

Um novo algoritmo de MPPT de alto desempenho assistido por um *surrogate model* para sistemas fotovoltaicos

Diogo Miguel Rodrigues Duarte

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

Orientador: Prof. Doutor José Álvaro Nunes Pombo

Covilhã, outubro de 2022

Declaração de Integridade

Eu, Diogo Miguel Rodrigues Duarte, que abaixo assino, estudante com o número de inscrição M10973 de Engenharia Eletrotécnica e de Computadores da Faculdade de Engenharia, declaro ter desenvolvido o presente trabalho e elaborado o presente texto em total consonância com o **Código de Integridades da Universidade da Beira Interior**.

Mais concretamente afirmo não ter incorrido em qualquer das variedades de Fraude Académica, e que aqui declaro conhecer, que em particular atendi à exigida referência de frases, extratos, imagens e outras formas de trabalho intelectual, e assumindo assim na íntegra as responsabilidades da autoria.

Universidade da Beira Interior, Covilhã 06 /10 /2022

A handwritten signature in blue ink that reads "Diogo Miguel Rodrigues Duarte". The signature is written in a cursive, flowing style.

Dedicatória

Aos meus pais, Alda e Carlos, pelo carinho, afeto, dedicação e cuidado que me transmitem diariamente.

Agradecimentos

Foi uma jornada longa, desafiante, cheia de altos e baixos que guardarei para sempre na memória. Definitivamente contribuiu para o meu desenvolvimento profissional e sobretudo pessoal.

Se a realização desta dissertação é hoje uma realidade é graças ao prestimoso apoio e conselhos que diversas pessoas me transmitiram. Por este motivo, expresso o meu mais profundo agradecimento a todos aqueles que me ajudaram a alcançar este objetivo de vida.

Aos meus pais, por acreditarem desde o início nas minhas capacidades e incutindo-me princípios fundamentais para a minha vida académica, profissional e pessoal, como a dedicação, persistência, determinação e humildade. Um obrigado nunca será suficiente para agradecer todo o esforço e sacrifício demonstrado. Como forma de agradecimento encerro esta jornada com a conclusão desta dissertação. Se hoje sou a pessoa que sou, a vocês o devo. Por isso Mãe, Pai, um muito Obrigado!

A toda a minha família, em especial ao meu padrinho Eurico que desde sempre me aconselhou, acreditou e apoiou da melhor forma possível, um muito obrigado.

Ao meu orientador, Professor Doutor José Álvaro Nunes Pombo, que sempre demonstrou prontidão em auxiliar-me, por todo o conhecimento e apoio prestado ao longo de todo o meu percurso académico e, em particular, na elaboração da presente dissertação. Graças aos seus incentivos em tornar o meu trabalho mais notável, foi possível experienciar uma aprendizagem mais completa e enriquecedora, sendo de destacar que o rigor e os detalhes bem elaborados fazem toda a diferença. Sem dúvida que foi um dos melhores professores que conheci e sem a sua ajuda, a realização do presente trabalho seria impossível.

Ao Mestre Hugo Gabriel Garcia Nunes pelo incentivo, acompanhamento e auxílio estando sempre dedicado a ajudar-me a ter o melhor trabalho possível, contribuindo sempre com ideias e diversas soluções no sentido de o potencializar.

A oportunidade que me foi dada, pelo Professor Doutor José Álvaro Nunes Pombo e Mestre Hugo Gabriel Garcia Nunes em desenvolver um artigo científico e, mais tarde, apresentá-lo em conferência em Eindhoven, Países Baixos.

À Universidade da Beira Interior, à Faculdade de Engenharia e, em particular, ao laboratório *Power Systems* pela disponibilização do espaço e equipamentos necessários para a realização do presente trabalho.

A todos os docentes que estiveram envolvidos durante o meu percurso académico pelos conhecimentos transmitidos.

À Doutora Sara Alvarinhas, por me escutar, acompanhar e apoiar estando sempre dedicada em ajudar-me, contribuindo sempre com ideias para o meu desenvolvimento pes-

soal.

Por fim, a todos aqueles que, de uma forma ou de outra, contribuíram para que esta dissertação pudesse ser possível.

A todos eles, o meu sincero obrigado!

Resumo

Atualmente, o mundo enfrenta um processo de transição energética, de uma matriz focada em combustíveis fósseis para uma matriz baseada em fontes renováveis, o qual se impôs face à necessidade de proteger o planeta da emissão de gases com efeito de estufa, em parte, responsáveis pelo aquecimento global. Na verdade, a queima de demasiados combustíveis fósseis, o abate de demasiadas árvores e a emissão de demasiados gases com efeito de estufa está a aumentar a temperatura do planeta, o que é uma ameaça para a sua sustentabilidade. Embora as sociedades tenham assistido a outras transições energéticas, no passado, nunca o planeta esteve tanto em risco. A atual transição energética, para além de ter impacto no clima terá forte influência na economia e na forma como a sociedade está organizada. Como prova disso, temos a atual guerra desencadeada pela Rússia na Ucrânia que ao congestionar o fornecimento de gás natural à Europa mostrou a necessidade, urgente, de reduzir a dependência energética entre os diferentes países. Portanto, para além de permitirem reduzir a pegada de carbono, é aqui que as fontes renováveis como a energia solar fotovoltaica têm vindo a ter uma contribuição significativa, nos últimos anos, e que necessariamente tem de continuar a crescer para se alcançar uma sociedade com zero ou baixas emissões de carbono.

Em resposta a esta necessidade energética a capacidade fotovoltaica instalada mundialmente tem mostrado um crescimento significativo, o qual por sua vez leva à necessidade de sistemas fotovoltaicos eficientes e confiáveis. Deste modo, insere-se aqui o tema da presente dissertação, a qual tem como objetivo propor um novo algoritmo de procura do ponto de máxima potência em sistemas fotovoltaicos. Para extrair a máxima potência disponível num sistema fotovoltaico o novo algoritmo de procura do ponto de máxima potência proposto combina as potencialidades do *Particle Swarm Optimization* Estocástico e do *Particle Swarm Optimization* Determinístico. Além disso, o algoritmo proposto utiliza uma *Radial Basis Function Neural Network* para construir um modelo aproximado das curvas características corrente-tensão e potência-tensão. Para isso, numa primeira fase, o *Particle Swarm Optimization* Estocástico obriga as partículas a percorrer o espaço de procura de forma aleatória, fornecendo a informação proveniente da sua execução à *Radial Basis Function Neural Network*. Posteriormente, são criados modelos aproximados das curvas características corrente-tensão e potência-tensão, permitindo identificar as regiões do espaço de procura promissoras. Uma vez identificadas e definidas essas regiões, as partículas são reposicionadas, e é acionado o *Particle Swarm Optimization* Determinístico para evitar um comportamento das partículas divergente e repetitivo. Após a convergência do *Particle Swarm Optimization* Determinístico é realizado um processo de refinamento das curvas características corrente-tensão e potência-tensão.

Para testar e validar o algoritmo proposto foram usados quatro casos de estudo em ambiente de simulação e dois casos de estudo em ambiente experimental. O desempenho do algoritmo proposto foi comparado com o método convencional de procura do ponto

de máxima potência Perturba e Observa, bem como, com diferentes métodos de procura do ponto de máxima potência meta-heurísticos, nomeadamente o *Differential Evolution*, o *Grey Wolf Optimizer* e o *Particle Swarm Optimization* clássico. Os resultados mostraram que o algoritmo proposto superou os métodos considerados ao encontrar o ponto de máxima potência global em termos de taxa de sucesso, tempo de procura e eficiência, além disso, apresentou menor número de oscilações respondendo com robustez às rápidas transições de irradiância perante condições de sombreamento parcial complexas.

Palavras-chave

Sistema Fotovoltaico, Procura do Ponto de Máxima Potência, Inteligência Artificial, *Particle Swarm Optimization*, *Radial Basis Function Neural Network*

Abstract

Currently, the world is facing an energy transition process, from a matrix focused on fossil fuels to a matrix based on renewable sources, which has imposed itself in the face of the need to protect the planet from the emission of greenhouse gases, partly responsible by global warming. In fact, burning too many fossil fuels, cutting too many trees and emitting too many greenhouse gases is increasing the temperature of the planet, which is a threat to its sustainability. While societies have seen other energy transitions in the past, the planet has never been more at risk. The current energy transition, in addition to having an impact on the climate, will have a strong influence on the economy and the way society is organized. As proof of this, we have the current war unleashed by Russia in Ukraine which, by congesting the supply of natural gas to Europe, showed the urgent need to reduce energy dependence between different countries. Therefore, in addition to reducing the carbon footprint, it is here that renewable sources such as photovoltaic solar energy have been making a significant contribution in recent years, and which necessarily must continue to grow to achieve a society with zero or low carbon emissions.

In response to this energy need, the photovoltaic capacity installed worldwide has shown significant growth, which in turn leads to the need for efficient and reliable photovoltaic systems. Thus, the theme of the present dissertation is inserted here, which aims to propose a new algorithm to search for the maximum power point in photovoltaic systems. To extract the maximum available power in a photovoltaic system, the new proposed maximum power point search algorithm combines the potential of Stochastic Particle Swarm Optimization and Deterministic Particle Swarm Optimization. Furthermore, the proposed algorithm uses a Radial Basis Function Neural Network to build an approximate model of the current-voltage and power-voltage characteristic curves. For that, in a first phase, the Stochastic Particle Swarm Optimization forces the particles to traverse the search space in a random way, supplying the information from its execution to the Radial Basis Function Neural Network. Subsequently, approximate models of the current-voltage and power-voltage characteristic curves are created, allowing the identification of promising regions of the search space. Subsequently, approximate models of the current-voltage and power-voltage characteristic curves are created, allowing the identification of promising regions of the search space. Once these regions are identified and defined, the particles are repositioned, and the Deterministic Particle Swarm Optimization is activated to avoid a divergent and repetitive behavior of the particles. After the convergence of the Deterministic Particle Swarm Optimization, a refinement process of the current-voltage and power-voltage characteristic curves is carried out.

To test and validate the proposed algorithm, four case studies were used in a simulation environment and two case studies in an experimental environment. The performance of the proposed algorithm was compared with the conventional maximum power point tracking method (Perturb and Observe) as well as with different meta-heuristic ma-

ximum power point tracking methods, namely Differential Evolution, Gray Wolf Optimizer and Classic Particle Swarm Optimization. The results showed that the proposed algorithm outperformed the considered methods in finding the global maximum power point in terms of success rate, search time and efficiency, in addition, it presented a lower number of oscillations responding with robustness to fast irradiance transitions under complex partial shading conditions.

Keywords

Photovoltaic System, Maximum Power Point Tracking, Artificial Intelligence, Particle Swarm Optimization, Radial Basis Function Neural Network

Índice

1	Introdução	1
1.1	Enquadramento	1
1.2	Organização da dissertação	5
2	Modelação Fotovoltaica	7
2.1	Modelo de um díodo	7
2.2	Modelo de dois díodos	8
2.3	Influência da irradiância e da temperatura	10
2.4	Modelação sob condições de sombreamento parcial	11
3	Técnicas de Inteligência Artificial e Algoritmo Proposto	15
3.1	<i>Particle Swarm Optimization</i>	15
3.2	<i>Particle Swarm Optimization</i> Determinístico	16
3.3	<i>Surrogate Model</i>	20
3.3.1	<i>Radial Basis Function Neural Network Approximation</i>	21
3.4	Algoritmo Proposto	24
4	Resultados de Simulação e Discussão	27
4.1	Caso de Estudo 1: Sem sombreamento parcial	28
4.2	Caso de Estudo 2: Variação da irradiância sem sombreamento parcial . . .	30
4.3	Caso de Estudo 3: Com sombreamento parcial	35
4.4	Caso de Estudo 4: Variação da irradiância com sombreamento parcial . . .	36
5	Resultados Experimentais e Discussão	43
5.1	Caso de Estudo 1: Variação da irradiância com sombreamento parcial . . .	44
5.2	Caso de Estudo 2: Funcionamento em perfil <i>full day</i>	45
6	Conclusão	47
	Referências Bibliográficas	49
	Anexo A - Artigo Científico	57

Lista de Figuras

2.1	Circuito elétrico equivalente do modelo de um díodo (SDM).	8
2.2	Circuito elétrico equivalente do modelo de dois díodos (DDM).	9
2.3	Curvas caraterísticas corrente-tensão (I-V) e potência-tensão (P-V): (a) In- fluência da irradiância; (b) Influência da temperatura.	10
2.4	Circuito elétrico equivalente sob PSC com o SDM e o DDM.	12
2.5	Curvas caraterísticas sob sombreamento parcial: (a) Curvas caraterísticas I-V; (b) Curvas caraterísticas P-V.	14
3.1	Domínios comportamentais no plano (ω, c)	19
3.2	Exemplos de comportamento dinâmico de uma partícula para diferentes parâmetros (ω, c)	20
3.3	Estrutura de uma RBFNN com uma variável de entrada, h unidades ocultas e uma variável de saída.	22
3.4	Fluxograma do algoritmo PSO-M em controladores MPPT de sistemas PV.	25
4.1	Diagrama de blocos de um sistema PV típico com controlo MPPT.	27
4.2	Resultados de simulação dos controladores de MPPT considerados, usando o P&O como referência, no primeiro caso de estudo: (a) Curvas de conver- gência de cada controlador de MPPT; (b) Curva PV estudada, histórico das partículas e modelos do PSO-M.	29
4.3	Resultados de simulação dos controladores de MPPT considerados, usando o P&O como referência, no segundo caso de estudo: (a) Curvas de conver- gência de cada controlador de MPPT nos três cenários; (b), (c) e (d) Curvas PV estudadas, histórico das partículas e modelos do PSO-M nos três cená- rios, respetivamente.	32
4.4	Resultados de simulação dos controladores de MPPT considerados, usando o P&O como referência, no terceiro caso de estudo: (a) Curvas de conver- gência de cada controlador de MPPT; (b) Curva PV estudada, histórico das partículas e modelos do PSO-M	36
4.5	Resultados de simulação dos controladores de MPPT considerados, usando o P&O como referência, no quarto caso de estudo: (a) Curvas de convergên- cia de cada controlador de MPPT nos três cenários; (b), (c) e (d) Curvas PV estudadas, histórico das partículas e modelos do PSO-M nos três cenários, respetivamente.	39
5.1	<i>Setup</i> experimental.	43
5.2	Resultados experimentais do PSO-M no primeiro caso de estudo: (a) Curva de convergência do PSO-M nos três cenários; (b), (c) e (d) Histórico das partículas e modelos do PSO-M nos três cenários, respetivamente.	44

5.3	Resultados experimentais do PSO-M no segundo caso de estudo: (a) Curva de potência no primeiro dia; (b) Perfis de irradiância e temperatura no primeiro dia.	45
5.4	Resultados experimentais do PSO-M no segundo caso de estudo: (a) Curva de potência no segundo dia; (b) Perfis de irradiância e temperatura no segundo dia.	46

Lista de Tabelas

4.1	Especificações do módulo PV SHARP ND-R250A5.	28
4.2	Parâmetros de controlo dos algoritmos de MPPT considerados.	28
4.3	Comparação de resultados do primeiro caso de estudo entre os diferentes algoritmos de MPPT considerados, com 50 execuções independentes . . .	31
4.4	Comparação de resultados do segundo caso de estudo entre os diferentes algoritmos de MPPT considerados, com 50 execuções independentes . . .	34
4.5	Comparação de resultados do terceiro caso de estudo entre os diferentes algoritmos de MPPT considerados, com 50 execuções independentes . . .	37
4.6	Comparação de resultados do quarto caso de estudo entre os diferentes algoritmos de MPPT considerados, com 50 execuções independentes	41

Lista de Acrónimos

ABC	<i>Artificial Bee Colony</i>
AC	Corrente Alternada
ACO	<i>Ant Colony Optimization</i>
ADC	Conversor Analógico Digital
BO	<i>Butterfly Optimization</i>
CI	Condutância Incremental
CS	<i>Cuckoo Search</i>
CV	Tensão Constante
DC	Corrente Contínua
DDM	Modelo de Dois Díodos
DE	<i>Differential Evolution</i>
FFO	<i>Farmland Fertility Optimization</i>
GHO	<i>Grasshopper Optimization</i>
GMPP	Ponto de Potência Máxima global
GWO	<i>Grey Wolf Optimizer</i>
HHO	<i>Harris Hawk Optimization</i>
I-V	Corrente-Tensão
LF	Lógica <i>Fuzzy</i>
LMPP	Pontos Locais de Máxima Potência
LWF	Função W de Lambert
ML	<i>Machine Learning</i>
MPP	Ponto de Máxima Potência
MPPT	Procura do Ponto de Máxima Potência
NRM	Método de Newton-Raphson
P&O	Perturba e Observa
PRSM	<i>Polynomial Response Surface Model</i>
PSC	Condições de Sombreamento Parcial
PSO	<i>Particle Swarm Optimization</i>
PSOC	<i>Particle Swarm Optimization</i> Clássico
PSO-M	<i>Particle Swarm Optimization</i> Modificado
PV	Fotovoltaica
P-V	Potência-Tensão
RBF	<i>Radial Basis Functions</i>
RBFNN	<i>Radial Basis Function Neural Network</i>
RNA	Redes Neurais Artificiais
SDM	Modelo de Um Díodo
SSO	<i>Salp Swarm Optimization</i>
SVR	<i>Support Vector Regression</i>

