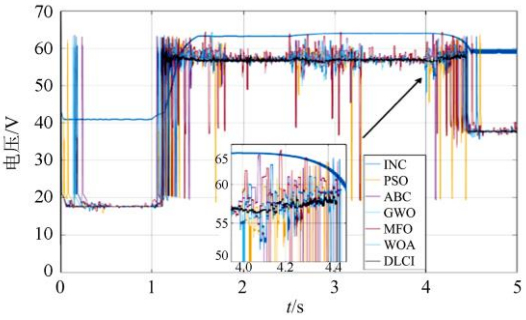

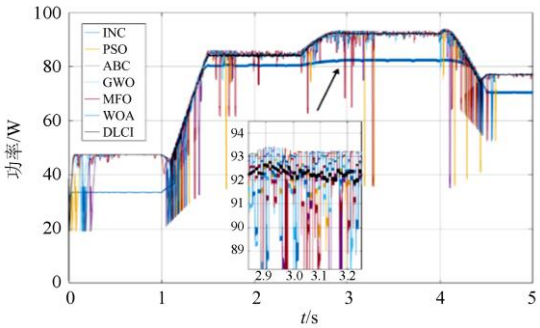

图 8 时变气候条件下 7 种算法的优化结果

Fig. 8 Optimization outcomes of seven algorithms obtained under the varying climate conditions

场址地理坐标介于北纬 23°43′35″～23°46′29″、东经 102°55′02″～102°56′54″。周边无高大山体遮挡，年水平面太阳总辐射量 5 756 MJ/m²。其详细的地理位置如图 9 所示。

图 9 建水南庄并网光伏电站地理位置图

Fig. 9 Geographical position of the grid-connected photovoltaic station in Nanzhuang, Jianshui

本算例仿真数据选自建水南庄光伏电站 2019 年 7 月 21 日的实时环境数据，数据记录间隔为 10 min。建水南庄光伏电站共有 A1、A2、A3、A4、A5、B1、B2、B3、B4 和 B5 10 个光伏发电区，其中每个区配置 30 个 1 MW 的光伏方阵。为模拟 PSC 条件，选择 A1 区的光伏方阵 #1~#8 作为实验对象，将光伏方阵 #1~#4 光照强度设置为无遮挡，光伏方阵 #5~#7 光照强度设置为 80%遮挡，光伏方阵 #8 光照强度设置为 50%遮挡，所得到的光照强度和温度数据如图 10 所示。

图 11 给出了建水南庄并网光伏电站实测数据下，7 种 MPPT 算法的电压和功率优化结果。可以看出，启发式算法可以输出比 INC 更高的功率。同时，由表 1 可知，DLCI 的功率波动明显小于其他算法，其功率平均波动度分别仅为 INC、PSO、ABC、GWO、MFO 和 WOA 的 34.34%、63.70%、82.48%、48.86%、59.20%和 95.07%。

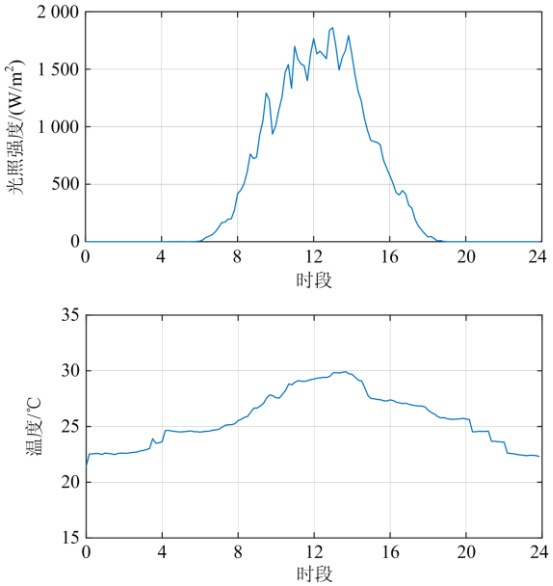

图 10 2019 年 7 月 21 日建水南庄并网光伏电站的实测数据

Fig. 10 Testing data obtained in the grid-connected photovoltaic station in Nanzhuang, Jianshui on July 21, 2019

