



UNIVERSIDADE DA BEIRA INTERIOR
Engenharia

Algoritmo Multiswarm Spiral Leader Particle Swarm Optimization para a estimação dos parâmetros PV

Pedro Nuno Carriço Silva

Dissertação para obtenção do Grau de Mestre em
Engenharia Eletrotécnica e de Computadores
(2º ciclo de estudos)

Orientadora: Prof^a. Doutora Maria do Rosário Alves Calado
Coorientador: Prof. Doutor José Álvaro Nunes Pombo

Covilhã, outubro de 2019

Dedicatória

Dedico este trabalho a toda a minha família e namorada pelo apoio, confiança e incentivo que generosamente me dispensaram ao longo desta caminhada.

Agradecimentos

O maior desafio, ao longo do meu percurso académico foi, sem dúvida, a realização do presente trabalho. Os meus sinceros agradecimentos a todos os que, de alguma forma, participaram e ajudaram na realização desta dissertação.

Agradeço, em primeiro lugar, aos Professores Doutores Maria do Rosário Alves Calado e José Álvaro Nunes Pombo, por toda a atenção, todas as horas que disponibilizaram para me ajudar e aconselhar durante a orientação deste trabalho. Sem a sua ajuda, a realização deste trabalho seria impossível.

Agradeço a todos os Professores pela disponibilidade e apoio que sempre demonstraram perante o meu percurso académico.

À Universidade da Beira Interior pelo apoio financeiro e, em especial, à Faculdade de Engenharia por me ter conduzido ao longo dos últimos anos.

Ao meu amigo Mestre Hugo Nunes pelo acompanhamento e auxílio na preparação desta dissertação.

A todos os demais, familiares, amigos, colegas e professores que, de algum modo, contribuíram com a sua amizade, carinho e motivação para a conclusão deste trabalho.

Finalmente, um agradecimento muito especial à minha namorada e melhor amiga, Bruna Silvestre, aos meus pais, Paula Silva e Pedro Silva, à minha irmã, Ana Rita Silva e respetivo companheiro, Helder Martins, pelo incentivo e apoio incondicional que me prestaram ao longo desta minha caminhada.

Resumo

O interesse em explorar a energia fotovoltaica tem crescido muito nos últimos anos. Tal deve - se ao facto de ser um tipo de energia renovável muito disponível (visto que provém do sol) e com um grande potencial de expansão e desenvolvimento. Nesse sentido, é essencial o desenvolvimento de métodos que permitam prever e analisar o comportamento dos sistemas fotovoltaicos, i.e., métodos que estimem com precisão os parâmetros dos módulos PV, sob quaisquer condições de operação.

O objetivo principal desta dissertação é descrever com exatidão a modelação de sistemas fotovoltaicos. Primeiramente é feita uma apresentação sobre os tipos de tecnologias fotovoltaicas existentes atualmente e também sobre o funcionamento dos sistemas fotovoltaicos em geral. Seguidamente são apresentados os vários modelos matemáticos que permitem caracterizar esses sistemas fotovoltaicos bem como os vários métodos utilizados para estimar os respetivos parâmetros. Essa estimação é feita a partir da informação disponibilizada pelos fabricantes ou através de dados medidos experimentalmente.

Por conseguinte, é aqui proposto um novo método denominado de *Multiswarm Spiral Leader Particle Swarm Optimization (M-SLPSO)*, com base no PSO, para resolver o problema da estimação dos parâmetros dos sistemas PV. Este método utiliza vários *swarms* com diferentes mecanismos de procura e cada *swarm* é guiado por um líder com uma trajetória em espiral diferente. De acordo com o desempenho dos *swarms*, estes podem trocar de mecanismos de procura entre si e os agentes podem migrar entre *swarms*, possibilitando assim um bom balanço entre os mecanismos de intensificação e de diversificação. Este método mantém uma boa diversidade nas trajetórias de exploração enquanto constrói novas soluções ao longo do processo de procura, mitigando a estagnação da população e a convergência prematura. Para além disso, consegue explorar o espaço de procura multidimensional em diferentes regiões simultaneamente e consegue adaptar-se aos vários problemas de otimização.

Finalmente, é feita uma análise e discussão dos resultados obtidos pelo método na resolução de funções de *benchmark* e na estimação dos parâmetros fotovoltaicos. Esses resultados são comparados com os resultados obtidos por vários algoritmos metaheurísticos de última geração e mostram que o método proposto apresenta um desempenho muito competitivo, encontrando soluções muito precisas e fiáveis.

Palavras-chave

Otimização; *Particle Swarm Optimization*; *Spiral Dynamics Algorithm*; *Multiswarm*; Modelo de um diodo; Modelo de dois díodos; Estimação de parâmetros; Produção fotovoltaica;

Abstract

The interest in exploring photovoltaic energy has grown a lot in recent years. This is due to the fact that is a type of renewable energy widely available (as it comes from the sun) and has great potential for improvement and expansion. To this end, it is essential to develop methods for predicting and analyzing the behavior of these photovoltaic systems under any operation conditions, i.e., methods that estimate with precision the photovoltaic model parameters under any operation conditions.

The main goal of this dissertation is to accurately describe the modeling of photovoltaic systems. Firstly, a presentation is made about the types of photovoltaic technologies currently available and also about the operation of the photovoltaic systems in general. After that, various mathematical models that allow the characterization of these photovoltaic systems as well as the various methods used to estimate their parameters are also presented. This estimation is either based on information provided by manufacturers or experimentally measured data.

Therefore, a new method called Multiswarm Spiral Leader Particle Swarm Optimization (M-SLPSO) based on the PSO, is proposed to solve the PV parameter estimation problem. This proposed method uses several swarms with different search mechanisms and each swarm is guided by a leader with a different spiral trajectory. Depending on the performance of the swarms, they can exchange search mechanisms with one another, and agents can migrate between swarms, enabling a good balance between the intensification and diversification mechanisms. This method maintains a good diversity in the exploration trajectories while building new solutions throughout the search process, mitigating population stagnation and premature convergence. In addition, it can explore the multidimensional search space in different regions simultaneously and can adapt to various optimization problems.

Finally, an analysis and discussion of the obtained results by the algorithm in the resolution of benchmark functions and in the estimation of photovoltaic parameters is made. These results are compared with the results obtained by several state-of-the-art metaheuristic algorithms and they show that the proposed algorithm presents a very competitive performance, finding highly accurate and reliable solutions.

Keywords

Optimization; Particle Swarm Optimization; Spiral Dynamics Algorithm; Multiswarm; Single-diode model; Double-diode model; Parameter estimation; Photovoltaic production.

Índice

Capítulo 1.....	1
1. Introdução.....	1
1.1. Importância e enquadramento do tema	1
1.2. Motivação e objetivos da investigação	6
1.3. Organização da dissertação	7
Capítulo 2.....	9
2. Produção fotovoltaica	9
2.1. Tecnologias de células fotovoltaicas.....	9
2.1.1. Tecnologia de 1ª Geração - Silício cristalino	9
2.1.2. Tecnologia de 2ª Geração - Filme fino	11
2.1.3. Tecnologia de 3ª Geração	12
2.2. Curvas características.....	14
2.3. Configurações de módulos PV.....	16
2.3.1. Configuração em série	16
2.3.2. Configuração em paralelo.....	17
2.3.3. Configuração mista.....	18
2.4. Díodos de bypass e de bloqueio	19
Capítulo 3.....	23
3. Modelação matemática.....	23
3.1. Modelos matemáticos	23
3.1.1. Modelo ideal	24
3.1.2. Modelo de um diodo (SDM)	25
3.1.3. Modelo de dois diodos (DDM)	26
3.1.4. Modelo de três diodos	28
3.1.5. Modelo de multidiodo.....	29
3.1.6. Modelo de diodo multidimensão	29
3.1.7. Modelo de Bishop.....	30

3.2.	Formulação do problema	31
3.3.	Métodos de estimação dos parâmetros PV	34
3.3.1.	Métodos analíticos	35
3.3.2.	Métodos numéricos	35
3.3.3.	Métodos híbridos	37
Capítulo 4	39
4.	Multiswarm spiral leader particle swarm optimization (M-SLPSO).....	39
4.1.	Particle Swarm Optimization (PSO).....	40
4.2.	Spiral dynamics algorithm (SDA)	42
4.3.	Mapas caóticos.....	45
4.4.	Algoritmo M-SLPSO	47
Capítulo 5	53
5.	M-SLPSO na resolução de funções de benchmark	53
5.1.	Otimização dos parâmetros de controlo	56
5.2.	Critérios de desempenho.....	57
5.3.	Resultados e análise estatística	58
Capítulo 6	63
6.	Estimação dos parâmetros PV, análise e discussão dos resultados	63
6.1.	Introdução.....	63
6.2.	Caso de estudo 1 - Photowatt-PWP201	64
6.2.1.	Resultados para o modelo de um díodo.....	64
6.2.2.	Resultados para o modelo de dois díodos	68
6.3.	Caso de estudo 2 - resultados experimentais do módulo PV Sharp ND-R250A5.....	72
6.3.1.	Resultados para o modelo de um díodo.....	72
6.3.2.	Resultados para o modelo de dois díodos	75
6.4.	Resultados estatísticos	79
Capítulo 7	85
7.	Conclusão	85
7.1.	Considerações finais	85
7.2.	Trabalhos futuros.....	88

Referências Bibliográficas.....	89
Anexos	101

Índice de Figuras

Figura 1.1 - Distribuição da potência instalada por tecnologia renovável em Portugal em 2018 (adaptado de [6]).	3
Figura 1.2 - Balanço da produção de energia em Portugal Continental (adaptado de [7]).	4
Figura 1.3 - Evolução da potência instalada por tipo de tecnologia renovável [6].	5
Figura 1.4 - Produção de energia PV ao longo dos anos por região em Portugal Continental (adaptado de [6]).	5
Figura 1.5 - Incorporação de energias renováveis de produção de energia elétrica em vários países da União Europeia [6].	6
Figura 2.1 - Célula solar monocristalina de silício [15].	10
Figura 2.2 - Célula solar de silício policristalino [15].	10
Figura 2.3 - Célula PV CIGS.	11
Figura 2.4 - Gráfico relativo aos melhores valores de eficiência alcançados em laboratório ao longo dos anos (adaptado de [18]).	12
Figura 2.5 - Representação das curvas características I-V (a) e P-V (b).	14
Figura 2.6 - Fator de forma de uma célula ou módulo PV.	16
Figura 2.7 - Células solares de silício cristalino ligadas em série (adaptado de [31]).	17
Figura 2.8 - Células PV ligadas com uma configuração em série.	17
Figura 2.9 - Células PV ligadas com uma configuração em paralelo.	18
Figura 2.10 - Células PV ligadas com uma configuração mista.	18
Figura 2.11 - Representação de um módulo PV.	20
Figura 2.12 - Curvas características I-V (esquerda) e P-V (direita) retiradas de um módulo PV sem sombreamento parcial.	20
Figura 2.13 - Fotografia do módulo PV sem sombreamento parcial.	21

Figura 2.14 - Curvas características I-V (esquerda) e P-V (direita) retiradas de um módulo PV com sombreamento parcial simulado.	21
Figura 2.15 - Fotografia do módulo PV com sombreamento parcial simulado.	21
Figura 3.1 - Curva característica I-V de uma célula PV.	24
Figura 3.2 - Circuito equivalente do modelo matemático ideal.	25
Figura 3.3 - Circuito equivalente do modelo matemático de um díodo de uma célula PV.	26
Figura 3.4 - Circuito equivalente do modelo matemático de dois díodos de uma célula PV. ...	27
Figura 3.5 - Circuito equivalente do modelo matemático de três díodos de uma célula PV. ...	28
Figura 3.6 - Circuito equivalente do modelo matemático de multidíodo de uma célula PV. ...	29
Figura 3.7 - Circuito equivalente do modelo matemático de díodo multidimensão de uma célula PV.	30
Figura 3.8 - Circuito equivalente do modelo matemático de <i>Bishop</i> de uma célula PV.	31
Figura 3.9 - Fluxograma do método de Newton-Raphson (adaptado de [34]).	34
Figura 4.1 - Representação gráfica da evolução das partículas com o PSO.	41
Figura 4.2 - Fluxograma do PSO.	41
Figura 4.3 - Trajetórias em espiral consideradas para o M-SLPSO: (a) Trajetória em espiral do <i>swarm</i> 1; (b) Trajetória em espiral do <i>swarm</i> 2; (c) Trajetória em espiral do <i>swarm</i> 3; (d) Trajetória em espiral do <i>swarm</i> 4; (e) Trajetória em espiral do <i>swarm</i> 5.	44
Figura 4.4 - Visualização dos diversos mapas caóticos considerados para o M-SLPSO.	46
Figura 4.5 - Representação esquemática do M-SLPSO.	48
Figura 4.6 - Fluxograma do M-SLPSO.	50
Figura 5.1 - Classificação média calculada pelo teste de Friedman dos 11 MHs em todas as funções de <i>benchmark</i>	61
Figura 5.2 - SR média dos 11 MHs em todas as funções de <i>benchmark</i>	61
Figura 6.1 - Valores do IAE entre os dados experimentais e os dados estimados para o SDM. .	66

Figura 6.2 - Curva I-V que contém a comparação entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO para o SDM.	67
Figura 6.3 - Curva P-V que contém a comparação entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO para o SDM.	67
Figura 6.4 - Valores do IAE entre os dados experimentais e os dados estimados para o DDM. .	70
Figura 6.5 - Curva I-V que contém a comparação entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO para o DDM.	71
Figura 6.6 - Curva P-V que contém a comparação entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO para o DDM.	71
Figura 6.7 - Representação dos valores do IAE entre os dados experimentais e os dados estimados para as diferentes condições de operação para o SDM.	73
Figura 6.8 - Curva característica I-V com as comparações entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO em diferentes condições de operação para o SDM. ...	74
Figura 6.9 - Curva característica P-V com as comparações entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO em diferentes condições de operação para o SDM. ...	74
Figura 6.10 - Representação dos valores do IAE entre os dados experimentais e os dados estimados para as diferentes condições de operação para o DDM.	77
Figura 6.11 - Curva característica I-V com as comparações entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO em diferentes condições de operação para o DDM. ...	78
Figura 6.12 - Curva característica P-V com as comparações entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO em diferentes condições de operação para o DDM. ...	78
Figura 6.13 - Distribuição do RMSE alcançada pelo M-SLPSO em 100 simulações para o SDM e DDM para o módulo PV Photowatt-PWP201.	82
Figura 6.14 - Distribuição do RMSE alcançada pelo M-SLPSO em 100 simulações com o SDM para diferentes condições de operação (módulo PV Sharp ND-R250A5).	82
Figura 6.15 - Distribuição do RMSE alcançada pelo M-SLPSO em 100 simulações com o DDM para diferentes condições de operação (módulo PV Sharp ND-R250A5).	83

Índice de Tabelas

Tabela 3.1 - Limites dos parâmetros para o SDM e DDM nos dois casos de estudo.	32
Tabela 4.1 - Mapas caóticos (retirado de [137])	45
Tabela 5.1 - Funções de <i>benchmark</i> usadas para avaliar o desempenho do M-SLPSO e a sua formulação.	54
Tabela 5.2 - Configuração dos parâmetros dos diferentes MHs.	56
Tabela 5.3 - Comparação dos valores dos erros (média e DP) alcançados pelos onze MHs em 100 simulações para as 17 funções escolhidas.	59
Tabela 6.1 - Comparação dos resultados entre o M-SLPSO e outros algoritmos de última geração encontrados na literatura para o módulo PV Photowatt-PWP201 com o SDM.	65
Tabela 6.2 - Comparação entre os resultados obtidos pelo M-SLPSO e por outros algoritmos de última geração para o módulo PV Photowatt-PWP201 com o DDM.	69
Tabela 6.3 - Parâmetros ótimos e valores do RMSE para o SDM obtidos pelo algoritmo M-SLPSO em diferentes condições de operação para o módulo PV Sharp ND-R250A5.	72
Tabela 6.4 - Parâmetros ótimos e valores do RMSE para o DDM obtidos pelo algoritmo M-SLPSO em diferentes condições de operação para o módulo PV Sharp ND-R250A5.	76
Tabela 6.5 - Resultados estatísticos do RMSE, número de iterações e tempo de simulação do M-SLPSO para cada caso de estudo para o SDM e para o DDM em 100 simulações independentes.	80

Lista de Siglas e Acrónimos

<i>α-Si</i>	Silício amorfo
<i>A-bcNM</i>	Método analítico com NMS
<i>ABC</i>	<i>Artificial Bee Colony</i>
<i>ABC-TRR</i>	<i>ABC com Trust-Region Reflective</i>
<i>AE</i>	<i>Absolute error</i> (erro absoluto)
<i>ALO</i>	<i>Ant Lion Optimizer</i>
<i>ALO-LW</i>	<i>Ant Lion Optimizer com Lambert W function</i>
<i>BPFPA</i>	<i>Bee Pollinator Flower Pollination Algorithm</i>
<i>BBO-M</i>	<i>Biogeography-Based Optimization with Mutation Strategies</i>
<i>BSA</i>	<i>Backtracking Search Algorithm</i>
<i>C-HCLPSO</i>	<i>Chaotic Heterogeneous Comprehensive Learning Particle Swarm Optimizer</i>
<i>CdTe</i>	Telureto de cádmio
<i>CGSA</i>	<i>Chaotic Gravitational Search Algorithm</i>
<i>CIABC</i>	<i>Chaotic Improved Artificial Bee Colony</i>
<i>CIGS</i>	Células de cobre, índio, gálio e selênio
<i>CPV</i>	<i>Concentrating Photovoltaics</i>
<i>CS</i>	<i>Cuckoo search</i>
<i>CSO</i>	<i>Cat Swarm Optimization</i>
<i>CWOA</i>	<i>Chaotic Whale Optimization Algorithm</i>
<i>DDM</i>	<i>Double diode model</i> (modelo de dois díodos)
<i>DE</i>	<i>Differential evolution</i>
<i>DET</i>	<i>Adaptive DE Technique</i>
<i>DP</i>	Desvio-padrão
<i>ELPSO</i>	<i>Enhanced Leader Particle Swarm Optimization</i>
<i>EPFL</i>	<i>École Polytechnique Fédérale de Lausanne</i>
<i>ePSO</i>	<i>Extrapolated PSO</i>
<i>FA</i>	<i>Firefly Algorithm</i>
<i>FF</i>	Fator de forma
<i>FO</i>	Função objetivo
<i>FPA</i>	<i>Flower Pollination Algorithm</i>
<i>FPSO</i>	<i>Forking PSO</i>
<i>GA</i>	<i>Genetic Algorithm</i>
<i>GACCC</i>	<i>Genetic Algorithm with Convex Combination Crossover</i>
<i>GCPSO</i>	<i>Guaranteed Convergence Particle Swarm Optimization</i>
<i>GOFPANM</i>	<i>Hybrid Flower Pollination Algorithm</i>
<i>GWO</i>	<i>Grey Wolf Optimizer</i>
<i>GSA</i>	<i>Gravitational Search Algorithm</i>
<i>HPSOSA</i>	Hybridization of PSO with SA
<i>HS</i>	<i>Harmony Search</i>
<i>I-V</i>	Corrente-tensão
<i>IAE</i>	<i>Individual absolute error</i> (erro absoluto individual)
<i>IDE-PSO</i>	<i>Individual Difference Evolution PSO</i>
<i>IJAYA</i>	<i>Improved JAYA</i>
<i>ILCOA</i>	<i>Improved Lozi map Based Chaotic Optimization Algorithm</i>
<i>ImCSA</i>	<i>Improved Cuckoo Search Algorithm</i>

<i>ISCE</i>	<i>Improved Shuffled Complex Evolution</i>
<i>ITO</i>	Óxido de índio-estanho
<i>ITLBO</i>	<i>Improved Teaching Learning Based Optimization</i>
<i>IWOA</i>	<i>Improved Whale Optimization Algorithm</i>
<i>LDW-PSO</i>	<i>Linearly Decreasing Weight PSO</i>
<i>LFPSO</i>	<i>Levy Flight Particle Swarm Optimization</i>
<i>LM</i>	Algoritmo de <i>Levenberg-Marquardt</i>
<i>LMSA</i>	LM com SA
<i>MAE</i>	<i>Medium absolute error</i> (erro absoluto médio)
<i>mc-Si</i>	Silício policristalino
<i>MCPSO</i>	<i>Multiswarm Cooperative PSO</i>
<i>MH</i>	Metaheurístico
<i>MLBSA</i>	<i>Multiple Learning Backtracking Search Algorithm</i>
<i>MNMS</i>	<i>Modified Nelder-Mead Simplex</i>
<i>MPP</i>	<i>Maximum power point</i> (ponto de máxima potência)
<i>MPSO</i>	<i>Modified PSO</i>
<i>MSCPSO</i>	<i>Multiswarm Self-Adaptive and Cooperative PSO</i>
<i>M-SLPSO</i>	<i>Multiswarm Spiral Leader Particle Swarm Optimization</i>
<i>NM-MPSO</i>	NM com MPSO
<i>NMS</i>	<i>Nelder-Mead Simplex</i>
<i>NOCT</i>	<i>Normal operating cell temperature</i>
<i>NRM</i>	Método de Newton-Raphson
<i>OC</i>	Ponto de circuito-aberto
<i>OBWOA</i>	<i>Improved Whale Optimization Algorithm using Opposition-Based Learning</i>
<i>OR_{CR}-IJADE</i>	<i>Onlooker-Ranking-Based Mutation Operator into an Improved Adaptive Differential Evolution</i>
<i>P-V</i>	Potência-tensão
<i>pf-PSO</i>	<i>Parameter-free PSO</i>
<i>PGJAYA</i>	<i>Performance-Guided JAYA algorithm</i>
<i>PS</i>	<i>Pattern Search</i>
<i>PSO</i>	<i>Particle Swarm Optimization</i>
<i>PV</i>	Fotovoltaico
<i>QPSO</i>	<i>Quantum PSO</i>
<i>RMSE</i>	<i>Root-mean-square error</i> (raiz quadrada do erro quadrático médio)
<i>SA</i>	<i>Simulated Annealing</i>
<i>SATLBO</i>	<i>Self-Adaptive Teaching Learning Based Optimization</i>
<i>SC</i>	Ponto de curto-circuito
<i>sc-Si</i>	Silício monocristalino
<i>SCA</i>	<i>Sine Cosine Algorithm</i>
<i>SDA</i>	<i>Spiral Dynamics Algorithm</i>
<i>SDM</i>	<i>Single diode model</i> (modelo de um diodo)
<i>SOS</i>	<i>Symbiotic Organisms Search</i>
<i>SR</i>	Taxa de sucesso ou <i>Successful rate</i>
<i>SSE</i>	Erro quadrático
<i>SSM-PSO</i>	<i>Supervisor Student Model PSO</i>
<i>STC</i>	<i>Standard test conditions</i>
<i>TLABC</i>	<i>Teaching-Learning-Based ABC</i>
<i>TLBO</i>	<i>Teaching-Learning-Based Optimization</i>
<i>TVACPSO</i>	<i>Time Varying Acceleration Coefficients PSO</i>

WDO *Wind Driven Optimization*
WOA *Whale Optimization Algorithm*

Lista de Símbolos

a	Número do agente
AM	Massa de ar
c_1	Coefficiente de aceleração cognitivo
c_2	Coefficiente de aceleração social
CR	Constante de <i>crossover</i> (algoritmo DE)
d	Dimensão do espaço de procura
E_{gap}	<i>Band gap</i> do material semiconductor
F	Fator de mutação (algoritmo DE)
G	Irradiância incidente
$gbest$	Melhor solução global
$Gbest$	Melhor global
$itermax$	Número máximo de iterações
I	Corrente de saída [A]
I_0, I_{01}, I_{02}	Corrente de saturação inversa dos díodos [μ A]
I_d, I_{d1}, I_{d2}	Correntes dos díodos [A]
Ind_{Gbest}	Índice da melhor solução global
Ind_{Lbest}	Índice da melhor solução local
Ind_{Lworst}	Índice da pior solução local
I_{mpp}	Corrente no ponto de potência máxima [A]
I_{ph}	Corrente fotoelétrica[A]
I_{sc}	Corrente de curto-circuito [A]
\hat{I}	Corrente estimada [A]
k	Constante de Boltzman [J/K]
L_{best}	Melhor local
n, n_1, n_2	Fator de idealidade dos díodos
N	Número dos pares de dados I-V experimentais
N_s	Número de células ligadas em série
N_{swarms}	Número de swarms
P	Número de agentes no <i>swarm</i>
p	Precisão de exploração (algoritmo MVO)
p_a	Taxa de descoberta (algoritmo CS)
$pbest$	Melhor solução individual
PR	Taxa de população
$PR_{Initial}$	Taxa de população inicial
PR_{Max}	Taxa de população máxima
PR_{Min}	Taxa de população mínima
P_T	Número de agentes na população
q	Carga do eletrão [C]
r	Raio da espiral
$r1, r2$	Números aleatórios entre 0 e 1
R	Matriz de rotação composta
R_p	Resistência em paralelo [Ω]
R_s	Resistência em série [Ω]
R_{power}, R_{norm}	Constantes necessárias para o GSA
S_c	Contador de sucessos

S_d	Matriz espiral
t	Iteração atual
T	Temperatura [K]
V	Tensão de saída [V]
V_{mpp}	Tensão no ponto de potência máxima [V]
V_{oc}	Tensão de circuito aberto [V]
V_t	Tensão térmica [V]
Wp	Watt pico
x	Posição do agente
x^*	Ponto central da espiral
x_{Gbest}	Melhor posição global
x_{Lbest}	Posição do líder
x_{Lworst}	Posição do pior líder
ξ	RMSE ponderado
η	Rendimento
DP	Desvio-padrão
α	Coefficiente aleatório entre [0,1]
β	Coefficiente de decaimento exponencial
τ	Parâmetros dos modelos
ϕ	Constante auxiliar de restrição de velocidade
v	Velocidade do agente
ω	Coefficiente de inércia
θ	Ângulo de rotação

Capítulo 1

Neste capítulo é apresentada a importância e o enquadramento do trabalho, a motivação que levou à escolha do tema, os objetivos da investigação e a organização da dissertação.

1. Introdução

1.1. Importância e enquadramento do tema

Desde o início da revolução industrial que o mundo tem vindo a enfrentar consequências nefastas para o meio ambiente que aumentam constantemente devido à emissão de gases provenientes da combustão de combustíveis fósseis. A variação dos custos dos combustíveis fósseis como o petróleo, carvão ou o gás natural e as alterações climáticas provocadas pelo CO₂ proveniente da sua combustão, torna a pesquisa e o desenvolvimento de sistemas com base em fontes de energias renováveis essenciais.

Vários países, incluindo Portugal, são deficitários em termos da matéria-prima necessária para produzir a sua energia sendo por isso ainda maior a necessidade na aposta em energias renováveis. Assim, a produção de energia elétrica constitui um grande desafio na atualidade. As tecnologias de geração de energia elétrica, através de fontes renováveis, possuem um papel muito importante não só para diminuir o uso dos combustíveis, como também para consciencializar as pessoas para a proteção do meio ambiente. Entre as fontes de energia renováveis, como a energia eólica, hídrica, geotérmica e biomassa, a energia solar (fotovoltaica ou PV) é considerada a que possui maior potencial devido, em grande parte, à sua grande disponibilidade e ausência de emissões de carbono [1].

A grande desvantagem dos sistemas que exploram a energia solar (sistemas PV) é o elevado custo na produção da energia que é muito superior ao custo da produção de energia das tecnologias tradicionais. No entanto, apresentam imensos benefícios para o meio ambiente e, além disso, existe ainda a possibilidade de se desenvolver um sistema energético autossustentável. A capacidade instalada dos sistemas PV tem vindo a aumentar exponencialmente nas últimas duas décadas, daí ser importante estudar a modelação PV e encontrar maneiras de aumentar a sua eficiência.

Embora os custos dos sistemas PV tenham descido nos últimos anos, ainda existem alguns obstáculos tecnológicos para obter uma implementação economicamente viável [2]. O principal obstáculo consiste na eficiência energética das células PV existentes atualmente.

Em 2017, a capacidade cumulativa de energia solar PV era cerca de 400 GW e gerou aproximadamente 460 TWh, o que representou cerca de 2% da potência global. A China representava cerca de um terço dessa capacidade com mais de 130 GW de capacidade acumulada instalada, seguida pela União Europeia com cerca de 26% ou 107 GW da capacidade total global [3], [4].

Portugal, tem vindo a desenvolver o seu sector de energia solar. Foi inaugurada a primeira grande central solar da Europa em julho de 2016 no distrito de Beja, a produzir energia em regime de mercado, i.e., sem tarifas garantidas ou outros subsídios estatais que acarretam custos para os consumidores e contribuintes. Esta central, que implicou um investimento de 35 milhões de euros, tem uma potência total instalada de 46 MWp e, durante 30 anos, irá produzir 80 GWh de energia por ano [5].

A Figura 1.1 ilustra a distribuição da potência instalada por tecnologia renovável em Portugal no ano de 2018. Através da análise da Figura 1.1, pode-se concluir que o Norte do país possui a maior parte da potência instalada de energia hídrica, seguida pelo Centro do país. De facto, a potência instalada de energia hídrica presente no Norte é superior à soma da potência instalada de energia hídrica do resto do país. Por outro lado, o Centro do país possui a maior parte da potência instalada de energia eólica, seguido pelo Norte. Em relação à potência instalada de energia PV, pode-se verificar que o Alentejo possui a maior parte. É de notar que, desde Junho de 2018 até Junho de 2019, o Alentejo foi responsável por 42% da produção PV nacional [6].

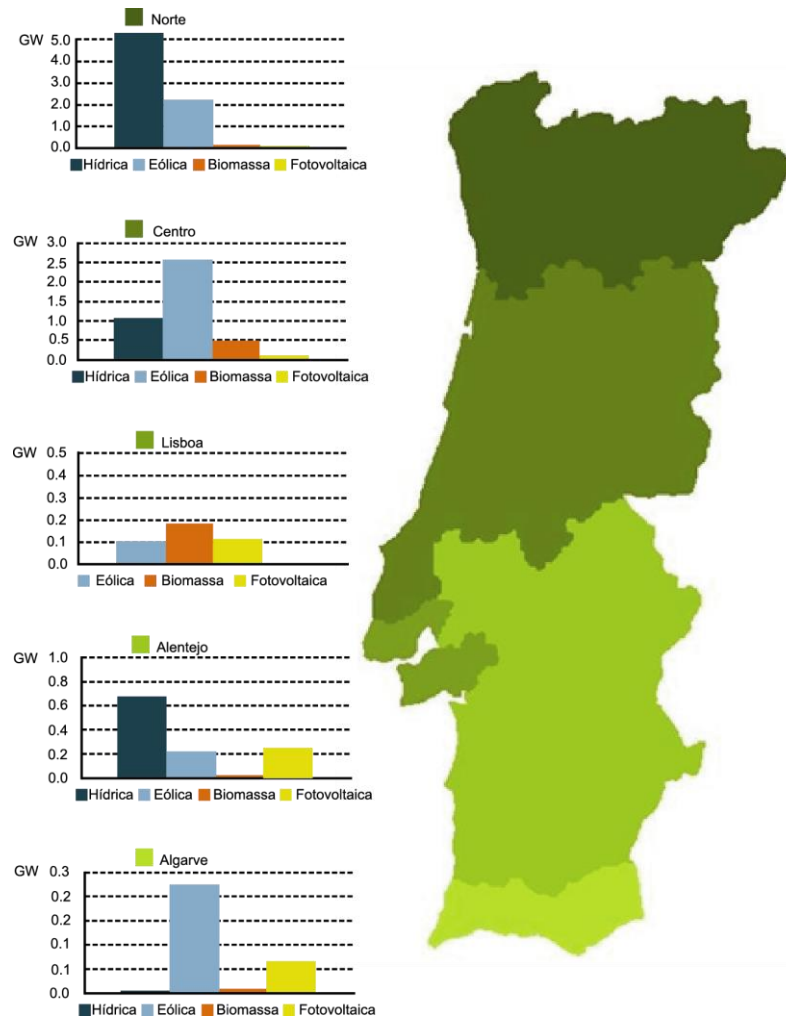


Figura 1.1 - Distribuição da potência instalada por tecnologia renovável em Portugal em 2018 (adaptado de [6]).

A Figura 1.2 ilustra o balanço da produção de energia em Portugal Continental desde janeiro de 2019 até julho de 2019. A partir desta figura, é possível verificar-se que a produção de energia através de fontes renováveis (51.8% ou 16.0 TWh) superou a produção de energia através dos métodos tradicionais fósseis (48.2% ou 14.9 TWh). A energia PV, durante esse tempo, representou um total de 2.4% da energia produzida em Portugal Continental [7].

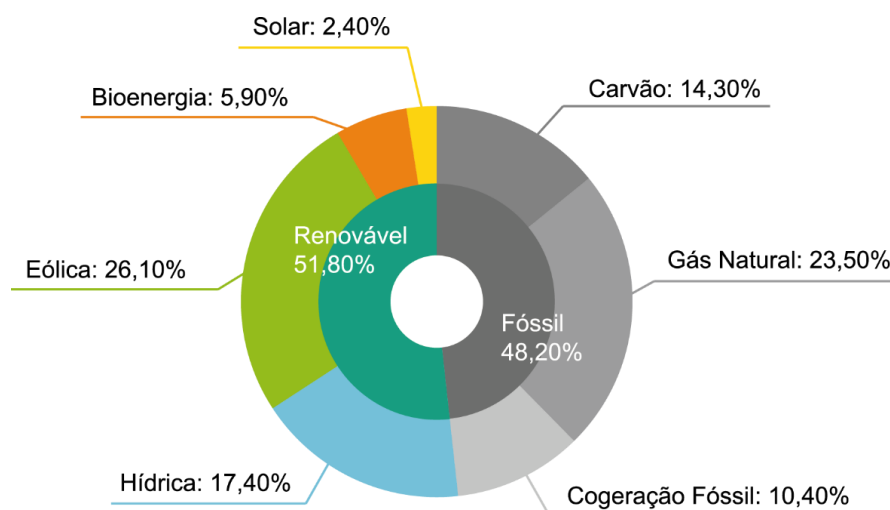


Figura 1.2 - Balanço da produção de energia em Portugal Continental (adaptado de [7]).

A produção de energia através de fontes renováveis tem, obviamente, vindo a crescer cada vez mais nas últimas décadas. Do ano de 2010 a junho de 2019 a fonte de energia renovável que mais cresceu foi a hídrica (crescimento de cerca de 2.2 GW), seguida pela energia eólica (crescimento de cerca de 1.6 GW) e pela energia PV (crescimento de cerca de 625 MW). Contudo, em termos relativos, o tipo de energia renovável com maior crescimento nesse período de tempo foi a PV, visto que evoluiu de uma potência instalada residual para uma potência instalada total de 759 MW [6].

A Figura 1.3 ilustra a evolução da potência instalada em Portugal, por tipo de tecnologia, desde 2010 até 2019, cujo total é de 14174 MW, onde a hídrica possui claramente a maior parte com uma potência instalada de 7111 MW, seguida da eólica com 5425 MW. Já a energia PV possui uma capacidade total instalada de 759 MW.