Lista de Símbolos

A	Matriz dinâmica
B	Matriz de entrada
$b_{1,h}$	Bias associada o h -ésimo neurónio da camada escondida
$b_{2,1}$	Bias associada ao neurónio de saída
c	Média dos coeficientes de aceleração
$c_{1,h}$	Vetor de coordenadas do centro do h -ésimo neurónio da camada
c_1	Coefficiente de aceleração cognitiva
c_2	Coefficiente de aceleração social
CR	Fator de cruzamento
d	Dimensão do problema
D, D_1, D_2	Díodos
D_{by}	Díodo <i>bypass</i>
E_f	Eficiência do MPPT [%]
F	Fator de mutação
G, G_1, G_2	Irradiâncias [W/m^2]
$gbest_d$	Melhor posição alcançada por todas as partículas da d -ésima dimensão
h	Índice do neurónio da camada escondida
i	Índice da partícula
I	Corrente de saída [A]
I_0, I_{01}, I_{02}	Correntes inversas de saturação dos díodos [μA]
I_d, I_{d1}, I_{d2}	Correntes dos díodos [A]
I_{mpp}	Corrente no ponto de máxima potência [A]
I_p	Corrente na resistência R_p [A]
I_{ph}	Corrente fotoelétrica [A]
I_{pv}	Corrente de saída de cada grupo de células PV [A]
I_{sc}	Corrente de curto circuito [A]
k	Número da iteração atual
k_B	Constante de Boltzman [J/K]
k_{max}	Número máximo de iterações permitidas
l_b	Límite inferior
m	Número de díodos de <i>bypass</i>
n, n_1, n_2	Fatores de idealidade dos díodos
n_p	Número de partículas da população
N_s	Número de células ligadas em série
p	Média ponderada do $pbest$ e do $gbest$
P_{disp}	Potência disponível
P_{extr}	Potência extraída

P_{mpp}	Potência no ponto de máxima potência [W]
$pbest_{i,d}$	Melhor posição individual alcançada pela partícula i da d -ésima dimensão
q	Carga do eletrão [C]
r_1, r_2	Números aleatórios com uma distribuição uniforme entre [0, 1]
R_{by}	Resistência que modela o diodo de <i>bypass</i> [Ω]
R_p	Resistência ligada em paralelo [Ω]
R_s	Resistência ligada em série [Ω]
t	Período de tempo [s]
T	Temperatura da junção [K]
u	Número de diodos do modelo PV
u_b	Limite superior
$v_{i,d}$	Velocidade da i -ésima partícula da d -ésima dimensão
V	Tensão de saída [V]
$V_{i,d}$	Partícula proveniente da mutação do algoritmo DE
V_i	Vetor de velocidade
V_{mpp}	Tensão no ponto de máxima potência [V]
V_{oc}	Tensão de circuito aberto [V]
V_{passo}	Tensão de perturbação [V]
$V_{p,i}$	Tensão da i -ésima partícula [V]
V_{pv}	Tensão de saída de cada grupo de células PV [V]
$W_{2,h}$	Peso sináptico entre o h -ésimo neurónio da camada escondida
$x_{i,d}$	Posição da i -ésima partícula da d -ésima dimensão
x_L	Vetor de entrada de uma <i>radial basis function neural network</i> com dimensão L
X_i	Vetor de posição
y	Estado atual da partícula
y_L	Vetor de saída de uma <i>radial basis function neural network</i> com dimensão L
α_i	Coefficiente de temperatura de corrente de curto circuito [%/°C]
α_p	Coefficiente de temperatura de potência máxima [%/°C]
α_v	Coefficiente de temperatura de tensão de circuito aberto [%/°C]
$\beta_1, \beta_2, \beta_3$	Índices mutuamente distintos
η	Eficiência do módulo PV
λ_1, λ_2	Autovalores
$\phi_{1,h}$	<i>Radial basis function</i> utilizada no h -ésimo neurónio da camada escondida
ω	Fator de inércia

Capítulo 1

Introdução

1.1 Enquadramento

Desde a industrialização, o rápido crescimento das atividades económicas juntamente com o aumento populacional fez com que a demanda por energia elétrica crescesse exponencialmente [1]. A maior parte dessa energia elétrica é, ainda hoje, produzida através de combustíveis fósseis, como por exemplo, carvão mineral, gás natural e petróleo (e seus derivados) [2]. Grandes quantidades de gases de efeito de estufa, como dióxido de carbono, óxido nítrico, metano, entre outros, são emitidos para a atmosfera durante a combustão desses combustíveis fósseis. A emissão de grandes quantidades destes gases são um dos principais fatores para o aquecimento global e para as alterações climáticas. O aquecimento global e as alterações climáticas têm inúmeros efeitos nocivos na saúde, na sustentabilidade e na preservação do meio ambiente [3]. Em consequência, governos de todo o mundo começaram a rever as suas estratégias e políticas energéticas, realizando vários protocolos e acordos como, o Protocolo de Quioto, o acordo Climático de Paris e o acordo Verde Europeu [4, 5].

Nas últimas décadas, a produção de energia elétrica através de fontes renováveis ganhou uma posição de destaque na política europeia decorrente da necessidade de combater as alterações climáticas e de reduzir a dependência energética face ao exterior. A transição para uma sociedade pós-carbono é um problema extremamente complexo devido à forma como a energia elétrica interfere na atividade humana, desde a privacidade do quotidiano doméstico às práticas partilhadas na atividade laboral, passando por aspectos tão centrais à vida contemporânea como a mobilidade, a segurança ou a comunicação. As fontes de energias renováveis mais conhecidas são, a energia solar que provém do sol, a energia eólica que provém do vento, a biomassa que provém de matéria orgânica, a energia hídrica explorada através de rios e correntes de água doce, a energia geotérmica explorada através do calor da Terra e ainda a energia oceânica que provém dos mares e oceanos [6].

No entanto, a energia solar tem vindo a afirmar-se nos últimos anos como uma verdadeira alternativa para a produção de energia elétrica. Como ela é proveniente do sol, a mesma é abundante, renovável a cada dia, não polui o ambiente e é gratuita. Estima-se que a energia solar fornecida pelo sol durante uma hora equivale à energia necessária pela população humana durante um ano [7]. Nos últimos anos, a produção fotovoltaica (PV) apresentou a maior margem de crescimento a nível mundial, estando previsto que se torne na principal fonte renovável de energia elétrica.

Embora a produção PV seja incentivada em todo o mundo, a mesma apresenta algumas desvantagens, tais como: o custo da instalação, a sua baixa eficiência de conversão de energia (cerca de 9 a 17%) e, além disso, apresenta um comportamento elétrico não-linear entre a tensão e a corrente dependente das condições climáticas (principalmente dos níveis de irradiância e de temperatura) [8]. Para contornar o comportamento não-linear da curva característica I-V e maximizar a produção PV em todo o instante de tempo é necessário garantir que o sistema PV opere num ponto de funcionamento ao qual corresponde a máxima potência disponível (MPP). Assim, para determinar esse ponto de funcionamento e retirar o máximo de potência disponível, independentemente das condições de operação do sistema PV, é fundamental o uso de algoritmos de procura do ponto de máxima potência (MPPT) [7]. Um algoritmo de MPPT deve apresentar uma estrutura de controlo simples, flexível, confiável e extremamente eficiente. Além disso, a nível de hardware deve ser simples, de baixo custo, robusto e usar o menor número possíveis de sensores [9].

Existem diversos algoritmos de MPPT que se podem encontrar na literatura especializada, que diferem em termos de complexidade, velocidade de convergência, sensores requeridos, custo, eficiência, implementação, popularidade, entre outros aspetos. Nesta forma, cada algoritmo de MPPT tem as suas próprias especificações, limitações e aplicações, no entanto, podem, de grosso modo, ser classificados em algoritmos convencionais, algoritmos avançados e algoritmos híbridos [10].

Os algoritmos de MPPT convencionais também podem ser classificados em função da técnica de procura implementada, existindo: a técnica de procura com parâmetros constantes, a técnica de procura com medição e comparação, a técnica de procura com tentativa e erro e, por último, a técnica de procura com cálculo matemático [11]. Os algoritmos de MPPT baseados na técnica de procura com parâmetros constantes, assumem a linearidade da tensão ou da corrente e utilizam valor fixos pré-determinados para determinar o MPP. Os mais simples e populares são os algoritmos de tensão de circuito aberto e corrente de curto-circuito que realizam a leitura da tensão de circuito aberto (V_{oc}) e da corrente de curto-circuito (I_{sc}) do sistema PV e os multiplicam por uma constante K obtendo, assim, a tensão ou a corrente no MPP, respetivamente [12]. No entanto, estes algoritmos requerem a interrupção momentânea do sistema PV para realizar as medições/leituras e assumem a linearidade da tensão ou da corrente em relação ao MPP. Uma solução para contornar esses problemas, consiste na introdução de uma célula piloto para realizar as medições/leituras ao sistema PV. Assim as leituras ocorrem apenas na célula piloto, que é eletricamente independente do sistema PV, e os ajustes são aplicados diretamente ao sistema PV [13]. Existem outros algoritmos que se inserem neste grupo, onde se destacam: o algoritmo de gradiente de temperatura [14], o algoritmo paramétrico de temperatura [15], o algoritmo de procura através da queda de tensão na junção PN [16].

Os algoritmos de MPPT baseados na técnica de procura com medição e comparação têm por base a medição de parâmetros intrínsecos e extrínsecos ao sistema PV, como por

exemplo, tensão, corrente, irradiância ou temperatura. Uma vez realizadas as medições/-leituras, esses valores são analisados e comparados com uma base de dados (tabelas), permitindo localizar o MPP. Neste grupo destaca-se o algoritmo MPPT *Look-up Table* que compara valores pré-armazenados, em várias condições de operação, com os valores reais/medidos [17]. Estas tabelas podem ser construídas com base nas especificações do fabricante, modelos matemáticos dos respectivos módulos PV ou através de testes experimentais sob diferentes condições de operação. O algoritmo de MPPT com base em *Look-up Table* é sensível à qualidade e a quantidade de dados, i.e., o seu desempenho depende da obtenção de um conjunto de dados extensivos em várias condições de operação. Outros algoritmos pertencentes a este grupo são, por exemplo, o algoritmo de controlo de corrente linear [18], o algoritmo de maximização da corrente de carga ou da tensão de carga [19].

Os algoritmos de MPPT baseados em técnicas de procura com tentativa e erro realizam tentativas de cálculo ou perturbações no sistema PV para alcançar o MPP. Neste grupo insere-se o algoritmo Perturba e Observa (P&O). Trata-se de um algoritmo amplamente utilizado por apresentar uma estrutura de controlo extremamente simples e um baixo custo computacional [20]. Resumidamente, este algoritmo perturba a tensão ou a corrente do sistema PV e observa a potência resultante dessa perturbação. Caso se verifique um aumento de potência, o P&O continua a perturbar no mesmo sentido, caso contrário, muda a direção da perturbação [21]. Diversas variantes do P&O foram propostas ao longo dos anos, com o objetivo de aumentar a sua eficiência, diminuindo as oscilações em torno do MPP, amplitude de perturbação e tempo de convergência [22–24]. Um outro algoritmo pertencente a este grupo é o *DC Link Droop Control* que foi desenvolvido para situações onde o sistema PV é colocado em paralelo com um conversor DC-AC [25].

Os algoritmos de MPPT baseados na técnica de procura com cálculo matemático determinam a localização do MPP através de cálculos matemáticos dos dados disponíveis (com base em equações matemáticas). O algoritmo mais conhecido que usa esta técnica é o Condutância Incremental (CI), também ele bastante difundido na literatura e na indústria [26, 27]. Este algoritmo baseia-se no facto da derivada da potência em relação à tensão ser nula. Teoricamente, a derivada da potência em relação à tensão é nula no MPP, negativa à direita e positiva à esquerda do MPP. Existem outros algoritmos que se inserem neste grupo como por exemplo, o algoritmo Beta [28–30], o controlo de correlação ondulada [31, 32], o controlo de *feedback* dP/dV ou dP/dI [25], o *Current Sweep* [11].

No entanto, muitos dos algoritmos de MPPT convencionais apresentam algumas desvantagens que limitam o seu desempenho e eficiência, como por exemplo: a sua dependência em relação à amplitude de perturbação, dificuldade em lidar com problemas não-lineares e também dificuldade na exploração do espaço de procura, elevado tempo de convergência e oscilações estacionárias em torno do MPP. Além disso, um sistema PV está sujeito a vários fatores climáticos, ambientais e/ou externos que podem facilmente

criar condições não uniformes de funcionamento, i.e., condições de sombreamento parcial (PSC). Em condições de sombreamento parcial, as curvas características I-V e P-V podem sofrer alterações devido à polarização direta díodos de *bypass*, i.e., a polarização direta dos díodos de *bypass* pode provocar múltiplos patamares ou *steps* na curva característica I-V e múltiplos picos na curva característica P-V. Nestas condições de operação/funcionamento, a curva característica P-V mostra um comportamento extremamente complexo com o surgimento de pontos locais de máxima potência (LMPP), embora apenas um seja o máximo global (tipicamente designado por GMPP). Em consequência, os algoritmos de MPPT convencionais são incapazes de distinguir os LMPP do GMPP, i.e., algoritmos de MPPT convencionais podem convergir para pontos locais de máxima potência (LMPP), diminuindo a sua eficiência e confiabilidade [33].

Para mitigar as desvantagens dos métodos convencionais surgiram na literatura especializada algoritmos de MPPT avançados, baseados em inteligência computacional e em algoritmos de otimização meta-heurísticos. Estes algoritmos avançados devido à sua robustez, flexibilidade, confiabilidade e capacidade de lidar com problemas não-lineares são altamente eficientes para procurar e localizar o GMPP, sob condições de sombreamento parcial complexas [10]. Os algoritmos avançados mais aplicados são os algoritmos de MPPT baseados em redes neuronais artificiais (RNA) [34–36], os algoritmos de MPPT baseados em Lógica *Fuzzy* (LF) [37–39] e os algoritmos de MPPT baseados em algoritmos de otimização. Estes últimos, geralmente consistem na minimização ou na maximização de uma determinada função objetivo. Encontrar e alcançar o MPP, em sistemas PV, é, portanto, um problema de maximização. No entanto, para condições uniformes de operação representa um problema de otimização unimodal, enquanto para condições de sombreamento parcial representa um problema de otimização multimodal. Nas últimas três décadas, os MPPT avançados baseados em algoritmos meta-heurísticos mostraram inúmeras vantagens quando comparados com os algoritmos convencionais de MPPT, nomeadamente: rápida convergência; não apresentam oscilações estacionárias em torno do MPP; elevada capacidade de lidar com problemas multimodais e não-lineares e ampla exploração do espaço de procura evitando, assim, a convergência prematura em ótimos locais (LMPP). Dos vários algoritmos meta-heurísticos aplicados na procura do ponto de máxima potência em sistemas PV, destacam-se: o algoritmo *Salp Swarm Optimization* (SSO) [40], o algoritmo *Butterfly Optimization* (BO) [41], o algoritmo *Grasshopper Optimization* (GHO) [42], o algoritmo *Farmland Fertility Optimization* (FFO) [43], o algoritmo *Harris Hawk Optimization* (HHO) [44], o algoritmo *Cuckoo Search* (CS) [45], o algoritmo *Grey Wolf Optimizer* (GWO) [46, 47], o algoritmo *Ant Colony Optimization* (ACO) [48], o algoritmo *Bat* [49], o algoritmo *Particle Swarm Optimization* (PSO) [50], o algoritmo *Differential Evolution* (DE) [51, 52], o algoritmo *Artificial Bee Colony* (ABC) [53], entre outros.

Já os algoritmos de MPPT híbridos geralmente combinam duas técnicas diferentes, podendo ser ambas convencionais, ambas avançadas ou uma combinação de técnicas convencionais e avançadas. Por exemplo, em [54] o algoritmo de MPPT convencional

P&O é modificado para integrar o algoritmo meta-heurístico *Artificial Bee Colony* (ABC). Em [55] foi implementado um algoritmo de MPPT híbrido, sendo uma hibridização entre algoritmos meta-heurísticos *Differential Evolution* (DE) e *Particle Swarm Optimization* (PSO). Em [56] foi desenvolvido um novo algoritmo de MPPT híbrido com a integração dos algoritmos meta-heurísticos *Salp Swarm Optimization* (SSO) e *Differential Evolution* (DE) com o algoritmo de MPPT convencional P&O. Em suma, existem inúmeras hibridizações na literatura especializada que visam melhorar a eficiência e o desempenho dos algoritmos de MPPT. No entanto, apesar dos MPPT avançados e híbridos demonstrarem um elevado desempenho, a seleção apropriada de determinados fatores como: os parâmetros de controle, o tamanho da população, o número de iterações e o equilíbrio/harmonia entre mecanismos de intensificação e diversificação inerentes, são essenciais para assegurar uma boa eficiência e confiabilidade na procura do GMMP. Assim, apesar de existir uma grande variedade de algoritmos de MPPT o desenvolvimento de novas linhas de investigação que visem promover a eficiência, confiabilidade, robustez e desempenho continua a justificar-se.

1.2 Organização da dissertação

A presente dissertação está organizada em seis capítulos. O Capítulo 1 realiza o enquadramento do tema em estudo e apresenta os principais objetivos.

No Capítulo 2 é feita uma revisão bibliográfica dos modelos matemáticos mais utilizados na literatura especializada para descrever o comportamento de uma célula ou de um módulo PV. Além disso, é apresentada a formulação matemática para modelar o comportamento de uma célula ou de um módulo PV sob condições de sombreamento parcial. Também é realizada uma breve análise sobre a influência da irradiância, temperatura e dos díodos bypass nas curvas características corrente-tensão (I-V) e potência-tensão (P-V).