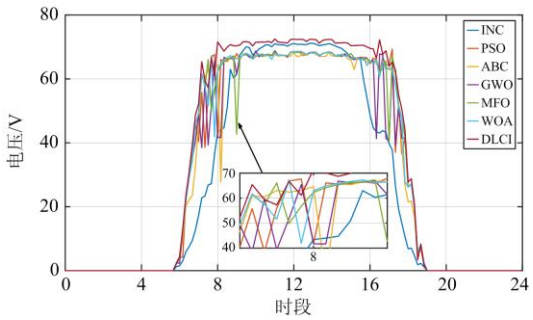

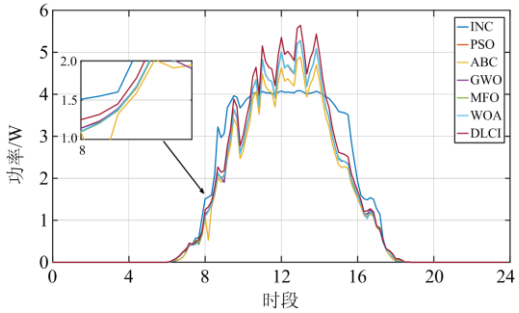

图 11 2019 年 7 月 21 日建水南庄并网光伏电站实测数据下 7 种算法的优化结果

Fig. 11 Optimization outcomes of seven algorithms obtained on testing data of the grid-connected photovoltaic station in Nanzhuang, Jianshui on July 21, 2019

4.4 统计分析

为了定量评估光伏系统的功率波动，在算例研究中引入如下两个指标，如式(22)。

$$\begin{cases} \Delta v^{\text{avg}} = \dfrac{1}{T-1}\sum_{t=2}^{T}\dfrac{\left|P_{\text{out}}(t)-P_{\text{out}}(t-1)\right|}{P_{\text{out}}^{\text{avg}}} \\ \Delta v^{\max} = \max\limits_{t=2,3,\cdots,T}\dfrac{\left|P_{\text{out}}(t)-P_{\text{out}}(t-1)\right|}{P_{\text{out}}^{\text{avg}}} \end{cases} \tag{22}$$

式中：Δv^{avg} 和 $\Delta v^{\max}$ 分别表示光伏系统输出功率平均波动度和最大波动度；T表示运行时间段；$P_{\text{out}}^{\text{avg}}$ 为光伏系统此时间内的平均输出功率。

表 1 给出了三种算例下 7 种算法的统计结果。可以发现，DLCI 在所有算法中能产生最大的能量且拥有最小的功率平均波动度。

表 1 三种算例下 7 种算法的统计结果

Table 1 Statistical results obtained by seven methods under three cases

算例	指标	INC	PSO	ABC	GWO	MFO	WOA	DLCI
恒定气候条件	能量/10^{-6}kWh	2.768 7	3.527 3	3.747 7	3.725 5	3.746 9	3.748 2	3.755 5
	$\Delta v^{\max}$/%	0.051 8	2.503 9	0.024 9	0.044 1	0.025 4	0.022 1	0.010 9
	Δv^{avg}/%	0.021 8	0.009 9	0.002 4	0.003 0	0.002 3	0.002 5	0.002 0
时变气候条件	能量/10^{-6}kWh	94.570 1	103.323 3	104.487 2	105.009 2	103.995 0	104.562 0	105.440
	$\Delta v^{\max}$/%	24.114 1	21.992 1	21.825 4	21.716 9	21.928 7	21.809 8	21.628 2
	Δv^{avg}/%	0.030 0	0.009 9	0.009 2	0.007 9	0.009 7	0.008 4	0.007 0
大型光伏电站	能量/MWh	25.026 2	30.231 2	28.215 4	30.213 1	30.186 1	30.157 1	31.284 4
	$\Delta v^{\max}$/%	5.921 1	2.471 3	2.742 5	3.265 7	1.684 9	2.572 2	1.648 2
	Δv^{avg}/%	0.056 2	0.030 3	0.023 4	0.039 5	0.032 6	0.020 3	0.019 3

