

改良型美洲獅演算法於多模型光伏電池參數辨識

羅鈺惟、陳柔玳、吳宗融、劉恩睿*

摘要

為因應 2050 淨零排放之全球轉型趨勢，光伏發電已成為綠色能源發展之核心技術。然而，光伏模組之輸出特性受內部半導體機制與環境條件影響，呈現高度非線性與強耦合特性，使參數辨識問題具有多峰性與非凸特性，增加模型建構與性能預測之難度。傳統方法除面臨計算成本高與實驗程序繁瑣等限制外，亦容易陷入區域最優解，進而影響辨識精度。

基於上述挑戰，本研究提出一種改良型美洲獅最佳化演算法（Shuffled Puma Optimizer, SPO）。該方法於原始美洲獅最佳化演算法（Puma Optimizer, PO）中導入洗牌機制，以提升族群多樣性並降低搜尋偏差，進而強化全域搜尋能力並加速收斂過程。

研究首先透過標準測試函數對 SPO 與 PO 進行效能基準比較，驗證其在搜尋能力與穩定性上的優勢；隨後，將所提出方法應用於光伏模型參數辨識，包括單二極體模型（SDM）、雙二極體模型（DDM）、三二極體模型（TDM）以及光伏模組模型（PMM）。實驗結果顯示，SPO 在各模型之辨識誤差均優於 PO，PO 誤差分別為 8.8180083×10^{-4} 、 8.75×10^{-4} 、 8.60×10^{-4} 和 2.604009×10^{-3} ，SPO 的誤差則分別為 8.8180080×10^{-4} 、 8.54×10^{-4} 、 8.49×10^{-4} 和 2.394094×10^{-3} ，顯示所提出方法在提升辨識精度與穩定性具有高度優勢。

關鍵詞：改良型美洲獅演算法、光伏打模型、參數辨識、元啟發式演算法

羅鈺惟，國立臺東大學綠能與資訊科技學系學生，Email: 11325116@gm.nttu.edu.tw

陳柔玳，國立臺東大學綠能與資訊科技學系學生，Email: 11122119@gm.nttu.edu.tw

吳宗融，國立臺東大學綠能與資訊科技學系學生，Email: 11325126@gm.nttu.edu.tw

劉恩睿(通訊作者)，國立臺東大學綠能與資訊科技學系助理教授，Email: ejliu@nttu.edu.tw

Shuffled Puma Optimization for Parameter Identification of Multiple Photovoltaic Models

Yu-Wei Luo, Rou-Wen Chen, Zing-Rong Wu and En-Jui Liu *

Abstract

In response to the global transition toward net-zero emissions by 2050, photovoltaic (PV) power generation has emerged as a core technology in green energy development. However, the output characteristics of PV modules are strongly influenced by internal semiconductor mechanisms and environmental conditions, resulting in highly nonlinear and strongly coupled behaviors. Consequently, the parameter identification problem is inherently multimodal and non-convex, which increases the difficulty of model construction and performance prediction. Conventional methods not only suffer from high computational cost and cumbersome experimental procedures but are also prone to being trapped in local optima, thereby degrading identification accuracy. To address these challenges, this study proposes a novel optimization algorithm termed shuffled puma optimizer (SPO).

The proposed method incorporates a shuffle mechanism into the puma optimizer (PO) to enhance population diversity and reduce search bias, thereby strengthening global search capability and accelerating convergence. First, benchmark tests using standard test functions are conducted to compare the performance of SPO and PO in terms of solution quality and convergence stability. Subsequently, the proposed method is applied to parameter identification of PV models, including the single-diode model (SDM), double-diode model (DDM), triple-diode model (TDM) and photovoltaic module model (PMM).

The experimental results demonstrate that SPO consistently outperforms PO across all models. For SDM, DDM, TDM, and PMM, the identification errors obtained by PO are 8.8180083×10^{-4} , 8.75×10^{-4} , 8.60×10^{-4} and 2.604009×10^{-3} , respectively, whereas the corresponding errors achieved by SPO are reduced to 8.8180080×10^{-4} , 8.54×10^{-4} , 8.49×10^{-4} , and 2.394094×10^{-3} . These results indicate that the proposed method provides consistent improvements in both identification accuracy and convergence stability.

Keywords: Shuffled Puma Optimizer, Photovoltaic Model, Parameter Identification, Metaheuristic Algorithm

Yu-Wei Luo, Department of Green Energy and Information Technology, National Taitung University. student、
Email: 11325116@gm.nttu.edu.tw

Rou-Wen Chen, Department of Green Energy and Information Technology, National Taitung University.
student, Email: 11122119@gm.nttu.edu.tw

Zing-Rong Wu, Department of Green Energy and Information Technology, National Taitung University. student,
Email: 11325126@gm.nttu.edu.tw

En-Jui Liu (Corresponding Author), Department of Green Energy and Information Technology, National
Taitung University. Assistant Professor, Email: ejliu@nttu.edu.tw

表 1.