No Capítulo 3 é apresentado o algoritmo meta-heurístico populacional *Particle Swarm Optimization* de caráter estocástico e determinístico. Tendo em conta a teoria de sistemas dinâmicos lineares no tempo discreto, o PSO determinístico é equacionado na forma de equações de estado com o objetivo de analisar e compreender as diversas trajetórias das partículas para alcançar a convergência. São também apresentados os conceitos inerentes aos *Surrogate Models* com maior destaque para a técnica de *Machine learning* (ML). Em particular, são apresentadas as noções fundamentais sobre as *Radial Basis Function Neural Networks*. No final do Capítulo 3 são descritas as várias etapas e processos que compõem o algoritmo de MPPT proposto, designado PSO-M.

No Capítulo 4 é realizada a validação do algoritmo proposto em quatro casos de estudo, implementados em ambiente de simulação. No primeiro caso de estudo, o sistema PV foi submetido a condições uniformes de operação (sem sombreamento parcial). No segundo caso de estudo, foi criado uma sequência de três cenários com pequenas variações de irradiância, mas sem sombreamento parcial. No terceiro caso de estudo, o sistema PV

foi submetido a condições não uniformes de operação (com sombreamento parcial). O quarto caso de estudo considerou uma sequência de três cenários com grandes variações de irradiância, devido a sombreamento parcial. O desempenho do algoritmo proposto (PSO-M) foi comparado com diferentes algoritmos de MPPT meta-heurísticos e retiradas as respectivas conclusões.

No Capítulo 5 é realizada a validação do algoritmo proposto em dois casos de estudo implementados em ambiente real. O primeiro caso de estudo considerou uma sequência de três cenários com grandes variações de irradiância, devido a sombreamento parcial. No segundo caso de estudo, é analisado o desempenho do PSO-M numa situação de operação real, ao longo de um dia (24 horas), considerado diferentes índices de claridade.

Por último, no Capítulo 6 são enunciadas as principais conclusões do trabalho realizado.

Capítulo 2

Modelação Fotovoltaica

Simular com precisão e eficiência o comportamento de uma célula ou módulo PV requer a utilização de um modelo matemático adequado. Na literatura especializada existem vários modelos matemáticos que permitem simular o comportamento dos dispositivos PV sob diferentes condições de operação. A simulação deste comportamento é conseguida através de um circuito elétrico equivalente que pode combinar diferentes componentes elétricos, tais como: fonte de corrente, díodos e resistências [57]. Nesta secção, são apresentados os modelos mais usados na literatura, nomeadamente o modelo de um díodo (SDM) e o modelo de dois díodos (DDM). Além disso, a sua formulação sob condições de sombreamento parcial (PSC) também é apresentada. O SDM distingue-se por garantir um bom compromisso entre simplicidade e precisão, enquanto que a utilização do DDM pode levar a ganhos significativos em termos de precisão em baixos níveis de irradiância e, particularmente, para determinadas tecnologias PV [58].

2.1 Modelo de um díodo

A Figura 2.1 mostra o circuito elétrico equivalente do SDM, constituído por uma fonte de corrente que simula a corrente fotoelétrica, (I_{ph}), gerada pelo efeito PV e altamente dependente da irradiância e temperatura. Em paralelo com a fonte de corrente, o modelo inclui um díodo, que permite representar os efeitos físicos da junção PN. Para representar as perdas devido à resistência de contato entre as superfícies de silício e os elétrodos, a resistência do fluxo de corrente no material de silício e a resistência dos elétrodos é incluída uma resistência, (R_s), em série com a fonte de corrente [57]. Enquanto que, a sensibilidade à temperatura é melhorada incluindo uma resistência, (R_p), em paralelo com a fonte de corrente e o díodo. Esta resistência tem ainda em consideração as correntes de fuga na junção PN, cujo a magnitude varia com as características construtivas/fabricação [57].

De acordo com a lei de Kirchhoff, a corrente de saída I , no circuito da Figura 2.1 é expressa pela equação 2.1.

$$I = I_{ph} - I_d - I_p \quad (2.1)$$

onde I_p é a corrente na resistência R_p e I_d a corrente do díodo, calculada através da equação Shockley dada por:

$$I_d = I_0 \left[\exp \left(\frac{q(V + R_s \times I)}{n \times N_s \times k_B \times T} \right) - 1 \right] \quad (2.2)$$

onde I_0 é a corrente inversa de saturação do díodo, V é a tensão de saída, n é o fator de idealidade do díodo, N_s é o número de células ligadas em série, k_B é a constante de Boltzman, q é a carga do eletrão e T é a temperatura da junção em Kelvin.




Figura 2.1: Circuito elétrico equivalente do modelo de um díodo (SDM).

De acordo com a lei de Ohm, a corrente I_p que circula na resistência R_p é dada pela equação 2.3.

$$I_p = \frac{V + R_s \times I}{R_p} \quad (2.3)$$

Combinando as equações 2.1, 2.2 e 2.3, obtemos a equação 2.4 que descreve a corrente de saída, I , do circuito elétrico equivalente do SDM. Esta é uma equação implícita em I , caracterizada por cinco parâmetros desconhecidos (I_{ph} , I_0 , n , R_s e R_p), não sendo possível determinar diretamente a sua solução. Para superar essa limitação, comumente, é usada a função W de Lambert (LWF) ou o método de Newton-Raphson (NRM).

$$I = I_{ph} - I_0 \left[\exp \left(\frac{q(V + R_s \times I)}{n \times N_s \times k_B \times T} \right) - 1 \right] - \frac{V + R_s \times I}{R_p} \quad (2.4)$$

De um modo geral, este modelo permite simular precisamente as características corrente-tensão (I-V) dos dispositivos PV. No entanto, a sua precisão tende a diminuir sob baixos níveis de irradiância, especialmente nas proximidades de V_{oc} [57]. Contudo, devido ao bom compromisso entre simplicidade e precisão o SDM é indiscutivelmente o modelo matemático mais utilizado na literatura especializada para simular e descrever o comportamento das células e módulos PV.

2.2 Modelo de dois díodos

O modelo de dois díodos (DDM), apresentado na Figura 2.2, é bastante similar ao SDM com a particularidade de ter dois díodos ligados em paralelo com a fonte de corrente. Este modelo descreve os fenômenos físicos na junção PN com maior precisão, particular-

mente, em baixos níveis de irradiância e para diferentes tecnologias [59]. O díodo D_1 representa a corrente de difusão na junção PN, ou seja, simula o processo de difusão dos portadores minoritários na camada de depleção, enquanto o díodo D_2 considera os efeitos de recombinação, i.e., representa a recombinação dos portadores de carga na região espaço-carga [58].




Figura 2.2: Circuito elétrico equivalente do modelo de dois díodos (DDM).

Aplicando as leis de Kirchhoff ao circuito da Figura 2.2, a corrente de saída I , é dada pela equação 2.5.

$$I = I_{ph} - I_{d1} - I_{d2} - I_p \quad (2.5)$$

onde I_{d1} e I_{d2} representam as correntes dos díodos D_1 e D_2 , respetivamente. As quais são respetivamente descritas, de acordo com a equação de Shockley, pelas equações 2.6 e 2.7.

$$I_{d1} = I_{01} \left[\exp \left(\frac{q(V + R_s \times I)}{n_1 \times N_s \times k_B \times T} \right) - 1 \right] \quad (2.6)$$

$$I_{d2} = I_{02} \left[\exp \left(\frac{q(V + R_s \times I)}{n_2 \times N_s \times k_B \times T} \right) - 1 \right] \quad (2.7)$$

onde I_{01} e I_{02} representam as correntes inversas de saturação dos díodos D_1 e D_2 , respetivamente. Sendo que, n_1 e n_2 correspondem aos fatores de idealidade dos díodos D_1 e D_2 , respetivamente.

Combinando as equações 2.3, 2.5, 2.6 e 2.7, a corrente de saída, I , do circuito elétrico equivalente do DDM é dada pela equação 2.8. Sendo esta, também uma equação implícita em I , caracterizada por sete parâmetros desconhecidos (I_{ph} , I_{01} , I_{02} , n_1 , n_2 , R_s e R_p).

$$I = I_{ph} - I_{01} \left[\exp \left(\frac{q(V + R_s \times I)}{n_1 \times N_s \times k_B \times T} \right) - 1 \right] - I_{02} \left[\exp \left(\frac{q(V + R_s \times I)}{n_2 \times N_s \times k_B \times T} \right) - 1 \right] - \frac{V + R_s \times I}{R_p} \quad (2.8)$$

Embora o DDM possa ser mais preciso que o SDM, especialmente, em baixos níveis de irradiância e com algumas tecnologias PV, é mais complexo devido ao aumento do seu número de parâmetros desconhecidos, requerendo um maior esforço computacional [58].

2.3 Influência da irradiância e da temperatura

Com o propósito de analisar a influência da irradiância e temperatura nas curvas características corrente-tensão (I-V) e potência-tensão (P-V) são modeladas na Figura 2.3 várias curvas características de uma célula PV em diferentes níveis de irradiância e temperatura. Na Figura 2.3a) são apresentadas quatro curvas características I-V a azul e quatro curvas características P-V a vermelho com diferentes níveis de irradiância (250 W/m^2 , 500 W/m^2 , 750 W/m^2 e 1000 W/m^2) a uma temperatura constante de $25 \text{ }^\circ\text{C}$. Observa-se que, a potência PV é fortemente afetada com a variação da irradiância incidente, pois a corrente é diretamente proporcional à variação da irradiância. Já a tensão no ponto de máxima potência (MPP), V_{mpp} , mantém-se fixa em torno do mesmo valor. Portanto, o grande deslocamento vertical do MPP com a variação da irradiância deve-se essencialmente à variação da corrente. Na Figura 2.3b) são igualmente apresentadas quatro curvas características I-V a azul e quatro curvas características P-V a vermelho, mas com diferentes níveis de temperatura ($20 \text{ }^\circ\text{C}$, $40 \text{ }^\circ\text{C}$, $60 \text{ }^\circ\text{C}$ e $80 \text{ }^\circ\text{C}$) a uma irradiância constante de 1000 W/m^2 . A potência PV é igualmente afetada pela variação da temperatura, uma vez que a tensão diminui com o aumento da temperatura. Nestas condições a V_{mpp} varia com a variação da temperatura originando, assim, um deslocamento para a esquerda do MPP, i.e., à medida que a temperatura aumenta a tensão diminui. Além disso, a corrente aumenta ligeiramente com a temperatura. Contudo, a influência da temperatura na potência PV é menos significativa que a influência da irradiância.

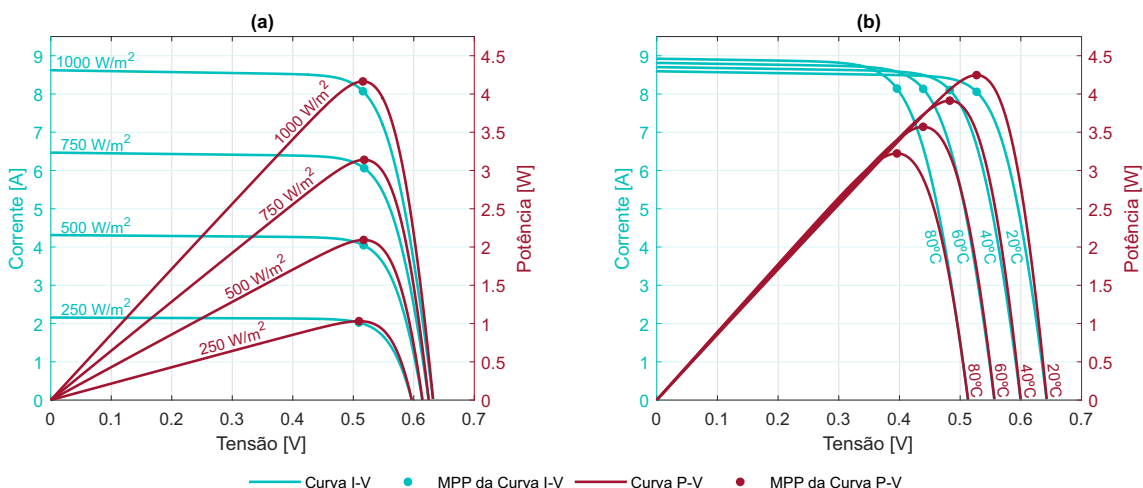


Figura 2.3: Curvas características corrente-tensão (I-V) e potência-tensão (P-V): (a) Influência da irradiância; (b) Influência da temperatura.

Deste modo, infere-se que o MPP está em constante movimento devido às condições de operação em ambiente real, as quais mudam a cada instante, tornando indispensável

o uso de algoritmos de seguimento do ponto de máxima potência (MPPT) para seguir o MPP global, a cada instante, de forma a extrair a potência máxima do sistema PV.

2.4 Modelação sob condições de sombreamento parcial

A operação ótima dos sistemas PV, visando a extração da máxima potência disponível, requiere uma modelação dinâmica que permita descrever precisamente o comportamento destes sistemas sob condições de operação reais. Tipicamente, uma célula PV apresenta uma tensão nominal de 0.6 V, enquanto a corrente gerada pode ser de vários amperes dependendo do nível de irradiância (por exemplo, até 9 A para a célula considerada na Figura 2.3). Portanto, para satisfazer uma carga com determinada potência várias células, ou ainda, módulos PV são ligados em série de forma a perfazer a potência desejada e, assim, alimentar a respetiva carga [60]. No entanto, as condições climatéricas não são constantes e causam variações significativas nos níveis de irradiância e temperatura, afetando negativamente a produção PV. Desta forma, as células que compõem um módulo PV são frequentemente expostas a diferentes níveis de irradiância, quer seja pela variabilidade da irradiância devido às condições climatéricas ou pela sua obstrução devido a fatores externos. Este fenómeno designa-se condição de sombreamento parcial (PSC) e pode reduzir significativamente a produção PV, uma vez que a potência do sistema PV reduz consideravelmente em tais circunstâncias [61]. Algumas causas do sombreamento parcial são nuvens, poeiras na atmosfera, neve, edifícios, árvores, dejetos de pássaros, acumulação de sujidade, entre outros [61]. As células PV sujeitas a PSC geram menos corrente comparativamente às células PV não sombreadas. Como as células PV são ligadas em série de forma a conceber um módulo PV, a corrente de saída do módulo é limitada pela corrente de saída da célula com menor irradiância incidente [62]. Concretamente, as células PV sombreadas comportam-se como uma carga e absorvem a energia produzida pelas restantes células, dissipando-a sob a forma de calor [63]. De facto, as células PV sombreadas podem atingir temperaturas elevadas, formando os denominados *hot-spots*, o que pode levar à sua danificação [64]. Portanto, o sombreamento parcial, além de reduzir significativamente a potência disponível, pode comprometer o bom funcionamento do sistema PV devido à ocorrência de pontos quentes [58]. Na verdade, a inversão de polaridade é a principal causa dos pontos quentes (operação em polaridade inversa), que surgem devido a divergências de potencial nas correntes geradas pelas várias células ligadas em série. Em resultado dessas divergências na corrente, surgem as designadas perdas por *mismatch* [58].

Para minimizar este problema são usados díodos de *bypass*, os quais desviam a corrente de um grupo de células PV que entre em polaridade inversa, minimizando assim os efeitos negativos do sombreamento parcial. Os díodos de *bypass* são ligados em antiparalelo, sendo que as células do módulo PV são agrupadas em m grupos de acordo com o número de díodos de *bypass* do respetivo módulo PV. Desta forma, um ou mais grupos de células PV podem ser colocados fora de funcionamento, enquanto as células pertencentes

a outro(s) grupo(s) continuam a funcionar [58]. O número de díodos de *bypass* é uma característica construtiva do módulo PV e está relacionado com o número total de células do módulo. Atualmente, a solução com três díodos de *bypass* é a mais comum. A Figura 2.4 mostra o circuito elétrico equivalente para modelar um módulo PV com m díodos de *bypass* sob PSC considerando o SDM e o DDM, respetivamente.