A Figura 1.4 apresenta a produção de energia PV por região desde 2010 até 2019, onde é claramente visível o seu grande crescimento. Em particular, no ano de 2010 foram produzidos 215 GWh, já em 2014 a produção de energia PV foi quase o triplo com 627 GWh e, finalmente, em 2019, essa produção foi quase o dobro da de 2014, com um valor de 1175 GWh. Além disso, a Figura 1.4 mostra, mais uma vez, que o Alentejo foi responsável pela maior parte da produção de energia PV em Portugal ao longo dos anos [6].

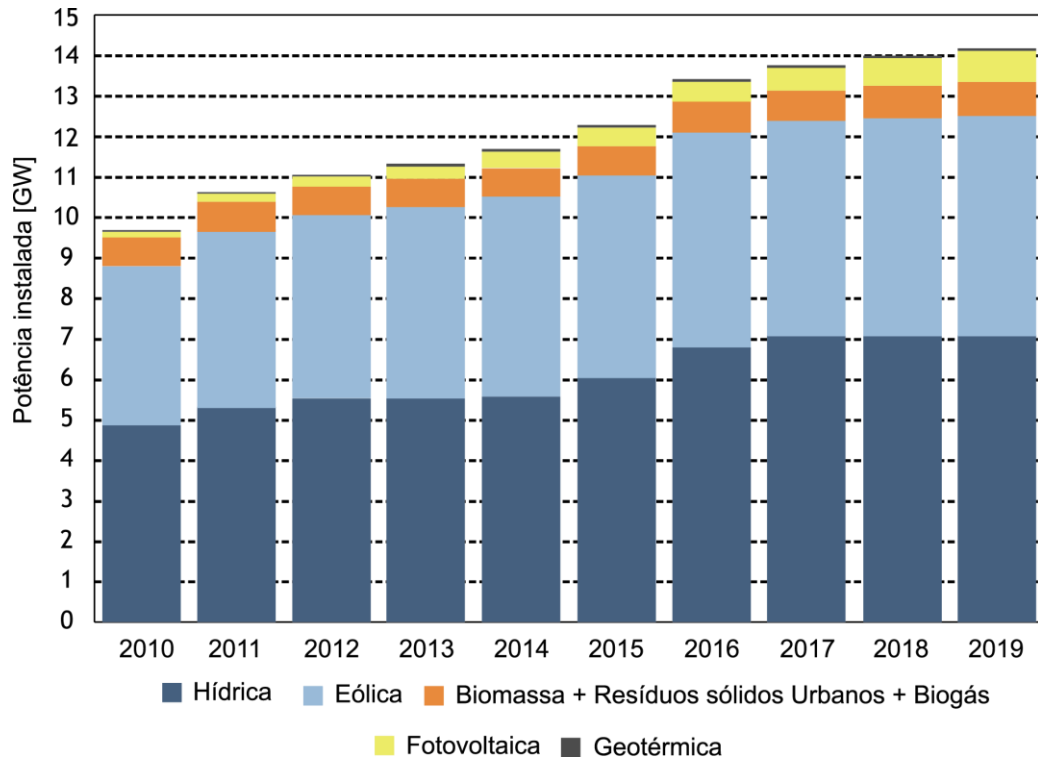


Figura 1.3 - Evolução da potência instalada por tipo de tecnologia renovável [6].




Figura 1.4 - Produção de energia PV ao longo dos anos por região em Portugal Continental (adaptado de [6]).

É de notar que em 2017, Portugal foi o quarto país da União Europeia com maior incorporação de energias renováveis no mix energético nacional. As fontes de energia hídrica e eólica foram as grandes contribuidoras para esse acontecimento, pois representaram cerca de 82% das fontes de energia renováveis.

A Figura 1.5 ilustra a incorporação de energias renováveis de produção de energia elétrica em vários países da União Europeia [6].

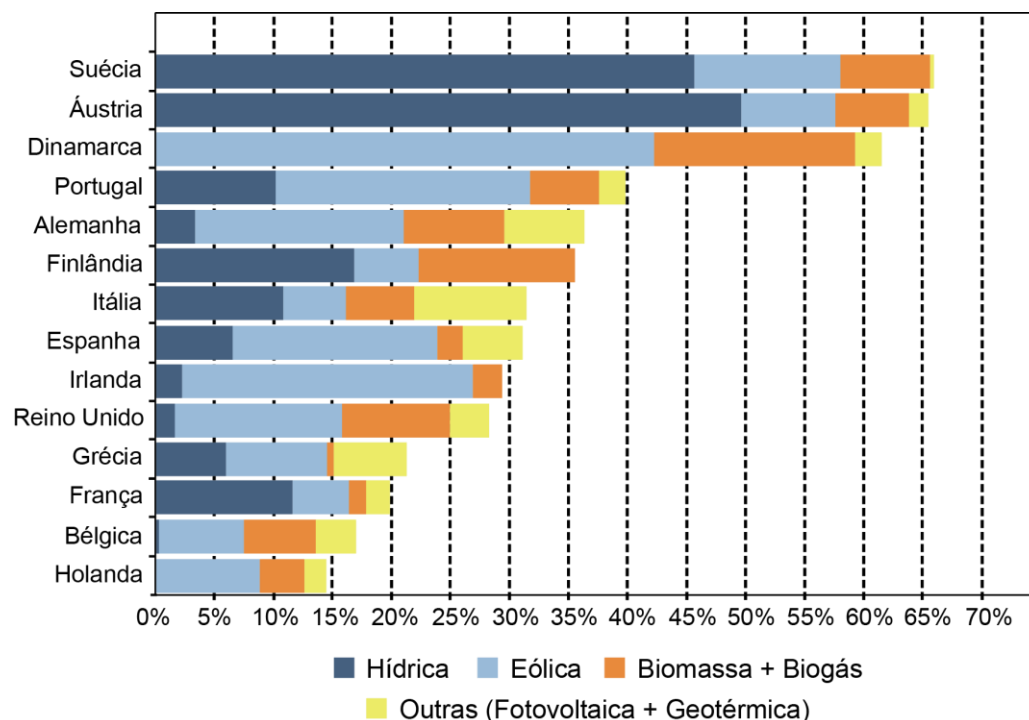


Figura 1.5 - Incorporação de energias renováveis de produção de energia elétrica em vários países da União Europeia [6].

Como se pode verificar, as fontes de energia renováveis constituem uma excelente alternativa para os sistemas de produção de energia tradicionais, não só pelo facto de que estão disponíveis em qualquer parte do mundo como pelo facto de não prejudicarem o meio ambiente. Pelo que existe uma grande importância em desenvolver módulos PV melhores, bem como desenvolver conversores de energia mais eficientes que consigam extrair o máximo da energia disponível a partir do *array* PV [8].

1.2. Motivação e objetivos da investigação

O objetivo desta dissertação é descrever, com exatidão, a modelação de sistemas PV introduzindo um novo modelo de estimação dos parâmetros PV, com baixa complexidade, eficiente e com um custo computacional reduzido, capaz de funcionar sob diferentes condições de operação, sobretudo de temperatura e de irradiância.

Um dos algoritmos mais eficientes, e mais utilizados na literatura para a extração dos parâmetros PV, é o *Particle Swarm Optimization* (PSO), proposto por Kennedy e Eberhart em 1995 [9]. Inúmeras aplicações em engenharia e várias variantes do PSO [10] foram propostas para mitigar a sua desvantagem principal: a convergência prematura. A convergência prematura do PSO clássico resulta da baixa diversidade do seu mecanismo de exploração, i.e.,

com o decorrer das iterações, as partículas diminuem a sua velocidade e permanecem praticamente imóveis. Para além disso, o seu carácter elitista obriga a que todas as partículas sejam atraídas para o mesmo líder, contribuindo para um aumento na falta de diversidade na construção de novas soluções.

A resolução do problema da convergência prematura associada ao PSO constitui outra motivação para o desenvolvimento desta dissertação, nomeadamente, quando se aplica o algoritmo em problemas de otimização multimodais, tais como o problema da estimação dos parâmetros PV.

Os objetivos específicos desta dissertação são os seguintes:

- Estudo sobre o estado da arte da modelação PV e dos algoritmos de estimação dos parâmetros PV existentes na literatura;
- Estudo aprofundado dos painéis PV;
- Estudo e implementação dos principais algoritmos bio inspirados;
- Desenvolvimento e apresentação de um novo algoritmo híbrido bio inspirado;
- Análise dos resultados dos diversos algoritmos implementados aplicados na estimação dos parâmetros PV;
- Comparação dos resultados obtidos a partir do novo algoritmo proposto com os dos algoritmos existentes;
- Publicação numa revista científica internacional.

1.3. Organização da dissertação

Para além da introdução, a presente dissertação contém mais seis capítulos estruturados da seguinte forma:

No capítulo 2 é feita uma revisão bibliográfica com a base teórica necessária sobre as tecnologias PV existentes atualmente, o funcionamento dos sistemas PV em geral e vários conceitos relacionados com os mesmos.

No capítulo 3 é realizada uma revisão bibliográfica sobre os modelos matemáticos que servem para simular o comportamento de células ou de módulos PV bem como todas as equações necessárias para os mesmos. É também feita uma revisão bibliográfica sobre os métodos de estimação dos parâmetros PV: métodos analíticos, numéricos e híbridos.

No capítulo 4 é feito um estudo sobre algoritmos de otimização. É feita a explicação do método proposto (M-SLPSO) e são especificados todos os parâmetros necessários para o bom funcionamento do mesmo.

No capítulo 5 são apresentados os algoritmos metaheurísticos de última geração que vão ser comparados com o método proposto (M-SLPSO) na resolução de funções de *benchmark*. De seguida, explicam-se os critérios de avaliação que foram utilizados para classificar os vários algoritmos e, finalmente, é apresentada uma discussão e uma análise estatística sobre os resultados obtidos pelo método proposto (M-SLPSO).

O capítulo 6 destina-se à avaliação do desempenho do método proposto (M-SLPSO) na estimação dos parâmetros PV para dois casos de estudo: o módulo PV Photowatt-PWP201 e o módulo PV Sharp ND-R250A5. Por fim é feita uma análise e uma discussão dos resultados obtidos.

No capítulo 7 sintetizam-se as principais conclusões extraídas no decorrer deste trabalho e sugerem-se, como resultado da experiência adquirida com o estudo desenvolvido, algumas perspetivas para trabalhos futuros no âmbito da temática abordada.

Capítulo 2

O presente capítulo apresenta uma revisão bibliográfica da base teórica necessária para a realização da presente dissertação: as tecnologias PV existentes atualmente, o funcionamento dos sistemas PV em geral e vários conceitos relacionados com os mesmos.

2. Produção fotovoltaica

2.1. Tecnologias de células fotovoltaicas

Atualmente, existe uma grande variedade de tecnologias PV no mercado que utilizam diferentes tipos de materiais. As tecnologias PV são, normalmente, classificadas em três gerações, dependendo do tipo de material utilizado [11]. A primeira geração é baseada no uso de silício cristalino e engloba as células de silício monocristalino e policristalino. A segunda geração é um tipo de tecnologias PV mais recente e é baseada em tecnologias de filme fino, que engloba as células de silício amorfo (α -Si), telureto de cádmio (CdTe) e as células de cobre, índio, gálio e selênio (CIGS). Por fim, a terceira geração inclui tecnologias de concentração (*Concentrating Photovoltaics* - CPV), material orgânico, células solares *dye-sensitized*, nanotecnologia, estando ainda em fase de desenvolvimento, não se encontrando disponíveis comercialmente.

2.1.1. Tecnologia de 1ª Geração - Silício cristalino

A tecnologia de silício cristalino é a tecnologia PV mais utilizada e mais vendida no mundo. Dentro desta tecnologia, as células PV de silício monocristalino (sc-Si), ilustradas na Figura 2.1, são o tipo de tecnologia PV mais antiga e mais utilizada devido à sua maior eficiência. A eficiência das células de silício monocristalino mais alta registrada até ao momento é de 26.7% [12]. A produção deste tipo de células torna-se complicada e mais cara que das células policristalinas de silício [13], [14]. Para a produção destas, são cortadas fatias de um cristal cilíndrico de silício de alta pureza. Essas fatias são depois polidas e dopadas para criar a junção P-N desejada, formando assim a célula.



Figura 2.1 - Célula solar monocristalina de silício [15].

As células PV de silício policristalino (mc-Si), ilustradas na Figura 2.2, são produzidas através de células cortadas de um lingote de silício derretido e recristalizado. Estes lingotes são cortados em cristais muito finos e montados para formarem células completas. As descontinuidades da estrutura molecular dificultam o movimento de eletrões, reduzindo assim a sua eficiência. O recorde atual de eficiência das células de silício policristalino é de 22.3% [16]. O seu processo de produção é mais barato do que o das células monocristalinas [13], [14]. Alguns autores propõem formas de aumentar a eficiência deste tipo de células como, por exemplo, em [17] onde é proposta uma célula cristalina com uma textura de favos de mel.




Figura 2.2 - Célula solar de silício policristalino [15].

2.1.2. Tecnologia de 2ª Geração - Filme fino

A maior rentabilidade das células pode ser definida pelo uso de menor quantidade de material e pelo aumento da eficiência na conversão de energia. A tecnologia de filme fino é uma tecnologia que consegue preencher tanto o critério da alta eficiência, como o critério da utilização de pouco material [18].

As células de filme fino mais comercializadas são as células de silício amorfo (α -Si), telureto de cádmio (CdTe) e as células de cobre, índio, gálio e selênio (CIGS). Este tipo de células (filme fino) possuem um coeficiente de temperatura muito baixo. No entanto, o coeficiente de absorção também é mais baixo do que o das células cristalinas, prejudicando o seu desempenho em situações de baixa irradiância [18].

As células de silício amorfo são uma tecnologia mais antiga e menos eficiente quando comparadas com as outras duas tecnologias de filme fino CdTe e CIGS. Além disso, são menos tóxicas quando comparadas com as de CdTe. Como resultado, as células de silício amorfo são mais utilizadas em dispositivos eletrônicos de consumo como calculadoras, relógios, etc [19].

Já as células de CdTe têm um custo de produção mais baixo quando comparadas com o das células de silício amorfo e, além disso, o material base destas células é o telureto de cádmio que é um material que possui elevada absorção de radiação solar. No entanto, estas possuem uma grande desvantagem que reside no facto de se utilizar o cádmio que é um material tóxico, limitando assim as suas aplicações comerciais [20].

Ultimamente, o preço das células de silício tem vindo a aumentar devido à grande procura e escassez de silício de alta pureza, levando a um grande interesse por células de filme fino, mais especificamente a tecnologia CIGS, ilustradas na Figura 2.3. Esta é a tecnologia mais promissora utilizando materiais semicondutores de baixo preço, alta eficiência, *band gaps* sintonizáveis, estabilidade a longo prazo e resistência a danos provenientes da radiação [21].




Figura 2.3 - Célula PV CIGS.

Atualmente, a tecnologia CIGS oferece a eficiência mais alta de entre todas as tecnologias de filme fino, com uma eficiência de 22.9% [22]. Por todas estas razões, a tecnologia CIGS é considerada muito competitiva quando comparada com a tecnologia PV baseada em silício. Na Figura 2.4 é apresentado um gráfico com a evolução da tecnologia das células solares CIGS. Foi em 1976 que os autores de [23] criaram a primeira célula solar de filme fino CIGS com uma eficiência de 4.5%. Em 1982, os autores de [24] conseguiram ultrapassar a meta dos 10%. A eficiência mais alta registada até ao momento, como já foi dito, é de 22.9%, conseguida em 2018 [22].




Figura 2.4 - Gráfico relativo aos melhores valores de eficiência alcançados em laboratório ao longo dos anos (adaptado de [18]).

2.1.3. Tecnologia de 3ª Geração

A terceira geração de células PV consiste em tecnologias que ainda estão em desenvolvimento; estas incluem:

- Tecnologias de concentração PV;
- Células PV orgânicas ou de polímero;
- Células PV *dye-sensitized*;
- Células PV com base em nanocristais.

As tecnologias de concentração PV consistem no uso de um sistema ótico que permite focar ou direcionar uma grande quantidade de luz solar para cada célula, para obter o máximo de eficiência possível. Este processo é conseguido através do uso de lentes e espelhos que focam

os raios solares nas células. Muitas vezes, as células utilizadas neste tipo de tecnologia são as células de multijunção [25]. As células de multijunção são células de alta eficiência (47.1% foi a eficiência mais alta conseguida por uma célula de multijunção registada até ao momento [26]), com várias junções P-N feitas a partir de materiais semicondutores diferentes, possibilitando a absorção de luz com diferentes comprimentos de onda e, desta forma, aumentar a eficiência da célula.

As células PV orgânicas ou de polímero são fabricadas a partir de filme fino (normalmente de 100 nm) de semicondutores orgânicos como polímeros e certos compostos [27]. A eficiência deste tipo de células é bastante baixa (cerca de 4%, 5%), mas o interesse pelas mesmas passa pelo seu baixo custo de produção, visto que são feitas, maioritariamente, de plástico. São células flexíveis que podem ser dobradas ou enroladas com possível utilização em carregadores de baterias para telemóveis, computadores, rádios, lanternas, brinquedos, etc. [28]. Estas células são tipicamente constituídas por uma parte frontal de vidro, uma camada de contacto transparente de óxido de índio-estanho (ITO), um polímero condutor, um polímero fotoativo e uma camada traseira de contacto [27].

As células PV *dye-sensitized* foram introduzidas por Michael Grätzel em 1991 no École Polytechnique Fédérale de Lausanne (EPFL), na Suíça [25]. Este tipo de células pertence também ao grupo das células de filme fino, constituídas por um semicondutor formado através de um ânodo fotossensibilizado e por um eletrólito. A atração por este tipo de células advém dos simples processos de fabricação, que englobam processos de impressão, de serem células flexíveis e por terem um preço relativamente baixo.

As células PV com base em nanocristais (também conhecidas como células solares *Quantum dot*) utilizam nanopartículas feitas a partir de materiais semicondutores com diâmetros na escala dos nanómetros. Estas partículas semicondutoras (*Quantum dots*) têm *band gaps* sintonizáveis sobre uma ampla gama de níveis de energia, ao contrário de outros materiais semicondutores como o silício, cuja *band gap* é fixa para o tipo de material [25]. A sintonização da *band gap* é feita ao mudar o tamanho dos *Quantum dots*. Esta propriedade torna este tipo de tecnologia atraente para células solares de multijunção, onde se podem utilizar junções com *Quantum dots* de diferentes tamanhos em cada junção [29].

2.2. Curvas características

As curvas características corrente-tensão (I-V) e potência-tensão (P-V) são curvas essenciais para o conhecimento de como se comportam os sistemas PV. São curvas não lineares caracterizadas, principalmente, por três pontos:

- O ponto de máxima potência (MPP) que é o ponto da curva I-V em que a célula PV funciona com a máxima potência. Neste ponto, a potência é calculada através de $P_{MPP} = I_{MPP} \times V_{MPP}$, onde o valor da corrente é I_{MPP} e o valor da tensão é V_{MPP} . O valor de P_{MPP} é medido em unidades de *watt* pico (Wp).
- Ponto de curto-circuito (SC) que é caracterizado por uma corrente de curto-circuito I_{SC} e por um valor de tensão zero aos terminais do módulo PV;
- Ponto de circuito-aberto (OC) que é caracterizado por uma tensão de circuito-aberto V_{OC} e por um valor de corrente zero aos terminais do módulo PV.

A curva característica I-V de uma célula ou módulo PV pode ser obtida através da medição da corrente e da tensão de saída variando uma carga aos seus terminais. As Figuras 2.5 (a) e (b) mostram uma representação das curvas I-V e P-V para uma célula ou módulo PV, respetivamente.

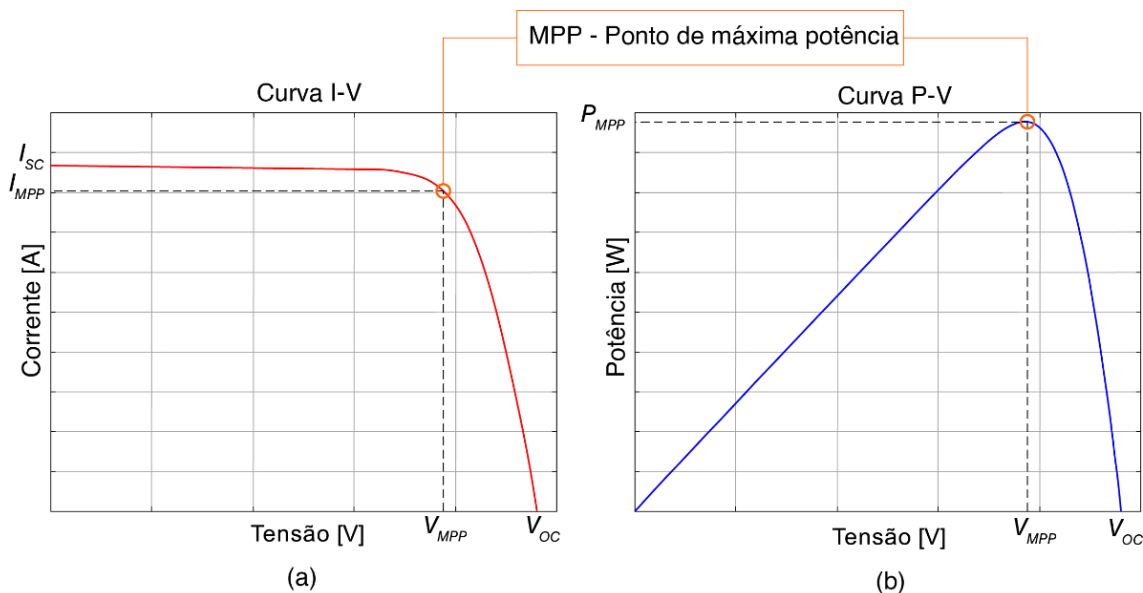


Figura 2.5 - Representação das curvas características I-V (a) e P-V (b).

As curvas características I-V e P-V são normalmente disponibilizadas nos *datasheets* do equipamento, em condições de referência (*standard test conditions* ou STC). Essas condições STC são definidas como [30]:

- Irradiância incidente de 1000 W/m^2 ;

- Temperatura das células de 25 °C;
- Espectro de luz com uma massa de ar de 1.5 (*air mass* ou $AM = 1.5$).

Outro ponto de funcionamento fornecido pelo *datasheet* é a temperatura de funcionamento normal da célula (*normal operating cell temperature* ou NOCT). Os seus valores variam entre os 45 °C e os 49 °C. O NOCT é definido como a temperatura da célula PV quando a temperatura ambiente é de 20 °C, a irradiância de 800 W/m² e a velocidade do vento de 1 m/s.

Um dos parâmetros que se utiliza para classificar uma célula ou módulo PV é o rendimento (η) que corresponde à eficiência do processo de conversão de energia solar em energia elétrica. O rendimento resulta do quociente entre a potência máxima produzida pelo módulo PV (P_{MPP}) e a potência disponibilizada pelo sol, que pode ser obtida através da multiplicação da área (A) do módulo PV em m² com a irradiância incidente (G) em W/m², como se pode ver na equação (2.1) [30].

$$\eta(\%) = \frac{P_{MPP}}{A \times G} \times 100 \quad (2.1)$$

Outro parâmetro que ajuda a classificar e a descrever a qualidade das células ou módulos PV é o fator de forma (FF). O FF, tal como o rendimento, pode ser calculado através da curva característica I-V e resulta do quociente entre a potência máxima obtida pela célula ou módulo PV e a potência máxima teórica. Onde a potência máxima teórica pode ser calculada pelo produto da corrente de curto-circuito com a tensão de circuito-aberto [30]. O FF é dado pela equação (2.2).

$$FF = \frac{I_{MPP} \times V_{MPP}}{I_{SC} \times V_{OC}} \quad (2.2)$$

O FF depende do tipo de tecnologia PV. Por exemplo, para a tecnologia cristalina o seu valor varia entre 0.75 e 0.85, enquanto que para a tecnologia amorfa varia entre os 0.5 e os 0.7. Outra maneira para calcular o FF é através do gráfico da curva I-V, ao fazer o quociente entre a área A e a área B (ver Figura 2.6) [30]. O FF é tanto melhor quanto mais perto estiver de FF=1.

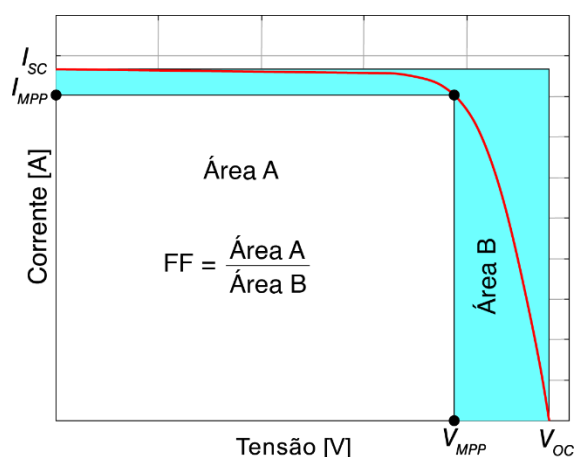


Figura 2.6 - Fator de forma de uma célula ou módulo PV.

2.3. Configurações de módulos PV

As células PV podem ser ligadas entre si em série e/ou paralelo, dependendo do que se pretende alcançar com a aplicação do sistema. Estes tipos de configurações permitem obter diferentes níveis de tensão e/ou corrente conforme o desejado. Certas aplicações necessitam de uma potência elevada, pelo que um único módulo PV poderá não ser suficiente e será necessário ligar vários módulos. Os módulos PV podem conter 36, 60, 72 ou 96 células, atingindo potências até ± 350 Wp.

As células PV podem então ser ligadas em série, caso o objetivo seja aumentar a tensão aos terminais e manter a corrente. Teoricamente, as células podem ser ligadas em paralelo, caso o objetivo seja aumentar a corrente aos terminais e manter a tensão, mas na realidade, as células constituintes dos módulos PV são normalmente ligadas em série devido à tensão operacional que fornecem. Por fim, nas aplicações onde é necessário aumentar a tensão e a corrente, será necessária uma configuração mista o que, mais uma vez, na realidade é raro.

2.3.1. Configuração em série

Na configuração em série, as células possuem a mesma corrente, mas o valor da tensão é a soma do total das tensões das células. Nesta configuração, o uso de células diferentes pode levar a perdas de potência no sistema, pelo que é recomendado usar sempre células do mesmo tipo de forma a minimizar essas perdas. Para esta configuração, os contactos frontais de cada célula são soldados aos contactos posteriores da próxima célula, ou seja, os polos negativos (frontais) de cada célula são ligados aos polos positivos (posteriores) da próxima célula, como se pode ver na Figura 2.7 [30].




Figura 2.7 - Células solares de silício cristalino ligadas em série (adaptado de [31]).

Na Figura 2.8 estão representadas três curvas características I-V e uma *string* com três células PV. Neste tipo de configuração, a corrente produzida mantém-se igual e a tensão produzida é três vezes superior [32].




Figura 2.8 - Células PV ligadas com uma configuração em série.

2.3.2. Configuração em paralelo

Na configuração em paralelo, as células possuem a mesma tensão, mas o valor da corrente é a soma do total das correntes das células, o que é ideal para aplicações cujo objetivo é o de obter correntes mais elevadas. Na Figura 2.9 estão representadas três curvas características I-V de três células em paralelo. Neste tipo de configuração, a tensão produzida mantém-se igual e a corrente produzida é três vezes superior.

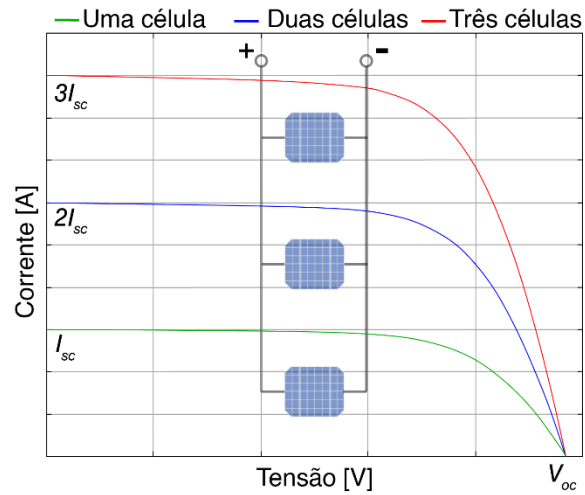


Figura 2.9 - Células PV ligadas com uma configuração em paralelo.

2.3.3. Configuração mista

Na configuração mista, as células são primeiro ligadas em série para formarem *strings* e depois, essas *strings* são ligadas em paralelo. Na Figura 2.10 está representada uma associação mista de $n \times m$ células, neste caso 9 células, bem como as respectivas curvas características I-V. Neste caso, a tensão produzida e a corrente produzida são três vezes superiores. É de notar que, nesta configuração, as *strings* têm que ter o mesmo número de células, serem do mesmo tipo e terem as mesmas características (tensão, corrente e potência) [32].

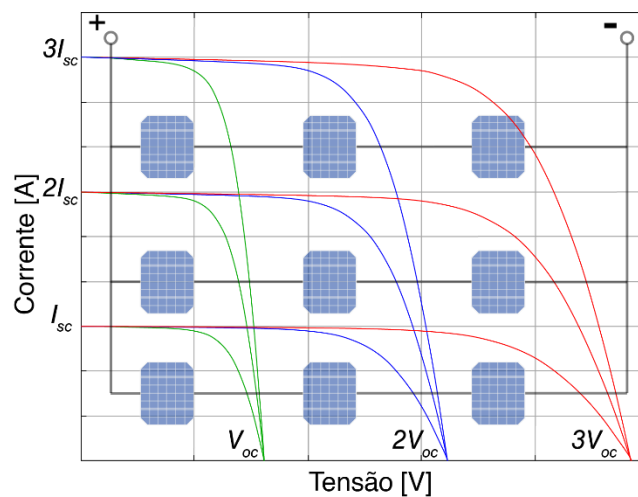


Figura 2.10 - Células PV ligadas com uma configuração mista.

2.4. Díodos de *bypass* e de bloqueio

Na prática, as células constituintes de um módulo PV nem sempre possuem exatamente as mesmas condições de funcionamento. A razão para tal recai sobre os processos de fabricação, envelhecimento, orientação, temperatura, e principalmente, sombreamento. O sombreamento é a principal razão pelo qual são necessários díodos de *bypass* nos painéis PV.

Quando uma célula ou módulo PV está sob sombreamento parcial e com um nível de irradiância inferior às restantes, a potência fornecida pelo painel é reduzida drasticamente. Este acontecimento pode dar origem a pontos quentes que podem danificar o painel. Os pontos quentes podem ser definidos como uma avaria num módulo PV. Estes surgem quando um módulo ou uma parte de um módulo está sob sombreamento e algumas das células pertencentes a esse módulo passam a estar inversamente polarizadas, funcionando como cargas em vez de geradores, o que pode levar a danos significativos no módulo PV. Para evitar estes acontecimentos, são ligados díodos de *bypass* em antiparalelo com um grupo de células PV de modo a desviar a corrente. Estes díodos só entram em funcionamento em situações de polarização inversa como, por exemplo, em situações onde há sombreamento, permitindo assim colocar uma célula ou um grupo de células PV (que está sob sombreamento) fora de serviço, deixando as restantes células a produzir.

A melhor maneira de limitar a consequência do sombreamento em módulos PV seria a utilização de um diodo de *bypass* em cada célula. No entanto, na prática, isso não acontece por razões económicas e de fabricação. Normalmente são ligados díodos de *bypass* em antiparalelo com *strings* de 18 a 20 células. Os díodos de *bypass* estão normalmente inseridos na caixa de junção do painel [30].

Outro diodo que é normalmente introduzido em módulos PV é o diodo de bloqueio. Este diodo está ligado em série a uma *string* PV e o seu objetivo é impedir a passagem de corrente inversa [33]. Essa corrente inversa pode ocorrer devido a um curto-circuito de um ou mais módulos; avarias nas *strings*, etc. Na Figura 2.11 está a representação de um módulo PV com 36 células ligadas em série com um diodo de *bypass* em cada 18 células.




Figura 2.11 - Representação de um módulo PV.

Para exemplificar o funcionamento dos diodos de *bypass* e a ocorrência de sombreamento, foram medidas experimentalmente curvas características I-V e P-V no módulo PV Sharp ND-R250A5 constituído por 60 células de silício monocristalino ligadas em série com 3 diodos de *bypass* (1 para 20 células) com e sem sombreamento. As curvas características da Figura 2.12 foram medidas quando o módulo PV não tinha qualquer tipo de sombreamento (ver Figura 2.13) e, como se pode ver, as curvas contêm apenas um ponto de máxima potência. Pelo contrário, para o caso da Figura 2.14 foi simulado sombreamento (ver Figura 2.15) no módulo pelo que, neste caso, foi ativado um diodo de *bypass* e a curva apresenta então dois pontos de máxima potência (um local e um global).




Figura 2.12 - Curvas características I-V (esquerda) e P-V (direita) retiradas de um módulo PV sem sombreamento parcial.



Figura 2.13 - Fotografia do módulo PV sem sombreamento parcial.

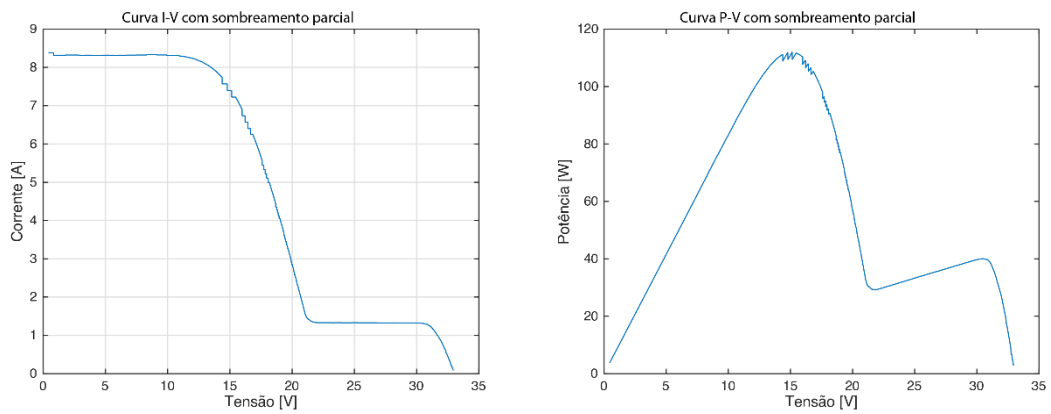


Figura 2.14 - Curvas características I-V (esquerda) e P-V (direita) retiradas de um módulo PV com sombreamento parcial simulado.



Figura 2.15 - Fotografia do módulo PV com sombreamento parcial simulado.

Capítulo 3

Neste capítulo é realizada uma revisão bibliográfica sobre os modelos matemáticos que servem para simular o comportamento de células ou de módulos PV bem como todas as equações necessárias para os mesmos. É também feita uma revisão bibliográfica sobre os métodos de estimação dos parâmetros PV: métodos analíticos, numéricos e híbridos.