演算法數學符號說明

$mode$	開發或探索	$rand_n$	取值 $[-4, 4]$ 之間
t	當前迭代次數	UB, LB	上界和下界
PF_1	初始設定參數為 0.5	G	$[-1, 1]$ 之間的方向因子
PF_3	初始設定參數為 0.3	$X_{a,G}, X_{b,G}, X_{c,G}$	隨機 6 個美洲獅的解
Seq	於開發或探索模式下美洲獅改進前和改進後計算結果的差值	$X_{d,G}, X_{e,G}, X_{f,G}$	隨機 6 個美洲獅的解
$SeqTime$	每個模式被選中次數	j_{rand}	介於 $[1, dim]$ 之間的整數
$Score_{Explore}$	探索分數	U	$[0, 1]$ 遞減數值，初始為 0.2
$Score_{Exploit}$	開發分數	N_{pop}	美洲獅的數量
$Cost_{old}^{mode}$	未更新前舊的適應度值	X_{new}	美洲獅新的解
$Cost_{new}^{mode}$	更新後新的適應度值	Sol_{total}	所有解的總和
T_t^{mode}	為該模式在上一次被選擇後沒被選擇的迭代數	X_1^r, X_2^r	隨機選擇的解
$S_{t,1}^{mode}$	當下模式改進前後適應度差值的最佳解	b	隨機產生數，0 或 1
$S_{t,2}^{mode}, S_{t,3}^{mode}$	前兩個模式改進前後適應度差值的最佳解	$T_{t,3}^{mode}$	前三次到前兩次未被選中的迭代數
$T_{t,1}^{mode}$	上次到當前未被選中的迭代數	α, L	常數，設 2 與 0.67
$rand_1 \sim rand_{12}$	$[0, 1]$ 之間的隨機數	X_i	之前迭代最佳解
$randn_1 \sim randn_5$	常態分佈的數	$T_{t,2}^{mode}$	前兩次到前一次未被選中的迭代數
		R_{dim}	$[0, 1]$ 之間的隨機數

表 2

演算法數學符號說明

$Pumamale$	全體最優秀的個體	y	探索後的新解
R	$[-1, 1]$ 之間的方向因子	X_{nx}, X_{nv}	交換解
$Iter$	當前迭代次數	X_{new}	成本較優解
$MaxIter$	最大迭代次數	X_i	當前解
$\alpha t^{mode}, \delta t^{mode}$	開發與探索模式的 α 與 δ 值	X_{best}	成本最優解
lc	開發與探索模式各自迭代前後最佳適應度差值	$Cost$	成本
C	$[1, dim]$ 之間的隨機整數，定義子序列交換起始位置	$exp, mean$	指數函數；平均
d	當前維度	$CostX_{new}$	新美洲獅的適應度值
x	當前解	$CostX_i$	原本美洲獅的適應度值

表 3

太陽能電池模型符號說明

T	電池的絕對溫度 (K)	N_p	並聯連接的電池數
R_{sh}	電池內部的漏電阻	N_s	串聯連接的電池數
I_{ph}	光電流源	$RMSE$	均方根誤差
I_{d1}	通過二極體電流	$CostX_i$	當前解之適應度值
I_{sh}	分流電阻電流	N	數據點數量
I_{sd1}, I_{sd2}	二極體逆向飽和電流	$n_1 \sim n_3$	二極體的理想因子
I_{sd3}	晶界效應產生的逆向飽和電流	R_s	電極阻抗及電流的流動阻抗
$I_{calculate}$	計算電流值	I_L	輸出端電流
$I_{experimental}$	實驗電流值	I_t	端電壓

壹、前言

隨著全球暖化、極端氣候以及海平面上升等環境問題日益嚴峻，各國皆將減少碳排放視為重要目標。近年來，已有超過 130 個國家推動「淨零碳排」政策，期望在 2050 年前實現環境永續。臺灣亦於 202 年由國家發展委員會公布「臺灣 2050 淨零排放路徑及策略總說明」，將「能源轉型」列為四大轉型策略之首。其中，太陽能光伏發電因具備零碳排、維護成本低、技術成熟且部署靈活等優勢，在提升再生能源比例中扮演著關鍵角色。

然而，光伏電池的轉換功率極易受到外部環境因素影響，導致其性能產生波動。此外，光伏電池模型具備高度非線性與多峰性特徵，若無法精確提取其物理參數，將導致發電效能預測失準，進而影響整體微電網的調度效率。傳統的實驗測量法不僅過程繁瑣，且難以因應環境變化進行即時調整。因此，開發高效、高精度的參數辨識演算法，以提升光伏系統效能並增進其在不同環境下的適應性，已成為能源管理領域的迫切需求。

為解決上述問題，本研究擬採用強化型元啟發式演算法，透過改善原始方法的全域搜尋能力，藉以提升光伏模組參數辨識的精確性。研究過程中，首先使用 23 個標準測試函數(Benchmark functions)對改良後演算法與其他演算法進行效能分析與比較，並計算全域搜尋與區域搜尋的比例，確保演算法的可靠性與有效性。隨後，將此演算法應用於單二極體(SDM)、雙二極體(DDM)、三二極體(TDM) (Kullampalayam Murugaiyan et al., 2024)及光電模組模型(PMM) (Zhou & Shang, 2024)進行參數最佳化，並詳細分析其最佳解、平均解與標準差。

根據上述，本研究提出一種結合提升元啟發式演算法之全域搜尋能力與收斂穩定性的機制，並應用於光伏模型參數辨識，最終透過標準測試函數(Benchmark functions)與實際模型實驗，充分驗證其優越性，進一步提升光伏系統的整體效能與可靠性。

貳、文獻回顧

一、元啟發式演算法

最佳化問題旨在可行解空間中尋求使目標函數極值化之方案，傳統演算法如梯度下降法、最小平方法，在高度非線性且參數耦合之問題，目標函數通常呈現非凸特性，容易陷入區域最優解。元啟發式演算法則透過探索(Exploration)與開發(Exploitation)機制的動態權衡，在合理成本下尋獲接近全域最優之解。根據「無免費午餐定理」(Wolpert & Macready, 1997)，不存在能解決所有問題的萬能演算法，故須依問題特性選擇最適策略。

在群體智慧分支中，粒子群演算法(Particle Swarm Optimization, PSO) (Kennedy & Eberhart, 1995)與遺傳演算法(Genetic Algorithm, GA) (Lambora et al., 2019)展現強健的探索能力；而本研究採用之美洲獅演算法(Abdollahzadeh et al., 2024)則模擬美洲獅獵食行為，具備優異的開發能力，特別擅長於已知空間之優化。