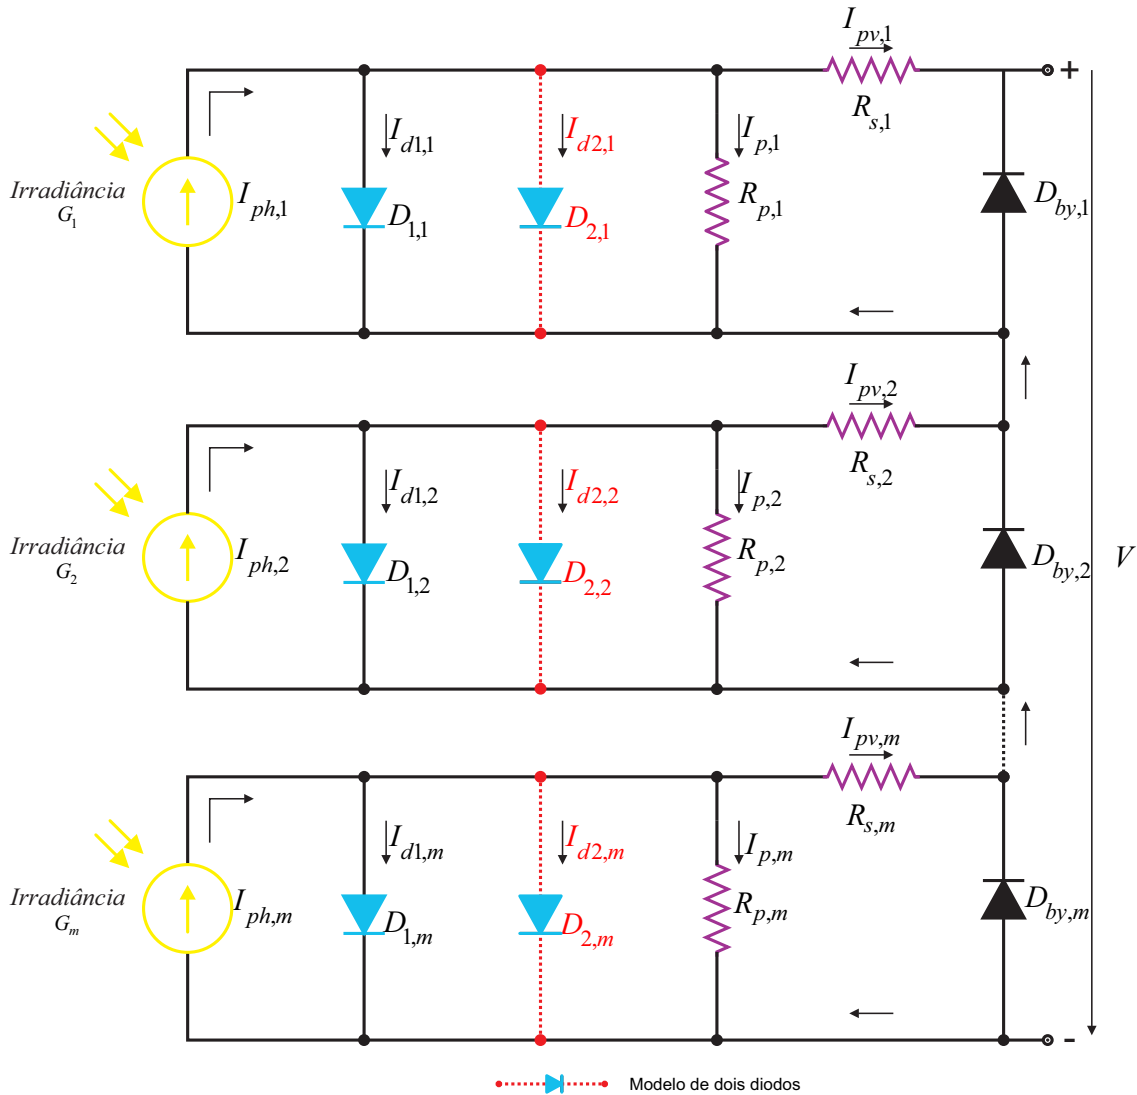


Figura 2.4: Circuito elétrico equivalente sob PSC com o SDM e o DDM.

Os díodos de *bypass* podem ser modelados matematicamente como uma resistência (R_{by}) em relação a (I_{ph}). Assim, um diodo de *bypass* é representado como uma alta resistência ($10^{10} \Omega$) quando inversamente polarizado e uma baixa resistência ($10^{-2} \Omega$) quando diretamente polarizado, conforme a equação 2.9 [58].

$$R_{by}(I_{ph}) = \begin{cases} 10^{-2}, & D_{by} = On \\ 10^{10}, & D_{by} = Off \end{cases} \quad (2.9)$$

Portanto, quando ocorre sombreamento parcial, a corrente e a tensão de saída podem

ser obtidas resolvendo as equações 2.10 e 2.11, respetivamente [58].

$$I = \begin{cases} \left[I_{ph,1}(G_1) - \sum_{i=1}^u \left[I_{0i,1} \left[\exp \left(\frac{q(V_{pv,1} + R_{s,1} \times I_{pv,1})}{n_{i,1} \times N_s \times k_B \times T} \right) - 1 \right] \right] - \frac{V_{pv,1} + R_{s,1} \times I_{pv,1}}{R_{p,1}} \right] & I > I_{ph,2} \\ \left[I_{ph,2}(G_2) - \sum_{i=1}^u \left[I_{0i,2} \left[\exp \left(\frac{q(V_{pv,2} + R_{s,2} \times I_{pv,2})}{n_{i,2} \times N_s \times k_B \times T} \right) - 1 \right] \right] - \frac{V_{pv,2} + R_{s,2} \times I_{pv,2}}{R_{p,2}} \right] & I_{ph,2} \geq I \geq I_{ph,m} \\ \left[I_{ph,m}(G_m) - \sum_{i=1}^u \left[I_{0i,m} \left[\exp \left(\frac{q(V_{pv,m} + R_{s,m} \times I_{pv,m})}{n_{i,m} \times N_s \times k_B \times T} \right) - 1 \right] \right] - \frac{V_{pv,m} + R_{s,m} \times I_{pv,m}}{R_{p,m}} \right] & I < I_{ph,m} \end{cases} \quad (2.10)$$

$$V = \begin{cases} V_{pv,1} & I > I_{ph,2} \\ V_{pv,2} + V_{pv,1} & I_{ph,2} \geq I \geq I_{ph,m} \\ V_{pv,m} + V_{pv,2} + V_{pv,1} & I < I_{ph,m} \end{cases} \quad (2.11)$$

onde G é a irradiância com $G_1 > G_2 > G_m$. I_{pv} e V_{pv} são a corrente e a tensão de saída de cada grupo de células PV, respetivamente. u representa o número de díodos no circuito elétrico equivalente do modelo PV, sendo que $u = 1$ corresponde ao SDM e $u = 2$ corresponde ao DDM [58].

Com o propósito de mostrar o efeito e influência da utilização de díodos de *bypass* nas curvas características I-V e P-V são modeladas, na Figura 2.5, curvas características de um módulo PV com 60 células ligadas em série e equipado com três díodos *bypass*. Assim, cada diódo de *bypass* está conectado em antiparalelo incluindo 20 células PV, o que forma um total 3 grupos de células. A Figura 2.5 apresenta três curvas características I-V e P-V, respetivamente. Considerando a Figura 2.5a) ou 2.5b) observa-se, em roxo, uma curva sem sombreamento parcial com uma irradiância de 1000 W/m² e temperatura de 25 °C. Em verde uma curva sob sombreamento parcial com um diódo de *bypass* ativado. Nesta curva, dois grupos de células recebem uma irradiância de 1000 W/m² a 25 °C, enquanto o terceiro grupo recebe uma irradiância de 500 W/m² a 25 °C. Já em azul uma curva sob sombreamento parcial com dois díodos de *bypass* ativados. Nesta última curva, dois grupos de células encontram-se sob sombreamento parcial. O primeiro grupo recebe uma irradiância de 1000 W/m² a 25 °C. o segundo grupo recebe uma irradiância de 600 W/m² a 25 °C e o terceiro grupo recebe uma irradiância de 200 W/m² a 25 °C. Quando os três díodos de *bypass* estão ativados, i.e., os três grupos de células estão suficientemente sombreados parcialmente, não existe geração PV do respetivo módulo, encontrando-se totalmente fora de funcionamento. Observa-se, na Figura 2.5b), que sob um perfil de irradiância uniforme (curva roxa) o sistema PV é operado apenas com um pico de potência,

o qual, não havendo perturbações externas, varia linearmente conforme o perfil de irradiação ao longo do dia. Esse pico de potência corresponde ao MPP e é seguido através do uso de algoritmos de MPPT. Quando ocorre sombreamento parcial, múltiplos picos de potência surgem na curva característica P V em resultado da ativação dos diodos de *bypass* do módulo PV. Deste modo, em tais circunstâncias, o sistema PV é operado no ponto de potência máxima global (GMPP), mas a presença de pontos de potência máxima locais (LMPPs) acarreta uma dificuldade acrescida, o que leva à necessidade de algoritmos MPPT extremamente eficientes, sendo este ainda um problema com o qual os investigadores lidam diariamente. Além disso, podemos constatar, na Figura 2.5b), que a operação de sistemas PV sob PSC reduz drasticamente a potência de saída, sendo de extrema importância mitigar ao máximo a ocorrência de tais circunstâncias, quer logo desde a fase de projeto como durante a operação e manutenção dos sistemas PV.

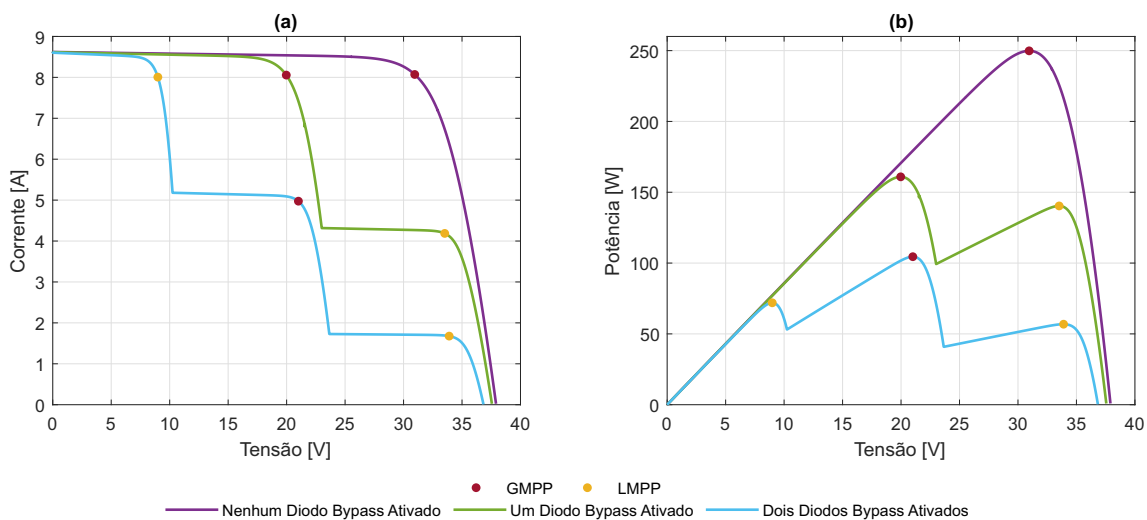


Figura 2.5: Curvas caraterísticas sob sombreamento parcial: (a) Curvas caraterísticas I-V; (b) Curvas caraterísticas P-V.

Capítulo 3

Técnicas de Inteligência Artificial e Algoritmo Proposto

A inteligência artificial é atualmente uma área de investigação abrangente, e em constante expansão, podendo ser aplicada nas mais diversas áreas de investigação com o propósito de contribuir para a resolução de problemas do mundo real. Resumidamente, consiste na capacidade de uma máquina reproduzir competências semelhantes às humanas como é o caso do raciocínio. Deste modo, devido à sua capacidade de aprendizagem e raciocínio, em semelhança ao comportamento humano, tem sido aplicada em inúmeras áreas de trabalho/investigação como a engenharia, economia, medicina, entre outras. Concretamente, o seu propósito é dotar máquinas com a capacidade de modelar, caracterizar, dimensionar, otimizar, prever e controlar a execução de determinadas tarefas ou processos de diferente complexidade. Para a resolução de problemas complexos, e não-lineares, podemos destacar de entre as diferentes técnicas de inteligência artificial a utilização de lógica *fuzzy*, redes neuronais artificiais e algoritmos meta-heurísticos. Particularmente, algumas das aplicações dessas técnicas no campo da energia PV são a previsão da radiação solar, a modelação dos sistemas PV considerando a estimação dos parâmetros associados em diferentes condições de operação, o controlo e gestão ótima da energia produzida através de controladores de MPPT, entre outras. Contudo, extrair a potência máxima produzida, em cada instante de tempo num sistema PV, requer a utilização de controladores de MPPT extremamente eficientes. Assim, e com o propósito de cumprir o objetivo desta dissertação é proposto no final do presente capítulo um algoritmo que utiliza técnicas de inteligência artificial, designado PSO-M, para procura do GMPP em sistemas PV.

3.1 Particle Swarm Optimization

O *Particle Swarm Optimization* (PSO), proposto por [65] em 1995, é um algoritmo de otimização meta-heurístico inspirado no comportamento exploratório de determinadas espécies animais (bando de pássaros ou cardume de peixes) na procura de recursos alimentares [66]. Sendo o mesmo inspirado nos princípios de cooperação, o PSO envolve uma população de partículas, que representam possíveis soluções, capazes de comunicar e cooperar entre si com o objetivo de explorar o espaço de procura multidimensional na procura de uma solução ótima. Num problema de otimização, com um espaço de procura multidimensional d , a partícula i possui um vetor de posição $X_i = [x_{i,1}, x_{i,2}, \dots, x_{i,d}]$ e um vetor de velocidade $V_i = [v_{i,1}, v_{i,2}, \dots, v_{i,d}]$ [67]. O movimento das partículas ocorre por ação da velocidade que considera as experiências cognitivas e sociais das partículas (histórico), i.e., a experiência da própria partícula (fator cognitivo) e a experiência das ou-

tras partículas que integram a população (fator social) [58], [59], [68]. As partículas são posicionadas inicialmente de forma aleatória dentro do espaço de procura multidimensional e avaliadas a cada iteração através de uma função objetivo. Durante o processo de otimização, o vetor de velocidade e de posição são atualizados, a cada iteração, de acordo com as equações 3.1 e 3.2, respectivamente [69]. A velocidade depende de três termos: o primeiro representa a tendência do movimento da partícula ponderada pelo fator de inércia (ω); o segundo move a partícula para a melhor posição já alcançada por ela mesma ($pbest$) e o terceiro move a partícula de acordo com a melhor posição alcançada por todas as partículas da população ($gbest$) [70].

$$v_{i,d}^{k+1} = \underbrace{\omega \cdot v_{i,d}^k}_{\text{Primeiro Termo}} + \underbrace{c_1 \cdot r_1 \cdot (pbest_{i,d}^k - x_{i,d}^k)}_{\text{Segundo Termo}} + \underbrace{c_2 \cdot r_2 \cdot (gbest_d^k - x_{i,d}^k)}_{\text{Terceiro Termo}} \quad (3.1)$$

$$x_{i,d}^{k+1} = x_{i,d}^k + v_{i,d}^{k+1} \quad (3.2)$$

onde $v_{i,d}^k$ representa a velocidade da d -ésima dimensão da i -ésima partícula na k -ésima iteração; $x_{i,d}^k$ é a posição da d -ésima dimensão da i -ésima partícula na k -ésima iteração; (ω) representa o fator de inércia; c_1 e c_2 são os coeficientes de aceleração utilizados para ajustar as contribuições cognitivas e sociais, respectivamente; r_1 e r_2 são dois números aleatórios com uma distribuição uniforme entre [0, 1] que estabelecem uma característica estocástica ao PSO e; $gbest$ e $pbest$ são as melhores posições globais e pessoais, respectivamente.

Durante o processo de otimização, as dinâmicas destes três termos estabelecem a harmonia entre os mecanismos de diversificação e intensificação. O mecanismo de diversificação consiste na tentativa de construir novas soluções em regiões afastadas da melhor solução encontrada até o momento (procura global). Já o mecanismo de intensificação consiste na construção de novas soluções, em regiões promissoras, com o objetivo de determinar com precisão a melhor solução.

O segundo e o terceiro termo apresentam um comportamento elitista ao favorecer o mecanismo intensificação, i.e., uma procura local. O mecanismo de diversificação depende apenas do primeiro termo que, com o decorrer das iterações, perde influência diminuindo o desempenho deste mecanismo [58].

3.2 Particle Swarm Optimization Determinístico

O PSO tem sido vastamente utilizado para resolver uma ampla gama de problemas de otimização, em diversas áreas da engenharia, devido à sua simplicidade, flexibilidade, confiabilidade e de necessitar de número reduzido de parâmetros de controle. Além disso, é um algoritmo de otimização meta-heurístico extremamente eficiente computacionalmente, requerendo apenas um conjunto reduzido de operações básicas ou simples. Po-

rém, o PSO, na sua formulação canônica (original), apresenta algumas limitações no seu processo e nas suas propriedades de convergência, i.e., a estagnação da população que, conseqüentemente, provoca a convergência prematura. Nas últimas décadas, com o objetivo de mitigar essas limitações foram propostas diversas variantes diferindo em termos de complexidade, custo computacional, precisão e popularidade [71–73]. Geralmente, essas variantes visam alcançar uma maior diversificação populacional e um maior equilíbrio entre os mecanismos de diversificação e de intensificação, através da hibridização, da parametrização ótima dos parâmetros de controlo, de novas estratégias de aprendizagem e de novas topologias de comunicação entre partículas.

No entanto, o comportamento ou a trajetória de cada partícula, em cada dimensão, é descrita de forma quadrática e apresenta uma grande variedade de comportamentos para alcançar a convergência. Assim, para garantir uma maior eficiência computacional é fundamental perceber como as partículas exploram o espaço de procura multidimensional para evitar um comportamento divergente (garantir a estabilidade) e repetitivo (construção de novas soluções já avaliadas anteriormente). Para tal, alguns autores, como por exemplo em [74], optam por uma análise do comportamento do PSO sem elementos estocásticos (PSO Determinístico), substituindo a característica estocástica r_1 e r_2 pelo ponto médio de uma distribuição uniforme entre $[0, 1]$, i.e., $r_1 = r_2 = \frac{1}{2}$.

A equação 3.1 pode ser simplificada usando as equações 3.3 e 3.4,

$$c = \frac{c_1 + c_2}{2} \quad (3.3)$$

$$p = \frac{c_1}{c_1 + c_2} pbest_{i,d}^k + \frac{c_2}{c_1 + c_2} gbest_d^k \quad (3.4)$$

Assim sendo, o PSO Determinístico pode ser expresso pelas equações 3.5 e 3.6,

$$v_{i,d}^{k+1} = \omega \cdot v_{i,d}^k + c \cdot (p + x_{i,d}^k) \quad (3.5)$$

$$x_{i,d}^{k+1} = x_{i,d}^k + v_{i,d}^{k+1} \quad (3.6)$$

onde c é a média dos coeficientes de aceleração e p a média ponderada do $pbest$ e $gbest$. Tendo em conta a teoria de sistemas dinâmicos lineares no tempo discreto, as equações 3.5 e 3.6 podem ser escritas na forma de equações de estado.

$$\underbrace{\begin{bmatrix} x_{i,d}^{k+1} \\ v_{i,d}^{k+1} \end{bmatrix}}_{y_{k+1}} = \underbrace{\begin{bmatrix} 1 - c & \omega \\ -c & \omega \end{bmatrix}}_A \underbrace{\begin{bmatrix} x_{i,d}^k \\ v_{i,d}^k \end{bmatrix}}_{y_k} + \underbrace{\begin{bmatrix} c \\ c \end{bmatrix}}_B p \quad (3.7)$$

onde y_k é o estado atual da partícula formado pela posição x_k e velocidade v_k , A é a matriz dinâmica cujas propriedades determinam o comportamento da partícula, p é a entrada

externa usada para conduzir a partícula em direção a uma posição específica (posição final de convergência) e B a matriz de entrada.