特别地，在恒定气候条件下，DLCI 产生的能量分别比 INC、PSO、ABC、GWO、MFO 和 WOA 的能量高 35.64%、6.47%、0.208%、0.805%、0.229%和 0.194%。同时，在时变气候条件下，DLCI 的功率平均波动度分别是 INC、PSO、ABC、GWO、MFO 和 WOA 平均波动度的 23.33%、77.78%、76.09%、88.6%、72.16%和 83.33%。此外，在大型光伏电站的仿真实验中，DLCI 所产生的能量分别比 INC、PSO、ABC、GWO、MFO 和 WOA 的能量高 56.22%、3.484%、10.88%、3.546%、3.638%和 3.738%。

5　硬件在环实验

为验证 DLCI 算法的硬件实施可行性，本章基于 dSpace 进行了 HIL 实验。图 12 和图 13 给出了 HIL 的系统框架和实验平台。DLCI 算法(5)—(19)以 f_c=10 kHz 的采样频率置于 DS1104 平台以实现其 MPPT；光伏系统(1)—(4)则以 f_s=100 kHz 的采样频率置于 DS1006 平台，以模拟 PSC 效应和各种气候条件。其中，温度和光照强度通过 DS1006 平台实时仿真测量得到，然后将其在线传输到 DS1104 平台计算输出光伏电压 V_{PV}。

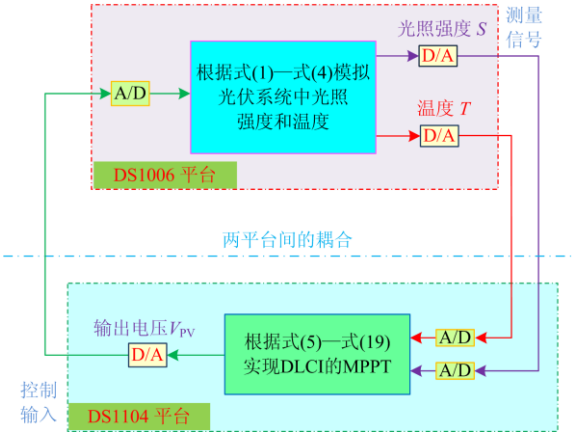

图 12 HIL 系统框架

Fig. 12 Configuration of HIL test

图 13 HIL 实验平台

Fig. 13 Experimental platform of the HIL test

5.1 恒定气候条件

图 14 给出了恒定气候条件下，基于仿真和 HIL 实验所获得的响应结果。由图 14 可知，HIL 实验结果与仿真结果拟合度较高。

5.2 时变气候条件

时变条件下的仿真和 HIL 实验结果如图 15 所示，可以很容易地观察到，HIL 实验结果与仿真结果非常相似。

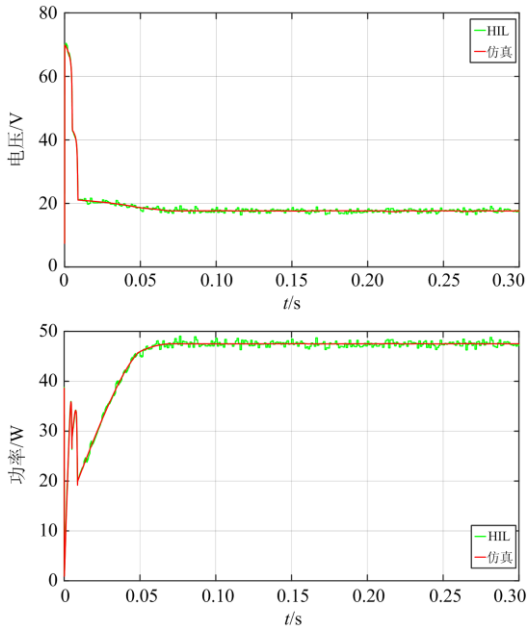

图 14 恒定气候条件下仿真和 HIL 实验结果图

Fig. 14 Simulation and HIL test results obtained under the constant climate conditions