然而，傳統探索階段雖常用變異與交叉增加解的多樣性，但在面對龐大且複雜的解空間時，其變異機制往往顯得過於侷限，容易導致演算法陷入局部最優解而缺乏突破能力。

為解決此一關鍵瓶頸本研究引入基因突變技術機制。Shuffle 策略的核心概念在於透過隨機重排或重組候選解，以引入隨機擾動機制。在每次迭代中，族群先依適應度進行排序，接著對排序結果施加隨機混合操作。此過程有助於降低結構性搜尋偏差並提升族群多樣性，從而強化全域搜尋能力。

二、光伏打電池模型

為了全面解析光伏系統的功率特性，建立適當的數學模型十分關鍵。光伏電池本質上可視為一種光電二極體，SDM 為最常使用的光伏模型(Kullampalayam Murugaiyan et al., 2024)，考慮到光伏電池中的負面參雜、缺陷以及系統本身漏電流等因素，圖 4 為 SDM 等效電路圖，SDM 需辨識五個參數。與 SDM 相比，DDM 額外增加了一個並聯二極體(Kullampalayam Murugaiyan et al., 2024)，加以考慮複合電流損耗的影響，特別是在低輻照度條件下效果更為顯著，圖 5 為 DDM 等效電路圖， I_{d1} 、 I_{d2} 皆為通過二極體之電流。TDM 相比於 DDM，多加考慮晶界複合所產生的洩漏電流影響(Kullampalayam Murugaiyan et al., 2024)，該模型針對光伏電池中可能存在的缺陷及非理想條件所引起的損耗進行了更精確的描述，圖 6 為 TDM 等效電路圖， I_{d1} 、 I_{d2} 、 I_{d3} 為通過二極體電流。而 PMM 為多個 SDM 串聯和並聯組成的光電模組(Zhou & Shang, 2024)。

參、研究方法

為開發具有全域搜尋能力之智慧演算法，本研究開發與驗證改良型美洲獅演算法，進而強化在光伏電池參數辨識問題中搜尋全域最優解之能力。

一、研究流程圖

本研究流程共分為三個階段。首先建構改良型美洲獅演算法(Shuffled Puma Optimization, SPO)，於美洲獅最佳化演算法中導入洗牌機制，以提升族群多樣性並強化全域搜尋能力。其次，透過標準測試函數對 SPO 與多種比較演算法進行效能基準測試，以評估演算法在最佳解搜尋能力與收斂穩定性方面之表現。最後，將所提出方法應用於光伏電池參數辨識問題，並以均方根誤差(Root Mean Square Error, RMSE)作為評估指標，以衡量模型之擬合精度，並透過多演算法比較分析驗證其穩健性。研究流程如圖 1 所示。




圖 1 研究流程圖

二、美洲獅演算法

美洲獅演算法 (Puma Optimizer, PO) 是由 Benyamin 等人於 2024 年提出的一種新型群體智慧元啟發式演算法。其核心靈感源自美洲獅的捕獵策略、生活習性與智慧行為，旨在解決複雜的非線性最佳化問題。

(一)美洲獅演算法

PO 靈感源自於美洲獅的智慧與生活習性，在探索與開發階段均設計了一套強大的搜索機制提高搜尋效率與精確度。PO 在搜索過程中能執行相變操作，透過分數計算從而在開發與探索靈活切換，並動態平衡探索與開發的比重，避免過早收斂陷入局部最優解，亦防止精確性不高。本節將對 PO 的數學模型進行詳細闡述，以說明其運作機制與應用潛力。

(二)無經驗階段

在前三次迭代同時進行探索及開發，因初始環境和獵物位置是未知的，所以為了尋找適合狩獵的區域，將一起執行探索與開發。在前三次的每次迭代中，原本的獅群會分別透過開發模式及探索模式生成兩群，然後透過適應度值對獅群進行排序，最後只會保留適應度最佳的美洲獅。

$$f1_{mode} = PF_1 \times \left(\frac{Seq_{mode}^1}{Seq_{Time}} \right) \quad (1)$$

$$f2_{mode} = PF_2 \times \left(\frac{Seq_{mode}^1 + Seq_{mode}^2 + Seq_{mode}^3}{Seq_{Time}^1 + Seq_{Time}^2 + Seq_{Time}^3} \right) \quad (2)$$

$$Score_{mode} = (PF_1 \times f1_{mode}) + (PF_2 \times f2_{mode}) \quad (3)$$

三次迭代之後，會使用公式(1)與公式(2)計算 $f1$ 、 $f2$ ，代入(3)算出數值，計算探索分數 $Score_{Explore}$ 以及開發分數 $Score_{Exploit}$ 。若 $Score_{Explore}$ 大於 $Score_{Exploit}$ ，則在有經驗階段選擇探索模式，反之則進入開發模式由於，無經驗階段開發與探索皆會執行，因此 Seq_{Time}^t 皆等於1。

(三)有經驗階段

經過三次迭代之後，美洲獅對於獵物位置及生活空間更加了解，依據經驗來選擇要進行的模式，在之後的每一次迭代中，只會選擇一種模式進行，並根據新的分數機制持續更改模式：

$$f_{1_t}^{mode} = PF_1 \times \left| \frac{Cost_{old}^{mode} - Cost_{new}^{mode}}{T_t^{mode}} \right| \quad (4)$$

$$f_{2_t}^{mode} = PF_2 \times \left| \frac{S_{t,1}^{mode} + S_{t,2}^{mode} + S_{t,3}^{mode}}{T_{t,1}^{mode} + T_{t,2}^{mode} + T_{t,3}^{mode}} \right| \quad (5)$$

$$f_{3_t}^{mode} = \begin{cases} \text{if selected,} & f_{3_t}^{mode} = 0 \\ \text{otherwise,} & f_{3_t}^{mode} + PF_3 \end{cases} \quad (6)$$