A localização dos pólos no plano complexo permite-nos obter informações relativamente à estabilidade e sobre o comportamento da partícula para alcançar a convergência. Assim, para obter os pólos deste sistema é necessário calcular os autovalores da matriz A . Os autovalores λ_1 e λ_2 são as soluções da seguinte equação:

$$\lambda^2 - (\omega - c + 1)\lambda + \omega = 0 \quad (3.8)$$

Para evitar um comportamento divergente, i.e., garantindo a estabilidade, todos os pólos devem estar dentro do círculo unitário. Analisando as raízes da equação 3.8 obtém-se as seguintes condições:

$$\omega < 1 \wedge c > 0 \wedge 2\omega - c + 2 > 0 \quad (3.9)$$

Para qualquer posição e velocidade inicial, a partícula convergirá para a sua posição final se e somente se os parâmetros de controlo (ω , c_1 e c_2) forem selecionados tendo em conta as condições descritas pela equação 3.8, cuja área de convergência no plano (ω , c) é ilustrada na Figura 3.1(a). No entanto, a partícula pode apresentar comportamentos diferentes até atingir a convergência. Um desses comportamentos pode ser oscilatório harmónico em torno da posição final. Este comportamento da partícula ocorre quando os pólos do sistema são caracterizados pela seguinte condição (pólos complexos conjugados), cujo domínio correspondente no plano (ω , c) é mostrado na Figura 3.1(b),

$$\omega^2 + c^2 - 2\omega c - 2\omega - 2c + 1 < 0 \quad (3.10)$$

Caso a condição descrita pela equação 3.11 seja satisfeita, a partícula vai apresentar um comportamento em “zig-zague” em torno da posição final de convergência. Este comportamento acontece quando pelo menos um dos pólos da matriz A (real ou complexo) possui parte real negativa, cujo domínio no plano (ω , c) é mostrado na Figura 3.1.

$$\omega < 0 \vee \omega - c + 1 < 0 \quad (3.11)$$

É também possível obter um comportamento híbrido, i.e., uma combinação de comportamentos em zig-zague e oscilatório harmónico. Assim, a posição dos pólos da matriz A , cujas áreas se encontram ilustradas na Figura 3.1(d), estabelecem às partículas diferentes comportamentos dinâmicos em torno da posição final de convergência principalmente, em termos de *overshoot* e de tempo de convergência (número de iterações necessárias para alcançar a convergência).

Para visualizar os possíveis comportamentos da partícula até atingir a posição final de convergência p , foram realizadas diversas simulações com a localização dos pólos nas di-

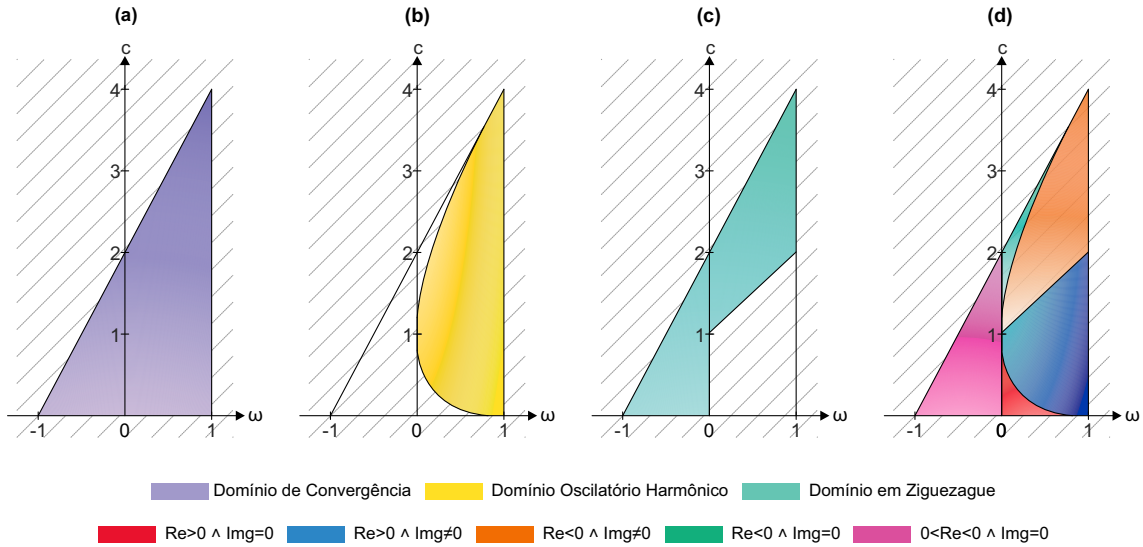


Figura 3.1: Domínios comportamentais no plano (ω, c) .

ferentes áreas da Figura 3.2(a), considerando: $x_0 = -2$, $v_0 = 0.1$, $p = 1$, $k = 50$ iterações.

O comportamento ou trajetória da partícula com oscilações harmônicas é ilustrado na Figura 3.2(b). A localização dos pólos próximos do centro do triângulo de estabilidade, induzem à partícula um comportamento com menor *overshoot* e, conseqüentemente, um menor tempo de convergência, como podemos verificar na Figura 3.2(b) a azul-claro. A convergência é atingida rapidamente, com pouca oscilação, beneficiando o mecanismo de intensificação. Já a localização dos pólos próximos dos limites do triângulo de estabilidade, i.e., pólos complexos com parte real positiva, impõem à partícula um maior *overshoot* e um maior tempo de convergência, como podemos verificar na Figura 3.2(b) a azul-escuro. Nesta situação, a trajetória da partícula apresenta uma maior oscilação e um maior tempo de convergência.

Na Figura 3.2(c) podemos observar um comportamento híbrido (pólos complexos com parte real negativa), i.e., uma combinação de oscilações harmônicas com ziguezague. Nesta situação, o mecanismo de diversificação tem uma maior ênfase relativamente ao mecanismo de intensificação, impondo à partícula uma trajetória com um elevado tempo de convergência e oscilação. Um exemplo de convergência não oscilatória (pólos reais positivos) é ilustrada na Figura 3.2(d). Este comportamento da partícula não garante a diversificação na construção de novas soluções, não sendo recomendado em problemas de otimização. No entanto, em casos especiais, esta pode ser uma opção recomendada ou útil.

A convergência simétrica em ziguezague (pólos reais negativos) é mostrada na Figura 3.2(e). Os parâmetros ω e c podem ser ajustados de forma a tornar a convergência mais lenta ou mais rápida. Já o comportamento em ziguezague assimétrico (pólos reais com sinais opostos) é ilustrado na Figura 3.2(f).

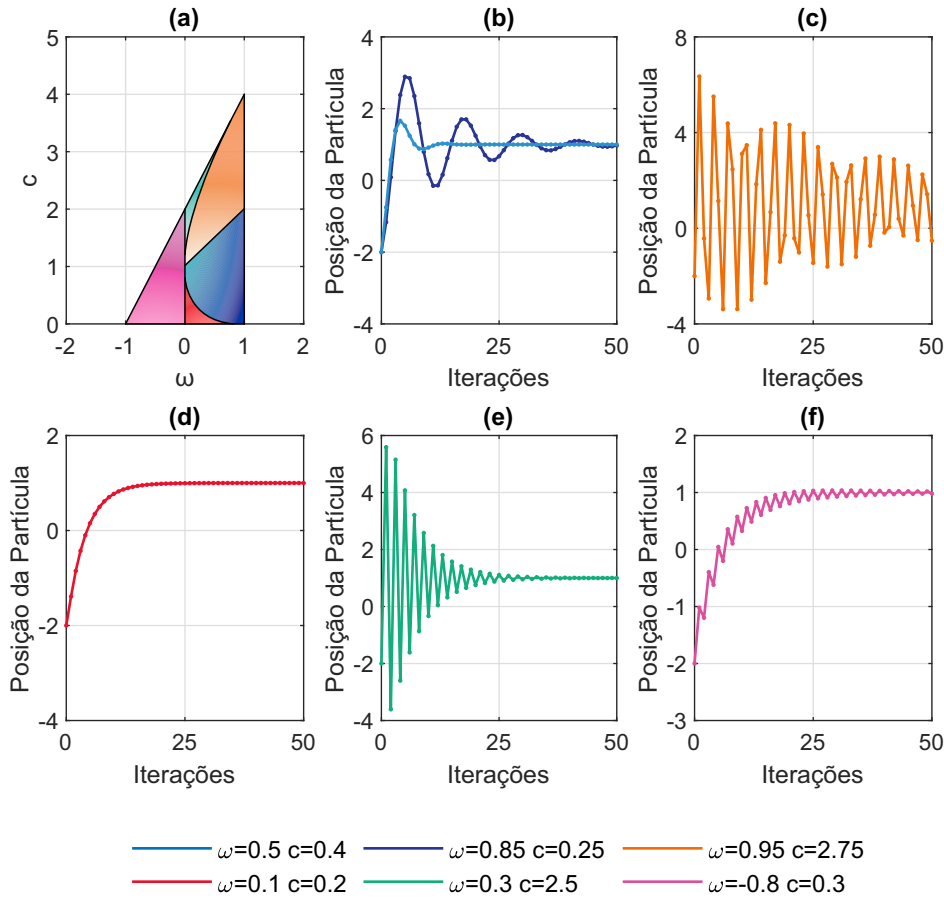


Figura 3.2: Exemplos de comportamento dinâmico de uma partícula para diferentes parâmetros (ω , c).

3.3 Surrogate Model

Com o surgimento e o desenvolvimento de poderosas ferramentas de computação, modelos matemáticos complexos tornaram-se parte integrante da engenharia. A discretização desses modelos matemáticos muitas das vezes leva a problemas de otimização complexos, de elevada dimensão, multimodais e com um elevado custo computacional. Assim, dependendo das especificidades envolvidas no problema de otimização, a obtenção de soluções de elevada qualidade é uma tarefa que envolve alguns constrangimentos, complexa e não trivial. Nas últimas décadas, manifestou-se uma forte aposta na utilização de algoritmos meta-heurísticos para ultrapassar esses constrangimentos e, assim, alcançar soluções de elevada qualidade e confiabilidade. No entanto, e dependendo sempre do mecanismo inerente a cada algoritmo meta-heurístico, o custo computacional deste tipo de algoritmo pode ser menos promissor. Além disso, podem convergir prematuramente para soluções ótimas locais, requerem recursos de computação elevados devido ao mecanismo de procura estocástico e a sua eficiência depende fortemente do ajuste adequado dos parâmetros de controlo e do balanço entre os mecanismos de diversificação e de intensificação. Assim, com o objetivo aumentar a eficiência dos algoritmos meta-heurísticos e de mitigar as limitações inerentes foram propostas diversas soluções diferindo em ter-

mos de complexidade, custo computacional e popularidade. Na literatura especializada, uma das soluções mais promissoras e com uma ampla aceitação consiste na utilização de *Surrogate Model* [75].

Um *Surrogate Model* é uma aproximação fiável e de baixo custo computacional do modelo matemático real, i.e., da função objetivo real, construída através de uma base de dados adquirida. Portanto, os *Surrogate Models*, através de uma base de dados adquirida (tipicamente o histórico da função objetivo real), permitem a construção de modelos aproximados da função objetivo real, extrapolando as relações entre entradas e saídas do problema de otimização [76]. A hibridização/fusão dos algoritmos meta-heurísticos com os *Surrogate Models* surgiu com o objetivo de diminuir o custo computacional envolvido na avaliação da função objetivo real e, ao mesmo tempo, identificar e/ou conduzir os algoritmos meta-heurísticos para regiões promissoras, i.e., regiões onde se pode encontrar soluções de elevada qualidade, evitando a convergência prematura. Outra aplicação comum dos *Surrogate Models* consiste na obtenção uma função contínua de um conjunto de dados reduzido [77]. Devido à sua ampla aplicabilidade, os *Surrogate Models* têm sido um tópico de pesquisa ativa por décadas. Várias são as técnicas que têm sido relatadas na literatura, como por exemplo: *Polynomial Response Surface Model* (PRSM) [78], *Kriging* [79], *Radial Basis Functions* (RBF) [80], redes neuronais artificiais e *Support Vector Regression* (SVR) [81].

3.3.1 Radial Basis Function Neural Network Approximation

As *Radial Basis Function Neural Networks* (RBFNNs) são amplamente utilizadas em vários campos da engenharia, como por exemplo, na aproximação de funções, na classificação de padrões, na previsão de séries temporais e em controlo de processos [82]. Quando comparada com outras arquiteturas de redes neuronais, do tipo *feed-forward*, a arquitetura da RBFNN oferece algumas vantagens devido a sua elevada capacidade na aproximação de funções em problemas não-lineares, rapidez e eficiência no seu processo de treino, possibilitando a obtenção de resultados com precisão. Além disso, também são caracterizadas pela propriedade de aproximação universal, robustez e boa capacidade de generalização [83].

Conforme ilustrado na Figura 3.3, a arquitetura de uma RBFNN pode ser interpretada como uma rede neuronal do tipo *feed-forward*, normalmente, composta por três camadas, i.e., uma camada de entrada, uma camada escondida e, finalmente, uma camada de saída [84].

A principal diferença de uma RBFNN está no princípio de funcionamento da camada escondida, concretamente no tipo de unidade elementar (neurónio) utilizado. A camada escondida contém neurónios com funções de ativação específicas, conhecidas como Funções de Base Radial (RBF). Estas funções devem ser completamente integráveis e apresentarem um comportamento monótono crescente ou decrescente em relação a um ponto central, como por exemplo, a função gaussiana, triangular, multi-quadrática, multi-qua-

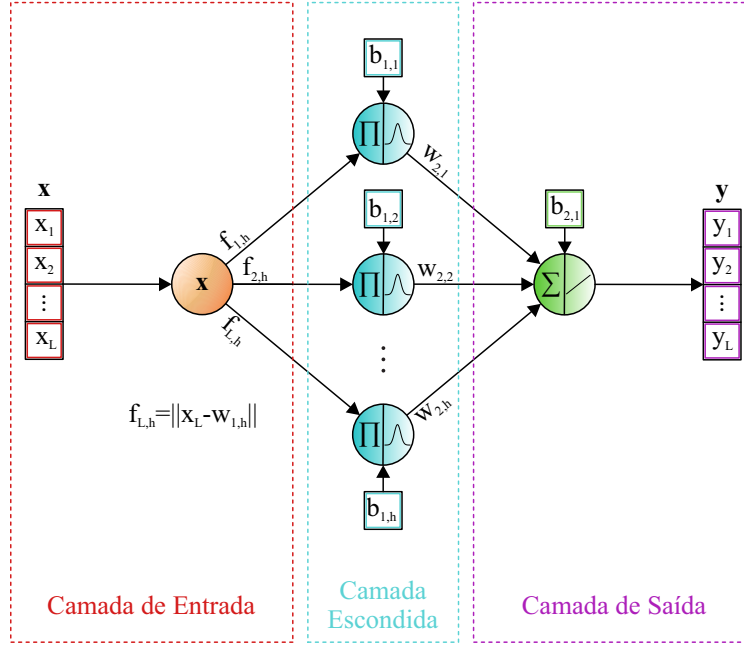


Figura 3.3: Estrutura de uma RBFNN com uma variável de entrada, h unidades ocultas e uma variável de saída.

drática inversa, entre outras [85]. No entanto, devido às suas propriedades estatísticas a RBF mais popular e difundida é a função Gaussiana. Assim, para o modelo da Figura 3.3, a função de ativação para os neurônios da camada escondida, pode ser expressa pela seguinte equação:

$$\phi_{1,h} (\|x - c_{1,h}\| \times b_{1,h}) = e^{-(\|x - c_{1,h}\| \times b_{1,h})^2} \quad (3.12)$$

onde x é o vetor de entrada, h é o índice do neurônio da camada escondida, $c_{1,h}$ é o vetor com as coordenadas do centro do h -ésimo neurônio da camada escondida, $b_{1,h}$ representa a bias associada ao h -ésimo neurônio da camada escondida, $\|\cdot\|$ representa a norma euclidiana e ϕ a RBF utilizada no h -ésimo neurônio da camada escondida.

A camada de saída é responsável por determinar a resposta (saída) da RBFNN realizando, para tal, um mapeamento/combinção linear das saídas provenientes dos neurônios da camada escondida. Desta forma, a resposta da RBFNN é obtida realizando um mapeamento não-linear entre a camada de entrada e a camada escondida e de um mapeamento linear entre a camada escondida e a camada de saída. Assim, considerando o modelo da RBFNN da Figura 3.3, a saída é definida da seguinte forma:

$$y_L(x) = b_{2,1} + \sum_{j=1}^h W_{2,h} \times \phi(\|x_L - c_{1,h}\| \times b_{1,h}) \quad (3.13)$$

onde y é vetor de saída, $W_{2,h}$ representa o peso sináptico entre o h -ésimo neurônio da camada escondida e o neurônio da camada de saída, $b_{2,1}$ representa a bias associada ao neurônio de saída.