3. Modelação matemática

3.1. Modelos matemáticos

Para perceber o comportamento de um módulo PV sob diferentes condições de funcionamento, é fundamental conhecer o modelo matemático de uma única célula PV. Uma célula PV é basicamente uma junção P-N com a particularidade de que, sem a presença de radiação solar, se comporta como um díodo e, conseqüentemente, a corrente é determinada através do modelo matemático de *Shockley*. No caso de haver presença de radiação solar, é necessário somar uma outra corrente designada de corrente fotoelétrica, I_{ph} , que depende da radiação solar incidente (irradiância) e da temperatura da célula. Quando a célula é polarizada diretamente, o seu ponto de funcionamento encontra-se no primeiro quadrante onde se verifica que a maior corrente é a corrente de curto-circuito, I_{sc} , que ocorre quando a tensão é nula. A máxima tensão obtida é a tensão de circuito aberto, V_{oc} , quando não há fluxo de corrente. Quando polarizada inversamente, o ponto de funcionamento encontra-se no segundo quadrante onde haverá condução de corrente apenas quando ultrapassada a tensão de bloqueio/rutura, V_{br} , podendo provocar danos na célula (ver Figura 3.1).

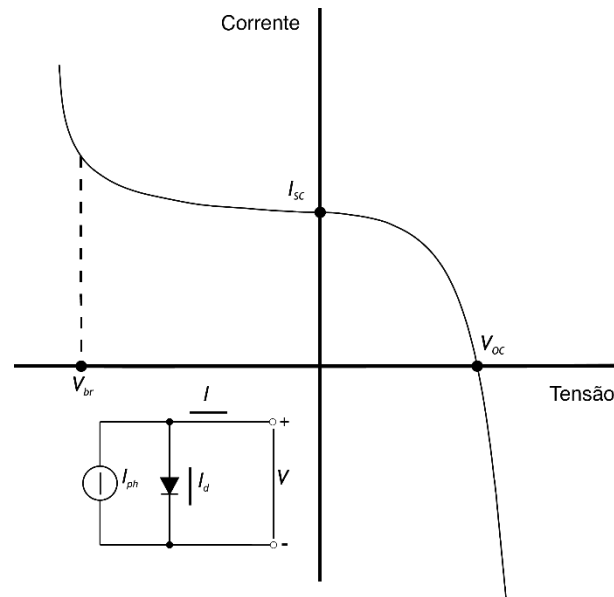


Figura 3.1 - Curva característica I-V de uma célula PV.

Existem vários modelos matemáticos que servem para simular o comportamento de células ou módulos PV sobre diferentes condições ambientais: o modelo de um diodo (*single diode model* ou SDM), o modelo de dois diodos (*double diode model* ou DDM), o modelo de três diodos, o modelo multidiodo, o modelo de diodo multidimensão e o modelo de Bishop. Os modelos mais utilizados pela literatura são os modelos de um e de dois diodos [34]. O modelo de um diodo, caracterizado por 5 parâmetros, usa a equação da junção P-N com apenas um termo exponencial e oferece um bom compromisso entre simplicidade e precisão [35]. O modelo de dois diodos é caracterizado por 7 parâmetros, tornando-o assim mais complexo. O desafio principal para este modelo é determinar a melhor solução para todos os parâmetros do modelo e manter um esforço computacional razoável [36]. O modelo de multidiodo pode ser caracterizado pelo facto de usar m diodos ligados em paralelo com $3 + 2m$ parâmetros [34]. O modelo de diodo multidimensão consiste no uso de n por m diodos em série e em paralelo [37], aumentando assim tanto a precisão como a complexidade.

3.1.1. Modelo ideal

A maneira mais simples para caracterizar uma célula solar é considerar uma fonte de corrente ligada em paralelo com um diodo ideal, como se ilustra na Figura 3.2. A fonte de corrente representa a corrente produzida pelo efeito PV, designada de corrente fotoelétrica (I_{ph}) e o diodo representa a junção P-N cujo funcionamento é semelhante ao de um diodo atravessado por uma corrente interna, designada de corrente do diodo (I_d). A equação que descreve a corrente de saída do circuito é composta por dois termos, um relacionado com a fonte e outro relacionado com a junção P-N [38].




Figura 3.2 - Circuito equivalente do modelo matemático ideal.

Aplicando as leis de *Kirchhoff* ao circuito da Figura 3.2, a corrente do circuito (I) é dada pela equação (3.1).

$$I = I_{ph} - I_d \quad (3.1)$$

De acordo com a equação de *Shockley*, a corrente do diodo (I_d) é dada pela equação (3.2)

$$I_d = I_0 \left[\exp\left(\frac{V}{n \times V_t}\right) - 1 \right] \quad (3.2)$$

onde V_t corresponde à tensão térmica e é dada pela equação (3.3) e n é o fator de idealidade do diodo.

$$V_t = \frac{N_s \times k \times T}{q} \quad (3.3)$$

Na equação (3.3), N_s é o número de células ligadas em série, k é a constante de Boltzman ($1.3806503E-23$ J/K), T é a temperatura em Kelvin e q é a carga do elétron ($1.60217646E-19$ C).

$$I_0 = C \times T^2 \exp\left(-\frac{E_{gap}}{k \times T}\right) \quad (3.4)$$

Na equação (3.4), E_{gap} é a *band gap* do material semiconductor sendo que, para o silício cristalino $E_{gap} = 1.124$ eV = $1.8E - 19$ J e para o silício amorfo $E_{gap} = 1.7$ eV = $2.72370016E - 19$ J e C é o coeficiente de temperatura.

3.1.2. Modelo de um diodo (SDM)

O SDM, representado na Figura 3.3 é composto por: uma fonte de corrente (que representa a energia solar incidente, que depende da variação da irradiância e da temperatura do módulo PV); um diodo (que representa a junção P-N cujo valor varia em função da temperatura e da carga); uma resistência em série, R_s (que representa as perdas por efeito de Joule); e uma

resistência em paralelo, R_p (que traduz as perdas através de correntes parasitas, i.e., correntes que circulam nas células devido a imperfeições na estrutura do material [34] [39]-[42]).




Figura 3.3 - Circuito equivalente do modelo matemático de um díodo de uma célula PV.

Aplicando as leis de *Kirchhoff* ao circuito da Figura 3.3, a equação que descreve a corrente do circuito (I) é dada pela equação (3.5)

$$I = I_{ph} - I_d - \frac{V + I \times R_s}{R_p} \quad (3.5)$$

em que, de acordo com a equação de *Shockley*:

$$I_d = I_0 \left[\exp\left(\frac{V + I \times R_s}{n \times V_t}\right) - 1 \right] \quad (3.6)$$

Na equação (3.6), a corrente inversa de saturação do díodo I_0 é dada pela equação (3.4), e $(V + I \times R_s)$ é a tensão no díodo.

Ao substituir a equação (3.6) na equação (3.5), obtemos a equação que descreve a corrente de saída do circuito para o SDM. Essa equação é dada pela equação (3.7).

$$I = I_{ph} - I_0 \left[\exp\left(\frac{V + I \times R_s}{n \times V_t}\right) - 1 \right] - \frac{V + I \times R_s}{R_p} \quad (3.7)$$

Este modelo é caracterizado por cinco parâmetros desconhecidos: a corrente fotoelétrica I_{ph} , a corrente inversa de saturação do díodo I_0 , o fator de idealidade do díodo n , a resistência R_s e a resistência R_p .

3.1.3. Modelo de dois díodos (DDM)

O DDM, representado na Figura 3.4, é constituído por dois díodos em paralelo com a fonte de corrente e é também conhecido como o modelo de exponencial dupla [36], [43]-[46]. Este modelo descreve com uma maior exatidão os fenómenos físicos que ocorrem ao nível da

junção P-N. É um modelo mais preciso do que o SDM para baixos níveis de irradiância em células de silício policristalino ou silício amorfo. O DDM possui os parâmetros caracterizados anteriormente para o SDM mais o fator de idealidade do segundo diodo e a sua correspondente corrente inversa de saturação.




Figura 3.4 - Circuito equivalente do modelo matemático de dois díodos de uma célula PV.

Aplicando as leis de *Kirchhoff* ao circuito da Figura 3.4, a corrente do circuito (I) é dada pela equação (3.8)

$$I = I_{ph} - I_{d1} - I_{d2} - \frac{V + I \times R_s}{R_p} \quad (3.8)$$

sendo as correntes dos díodos (I_{d1} e I_{d2}) dadas pelas equações (3.9) e (3.10), de acordo com a equação de *Shockley*

$$I_{d1} = I_{01} \left[\exp\left(\frac{V + I \times R_s}{n_1 \times V_t}\right) - 1 \right] \quad (3.9)$$

$$I_{d2} = I_{02} \left[\exp\left(\frac{V + I \times R_s}{n_2 \times V_t}\right) - 1 \right] \quad (3.10)$$

onde I_{01} é a corrente inversa de saturação do diodo 1 obtida pela equação (3.11) e I_{02} é a corrente inversa de saturação do diodo 2 obtida pela equação (3.12), n_1 é o fator de idealidade do diodo 1 e n_2 é o fator de idealidade do diodo 2:

$$I_{01} = C_1 \times T^3 \exp\left(-\frac{E_{gap}}{k \times T}\right) \quad (3.11)$$

$$I_{02} = C_2 \times T^{\frac{5}{2}} \exp\left(-\frac{E_{gap}}{2 \times k \times T}\right) \quad (3.12)$$

onde C_1 e C_2 representam os coeficientes de temperatura.

Ao substituir as equações (3.9) e (3.10) na equação (3.8), obtemos a equação que descreve a corrente do circuito para o DDM. Essa equação é dada pela equação (3.13).

$$I = I_{ph} - I_{01} \left[\exp\left(\frac{V + I \times R_s}{n_1 \times V_t}\right) - 1 \right] - I_{02} \left[\exp\left(\frac{V + I \times R_s}{n_2 \times V_t}\right) - 1 \right] - \frac{V + I \times R_s}{R_p} \quad (3.13)$$

Este modelo é caracterizado por sete parâmetros desconhecidos: a corrente fotoelétrica I_{ph} , a corrente inversa de saturação do diodo 1 I_{01} , a corrente inversa de saturação do diodo 2 I_{02} , o fator de idealidade do diodo 1 n_1 , o fator de idealidade do diodo 2 n_2 , a resistência R_s e a resistência R_p .

3.1.4. Modelo de três díodos

O modelo de três díodos, representado na Figura 3.5, utiliza três díodos ligados em paralelo com a fonte de corrente [47]. O terceiro diodo tem em conta a influência dos limites de grãos e correntes de fuga através das periferias [48]. A utilização de modelos mais detalhados cai sobre o facto de haverem cada vez mais grandes instalações de sistemas PV [49].




Figura 3.5 - Circuito equivalente do modelo matemático de três díodos de uma célula PV.

Aplicando as leis de *Kirchhoff* ao circuito da Figura 3.5, a corrente do circuito (I) é dada pela equação (3.14).

$$I = I_{ph} - I_{d1} - I_{d2} - I_{d3} - \frac{V + I \times R_s}{R_p} \quad (3.14)$$

Sendo que as correntes dos díodos (I_{d1} e I_{d2}) são obtidas de forma semelhante ao DDM através das equações (3.9) e (3.10) e a corrente do diodo 3 (I_{d3}) é dada pela equação (3.15) de acordo com a equação de *Shockley*:

$$I_{d3} = I_{03} \left[\exp\left(\frac{V + I \times R_s}{n_3 \times V_t}\right) - 1 \right] \quad (3.15)$$

onde I_{03} é a corrente inversa de saturação do diodo 3 e n_3 é o fator de idealidade do diodo 3.

Ao substituir as equações (3.9), (3.10) e (3.15) na equação (3.14), obtemos a equação que descreve a corrente do circuito para o DDM. Essa equação é dada pela equação (3.16).

$$I = I_{ph} - I_{01} \left[\exp\left(\frac{V + I \times R_s}{n_1 \times V_t}\right) - 1 \right] - I_{02} \left[\exp\left(\frac{V + I \times R_s}{n_2 \times V_t}\right) - 1 \right] - I_{03} \left[\exp\left(\frac{V + I \times R_s}{n_3 \times V_t}\right) - 1 \right] - \frac{V + I \times R_s}{R_p} \quad (3.16)$$

Este modelo é caracterizado por nove parâmetros desconhecidos: a corrente fotoelétrica I_{ph} , a corrente inversa de saturação do díodo 1 I_{01} , a corrente inversa de saturação do díodo 2 I_{02} , a corrente inversa de saturação do díodo 3 I_{03} , o fator de idealidade do díodo 1 n_1 , o fator de idealidade do díodo 2 n_2 , o fator de idealidade do díodo 3 n_3 , a resistência R_s e a resistência R_p .

3.1.5. Modelo de multidíodo

O modelo de multidíodo, representado na Figura 3.6 é constituído por m díodos ligados em paralelo com $3 + 2m$ parâmetros [34]. A equação que descreve a corrente do circuito (I) é dada pela equação (3.17)

$$I = I_{ph} - \sum_{i=1}^m I_{0i} \left[\exp\left(\frac{V + I \times R_s}{n_i \times V_t}\right) - 1 \right] - \frac{V + I \times R_s}{R_p} \quad (3.17)$$

onde m é o número de díodos no circuito.




Figura 3.6 - Circuito equivalente do modelo matemático de multidíodo de uma célula PV.

3.1.6. Modelo de díodo multidimensão

Para melhorar a precisão, é apresentado outro modelo que se encontra na literatura, o modelo de díodo multidimensão [50], representado na Figura 3.7. Este modelo permite que os díodos sejam configurados tanto em série como em paralelo de acordo com as características de saída do modelo PV.

O modelo de diodo multidimensão possui n diodos ligados em série e m strings de diodos ligadas em paralelo.




Figura 3.7 - Circuito equivalente do modelo matemático de diodo multidimensão de uma célula PV.

Neste modelo, o número parâmetros desconhecidos é dado por: para $n = 1$, são $3 + 2m$ parâmetros; para $n > 1$, ou seja, mais do que um diodo ligados em série, são $(3 + 2m) + (m \times (n - 1))$ parâmetros. A equação que descreve a corrente do circuito (I) é dada pela equação (3.18).

$$I = I_{ph} - \sum_{i=1}^m I_{0i} \left[\exp \left(\sum_{j=1}^n \frac{V + I \times R_s}{n_i \times V_t} \right) - 1 \right] - \frac{V + I \times R_s}{R_p} \quad (3.18)$$

3.1.7. Modelo de Bishop

Outro modelo existente na literatura, é o modelo de *Bishop* [51], representado na Figura 3.8. Este modelo é utilizado quando um módulo PV é sujeito a condições de irradiância não uniformes, como por exemplo na ocorrência de sombreamento no módulo, onde algumas células podem deslocar o seu ponto de funcionamento do primeiro para o segundo quadrante. Para modelar esta característica é necessário introduzir nos modelos matemáticos o termo proposto em [51], dado pela equação (3.19). Este termo consiste basicamente de uma fonte de corrente controlada e considera essa característica como um fator de multiplicação não-linear que influencia a corrente na resistência R_p , ou seja, permite controlar a corrente no ramo da resistência R_p . A abordagem de *Bishop*, apesar de ser frequentemente utilizada na literatura, tem sido criticada de não estar fisicamente correta, uma vez que este fenómeno físico deve afetar toda a junção P-N por inteiro, não apenas a corrente na resistência R_p [8].

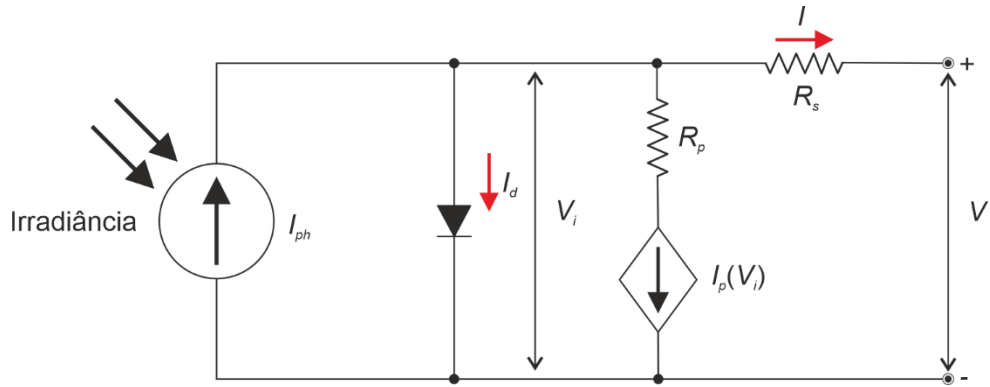


Figura 3.8 - Circuito equivalente do modelo matemático de *Bishop* de uma célula PV.

A corrente I_p que atravessa a resistência R_p é então obtida pela equação (3.19)

$$I_p = \frac{V_i}{R_p} \left(1 + \alpha \left(1 - \frac{V + I \times R_s}{V_{br}} \right)^{-m} \right) \quad (3.19)$$

onde, V_i é a tensão que atravessa a junção (V), α é a fração de corrente ôhmica envolvida na avaria súbita e m é o expoente de avaria súbita [51].

A equação que descreve a corrente do circuito (I) é dada pela equação (3.20).

$$I = I_{ph} - I_0 \left[\exp \left(\frac{V + I \times R_s}{n \times V_t} \right) - 1 \right] - I_p \quad (3.20)$$

3.2. Formulação do problema

O principal objetivo da modelação matemática PV é a estimação dos parâmetros PV. Neste caso, a estimação dos parâmetros do SDM (equação (3.7)) e do DDM (equação (3.13)), com $\tau = [I_{ph}, I_0, n, R_s, R_p]$ e $\tau = [I_{ph}, I_{01}, I_{02}, n_1, n_2, R_s, R_p]$, respetivamente. Portanto, este problema é formulado como um problema de otimização cujo objetivo consiste na minimização do erro entre os dados de corrente medidos e os dados de corrente estimados, através de um índice de desempenho, i.e., uma função objetivo (FO). Existem alguns índices de desempenho na literatura que quantificam esta diferença [52]: o erro absoluto (AE) na equação (3.21), o erro absoluto médio (MAE) na equação (3.22), o erro quadrático (SSE) na equação (3.23), a raiz quadrada do erro quadrático médio (RMSE) na equação (3.24) e o RMSE ponderado (ξ) na equação (3.25), proposto por [38].

$$AE = \sum_{i=1}^N |I_i - \hat{I}_{(V_i, \tau)}| \quad (3.21)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |I_i - \hat{I}_{(V_i, \tau)}| \quad (3.22)$$

$$SSE = \sum_{i=1}^N (I_i - \hat{I}_{(V_i, \tau)})^2 \quad (3.23)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (I_i - \hat{I}_{(V_i, \tau)})^2} \quad (3.24)$$

$$\xi = \frac{RMSE}{I_{sc}} = \frac{1}{I_{sc}} \sqrt{\frac{1}{N} \sum_{i=1}^N (I_i - \hat{I}_{(V_i, \tau)})^2} \quad (3.25)$$

onde N representa um conjunto de pontos empíricos (I_i, V_i) medidos experimentalmente com $i \in N$, e $\hat{I}_{(V_i, \tau)}$ o valor estimado da corrente em função dos parâmetros desconhecidos τ que caracterizam os modelos descritos pelas equações (3.7) e (3.13). Os parâmetros do SDM e do DDM estão limitados dentro dos intervalos apresentados na Tabela 3.1.

Tabela 3.1 - Limites dos parâmetros para o SDM e DDM nos dois casos de estudo.

Parâmetros	Caso de estudo 1: SDM e DDM		Caso de estudo 2: SDM e DDM	
	Limite inferior	Limite superior	Limite inferior	Limite superior
I_{ph} [A]	0	1.2	0	10
I_0, I_{01}, I_{01} [A]	1E-12	1E-05	1E-12	1E-05
n, n_1, n_2	0.5	2.5	0.5	2.5
R_s [Ω]	0.001	2	0.001	2
R_p [Ω]	0.001	5000	0.001	5000

Apesar de todos estes índices de desempenho serem eficientes, o mais utilizado na literatura é o RMSE. Por essa razão, a FO é formulada da seguinte forma:

$$\text{Min } OF = \text{Min} \sqrt{\frac{1}{N} \sum_{i=1}^N (I_i - \hat{I}_{(V_i, \tau)})^2} \quad (3.26)$$

com $\tau \in R_+^5$ para o SDM e $\tau \in R_+^7$ para o DDM.

Teoricamente, o valor do RMSE entre a corrente medida e a estimada devia ser zero, o que significaria que os valores estimados seriam valores exatos. No entanto, os valores exatos dos parâmetros PV são desconhecidos, por isso, o valor do RMSE é usado para medir o desempenho do método em termos de precisão; quanto mais baixo for o valor do RMSE, mais preciso é o método.

No entanto, a natureza implícita da equação que permite estimar a corrente de saída do circuito equivalente I constitui uma limitação significativa para a extração dos parâmetros do modelo matemático. Para ultrapassar essa limitação foi utilizado o método de Newton-Raphson (NRM) [53], cujo fluxograma é representado na Figura 3.9, para calcular a corrente estimada $\hat{I}_{(V_i, \tau)}$. Desta forma, os valores das correntes são determinados ao resolver a equação $f(\hat{I}_{(V_i, \tau)}) = 0$ expressa pela equação (3.27) para o SDM e pela equação (3.28) para o DDM, num processo iterativo, até que a condição de paragem pré-definida, $|f(\hat{I}_{(V_i, \tau)})| < 10^{-10}$, seja alcançada. Para o cálculo do novo valor da corrente estimada, $\hat{I}_{(V_i, \tau)}$, o método vai requerendo o conhecimento da derivada da função $f(\hat{I}_{(V_i, \tau)})$ (calculada através da equação (3.29) para o SDM e pela equação (3.30) para o DDM), em relação a $\hat{I}_{(V_i, \tau)}$, ao longo das iterações.

$$f(\hat{I}_{(V_i, \tau)}) = I_{ph} - I_0 \left[\exp \left(\frac{V_i + \hat{I}_{(V_i, \tau)} \times R_s}{n \times V_t} \right) - 1 \right] - \frac{V_i + \hat{I}_{(V_i, \tau)} \times R_s}{R_p} - \hat{I}_{(V_i, \tau)} \quad (3.27)$$

$$f(\hat{I}_{(V_i, \tau)}) = I_{ph} - I_{01} \left[\exp \left(\frac{V_i + \hat{I}_{(V_i, \tau)} \times R_s}{n_1 \times V_t} \right) - 1 \right] - I_{02} \left[\exp \left(\frac{V_i + \hat{I}_{(V_i, \tau)} \times R_s}{n_2 \times V_t} \right) - 1 \right] - \frac{V_i + \hat{I}_{(V_i, \tau)} \times R_s}{R_p} - \hat{I}_{(V_i, \tau)} \quad (3.28)$$

$$\frac{\partial f(\hat{I}_{(V_i, \tau)})}{\partial \hat{I}_{(V_i, \tau)}} = - \left(\frac{I_0 \times R_s \left[\exp \left(\frac{V_i + \hat{I}_{(V_i, \tau)} \times R_s}{n \times V_t} \right) \right]}{n \times V_t} \right) - \frac{R_s}{R_p} - 1 \quad (3.29)$$

$$\frac{\partial f(\hat{I}_{(V_i, \tau)})}{\partial \hat{I}_{(V_i, \tau)}} = - \left(\frac{I_{01} \times R_s \left[\exp \left(\frac{V_i + \hat{I}_{(V_i, \tau)} \times R_s}{n_1 \times V_t} \right) \right]}{n_1 \times V_t} \right) - \left(\frac{I_{02} \times R_s \left[\exp \left(\frac{V_i + \hat{I}_{(V_i, \tau)} \times R_s}{n_2 \times V_t} \right) \right]}{n_2 \times V_t} \right) - \frac{R_s}{R_p} - 1 \quad (3.30)$$

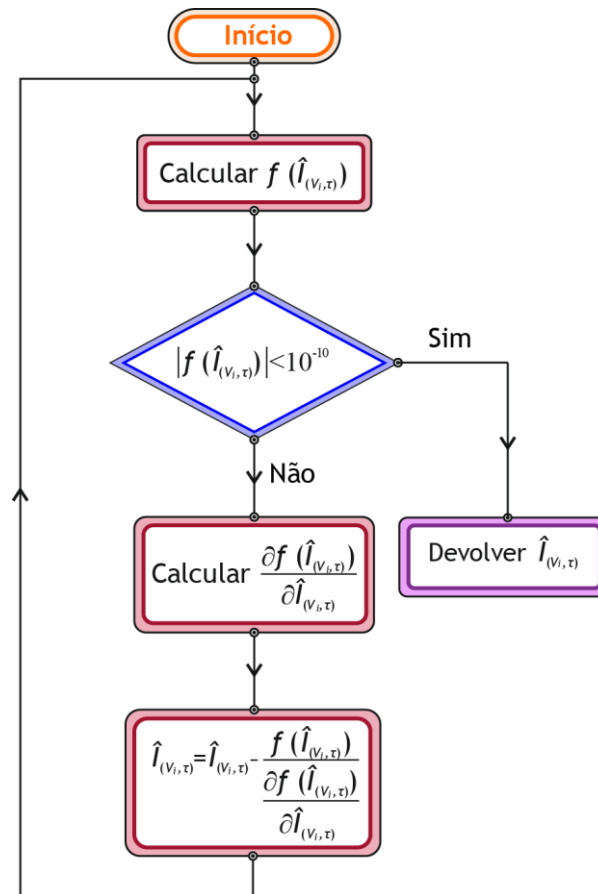


Figura 3.9 - Fluxograma do método de Newton-Raphson (adaptado de [34]).

3.3. Métodos de estimação dos parâmetros PV

A estimação dos parâmetros PV é um problema complexo e multimodal que pode assumir várias soluções ótimas locais e é condicionado pela informação disponível, i.e., pode ser resolvido de duas maneiras: a partir dos dados disponíveis pelos fabricantes (pontos característicos [36], [38], [39], [54]-[57]), ou através de dados medidos experimentalmente (curvas características I-V e P-V [53], [58]-[64]).

Quando os dados dos fabricantes estão disponíveis, a abordagem mais comum na estimação dos parâmetros PV é a analítica, visto que permite utilizar alguns pontos-chave da curva característica e algumas formulações matemáticas simples para determinar as características I-V das células ou módulos PV. Como já foi dito na secção 2.2 da presente dissertação, esses pontos-chave são o ponto de circuito aberto (OC), o ponto de potência máxima (MPP) e o ponto de curto-circuito (SC). Alguns autores na literatura recorrem ainda a dois pontos intermédios, o valor da corrente correspondente ao ponto médio entre V_{OC} e V_{MPP} e o valor da corrente correspondente ao ponto médio entre 0 e V_{MPP} .

Por outro lado, quando os dados experimentais são conhecidos, a abordagem numérica é a mais comum e tem normalmente em consideração todos os pontos da curva característica permitindo assim obter parâmetros PV mais precisos. Esta abordagem pode ser do tipo determinístico ou do tipo metaheurístico, sendo a estimação dos parâmetros PV formulada como um problema de otimização. Desta forma, podem-se categorizar os métodos de estimação dos parâmetros PV em métodos analíticos, determinísticos e metaheurísticos.

3.3.1. Métodos analíticos

Os métodos analíticos usam equações matemáticas, tendo em conta alguns pontos característicos da curva característica I-V, para encontrar os parâmetros PV e são caracterizados pela sua simplicidade, baixo custo computacional e fácil implementação [65]. No entanto, a precisão dos métodos analíticos depende muito dos pontos característicos selecionados, bem como da necessidade de realizar algumas simplificações ou aproximações [34]. Além disso, o facto de que este tipo de método normalmente requer que os dados do fabricante sejam obtidos sob as STC, i.e., dados diferentes dos que a curva característica I-V precisa para ser simulada, limita a precisão dos parâmetros obtidos. Por exemplo, em [66] é proposto um método iterativo para estimar os parâmetros do SDM diretamente do *datasheets* do fabricante sem equações implícitas.

3.3.2. Métodos numéricos

Como já foi dito os métodos numéricos podem ser divididos em dois grupos: determinísticos e metaheurísticos. Os métodos determinísticos, apesar de serem bastante eficientes numa procura local, tendem a convergir prematuramente para mínimos locais e, além disso, necessitam de convexidade, continuidade e diferenciação [67]. A sua precisão não é muito confiável visto que o problema da estimação de parâmetros de módulos PV é não linear e multimodal. Também a sua eficiência depende muito do posicionamento inicial, i.e., caso o posicionamento inicial seja realizado longe da solução ótima a sua eficiência será mais baixa [68]. Exemplos dos métodos determinísticos são o *Newton-Raphson method* (NRM) [53], o algoritmo de *Levenberg-Marquardt* (LM) [62], *Pattern Search* (PS) [69], *Nelder-Mead simplex* (NMS) [70], entre outros.

Para superar as desvantagens dos métodos determinísticos, os métodos metaheurísticos (MH) têm sido muito utilizados nos últimos anos para resolver vários problemas como a estimação dos parâmetros PV. Muitos dos MHs são métodos inspirados na natureza, baseados numa população que trabalha em conjunto para encontrar boas soluções ao minimizar uma FO e são adequados para problemas de otimização global [71], [72]. As principais vantagens destes métodos são: não exigem restrições na formulação do problema, ou seja, podem ser aplicados numa grande variedade de problemas; possuem simplicidade conceitual; e são capazes de resolver problemas multimodais (com mais do que uma solução) [73], [74]. No entanto,

dependendo do mecanismo inerente a cada MH, o custo computacional deste tipo de métodos pode ser menos promissor. Atualmente, existe uma variedade enorme de MHs bem-sucedidos na literatura para certos problemas de otimização, com mais ou menos parâmetros de controlo, mas não existe um MH universal que possa ser usado para qualquer problema de otimização. Alguns exemplos de MHs são: *Particle Swarm Optimization* (PSO) [75], *Genetic Algorithm* (GA) [76], *Simulated Annealing* (SA) [77], *Differential Evolution* (DE) [78], *Adaptive DE Technique* (DET) [79], *Cuckoo Search* (CS) [80], *Artificial Bee Colony* (ABC) [81], *Teaching-Learning-Based ABC* (TLABC) [73], *Flower Pollination Algorithm* (FPA) [82], *Hybrid Flower Pollination Algorithm* (GOFPANM) [1], *Quantum PSO* (QPSO) [64], *Harmony Search* (HS) [83], *Teaching-Learning-Based Optimization* (TLBO) [84], [85], *Self-Adaptive Teaching Learning Based Optimization* (SATLBO) [86], *Time Varying Acceleration Coefficients PSO* (TVACPSO) [87], *Cat Swarm Optimization* (CSO) [88], *Grey Wolf Optimizer* (GWO) [89], *Whale Optimization Algorithm* (WOA) [90], *Chaotic Whale Optimization Algorithm* (CWOA) [91], *Sine Cosine Algorithm* (SCA) [92], *Chaotic Improved Artificial Bee Colony* (CIABC) [93], *Gravitational Search Algorithm* (GSA) [94], *Chaotic Gravitational Search Algorithm* (CGSA) [95], *Wind Driven Optimization* (WDO) [96], *Improved JAYA* (IJAYA) [97], *Enhanced Leader Particle Swarm Optimization* (ELPSO) [98], *Guaranteed Convergence Particle Swarm Optimization* (GCP SO) [34], *Improved Shuffled Complex Evolution* (ISCE) [99], *Genetic Algorithm with Convex Combination Crossover* (GACCC) [100], *Firefly Algorithm* (FA) [101], *Improved Cuckoo Search Algorithm* (ImCSA) [102], *Improved Teaching Learning Based Optimization* (ITLBO) [43], [103], *Improved Whale Optimization Algorithm using Opposition-Based Learning* (OBWOA) [104], *Backtracking Search Algorithm* (BSA) [105], *Multiple Learning Backtracking Search Algorithm* (MLBSA) [106], *Biogeography-Based Optimization with Mutation Strategies*(BBO-M) [107], *Ant Lion Optimizer* (ALO) [108], *Ant Lion Optimizer with Lambert W function* (ALO-LW) [109], *Modified Nelder-Mead Simplex* (MNMS) [110], *Improved Whale Optimization Algorithm* (IWOA) [111], *Onlooker-Ranking-Based Mutation Operator into an Improved Adaptive Differential Evolution* (OR_{CR}-IJADE) [112], *Symbiotic Organisms Search* (SOS) [65], *Chaotic Heterogeneous Comprehensive Learning Particle Swarm Optimizer* (C-HCLPSO) [113], *Performance-guided JAYA Algorithm* (PGJAYA) [114], e *Improved Lozi Map Based Chaotic Optimization Algorithm* (ILCOA) [115].

Os MHs são geralmente bons para uma pesquisa global e para resolver problemas multimodais. No entanto, podem convergir prematuramente para soluções ótimas locais, são baseados numa população e, conseqüentemente, requerem recursos de computação elevados devido ao mecanismo de procura estocástico [68]. Além disso, a sua eficiência depende fortemente do ajuste adequado dos parâmetros de controlo e do balanço entre os mecanismos de diversificação e de intensificação. Entenda-se como mecanismo de diversificação como o mecanismo de construção de novas soluções em zonas ainda não exploradas dentro do espaço de procura e o mecanismo de intensificação como o mecanismo de construção de novas soluções em zonas já exploradas.

3.3.3. Métodos híbridos

Recentemente, os métodos híbridos surgiram na literatura para combinar as potencialidades de diferentes métodos. Esta hibridização pode ser feita a partir da combinação de métodos analíticos com métodos numéricos ou diferentes MHs.

Uma prática comum no processo de hibridização é a combinação de dois ou mais MHs com diferentes mecanismos de procura para criar um método híbrido que consiga estabelecer um bom balanço entre os mecanismos de diversificação e de intensificação, pelo que alguns MHs oferecem um mecanismo de intensificação melhor, favorecendo a procura local e, pelo contrário, outros MHs têm um mecanismo de diversificação melhor, favorecendo a procura global. No entanto, a prática da hibridização requer o ajuste de muitos parâmetros de controlo, que tem que ser feito experimentalmente ou através de tentativa e erro, podendo reduzir a eficiência e a precisão do algoritmo [91]. Outra desvantagem nos métodos híbridos é a sua necessidade de um custo computacional superior pelo que, no problema da estimação dos parâmetros PV, alguns autores da literatura utilizam expressões analíticas para calcular alguns parâmetros, permitindo reduzir consideravelmente o custo computacional, mas com a consequência de comprometer a precisão dos resultados [34]. Exemplos de métodos híbridos são: o HPSOSA [116] que combina o PSO com o SA; o A-bcNM [117] que combina um método analítico com o NMS; o GOFPANM [1] que combina o algoritmo FPA com o algoritmo NMS; o *Bee Pollinator Flower Pollination Algorithm* (BPFPA) [118]; o NM-MPSO [119] que combina o NMS com o *Modified* PSO (MPSO); o LMSA [120] que resulta da combinação entre o método de otimização de *Levenberg-Marquardt* (LM) com o SA; e o ABC-TRR [71] que combina o algoritmo determinístico *Trust-Region Reflective* com o algoritmo ABC.

Capítulo 4

Neste capítulo apresenta-se de forma detalhada o método proposto(M-SLPSO), implementado em Matlab e são especificados todos os parâmetros necessários para o bom funcionamento do mesmo. São também apresentados os dois algoritmos essenciais para o desenvolvimento do M-SLPSO.