此階段中，PO 會使用公式(4)~(6)計算 $f_{1_t}^{mode}$ 、 $f_{2_t}^{mode}$ 及 $f_{3_t}^{mode}$ ，但是這裡的 f_1 和 f_2 與無經驗階段的 f_1 、 f_2 計算方式不一樣。在此階段中， f_1 會使陷入局部最優解時執行更多的全域探索， f_2 可以在探索模式後執行更多局部開發， f_3 可以使重複未被選中的模式也有被選擇的機會，避免不斷進行同一個模式導致陷入局部最優解。

(四)探索階段

$$\begin{aligned} & \text{If } rand_1 > 0.5: \\ & Z_{i,G} = R_{Dim} \times (UB - LB) + LB \\ & \text{Otherwise:} \\ & Z_{i,G} = X_{a,G} + G \times (X_{a,G} - X_{b,G}) + G \times \left(\begin{aligned} & \left((X_{a,G} - X_{b,G}) - (X_{c,G} - X_{d,G}) \right) \\ & + \left((X_{c,G} - X_{d,G}) - (X_{e,G} - X_{f,G}) \right) \end{aligned} \right) \quad (7) \\ & G = 2 \cdot rand_2 - 1 \quad (8) \end{aligned}$$

若 $rand_1 > 0.5$ ，生成在上界之中的隨機數做為新的解。而 $rand_1 \leq 0.5$ ，則在獅群中隨機選擇 6 隻美洲獅的座標計算新的解。

$$X_{new} = \begin{cases} Z_{i,G}, & \text{if } j = j_{rand} \text{ or } rand_3 \leq U \\ X_{a,G}, & \text{otherwise} \end{cases} \quad (9)$$

$$p = \frac{NC}{Npop}, \text{ where } NC = 1 - U \quad (10)$$

$$\begin{aligned} & \text{if } CostX_{new} < CostX_i : \\ & \quad X_i = X_{new} \\ & \text{Otherwise: } U = U + p \end{aligned} \quad (11)$$

PO 會遍歷按適應度排序的美洲獅族群，透過隨機交叉替換維度產生 X_{new} ，隨後根據適應度值進行優勝劣汰的更新，若新解表現優於原解，則予以取代，反之保留原數值。

$$\begin{aligned} & \text{if } rand_4 \geq 0.5 : \\ & X_{new} = \frac{\left(\frac{mean(Sol_{total})}{Npop} \right) \times X_1^r - (-1)^\beta \times X_i}{1 + (\alpha \times rand_5)} \end{aligned} \quad (12)$$

$$\begin{aligned}
 & \text{otherwise:} \\
 & \text{if } rand_6 \geq L: \\
 & X_{new} = Puma_{male} + (2 \times rand_7) \cdot \exp(randn_1) \times (X_2^r - X_i) \\
 & \text{otherwise:} \\
 & X_{new} = (2 \times rand_8) \times \frac{(F_1 \times R \times X_i + F_2 \times (1 - R) \times Puma_{male})}{(2 \times rand_9 - 1 + randn_2)} - Puma_{male} \\
 & X_2^r = round(1 + (Npop - 1) \cdot rand_{10}) \quad (13)
 \end{aligned}$$

$$R = 2 \cdot rand_{11} - 1 \quad (14)$$

$$F_1 = randn_3 \times \exp\left(2 - Iter \times \left(\frac{2}{MaxIter}\right)\right) \quad (15)$$

$$F_2 = randn_4 \times (randn_5)^2 \times \cos((2 \times rand_{12}) \times randn_4) \quad (16)$$

(五)開發階段

如果 $rand_4 \geq 0.5$ 將執行快速奔跑，否則伏擊，其中伏擊又分成兩種， $rand_6 \geq L$ ，進行短跳，反之長跳。開發模式結束時，會比較新舊解的適應度值，只取其優解。

(六)探索模式及開發模式的分數

$$F_t^{mode} = (\alpha_t^{mode} \times (f_{1_t}^{mode})) + (\alpha_t^{mode} \times (f_{2_t}^{mode})) + (\delta_t^{mode} \times (|lc| \times f_{3_t}^{mode})) \quad (17)$$

PO 透過動態權重機制來平衡探索與開發：系統會比較兩者的得分，若開發得分較高，表示當前開發比重不足，此時會利用 α 參數線性降低探索比重，反之亦然。當 α 趨近於 1 時，迭代間的相互影響力增強， δ 則趨近於 0 並降低解的多樣性。藉由這種模式切換，PO 能防止過早收斂至局部最優解的同時，避免過度全域搜索產生不精確的解。

三、改良型美洲獅演算法

本研究的重點放在改良探索階段，由於傳統的變異與交叉機制在面對複雜地形時，容易因突破能力不足而陷於局部最優解，因此引入 Shuffle 策略作為創新的變異手段。對探索階段進行優化，圖 2 為改良方法。




圖 2 Shuffle 策略流程圖

本研究針對 PO 中的變異與選擇機制進行改良，為了提升在高維度解空間中的探索能力與整體搜尋效能。原始 PO 中公式(9)~(11)，被重設計為公式(18)~(20)，進一步增強對全域解的搜尋能力。

$$X_{nx}(d) = \begin{cases} x(d), & \text{if } (rand > 0.5 \text{ and } d < C) \text{ or } (rand \leq 0.5 \text{ and } d > C) \\ y(d), & \text{Otherwise} \end{cases} \quad (18)$$

$$X_{ny}(d) = \begin{cases} y(d), & \text{if } (rand > 0.5 \text{ and } d < C) \text{ or } (rand \leq 0.5 \text{ and } d > C) \\ x(d), & \text{Otherwise} \end{cases} \quad (19)$$

$$X_n = \begin{cases} X_{nx}, & \text{if } CostX_{nx} < CostX_{ny} \\ X_{ny}, & \text{Otherwise} \end{cases} \quad (20)$$

$$X_{new} = \begin{cases} X_n, & \text{if } CostX_n < CostX_y \\ X_y, & \text{Otherwise} \end{cases} \quad (21)$$

$$X_{best} = \begin{cases} X_{new}, & \text{if } CostX_{new} < CostX_i \\ X_i, & \text{Otherwise} \end{cases} \quad (21)$$