Na literatura especializada é possível encontrar diversos métodos para realizar o processo de treino de uma RBFNN que podem ser classificados como: supervisionados, não supervisionados e híbridos. Tipicamente, a maioria dos métodos são classificados como híbridos por serem compostos por duas fases. Numa primeira fase, através de métodos não supervisionados, são definidos os parâmetros inerentes à camada escondida, como por exemplo, o número de unidades RBF (neurónios) e a posição dos seus centros. Esta fase é fundamental para a RBFNN alcançar um equilíbrio ou um compromisso entre resultados de elevada qualidade (com precisão) e uma boa capacidade de generalização. Numa segunda fase, e tipicamente através de métodos supervisionados, os pesos sinápticos e o valor da bias dos neurónios pertencentes à camada de saída são determinados/ajustados [86].

3.4 Algoritmo Proposto

O algoritmo proposto, designado PSO-M, combina as especificidades do PSO Estocástico e do PSO Determinístico com o objetivo de aumentar a eficiência do algoritmo de MPPT, diminuindo o tempo de convergência e as oscilações na procura do GMPP. Além disso, através de *Surrogate Models* (RBFNN) é possível construir modelos aproximados das curvas características I-V e P-V, permitindo analisar, monitorizar e diagnosticar problemas ou avarias na instalação PV, em tempo real e online. Para tal, numa primeira fase, o PSO Estocástico obriga as partículas a percorrer o espaço de procura de forma aleatória, fornecendo os dados provenientes da sua execução (histórico) para uma RBFNN (*Surrogate Model*). Posteriormente, recorrendo a essa RBFNN, são criados modelos aproximados das curvas características I-V e P-V, permitindo verificar o estado de funcionamento da instalação PV e, principalmente, identificar as regiões promissoras, i.e., a região ou área onde se encontra o máximo global e/ou máximos locais em caso de sombreamento parcial. Uma vez identificadas e definidas essas regiões, as partículas são reposicionadas, e é acionado o PSO Determinístico para evitar um comportamento das partículas divergente e repetitivo, diminuindo assim o tempo de convergência e as oscilações na procura do GMPP. Uma vez alcançada a convergência do PSO Determinístico e, conseqüentemente, determinado o GMPP é realizado um processo de refinamento objetivando um refinamento/atualização das curvas características I-V e P-V.

O fluxograma representativo do algoritmo proposto é ilustrado na Figura 3.4. Numa primeira fase, é realizada a inicialização de todos os parâmetros e variáveis necessárias para o seu funcionamento, incluindo: todos os parâmetros de controlo inerentes ao PSO Determinístico e Estocástico; a dimensão do problema (d), o número de partículas da população (n_p); o número de iterações máximas permitidas (k_{max}) e os limites inferiores (l_b) e superiores (u_b). O limite inferior (l_b) é zero e para definir o limite superior (u_b) é realizada uma medição inicial da tensão de circuito aberto (V_{oc}) do sistema PV. Finalizadas as inicializações das variáveis e dos parâmetros, o algoritmo PSO-M realiza o posicionamento inicial das partículas, de forma seletiva, através da seguinte equação $V_{p,i} = \frac{V_{oc}}{6} \times i$, com $i = 1, 2, \dots, n_p$.

Posteriormente, é executado o PSO Estocástico com uma população de cinco partículas e uma topologia em estrela, i.e., todas as partículas comunicam entre si. Resumidamente, a cada período de tempo t , o PSO-M posiciona a partícula correspondente ($V_{p,i}$) e avalia o seu desempenho através da potência do sistema PV. Após a avaliação de todas as partículas pertencentes à população, o histórico é guardado numa base de dados e atualizadas as velocidades e as novas posições de cada partícula através das equações 3.1 e 3.2, respetivamente.

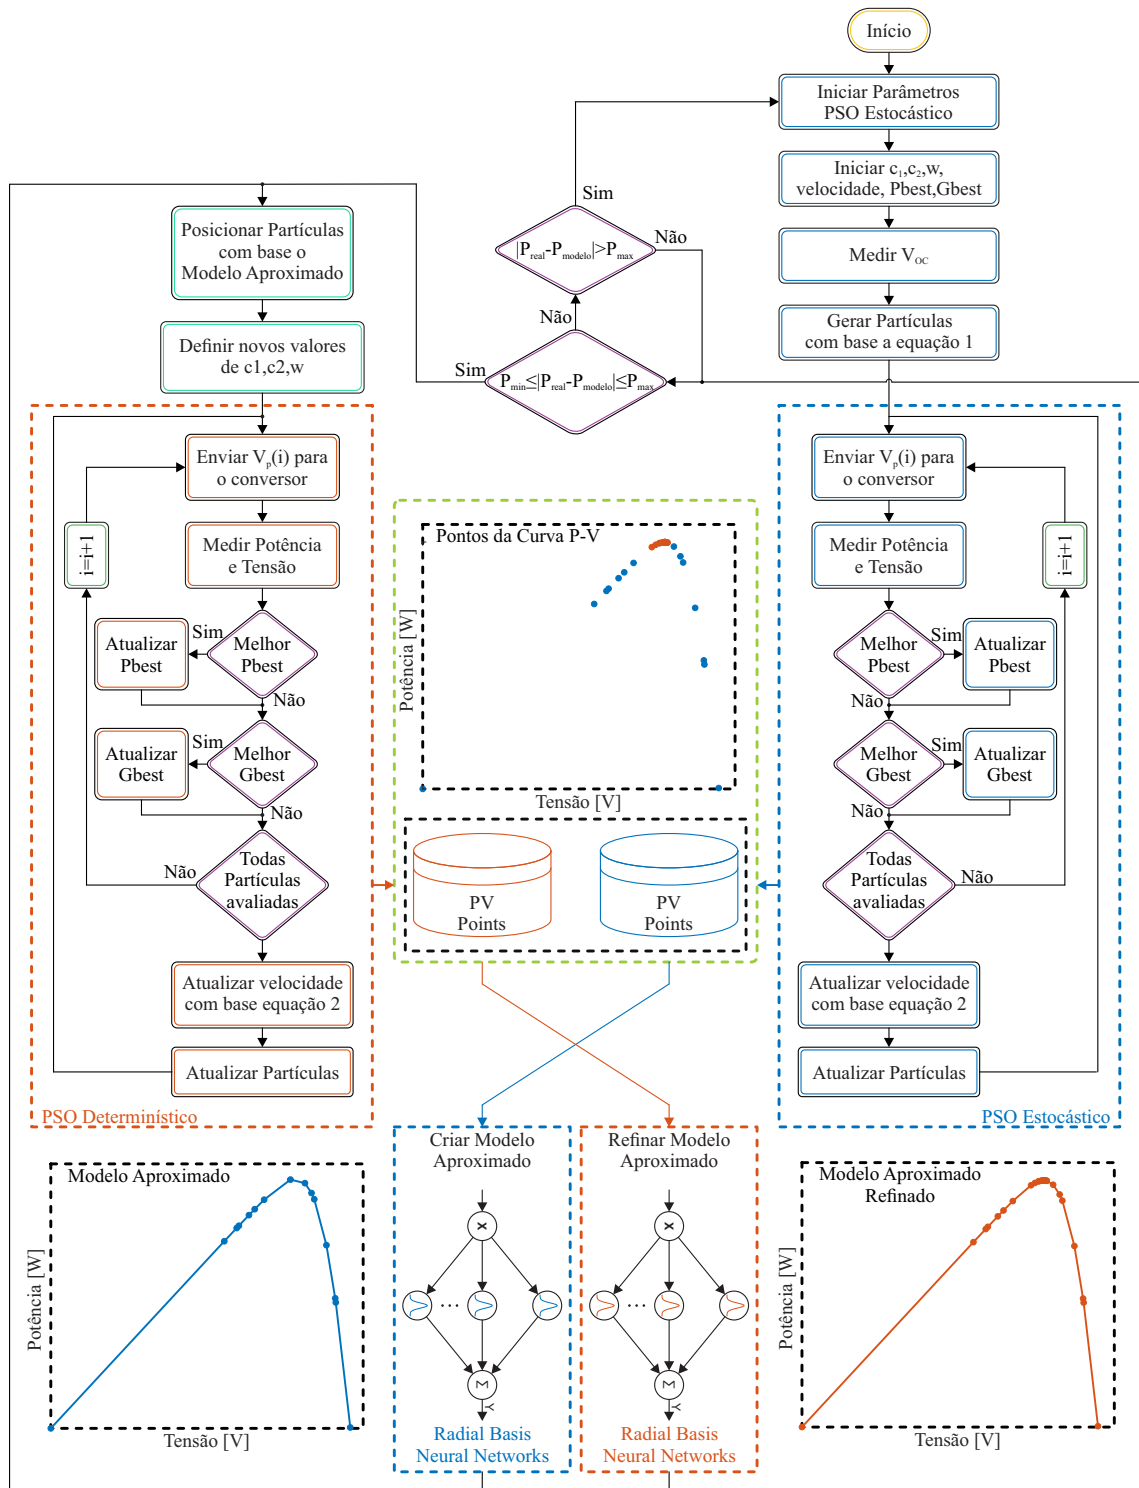


Figura 3.4: Fluxograma do algoritmo PSO-M em controladores MPPT de sistemas PV.

Assim que o PSO Estocástico atinge o critério de paragem (número de iterações permitidas), o PSO-M inicia o treino da RBFNN objetivando a construção do modelo aproximado das curvas características I-V e P-V, através da base de dados criada (histórico do PSO Estocástico). Obtido o modelo aproximado das curvas características é aplicado à curva características P-V um algoritmo para determinar o máximo global e/ou locais em

caso de sombreamento parcial, com base no cálculo da derivada e na detecção de mudanças do seu sinal. Desta forma, é possível verificar o estado de funcionamento da instalação PV em tempo real e identificar a região ou as regiões promissoras, i.e., onde se encontra o máximo global e/ou os máximos locais. No entanto, importa referir, que a precisão do modelo aproximado obtido pela RBFNN, vai depender do critério de paragem definido no PSO Estocástico, i.e., da dimensão da base de dados criada.

Uma vez identificada a região onde se pode encontrar o GMPP, as partículas são repositionadas de forma aleatória dentro dessa região e é acionado o PSO Determinístico. Também o PSO Determinístico é constituído por uma população de cinco partículas e uma topologia em estrela. No entanto, com o objetivo de diminuir o tempo de convergência e as oscilações na procura do GMPP, os parâmetros de controlo são definidos de forma a dar 100% ênfase à intensificação e 0% à diversificação. O PSO Determinístico, movimenta as partículas, forma determinística através da equação 3.7, até alcançarem a convergência. Tal como no PSO Estocástico, sempre que as partículas são avaliadas através da função objetivo (potência do sistema PV), as mesmas continuam a ser guardadas na base de dados. Alcançada a convergência e o GMPP, o PSO-M inicia novamente o treino da RBFNN para obter um modelo refinado das curvas características I-V e P-V, i.e., com um menor erro de aproximação.

Este processo de refinamento é extremamente importante para aumentar a eficiência e o desempenho do PSO-M na procura do GMPP quando submetido a pequenas variações na produção PV. Tipicamente, estas variações na produção PV estão relacionadas, como por exemplo, com a variação natural da irradiância que ocorre durante o dia. Assim, quando ocorre uma pequena variação de produção PV é possível definir uma nova região, onde se encontra o novo GMPP, com base no modelo refinado das curvas características I-V e P-V. Identificada essa nova região, é realizado um posicionamento aleatório das partículas e definidos os parâmetros de controlo do PSO Determinístico. Além disso, toda a base de dados é apagada, com a exceção da corrente de curto-circuito e a tensão de circuito aberto, de forma a guardar as novas partículas geradas pelo PSO Determinístico. Realizados estes procedimentos, o PSO Determinístico pode procurar o novo GMPP sem necessidade de reinicializar todo o processo, aumentando a eficiência e o desempenho do PSO-M. Assim que o PSO Determinístico atinge a convergência, o PSO-M inicia novamente o treino da RBFNN com a nova base de dados criada.

Quando submetido a grandes variações na produção PV, o GMPP muda drasticamente e o PSO-M não consegue identificar uma região promissora. Nesta situação, é realizada uma reinicialização de todo o processo inerente ao PSO-M.

Capítulo 4

Resultados de Simulação e Discussão

Para analisar e validar o desempenho do PSO-M na procura do GMPP em diversas condições de operação, foi implementado o sistema PV apresentado na Figura 4.1. Este sistema PV é constituído por dois módulos PV Sharp ND-R250A5, ligados em série, cujas características são apresentadas na Tabela 4.1. Cada módulo PV é constituído por 60 células ligadas em série e possui três díodos *bypass* ligados em antiparalelo, i.e., um diodo *bypass* por cada grupo de vinte células. O controlador MPPT atua no índice de modulação de um conversor DC-DC Boost com realimentação (malha fechada) da tensão do sistema PV, realizando amostragens periódicas da tensão e da corrente instantânea (com um período de amostragem de 0.05 s). Assim, através do sistema PV considerado e detalhado

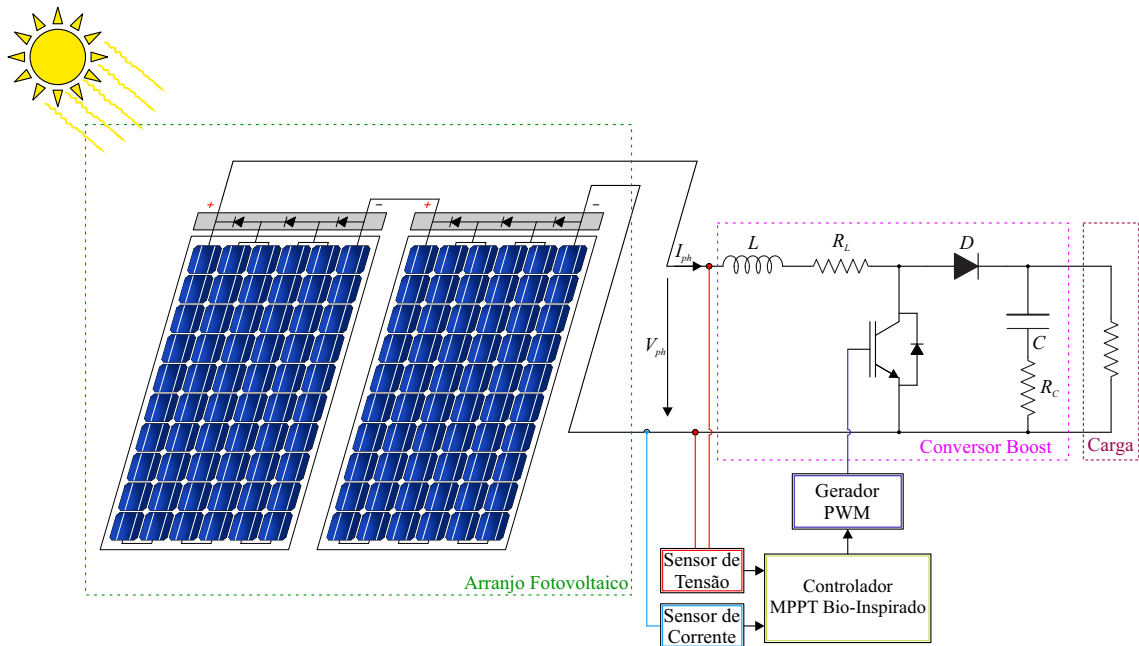


Figura 4.1: Diagrama de blocos de um sistema PV típico com controlo MPPT.

anteriormente foi possível construir quatro casos de estudo. No primeiro caso de estudo, o sistema PV foi submetido a condições uniformes de operação em termos de irradiância e de temperatura (sem sombreamento parcial). No segundo caso de estudo, e de forma a representar a variação natural da irradiância ao longo do dia, foi criado uma sequência de três cenários com pequenas variações da irradiância. No terceiro caso de estudo, o sistema PV foi submetido a condições não uniformes de operação em termos de irradiância (com sombreamento parcial). Por fim, foi criado um quarto caso de estudo, que considerou uma sequência de três cenários com grandes variações de irradiância, devido a sombreamento parcial. O desempenho do algoritmo proposto (PSO-M) foi comparado com diferentes

algoritmos de MPPT meta-heurísticos, como o *Differential Evolution* (DE), o *Grey Wolf Optimizer* (GWO), o *Particle Swarm Optimization* Clássico (PSOC) e com o convencional P&O. Os parâmetros de controlo inerentes a cada algoritmo são apresentados na Tabela 4.2.

Tabela 4.1: Especificações do módulo PV SHARP ND-R250A5.

Parâmetros	Valores
Potencia Máxima de Operação, V_{mpp}	250.29 W
Tensão Máxima de Operação, V_{mpp}	30.90 V
Corrente Máxima de Operação, I_{mpp}	8.10 A
Corrente de Curto Circuito, I_{sc}	8.68 A
Tensão de Circuito Aberto, V_{oc}	37.60 A
Eficiência, η	15.20 %
Coefficiente de Temperatura de Potência Máxima, α_p	-0.440 %/°C
Coefficiente de Temperatura de Tensão de Circuito Aberto, α_v	-0.329 %/°C
Coefficiente de Temperatura de Corrente de Curto Circuito, α_i	+0.038 %/°C
Número de células, N_s	60

Os resultados obtidos foram analisados em termos da taxa de sucesso, do valor do GMPP alcançado, do número de avaliações, do tempo de convergência e da eficiência do MPPT (E_f). A eficiência foi calculada através da equação 4.1 que consiste na razão entre o somatório da potência extraída pelo algoritmo de MPPT e o somatório da potência disponível no sistema PV [87].

$$E_f = \frac{\sum P_{extr}}{\sum P_{disp}} \times 100 \quad (4.1)$$

Para determinar a taxa de sucesso foi estabelecida uma região limitada superiormente pelo GMMP e inferiormente por GMMP-0.5. Assim, a convergência é considerada válida quando com todas as partículas pertencentes à população se encontrem dentro dessa região.