4. Multiswarm spiral leader particle swarm optimization (M-SLPSO)

Neste capítulo é descrito o método proposto, denominado de *multiswarm spiral leader particle swarm optimization* (M-SLPSO). O M-SLPSO consiste numa versão melhorada do PSO clássico capaz de: superar os mínimos locais e, conseqüentemente, mitigar a convergência prematura; aumentar a diversidade (mecanismo de diversificação) na procura de novas soluções; explorar simultaneamente diferentes regiões do espaço de procura; evitar a estagnação dos *swarms*; e ter a capacidade de se adaptar a diferentes problemas de otimização. Para conseguir alcançar todos estes objetivos, foi adotada uma estratégia de *multiswarm*, na qual os líderes de cada grupo de agentes (*swarm*) são guiados de acordo com diferentes trajetórias em espiral. A metodologia desenvolvida fornece uma nova alternativa que permite corrigir as desvantagens associadas ao mecanismo de exploração do PSO (explicados anteriormente na secção 1.2), aumentando a diversidade na procura de novas soluções e melhorando o balanço entre os mecanismos de diversificação e de intensificação.

Para se perceber o M-SLPSO é necessário em primeiro lugar ter-se conhecimento sobre dois algoritmos que foram essenciais para o desenvolvimento do M-SLPSO. Esses dois algoritmos são o PSO e o *Spiral Dynamics Algorithm* (SDA) e a sua explicação é feita nas secções 4.1 e 4.2, respetivamente.

4.1. Particle Swarm Optimization (PSO)

O *particle swarm optimization* (PSO) [9] é um MH baseado numa população e inspirado pelos princípios de cooperação e comportamento em sociedade. O algoritmo contém um enxame (*swarm*) de partículas (população) também chamadas de agentes, onde cada um representa uma possível solução, normalmente num espaço de procura multidimensional. As partículas são inicializadas aleatoriamente e exploram o espaço de procura, guiadas pelas experiências individuais e coletivas que melhor satisfazem a FO. Para tal, o melhor desempenho individual de cada partícula e a sua posição são guardados, bem como o desempenho e a posição da partícula com o melhor desempenho global. Cada partícula é movida dinamicamente dentro do espaço de procura, através de uma equação de atualização de velocidade que considera o histórico das experiências individuais e coletivas na procura da melhor solução global. Portanto, a cada iteração, o algoritmo avalia o desempenho de cada partícula da população através de uma FO e a velocidade de cada partícula é ajustada na direção da melhor solução individual (*pbest*), bem como na direção da melhor solução global (*gbest*). A posição (x) e a velocidade (v) de cada agente é atualizada de acordo com as equações (4.1) e (4.2), respetivamente. A evolução da posição das partículas está ilustrada na Figura 4.1 e o fluxograma do PSO está ilustrado na Figura 4.2.

$$x_{a,d}(t+1) = x_{a,d}(t) + v_{a,d}(t) \quad (4.1)$$

$$v_{a,d}(t+1) = \omega v_{a,d}(t) + c_1 r_1 (pbest_{a,d}(t) - x_{a,d}(t)) + c_2 r_2 (gbest_d(t) - x_{a,d}(t)) \quad (4.2)$$

onde $x_{a,d}(t)$ é a posição do agente a na iteração t , $v_{a,d}(t)$ é a velocidade do agente a na iteração t , $pbest_{a,d}(t)$ é a melhor posição encontrada pelo agente a até ao momento, $gbest_d(t)$ é a melhor posição global encontrada até ao momento, c_1 e c_2 são coeficientes de aceleração e o ω é o coeficiente de inércia e devem respeitar a equação (4.3) e (4.4) respetivamente, para que as velocidades e posições das partículas não divirjam. r_1 e r_2 são duas variáveis com um número aleatório entre 0 e 1.

$$c_1 + c_2 \leq 4 \quad (4.3)$$

$$\omega = \omega_{m\acute{a}x} - \frac{\omega_{m\acute{a}x} - \omega_{min}}{Max_iter} \times t \quad (4.4)$$




Figura 4.1 - Representação gráfica da evolução das partículas com o PSO.

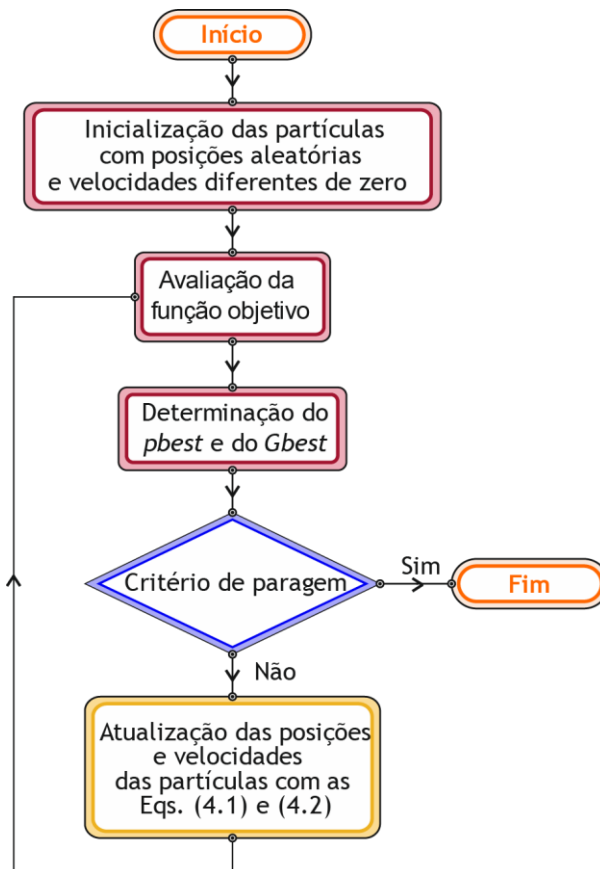


Figura 4.2 - Fluxograma do PSO.

Para mitigar as desvantagens já descritas do algoritmo PSO, vários autores da literatura propuseram variantes cujo objetivo é introduzir algumas modificações para melhorar o seu desempenho e eficiência. As principais contribuições de algumas variantes para a evolução do algoritmo PSO consistem, por exemplo: no ajuste dos parâmetros de controlo, como a alteração dos coeficientes de aceleração [121]; na modificação do coeficiente de inércia [122]-[124]; na adição de um fator de constrição [125]; na adição de novos parâmetros como o coeficiente de competição [126], coeficientes de extrapolação [127], ou no caso de [128], o fator de momento.

Outra estratégia utilizada na literatura é a estratégia de *multiswarm*. A introdução desta estratégia visa resolver os problemas associados ao PSO quando este é aplicado a problemas mais complexos, i.e., problemas multimodais. A estratégia de *multiswarm* (com mais do que um *swarm*) consiste: na interação entre vários grupos de partículas à procura de soluções ótimas; numa maior eficiência no balanço entre os mecanismos de intensificação e de diversificação; e na melhoria da diversidade dos *swarms*.

Em [129] é proposto um esquema *multiswarm* cooperativo denominado de “*Meeting Room Approach*” inspirado pelo comportamento social humano. Neste caso, os *swarms* são chamados de “*clans*” e cada “*clan*” tem um líder. Além disso, cada “*clan*” possui um conjunto de soluções que representam as partículas que fazem parte desse “*clan*”, a partícula que representa a melhor solução é considerada como líder e o líder controla os outros membros do “*clan*”. No fim de cada iteração (geração), os líderes encontram-se todos numa “sala” onde o melhor de todos os líderes partilha a sua posição com os outros líderes normais.

Já em [130], é proposto um esquema denominado de *Forking PSO* (FPSO). Inicialmente, existe apenas um *swarm* principal que percorre e pesquisa todo o espaço de procura através do PSO. Em cada iteração, é verificado se o *swarm* principal cumpre os requisitos necessários para o processo de *forking*. Caso isso aconteça, o mesmo envia uma parte das suas partículas, criando assim um *swarm* “criança”, para explorar independentemente o subespaço onde as condições foram inicialmente cumpridas. Depois disso, o *swarm* principal é reinicializado e continua a procurar no restante espaço de procura.

4.2. Spiral dynamics algorithm (SDA)

O *spiral dynamics algorithm* (SDA) é um algoritmo de otimização MH proposto por Tamura e Yasuda [131], [132] em 2011, que utiliza espirais logarítmicas para replicar fenómenos naturais tais como as correntes de redemoinho, conchas de fósseis e braços de galáxias espirais. Inicialmente, os autores formularam o SDA apenas para problemas de otimização contínuos de duas dimensões e posteriormente para d dimensões. A principal característica do SDA é a sua estratégia espiral simples e eficiente que fornece um bom mecanismo de diversificação bem como um bom mecanismo de intensificação durante o processo de

$$R^{(d)}(\theta_{1,2}, \theta_{1,3}, \dots, \theta_{d,d-1}) = \prod_{i=1}^{d-1} \left(\prod_{j=1}^i R_{d-i,d+1-j}^{(d)}(\theta_{d-i,n+1-j}) \right) \quad (4.7)$$

Apesar do SDA ter apenas dois parâmetros de controlo (r e θ) é muito sensível ao posicionamento inicial, visto que todos os agentes desenham trajetórias em espiral em direção a um centro comum. Portanto, no M-SLPSO, a trajetória em espiral do SDA é utilizada apenas para atualizar a posição do melhor agente de cada *swarm*. No PSO clássico, se a posição do agente a , na iteração t , coincidir com a melhor posição global $gbest(t)$, i.e., $x_a(t) = pbest_a(t) = gbest(t)$, a atualização da velocidade do agente torna-se total e exclusivamente dependente do termo $\omega v_{i,d}(t)$, que com o decorrer das iterações tende para zero. Com a introdução da trajetória em espiral, a probabilidade de encontrar uma melhor solução à volta da posição do melhor agente de cada *swarm* é maior, mitigando assim a estagnação do *swarm* e a convergência prematura. Os melhores agentes dos vários *swarms* (para fins de implementação foram considerados cinco *swarms*) do M-SLPSO possuem uma trajetória em espiral diferente, i.e., foram definidos valores de r e θ diferentes em cada *swarm*, permitindo assim ao algoritmo ter a habilidade de se adaptar ao problema de otimização. A Figura 4.3 mostra a trajetória em espiral definida (parâmetros de controlo r e θ) em cada *swarm* do M-SLPSO, de forma a aumentar a diversidade na construção de novas soluções e para mitigar a ocorrência de convergência prematura.

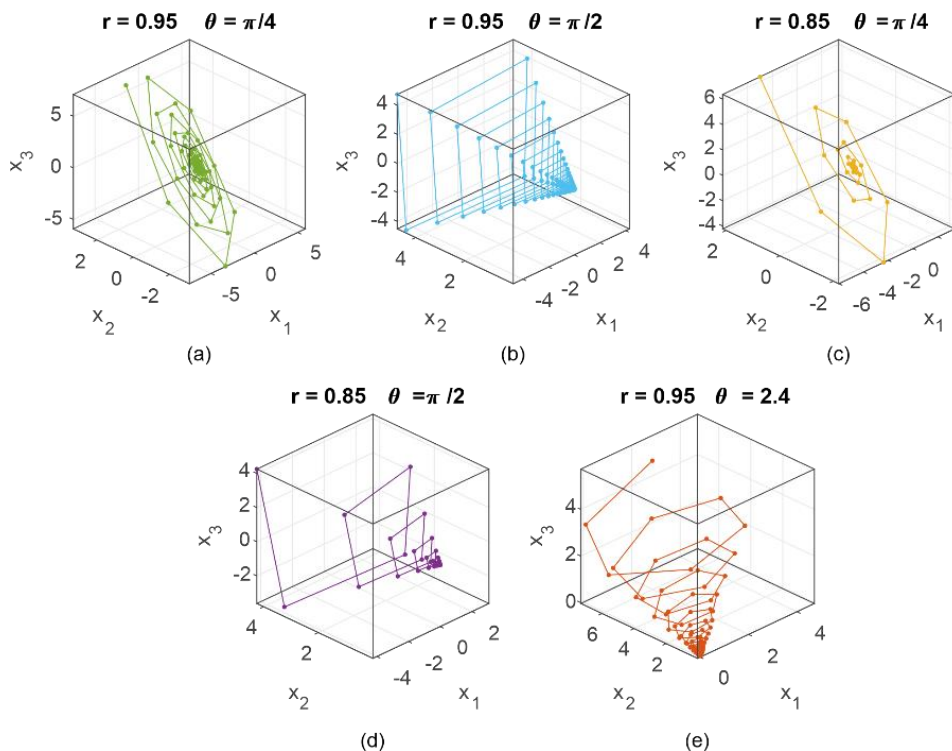


Figura 4.3 - Trajetórias em espiral consideradas para o M-SLPSO: (a) Trajetória em espiral do *swarm* 1; (b) Trajetória em espiral do *swarm* 2; (c) Trajetória em espiral do *swarm* 3; (d) Trajetória em espiral do *swarm* 4; (e) Trajetória em espiral do *swarm* 5.

4.3. Mapas caóticos

Como já foi dito anteriormente na presente dissertação, o M-SLPSO possui vários *swarms* (mais precisamente cinco *swarms* para fins de implementação) e cada líder possui uma trajetória em espiral que será explicada na secção 4.4. Sempre que a posição dos líderes chega ao centro dessa espiral (i.e., convergiu para o centro da espiral) ou quando algum líder é substituído por outro agente (com uma solução melhor que o líder atual), esse líder é reposicionado, forçando o algoritmo a procurar uma nova solução. A realização do novo posicionamento dos líderes dos *swarms* com os três melhores desempenhos é feita através de mapas caóticos com trajetórias diferentes e únicas. Assim, é possível posicionar os líderes de uma forma caótica, o que contribui significativamente para a diversidade dos *swarms*. O uso de mapas caóticos, provenientes da teoria do caos, é uma abordagem que surgiu na literatura para melhorar os mecanismos de intensificação e de diversificação de algoritmos. A teoria do caos é o estudo de equações diferenciais determinísticas que apresentam um comportamento pseudo-aleatório e uma forte dependência nas condições iniciais [136]. Os três mapas caóticos que possuem o melhor desempenho para o problema em questão foram selecionados a partir de dez mapas caóticos iniciais diferentes, apresentados na Tabela 4.1 e na Figura 4.4. Depois de várias simulações em funções de *benchmark*, foram escolhidos os mapas *Sine*, *Gauss/mouse* e *Circle* por serem os que concederam ao algoritmo uma melhor adaptação para diferentes problemas de otimização.

Tabela 4.1 - Mapas caóticos (retirado de [137])

No.	Nome	Mapa caótico	Alcance
1	Chebyshev	$x_{i+1} = \cos(\text{icos}^{-1}(x_i))$	[-1,1]
2	Circle	$x_{i+1} = \text{mod}\left(x_i + b - \left(\frac{a}{2\pi}\right) \sin(2\pi x_i), 1\right)$, $a=0.5$ e $b=0.2$	[0,1]
3	Gauss/mouse	$x_{i+1} = \begin{cases} 1 & x_i=0 \\ \frac{1}{\text{mod}(x_i, 1)} & \text{caso contrário} \end{cases}$	[0,1]
4	Iterative	$x_{i+1} = \sin\left(\frac{a\pi}{x_i}\right)$, $a=0.7$	[-1,1]
5	Logistic	$x_{i+1} = ax_i(1 - x_i)$, $a=4$	[0,1]
6	Piecewise	$x_{i+1} = \begin{cases} \frac{x_i}{P} & 0 \leq x_i < P \\ \frac{x_i - P}{0.5 - P} & P \leq x_i < 0.5 \\ \frac{1 - P - x_i}{0.5 - P} & 0.5 \leq x_i < 1 - P \\ \frac{1 - x_i}{P} & 1 - P \leq x_i < 1 \end{cases}$, $P=0.4$	[0,1]
7	Sine	$x_{i+1} = \frac{a}{4} \sin(\pi x_i)$, $a=4$	[0,1]
8	Singer	$x_{i+1} = \mu(7.86x_i - 23.31x_i^2 + 28.75x_i^3 - 13.302875x_i^4)$, $\mu=1.07$	[0,1]
9	Sinusoidal	$x_{i+1} = ax_i^2 \sin(\pi x_i)$, $a=2.3$	[0,1]
10	Tent	$x_{i+1} = \begin{cases} x_i & x_i < 0.7 \\ \frac{0.7}{10} & \\ \frac{10}{3}(1 - x_i) & x_i \geq 0.7 \end{cases}$	[0,1]

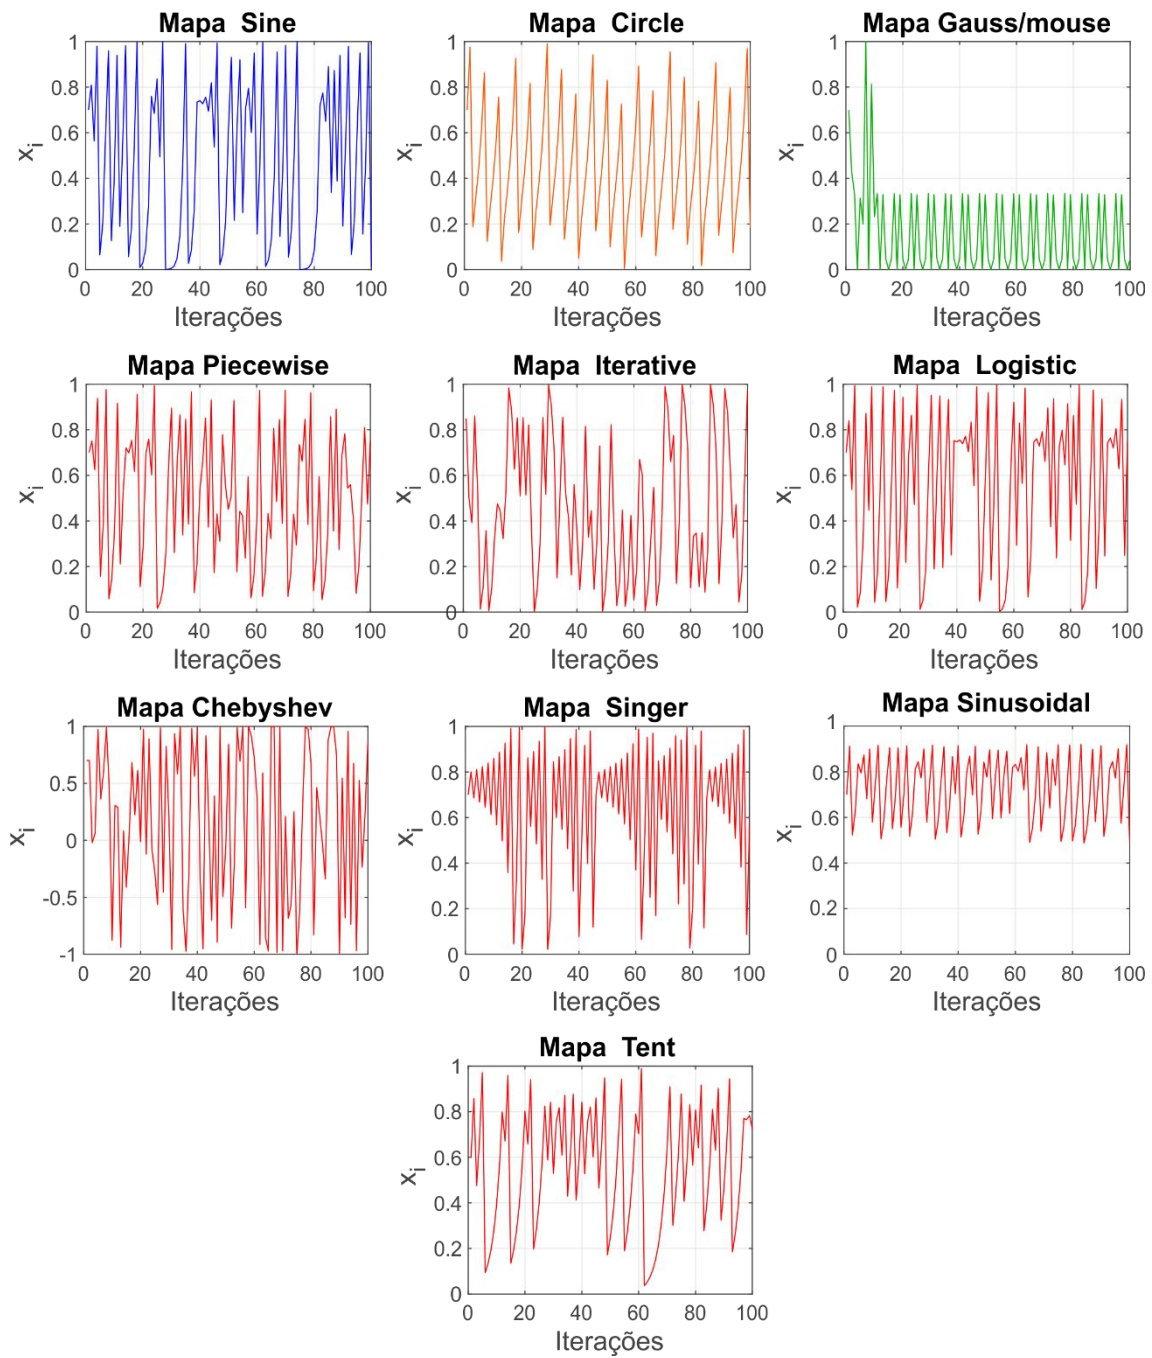


Figura 4.4 - Visualização dos diversos mapas caóticos considerados para o M-SLPSO.

É de notar que o valor inicial pode ter um impacto significativo no padrão de flutuação de alguns mapas, por isso, o ponto inicial de todos os mapas foi definido como 0.7, como sugerido na literatura [137].

4.4. Algoritmo M-SLPSO

O M-SLPSO cuja representação esquemática é ilustrada na Figura 4.5 foi projetado para executar N_{swarms} (grupos de agentes) com diferentes mecanismos de procura, cada um com o seu próprio líder. A ideia principal é ter um algoritmo com vários grupos de agentes (*swarms*) que possuem características diferentes, colaborando mutuamente, partilhando informação e experiência, à procura de uma solução ótima de uma forma eficiente e com um custo computacional reduzido. No M-SLPSO os *swarms* podem trocar de mecanismo de procura (representados na Figura 4.5 em cores diferentes) e a sua população é ajustada de acordo com o seu desempenho, i.e., os agentes podem migrar entre *swarms*.

Portanto, o M-SLPSO contém na sua população vários *swarms*, guiados por líderes diferentes, que fornecem ao algoritmo uma boa diversidade na construção de soluções e uma exploração rápida do espaço de procura através de uma cooperação adequada entre eles. O *swarm* com o melhor desempenho possui o líder global, designado de *global best* (G_{best}), enquanto que os líderes dos *swarms* restantes são designados de *local best* (L_{best}). A informação do G_{best} é partilhada por todos os *swarms* e o número de agentes de cada *swarm* é atualizado em cada iteração de acordo com o seu desempenho, i.e., de acordo com o número de melhorias na FO (sucessos), favorecendo com mais agentes os *swarms* com melhor desempenho e desfavorecendo com menos agentes os *swarms* com o pior desempenho.

Na estratégia de *multiswarm* do M-SLPSO, cada *swarm* possui um mecanismo de procura diferente, através do qual o líder de cada *swarm* é guiado por uma trajetória em espiral diferente, enquanto que os restantes agentes são guiados pelas equações típicas do PSO (equações (4.1) e (4.2)). A trajetória em espiral de cada líder é definida pela equação (4.5) com diferentes valores de r e θ , sendo que cada *swarm*, dependendo do seu desempenho, está associado a uma certa trajetória (ver Figuras 4.3 e 4.5). Além disso, sempre que a trajetória em espiral dos líderes convergir, ou houver uma mudança de líderes, é feito um novo posicionamento destes líderes através das equações (4.8)-(4.12), i.e., é realizada uma expansão da respetiva espiral. Esta expansão é diferente entre os vários *swarms*, visto que os *swarms* estão associados a uma determinada expansão dependendo do seu desempenho. A expansão para os três *swarms* com os três melhores desempenhos é feita utilizando mapas caóticos (CM_{Sine} , $CM_{Gauss/mouse}$ e CM_{Circle} através das equações (4.8), (4.9) e (4.10), respetivamente) com base na posição atual dos líderes ($x_{L_{best}}$). Este reposicionamento permite a procura de novas soluções em volta da melhor solução global, i.e., favorecendo o mecanismo de intensificação. Para assegurar a construção de novas soluções numa região longe da melhor solução global (beneficiando o mecanismo de diversificação), a expansão do *swarm* com o quarto melhor desempenho é feita através da equação (4.11), que utiliza um coeficiente (β) que vai decrescendo exponencialmente com o decorrer das iterações e considera a diferença entre os limites das variáveis do problema. Com o mesmo propósito, a

expansão do *swarm* com o pior desempenho é feita através da equação (4.12), que utiliza um coeficiente aleatório (α) e considera a diferença entre a posição atual do líder do pior *swarm*, $x_{Lbest,swarm 5}$, e a posição do pior agente do *swarm* ($x_{Lworst,swarm 5}$), como se ilustra nas Figuras 4.4 e 4.5.

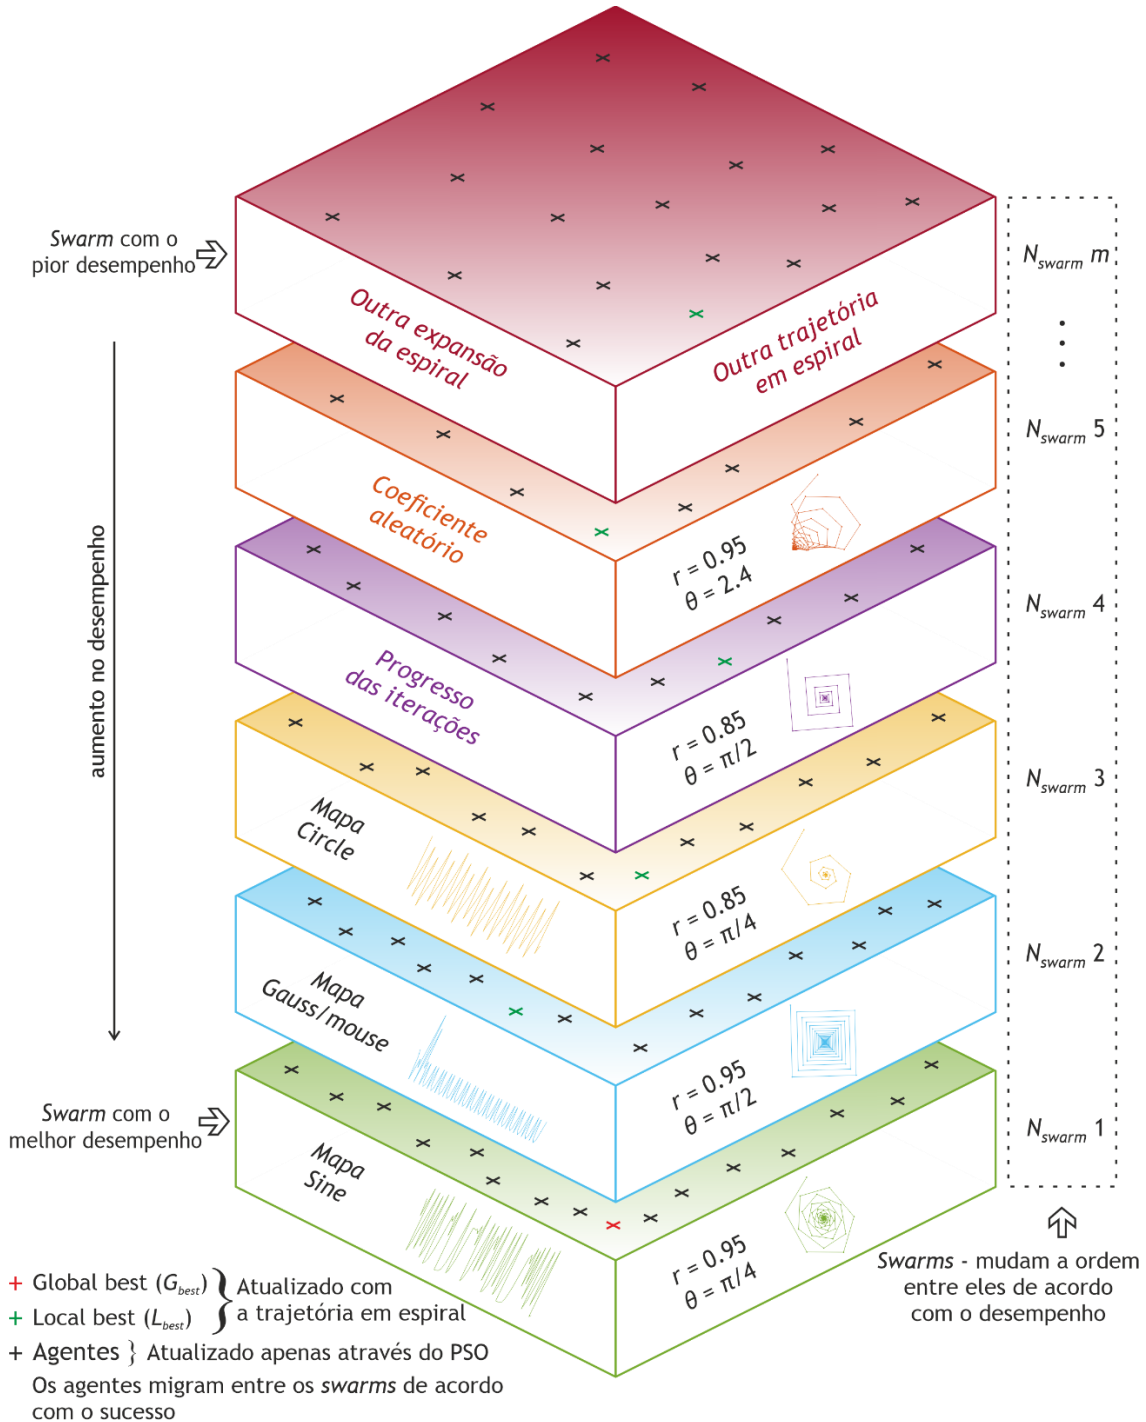


Figura 4.5 - Representação esquemática do M-SLPSO.

$$x_{Lbest,swarm\ 1}(t + 1) = x_{Lbest,swarm\ 1} + x_{Lbest,swarm\ 1} \times CM_{Sine} \quad (4.8)$$

$$x_{Lbest,swarm\ 2}(t + 1) = x_{Lbest,swarm\ 2} + x_{Lbest,swarm\ 2} \times CM_{Gauss/mouse} \quad (4.9)$$

$$x_{Lbest,swarm\ 3}(t + 1) = x_{Lbest,swarm\ 3} + x_{Lbest,swarm\ 3} \times CM_{Circle} \quad (4.10)$$

$$x_{Lbest,swarm\ 4}(t + 1) = x_{Lbest,swarm\ 4} + (Upper_{bound} - Lower_{bound}) \times \beta \quad (4.11)$$

$$x_{Lbest,swarm\ 5}(t + 1) = x_{Lbest,swarm\ 5} + (x_{Lbest,swarm\ 5} - x_{Lworst,swarm\ 5}) \times \alpha \quad (4.12)$$

Por outro lado, os *swarms* com o pior desempenho são exponencialmente atraídos para o *swarm* com o melhor desempenho através da equação (4.13), onde o coeficiente β , dado pela equação (4.14), decresce exponencialmente ao longo do percorrer das iterações. Esta atração assegura a convergência do algoritmo, bem como a sua eficiência.

$$x_{Lbest,swarm\ i} = x_{Gbest} + (x_{Gbest} - x_{Lbest,swarm\ i}) \times \beta \quad (4.13)$$

onde x_{Gbest} representa a melhor posição global e $x_{Lbest,swarm\ i}$ a posição atual do líder do *swarm* i .

$$\beta = 1 \times \exp\left(-\frac{t \times 2^2}{itermax}\right) \quad (4.14)$$

onde t é a iteração atual e $itermax$ é o número máximo de iterações.

Esta descrição acima (sumarizada na Figura 4.5) destaca a grande vantagem do M-SLPSO que é aumentar a diversidade de soluções e assegurar uma forte procura nas fases de diversificação e de intensificação, visto que possui vários mecanismos de procura (destacadas a cor na Figura 4.5) com características distintas, fornecendo ao algoritmo a habilidade de se adaptar ao problema de otimização a ser resolvido.

A Figura 4.6 retrata o fluxograma do M-SLPSO na solução de problemas de otimização, tais como a estimação de parâmetros PV. O primeiro passo do M-SLPSO consiste na inicialização de todos os parâmetros e variáveis necessárias para o seu funcionamento, incluindo: todos os parâmetros de controlo; a dimensão do problema (d), os limites inferiores e superiores das variáveis do problema; o número de agentes na população (P_T); o número de *swarms* (N_{swarms}); o contador de sucessos de cada *swarm* (S_c); a taxa de população inicial ($PR_{initial}$) que consiste na percentagem inicial de agentes em cada *swarm* (que considera o número de *swarms*, N_{swarms}); as taxas de população mínima e máxima (PR_{Min} e PR_{Max}) que são as percentagens mínima e máxima de agentes que um *swarm* pode ter para evitar a representação ausente ou excessiva dos vários *swarms*; o valor inicial dos mapas caóticos que foi definido como 0.7 para todos os mapas; e o número máximo de iterações ($itermax$). Depois disso, o número de agentes em cada *swarm* (P) é calculado com base no $PR_{initial}$ e no

P_T e os respetivos agentes são posicionados aleatoriamente no espaço de procura, tendo em conta os limites inferiores e superiores impostos para as variáveis do problema.