在變異操作方面，我們改良了傳統的交叉方式，如公式(18)。當 $rand$ 大於0.5且 $d < C$ ，或 $rand \leq 0.5$ 且 $d > C$ 時， C 之前的子序列會保持初始解 x ， C 之後的子序列會是搜索過後新解 y ；反之， C 之前的子序列會保持初始解 y ， C 之後的子序列會是搜索過後新解 x ，會產生交換解 X_{nx} 和 X_{ny} 。放棄原本的隨機多點交叉法，改採更具控制力的交換策略降低陷入局部解的風險性。

所有新解均須透過適應度分析於解空間中的優劣，藉此識別潛在的高品質候選解。如(18)所示，初生成兩組交叉解 X_{nx} 和 X_{ny} 首輪成本比較。選取較優者 X_n 。隨後，將此結果與探索得新解 X_y 進行二階比對，將成本較低者標記為 X_{new} 。最後，再將 X_{new} 與當前解 X_i ，進行第三階段比較，選取成本最低者作為本次迭代的最優解 X_{best} 。此逐層篩選與比較機制確保演算法在每次迭代中都能保留品質最佳的解，並作為後續選擇與更新操作的依據，從而促進整體族群穩定邁向全域最適解。圖 3 為 SPO 流程圖。




圖 3 SPO 流程圖

四、演算法強健度之測試與分析：最佳化函數集為例

演算法強健度測試與分析：以最佳化函數集為例元啟發式演算法的核心在於探索（全域搜索）與開發（區域搜尋）的動態平衡。而關鍵機制在於必須保留適度隨機性；隨機性過高會導致難以收斂，過低則易陷入局部最佳解的陷阱。透過 PO 透過兩大模式的持續交互作用，能自動優化並找出最合適的搜尋比例。

（一）光伏等效電路模型建立

SDM 是光伏系統中最常被採用的模型，由於考慮到光伏電池中的負面參雜、缺陷以及系統本身漏電流，系統的輸出端電流 I_L 計算方式如公式(22)。

$$I_L = I_{ph} - I_{d1} - I_{sh} \quad (22)$$

$$I_{d1} = I_{sd1} \left[\exp \left(\frac{q(V_L + I_L R_S)}{n_1 k T} \right) - 1 \right] \quad (23)$$

$$I_{sh} = \frac{V_L + I_L R_S}{R_{sh}} \quad (24)$$

I_{d1} 的計算根據肖克利二極體方程式(Shockley diode equation) (Martí et al., 1997)於公式(23)， I_{sh} 的計算方法於公式(24)。SDM 需辨識參數為 $[I_{ph}, I_{sd1}, R_S, R_{sh}, n_1]$ 。DDM 比 SDM 更為複雜，但精度也會隨之提高。DDM 的 I_L 可由公式(25)表達。

$$I_t = I_{ph} - I_{d1} - I_{d2} - I_{sh} \quad (25)$$

I_{d1} 、 I_{d2} 的計算詳列於公式(26)及公式(27)。

$$I_{d1} = I_{sd1} \left[\exp \left(\frac{q(V_L + I_L R_S)}{n_1 k T} \right) - 1 \right] \quad (26)$$

$$I_{d2} = I_{sd2} \left[\exp \left(\frac{q(V_L + I_L R_S)}{n_2 k T} \right) - 1 \right] \quad (27)$$

DDM 所需要的參數為 $[I_{ph}, I_{sd1}, I_{sd2}, R_S, R_{sh}, n_1, n_2]$ 。 I_t 端電壓的計算表達式如公式(28)所示：

$$I_t = I_{ph} - I_{d1} - I_{d2} - I_{d3} - I_{sh} \quad (28)$$

I_{d1} 、 I_{d2} 及 I_{d3} 的計算詳列於公式(29)、公式(30)及公式(31)。

$$I_{d1} = I_{sd1} \left[\exp \left(\frac{q(V_L + I_L R_S)}{n_1 k T} \right) - 1 \right] \quad (29)$$

$$I_{d2} = I_{sd2} \left[\exp \left(\frac{q(V_L + I_L R_S)}{n_2 k T} \right) - 1 \right] \quad (30)$$

$$I_{d3} = I_{sd3} \left[\exp \left(\frac{q(V_L + I_L R_S)}{n_3 k T} \right) - 1 \right] \quad (31)$$

TDM 模型所需要的參數為 $[I_{ph}, I_{sd1}, I_{sd2}, I_{sd3}, R_S, R_{sh}, n_1, n_2, n_3]$ 。光電模組模型為多數個 SDM 串聯和並聯所形成的，其端電壓 I_t 的計算表達式如公式(32)所示。PMM 與 SDM 需辨識五個參數，分別為 $[I_{ph}, I_{sd1}, R_S, R_{sh}, n_1]$ 。

$$I_t = I_{ph}N_p - I_{sd1}N_p \left[\exp\left(\frac{q(V_L/N_s + I_L R_s/N_p)}{n_1 kT}\right) - 1 \right] - \frac{V_L N_p/N_s + I_L R_s}{R_{sh}} \quad (32)$$