Tabela 4.2: Parâmetros de controlo dos algoritmos de MPPT considerados.

Técnica MPPT	Parâmetros
DE	$V_{i,d}^{k+1} = x_{\beta_1,d}^k + F \times (x_{\beta_2,d}^k - x_{\beta_3,d}^k)$ $F = 0.3, CR = 0.7$
GWO	$a = \left(1 - \frac{k}{k_{max}}\right)^2$
P&O	$V_{passo} = 1 V$
PSOC	$c_1 = c_2 = 0.748, \omega = 0.34, r_1 \wedge r_2 \in random [0, 1]$
PSO-M	PSO Estocástico $c_1 = 3.1, c_2 = 4, \omega = 0.8, r_1 \wedge r_2 \in random [0, 1]$ PSO Determinístico $c_1 = 0.05, c_2 = 2.65, \omega = 0.05, r_1 = r_2 = 0.5$

4.1 Caso de Estudo 1: Sem sombreamento parcial

No primeiro caso de estudo, uma irradiância constante de 500 W/m² incidiu nos três grupos de células de cada módulo PV com uma temperatura de 25 °C. A curva P-V apre-

sentou apenas um ponto de máxima potência, cujo valor de tensão e de potência foi de 62.57 V e 250.99 W, respectivamente. Além disso, para estas condições de operação a corrente de curto-circuito e a tensão de circuito aberto foram de 4.35 A e 73.13 V, respectivamente. A curva característica P-V resultante está representada na Figura 4.2(b) a vermelho.

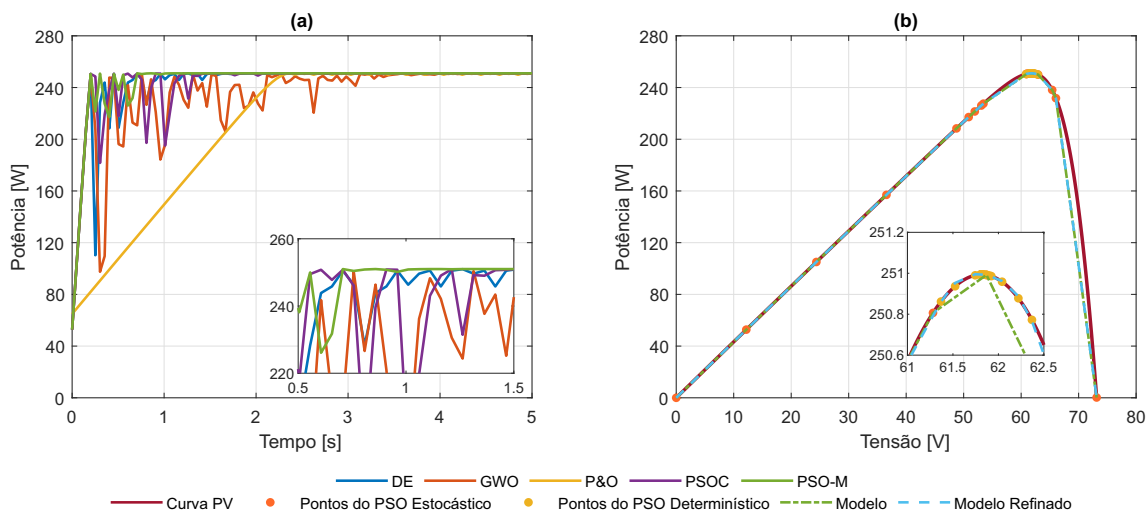


Figura 4.2: Resultados de simulação dos controladores de MPPT considerados, usando o P&O como referência, no primeiro caso de estudo: (a) Curvas de convergência de cada controlador de MPPT; (b) Curva PV estudada, histórico das partículas e modelos do PSO-M.

O PSO-M, conseguiu alcançar o GMPP em todas as 50 runs realizadas, convergindo sempre para os 250.99 W. O PSO-M avaliou, em média, 20 vezes a função objetivo, o que correspondeu a um tempo médio de convergência de 0.94 s, até atingir o GMPP. O menor e maior número de avaliações foram de 17 e 22 vezes com um tempo de convergência de 0.81 s e 1.06 s, respectivamente. Em termos de eficiência, o algoritmo proposto obteve uma eficiência média de 94.85% sendo o pior caso de 92.90% e o melhor caso de 97.50%.

Na Figura 4.2(a) são apresentadas as curvas de convergência obtidas pelos algoritmos de MPPT considerados. Pode-se verificar que o PSO-M foi o algoritmo que apresentou o menor tempo de convergência e a menor oscilação durante a procura do GMPP. O conhecimento do modelo aproximado das curvas características I-V e P-V foi fundamental para obter esse desempenho. O PSO Estocástico obrigou as partículas a movimentarem-se aleatoriamente dentro do espaço de procura, provocando as oscilações visíveis na curva de convergência (parte inicial da curva de convergência). Esta aleatoriedade possibilitou diversificar as posições das partículas, ao longo da curva P-V e, ao mesmo tempo, construir uma base de dados válida para o processo de treino da RBFNN. Na Figura 4.2(b) são apresentadas, a laranja, todas as posições/partículas geradas pelo PSO Estocástico.

Alcançado o critério de paragem estabelecido para o PSO Estocástico, foi treinada a RBFNN (apenas com um custo computacional de 0.05 s) e obtido o modelo aproximado da curva característica P-V ilustrado na Figura 4.2(b) a verde tracejado. Identificada a região

promissora, essa informação foi compartilhada com PSO-Determinístico que reposicionou as partículas dentro de um determinado raio. Após o reposicionamento das partículas, o PSO Determinístico alcançou o GMPP evitando um comportamento das partículas divergente e repetitivo. Na Figura 4.2(b), a amarelo, é possível visualizar o reposicionamento das partículas e a respectiva movimentação para o GMPP.

Nem sempre o modelo aproximado das curvas características I-V e P-V apresenta uma boa aproximação, em particular na região próxima do GMPP. Para contornar esse constrangimento, é realizado um processo de refinamento com a base de dados criada pelo PSO Estocástico e Determinístico. O modelo refinado da curva característica P-V é ilustrado a azul tracejado na Figura 4.2(b).

Todos os algoritmos implementados obtiveram uma taxa de sucesso de 100%. Todos os algoritmos convergiram para uma potência de 250.99 W (GMPP), excepto o DE que convergiu, em média, para uma potência de 250.97 W. O PSO-M necessitou, em média, de 20 avaliações, enquanto o DE, GWO e o PSOC necessitaram, em média, de 49, 80, 53 avaliações, respectivamente. Como o tempo de convergência está relacionado com o número de avaliações, o PSO-M apresentou o menor tempo de convergência com uma média de 0.94 s, enquanto o DE, o GWO e o PSOC demoraram, em média, 2.41 s, 4.01 s e 2.64 s. Em termos de eficiência, o PSO-M obteve a maior percentagem com 94.85% seguido pelo DE com 94.42%. O PSOC alcançou 94.39% e por último, o GWO conseguiu 89.84%.

4.2 Caso de Estudo 2: Variação da irradiância sem sombreamento parcial

No segundo caso de estudo, foi considerado uma sequência de três cenários com pequenas variações de irradiância, i.e., a cada 6 segundos, variou-se os níveis de irradiância incidente em ambos os módulos PV. A temperatura considerada nos 3 cenários foi de 25 °C. No primeiro cenário, o sistema PV foi submetido a um nível de irradiância de 981 W/m². A curva característica P-V resultante, representada na Figura 4.3(b) a vermelho, apresentou uma tensão e potência no MPP de 61.80 V e 491.28 W, respectivamente. Já a corrente de curto-circuito e a tensão de circuito aberto foram de 8.53 A e 75.14 V, respectivamente.

No segundo cenário, o sistema PV foi submetido a um ligeiro aumento dos níveis de irradiância (1000 W/m²). A curva P-V resultante, representada na Figura 4.3(c), apresentou uma tensão e potência no MPP de 61.75V e 500.57 W, respectivamente. A corrente de curto-circuito e a tensão de circuito aberto foram de 8.69 A e 75.19 V, respectivamente.

No terceiro cenário, os níveis de irradiância que incidiram nos três grupos de células de cada módulo PV diminuiu para os 987 W/m². A curva P-V resultante, ilustrada na Figura 4.3(d), no MPP apresentou uma tensão e potência de 61.81V e 494.21 W, respectivamente.

Tabela 4-3: Comparação de resultados do primeiro caso de estudo entre os diferentes algoritmos de MPPT considerados, com 50 execuções independentes

Caso de Estudo 1: Sem Sombreamento Parcial														
Método	GMPP [W]	Taxa de sucesso [%]	GMPP rastreado [W]			Número de avaliações			Tempo de convergência [s]			Eficiência [%]		
			Mín	Média	Máx	Mín	Média	Máx	Mín	Média	Máx	Mín	Média	Máx
DE	250,99	100	250,74	250,97	250,99	23	49	75	1,11	2,41	3,74	88,54	94,42	96,67
GWO	250,99	100	250,99	250,99	250,99	75	80	86	3,74	4,01	4,29	87,28	89,84	93,26
PSOC	250,99	100	250,99	250,99	250,99	38	53	83	1,87	2,64	4,14	91,03	94,39	96,68
PSO-M	250,99	100	250,99	250,99	250,99	17	20	22	0,81	0,94	1,06	92,90	94,85	97,50

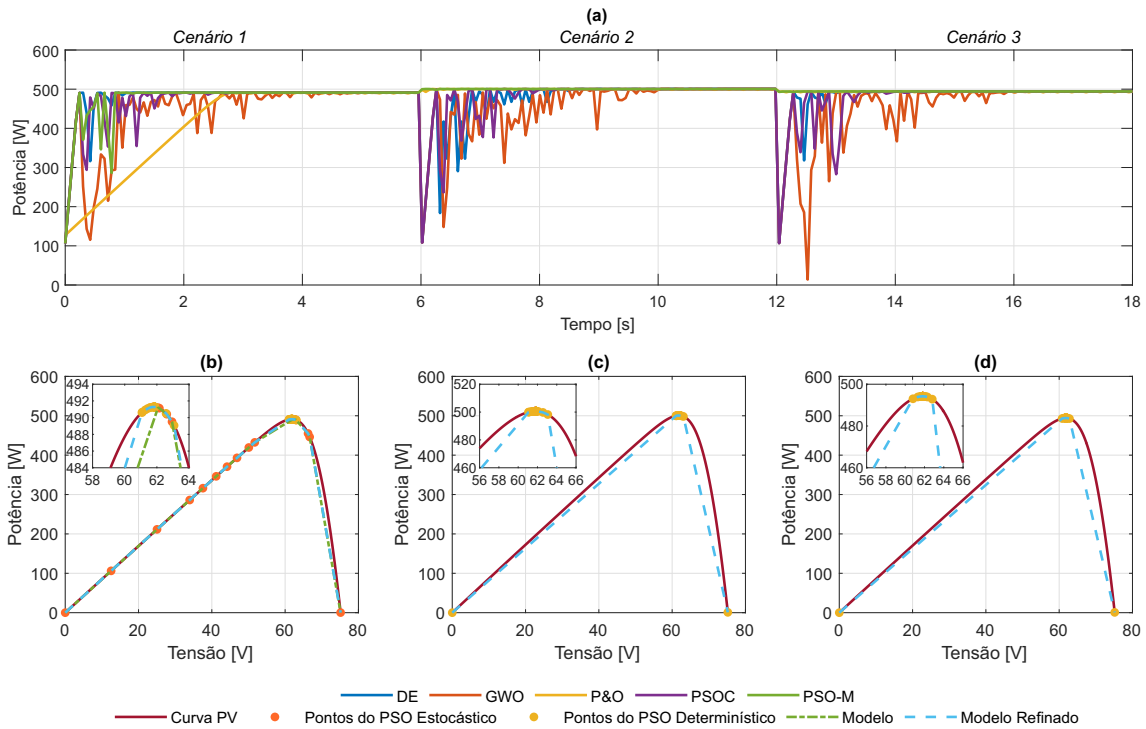


Figura 4.3: Resultados de simulação dos controladores de MPPT considerados, usando o P&O como referência, no segundo caso de estudo: (a) Curvas de convergência de cada controlador de MPPT nos três cenários; (b), (c) e (d) Curvas PV estudadas, histórico das partículas e modelos do PSO-M nos três cenários, respetivamente.

Neste cenário, a corrente de curto-circuito e a tensão de circuito aberto foram de 8.58 A e 75.15 V, respetivamente.

No primeiro cenário, o PSO-M convergiu sempre para os 491.28 W (valor ao qual corresponde o GMPP), em todas as 50 runs executadas. O PSO-M avaliou, em média, 23 vezes a função objetivo, o que correspondeu a um tempo médio de convergência de 1.32 s, até alcançar o GMPP. O menor e maior número de avaliações foram 18 e 26 vezes com um tempo de convergência de 1.03 s e 1.52 s, respetivamente. Em termos de eficiência, o PSO-M obteve uma eficiência média de 95% sendo o pior caso de 92.90% e o melhor de 96.68%. O PSO-M foi o algoritmo que apresentou o menor tempo de convergência e a menor oscilação durante a procura do GMPP, como se pode verificar na Figura 4.3(a). Na Figura 4.3(b) são apresentadas a laranja e a amarelo o histórico das partículas do PSO Estocástico e do PSO Determinístico, respetivamente. O modelo aproximado da curva característica P-V, obtido pela RBFNN com base no histórico do PSO Estocástico, é mostrado na Figura 4.3(b) a verde tracejado. Ao observar a figura podemos verificar que o modelo aproximado não obteve uma boa aproximação na região próxima GMPP. A precisão do modelo vai depender do critério de paragem definido no PSO Estocástico, i.e., da dimensão da base de dados criada. No entanto, com a inclusão do histórico do PSO-determinístico no processo de treino da RBFNN, o modelo refinado obteve um excelente nível de precisão. O modelo refinado da curva característica P-V é apresentando a azul na

Figura 4.3(b).

No segundo cenário, o PSO-M convergiu sempre para o GMPP que corresponde uma potência de 500.57 W. O PSO-M avaliou, em média, 8 vezes a função objetivo, o que correspondeu a um tempo médio de convergência de 0.42 s, até atingir o GMPP. O menor e maior número de avaliações foram 3 e 11 vezes com um tempo de convergência de 0.12 s e 0.61 s, respectivamente. Em termo de eficiência, o PSO-M obteve uma eficiência de 99.99%. Novamente, o PSO-M foi o algoritmo que apresentou o menor tempo de convergência e a menor oscilação durante a procura do GMPP como se pode verificar na Figura 4.3(a). A variação dos níveis de irradiância não provocou grandes mudanças na produção do sistema PV, deslocando ligeiramente o GMPP. Nestas situações, é possível definir uma nova região, onde se encontra o novo GMPP, com base no modelo refinado das curvas características I-V e P-V.

Assim, o PSO-M reposicionou as partículas perto do novo GMPP, com base o modelo refinado do primeiro cenário. Na Figura 4.3(c), a amarelo, são visíveis o reposicionamento e o movimento das partículas. Após a convergência e, conseqüentemente, alcançado o novo GMPP é realizado um novo refinamento para atualizar as curvas características I-V e P-V, como se ilustra a azul na Figura 4.3(c). Neste processo de refinamento apenas a corrente de curto-circuito, a tensão de circuito aberto e o histórico do PSO Determinístico constituem a base de dados para o processo de treino da RBFNN. Desta forma, o PSO-M apresentou uma convergência praticamente instantânea e quase nenhuma oscilação na procura do novo GMPP.

No terceiro cenário, o PSO-M convergiu sempre para os 494.21 W (GMPP). O PSO-M avaliou apenas de 6 vezes a função objetivo, o que correspondeu a um tempo de convergência de 0.30 s. A eficiência foi de 99.99%, apresentando o menor tempo de convergência e a menor oscilação durante a procura do GMPP como se pode verificar na Figura 4.3(a) cenário 3. Na Figura 4.3(d) é visível, a amarelo, o reposicionamento e histórico das partículas geradas pelo PSO Determinístico. Após a convergência, a atualização da curva característica P-V é ilustrada a azul na Figura 4.3(d).

No primeiro cenário, todos os algoritmos obtiveram uma taxa de sucesso de 100% com a exceção do DE, que obteve 96%. Todos os algoritmos convergiram para uma potência de 491.28 W (GMPP), expeto o DE que convergiu em média para uma potencia de 491.25 W. O PSO-M avaliou, em média, de 23 vezes a função objetivo, enquanto o DE, o GWO e o PSOC avaliaram, em média, 53, 83 e 58 vezes a função objetivo, respectivamente. Isto correspondeu a um tempo de convergência médio de 1.32 s, 3.18 s, 4.99 s, e 3.43 s para o PSO-M, DE, GWO e PSOC, respectivamente. Em termo de eficiência, o PSO-M obteve uma eficiência média de 95%, enquanto o DE, o GWO e o PSOC obtiveram 94.71%, 90.13% e 94.72%, respectivamente.