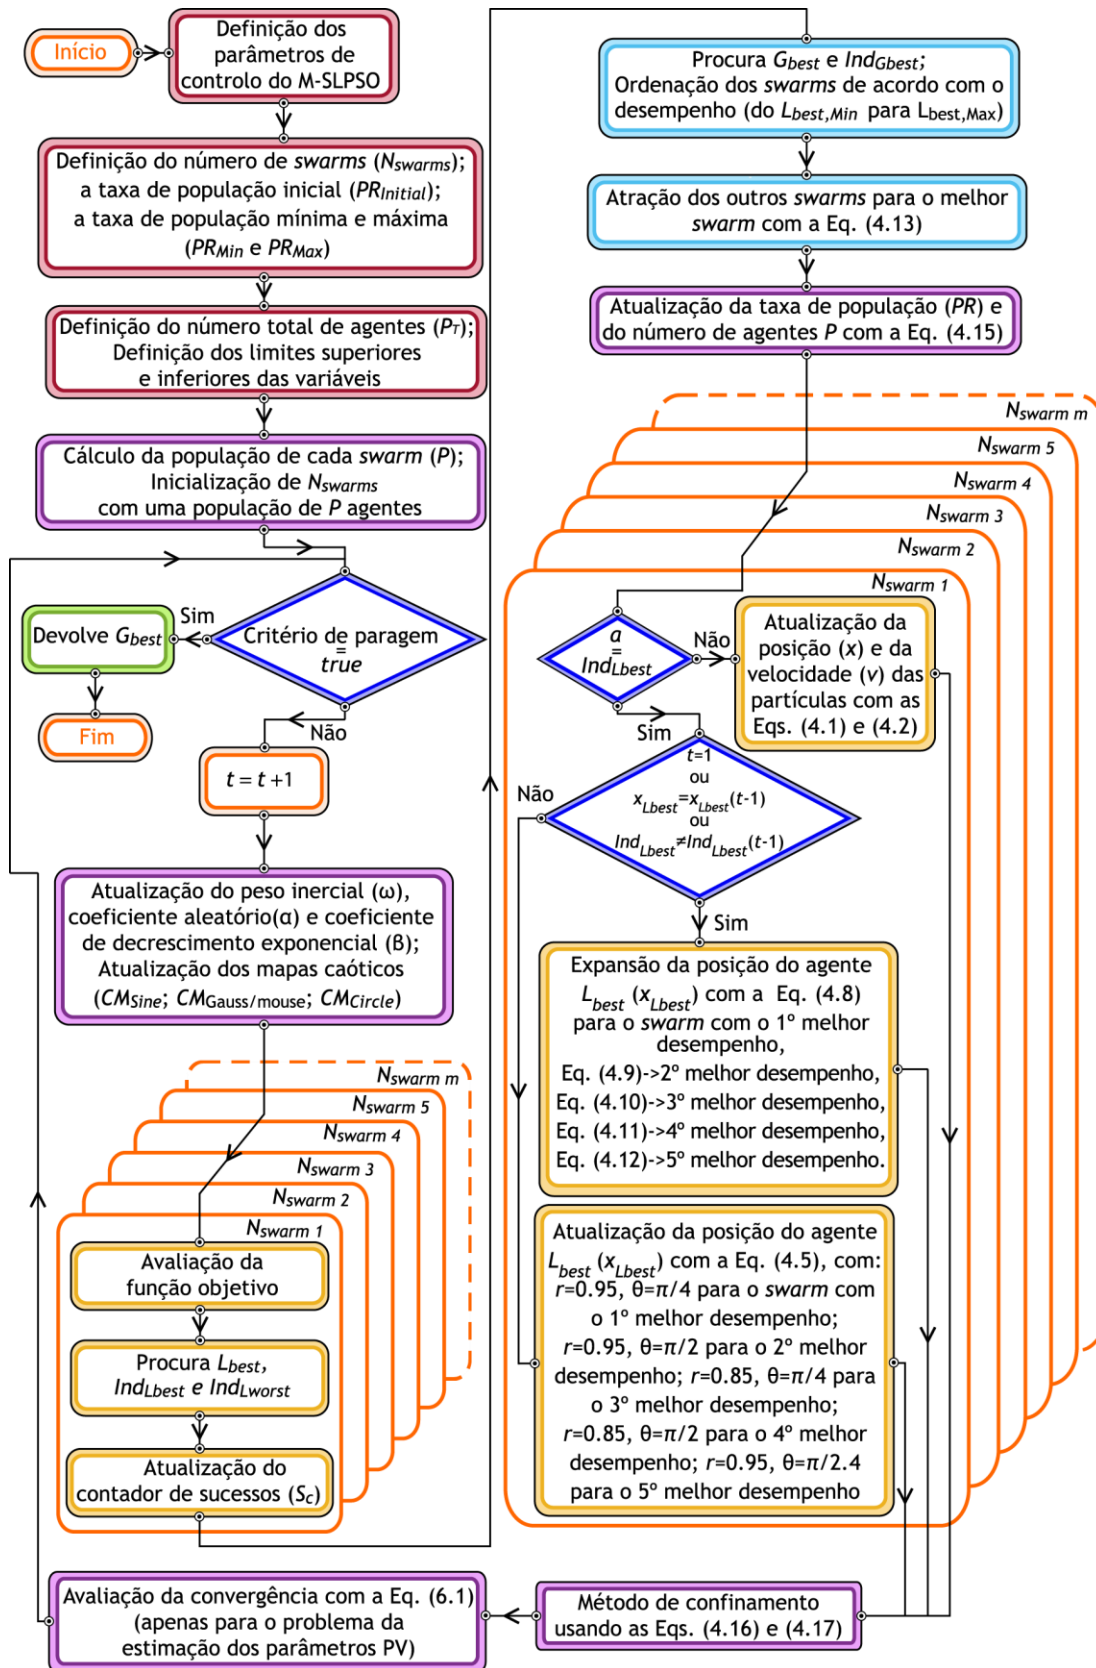


Figura 4.6 - Fluxograma do M-SLPSO.

São necessárias várias iterações para que o M-SLPSO possa explorar adequadamente o espaço de procura, avaliar possíveis soluções e convergir para a melhor solução, que idealmente seria a solução global ótima. Para tal, são necessárias algumas atualizações em cada iteração, como: o coeficiente de inércia (ω); o coeficiente aleatório (α); o coeficiente de decréscimo exponencial (β); e os mapas caóticos (CM_{Sine} , $CM_{Gauss/mouse}$ e o CM_{Circle}). Depois disso, o desempenho dos agentes de cada *swarm* é avaliado através da FO, o L_{best} de cada *swarm* é determinado e o índice do melhor agente local ($Ind_{L_{best}}$) e o índice do pior agente local ($Ind_{L_{worst}}$) são guardados. Para contar o número de melhorias da FO, sempre que um agente supera o desempenho do seu L_{best} , o contador de sucessos do respetivo *swarm* é incrementado. Quando este procedimento é concluído pelos vários *swarms*, o G_{best} e o seu índice ($Ind_{G_{best}}$) são determinados ao avaliar o L_{best} de cada *swarm* e esta informação é passada para os outros *swarms*. Ao mesmo tempo, os *swarms* são ordenados de acordo com o seu desempenho, i.e., do $L_{best,Min}$ para o $L_{best,Max}$ para que sejam associados aos diferentes mecanismos de procura, como mostra a Figura 4.5. O próximo passo é atrair os *swarms* com o pior desempenho para o *swarm* com o melhor desempenho através da equação (4.13). O ajuste da população de cada *swarm* é realizado através da equação (4.15) onde a taxa de população do *swarm* i na iteração t ($PR_{i,t}$) é dada pelo quociente entre o contador de sucessos do *swarm* i na iteração t ($S_{i,t}$) e a soma dos contadores de sucessos dos vários *swarms*. Para assegurar um bom funcionamento por parte de todos os *swarms*, é definido um PR_{Min} que determina o PR_{Max} .

$$P_{i,t} = \begin{cases} P_T \times \left(1 - \frac{PR_{i,t}}{PR_{Min} \times (N_{swarms} - 1)}\right)^{PR_{Max}} & \text{se } P_{i,t} > P_T \times PR_{Max} \\ P_T \times \frac{S_{i,t}}{\sum_{j=1}^{N_{swarms}} S_{j,t}} & \text{se } P_T \times PR_{Min} \leq P_{i,t} \leq P_T \times PR_{Max} \text{ com } i \in \{1, \dots, N_{swarms}\} \\ P_T \times PR_{Min} & \text{se } P_{i,t} < P_T \times PR_{Min} \end{cases} \quad (4.15)$$

O procedimento da movimentação do agente começa com a seguinte verificação: se o agente a é ou não é um L_{best} dos vários *swarms*. Se o agente a não é um L_{best} , a sua posição e a sua velocidade são atualizadas através das equações (4.1) e (4.2), respetivamente. Se o agente a é um L_{best} , a espiral do respetivo *swarm* é expandida (ou iniciada, no caso da primeira iteração) através das equações (4.8)-(4.12), dependendo do desempenho do *swarm*. No entanto, se a espiral não convergiu ou se o L_{best} não foi substituído, a respetiva trajetória em espiral é atualizada através da equação (4.5) com os parâmetros de controlo r e θ correspondentes ao *swarm* em questão. Desta forma, o líder de cada *swarm* é guiado por uma trajetória em espiral diferente, e a espiral também é expandida de uma maneira diferente. Além disso, os *swarms* podem trocar o mecanismo de procura do seu líder, de acordo com o desempenho, conferindo uma grande capacidade de adaptação dinâmica. Uma vez a posição dos agentes atualizada, é necessário utilizar um método de confinamento para prevenir que os agentes sejam movidos para fora do espaço de procura ao longo das iterações. Para tal, foi

implementada a estratégia de confinamento hiperbólico proposta por [138], que modifica o movimento do agente quando este excede os limites superior ou inferior, garantindo que a nova posição está dentro do espaço de procura. Este procedimento é expresso pelas equações (4.16) e (4.17), respetivamente, que modificam a posição do agente caso este exceda qualquer limite superior ou inferior.

$$v_{a,d}(t+1) = \frac{v_{a,d}(t+1)}{1 + \left| \frac{v_{a,d}(t+1)}{x_{d,max} - x_{a,d}} \right|} \text{ if } v_{a,d}(t+1) > 0 \quad (4.16)$$

$$v_{a,d}(t+1) = \frac{v_{a,d}(t+1)}{1 + \left| \frac{v_{a,d}(t+1)}{x_{a,d} - x_{d,min}} \right|} \text{ if } v_{a,d}(t+1) < 0 \quad (4.17)$$

O processo iterativo é repetido até que o critério de paragem seja alcançado. Quando esse critério de paragem é alcançado, o G_{best} é devolvido como a solução do problema. Podem ser utilizados critérios de paragem como: o máximo número de iterações; tempo de execução do algoritmo; convergência, quando o valor da FO chega ao limite especificado previamente; ou quando ocorrem várias iterações pré-definidas sem melhorias significantes na FO.

Em suma, apesar da sua estrutura simples, o M-SLPSO possui uma ótima diversidade nos mecanismos de procura, o que é uma característica fundamental para resolver problemas de otimização multimodais.

Capítulo 5

Neste capítulo são apresentados os algoritmos metaheurísticos de última geração que vão ser comparados com o método proposto (M-SLPSO) na resolução de funções de benchmark. De seguida, é feita a explicação dos critérios de avaliação utilizados para a classificação dos vários algoritmos e, finalmente, é realizada uma discussão e uma análise estatística sobre os resultados obtidos pelo método proposto (M-SLPSO).

5. M-SLPSO na resolução de funções de benchmark

Para avaliar o desempenho do M-SLPSO, foram consideradas 17 funções de *benchmark* com características diferentes muito utilizadas na literatura [74], [86], [107], [139]. A Tabela 5.1 apresenta a formulação das várias funções em concordância com [140], que estão classificadas como unimodais ou multimodais. Por exemplo, a função *Step (f6)* é unimodal e descontínua. A dimensão e os limites definidos para cada função são apresentados na Tabela 5.1, bem como a respetiva solução global ótima (f_{min}).

A fim de avaliar adequadamente o desempenho do M-SLPSO, os resultados obtidos foram comparados com os resultados obtidos por outros MHs competitivos encontrados na literatura, nomeadamente o *particle swarm optimization* (PSO), *Levy flight particle swarm optimization* (LFPSO), *spiral dynamic algorithm* (SDA), *cuckoo search* (CS), *differential evolution* (DE), *gravitational search algorithm* (GSA), *grey wolf optimizer* (GWO), *whale optimization algorithm* (WOA), *multi-verse optimizer* (MVO) e *wind driven optimization* (WDO).

Tabela 5.1 - Funções de *benchmark* usadas para avaliar o desempenho do M-SLPSO e a sua formulação.

No.	Função	Formulação	Tipo	Dim (d)	Limites	f_{min}
1	<i>Sphere</i>	$f_1(x) = \sum_{i=1}^d x_i^2$	Unimodal	30	[-100,100]	0
2	Schwefel 2.22	$f_2(x) = \sum_{i=1}^d x_i + \prod_{i=1}^d x_i $	Unimodal	30	[-10,10]	0
3	Schwefel 1.2	$f_3(x) = \sum_{i=1}^d \left(\sum_{j=1}^i x_j \right)^2$	Unimodal	30	[-100,100]	0
4	Schwefel 2.21	$f_4(x) = \max_i \{ x_i , 1 \leq i \leq d\}$	Unimodal	30	[-100,100]	0
5	Rosenbrock	$f_5(x) = \sum_{i=1}^{d-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	Unimodal	30	[-30,30]	0
6	<i>Step</i>	$f_6(x) = \sum_{i=1}^d (x_i + 0.5)^2$	Unimodal	30	[-100,100]	0
7	<i>Quartic</i>	$f_7(x) = \sum_{i=1}^d ix_i^4 + \text{random}[0,1]$	Unimodal	30	[-1.28,1.28]	0
8	Schwefel 2.26	$f_8(x) = - \sum_{i=1}^d (x_i \sin(\sqrt{ x_i }))$	Multimodal	30	[-500,500]	-12569.5
9	Rastrigin	$f_9(x) = \sum_{i=1}^d [x_i^2 - 10 \cos(2\pi x_i) + 10]$	Multimodal	30	[-5.12,5.12]	0
10	Ackley	$f_{10}(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{d} \sum_{i=1}^d x_i^2}\right) - \exp\left(\frac{1}{d} \sum_{i=1}^d \cos(2\pi x_i)\right) + 20 + e$	Multimodal	30	[-32,32]	0
11	Griewank	$f_{11}(x) = \frac{1}{4000} \sum_{i=1}^d x_i^2 - \prod_{i=1}^d \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	Multimodal	30	[-600,600]	0
12	<i>Penalized 1</i>	$f_{12}(x) = \frac{\pi}{d} \left\{ 10 \sin^2(\pi y_1) + \sum_{i=1}^{d-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_d - 1)^2 \right\} + \sum_{i=1}^d u(x_i, 10, 100, 4)$ $y_i = 1 + \frac{1}{4}(x_i + 1)$	Multimodal	30	[-50,50]	0

		$u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m, & x_i > a \\ 0, & -a \leq x_i \leq a \\ k(-x_i - a)^m, & x_i < -a \end{cases}$				
13	Penalized 2	$f_{13}(x) = 0.1 \left\{ \sin^2(3\pi x_1) + \sum_{i=1}^{d-1} (x_i - 1)^2 [1 + \sin^2(3\pi x_{i+1})] + (x_d - 1)^2 [1 + \sin^2(2\pi x_d)] \right\} + \sum_{i=1}^d u(x_i, 5, 100, 4)$	Multimodal	30	[-50,50]	0
14	Michalewicz	$f_{14}(x) = - \sum_{i=1}^d \sin(x_i) \sin^{2m} \left(\frac{i x_i^2}{\pi} \right)$	Multimodal	10	[0,π]	-9.66015
15	Zakharov	$f_{15}(x) = \sum_{i=1}^d x_i^2 + \left(\sum_{i=1}^d 0.5 i x_i \right)^2 + \left(\sum_{i=1}^d 0.5 i x_i \right)^4$	Unimodal	30	[-5,10]	0
16	Levy	$f_{16}(x) = \sin^2(\pi w_1) + \sum_{i=1}^{d-1} (w_i - 1)^2 [1 + 10 \sin^2(\pi w_{i+1})] + (w_d - 1)^2 [1 + \sin^2(2\pi w_d)]$ $w_i = 1 + \frac{x_i - 1}{4}$	Multimodal	30	[-10,10]	0
17	Rotated Hyper-Ellipsoid	$f_{17}(x) = \sum_{i=1}^d \sum_{j=1}^i x_j^2$	Unimodal	30	[-65.536,65.536]	0

5.1. Otimização dos parâmetros de controlo

A otimização dos parâmetros de controlo representa uma tarefa crucial em qualquer MH. A Tabela 5.2 apresenta os parâmetros de controlo utilizados pelo M-SLPSO e para os 10 MHs considerados para fins comparativos e de acordo com sugestões da literatura. O M-SLPSO dá uso a uma estratégia de *multiswarm*, onde cada *swarm* começa com um $PR_{initial}$ e, durante o processo iterativo, os agentes migram entre *swarms* tendo em conta um PR_{Min} para preservar a representação de todos os *swarms*.

Tabela 5.2 - Configuração dos parâmetros dos diferentes MHs.

Algoritmo metaheurístico	Parâmetros de controlo
PSO	Coeficiente de aceleração cognitivo $c_1=2$ Coeficiente de aceleração social $c_2=2$ Coeficiente de inércia $\omega: 0.9 - 0.4$
LFPSO	Coeficiente de aceleração cognitivo $c_1=2$ Coeficiente de aceleração social $c_2=2$ Coeficiente de inércia $\omega: 1 - 0$ Limite: 10
SDA	$r = 0.95$ $\theta = \pi/4$
CS	Taxa de descoberta $p_a=0.25$
DE	Fator de mutação $F = 0.6$ Constante de <i>crossover</i> $CR = 0.9$
GSA	<i>ElitistCheck</i> = 1 (True) <i>Rpower</i> = 1 <i>Rnorm</i> = 2
GWO	α diminui linearmente de 2 para 0
WOA	<i>Shrinking encircling mechanism</i> ou <i>spiral updating position</i> $p = 0.5$ α diminui linearmente de 2 para 0
MVO	<i>Minimum wormhole existence probability</i> : 0.2 <i>Maximum wormhole existence probability</i> : 1 Precisão de exploração $p = 6$
WDO	Coeficiente $RT=3$ Constante gravitacional = 0.2 Efeito Coriolis = 0.4 Constantes na equação de atualização = 0.4 Velocidade máxima permitida = 0.3
M-SLPSO	Coeficiente de aceleração cognitivo $c_1=2$ Coeficiente de aceleração social $c_2=2$ Coeficiente de inércia $\omega: 0.9 - 0.4$ Primeiro melhor <i>swarm</i> : $r = 0.95, \theta = \pi/4$ Segundo melhor <i>swarm</i> : $r = 0.95, \theta = \pi/2$

Terceiro melhor *swarm*: $r = 0.85$, $\theta = \pi/4$

Quarto melhor *swarm*: $r = 0.85$, $\theta = \pi/2$

Quinto melhor *swarm*: $r = 0.95$, $\theta = 2.4$

$PR_{initial} = 20\%$

$PR_{Min} = 10\%$

Uma comparação justa entre desempenhos de diferentes MHs requer um certo grau de igualdade. Para tal, foi definida a mesma população inicial para todos os MHs, i.e., uma população constituída por 30 agentes (com posições diferentes) a começarem na mesma posição para todos os MHs. É igualmente importante estabelecer a igualdade no número máximo de avaliações para cada função de *benchmark*. Por isso, foi definido como critério de paragem o número máximo de 500 iterações, que corresponde a 15000 avaliações. Para fins estatísticos, foram realizadas 100 simulações diferentes para cada função de *benchmark*.

5.2. Critérios de desempenho

Os critérios de avaliação utilizados para classificar o desempenho de cada um dos MHs implementados, foram os seguintes [72]:

1. Erro: diferença entre a solução s e a solução global ótima s^* (erro = $s - s^*$). A precisão da solução obtida por cada MH é quantificada pelo valor do erro. É de notar que o erro mínimo foi guardado quando o número máximo de avaliações foi alcançado. A média e o desvio padrão (DP) dos valores dos erros também foram calculados considerando as 100 simulações.
2. Wilcoxon *signed-rank test*: teste de hipóteses não paramétrico utilizado para identificar diferenças significativas entre pares de MHs com um nível de 5% de significância.
3. Teste de Friedman: teste estatístico não paramétrico utilizado para obter a classificação (*ranking*) dos MHs.
4. Taxa de sucesso (*successful rate* em inglês ou SR): quantifica a fiabilidade de um MH. Uma simulação com sucesso indica que o MH conseguiu obter o valor de aceitação antes de ser alcançado o número máximo de avaliações. A SR é calculada como o número de simulações com sucesso dividido pelo número total de simulações.

5.3. Resultados e análise estatística

Nesta secção, são apresentados e discutidos os resultados das simulações dos diversos algoritmos considerados nas 17 funções de *benchmark*. Para isso, a média e o DP dos valores dos erros obtidos pelos 11 MHs são apresentados para cada função na Tabela 5.3. Os melhores resultados encontram-se a sombreado e mostram que o M-SLPSO foi o MH que obteve a melhor média por mais vezes. A Tabela 5.3 indica que o M-SLPSO apresentou o melhor desempenho geral quando comparado com os outros MHs considerados.

Tabela 5.3 - Comparação dos valores dos erros (média e DP) alcançados pelos onze MHs em 100 simulações para as 17 funções escolhidas.

Função		PSO	LFPSO	SDA	CS	DE	GSA	GWO	WOA	MVO	WDO	M-SLPSO
f_1	Média	1.02E+03	2.10E+03	3.99E+03	4.13E+01	1.92E-01	2.10E-03	1.34E-27	3.22E-73	1.24E+00	7.55E-26	1.60E-40
	DP	3.01E+03	4.56E+03	3.08E+03	1.70E+01	1.73E-01	1.97E-02	3.86E-27	1.39E-72	3.22E-01	4.81E-25	1.60E-39
f_2	Média	5.61E+01	4.86E+01	1.11E+02	1.70E+01	2.21E-01	5.52E-01	9.98E-17	1.34E-49	4.18E+00	2.36E-13	4.80E-17
	DP	2.12E+01	2.14E+01	2.50E+01	6.51E+00	1.09E-01	1.15E+00	7.71E-17	8.88E-49	1.70E+01	3.40E-13	4.78E-16
f_3	Média	3.73E+04	3.53E+04	2.16E+04	3.67E+03	1.22E+03	1.03E+03	9.71E-06	4.06E+04	2.02E+02	1.37E-18	2.36E-48
	DP	1.11E+04	1.04E+04	9.12E+03	9.66E+02	5.71E+02	3.35E+02	2.94E-05	1.28E+04	8.16E+01	4.47E-18	2.26E-47
f_4	Média	4.28E+01	4.01E+01	4.61E+01	1.15E+01	1.78E+01	7.40E+00	7.16E-07	4.79E+01	2.08E+00	5.78E-12	1.32E-24
	DP	7.12E+00	6.85E+00	1.05E+01	2.24E+00	6.16E+00	2.17E+00	8.06E-07	2.66E+01	9.65E-01	1.81E-11	1.32E-23
f_5	Média	2.54E+04	2.79E+04	2.63E+06	1.85E+03	2.74E+02	6.05E+01	2.71E+01	2.80E+01	5.29E+02	2.86E+01	2.79E+01
	DP	3.85E+04	4.10E+04	4.91E+06	1.03E+03	3.81E+02	6.27E+01	7.88E-01	4.83E-01	7.70E+02	5.90E-02	3.01E-01
f_6	Média	2.22E+03	1.80E+03	3.98E+03	4.15E+01	1.91E-01	2.64E-02	8.16E-01	4.31E-01	1.21E+00	2.21E-02	4.44E-02
	DP	4.63E+03	4.11E+03	3.52E+03	1.61E+01	1.58E-01	1.61E-01	4.16E-01	2.46E-01	3.71E-01	9.40E-03	2.59E-02
f_7	Média	4.67E+00	4.34E+00	2.76E+00	9.48E-02	7.95E-02	6.13E-01	2.21E-03	3.80E-03	3.47E-02	3.23E-04	1.20E-02
	DP	6.63E+00	5.32E+00	3.09E+00	3.49E-02	2.12E-02	1.58E+00	1.36E-03	4.39E-03	1.40E-02	2.85E-04	1.19E-02
f_8	Média	4.38E+03	4.57E+03	6.62E+03	6.76E+03	6.28E+03	9.99E+03	6.60E+03	2.43E+03	4.88E+03	6.96E+03	2.41E+03
	DP	7.34E+02	8.47E+02	9.91E+02	3.60E+02	8.20E+02	4.65E+02	8.44E+02	1.84E+03	6.89E+02	7.68E+02	1.12E+03
f_9	Média	1.80E+02	1.60E+02	2.32E+02	1.72E+02	2.00E+02	3.56E+01	2.83E+00	2.27E-15	1.18E+02	6.93E+01	3.39E+01
	DP	3.85E+01	3.59E+01	4.84E+01	1.56E+01	1.90E+01	9.94E+00	3.68E+00	1.12E-14	2.61E+01	2.74E+01	3.79E+01
f_{10}	Média	1.59E+01	1.43E+01	1.76E+01	8.63E+00	4.38E+00	7.19E-02	1.05E-13	5.04E-15	2.09E+00	6.43E-14	7.32E-15
	DP	6.38E+00	7.64E+00	3.78E+00	2.50E+00	7.44E+00	2.65E-01	2.00E-14	2.48E-15	1.90E+00	1.39E-13	9.84E-15
f_{11}	Média	1.55E+01	2.29E+01	3.53E+01	1.36E+00	3.53E-01	2.77E+01	4.43E-03	1.45E-02	8.56E-01	1.03E-02	1.33E-17
	DP	3.78E+01	4.13E+01	2.25E+01	1.26E-01	2.03E-01	6.55E+00	8.81E-03	4.97E-02	7.35E-02	3.11E-02	6.75E-17
f_{12}	Média	2.21E+01	5.86E+00	1.38E+06	4.77E+00	2.42E+01	1.92E+00	4.36E-02	2.38E-02	2.27E+00	5.24E-02	1.03E-02
	DP	3.69E+01	3.39E+00	5.66E+06	1.80E+00	2.23E+02	9.76E-01	2.19E-02	1.51E-02	1.44E+00	1.22E-01	4.66E-02
f_{13}	Média	3.03E+02	1.79E+01	5.39E+06	1.34E+01	3.37E+02	8.67E+00	6.63E-01	5.36E-01	1.76E-01	3.56E-01	2.13E-01
	DP	7.37E+02	9.87E+00	1.83E+07	6.73E+00	1.82E+03	6.18E+00	2.50E-01	2.74E-01	7.76E-02	8.87E-01	1.83E-01
f_{14}	Média	2.03E+00	2.19E+00	4.11E+00	2.33E+00	1.93E+00	2.77E+00	2.09E+00	3.82E+00	2.91E+00	2.22E+00	1.91E+00
	DP	7.67E-01	7.35E-01	1.14E+00	4.22E-01	6.52E-01	1.44E+00	9.47E-01	8.41E-01	9.96E-01	8.96E-01	7.84E-01
f_{15}	Média	5.54E+02	5.77E+02	3.73E+02	1.80E+02	6.39E+01	1.83E+02	2.72E-07	5.03E+02	4.70E-01	7.21E+01	3.76E-20
	DP	1.45E+02	1.65E+02	1.47E+02	4.04E+01	2.00E+01	4.19E+01	6.34E-07	1.16E+02	2.15E-01	2.47E+01	3.76E-19
f_{16}	Média	1.57E+01	1.16E+01	4.16E+01	3.04E+00	3.60E-01	2.93E-01	1.14E+00	4.64E-01	1.99E+01	5.33E+00	4.09E-01
	DP	8.28E+00	7.54E+00	1.36E+01	1.51E+00	4.80E-01	4.64E-01	2.36E-01	3.08E-01	1.00E+01	4.14E+00	2.28E-01
f_{17}	Média	4.19E+04	3.75E+04	3.18E+04	2.06E+02	1.17E+00	2.15E+00	7.59E-27	3.80E-72	5.35E+01	1.28E-23	4.15E-51
	DP	2.88E+04	3.04E+04	2.94E+04	9.13E+01	1.01E+00	8.60E+00	1.96E-26	3.45E-71	4.23E+01	6.04E-23	3.12E-50
Ganha		16	17	17	17	15	14	13	10	16	13	
Empata		1	0	0	0	2	1	1	4	1	1	
Perde		0	0	0	0	0	2	3	3	0	3	

O M-SLPSO obteve os melhores valores de erro em termos de média para as funções f_3 , f_4 , f_8 , f_{11} , f_{12} , f_{14} e f_{15} e, em termos do DP, para as funções f_3 , f_4 , f_{11} , f_{15} e f_{16} . O MH que apresentou um desempenho mais competitivo para o M-SLPSO foi o WOA que obteve a melhor média e o melhor DP para as funções f_1 , f_2 , f_9 , f_{10} e f_{17} , bem como o melhor DP para a função f_{12} . No entanto, o Wilcoxon *signed-rank test* mostra que o M-SLPSO, em termos de desempenho, supera significativamente o WOA em 10 funções, é semelhante em 4 funções e é pior em 3 funções. O WDO obteve a melhor média e o melhor DP para as funções f_6 e f_7 , bem como o melhor DP para a função f_5 ; o MVO obteve a melhor média e o melhor DP para a função f_{13} ; o GWO e o GSA obtiveram os melhores valores de média para as funções f_5 e f_{16} , respetivamente; e o CS obteve o melhor DP para as funções f_8 e f_{14} .

A parte inferior da Tabela 5.3 apresenta também os resultados do Wilcoxon *signed-rank test* com um nível de significância de 5%, utilizando os sinais “+”, “=” e “-”, caso o desempenho do M-SLPSO seja respectivamente melhor, semelhante ou pior quando comparado com os outros MHs. Com base nos resultados obtidos, o M-SLPSO é significativamente melhor que o PSO, LFPSO, SDA, CS, DE, GSA, GWO, WOA, MVO e WDO em 16, 17, 17, 17, 15, 14, 13, 10, 16 e 13 funções de teste, respetivamente; significativamente semelhante em 1, 0, 0, 0, 2, 1, 1, 4, 1 e 1 funções de teste, respetivamente; e significativamente pior em 0, 0, 0, 0, 0, 2, 3, 3, 0 e 3 funções de teste, respetivamente. Como já foi mencionado acima, o WOA foi o MH que esteve mais perto do M-SLPSO em termos de desempenho, mas perdeu em 10 funções, empatou em 4 e ganhou apenas em 3 funções. Portanto, o M-SLPSO foi significativamente melhor na maior parte das funções de *benchmark* quando comparado com os outros MHs, obtendo assim resultados altamente competitivos e consistentes.

A Figura 5.1 mostra a classificação média de cada MH, com base no teste de Friedman, considerando as 17 funções de *benchmark*. Esta classificação média foi obtida tendo em conta a classificação de cada MH em cada função de *benchmark* que, por sua vez, considera os valores dos erros individuais nas 100 simulações. Analisando a Figura 5.1, é possível verificar que a melhor classificação foi obtida pelo M-SLPSO (17.17), seguido pelo WDO (31.06), GWO (32.54), WOA (38.43), GSA (52.98), DE (54.54), MVO (55.35), CS (73.17), LFPSO (76.08), PSO (83.69), e finalmente o SDA (95.49). A grande diferença nos valores da classificação média entre o M-SLPSO e o PSO mostra claramente a superioridade do M-SLPSO que, com uma estrutura simples, consegue superar a fraqueza do PSO clássico, e ainda dos outros MHs competitivos da última geração.




Figura 5.1 - Classificação média calculada pelo teste de Friedman dos 11 MHs em todas as funções de *benchmark*.

Considerando também os erros individuais das 100 simulações, foi calculada a SR para cada MH em cada função de *benchmark*. A SR média, entre todas as funções, foi utilizada para avaliar a fiabilidade dos diferentes MHs. Para se fazer uma comparação justa entre os 11 MHs, foi definido um valor de aceitação de erro de 1E-08 para todas as funções, exceto para as funções f_8 , f_{14} e f_{15} . Nestes casos, o valor de aceitação de erro foi definido com 1E03, 2 e 5, respetivamente [74], [86], [141], [142]. A SR média pode ser vista na Figura 5.2, onde está claramente destacado que o M-SLPSO foi o MH mais fiável (53.71%), seguido pelo WDO (42.71%), GWO (40.12%), WOA (37%), GSA (19.94%), MVO (7.18%), PSO (3%), DE (2.94%), LFPSO (1.94%), CS (1%), e finalmente o SDA (0.18%). O M-SLPSO alcançou 100% de fiabilidade nas funções f_1-f_4 , f_{10} , f_{11} , f_{15} e f_{17} , exibindo um desempenho notável nas funções unimodais e multimodais.

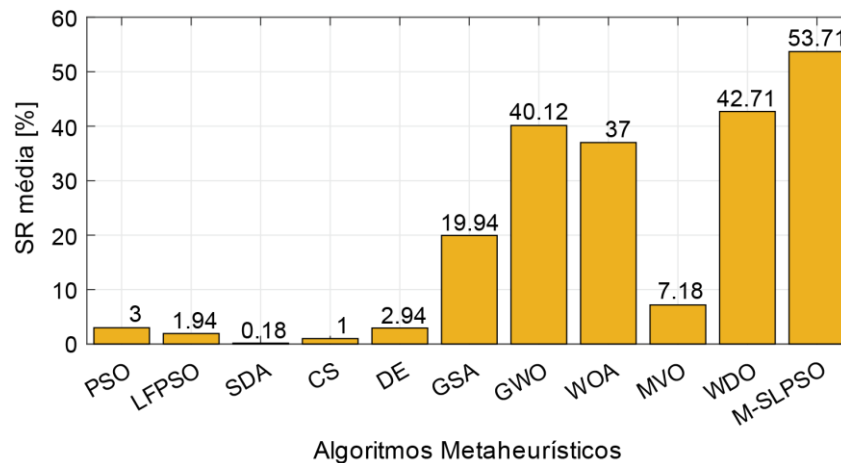


Figura 5.2 - SR média dos 11 MHs em todas as funções de *benchmark*.

Capítulo 6

Este capítulo destina-se à avaliação do desempenho do método proposto (M-SLPSO) na estimação dos parâmetros PV para dois casos de estudo, nomeadamente o módulo PV Photowatt-PWP201 e o módulo PV Sharp ND-R250A5. Por fim é feita uma análise e uma discussão dos resultados obtidos.

6. Estimação dos parâmetros PV, análise e discussão dos resultados

6.1. Introdução

Este capítulo tem como objetivo avaliar o desempenho do M-SLPSO na estimação dos parâmetros PV, particularmente o problema de otimização multimodal (formulado na secção 3.2) onde o SDM e o DDM são utilizados, com o objetivo de identificar os cinco e os sete parâmetros desconhecidos, respetivamente. Foram utilizados dados experimentais para avaliar o desempenho do M-SLPSO no problema em questão, i.e., as curvas características I-V sob diferentes níveis de irradiância e de temperatura, o que permite, através do RMSE, avaliar a precisão das curvas características I-V com base nos parâmetros estimados para cada modelo pelo M-SLPSO. Desta forma, o desempenho do M-SLPSO é tido em conta quantitativamente para ser comparado com o desempenho de outros algoritmos metaheurísticos de última geração.

Foram considerados dois casos de estudo para a validação do M-SLPSO. O primeiro caso de estudo consiste no módulo PV Photowatt-PWP201 com 36 células de silício policristalino ligadas em série, a operar sob uma irradiância de 1000 W/m^2 e uma temperatura de $45 \text{ }^\circ\text{C}$, proposto inicialmente por [53], e amplamente referenciado na literatura [1], [65], [102], [106], [109]-[112], [143]-[146], [71], [147], [148], [73], [86], [97]-[101]. O segundo caso de estudo inclui um conjunto de dados medidos num ambiente experimental para avaliar a precisão, a eficiência e a robustez do M-SLPSO numa aplicação real. Este caso de estudo refere-se ao módulo PV Sharp ND-R250A5 com 60 células de silício policristalino ($156.5 \text{ mm} \times 156.5 \text{ mm}$) ligadas em série [149], para o qual foram consideradas oito curvas características I-V sob diferentes condições de operação. Estas curvas foram medidas com a ajuda de uma

carga programável DC em diferentes alturas do dia, para contemplar condições de operação com diferentes níveis de irradiância e de temperatura. As oito curvas consideradas são: 1040 W/m² a 59°C, 924 W/m² a 68°C, 836 W/m² a 63°C, 743 W/m² a 67°C, 646 W/m² a 64°C, 544 W/m² a 53°C, 437 W/m² a 48°C e 223 W/m² a 29°C.