圖 4 SDM 等效電路圖




圖 5 DDM 等效電路圖




圖 6 TDM 等效電路圖




圖 7 PPM 等效電路圖

五、光伏模型

在參數辨識過程中，演算法於搜索空間內持續優化模型參數，並將其代入目標函數以獲得計算電流。透過不斷迭代找尋最優解，演算法旨在尋找一組最優參數解，使模擬結果與實驗數據之間的誤差達到最小。本研究選用 RMSE 作為目標函數，計算實驗電流與計算電流之間的誤差，如公式(33)所示， x 為待變參數陣列， f 為四種模型之目標函數。如表 4。

表 4

光伏電池模型之參數向量定義表

目標函數	參數陣列 X 的組成內容
f_{SDM}	$[I_{ph} , I_{sd1} , R_s , R_{sh} , n_1]$
f_{DDM}	$[I_{ph} , I_{sd1} , I_{sd2} , R_s , R_{sh} , n_1 , n_2]$
f_{TDM}	$[I_{ph} , I_{sd1} , I_{sd2} , I_{sd3} , R_s , R_{sh} , n_1 , n_2 , n_3]$
f_{PPM}	$[I_{ph} , I_{sd1} , R_s , R_{sh} , n_1]$

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (I_{calculate} - I_{experimental})^2} = \sqrt{\frac{1}{N} \sum_{t=1}^N (f_{model}(V_L, I_L, x) - I_L)^2} \quad (33)$$

肆、結果與討論

本章節旨在呈現改良型美洲獅演算法的各項實驗結果，並與美洲獅演算法及三種主流群體智慧演算法進行深入對比分析。

一、改良型演算法之穩健性測試

本研究將 SPO 與 PO 及三種主流群體智慧演算法－蛾類撲火最佳化演算法 (Moth-Flame Optimization, MFO) (Mirjalili, 2015)、鯨魚最佳化演算法 (The-Whale Optimization algorithm, WOA) (Mirjalili & Lewis, 2016) 與灰狼演算法 (Grey Wolf Optimization, GWO) (Mirjalili et al., 2014) 進行對比性能測試。實驗採用 CEC2005 (Yao et al. 1999) 測試集之 23 種基準函數，涵蓋單峰 (F1~F7)、多峰 (F8~F13) 及固定維度多峰 (F14~F23) 等類型，用以全面評估演算法的收斂精度與穩健性。

評估機制以 23 種函數測試後之平均最佳適應值 (Mean) 與標準差 (Std.) 為基準。為量化總體效能，研究引入強健性評分系統：若演算法在該函數獲得最佳或並列最佳結果，則計得 1 分，否則不計分。所有實驗均於 MATLAB 2024a 環境下執行，硬體採用 Intel i9-13950HX CPU 與 48GB RAM 之電腦設備。實驗統一設定群體大小為 30，迭代次數為 1000 次，相關演算法參數則詳列於表 5。

表 5

演算法相關參數設定

Algorithm	Parameter	Value
PO SPO	PF_1	1
	PF_2	0.99
	PF_3	1.5
	U	2.0
	L	0.9
	α	2
WOA	Decreasing convergence constant a	[2,0]
	Spiral factor b	1
GWO	Decreasing convergence constant a	[2,0]
MFO	Decreasing convergence constant a	[-2-1]

表 6

Benchmark function 測試結果

Function		PO	SPO	MFO	WOA	GWO
F1	Best	0	0	9.46E-06	8.74E-171	1.43E-61
	Mean	0	0	3333.334992	1.79E-150	4.35E-59
	Std.	0	0	7111.589235	1.79E-150	0
F2	Best	6.71E-265	1.58E-257	6.79E-05	1.75E-113	8.75E-36
	Mean	4.08E-258	4.67E-244	30.3336042	2.26E-105	7.52E-35
	Std.	0	4.67E-244	20.591667	2.26E-105	0
F3	Best	0	0	373.7855861	2363.808396	9.91E-21
	Mean	0	0	12106.99816	20412.56188	2.02E-14
	Std.	0	0	8657.410184	20412.56188	0
F4	Best	2.14E-266	7.62E-259	45.91367811	0.038043783	5.96E-16