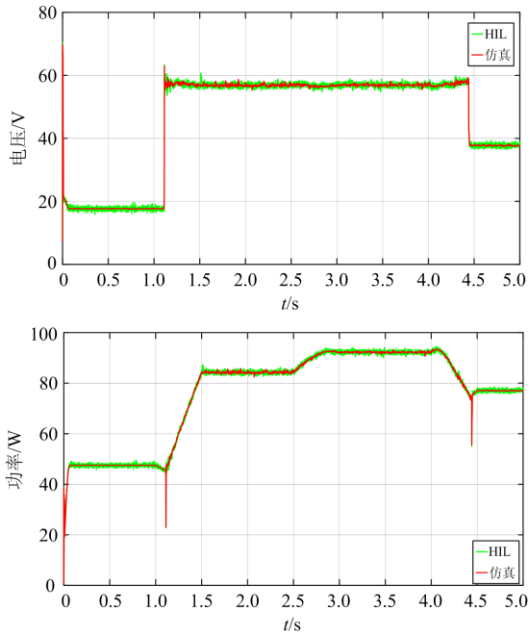

图 15 时变气候条件下仿真和 HIL 实验结果图

Fig. 15 Simulation and HIL test results obtained under the varying climate conditions

6　结论

本文设计了一种新型DLCI算法用于PSC下光伏系统的MPPT，其主要结论如下：

(1) 随着各类型子优化器被合并到集体智慧中，

可以显著提高DLCI的全局搜索能力。此外，基于动态领导的引导策略可实现更深度的局部搜索与快速收敛；

(2) 与其他经典的启发式算法相比，DLCI能更快速地收敛至全局最大功率点，并且能在不同工况下产生最高的能量；

(3) 由于DLCI的收敛稳定性最高，因此，在相同的气候条件下，其产生的功率波动相较于其他经典启发式算法而言最低；

(4) 对DLCI算法进行了基于dSpace的HIL实验，该实验结果与仿真结果拟合度较高，有效验证了DLIC算法的硬件实施可行性。

参考文献

[1] 孙立明, 杨博. 超级电容储能系统的无源分数阶滑模控制设计[J]. 电力系统保护与控制, 2020, 48(16): 76-83.
SUN Liming, YANG Bo. Passive fractional-order sliding-mode control design of a supercapacitor energy storage system[J]. Power System Protection and Control, 2020, 48(16): 76-83.

[2] 姜海洋, 杜尔顺, 朱桂萍, 等. 面向高比例可再生能源电力系统的季节性储能综述与展望[J]. 电力系统自动化, 2020, 44(19): 194-207.
JIANG Haiyang, DU Ershun, ZHU Guiping, et al. Review and prospect of seasonal energy storage for power system with high proportion of renewable energy[J]. Automation of Electric Power Systems, 2020, 44(19): 194-207.

[3] 程耀华, 张宁, 王佳明, 等. 面向高比例可再生能源并网的输电网规划方案综合评价[J]. 电力系统自动化, 2019, 43(3): 33-42.
CHENG Yaohua, ZHANG Ning, WANG Jiaming, et al. Comprehensive evaluation of transmission network planning for integration of high-penetration renewable energy[J]. Automation of Electric Power Systems, 2019, 43(3): 33-42.

[4] 张宁, 杨洪明, 徐岩, 等. 局部阴影条件下太阳能电池-超级电容器件的充放电控制方法[J]. 电力系统保护与控制, 2020, 48(4): 72-79.
ZHANG Ning, YANG Hongming, XU Yan, et al. Charge and discharge control method of solar cell-supercapacitor under partial shading condition[J]. Power System Protection and Control, 2020, 48(4): 72-79.