Todas as tarefas computacionais foram implementadas com a utilização do Matlab® num computador com um processador CPU Intel® Xeon® E5-1620 @3.60 GHz, 8 GB RAM e o sistema operacional Windows 7 Professional 64-bit. Para cada caso de estudo, foram realizadas 100 simulações independentes com ambos os modelos de modo a minimizar erros estatísticos. Para o SDM, a população foi de 100 agentes e foi usado um número máximo de 1500 iterações, enquanto que para o DDM foi usada uma população de 140 agentes e um número máximo de 2500 iterações. O critério de paragem incluiu duas estratégias diferentes: o número máximo de iterações, *itermax*; e a convergência de 80% dos agentes dentro da região definida pela equação (6.1), onde $x_{G_{best}}$ representa a melhor posição global e x_a a solução atual de cada agente da população P_T . O segundo critério de paragem foi utilizado apenas porque não afeta o algoritmo em termos de desempenho e reduz o custo computacional, aumentando a eficiência computacional.

$$x_{G_{best,d}} - x_{G_{best,d}} \times 0.000001 \leq x_{a,d}(t) \leq x_{G_{best,d}} + x_{G_{best,d}} \times 0.000001 \quad (6.1)$$

6.2. Caso de estudo 1 - Photowatt-PWP201

Para o primeiro caso de estudo, foram utilizados dados experimentais muito utilizados na literatura, os quais foram adquiridos com o módulo PV Photowatt-PWP201 sob uma condição de operação de 1000 W/m² e 45°C. Os parâmetros PV foram estimados para ambos os modelos (SDM e DDM) através do uso do M-SLPSO com base na respetiva curva experimental, que inclui 26 pares de dados de corrente e tensão. Para cada modelo, os valores ótimos obtidos para os parâmetros PV, bem como o valor do RMSE correspondente a essa solução, foram comparados com os obtidos com outros métodos da literatura.

6.2.1. Resultados para o modelo de um díodo

O desempenho do M-SLPSO foi avaliado primeiro para o SDM. Os resultados obtidos são apresentados na Tabela 6.1, onde foi realizada a comparação entre vários métodos recentes de estimação de parâmetros PV. O M-SLPSO, tal como outros métodos recentes encontrados na literatura, nomeadamente o WDOWOAPSO, o GCPSO, o RF 1C, o RF 1D, o RSS 1(b) e o TSLLS 1(b), obteve um valor do RMSE de 2.0465E-03 entre os dados experimentais e os dados estimados. Os restantes métodos obtiveram valores piores do RMSE. Ao observar a Tabela 6.1, pode-se verificar que muitos destes métodos alcançaram o mesmo valor RMSE (2.4251E-03), o

que aparentemente indica que estes métodos convergiram prematuramente para uma solução ótima local. O pior valor do RMSE obtido de entre todos os métodos apresentados na Tabela 6.2 pertence ao método ALO-LW. Os valores dos parâmetros PV obtidos pelo M-SLPSO estão muito próximos dos valores dos parâmetros PV obtidos pelos métodos que obtiveram o mesmo valor do RMSE (2.0465E-03), o que, de certa forma, mostra a consistência da solução encontrada. Portanto, os resultados mostram que o M-SLPSO é uma boa alternativa para o problema da estimação dos parâmetros PV, visto que é bastante competitivo quando comparado com os métodos recentes encontrados na literatura.

Tabela 6.1 - Comparação dos resultados entre o M-SLPSO e outros algoritmos de última geração encontrados na literatura para o módulo PV Photowatt-PWP201 com o SDM.

Método	I_{ph} [A]	I_0 [μ A]	N	R_s [Ω]	R_p [Ω]	RMSE
M-SLPSO	1.03238233	2.51292744	1.31730506	1.23928791	744.71580723	2.046535E-03
WDOWOAPSO [72]	1.03238234	2.51291155	1.31730442	1.23928866	744.71435816	2.046535E-03
GCP SO [34]	1.03238232	2.51292213	1.31730484	1.2392882	744.716635	2.046535E-03
RF 1C [52]	1.032376	2.518889	1.3174	1.239019	745.6443	2.0465E-03
RF 1D [52]	1.032376	2.518885	1.3174	1.239019	745.6431	2.0465E-03
RSS 1(b) [63]	1.032377	2.517957	1.317364	1.23906	745.712155	2.0465E-03
TSLLS 1(b) [147]	1.032382	2.512906	1.317159	1.300151	744.71302	2.0465E-03
RSS 1(a) [63]	1.032345	2.515158	1.31724	1.238972	747.943156	2.0468E-03
TVACPSO [87]	1.031435	2.63861	1.321018	1.235611	821.595146	2.0530E-03
RF 1A [52]	1.032173	3.035367	1.336752	1.218407	783.516	2.1176E-03
RF 1B [52]	1.033537	2.825571	1.329426	1.224053	689.321	2.1547E-03
TSLLS 1(a) [147]	1.033569	2.270976	1.306956	1.259967	687.87337	2.1723E-03
ABC-DE [60]	1.0318	3.2774	1.3443	1.2062	845.2495	2.4000E-03
EHA-NMS [68]	1.030514	3.482263	1.35119	1.201271	981.982256	2.4250E-03
GACCC [100]	1.030514	3.482263	1.35119	1.201271	981.98554	2.4250E-03
ImCSA [102]	1.030514	3.482263	1.351678	1.201271	981.982233	2.4250E-03
ABC-TRR [71]	1.030514	3.482263	1.35119	1.201271	981.982231	2.4250E-03
TLABC [73]	1.03056	3.4715	1.35087	1.20165	972.93567	2.4251E-03
MNMS [110]	1.030514	3.482263	1.35119	1.201271	981.982185	2.4251E-03
OR _{CR} -IJADE [112]	1.030514	3.482263	1.35119	1.201271	981.982241	2.4251E-03
GOF PANM [1]	1.030514	3.482263	1.35119	1.201271	981.982329	2.4251E-03
SATLBO [86]	1.030511	3.48271	1.351203	1.201263	982.40376	2.4251E-03
ISCE [99]	1.030514	3.482263	1.35119	1.201271	981.98228	2.4251E-03
MLBSA [106]	1.0305	3.4823	1.351189	1.2013	981.9823	2.4251E-03
DE/WOA [144]	1.030514	3.482263	1.35119	1.201271	981.982143	2.4251E-03
PGJAYA [114]	1.0305	3.4818	1.351178	1.2013	981.8545	2.4251E-03
IJAYA [97]	1.0305	3.4703	1.350828	1.2016	977.3752	2.4251E-03
HFAPS [143]	1.0305	3.4842	1.351247	1.2013	984.2813	2.4251E-03
IWOA [111]	1.0305	3.4717	1.350869	1.2016	978.6771	2.4251E-03
SOS [65]	1.0303	3.5616	1.353586	1.1991	1017.7	2.4251E-03
ITLBO [43], [103]	1.0305	3.4823	1.351189	1.2013	981.9823	2.4251E-03
ALO-LW [109]	1.03166	4.511703	1.383089	1.09352	404.943	2.8000E-03

Para obter uma melhor avaliação da precisão dos valores dos parâmetros PV estimados pelo M-SLPSO, foi calculado o erro absoluto individual (IAE), dado pela equação (6.2), e o erro absoluto (AE), dado pela equação (3.21). A Tabela A1 do apêndice A apresenta o valor do IAE, equação (6.2), para cada um dos 26 pontos da curva, e o valor do AE. Estes resultados mostram a proximidade entre a corrente experimental e a corrente estimada, provando que os valores dos parâmetros PV são precisos.

$$IAE = |I_i - \hat{I}_{(V_i, \tau)}| \quad (6.2)$$

A Figura 6.1 mostra a distribuição dos valores do IAE para o SDM, onde é claramente visível que para a maioria dos pontos da curva, o seu valor é inferior a 2.5E-03, sendo apenas superior em seis pontos. Ainda assim, em qualquer ponto, a corrente estimada é consideravelmente próxima da corrente medida experimentalmente.




Figura 6.1 - Valores do IAE entre os dados experimentais e os dados estimados para o SDM.

Foram também reconstruídas as curvas características I-V e P-V a partir dos parâmetros PV estimados para serem comparadas com os dados experimentais. As Figuras 6.2 e 6.3 mostram as curvas I-V e P.V, respetivamente, onde é claramente visível, mais uma vez, a proximidade entre os dados experimentais e os dados estimados, mais especificamente nos três pontos característicos (ponto de curto-circuito, ponto de circuito aberto e ponto de máxima potência), demonstrando a eficiência do M-SLPSO.




Figura 6.2 - Curva I-V que contém a comparação entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO para o SDM.




Figura 6.3 - Curva P-V que contém a comparação entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO para o SDM.

6.2.2. Resultados para o modelo de dois díodos

Tal como para o SDM, procedeu-se à avaliação do desempenho do M-SLPSO para o DDM, sendo também feita a comparação com outros métodos encontrados na literatura. A Tabela 6.2 apresenta os sete parâmetros ótimos estimados para o DDM, bem como o RMSE obtido correspondente a esta solução. Neste caso, o M-SLPSO conseguiu igualar a precisão dos métodos WDOWOAPSO e GCPSO. O RMSE obtido para o DDM foi de $2.0465E-03$, o mesmo obtido para o SDM. Este valor é então seguido pelo valor do RMSE obtido pelo TVACPSO e consequentemente pelo ABC-DE que obteve o pior valor do RMSE. A proximidade entre os valores da maior parte dos parâmetros PV dos métodos que obtiveram um RMSE de $2.0465E-03$ mostra, de certa forma, a consistência da solução. O facto de que foi obtido o mesmo valor do RMSE para ambos os modelos matemáticos, mostra que o DDM não adicionou nenhuma melhoria ao problema considerado. No entanto, mostra que o M-SLPSO mantém a sua eficácia e precisão em problemas de estimação de parâmetros PV mais complexos, i.e., independentemente da dimensão.

Tabela 6.2 - Comparação entre os resultados obtidos pelo M-SLPSO e por outros algoritmos de última geração para o módulo PV Photowatt-PWP201 com o DDM.

Método	I_{ph} [A]	I_{01} [μ A]	I_{02} [μ A]	n_1	n_2	R_s [Ω]	R_p [Ω]	RMSE
M-SLPSO	1.03238235	2.51291079	1.00015532E-06	1.31730439	2.49965965	1.23928866	744.71377377	2.046535E-03
WDOWOAPSO	1.03238234	1.72494775	7.87963228E-01	1.31730435	1.31730449	1.23928868	744.71426467	2.046535E-03
GCPSO	1.03238233	2.51291639	1.00005742E-06	1.31730465	1.31693992	1.2392884	744.71539851	2.046535E-03
TVACPSO	1.031434	2.638124	1E-06	1.3209988	2.7777778	1.235632	821.65281	2.0530E-03
ABC-DE	1.0318	3.2774E-01	2.4305E-06	1.3443	1.3443	1.2062	845.2495	2.4000E-03

Os sete parâmetros PV estimados pelo M-SLPSO para o DDM foram utilizados para estimar a corrente e os valores do IAE e do AE entre os dados experimentais e os dados estimados, para, deste modo, avaliar a precisão do conjunto de parâmetros obtida. Os valores do IAE e do AE para os 26 pontos da curva são apresentados na Tabela A1 (Apêndice A), e estes mostram mais uma vez uma boa proximidade entre a corrente experimental e a corrente estimada, demonstrando a precisão nos parâmetros estimados.

Para o DDM, é apresentada a distribuição dos valores do IAE na Figura 6.4. Tal como na Figura 6.1 (distribuição dos valores do IAE obtidos para o SDM), a maior parte dos valores do IAE são inferiores a $2.5E-03$, verificando assim, novamente a alta coincidência entre ambas as correntes.

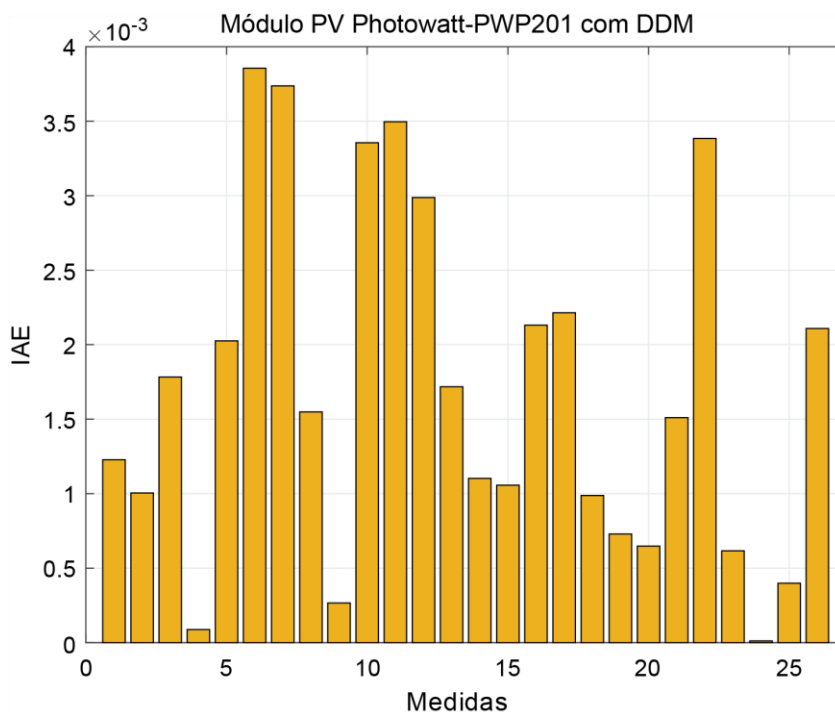


Figura 6.4 - Valores do IAE entre os dados experimentais e os dados estimados para o DDM.

As Figuras 6.5 e 6.6 mostram, respetivamente, as curvas características I-V e P-V reconstruídas a partir dos parâmetros PV estimados pelo M-SLPSO. Mais uma vez, os dados estimados estão de acordo com os dados experimentais, mais particularmente nos pontos característicos, permitindo observar o bom desempenho do M-SLPSO.




Figura 6.5 - Curva I-V que contém a comparação entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO para o DDM.




Figura 6.6 - Curva P-V que contém a comparação entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO para o DDM.

6.3. Caso de estudo 2 - resultados experimentais do módulo PV Sharp ND-R250A5

No segundo caso de estudo, foram incluídos vários conjuntos de dados experimentais, i.e., foram medidas várias curvas características I-V experimentalmente utilizando o módulo PV Sharp ND-R250A5, sob diferentes níveis de irradiância e temperatura. Neste caso de estudo, o desempenho do M-SLPSO foi avaliado em oito curvas diferentes: 1040 W/m² a 59°C, 924 W/m² a 68°C, 836 W/m² a 63°C, 743 W/m² a 67°C, 646 W/m² a 64°C, 544 W/m² a 53°C, 437 W/m² a 48°C e 223 W/m² a 29°C. Estas curvas continham 36, 31, 31, 30, 27, 25, 23 e 23 pares de dados de corrente e tensão, respetivamente. Os parâmetros PV foram estimados com base em cada um destes conjuntos de dados experimentais para o SDM e para o DDM a fim de investigar a viabilidade do M-SLPSO em condições de operação instáveis.

6.3.1. Resultados para o modelo de um díodo

A Tabela 6.3 mostra os parâmetros ótimos e os valores do RMSE estimados pelo M-SLPSO para o SDM, para cada uma das condições de operação já referidas. Como se pode ver, os RMSE obtidos para as várias curvas estão todos na mesma ordem de grandeza, o que demonstra a excelente eficácia do M-SLPSO em problemas de estimação de parâmetros PV, visto que consegue obter resultados precisos independentemente dos níveis de irradiância e temperatura, i.e., independentemente da instabilidade associada à produção de energia PV.

Tabela 6.3 - Parâmetros ótimos e valores do RMSE para o SDM obtidos pelo algoritmo M-SLPSO em diferentes condições de operação para o módulo PV Sharp ND-R250A5.

Curva	I_{ph} [A]	I_0 [μ A]	N	R_s [Ω]	R_p [Ω]	RMSE
1040 W/m ² a 59 °C	9.144865	9.958505E-01	1.206579	0.591871	4999.999989	7.69772E-03
924 W/m ² a 68 °C	8.151385	1.466809	1.201097	0.590546	4999.999999	7.72753E-03
836 W/m ² a 63 °C	7.360352	3.056599E-01	1.122491	0.613205	5000.000000	7.51043E-03
743 W/m ² a 67 °C	6.560009	1.803412E-01	1.079781	0.633777	5000.000000	8.93948E-03
646 W/m ² a 64 °C	5.696669	2.219184E-01	1.116652	0.607749	5000.000000	9.08758E-03
544 W/m ² a 53 °C	4.771024	6.089759E-02	1.106587	0.615501	5000.000000	4.82806E-03
437 W/m ² a 48 °C	3.826375	3.318537E-02	1.111764	0.612525	5000.000000	5.19364E-03
223 W/m ² a 29 °C	1.939321	1.001882E-03	1.064836	0.600169	1301.595772	1.78847E-03

A Figura 6.7 e as Tabelas A2-A9 (Apêndice A) apresentam os resultados dos valores do IAE para cada condição de operação considerada para o SDM. Os valores do IAE foram inferiores a 2E-02 em todos os pontos das oito curvas (medições), exceto para o sexto ponto (sexta medida) da curva com 924 W/m² a 68°C, que é ligeiramente superior. Os valores do AE foram também calculados (ver as Tabelas A2-A9), sendo estes (da irradiância mais alta para a irradiância mais baixa) de: 0.21867823, 0.16678141, 0.17921983, 0.23317725, 0.20923581, 0.09973952, 0.09710462 e 0.03445533, respetivamente. Portanto, a proximidade entre os

dados experimentais e os dados estimados é um bom indicador de precisão dos parâmetros PV obtidos. As três condições de operação com a irradiância mais baixa foram as que apresentaram os melhores valores do IAE, visto que estes foram quase todos inferiores a $1E-02$. A curva com 743 W/m^2 a 67°C teve tendência a ter valores do IAE superiores, sendo também a curva que obteve o maior valor do AE (0.23317725).




Figura 6.7 - Representação dos valores do IAE entre os dados experimentais e os dados estimados para as diferentes condições de operação para o SDM.

Os parâmetros PV estimados para cada condição de operação para o SDM foram utilizados para reconstruir as curvas características I-V e P-V apresentadas nas Figuras 6.8 e 6.9, respectivamente. Os resultados obtidos revelam que existe uma grande proximidade entre os dados experimentais e os dados estimados, independentemente dos níveis de irradiância e de temperatura. As Figuras 6.8 e 6.9 também mostram que quanto mais baixa a irradiância, mais baixa é a corrente e, portanto, mais baixa é a potência de saída. Existe também uma ligeira diminuição na tensão, com o aumento da temperatura.

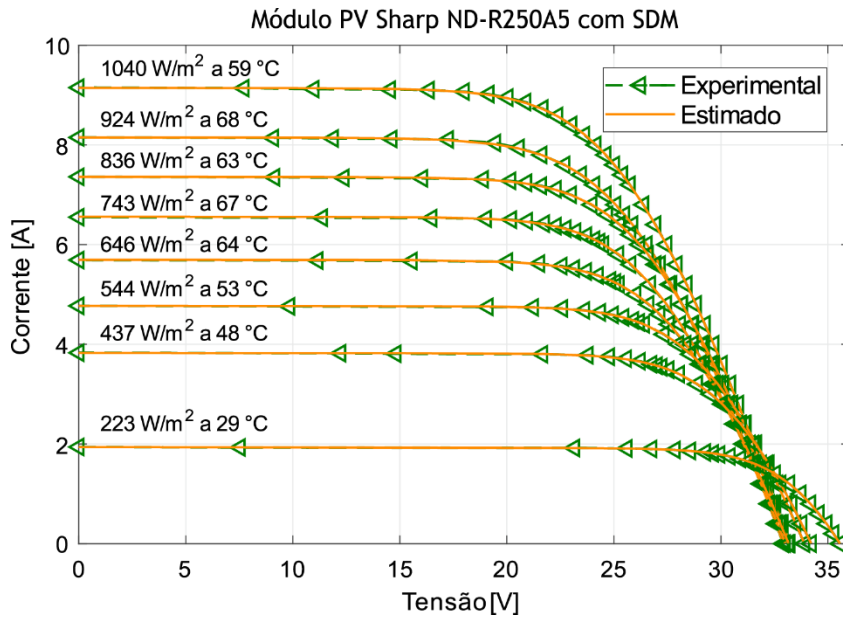


Figura 6.8 - Curva característica I-V com as comparações entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO em diferentes condições de operação para o SDM.




Figura 6.9 - Curva característica P-V com as comparações entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO em diferentes condições de operação para o SDM.

6.3.2. Resultados para o modelo de dois díodos

A Tabela 6.4 apresenta os sete parâmetros estimados (para o DDM) com o M-SLPSO para as diferentes condições de operação, bem como os respectivos valores do RMSE. Assim, como no SDM, os resultados mostram que o M-SLPSO obteve parâmetros PV precisos sob quaisquer condições de operação. De facto, considerando as casas decimais apresentadas nos resultados, pode-se afirmar que os RMSE de ambos os modelos são equivalentes, exceto para a curva com 223 W/m^2 a 29°C , na qual o valor do RMSE do DDM foi melhor ($1.761226\text{E-}03$) devido ao facto de que este modelo descreve melhor o comportamento dos módulos PV sob baixas condições de irradiância. Apesar do M-SLPSO requerer um custo computacional superior para o DDM, devido ao aumento do número de dimensões no problema, a sua eficiência não é comprometida por este aumento na complexidade.

Tabela 6.4 - Parâmetros ótimos e valores do RMSE para o DDM obtidos pelo algoritmo M-SLPSO em diferentes condições de operação para o módulo PV Sharp ND-R250A5.

Curva	I_{ph} [A]	I_{01} [μ A]	I_{02} [μ A]	n_1	n_2	R_s [Ω]	R_p [Ω]	RMSE
1040 W/m ² a 59°C	9.14486540	9.95853620E-01	1.00705983E-06	1.20657906	2.49556142	0.59187049	4999.99998215	7.697717E-03
924 W/m ² a 68°C	8.15138470	1.46680451	1.00887421E-06	1.20109642	2.49955927	0.59054654	4999.99999694	7.727531E-03
836 W/m ² a 63°C	7.36035188	3.05659858E-01	1.00000140E-06	1.12249071	2.49974677	0.61320515	5000.00000000	7.510429E-03
743 W/m ² a 67°C	6.56000997	1.80341229E-01	1.00000171E-06	1.07978061	2.49985770	0.63377685	5000.00000000	8.939484E-03
646 W/m ² a 64°C	5.69666987	2.21918316E-01	1.00000151E-06	1.11665190	2.49999780	0.60774984	5000.00000000	9.087578E-03
544 W/m ² a 53°C	4.77102395	6.08975947E-02	1.00000105E-06	1.10658692	2.50000000	0.61550069	4999.99999999	4.828056E-03
437 W/m ² a 48°C	3.82637532	3.31853716E-02	1.00000488E-06	1.11176402	2.49998829	0.61252529	5000.00000000	5.193641E-03
223 W/m ² a 29°C	1.93884393	4.63378564E-04	1.93718622E-01	1.02982342	1.75090200	0.61774786	1475.75863441	1.761226E-03

A Figura 6.10 e as Tabelas A2-A9 (Apêndice A) apresentam os resultados dos valores do IAE para cada condição de operação considerada para o DDM. Tal como os valores do RMSE, os valores do IAE foram muito idênticos para ambos os modelos matemáticos. Os valores do AE foram também calculados (ver as Tabelas A2-A9), sendo estes (da irradiância mais alta para a irradiância mais baixa) de: 0.21867810; 0.16678231; 0.17921984; 0.23317725; 0.20923581; 0.09973952; 0.09710461; e 0.03220699. O valor do AE que mais se diferencia, em relação ao SDM, é o valor obtido para a curva com 223 W/m² a 29°C que é cerca de 7% inferior. Apesar disso, existe uma boa proximidade entre os dados experimentais e os dados estimados.

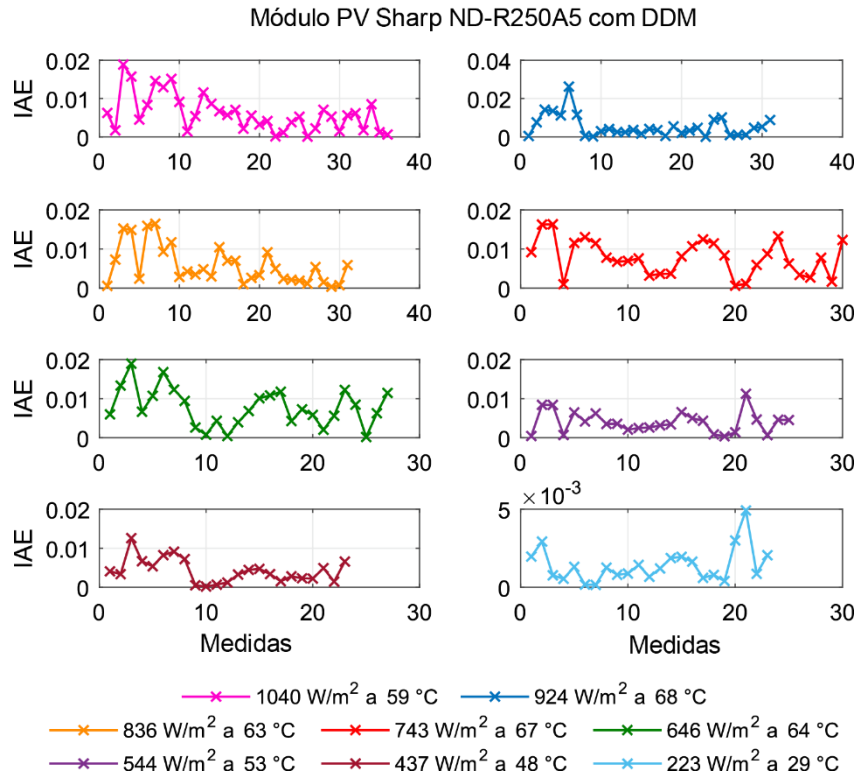


Figura 6.10 - Representação dos valores do IAE entre os dados experimentais e os dados estimados para as diferentes condições de operação para o DDM.

As Figuras 6.11 e 6.12 mostram, respetivamente, as curvas características I-V e P-V reconstruídas através do uso dos sete parâmetros PV estimados. A proximidade entre os dados estimados e os dados experimentais, calculados a partir dos parâmetros obtidos pelo M-SLPSO, demonstram assim uma boa precisão para as diferentes condições de operação.




Figura 6.11 - Curva característica I-V com as comparações entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO em diferentes condições de operação para o DDM.




Figura 6.12 - Curva característica P-V com as comparações entre os dados experimentais e os dados estimados obtidos pelo M-SLPSO em diferentes condições de operação para o DDM.

6.4. Resultados estatísticos

Apesar do excelente desempenho do M-SLPSO ter sido provado nas secções anteriores, a natureza multimodal do problema da estimação dos parâmetros PV torna a avaliação da sua fiabilidade indispensável. Nesta secção é avaliada a fiabilidade do M-SLPSO nos vários problemas de estimação dos parâmetros PV considerados, incluindo ambos os modelos matemáticos (SDM e DDM). O custo computacional em cada caso de estudo é também apresentado. A Tabela 6.5 apresenta os resultados estatísticos (valor do RMSE, iterações e tempo de simulação) que incluem as 100 simulações independentes para cada caso de estudo.

Tabela 6.5 - Resultados estatísticos do RMSE, número de iterações e tempo de simulação do M-SLPSO para cada caso de estudo para o SDM e para o DDM em 100 simulações independentes.

Caso de estudo	Modelo PV	RMSE				Nº de iterações			Tempo[s]		
		Mínimo	Médio	Máximo	DP	Mínimo	Médio	Máximo	Mínimo	Médio	Máximo
Photowatt-PWP201	SDM	2.046535E-03	2.046535E-03	2.046535E-03	3.527834E-11	789	1015	1400	17	21	29
	DDM	2.046535E-03	2.046600E-03	2.051405E-03	5.093012E-07	1056	1515	2500	34	48	80
Curva 1040 W/m ² a 59°C	SDM	7.697717E-03	7.697752E-03	7.699653E-03	2.234096E-07	785	1078	1414	19	26	34
	DDM	7.697717E-03	7.698658E-03	7.736605E-03	4.785351E-06	1140	1496	2500	42	56	97
Curva 924 W/m ² a 68°C	SDM	7.727531E-03	7.727687E-03	7.734416E-03	9.315807E-07	800	1035	1270	18	23	28
	DDM	7.727531E-03	7.728088E-03	7.778695E-03	5.131535E-06	1118	1439	2500	39	50	87
Curva 836 W/m ² a 63°C	SDM	7.510429E-03	7.510573E-03	7.517071E-03	8.878008E-07	867	1225	1500	20	28	34
	DDM	7.510429E-03	7.510430E-03	7.510445E-03	1.550154E-09	1252	1603	2500	42	54	85
Curva 743 W/m ² a 67°C	SDM	8.939484E-03	8.939835E-03	8.959509E-03	2.452190E-06	843	1285	1500	19	29	36
	DDM	8.939484E-03	8.939512E-03	8.942278E-03	2.794047E-07	1148	1633	2500	39	56	86
Curva 646 W/m ² a 64°C	SDM	9.087578E-03	9.087583E-03	9.088076E-03	4.971348E-08	850	1251	1500	18	27	32
	DDM	9.087578E-03	9.087582E-03	9.087982E-03	4.031800E-08	1098	1583	2479	36	52	83
Curva 544 W/m ² a 53°C	SDM	4.828056E-03	4.833057E-03	4.943484E-03	1.744998E-05	948	1423	1500	21	31	34
	DDM	4.828056E-03	4.828059E-03	4.828433E-03	3.769920E-08	1175	1847	2451	39	61	80
Curva 437 W/m ² a 48°C	SDM	5.193641E-03	5.198169E-03	5.257857E-03	1.233741E-05	1027	1416	1500	22	30	34
	DDM	5.193641E-03	5.197220E-03	5.546200E-03	3.525165E-05	1318	1892	2500	41	58	78
Curva 223 W/m ² a 29°C	SDM	1.788469E-03	2.725242E-03	3.298884E-03	6.103875E-04	1399	1500	1500	28	30	31
	DDM	1.761226E-03	1.960293E-03	2.381501E-03	1.666899E-04	2362	2500	2500	72	77	84

Analisando os resultados do RMSE da Tabela 6.5, e como já foi mencionado, pode-se verificar que o valor do RMSE mínimo entre o SDM e o DDM é o mesmo para o módulo PV Photowatt-PWP201 (caso de estudo 1), bem como para quase todas as curvas analisadas para o módulo PV Sharp ND-R250A5 (caso de estudo 2), à exceção da curva com 223 W/m^2 a 29°C . Relativamente ao valor médio do RMSE, os valores mais próximos do RMSE mínimo foram melhores, resultando num valor de DP melhor. Deste modo, como pode ser visto na Tabela 6.5, os valores do RMSE mínimos e médios só foram iguais para o SDM do módulo PV Photowatt-PWP201, dando origem ao melhor valor de DP ($3.527834\text{E-}11$). Nos restantes casos, estes valores (RMSE mínimo e máximo) foram ligeiramente diferentes, resultando em valores de DP superiores, mas bons o suficiente para provar a fiabilidade do M-SLPSO. Os valores de DP superiores foram obtidos para a curva com 223 W/m^2 a 29°C , onde o M-SLPSO apresentou uma dificuldade maior, como pode ser visto pelo custo computacional. De facto, o custo computacional teve tendência a ser superior para as curvas com irradiâncias mais baixas, como verificado na Tabela 6.5 pela análise do número de iterações e tempo de simulação. Para o módulo PV Photowatt-PWP201, e para as curvas com 1040 W/m^2 a 59°C e 924 W/m^2 a 68°C , foi necessária em média 1000 e 1500 iterações para o SDM e DDM, respetivamente; as curvas com 836 W/m^2 a 63°C , 743 W/m^2 a 67°C e 646 W/m^2 a 64°C precisaram cerca de 1200 e de 1600 iterações; as curvas com 544 W/m^2 a 53°C e 437 W/m^2 a 48°C precisaram cerca de 1400 e 1800 iterações; e, finalmente, a curva com 223 W/m^2 a 29°C precisou do número máximo de iterações permitido (1500 e 2500) para ambos os modelos matemáticos. Em relação ao tempo de simulação, foi observado um valor médio global de 27 segundos para o SDM e de 57 segundos para o DDM.

As Figuras 6.13-6.15 ilustram a variação da distribuição do RMSE para as 100 simulações independentes. Ao analisar estas figuras, pode-se verificar que os resultados do M-SLPSO apresentam pequenos desvios para a solução ótima, dando origem a soluções precisas. Além disso, possui uma excelente robustez visto que resolveu os diferentes problemas considerados utilizando os mesmos parâmetros de controlo.

A Figura 6.13 apresenta a distribuição do RMSE no primeiro caso de estudo para ambos os modelos (SDM e DDM), onde podemos concluir que o desvio para a solução ótima global foi superior para o DDM. Já as Figuras 6.14 e 6.15 mostram a distribuição do RMSE para o segundo caso de estudo nas oito condições de operação utilizando o SDM e o DDM, respetivamente. Os resultados mostram um desvio ligeiramente superior para as curvas com 1040 W/m^2 a 59°C , 924 W/m^2 a 68°C e 437 W/m^2 a 48°C utilizando o DDM; um desvio ligeiramente inferior para as curvas com 836 W/m^2 a 63°C , 743 W/m^2 a 67°C e 544 W/m^2 a 53°C ; e um desvio semelhante para a curva com 646 W/m^2 a 64°C . Apesar do DDM ter obtido uma melhor precisão para a curva com 223 W/m^2 a 29°C , esta foi a que obteve o maior desvio para a solução ótima.




Figura 6.13 - Distribuição do RMSE alcançada pelo M-SLPSO em 100 simulações para o SDM e DDM para o módulo PV Photowatt-PWP201.




Figura 6.14 - Distribuição do RMSE alcançada pelo M-SLPSO em 100 simulações com o SDM para diferentes condições de operação (módulo PV Sharp ND-R250A5).




Figura 6.15 - Distribuição do RMSE alcançada pelo M-SLPSO em 100 simulações com o DDM para diferentes condições de operação (módulo PV Sharp ND-R250A5).

O excelente desempenho do M-SLPSO para problemas de estimação dos parâmetros PV foi demonstrado através da comparação com os dados da literatura e com dados experimentais, constituindo assim uma alternativa competitiva capaz de encontrar soluções precisas e fiáveis.

Capítulo 7

No presente capítulo sintetizam-se as principais conclusões extraídas no decorrer deste trabalho e sugerem-se, como resultado da experiência adquirida com o estudo desenvolvido, algumas perspectivas para trabalhos futuros no âmbito da temática abordada.

7. Conclusão

7.1. Considerações finais

A presente dissertação teve como objetivo fundamental a descrição da modelação de sistemas PV apresentando um novo algoritmo metaheurístico híbrido bio inspirado eficiente, com baixa complexidade e custo computacional reduzido, capaz de estimar os parâmetros PV com eficiência, independentemente das condições de operação, i.e., dos níveis de irradiância e de temperatura. No entanto, para o desenvolvimento deste novo algoritmo foi necessário, em primeiro lugar, ter um bom conhecimento sobre o funcionamento dos sistemas PV e da produção PV em geral.

Atualmente, existem várias tecnologias PV e são, normalmente, divididas em três gerações diferentes. A primeira geração de células PV são à base de silício cristalino e incluem as células PV de silício monocristalino e policristalino. As células PV de silício monocristalino possuem eficiências superiores às de silício policristalino e são as mais utilizadas e mais vendidas no mundo. A segunda geração de células pertence às tecnologias de filme fino. Dentro destas, as mais comercializadas são as células de silício amorfo (α -Si), as células de telureto de cádmio (CdTe) e as células de cobre, índio, gálio e selênio (CIGS). O tipo de células de filme fino, entre as três referidas, com maior eficiência são as células CIGS. Finalmente, as tecnologias PV de terceira geração não são ainda comercializadas e encontram-se em desenvolvimento. Nelas, estão incluídas as tecnologias de concentração PV, células PV orgânicas ou de polímero, células PV *dye-sensitized* e células PV com base em nanocristais.