Function		PO	SPO	MFO	WOA	GWO
	Mean	1.69E-260	3.64E-247	64.80575858	36.91031337	1.03E-14
	Std.	0	3.64E-247	7.262226	36.91031337	0
F5	Best	6.51E-05	2.41E-06	19.06758062	26.59963517	25.26193348
	Mean	24.70822581	21.0370063	2677128.656	27.17880789	26.70432108
	Std.	4.675912	21.0370063	1.46E+07	27.17880789	0.739694
F6	Best	8.89E-09	6.61E-17	1.81E-05	0.007406642	1.66E-05
	Mean	5.45E-08	8.94E-15	2660.066886	0.07519755	0.57299166
	Std.	0	8.94E-15	5185.760141	0.07519755	0.291827
F7	Best	5.93E-06	1.85E-05	0.041430035	9.04E-06	1.00E-04
	Mean	8.54E-05	1.19E-04	5.697443507	0.002040244	8.36E-04
	Std.	6.30E-05	1.19E-04	9.503771	0.002040244	5.30E-04
F8	Best	-12569.48661	-12569.48662	-10150.60746	-12569.11966	-7225.11669
	Mean	-11922.66706	-12357.05653	-8715.524936	-10826.25145	-6052.379167
	Std.	762.137812	-12357.05653	764.095649	-10826.25145	686.077721
F9	Best	0	0	78.60143134	0	0
	Mean	0	0	155.7505999	0	0.645623184
	Std.	0	0	35.278961	0	1.847468
F10	Best	4.44E-16	4.44E-16	0.00508684	4.44E-16	1.11E-14
	Mean	4.44E-16	4.44E-16	14.88237406	3.17E-15	1.55E-14
	Std.	0	4.44E-16	7.746254	3.17E-15	0
F11	Best	0	0	4.23E-05	0	0
	Mean	0	0	30.08476681	0.003527721	0.001273467
	Std.	0	0	64.117691	0.003527721	0.004107
F12	Best	1.45E-10	7.29E-18	4.82E-06	0.001446159	0.012188712
	Mean	2.52E-09	1.23E-15	8533334.669	0.008996273	0.057084543
	Std.	0	1.23E-15	4.67E+07	0.008996273	0.093799
F13	Best	2.14E-09	4.68E-17	1.96E-04	0.009585554	0.213322385
	Mean	7.33E-04	1.55E-14	0.295780993	0.199160555	0.517233149
	Std.	0.002788	1.55E-14	0.600144	0.199160555	0.165819
F14	Best	0.998003838	0.998003838	0.998003838	0.998003838	0.998003838
	Mean	0.998003838	0.998003838	2.706762397	4.037183151	5.102662443
	Std.	0	0.998003838	2.444637	4.037183151	4.717367
F15	Best	3.07E-04	3.07E-04	6.99E-04	3.10E-04	3.07E-04
	Mean	3.69E-04	3.38E-04	0.00127137	5.75E-04	0.002352523
	Std.	2.32E-04	3.38E-04	0.001393	5.75E-04	0.006109
F16	Best	-1.031628453	-1.031628453	-1.031628453	-1.031628453	-1.03162845
	Mean	-1.031628453	-1.031628453	-1.031628453	-1.031628453	-1.031628448
	Std.	0	-1.031628453	0	-1.031628453	0
F17	Best	0.397887358	0.397887358	0.397887358	0.397887358	0.39788736
	Mean	0.397887358	0.397887358	0.397887358	0.397888422	0.397894571
	Std.	0	0.397887358	0	0.397888422	3.70E-05
F18	Best	3	3	3	3.000000001	3.000000095
	Mean	3	3	3	3.00001101	3.000010671
	Std.	0	3	0	3.00001101	1.30E-05
F19	Best	-3.862782148	-3.862782148	-3.862782148	-3.862781448	-3.86278206
	Mean	-3.862782148	-3.862782148	-3.862782148	-3.859754165	-3.861232901
	Std.	0	-3.862782148	0	-3.859754165	0.002822
F20	Best	-3.321995172	-3.321995172	-3.321995172	-3.321965726	-3.32199421
	Mean	-3.270474819	-3.290290339	-3.240360435	-3.244925424	-3.267455724
	Std.	0.059923	-3.290290339	0.059893	-3.244925424	0.064446

Function		PO	SPO	MFO	WOA	GWO
F21	Best	-10.15319968	-10.15319968	-10.15319968	-10.15319041	-10.1530422
	Mean	-10.15319968	-10.15319968	-5.97112902	-9.131934936	-8.969295143
	Std.	0	-10.15319968	3.372147	-9.131934936	2.181789
F22	Best	-10.40294057	-10.40294057	-10.40294057	-10.40291587	-10.4028877
	Mean	-10.18031923	-10.18031923	-7.265857031	-8.761099557	-10.22664576
	Std.	1.219347	-10.18031923	3.67739	-8.761099557	0.962962
F23	Best	-10.53640982	-10.53640982	-10.53640982	-10.53637143	-10.5363777
	Mean	-10.31291664	-10.31304372	-7.150894858	-8.236568468	-10.26546163
	Std.	1.223403	-10.31304372	3.724506	-8.236568468	1.481445
Score	Best	14	19	7	3	2
	Mean	13	19	3	1	1
	Std.	17	19	4	6	7
		44	57	14	10	10

二、SPO 和 PO 全局與區域搜索比例結果

本研究改進演算法之目標在於強化其全域搜尋能力。由表 7 可觀察到，SPO 在全域探索比例上呈現上升趨勢，顯示所提出之機制能有效提升演算法之探索能力。

表 7

SPO 和 PO 全局與區域搜索比例結果

Function		SPO	PO
F1	區域搜索 (%)	91.77533	95.58676
	全域探索 (%)	8.224674	4.41324
F2	區域搜索 (%)	89.2678	93.98195
	全域探索 (%)	10.7322	6.018054
F3	區域搜索 (%)	94.88465	94.58375
	全域探索 (%)	5.115346	5.416249
F4	區域搜索 (%)	86.25878	94.18255
	全域探索 (%)	13.74122	5.817452
F5	區域搜索 (%)	22.3671	43.32999
	全域探索 (%)	77.6329	56.67001
F6	區域搜索 (%)	27.98395	37.31194
	全域探索 (%)	72.01605	62.68806
F7	區域搜索 (%)	50.25075	51.25376
	全域探索 (%)	49.74925	48.74624
F8	區域搜索 (%)	30.39117	35.80742
	全域探索 (%)	69.60883	64.19258
F9	區域搜索 (%)	51.25376	51.55466
	全域探索 (%)	48.74624	48.44534
F10	區域搜索 (%)	52.85858	52.65797
	全域探索 (%)	47.14142	47.34203
F11	區域搜索 (%)	51.55466	51.55466
	全域探索 (%)	48.44534	48.44534
F12	區域搜索 (%)	22.1665	38.81645
	全域探索 (%)	77.8335	61.18355