[5] 王志忠, 韩茂林, 胡海, 等. 基于晴朗系数和多层次匹配的光伏功率预测方法研究[J]. 电测与仪表, 2019, 56(8): 45-50.
WANG Zhizhong, HAN Maolin, HU Hai, et al. Research on photovoltaic power prediction method based on sunny coefficient and multi similarity matching[J]. Electrical Measurement & Instrumentation, 2019, 56(8): 45-50.

[6] 王继拓, 王万成, 陈宏伟. 基于回归—马尔科夫链的光伏发电功率预测[J]. 电测与仪表, 2019, 56(1): 76-81.
WANG Jituo, WANG Wancheng, CHEN Hongwei. Photovoltaic power generation forecasting based on regression-Markov chain[J]. Electrical Measurement & Instrumentation, 2019, 56(1): 76-81.

[7] 吴海涛, 孙以泽, 孟婥. 粒子群优化模糊控制器在光伏发电系统最大功率跟踪中的应用[J]. 中国电机工程学报, 2011, 31(6): 52-57.
WU Haitao, SUN Yize, MENG Chuo. Application of fuzzy controller with particle swarm optimization algorithm to maximum power point tracking of photovoltaic generation system[J]. Proceedings of the CSEE, 2011, 31(6): 52-57.

[8] SHANG L Q, ZHU W W, LI P W, et al. Maximum power point tracking of PV system under partial shading conditions through flower pollination algorithm[J]. Protection and Control of Modern Power Systems, 2018, 3(3): 400-406. DOI: 10.1186/s41601-018-0111-3.

[9] 曹松青, 郝万君, 郝诗源, 等. 基于超扭曲优化算法的风机最大功率跟踪控制[J]. 电力系统保护与控制, 2019, 47(15): 61-68.
CAO Songqing, HAO Wanjun, HAO Shiyuan, et al. Maximum power tracking control of wind turbine based on super twisting optimization algorithm[J]. Power System Protection and Control, 2019, 47(15): 61-68.

[10] 方云熠, 曾喆昭, 王可煜, 等. 永磁直驱风力发电系统最大功率跟踪改进型积分滑模控制[J]. 电力系统保护与控制, 2019, 47(13): 77-83.
FANG Yunyi, ZENG Zhezhao, WANG Keyu, et al. MPPT control with improved integral SMC for D-PMSG wind power generation system[J]. Power System Protection and Control, 2019, 47(13): 77-83.

[11] ALIK R, JUSOH A. Modified perturb and observe (P&O) with checking algorithm under various solar irradiation[J]. Solar Energy, 2017, 148: 128-139.

[12] LOUKRIZ A, HADDADI M, MESSALTI S. Simulation and experimental design of a new advanced variable step size incremental conductance MPPT algorithm for PV systems[J]. ISA Transactions, 2016, 62: 30-38.

[13] 刘晓艳, 祁新梅, 郑寿森, 等. 局部阴影条件下光伏阵列的建模与分析[J]. 电网技术, 2010, 34(11): 192-197.
LIU Xiaoyan, QI Xinmei, ZHENG Shousen, et al. Model and analysis of photovoltaic array under partial shading[J]. Power System Technology, 2010, 34(11): 192-197.

[14] SALMAN S, AI X, WU Z Y. Design of a P-&-O algorithm

based MPPT charge controller for a stand-alone 200 W PV system[J]. Protection and Control of Modern Power Systems, 2018, 3(3): 259-266. DOI: 10.1186/s41601-018-0099-8.

[15] 陈阿莲, 冯丽娜, 杜春水, 等. 基于支持向量机的局部阴影条件下光伏阵列建模[J]. 电工技术学报, 2011, 26(3): 140-147.
CHEN Alian, FENG Lina, DU Chunshui, et al. Modeling of photovoltaic array based on support vector machines under partial shaded conditions[J]. Transactions of China Electrotechnical Society, 2011, 26(3): 140-147.

[16] DARABAN S, PETREUS D, MOREL C. A novel MPPT (maximum power point tracking) algorithm based on a modified genetic algorithm specialized on tracking the global maximum power point in photovoltaic systems affected by partial shading[J]. Energy, 2014, 74: 374-388.