Seguidamente, procedeu-se ao estudo de alguns conceitos essenciais para a produção PV. Esses conceitos incluem as curvas características I-V e P-V que são curvas não lineares caracterizadas pelo ponto de máxima potência (MPP), o ponto de curto-circuito (SC) e o ponto

de circuito-aberto (OC); o rendimento e o fator de forma que ajudam a classificar e a descrever a qualidade das células ou módulos PV; as várias configurações de módulos PV (configuração em série, em paralelo e ou mista); os conceitos de sombreamento; os díodos de bypass e de bloqueio. Para a exemplificação de alguns destes conceitos, foram medidas experimentalmente curvas características I-V e P-V no módulo PV Sharp ND-R250A5 de forma a visualizar a diferença entre as curvas características I-V e P-V com e sem sombreamento.

Relativamente à modelação matemática das células ou módulos PV, existem vários modelos matemáticos que permitem simular o comportamento de células ou módulos PV sob diferentes condições ambientais, nomeadamente o modelo de um díodo, o modelo de dois díodos, o modelo de três díodos, o modelo multidíodo, o modelo de díodo multidimensão e o modelo de Bishop. Os modelos mais utilizados na literatura são os modelos de um díodo e de dois díodos, sendo que o modelo de dois díodos é mais preciso para baixos níveis de irradiância.

O principal objetivo da modelação matemática PV é a estimação dos parâmetros PV. Existem duas formas de extrair os parâmetros PV: através da informação disponibilizada pelos fabricantes (pontos característicos das curvas características I-V e P-V) ou através de dados medidos experimentalmente (curvas características I-V e P-V que tenham sido medidas experimentalmente).

A abordagem analítica é a mais comum quando a informação é disponibilizada pelos fabricantes. Esta utiliza alguns pontos-chave da curva característica e algumas simplificações matemáticas para determinar os parâmetros PV das células ou módulos PV. A abordagem numérica é a mais utilizada quando se conhecem os dados experimentais. Nesta não considerados apenas os pontos-chave da curva característica, mas sim todos os pontos presentes na mesma, obtendo com maior precisão os valores dos parâmetros PV que caracterizam o modelo matemático.

O problema da estimação dos parâmetros PV pode ser formulado como um problema de otimização e o seu objetivo consiste na minimização de uma função objetivo que, normalmente, se traduz no erro entre os dados medidos (experimentais) e os dados estimados. No entanto, o problema da estimação dos parâmetros PV é complexo, pois não só depende das condições de operação (irradiância e temperatura) que estão constantemente a mudar, como também existe uma limitação associada à equação que permite estimar a corrente de saída do circuito equivalente, limitação essa que deriva da natureza implícita da equação. Para ultrapassar a situação, foi utilizado o método de Newton-Raphson.

Relativamente ao algoritmo proposto *multiswarm spiral leader particle swarm optimization* (M-SLPSO), este consiste numa versão melhorada do PSO clássico capaz de superar as desvantagens associadas ao mesmo. Este algoritmo permite: manter a diversidade na construção de novas soluções ao longo de todo o processo de procura, mitigando a

convergência prematura; evitar a estagnação dos líderes e consequentemente a estagnação da população; incorporar vários *swarms* com diferentes mecanismos de procura, fornecendo ao algoritmo um bom balanço entre os mecanismos de diversificação e de intensificação; assegurar a eficiência e a eficácia ao adaptar-se dinamicamente de acordo com o desempenho; explorar o espaço de procura multidimensional em diferentes regiões simultaneamente e adaptar-se ao problema de otimização a ser resolvido.

No M-SLPSO, a informação do melhor agente global é partilhada por todos os *swarms* e o número de agentes de cada *swarm* é atualizado em cada iteração de acordo com o desempenho dos *swarms*, i.e., de acordo com o número de melhorias na função objetivo, favorecendo com mais agentes os *swarms* com melhor desempenho e desfavorecendo com menos agentes os *swarms* com o pior desempenho. Outra característica inerente ao M-SLPSO é o facto de possuir vários *swarms*, onde cada *swarm* tem um diferente mecanismo de procura. Além disso, os *swarms* podem trocar de mecanismos dependendo do seu desempenho, aumentando assim a diversidade nas soluções e permitindo ao algoritmo adaptar-se a diferentes problemas de otimização.

Numa primeira fase, foi avaliado o desempenho do M-SLPSO na resolução de 17 diferentes funções de *benchmark* muito utilizadas na literatura e os resultados obtidos foram comparados com os resultados obtidos por outros algoritmos metaheurísticos de última geração. Para fins estatísticos, foram realizadas 100 simulações diferentes para cada função. Os resultados indicam que o M-SLPSO obteve o melhor desempenho geral quando comparado com os outros algoritmos metaheurísticos considerados. O M-SLPSO obteve os melhores valores de erro em termos de média (das 100 simulações diferentes) para 7 diferentes funções e obteve os melhores valores de erro, em termos do desvio-padrão, para 5 diferentes funções. O algoritmo metaheurístico que apresentou um desempenho mais competitivo para o M-SLPSO foi o WOA. No entanto, o Wilcoxon *signed-rank test* mostra que o M-SLPSO, em termos de desempenho, supera significativamente o WOA em 10 funções, é semelhante em 4 funções e é pior em 3 funções.

Finalmente, foi utilizado o M-SLPSO para estimar os parâmetros PV para os modelos de um e de dois díodos em dois casos de estudo: o módulo PV Photowatt-PWP201 e o módulo PV Sharp ND-R250A5. Neste último, foram consideradas oito curvas características I-V medidas num ambiente experimental para avaliar o M-SLPSO numa aplicação real. Estas curvas foram medidas em diferentes alturas do dia para contemplar condições de operação com diferentes níveis de irradiância e de temperatura. Mais uma vez foram realizadas 100 simulações independentes com ambos os modelos matemáticos de modo a minimizar erros estatísticos. Os resultados obtidos pelo M-SLPSO foram comparados com vários algoritmos metaheurísticos de última geração. No caso de estudo 1, para o modelo de um díodo, o M-SLPSO alcançou o valor mínimo do RMSE documentado na literatura, tal como o WDOWOAPSO, o GCP SO, o RF 1C, o RF 1D, o RSS 1(b) e o TSLLS 1(b). Para o modelo de dois díodos, o M-SLPSO alcançou

novamente o valor do RMSE mínimo documentado na literatura, tal como o WDOWOAPSO e o GCPSO, provando que o M-SLPSO mantém a sua eficácia e precisão independentemente da complexidade do problema.

Em relação ao segundo caso de estudo, o M-SLPSO obteve resultados muito precisos e equivalentes para ambos os modelos, com a exceção da curva com a irradiância mais baixa na qual o valor do RMSE do modelo de dois díodos foi melhor. Visto que os resultados foram semelhantes em ambos os modelos, pode-se concluir mais uma vez que o M-SLPSO consegue estimar os parâmetros PV independentemente da complexidade do problema e independentemente das condições de operação.

7.2. Trabalhos futuros

O presente estudo permite abrir novas perspectivas de investigação e desenvolvimento, tendo em conta alguns assuntos nele abordados, uma vez que não esgota os assuntos referidos. Para o prosseguimento do estudo, são formulados alguns tópicos considerados interessantes, para investigações futuras:

- Aplicar o método proposto na presente dissertação na identificação dos parâmetros PV noutras tecnologias mais recentes, de forma a verificar a sua fiabilidade;
- Aplicar o método proposto em problemas em tempo real e estudar o seu desempenho nesses problemas;
- Desenvolver novos métodos com base no método proposto, com o objetivo de reduzir o esforço computacional, i.e., o tempo de computação e melhorar ainda mais a precisão das soluções obtidas.

Referências Bibliográficas

- [1] S. Xu and Y. Wang, “Parameter estimation of photovoltaic modules using a hybrid flower pollination algorithm,” *Energy Convers. Manag.*, vol. 144, pp. 53-68, 2017.
- [2] N. S. Lewis, “Research opportunities to advance solar energy utilization,” *Science*, vol. 351, no. 6271, pp. aad1920-1-aad1920-9, 2016.
- [3] A. Jäger-Waldau, “Snapshot of photovoltaics – February 2018,” *EPJ Photovoltaics*, vol. 9, no. 6, p. 6, 2018.
- [4] International Energy Agency (IEA), “Solar Energy,” 2018. [Online]. Available: <https://www.iea.org/topics/renewables/solar/>. [Accessed: 05-Mar-2019].
- [5] “Portugal é um dos países mais competitivos do mundo para produzir energia solar,” *Diário de Notícias*, 2018. [Online]. Available: <https://www.dn.pt/lusa/interior/portugal-e-um-dos-paises-mais-competitivos-do-mundo-para-produzir-energia-solar---ministro-caudio-9642999.html>. [Accessed: 07-Mar-2019].
- [6] DGEG, “Renováveis - Estatísticas Rápidas,” 2019. [Online]. Available: <http://www.dgeg.gov.pt/>. [Accessed: 06-Sep-2019].
- [7] APREN - Associação de Energias Renováveis, “Energias Renováveis,” 2019. [Online]. Available: <https://www.apren.pt/>. [Accessed: 05-Sep-2019].
- [8] D. Sera, “Real-time Modelling, Diagnostics and Optimised MPPT for Residential PV systems,” Aalborg: Institut for Energiteknik, Aalborg Universitet, 2009, p. 189.
- [9] J. Kennedy and R. Eberhart, “Particle swarm optimization,” in *IEEE international conference on neural networks*, 1995, pp. 1942-1948.
- [10] A. R. Jordehi, “Enhanced leader PSO (ELPSO): A new PSO variant for solving global optimisation problems,” *Appl. Soft Comput.*, vol. 26, pp. 401-417, 2014.
- [11] D. Gielen, “Renewable Energy technologies: cost analysis series,” IRENA, 2012.
- [12] K. Yoshikawa *et al.*, “Silicon heterojunction solar cell with interdigitated back contacts for a photoconversion efficiency over 26%,” *Nat. Energy*, vol. 2, no. 17032, 2017.
- [13] National Energy Foundation, “Types of Photovoltaic (PV) Cells - National Energy Foundation,” 2016. [Online]. Available: <http://www.nef.org.uk/knowledge-hub/solar-energy/types-of-photovoltaic-pv-cells>. [Accessed: 09-Jul-2019].
- [14] R. M. G. Castro, *INTRODUÇÃO À ENERGIA FOTOVOLTAICA*, 2nd ed. Lisboa, 2002.

- [15] Solar Quotes, "Monocrystalline Vs Polycrystalline Solar Panels," 2018. [Online]. Available: <https://www.solarquotes.com.au/panels/photovoltaic/monocrystalline-vs-polycrystalline/>. [Accessed: 27-Mar-2019].
- [16] J. Benick *et al.*, "High-Efficiency n-Type HP mc Silicon Solar Cells," *IEEE J. Photovoltaics*, vol. 7, no. 5, pp. 1171-1175, 2017.
- [17] J. Zhao, A. Wang, M. A. Green, and F. Ferrazza, "19.8% efficient 'honeycomb' textured multicrystalline and 24.4% monocrystalline silicon solar cells," *Appl. Phys. Lett.*, vol. 73, no. 14, pp. 1991-1993, 1998.
- [18] T. D. Lee and A. U. Ebong, "A review of thin film solar cell technologies and challenges," *Renew. Sustain. Energy Rev.*, vol. 70, pp. 1286-1297, 2017.
- [19] J. I. B. Wilson and J. McGill, "Amorphous-silicon m.i.s. solar cells," *IEE J. SolidState Electron Devices*, vol. 2, 1978.
- [20] A. Shah, P. Torres, R. Tscharnner, N. Wyrsh, and H. Keppner, "Photovoltaic Technology: The Case for Thin-Film Solar Cells," *Science*, vol. 285, no. 5428, pp. 692-698, 1999.
- [21] A. Benmir and M. S. Aida, "Analytical Modeling and Simulation of CIGS Solar Cells," *Energy Procedia*, vol. 36, pp. 618-627, 2013.
- [22] J.-L. Wu, H. Y., T. Kato, H. Sugimoto, and V. Bermudez, "New world record efficiency up to 22.9% for Cu (In, Ga)(Se, S) 2 thin-film solar cells," in *7th World Conference on Photovoltaic Energy conversion (WCPEC-7)*, 2018, pp. 10-15.
- [23] L. L. Kazmerski, F. R. White, and G. K. Morgan, "Thin-film CuInSe 2/CdS heterojunction solar cells," *Appl. Phys. Lett.*, vol. 29, no. 268, pp. 268-270, 1976.
- [24] K. L. Chopra, P. D. Paulson, and V. Dutta, "Thin-film solar cells: an overview," *Prog. Photovoltaics Res. Appl.*, vol. 12, no. 23, pp. 69-92, 2004.
- [25] A. Mohammad Bagher, "Types of Solar Cells and Application," *Am. J. Opt. Photonics*, vol. 3, no. 5, p. 94, 2015.
- [26] M. A. Green, E. D. Dunlop, D. H. Levi, J. Hohl-Ebinger, M. Yoshita, and A. W. Y. Ho-Baillie, "Solar cell efficiency tables (version 54)," *Prog. Photovoltaics Res. Appl.*, vol. 27, no. 7, pp. 565-575, 2019.
- [27] L. El Chaar, L. A. Lamont, and N. El Zein, "Review of photovoltaic technologies," *Renew. Sustain. Energy Rev.*, vol. 15, no. 5, pp. 2165-2175, 2011.
- [28] A. H. Eldin, M. Refaey, and A. Farghly, "A Review on Photovoltaic Solar Energy Technology and its Efficiency," in *17th International Middle-East Power System Conference (MEPCON'15)*, 2015.

- [29] A. Smets, K. Jäger, O. Isabella, R. van Swaaij, and M. Zeman, *Solar energy: The Physics and Engineering of Photovoltaic Conversion, Technologies and Systems*. UIT Cambridge Ltd., 2016.
- [30] The German Solar Energy Society, *Planning and Installing Photovoltaic Systems: A guide for installers, architects and engineers*, Second Ed. London: Earthscan, 2008.
- [31] M. T. Zarmai, N. N. Ekere, C. F. Oduoza, and E. H. Amalu, "A review of interconnection technologies for improved crystalline silicon solar cell photovoltaic module assembly," *Appl. Energy*, vol. 154, pp. 173-182, 2015.
- [32] A. Ingle, D. I. Sangotra, R. B. Chadge, and P. Thorat, "Module configurations in photovoltaic system: A review," *Mater. Today Proc.*, vol. 4, no. 14, pp. 12625-12629, 2017.
- [33] K. Kato and H. Koizumi, "A study on effect of blocking and bypass diodes on partial shaded PV string with compensating circuit using voltage equalizer," in *2015 IEEE International Symposium on Circuits and Systems (ISCAS)*, 2015, pp. 241-244.
- [34] H. G. G. Nunes, J. A. N. Pombo, S. J. P. S. Mariano, M. R. A. Calado, and J. A. M. Felipe de Souza, "A new high performance method for determining the parameters of PV cells and modules based on guaranteed convergence particle swarm optimization," *Appl. Energy*, vol. 211, pp. 774-791, 2018.
- [35] C. Carrero, J. Amador, and S. Arnaltes, "A single procedure for helping PV designers to select silicon PV modules and evaluate the loss resistances," *Renew. Energy*, vol. 32, no. 15, pp. 2579-2589, 2007.
- [36] K. Ishaque, Z. Salam, and H. Taheri, "Simple, fast and accurate two-diode model for photovoltaic modules," *Sol. Energy Mater. Sol. Cells*, vol. 95, no. 2, pp. 586-594, 2011.
- [37] J. J. Soon, K. S. Low, and S. T. Goh, "Multi-dimension diode photovoltaic (PV) model for different PV cell technologies," *IEEE Int. Symp. Ind. Electron.*, pp. 2496-2501, 2014.
- [38] J. Cubas, S. Pindado, and M. Victoria, "On the analytical approach for modeling photovoltaic systems behavior," *J. Power Sources*, vol. 247, pp. 467-474, 2014.
- [39] M. G. Villalva, J. R. Gazoli, and E. R. Filho, "Comprehensive Approach to Modeling and Simulation of Photovoltaic Arrays," *IEEE Trans. Power Electron.*, vol. 24, no. 5, pp. 1198-1208, 2009.
- [40] Y. Mahmoud, W. Xiao, and H. H. Zeineldin, "A Simple Approach to Modeling and Simulation of Photovoltaic Modules," *IEEE Trans. Sustain. Energy*, vol. 3, no. 1, pp. 185-186, 2012.

- [41] K. Ishaque and Z. Salam, "An improved modeling method to determine the model parameters of photovoltaic (PV) modules using differential evolution (DE)," *Sol. Energy*, vol. 85, no. 9, pp. 2349-2359, 2011.
- [42] F. Ghani, G. Rosengarten, M. Duke, and J. K. Carson, "The numerical calculation of single-diode solar-cell modelling parameters," *Renew. Energy*, vol. 72, pp. 105-112, 2014.
- [43] Y. Chen, Y. Sun, and Z. Meng, "An improved explicit double-diode model of solar cells: Fitness verification and parameter extraction," *Energy Convers. Manag.*, vol. 169, pp. 345-358, 2018.
- [44] L. Sandrolini, M. Artioli, and U. Reggiani, "Numerical method for the extraction of photovoltaic module double-diode model parameters through cluster analysis," *Appl. Energy*, vol. 87, no. 2, pp. 442-451, 2010.
- [45] B. Romero, G. del Pozo, and B. Arredondo, "Exact analytical solution of a two diode circuit model for organic solar cells showing S-shape using Lambert W-functions," *Sol. Energy*, vol. 86, no. 10, pp. 3026-3029, 2012.
- [46] F. Ghani, M. Duke, and J. Carson, "Numerical calculation of series and shunt resistance of a photovoltaic cell using the Lambert W-function: Experimental evaluation," *Sol. Energy*, vol. 87, pp. 246-253, 2013.
- [47] D. Allam, D. A. Yousri, and M. B. Eteiba, "Parameters extraction of the three diode model for the multi-crystalline solar cell/module using Moth-Flame Optimization Algorithm," *Energy Convers. Manag.*, vol. 123, pp. 535-548, 2016.
- [48] K. Nishioka, N. Sakitani, Y. Uraoka, and T. Fuyuki, "Analysis of multicrystalline silicon solar cells by modified 3-diode equivalent circuit model taking leakage current through periphery into consideration," *Sol. Energy Mater. Sol. Cells*, vol. 91, no. 13, pp. 1222-1227, 2007.
- [49] V. J. Chin, Z. Salam, and K. Ishaque, "Cell modelling and model parameters estimation techniques for photovoltaic simulator application: A review," *Appl. Energy*, vol. 154, pp. 500-519, 2015.
- [50] J. J. Soon and K. S. Low, "Optimizing Photovoltaic Model for Different Cell Technologies Using a Generalized Multidimension Diode Model," *IEEE Trans. Ind. Electron.*, vol. 62, no. 10, pp. 6371-6380, 2015.
- [51] J. W. Bishop, "Computer simulation of the effects of electrical mismatches in photovoltaic cell interconnection circuits," *Sol. Cells*, vol. 25, pp. 73-89, 1988.

- [52] A. Laudani, F. Riganti Fulginei, and A. Salvini, "High performing extraction procedure for the one-diode model of a photovoltaic panel from experimental I-V curves by using reduced forms," *Sol. Energy*, vol. 103, pp. 316-326, 2014.
- [53] T. Easwarakhanthan, J. Bottin, I. Bouhouch, and C. Boutrit, "Nonlinear Minimization Algorithm for Determining the Solar Cell Parameters with Microcomputers," *Int. J. Sol. Energy*, vol. 4, pp. 1-12, 1986.
- [54] V. Lo Brano and G. Ciulla, "An efficient analytical approach for obtaining a five parameters model of photovoltaic modules using only reference data," *Appl. Energy*, vol. 111, pp. 894-903, 2013.
- [55] N. T. Tong and W. Pora, "A parameter extraction technique exploiting intrinsic properties of solar cells," *Appl. Energy*, vol. 176, pp. 104-115, 2016.
- [56] E. E. Ali, M. A. El-Hameed, A. A. El-Fergany, and M. M. El-Arini, "Parameter extraction of photovoltaic generating units using multi-verse optimizer," *Sustain. Energy Technol. Assessments*, vol. 17, pp. 68-76, 2016.
- [57] E. I. Ortiz-Rivera and F. Z. Peng, "Analytical Model for a Photovoltaic Module using the Electrical Characteristics provided by the Manufacturer Data Sheet," in *IEEE 36th Conference on Power Electronics Specialists, 2005.*, 2005, pp. 2087-2091.
- [58] E. Q. B. Macabebe, C. J. Sheppard, and E. E. van Dyk, "Parameter extraction from I-V characteristics of PV devices," *Sol. Energy*, vol. 85, no. 1, pp. 12-18, 2011.
- [59] L. H. I. Lim, Z. Ye, J. Ye, D. Yang, and H. Du, "A linear identification of diode models from single I-V characteristics of PV panels," *IEEE Trans. Ind. Electron.*, vol. 62, no. 7, pp. 4181-4193, 2015.
- [60] O. Hachana, K. E. Hemsas, G. M. Tina, and C. Ventura, "Comparison of different metaheuristic algorithms for parameter identification of photovoltaic cell/module," *J. Renew. Sustain. Energy*, vol. 5, no. 5, pp. 053122-1-053122-18, 2013.
- [61] G. Xian-Kun, Y. Chuan-An, G. Xiang-Chuan, and Y. Yong-Chang, "Accuracy comparison between implicit and explicit single-diode models of photovoltaic cells and modules," *Acta Phys. Sin.*, vol. 63, no. 17, pp. 1-10, 2014.
- [62] A. K. Tossa, Y. M. Soro, Y. Azoumah, and D. Yamegueu, "A new approach to estimate the performance and energy productivity of photovoltaic modules in real operating conditions," *Sol. Energy*, vol. 110, pp. 543-560, 2014.
- [63] A. A. Cárdenas, M. Carrasco, F. Mancilla-David, A. Street, and R. Cárdenas, "Experimental Parameter Extraction in the Single - Diode Photovoltaic Model via a Reduced - Space Search," *IEEE Trans. Ind. Electron.*, vol. 64, no. 2, pp. 1468-1476, 2016.

- [64] R. Muralidharan, "Parameter extraction of solar photovoltaic cells and modules using current-voltage characteristics," *Int. J. Ambient Energy*, vol. 38, no. 5, pp. 509-513, 2017.
- [65] G. Xiong, J. Zhang, X. Yuan, D. Shi, and Y. He, "Application of Symbiotic Organisms Search Algorithm for Parameter Extraction of Solar Cell Models," *Appl. Sci.*, vol. 8, no. 11, pp. 1-18, 2018.
- [66] G. Wang *et al.*, "An iterative approach for modeling photovoltaic modules without implicit equations," *Appl. Energy*, vol. 202, pp. 189-198, 2017.
- [67] M. Merchaoui, A. Sakly, and M. F. Mimouni, "Particle swarm optimisation with adaptive mutation strategy for photovoltaic solar cell/module parameter extraction," *Energy Convers. Manag.*, vol. 175, pp. 151-163, 2018.
- [68] Z. Chen, L. Wu, P. Lin, Y. Wu, and S. Cheng, "Parameters identification of photovoltaic models using hybrid adaptive Nelder-Mead simplex algorithm based on eagle strategy," *Appl. Energy*, vol. 182, pp. 47-57, 2016.
- [69] M. F. AlHajri, K. M. El-Naggar, M. R. AlRashidi, and A. K. Al-Othman, "Optimal extraction of solar cell parameters using pattern search," *Renew. Energy*, vol. 44, pp. 238-245, 2012.
- [70] J. A. Nelder and R. Mead, "A Simplex Method for Function Minimization," *Comput. J.*, vol. 7, no. 4, pp. 308-313, 1965.
- [71] L. Wu *et al.*, "Parameter extraction of photovoltaic models from measured I-V characteristics curves using a hybrid trust-region reflective algorithm," *Appl. Energy*, vol. 232, pp. 36-53, 2018.
- [72] H. G. G. Nunes, J. A. N. Pombo, P. M. R. Bento, S. J. P. S. Mariano, and M. R. A. Calado, "Collaborative swarm intelligence to estimate PV parameters," *Energy Convers. Manag.*, vol. 185, pp. 866-890, 2019.
- [73] X. Chen, B. Xu, C. Mei, Y. Ding, and K. Li, "Teaching-learning-based artificial bee colony for solar photovoltaic parameter estimation," *Appl. Energy*, vol. 212, pp. 1578-1588, 2018.
- [74] X. Chen, K. Yu, W. Du, W. Zhao, and G. Liu, "Parameters identification of solar cell models using generalized oppositional teaching learning based optimization," *Energy*, vol. 99, pp. 170-180, 2016.
- [75] M. Ye, X. Wang, and Y. Xu, "Parameter extraction of solar cells using particle swarm optimization," *J. Appl. Phys.*, vol. 105, no. 9, pp. 094502-1-094502-8, 2009.
- [76] M. Zagrouba, A. Sellami, M. Bouaïcha, and M. Ksouri, "Identification of PV solar cells and modules parameters using the genetic algorithms: Application to maximum power extraction," *Sol. Energy*, vol. 84, no. 5, pp. 860-866, 2010.

- [77] K. M. El-Naggar, M. R. AlRashidi, M. F. AlHajri, and A. K. Al-Othman, "Simulated Annealing algorithm for photovoltaic parameters identification," *Sol. Energy*, vol. 86, no. 1, pp. 266-274, 2012.
- [78] R. Tamrakar and A. Gupta, "Extraction of Solar Cell Modelling Parameters Using Differential Evolution Algorithm," *Int. J. Innov. Res. Electr. Electron. Instrum. Control Eng.*, vol. 3, no. 11, pp. 78-82, 2015.
- [79] C. Chellaswamy and R. Ramesh, "Parameter extraction of solar cell models based on adaptive differential evolution algorithm," *Renew. Energy*, vol. 97, pp. 823-837, 2016.
- [80] J. Ma, T. O. Ting, K. L. Man, N. Zhang, S.-U. Guan, and P. W. H. Wong, "Parameter Estimation of Photovoltaic Models via Cuckoo Search," *J. Appl. Math.*, vol. 2013, pp. 1-8, 2013.
- [81] D. Oliva, E. Cuevas, and G. Pajares, "Parameter identification of solar cells using artificial bee colony optimization," *Energy*, vol. 72, pp. 93-102, 2014.
- [82] D. F. Alam, D. A. Yousri, and M. B. Eteiba, "Flower Pollination Algorithm based solar PV parameter estimation," *Energy Convers. Manag.*, vol. 101, pp. 410-422, 2015.
- [83] A. Askarzadeh and A. Rezazadeh, "An Innovative Global Harmony Search Algorithm for Parameter Identification of a PEM Fuel Cell Model," *IEEE Trans. Ind. Electron.*, vol. 59, no. 9, pp. 3473-3480, 2012.
- [84] R. V. Rao, V. J. Savsani, and D. P. Vakharia, "Teaching-learning-based optimization: A novel method for constrained mechanical design optimization problems," *CAD Comput. Aided Des.*, vol. 43, no. 3, pp. 303-315, 2011.
- [85] R. V. Rao, V. J. Savsani, and D. P. Vakharia, "Teaching-Learning-Based Optimization: An optimization method for continuous non-linear large scale problems," *Inf. Sci. (Ny)*, vol. 183, no. 1, pp. 1-15, 2012.
- [86] K. Yu, X. Chen, X. Wang, and Z. Wang, "Parameters identification of photovoltaic models using self-adaptive teaching-learning-based optimization," *Energy Convers. Manag.*, vol. 145, pp. 233-246, 2017.
- [87] A. R. Jordehi, "Time varying acceleration coefficients particle swarm optimisation (TVACPSO): A new optimisation algorithm for estimating parameters of PV cells and modules," *Energy Convers. Manag.*, vol. 129, pp. 262-274, 2016.
- [88] L. Guo, Z. Meng, Y. Sun, and L. Wang, "Parameter identification and sensitivity analysis of solar cell models with cat swarm optimization algorithm," *Energy Convers. Manag.*, vol. 108, pp. 520-528, 2016.
- [89] S. Mirjalili, S. M. Mirjalili, and A. Lewis, "Grey Wolf Optimizer," *Adv. Eng. Softw.*, vol. 69, pp. 46-61, 2014.

- [90] S. Mirjalili and A. Lewis, "The Whale Optimization Algorithm," *Adv. Eng. Softw.*, vol. 95, pp. 51-67, 2016.
- [91] D. Oliva, M. Abd El Aziz, and A. Ella Hassanien, "Parameter estimation of photovoltaic cells using an improved chaotic whale optimization algorithm," *Appl. Energy*, vol. 200, pp. 141-154, 2017.
- [92] S. Mirjalili, "SCA: A Sine Cosine Algorithm for solving optimization problems," *Knowledge-Based Syst.*, vol. 96, pp. 120-133, 2016.
- [93] D. Oliva, A. A. Ewees, M. A. El Aziz, A. E. Hassanien, and M. Pérez-Cisneros, "A Chaotic Improved Artificial Bee Colony for Parameter Estimation of Photovoltaic Cells," *Energies*, vol. 10, no. 7, pp. 1-19, 2017.
- [94] E. Rashedi, H. Nezamabadi-pour, and S. Saryazdi, "GSA: A Gravitational Search Algorithm," *Inf. Sci. (Ny)*, vol. 179, no. 13, pp. 2232-2248, 2009.
- [95] A. Valdivia-González, D. Zaldívar, E. Cuevas, M. Pérez-Cisneros, F. Fausto, and A. González, "A chaos-embedded Gravitational Search Algorithm for the identification of electrical parameters of photovoltaic cells," *Energies*, vol. 10, no. 7, 2017.
- [96] M. Derick, C. Rani, M. Rajesh, M. E. Farrag, Y. Wang, and K. Busawon, "An improved optimization technique for estimation of solar photovoltaic parameters," *Sol. Energy*, vol. 157, pp. 116-124, 2017.
- [97] K. Yu, J. J. Liang, B. Y. Qu, X. Chen, and H. Wang, "Parameters identification of photovoltaic models using an improved JAYA optimization algorithm," *Energy Convers. Manag.*, vol. 150, pp. 742-753, 2017.
- [98] A. Rezaee Jordehi, "Enhanced leader particle swarm optimisation (ELPSO): An efficient algorithm for parameter estimation of photovoltaic (PV) cells and modules," *Sol. Energy*, vol. 159, pp. 78-87, 2018.
- [99] X. Gao *et al.*, "Parameter extraction of solar cell models using improved shuffled complex evolution algorithm," *Energy Convers. Manag.*, vol. 157, pp. 460-479, 2018.
- [100] N. Hamid, R. Abounacer, M. Idali Oumhand, M. Feddaoui, and D. Agliz, "Parameters identification of photovoltaic solar cells and module using the genetic algorithm with convex combination crossover," *Int. J. Ambient Energy*, vol. 40, no. 5, pp. 517-524, 2019.
- [101] M. Louzazni, A. Khouya, K. Amechnoue, A. Gandelli, M. Mussetta, and A. Crăciunescu, "Metaheuristic Algorithm for Photovoltaic Parameters: Comparative Study and Prediction with a Firefly Algorithm," *Appl. Sci.*, vol. 8, no. 3, pp. 1-22, 2018.
- [102] T. Kang, J. Yao, M. Jin, S. Yang, and T. Duong, "A novel improved cuckoo search algorithm for parameter estimation of photovoltaic (PV) models," *Energies*, vol. 11, no. 5, pp. 1-31, 2018.

- [103] S. Li *et al.*, “Parameter extraction of photovoltaic models using an improved teaching-learning-based optimization,” *Energy Convers. Manag.*, vol. 186, pp. 293-305, 2019.
- [104] M. Abd Elaziz and D. Oliva, “Parameter estimation of solar cells diode models by an improved opposition-based whale optimization algorithm,” *Energy Convers. Manag.*, vol. 171, pp. 1843-1859, 2018.
- [105] P. Civicioglu, “Backtracking Search Optimization Algorithm for numerical optimization problems,” *Appl. Math. Comput.*, vol. 219, no. 15, pp. 8121-8144, 2013.
- [106] K. Yu, J. J. Liang, B. Y. Qu, Z. Cheng, and H. Wang, “Multiple learning backtracking search algorithm for estimating parameters of photovoltaic models,” *Appl. Energy*, vol. 226, pp. 408-422, 2018.
- [107] Q. Niu, L. Zhang, and K. Li, “A biogeography-based optimization algorithm with mutation strategies for model parameter estimation of solar and fuel cells,” *Energy Convers. Manag.*, vol. 86, pp. 1173-1185, 2014.
- [108] S. Mirjalili, “The ant lion optimizer,” *Adv. Eng. Softw.*, vol. 83, pp. 80-98, 2015.
- [109] G. Kanimozhi and Harish Kumar, “Modeling of solar cell under different conditions by Ant Lion Optimizer with LambertW function,” *Appl. Soft Comput. J.*, vol. 71, pp. 141-151, 2018.
- [110] X. Gao, Y. Cui, J. Hu, N. Tahir, and G. Xu, “Performance comparison of exponential, Lambert W function and Special Trans function based single diode solar cell models,” *Energy Convers. Manag.*, vol. 171, pp. 1822-1842, 2018.
- [111] G. Xiong, J. Zhang, D. Shi, and Y. He, “Parameter extraction of solar photovoltaic models using an improved whale optimization algorithm,” *Energy Convers. Manag.*, vol. 174, pp. 388-405, 2018.
- [112] N. Muangkote, K. Sunat, S. Chiewchanwattana, and S. Kaiwinit, “An advanced onlooker-ranking-based adaptive differential evolution to extract the parameters of solar cell models,” *Renew. Energy*, vol. 134, pp. 1129-1147, 2019.
- [113] D. Yousri, D. Allam, M. B. Eteiba, and P. N. Suganthan, “Static and dynamic photovoltaic models’ parameters identification using Chaotic Heterogeneous Comprehensive Learning Particle Swarm Optimizer variants,” *Energy Convers. Manag.*, vol. 182, pp. 546-563, 2019.
- [114] J. Liang, C. Yue, B. Qu, K. Yu, X. Chen, and S. Ge, “A performance-guided JAYA algorithm for parameters identification of photovoltaic cell and module,” *Appl. Energy*, vol. 237, pp. 241-257, 2019.
- [115] N. Pourmousa, S. M. Ebrahimi, M. Malekzadeh, and M. Alizadeh, “Parameter estimation of photovoltaic cells using improved Lozi map based chaotic optimization Algorithm,” *Sol. Energy*, vol. 180, pp. 180-191, 2019.