Function		SPO	PO
<i>F13</i>	區域搜索 (%)	25.37613	40.82247
	全域探索 (%)	74.62387	59.17753
<i>F14</i>	區域搜索 (%)	49.94985	48.34504
	全域探索 (%)	50.05015	51.65496
<i>F15</i>	區域搜索 (%)	45.03511	51.75527
	全域探索 (%)	54.96489	48.24473
<i>F16</i>	區域搜索 (%)	48.84654	51.95587
	全域探索 (%)	51.15346	48.04413
<i>F17</i>	區域搜索 (%)	48.94684	49.64895
	全域探索 (%)	51.05316	50.35105
<i>F18</i>	區域搜索 (%)	48.24473	48.54564
	全域探索 (%)	51.75527	51.45436
<i>F19</i>	區域搜索 (%)	47.64293	47.44233
	全域探索 (%)	52.35707	52.55767
<i>F20</i>	區域搜索 (%)	48.14443	47.04112
	全域探索 (%)	51.85557	52.95888
<i>F21</i>	區域搜索 (%)	47.44233	49.54865
	全域探索 (%)	52.55767	50.45135
<i>F22</i>	區域搜索 (%)	46.63992	51.95587
	全域探索 (%)	53.36008	48.04413
<i>F23</i>	區域搜索 (%)	45.53661	52.55767
	全域探索 (%)	54.46339	47.44233

三、參數辨識結果

為了驗證 SPO 適用於光伏電池參數辨識，分別對四種二極體電路進行參數辨識，實驗數據使用兩組廣泛應用的光伏數據集，以操作溫度 303.15 K 及輻射度 1000 W/m² 的光照條件的商用型 R.T.C France 光伏電池，和操作溫度 318.15 K 及輻射度 1000 W/m² 的光照條件的 Photowatt-PWM201 模組(Premkumar et al., 2020)。

(一)光伏模型

由表 8 可知 SPO 的最優解比 PO 優秀，可知 Shuffle 加強在探索階段的多樣性，提升總體演算法的搜尋能力。圖 8 分別為四種光伏模型參數辨識之最優解結果。

表 8

光伏模型參數辨識之最優解結果

	<i>SDM</i>	<i>DDM</i>	<i>TDM</i>	<i>PMM</i>
<i>SPO</i>	8.8180080×10^{-4}	8.54×10^{-4}	8.49×10^{-4}	2.394×10^{-3}
<i>PO</i>	8.8180083×10^{-4}	8.75×10^{-4}	8.60×10^{-4}	2.604×10^{-3}




圖8 光伏電池模型 (a) SDM (b) DDM (c) TDM (d) PMM 之最佳收斂曲線

伍、結論

本研究以仿生演算法中的PO為基礎，並結合洗牌機制的高隨機性特徵進行改良，提出改良型演算法 SPO。首先，透過 23 個 Benchmark Function 驗證其效能，並以平均值、最佳值及標準差進行統計評估，結果顯示 SPO 獲得 57 分，顯著優於原始 PO 的 44 分以及 MFO (14 分)、WOA (10 分)與 GWO (9/10 分)，凸顯其在多種測試函數上的優勢。其次，透過分析演算法開發和探索比例的變化，證實洗牌機制能有效提升探索階段的比例，進而在搜尋過程中促進開發與探索的平衡。在光伏模組中，改良後的 SPO 在最優解結果上優於原始 PO，相較於原始 PO、MFO、WOA 及 GWO，SPO 展現出更快的收斂速度與更高的運算精確度。

參考文獻

- Abdollahzadeh, B., Khodadadi, N., Barshandeh, S., Trojovský, P., Gharehchopogh, F. S., El-Kenawy, E. S. M., ... & Mirjalili, S. (2024). Puma optimizer (PO): a novel metaheuristic optimization algorithm and its application in machine learning. *Cluster Computing*, 27(4), 5235-5283. 27(4), 5235-5283.
- Kennedy, J., & Eberhart, R. (1995, November). Particle swarm optimization. In *Proceedings of ICNN'95-international conference on neural networks* (Vol. 4, pp. 1942-1948). IEEE.
- Kullampalayam Murugaiyan, N., Chandrasekaran, K., Manoharan, P., & Derebew, B. (2024). Leveraging opposition-based learning for solar photovoltaic model parameter estimation with exponential distribution optimization algorithm. *Scientific Reports*, 14(1), 528.
- Lambora, A., Gupta, K., & Chopra, K. (2019, February). Genetic algorithm-A literature review. In *2019 international conference on machine learning, big data, cloud and parallel computing (COMITCon)* (pp. 380-384). IEEE.
- Liu, E. J., Chen, R. W., Wang, Q. A., & Lu, W. L. (2025). Shuffled puma optimizer for parameter extraction and sensitivity analysis in photovoltaic models. *Energies*, 18(15), 4008.
- Lelie, M., Braun, T., Knips, M., Nordmann, H., Ringbeck, F., Zappen, H., & Sauer, D. U. (2018). Battery management system hardware concepts: An overview. *Applied Sciences*, 8(4), 534.
- Marti, A., Balenzategui, J. L., & Reyna, R. F. (1997). Photon recycling and Shockley's diode equation. *Journal of Applied Physics*, 82(8), 4067-4075.
- Mirjalili, S. (2015). Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm. *Knowledge-based systems*, 89, 228-249.
- Mirjalili, S., & Lewis, A. (2016). The whale optimization algorithm. *Advances in engineering software*, 95, 51-67.
- Mirjalili, S., & Lewis, A. (2016). The whale optimization algorithm. *Advances in engineering software*, 95, 51-67.
- Premkumar, M., Babu, T. S., Umashankar, S., & Sowmya, R. (2020). A new metaphor-less algorithms for the photovoltaic cell parameter estimation. *Optik*, 208, 164559.
- Wolpert, D. H., & Macready, W. G. (2002). No free lunch theorems for optimization. *IEEE transactions on evolutionary computation*, 1(1), 67-82.
- Yao, X., Liu, Y., & Lin, G. (1999). Evolutionary programming made faster. *IEEE Transactions on Evolutionary computation*, 3(2), 82-102.
- Zhou, T. T., & Shang, C. (2024). Parameter identification of solar photovoltaic models by multi strategy sine-cosine algorithm. *Energy Science & Engineering*, 12(4), 1422-1445.