[17] SEN T, PRAGALLAPATI N, AGARWAL V, et al. Global maximum power point tracking of PV arrays under partial shading conditions using a modified particle velocity-based PSO technique[J]. IET Renewable Power Generation, 2018, 12(5): 555-564.

[18] TITRI S, LARBES C, TOUMI K Y, et al. A new MPPT controller based on the ant colony optimization algorithm for photovoltaic systems under partial shading conditions[J]. Applied Soft Computing, 2017, 58: 465-479.

[19] AHMED J, SALAM Z. A maximum power point tracking (MPPT) for PV system using Cuckoo search with partial shading capability[J]. Applied Energy, 2014, 119: 118-130.

[20] KUMAR N, HUSSAIN I, SINGH B, et al. MPPT in dynamic condition of partially shaded PV system by using WODE technique[J]. IEEE Transactions on Sustainable Energy, 2017, 8(3): 1204-1214.

[21] SRIDHAR R, JEEVANANTHAN S, DASH S S, et al. A new maximum power tracking in PV system during partially shaded conditions based on shuffled frog leap algorithm[J]. Journal of Experimental and Theoretical Artificial Intelligence, 2016, 29(3): 481-493.

[22] MOHANTY S, SUBUDHI B, RAY P K. A new MPPT design using grey wolf optimization technique for photovoltaic system under partial shading conditions[J]. IEEE Transactions on Sustainable Energy, 2015, 7(1): 181-188.

[23] LEVY P, BONONNO R. Collective intelligence: mankind's emerging world in cyberspace[M]. Cambridge, Mass: Basic Books, 1999.

[24] 林泽宏, 李敬光, 陈威洪, 等. 基于交互式教-学优化算法的阴影条件下光伏系统最大功率跟踪[J]. 电测与仪表, 2021, 58(8): 154-159.
LIN Zehong, LI Jingguang, CHEN Weihong, et al. Interactive teaching-learning optimization based maximum power point tracking of PV systems under partial shading conditions[J]. Electrical Measurement & Instrumentation 2021, 58(8): 154-159.

[25] 卞海红, 徐青山, 高山, 等. 考虑随机阴影影响的光伏阵列失配运行特性[J]. 电工技术学报, 2010, 25(6): 104-109.
BIAN Haihong, XU Qingshan, GAO Shan, et al. Operation mismatches of photovoltaic array considering random shadows[J]. Transactions of China Electrotechnical Society, 2010, 25(6): 104-109.

[26] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.

[27] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67.

[28] MIRJALILI S. Moth-flame optimization algorithm: a novel nature-inspired heuristic paradigm[J]. Knowledge-Based Systems, 2015, 89: 228-249.

[29] XIANG W L, LI Y Z, MENG X L, et al. A grey artificial bee colony algorithm[J]. Applied Soft Computing, 2017, 60: 1-17.

[30] CHEN Y G, LI L X, XIAO J H, et al. Particle swarm optimizer with crossover operation[J]. Engineering Applications of Artificial Intelligence, 2018, 70: 159-169.

[31] 杨博, THIDAR S, 钟林恩, 等. 阴影条件下基于迁移强化学习的光伏系统最大功率跟踪[J]. 控制与决策, 2020, 35(12): 2939-2949.
YANG Bo, THIDAR S, ZHONG Lin'en, et al. Transfer reinforcement learning based maximum power point tracker of PV systems under partial shading condition[J]. Control and Decision, 2020, 35(12): 2939-2949.

收稿日期：2020-11-20；　　**修回日期：**2021-03-25

作者简介：

胡依林(1991—)，男，硕士，助教，主要研究方向为人工智能在新能源发电系统与智能电网中的应用；E-mail: 1554032180@qq.com

成　奎(1989—)，男，硕士，助教，主要研究方向为人工智能与机器人；E-mail: 1334487410@qq.com

杨　博(1988—)，男，通信作者，博士，副教授，主要研究方向为新能源发电系统优化与控制、人工智能在智能电网中的应用。E-mail: yangbo_ac@outlook.com

（编辑　葛艳娜）