- [116] M. A. Mughal, Q. Ma, and C. Xiao, "Photovoltaic cell parameter estimation using hybrid particle swarm optimization and simulated annealing," *Energies*, vol. 10, no. 8, pp. 1-14, 2017.
- [117] X. Gao, C. Yao, X. Gao, and Y. Yu, "Identification of solar cell model parameters by combining analytical method with Nelder-Mead simplex method," *Nongye Gongcheng Xuebao/Transactions Chinese Soc. Agric. Eng.*, vol. 30, no. 6, pp. 97-106, 2014.
- [118] J. P. Ram, T. S. Babu, T. Dragicevic, and N. Rajasekar, "A new hybrid bee pollinator flower pollination algorithm for solar PV parameter estimation," *Energy Convers. Manag.*, vol. 135, pp. 463-476, 2017.
- [119] N. F. A. Hamid, N. A. Rahim, and J. Selvaraj, "Solar cell parameters identification using hybrid Nelder-Mead and modified particle swarm optimization," *J. Renew. Sustain. Energy*, vol. 8, no. 1, p. 015502, 2016.
- [120] F. Dkhichi, B. Oukarfi, A. Fakkar, and N. Belbounaguia, "Parameter identification of solar cell model using Levenberg-Marquardt algorithm combined with simulated annealing," *Sol. Energy*, vol. 110, pp. 781-788, 2014.
- [121] A. Ratnaweera, S. K. Halgamuge, and H. C. Watson, "Self-Organizing Hierarchical Particle Swarm Optimizer With Time-Varying Acceleration Coefficients," *IEEE Trans. Evol. Comput.*, vol. 8, no. 3, pp. 240-255, Jun. 2004.
- [122] Y. Shi and R. Eberhart, "A modified particle swarm optimizer," in *1998 IEEE International Conference on Evolutionary Computation Proceedings. IEEE World Congress on Computational Intelligence (Cat. No.98TH8360)*, 1998, pp. 69-73.
- [123] Y. Shi and R. C. Eberhart, "Empirical study of particle swarm optimization," in *Proceedings of the 1999 Congress on Evolutionary Computation-CEC99 (Cat. No. 99TH8406)*, 1999, vol. 3, pp. 1945-1950.
- [124] H.-R. Li and Y.-L. Gao, "Particle Swarm Optimization Algorithm with Exponent Decreasing Inertia Weight and Stochastic Mutation," in *2009 Second International Conference on Information and Computing Science*, 2009, vol. 1, no. 3, pp. 66-69.
- [125] M. Clerc and J. Kennedy, "The Particle Swarm - Explosion, Stability, and Convergence in a Multidimensional Complex Space," *IEEE Trans. Evol. Comput.*, vol. 6, no. 1, pp. 58-73, 2002.
- [126] J. Gou, Y. X. Lei, W. P. Guo, C. Wang, Y. Q. Cai, and W. Luo, "A novel improved particle swarm optimization algorithm based on individual difference evolution," *Appl. Soft Comput. J.*, vol. 57, pp. 468-481, 2017.
- [127] G. R. Murthy, M. S. Arumugam, and C. K. Loo, "Hybrid particle swarm optimization algorithm with fine tuning operators," *Int. J. Bio-Inspired Comput.*, vol. 1, no. 1/2, pp. 14-31, 2009.

- [128] Y. Liu, Z. Qin, and X. He, "Supervisor-student model in particle swarm optimization," *Congr. Evol. Comput. 2004. CEC2004*, vol. 1, pp. 542-547, 2004.
- [129] S. Q. Salih and A. A. Alsewari, "Solving large-scale problems using multi-swarm particle swarm approach," *Int. J. Eng. Technol.*, vol. 7, no. 3, pp. 1725-1729, 2018.
- [130] Hongfeng Wang, Na Wang, and Dingwei Wang, "Multi-swarm optimization algorithm for dynamic optimization problems using forking," in *2008 Chinese Control and Decision Conference*, 2008, pp. 2415-2419.
- [131] K. Tamura and K. Yasuda, "Spiral Dynamics Inspired Optimization," *J. Adv. Comput. Intell. Intell. Informatics*, vol. 15, no. 8, pp. 1116-1122, 2011.
- [132] K. Tamura and K. Yasuda, "Primary study of spiral dynamics inspired optimization," *IEEJ Trans. Electr. Electron. Eng.*, vol. 6, no. S1, pp. S98-S100, 2011.
- [133] A. N. K. Nasir, M. O. Tokhi, N. M. Abd Ghani, and M. A. Ahmad, "A novel hybrid spiral-dynamics bacterial-foraging algorithm for global optimization with application to control design," *2012 12th UK Work. Comput. Intell.*, pp. 1-7, 2012.
- [134] A. N. K. Nasir and M. O. Tokhi, "An Improved Spiral Dynamic Optimization Algorithm With Engineering Application," *IEEE Trans. Syst. Man, Cybern. Syst.*, vol. 45, no. 6, pp. 943-954, 2015.
- [135] K. TAMURA and K. YASUDA, "Spiral Optimization Algorithm Using Periodic Descent Directions," *SICE J. Control. Meas. Syst. Integr.*, vol. 9, no. 3, pp. 134-143, 2016.
- [136] W. A. Brock, "Chaos Theory," in *International Encyclopedia of the Social & Behavioral Sciences*, vol. 24, no. 11, Elsevier, 2001, pp. 1643-1646.
- [137] S. Saremi, S. Mirjalili, and A. Lewis, "Biogeography-based optimisation with chaos," *Neural Comput. Appl.*, vol. 25, no. 5, pp. 1077-1097, 2014.
- [138] M. Clerc, "Confinements and Biases in Particle Swarm Optimisation," *Sci. Non Linéaire*, vol. hal-001227, pp. 1-9, 2006.
- [139] R. Wang, Y. Zhan, and H. Zhou, "Application of Artificial Bee Colony in Model Parameter Identification of Solar Cells," *Energies*, vol. 8, no. 8, pp. 7563-7581, 2015.
- [140] Xin Yao, Yong Liu, and Guangming Lin, "Evolutionary programming made faster," *IEEE Trans. Evol. Comput.*, vol. 3, no. 2, pp. 82-102, 1999.
- [141] Y. Zhang, P. Lin, Z. Chen, and S. Cheng, "A Population Classification Evolution Algorithm for the Parameter Extraction of Solar Cell Models," *Int. J. Photoenergy*, vol. 2016, pp. 1-16, 2016.
- [142] P. N. Suganthan *et al.*, "Problem definitions and evaluation criteria for the CEC 2005 special session on real-parameter optimization," *KanGal Rep.*, vol. 2005005, 2005.

- [143] A. M. Beigi and A. Maroosi, "Parameter identification for solar cells and module using a Hybrid Firefly and Pattern Search Algorithms," *Sol. Energy*, vol. 171, pp. 435-446, Sep. 2018.
- [144] G. Xiong, J. Zhang, X. Yuan, D. Shi, Y. He, and G. Yao, "Parameter extraction of solar photovoltaic models by means of a hybrid differential evolution with whale optimization algorithm," *Sol. Energy*, vol. 176, pp. 742-761, 2018.
- [145] V. J. Chin and Z. Salam, "A New Three-point-based Approach for the Parameter Extraction of Photovoltaic Cells," *Appl. Energy*, vol. 237, pp. 519-533, 2019.
- [146] M. Louzazni, A. Khouya, K. Amechnoue, M. Mussetta, and A. Crăciunescu, "Comparison and evaluation of statistical criteria in the solar cell and photovoltaic module parameters' extraction," *Int. J. Ambient Energy*, vol. 0750, pp. 1-13, 2018.
- [147] F. J. Toledo, J. M. Blanes, and V. Galiano, "Two-Step Linear Least-Squares Method For Photovoltaic Single-Diode Model Parameters Extraction," *IEEE Trans. Ind. Electron.*, vol. 65, no. 8, pp. 6301-6308, 2018.
- [148] D. Kler, P. Sharma, A. Banerjee, K. P. S. Rana, and V. Kumar, "PV cell and module efficient parameters estimation using Evaporation Rate based Water Cycle Algorithm," *Swarm Evol. Comput.*, vol. 35, pp. 93-110, 2017.
- [149] Sharp, "Sharp solar modules, ND-R250A5," 2012. [Online]. Available: https://www.sharp.co.uk/cps/rde/xbcr/documents/documents/Marketing/Datasheet/NDR250A5_NDR245A5_Flyer_0414_en.pdf. [Accessed: 16-Apr-2019].

Anexos

Anexo A

Tabela A1 - Corrente estimada e IAE do M-SLPSO para o módulo PV Photowatt-PWP201.

Medida	Dados experimentais		Dados estimados para o SDM		Dados estimados para o DDM	
	V_{medida} [V]	I_{medida} [A]	$I_{estimada}$ [A]	IAE	$I_{estimada}$ [A]	IAE
1	-1.9426	1.0345	1.03327237	0.00122763	1.03327238	0.00122762
2	0.1248	1.0315	1.03049502	0.00100498	1.03049503	0.00100497
3	1.8093	1.0300	1.02821733	0.00178267	1.02821734	0.00178266
4	3.3511	1.0260	1.02608951	0.00008951	1.02608951	0.00008951
5	4.7622	1.0220	1.02402619	0.00202619	1.02402618	0.00202618
6	6.0538	1.0180	1.02185493	0.00385493	1.02185492	0.00385492
7	7.2364	1.0155	1.01923669	0.00373669	1.01923668	0.00373668
8	8.3189	1.0140	1.01554896	0.00154896	1.01554895	0.00154895
9	9.3097	1.0100	1.00973270	0.00026730	1.00973270	0.00026730
10	10.2163	1.0035	1.00014468	0.00335532	1.00014468	0.00335532
11	11.0449	0.9880	0.98450342	0.00349658	0.98450343	0.00349657
12	11.8018	0.9630	0.96001257	0.00298743	0.96001259	0.00298741
13	12.4929	0.9255	0.92378193	0.00171807	0.92378196	0.00171804
14	12.6490	0.9120	0.91310302	0.00110302	0.91310305	0.00110305
15	13.1231	0.8725	0.87355761	0.00105761	0.87355764	0.00105764
16	14.2221	0.7265	0.72863145	0.00213145	0.72863147	0.00213147
17	14.6995	0.6345	0.63671422	0.00221422	0.63671423	0.00221423
18	15.1346	0.5345	0.53548792	0.00098792	0.53548793	0.00098793
19	15.5311	0.4275	0.42822974	0.00072974	0.42822973	0.00072973
20	15.8929	0.3185	0.31785193	0.00064807	0.31785192	0.00064808
21	16.2229	0.2085	0.20698925	0.00151075	0.20698923	0.00151077
22	16.5241	0.1010	0.09761540	0.00338460	0.09761538	0.00338462
23	16.7987	-0.0080	-0.00861678	0.00061678	-0.00861680	0.00061680
24	17.0499	-0.1110	-0.11098759	0.00001241	-0.11098760	0.00001240
25	17.2793	-0.2090	-0.20860098	0.00039902	-0.20860098	0.00039902
26	17.4885	-0.3030	-0.30089158	0.00210842	-0.30089157	0.00210843
AE				0.04400027		0.04400032

Tabela A2 - Corrente estimada e IAE do M-SLPSO para a curva com 1040 W/m² a 59°C (módulo PV Sharp ND-R250A5).

Medida	Dados experimentais		Dados estimados para o SDM		Dados estimados para o DDM	
	V_{medida} [V]	I_{medida} [A]	$I_{estimada}$ [A]	IAE	$I_{estimada}$ [A]	IAE
1	0.0000	9.1500	9.14377040	0.00622960	9.14377045	0.00622955
2	7.7100	9.1400	9.14168225	0.00168225	9.14168230	0.00168230
3	10.9800	9.1200	9.13887732	0.01887732	9.13887737	0.01887737
4	14.5500	9.1100	9.12574845	0.01574845	9.12574848	0.01574848
5	16.3600	9.1000	9.10450083	0.00450083	9.10450085	0.00450085
6	18.0000	9.0700	9.06168661	0.00831339	9.06168662	0.00831338
7	19.1500	9.0200	9.00539847	0.01460153	9.00539846	0.01460154
8	20.0400	8.9500	8.93702854	0.01297146	8.93702851	0.01297149
9	20.8700	8.8600	8.84484263	0.01515737	8.84484259	0.01515741
10	21.6700	8.7300	8.72087516	0.00912484	8.72087510	0.00912490
11	22.3600	8.5800	8.57859889	0.00140111	8.57859883	0.00140117
12	23.0200	8.4000	8.40537380	0.00537380	8.40537374	0.00537374
13	23.6200	8.2000	8.21159597	0.01159597	8.21159591	0.01159591
14	24.1500	8.0000	8.00863247	0.00863247	8.00863241	0.00863241
15	24.6100	7.8000	7.80668555	0.00668555	7.80668551	0.00668551
16	25.0200	7.6000	7.60570871	0.00570871	7.60570867	0.00570867
17	25.3900	7.4000	7.40703585	0.00703585	7.40703583	0.00703583
18	25.7500	7.2000	7.19787658	0.00212342	7.19787657	0.00212343
19	26.3800	6.8000	6.79445213	0.00554787	6.79445214	0.00554786
20	26.9400	6.4000	6.39677883	0.00322117	6.39677886	0.00322114

21	27.4600	6.0000	5.99588447	0.00411553	5.99588452	0.00411548
22	27.9400	5.6000	5.60010453	0.00010453	5.60010458	0.00010458
23	28.4000	5.2000	5.19888966	0.00111034	5.19888973	0.00111027
24	28.8400	4.8000	4.79618210	0.00381790	4.79618218	0.00381782
25	29.2500	4.4000	4.40523913	0.00523913	4.40523921	0.00523921
26	29.6600	4.0000	4.00005381	0.00005381	4.00005389	0.00005389
27	30.0500	3.6000	3.60219704	0.00219704	3.60219712	0.00219712
28	30.4400	3.2000	3.19293743	0.00706257	3.19293751	0.00706249
29	30.8100	2.8000	2.79474318	0.00525682	2.79474325	0.00525675
30	31.1700	2.4000	2.39857395	0.00142605	2.39857400	0.00142600
31	31.5200	2.0000	2.00561155	0.00561155	2.00561160	0.00561160
32	31.8800	1.6000	1.59384800	0.00615200	1.59384803	0.00615197
33	32.2200	1.2000	1.19829368	0.00170632	1.19829370	0.00170630
34	32.5500	0.8000	0.80851160	0.00851160	0.80851161	0.00851161
35	32.8900	0.4000	0.40119399	0.00119399	0.40119397	0.00119397
36	33.2200	0.0000	0.00058611	0.00058611	0.00058608	0.00058608
AE				0.21867823		0.21867810

Tabela A3 - Corrente estimada e IAE do M-SLPSO para a curva com 924 W/m² a 68°C (módulo PV Sharp ND-R250A5).

Medida	Dados experimentais		Dados estimados para o SDM		Dados estimados para o DDM	
	V _{medida} [V]	I _{medida} [A]	I _{estimada} [A]	IAE	I _{estimada} [A]	IAE
1	0.0000	8.1500	8.15040932	0.00040932	8.15040932	0.00040932
2	9.0900	8.1400	8.14757150	0.00757150	8.14757150	0.00757150
3	11.8800	8.1300	8.14419425	0.01419425	8.14419426	0.01419426
4	14.6200	8.1200	8.13350494	0.01350494	8.13350496	0.01350496
5	17.2600	8.1100	8.09881197	0.01118803	8.09881201	0.01118799
6	19.4600	8.0400	8.01374538	0.02625462	8.01374546	0.02625454
7	20.5600	7.9400	7.92843454	0.01156546	7.92843464	0.01156536
8	21.6200	7.8000	7.79952347	0.00047653	7.79952359	0.00047641
9	22.7000	7.6000	7.60017504	0.00017504	7.60017519	0.00017519
10	23.4700	7.4000	7.40294516	0.00294516	7.40294531	0.00294531
11	24.0900	7.2000	7.20407811	0.00407811	7.20407826	0.00407826
12	24.6200	7.0000	7.00252224	0.00252224	7.00252239	0.00252239
13	25.0800	6.8000	6.80241160	0.00241160	6.80241174	0.00241174
14	25.4900	6.6000	6.60355696	0.00355696	6.60355710	0.00355710
15	25.8700	6.4000	6.40164766	0.00164766	6.40164778	0.00164778
16	26.5400	6.0000	6.00409283	0.00409283	6.00409293	0.00409293
17	27.1500	5.6000	5.59648758	0.00351242	5.59648765	0.00351235
18	27.6900	5.2000	5.20043046	0.00043046	5.20043052	0.00043052
19	28.1900	4.8000	4.80545490	0.00545490	4.80545494	0.00545494
20	28.6700	4.4000	4.40197344	0.00197344	4.40197346	0.00197346
21	29.1200	4.0000	4.00324367	0.00324367	4.00324368	0.00324368
22	29.5600	3.6000	3.59530781	0.00469219	3.59530782	0.00469218
23	29.9700	3.2000	3.20003231	0.00003231	3.20003231	0.00003231
24	30.3800	2.8000	2.79099337	0.00900663	2.79099337	0.00900663
25	30.7700	2.4000	2.38987751	0.01012249	2.38987750	0.01012250
26	31.1400	2.0000	1.99911374	0.00088626	1.99911373	0.00088627
27	31.5100	1.6000	1.59896344	0.00103656	1.59896344	0.00103656
28	31.8700	1.2000	1.20111963	0.00111963	1.20111964	0.00111964
29	32.2300	0.8000	0.79534902	0.00465098	0.79534903	0.00465097
30	32.5700	0.4000	0.40523607	0.00523607	0.40523609	0.00523609
31	32.9100	0.0000	0.00878915	0.00878915	0.00878918	0.00878918
AE				0.16678141		0.16678231

Tabela A4 - Corrente estimada e IAE do M-SLPSO para a curva com 836 W/m² a 63°C (módulo PV Sharp ND-R250A5).

Medida	Dados experimentais		Dados estimados para o SDM		Dados estimados para o DDM	
	V _{medida} [V]	I _{medida} [A]	I _{estimada} [A]	IAE	I _{estimada} [A]	IAE
1	0.0000	7.3600	7.35944654	0.00055346	7.35944653	0.00055347
2	9.1400	7.3500	7.35729015	0.00729015	7.35729015	0.00729015
3	12.3800	7.3400	7.35523252	0.01523252	7.35523252	0.01523252
4	16.0500	7.3300	7.34487559	0.01487559	7.34487559	0.01487559
5	18.8900	7.3100	7.30759202	0.00240798	7.30759202	0.00240798
6	20.1700	7.2800	7.26407797	0.01592203	7.26407796	0.01592204
7	20.9100	7.2400	7.22354222	0.01645778	7.22354222	0.01645778
8	21.6000	7.1800	7.17067497	0.00932503	7.17067497	0.00932503
9	22.2900	7.1100	7.09827925	0.01172075	7.09827925	0.01172075
10	23.0000	7.0000	6.99713909	0.00286091	6.99713909	0.00286091
11	23.9600	6.8000	6.80423706	0.00423706	6.80423707	0.00423707
12	24.6900	6.6000	6.60350036	0.00350036	6.60350036	0.00350036
13	25.2700	6.4000	6.40482827	0.00482827	6.40482827	0.00482827
14	25.7700	6.2000	6.20300176	0.00300176	6.20300176	0.00300176
15	26.1900	6.0000	6.01044953	0.01044953	6.01044953	0.01044953
16	26.5900	5.8000	5.80700420	0.00700420	5.80700420	0.00700420
17	26.9500	5.6000	5.60700814	0.00700814	5.60700814	0.00700814
18	27.6100	5.2000	5.19900691	0.00099309	5.19900691	0.00099309
19	28.1900	4.8000	4.79736997	0.00263003	4.79736997	0.00263003
20	28.7200	4.4000	4.39669228	0.00330772	4.39669228	0.00330772
21	29.2200	4.0000	3.99084857	0.00915143	3.99084857	0.00915143
22	29.6800	3.6000	3.59503954	0.00496046	3.59503954	0.00496046
23	30.1200	3.2000	3.19759670	0.00240330	3.19759670	0.00240330
24	30.5400	2.8000	2.80213438	0.00213438	2.80213438	0.00213438
25	30.9500	2.4000	2.40191421	0.00191421	2.40191421	0.00191421
26	31.3500	2.0000	1.99883462	0.00116538	1.99883462	0.00116538
27	31.7400	1.6000	1.59460521	0.00539479	1.59460521	0.00539479
28	32.1100	1.2000	1.20150732	0.00150732	1.20150732	0.00150732
29	32.4800	0.8000	0.79964424	0.00035576	0.79964424	0.00035576
30	32.8400	0.4000	0.40073942	0.00073942	0.40073942	0.00073942
31	33.1900	0.0000	0.00588702	0.00588702	0.00588702	0.00588702
AE				0.17921983		0.17921984

Tabela A5 - Corrente estimada e IAE do M-SLPSO para a curva com 743 W/m² a 67°C (módulo PV Sharp ND-R250A5).

Medida	Dados experimentais		Dados estimados para o SDM		Dados estimados para o DDM	
	V _{medida} [V]	I _{medida} [A]	I _{estimada} [A]	IAE	I _{estimada} [A]	IAE
1	0.0000	6.5500	6.55917713	0.00917713	6.55917713	0.00917713
2	11.3700	6.5400	6.55625689	0.01625689	6.55625689	0.01625689
3	16.4800	6.5300	6.54632134	0.01632134	6.54632134	0.01632134
4	19.0300	6.5200	6.51901635	0.00098365	6.51901634	0.00098366
5	20.2000	6.5000	6.48844229	0.01155771	6.48844229	0.01155771
6	20.9500	6.4700	6.45697134	0.01302866	6.45697134	0.01302866
7	21.7400	6.4200	6.40854459	0.01145541	6.40854459	0.01145541
8	22.2900	6.3700	6.36221584	0.00778416	6.36221584	0.00778416
9	22.7500	6.3200	6.31325702	0.00674298	6.31325702	0.00674298
10	23.2100	6.2600	6.25303104	0.00696896	6.25303104	0.00696896
11	23.7100	6.1800	6.17240106	0.00759894	6.17240106	0.00759894
12	24.1000	6.1000	6.09679744	0.00320256	6.09679744	0.00320256
13	24.3300	6.0500	6.04637958	0.00362042	6.04637959	0.00362041
14	24.5100	6.0000	6.00368072	0.00368072	6.00368072	0.00368072
15	25.2100	5.8000	5.80809889	0.00809889	5.80809889	0.00809889
16	25.7800	5.6000	5.61071398	0.01071398	5.61071398	0.01071398
17	26.7000	5.2000	5.21246524	0.01246524	5.21246525	0.01246525

18	27.4500	4.8000	4.81144404	0.01144404	4.81144404	0.01144404
19	28.1000	4.4000	4.40836206	0.00836206	4.40836207	0.00836207
20	28.6900	4.0000	3.99939252	0.00060748	3.99939252	0.00060748
21	29.2200	3.6000	3.59888048	0.00111952	3.59888048	0.00111952
22	29.7200	3.2000	3.19407173	0.00592827	3.19407173	0.00592827
23	30.1900	2.8000	2.79126373	0.00873627	2.79126373	0.00873627
24	30.6400	2.4000	2.38675225	0.01324775	2.38675225	0.01324775
25	31.0600	2.0000	1.99372591	0.00627409	1.99372591	0.00627409
26	31.4700	1.6000	1.59662943	0.00337057	1.59662943	0.00337057
27	31.8700	1.2000	1.19729976	0.00270024	1.19729976	0.00270024
28	32.2500	0.8000	0.80775977	0.00775977	0.80775977	0.00775977
29	32.6400	0.4000	0.39833901	0.00166099	0.39833900	0.00166100
30	33.0000	0.0000	0.01230855	0.01230855	0.01230854	0.01230854
AE				0.23317725		0.23317725

Tabela A6 - Corrente estimada e IAE do M-SLPSO para a curva com 646 W/m² a 64 °C (módulo PV Sharp ND-R250A5).

Medida	Dados experimentais		Dados estimados para o SDM		Dados estimados para o DDM	
	V _{medida} [V]	I _{medida} [A]	I _{estimada} [A]	IAE	I _{estimada} [A]	IAE
1	0.0000	5.6900	5.69597643	0.00597643	5.69597643	0.00597643
2	11.1600	5.6800	5.69333617	0.01333617	5.69333617	0.01333617
3	15.5600	5.6700	5.68892985	0.01892985	5.68892985	0.01892985
4	20.0200	5.6600	5.65336201	0.00663799	5.65336201	0.00663799
5	21.5200	5.6200	5.60928418	0.01071582	5.60928419	0.01071581
6	22.5600	5.5700	5.55322939	0.01677061	5.55322939	0.01677061
7	23.1400	5.5200	5.50768570	0.01231430	5.50768571	0.01231429
8	23.7000	5.4600	5.45058638	0.00941362	5.45058638	0.00941362
9	24.2600	5.3800	5.37738821	0.00261179	5.37738822	0.00261178
10	24.8400	5.2800	5.28077401	0.00077401	5.28077402	0.00077402
11	25.0700	5.2400	5.23566560	0.00433440	5.23566560	0.00433440
12	25.2400	5.2000	5.19959247	0.00040753	5.19959248	0.00040752
13	26.0100	5.0000	5.00394483	0.00394483	5.00394483	0.00394483
14	26.6200	4.8000	4.80681844	0.00681844	4.80681845	0.00681845
15	27.1300	4.6000	4.61009909	0.01009909	4.61009909	0.01009909
16	27.5800	4.4000	4.41082267	0.01082267	4.41082267	0.01082267
17	28.3500	4.0000	4.01175241	0.01175241	4.01175241	0.01175241
18	29.0200	3.6000	3.60425562	0.00425562	3.60425561	0.00425561
19	29.6200	3.2000	3.19273874	0.00726126	3.19273873	0.00726127
20	30.1500	2.8000	2.79416060	0.00583940	2.79416059	0.00583941
21	30.6400	2.4000	2.39795792	0.00204208	2.39795792	0.00204208
22	31.1100	2.0000	1.99439601	0.00560399	1.99439601	0.00560399
23	31.5600	1.6000	1.58777522	0.01222478	1.58777522	0.01222478
24	31.9800	1.2000	1.19155967	0.00844033	1.19155967	0.00844033
25	32.3800	0.8000	0.80018599	0.00018599	0.80018599	0.00018599
26	32.7700	0.4000	0.40626131	0.00626131	0.40626132	0.00626132
27	33.1500	0.0000	0.01146109	0.01146109	0.01146110	0.01146110
AE				0.20923581		0.20923581

Tabela A7 - Corrente estimada e IAE do M-SLPSO para a curva com 544 W/m² a 53°C (módulo PV Sharp ND-R250A5).

Medida	Dados experimentais		Dados estimados para o SDM		Dados estimados para o DDM	
	V _{medida} [V]	I _{medida} [A]	I _{estimada} [A]	IAE	I _{estimada} [A]	IAE
1	0.0000	4.7700	4.77043648	0.00043648	4.77043648	0.00043648
2	9.8400	4.7600	4.76841164	0.00841164	4.76841164	0.00841164
3	19.1100	4.7500	4.75838441	0.00838441	4.75838441	0.00838441
4	21.2300	4.7400	4.74069538	0.00069538	4.74069538	0.00069538
5	22.5900	4.7200	4.71353479	0.00646521	4.71353479	0.00646521
6	23.6200	4.6800	4.67584661	0.00415339	4.67584661	0.00415339
7	24.3600	4.6400	4.63378442	0.00621558	4.63378442	0.00621558
8	24.9600	4.5900	4.58648299	0.00351701	4.58648299	0.00351701
9	25.4500	4.5400	4.53643562	0.00356438	4.53643562	0.00356438
10	25.9100	4.4800	4.47792755	0.00207245	4.47792755	0.00207245
11	26.1800	4.4400	4.43752343	0.00247657	4.43752343	0.00247657
12	26.4200	4.4000	4.39738798	0.00261202	4.39738798	0.00261202
13	27.3300	4.2000	4.20315207	0.00315207	4.20315207	0.00315207
14	28.0200	4.0000	4.00342601	0.00342601	4.00342601	0.00342601
15	28.5700	3.8000	3.80653643	0.00653643	3.80653644	0.00653644
16	29.0500	3.6000	3.60499568	0.00499568	3.60499568	0.00499568
17	29.8500	3.2000	3.20434628	0.00434628	3.20434628	0.00434628
18	30.5300	2.8000	2.79913655	0.00086345	2.79913655	0.00086345
19	31.1200	2.4000	2.40035652	0.00035652	2.40035653	0.00035653
20	31.6600	2.0000	1.99861631	0.00138369	1.99861631	0.00138369
21	32.1700	1.6000	1.58876597	0.01123403	1.58876597	0.01123403
22	32.6300	1.2000	1.19534372	0.00465628	1.19534372	0.00465628
23	33.0700	0.8000	0.79934431	0.00065569	0.79934431	0.00065569
24	33.4900	0.4000	0.40459516	0.00459516	0.40459516	0.00459516
25	33.9000	0.0000	0.00453370	0.00453370	0.00453370	0.00453370
AE				0.09973952		0.09973952

Tabela A8 - Corrente estimada e IAE do M-SLPSO para a curva com 437 W/m² a 48°C (módulo PV Sharp ND-R250A5).

Medida	Dados experimentais		Dados estimados para o SDM		Dados estimados para o DDM	
	V _{medida} [V]	I _{medida} [A]	I _{estimada} [A]	IAE	I _{estimada} [A]	IAE
1	0.0000	3.8300	3.82590653	0.00409347	3.82590654	0.00409346
2	12.2300	3.8200	3.82337104	0.00337104	3.82337104	0.00337104
3	14.8100	3.8100	3.82258067	0.01258067	3.82258067	0.01258067
4	21.6600	3.8000	3.80668243	0.00668243	3.80668243	0.00668243
5	23.7800	3.7800	3.77461537	0.00538463	3.77461537	0.00538463
6	24.7800	3.7500	3.74176809	0.00823191	3.74176809	0.00823191
7	25.5700	3.7100	3.70088597	0.00911403	3.70088597	0.00911403
8	26.2200	3.6600	3.65277025	0.00722975	3.65277025	0.00722975
9	26.7600	3.6000	3.59947124	0.00052876	3.59947124	0.00052876
10	27.0100	3.5700	3.56979545	0.00020455	3.56979545	0.00020455
11	27.2300	3.5400	3.54069179	0.00069179	3.54069179	0.00069179
12	27.5600	3.4900	3.49123550	0.00123550	3.49123550	0.00123550
13	28.0500	3.4000	3.40328235	0.00328235	3.40328235	0.00328235
14	28.8900	3.2000	3.20445401	0.00445401	3.20445401	0.00445401
15	29.5300	3.0000	3.00472493	0.00472493	3.00472493	0.00472493
16	30.0600	2.8000	2.80338604	0.00338604	2.80338604	0.00338604
17	30.9200	2.4000	2.40155117	0.00155117	2.40155117	0.00155117
18	31.6300	2.0000	1.99718314	0.00281686	1.99718314	0.00281686
19	32.2400	1.6000	1.59767946	0.00232054	1.59767946	0.00232054
20	32.7900	1.2000	1.19776315	0.00223685	1.19776315	0.00223685
21	33.3000	0.8000	0.79508425	0.00491575	0.79508425	0.00491575

22	33.7700	0.4000	0.39852477	0.00147523	0.39852477	0.00147523
23	34.2100	0.0000	0.00659237	0.00659237	0.00659237	0.00659237
AE				0.09710462		0.09710461

Tabela A9 - Corrente estimada e IAE do M-SLPSO para a curva com 223 W/m² a 29°C (módulo PV Sharp ND-R250A5).

Medida	Dados experimentais		Dados estimados para o SDM		Dados estimados para o DDM	
	V _{medida} [V]	I _{medida} [A]	I _{estimada} [A]	IAE	I _{estimada} [A]	IAE
1	0.0000	1.9400	1.93842742	0.00157258	1.93803257	0.00196743
2	7.5300	1.9300	1.93264469	0.00264469	1.93292775	0.00292775
3	23.1500	1.9200	1.91844931	0.00155069	1.91923419	0.00076581
4	25.6000	1.9100	1.90920878	0.00079122	1.90945003	0.00054997
5	26.7600	1.9000	1.89875596	0.00124404	1.89869003	0.00130997
6	27.8500	1.8800	1.88047132	0.00047132	1.88017471	0.00017471
7	28.5700	1.8600	1.86052621	0.00052621	1.86015646	0.00015646
8	29.2700	1.8300	1.83160936	0.00160936	1.83126006	0.00126006
9	29.6400	1.8100	1.81110162	0.00110162	1.81080458	0.00080458
10	29.9400	1.7900	1.79111483	0.00111483	1.79088067	0.00088067
11	30.4200	1.7500	1.75153269	0.00153269	1.75143133	0.00143133
12	30.9100	1.7000	1.69926531	0.00073469	1.69932386	0.00067614
13	31.2900	1.6500	1.64861328	0.00138672	1.64879442	0.00120558
14	31.6100	1.6000	1.59785851	0.00214149	1.59812786	0.00187214
15	32.0800	1.5100	1.50769904	0.00230096	1.50804844	0.00195156
16	32.5300	1.4000	1.40129767	0.00129767	1.40164361	0.00164361
17	33.2000	1.2000	1.20043261	0.00043261	1.20060642	0.00060642
18	33.7300	1.0000	1.00085310	0.00085310	1.00079013	0.00079013
19	34.1800	0.8000	0.80065633	0.00065633	0.80040289	0.00040289
20	34.5700	0.6000	0.60333083	0.00333083	0.60299969	0.00299969
21	34.9400	0.4000	0.39534169	0.00465831	0.39508608	0.00491392
22	35.2600	0.2000	0.19915290	0.00084710	0.19913590	0.00086410
23	35.5600	0.0000	0.00165626	0.00165626	0.00205204	0.00205204
AE				0.03445533		0.03220699

Anexo B

Artigos desenvolvidos durante a dissertação:

Multiswarm spiral leader particle swarm optimization algorithm for PV parameter identification

H.G.G. Nunes^{a,b}, P.N.C. Silva^{a,b}, J.A.N. Pombo^a, S.J.P.S. Mariano^{a,b}*, M.R.A. Calado^{a,b}

^a Department of Electromechanical Engineering, University of Beira Interior, Covilhã 6201-001, Portugal

^b Instituto de Telecomunicações, Calçada Fonte do Lameiro, Covilhã 6201-001, Portugal

Abstract

The growing interest in photovoltaic (PV) systems, the concern for optimal utilization and the uncertainty associated with its energy production have led to an accelerated research in this field. Precise modelling of PV systems under any operating condition is necessary to obtain accurate and reliable estimates of PV model parameters. In this paper, we propose a new multiswarm spiral leader particle swarm optimization (M-SLPSO) algorithm to solve the PV parameter identification problem. The proposed M-SLPSO used several swarms with different search mechanisms: each swarm is guided by a leader with a different spiral trajectory. In addition, swarms can exchange search mechanisms, according to their performance, and agents can migrate between swarms, enabling a good balance between exploration and exploitation mechanisms. This algorithm maintains a diversity of exploratory trajectories when building new solutions throughout the entire search process, mitigating population stagnation and premature convergence. Furthermore, it explores multidimensional search space in different regions simultaneously and adapts to the specific optimization problem. Performance was evaluated and compared with other state-of-the-art metaheuristics, by applying the M-SLPSO to several benchmark functions and to the PV parameter identification problem, using both single and double-diode models, in two case studies. The first case study used standard literature data, whereas the second used data measured from a real application under different operating conditions. Comparative and statistical results demonstrate that the proposed M-SLPSO presents a very competitive performance, finding highly accurate and reliable solutions.

Keywords

Spiral leader particle swarm optimization; Multiswarm; Benchmark functions; Photovoltaic models; Parameter identification

Artigo submetido numa revista da Elsevier, em fase de revisão.