No segundo cenário, todos os algoritmos obtiveram uma taxa de sucesso de 100% com a exceção do DE, que obteve 98%. Todos os algoritmos convergiram para uma potência de 500.57 W (GMPP) expeto o DE que convergiu, em média para uma potência de 500.53

Tabela 4.4: Comparação de resultados do segundo caso de estudo entre os diferentes algoritmos de MPPT considerados, com 50 execuções independentes

Método MPPT		GMPPT [W]	Taxa de sucesso [%]	GMPPT Médio [W]			Número de avaliações			Tempo de convergência [s]			Eficiência [%]		
				Mín	Média	Máx	Mín	Média	Máx	Mín	Média	Máx	Mín	Média	Máx
Cenário 1															
DE		491,28	96	490,50	491,25	491,28	24	53	100	1,39	3,18	6,00	88,86	94,71	97,47
GW/O		491,28	100	491,27	491,28	491,28	76	83	91	4,55	4,99	5,45	87,20	90,13	93,06
PSOC		491,28	100	491,28	491,28	491,28	40	58	82	2,36	3,43	4,91	91,55	94,72	96,72
PSO-M		491,28	100	491,28	491,28	491,28	18	23	26	1,03	1,32	1,52	92,90	95,00	96,68
Cenário 2															
DE		500,57	98	499,93	500,53	500,57	31	57	100	1,82	3,41	6,00	88,60	94,61	97,17
GW/O		500,57	100	500,57	500,57	500,57	69	83	90	4,12	4,96	5,39	87,71	90,32	92,31
PSOC		500,57	100	500,57	500,57	500,57	43	59	93	2,55	3,52	5,58	89,18	94,45	96,37
PSO-M		500,57	100	500,57	500,57	500,57	3	8	11	0,12	0,42	0,61	99,99	99,99	99,99
Cenário 3															
DE		494,21	96	493,34	494,17	494,21	27	53	100	1,58	3,15	6,00	88,57	94,72	97,53
GW/O		494,21	100	494,21	494,21	494,21	78	84	91	4,67	5,03	5,45	87,27	89,77	92,61
PSOC		494,21	100	494,21	494,21	494,21	36	57	97	2,12	3,39	5,82	91,31	94,78	96,69
PSO-M		494,21	100	494,21	494,21	494,21	6	6	6	0,30	0,30	0,30	99,99	99,99	99,99

W. O PSO-M avaliou, em média, 8 vezes a função objetivo, enquanto o DE, o GWO e o PSOC avaliaram, em média, 57, 83 e 59 vezes a função objetivo, respectivamente. Isto correspondeu a um tempo de convergência médio de 0.42 s, 3.41 s, 4.96 s, e 3.52 s para o PSO-M, DE, GWO e PSOC, respectivamente. Em termo de eficiência, o PSO-M obteve uma eficiência de 99.99%, enquanto o DE, o GWO e o PSOC obtiveram 94.61%, 90.32% e 94.45%, respectivamente.

No terceiro cenário, todos os algoritmos obtiveram uma taxa de sucesso de 100% com a exceção do DE, que obteve 96%. Todos os algoritmos convergiram para uma potência de 494.21 W (GMPP) expeto o DE que convergiu, em média para uma potência de 494.17 W. O PSO-M avaliou, 6 vezes a função objetivo, enquanto o DE, o GWO e o PSOC avaliaram, em média, 53, 84 e 57 vezes a função objetivo, respectivamente. Isto correspondeu a um tempo de convergência de 0.3 s para o PSO-M, enquanto para o DE, o GWO e o PSOC corresponderam a um tempo de convergência médio de 3.15 s, 5.03 s, e 3.39 s, respectivamente. Em termo de eficiência, o PSO-M obteve uma eficiência 99.99%, enquanto o DE, o GWO e o PSOC obtiveram uma média de 94.72%, 89.77% e 94.78%, respectivamente.

4.3 Caso de Estudo 3: Com sombreamento parcial

No terceiro caso de estudo, o sistema PV foi submetido a condições de sombreamento parcial. Para tal, os três grupos de células, em ambos os módulos PV, foram submetidos a diferentes níveis de irradiância, concretamente 1000 W/m^2 , 300 W/m^2 e 100 W/m^2 , com uma temperatura constante de $25 \text{ }^\circ\text{C}$. A curva característica P-V resultante, representada na Figura 4.4(b) a vermelho, apresentou três máximos locais sendo um deles o máximo global com uma potência de 140.85 W e uma tensão de 17.56 V. Neste caso de estudo, a corrente de curto-circuito e a tensão de circuito aberto foram de 8.69 A e 71.71 V, respectivamente.

O PSO-M localizou e identificou o valor do GMPP em todas as 50 runs simuladas, convergindo, em média, para uma potência de 140.84 W. A potência mínima obtida pelo PSO-M foi de 140.77 W enquanto a potência máxima foi de 140.85 W (valor do GMPP). Avaliou, em média, 28 vezes a função objetivo, o que correspondeu a um tempo médio de convergência de 1.37 s, até atingir o GMPP. O menor e maior número de avaliações foi 25 e 31, com um tempo de convergência de 1.21 s e 1.52 s, respectivamente. Em termos de eficiência, o PSO-M obteve uma eficiência média de 91.89% sendo o pior caso de 90.36% e o melhor de 93.41%.

Na Figura 4.4(a) são apresentadas a curvas de convergência obtidas pelos algoritmos de MPPT considerados. Pode-se verificar que o PSO-M foi o algoritmo que apresentou o menor tempo de convergência e a menor oscilação durante a procura do GMPP. Na Figura 4.4(b) são apresentadas a laranja e a amarelo, o histórico obtido pelo PSO Estocástico e pelo PSO Determinístico, respectivamente.

Já o modelo aproximado e o modelo refinado das curvas características, obtido pela

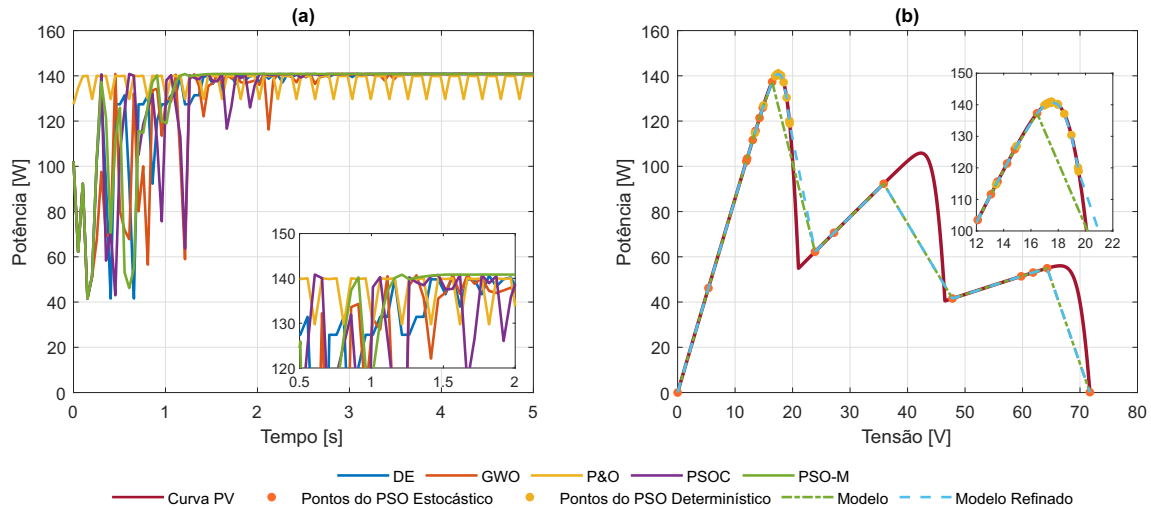


Figura 4.4: Resultados de simulação dos controladores de MPPT considerados, usando o P&O como referência, no terceiro caso de estudo: (a) Curvas de convergência de cada controlador de MPPT; (b) Curva PV estudada, histórico das partículas e modelos do PSO-M

RBFNN, são ilustrados na Figura 4.4(b) a verde e a azul tracejado, respectivamente. Mesmo quando submetido a condições complexas de sombreamento parcial, tanto o modelo aproximado como o modelo refinado obtiveram uma boa representação das curvas características I-V e P-V e, conseqüentemente, da produção do sistema PV.

Apenas o PSO-M obteve uma taxa de sucesso de 100%, enquanto o DE, o GWO e o PSOC obtiveram 72%, 12% e 96%, respectivamente. Relativamente ao GMPP, o PSO-M obteve uma média de 140.84 W enquanto o DE, o GWO e o PSOC obtiveram uma média de 136.75 W, 118.98 W e 139.45 W, respectivamente. O PSO-M necessitou em média de 28 avaliações, enquanto o DE, GWO e o PSOC necessitaram, em média, de 76, 97, 65 avaliações, respectivamente. Como o tempo de convergência está relacionado com o número de avaliações, o PSO-M apresentou o menor tempo de convergência com uma média de 1.37 s, enquanto o DE, o GWO e o PSOC requereram, em média, 3.81 s, 4.86 s e 3.25 s. Em termos de eficiência o PSO-M apresentou a maior percentagem com 91.89% seguido pelo PSOC com 88.65%. O DE obteve 86.36% e por último, o GWO alcançou 64.81%.

4.4 Caso de Estudo 4: Variação da irradiância com sombreamento parcial

No quarto caso de estudo, considerou-se uma sequência de três cenários com grandes variações de irradiância, devido a condições de operação com sombreamento parcial. A cada 6 segundos, foram alterados os níveis de irradiância incidente em cada grupo de células PV de modo a polarizar diretamente os respectivos díodos *bypass*. A temperatura ambiente considerada nos 3 cenários foi de 25 °C.

Tabela 4-5: Comparação de resultados do terceiro caso de estudo entre os diferentes algoritmos de MPPT considerados, com 50 execuções independentes

Caso de estudo 3: Sem Sombreamento Parcial														
Método	GMPP [W]	Taxa de sucesso [%]	GMPP Medio [W]			Número de avaliações			Tempo de convergência [s]			Eficiência [%]		
			Mín	Média	Máx	Mín	Média	Máx	Mín	Média	Máx	Mín	Média	Máx
MPPT	140,85	72	105,84	136,75	140,85	45	76	100	2,22	3,81	5,00	68,15	86,36	93,05
DE	140,85	12	102,24	118,98	140,85	71	97	100	3,54	4,86	5,00	47,72	64,81	90,71
PSOC	140,85	96	105,84	139,45	140,85	46	65	100	2,27	3,25	5,00	67,40	88,65	92,39
PSO-M	140,85	100	140,77	140,84	140,85	25	28	31	1,21	1,37	1,52	90,36	91,89	93,41

No primeiro cenário apenas um diodo *bypass* em cada módulo PV foi polarizado diretamente. Para tal, dois grupos de células PV foram submetidas a elevados níveis de irradiância (1000 W/m^2) e o terceiro grupo submetido a um nível de irradiância de 400 W/m^2 . Para este cenário a curva característica P-V, ilustrada na Figura 4.5(b) a vermelho, apresentou dois máximos locais sendo um deles o GMPP. A tensão e a potência no GMPP foram de 39.68 V e 320.69 W , respetivamente. Já a corrente de curto-circuito e a tensão de circuito aberto foram de 8.69 A e 74.29 V , respetivamente. No segundo cenário, dois diodos *bypass* de cada módulo PV foram polarizados diretamente. Para tal, os três grupos de células de cada módulo PV receberam 1000 W/m^2 , 600 W/m^2 e 400 W/m^2 , respetivamente. Para este cenário, a curva característica P-V, representada na Figura 4.5(c) a vermelho, apresentou três máximos locais sendo um deles o GMPP. A tensão e a potência no GMPP foram de 66.23 V e 222.56 W , respetivamente. A corrente de curto-circuito e a tensão de circuito aberto foram de 8.69 A e 73.77 V , respetivamente.

No terceiro cenário apenas um módulo PV foi submetido a condições de operação com sombreamento parcial. Para simular essas condições de operação, os três grupos de células do módulo PV foram submetidos a diferentes níveis de irradiância, concretamente 550 W/m^2 , 450 W/m^2 e 350 W/m^2 . O outro módulo PV foi submetido a uma condição de operação sem sombreamento parcial, com um nível de irradiância constante de 1000 W/m^2 . A curva característica P-V, mostrada na Figura 4.5(d) a vermelho, apresentou quatro máximos locais sendo um deles o GMPP. A tensão e a potência no GMPP foram de 28.62 V e 230.79 W , respetivamente. A corrente de curto-circuito e a tensão de circuito aberto foram de 8.69 A e 73.98 V , respetivamente.

No primeiro cenário, o PSO-M conseguiu localizar o GMPP em todas as 50 runs efetuadas, convergindo, em média, para uma potência de 320.68 W . A potência mínima e máxima obtida pelo PSO-M foi de 320.56 W e de 320.69 W , respetivamente. O PSO-M avaliou, em média, 26 vezes a função objetivo, o que correspondeu a um tempo médio de convergência de 1.51 s , até convergir para o GMPP. O menor e maior número de avaliações foram 23 e 31 vezes com um tempo de convergência de 1.33 s e 1.82 s , respetivamente. Em termo de eficiência, o PSO-M obteve uma eficiência média de 94.90% sendo o pior caso de 93.12% e o melhor de 96.29% . O PSO-M foi o algoritmo que apresentou o menor tempo de convergência e a menor oscilação durante a procura do GMPP como se pode verificar na Figura 4.5 cenário 1.

No segundo cenário, o PSO-M convergiu sempre para um valor de potência de 222.56 W (valor do GMPP). O PSO-M avaliou, em média, 26 vezes a função objetivo o que correspondeu a um tempo médio de convergência de 1.50 s , até atingir a convergência. O menor e maior número de avaliações foram 23 e 31 vezes com um tempo de convergência de 1.33 s e 1.82 s , respetivamente. Em termo de eficiência, o PSO-M obteve uma eficiência média de 95.81% sendo o pior caso de 94.67% e o melhor de 97.25% . Novamente, o PSO-M foi o algoritmo que apresentou o menor tempo de convergência e a menor oscilação durante a procura do GMPP como se pode verificar na Figura 4.5(a) cenário 2. Nesta situação o

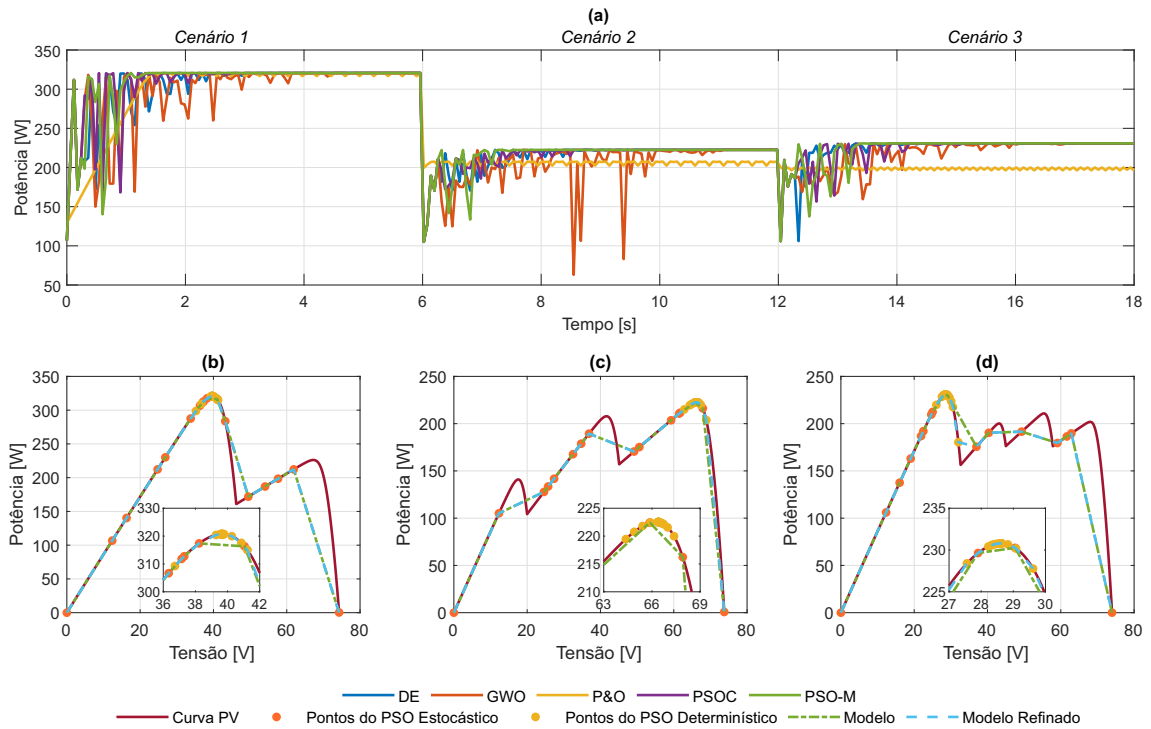


Figura 4.5: Resultados de simulação dos controladores de MPPT considerados, usando o P&O como referência, no quarto caso de estudo: (a) Curvas de convergência de cada controlador de MPPT nos três cenários; (b), (c) e (d) Curvas PV estudadas, histórico das partículas e modelos do PSO-M nos três cenários, respetivamente.

PSO-M foi submetido a uma grande variação na produção do sistema PV, i.e., a potência do GMPP mudou de 320.69 W (valor de potência do cenário 1) para 222.56 W, obrigando o PSO-M a reinicializar todo o seu processo de procura.

No terceiro cenário, o PSO-M conseguiu localizar o GMPP em todas as 50 runs realizadas, convergindo, em média, para uma potência de 230.78 W (GMPP). A potência mínima obtida pelo PSO-M foi de 230.73 W enquanto, a potência máxima foi de 230.79 W. O PSO-M avaliou, em média, 26 vezes a função objetivo, o que correspondeu a um tempo médio de convergência de 1.51 s, até atingir a convergência. O menor e maior número de avaliações foram 22 e 31 vezes com um tempo de convergência de 1.27 s e 1.82 s, respetivamente. Em termos de eficiência, o PSO-M obteve uma eficiência média de 95.98% sendo o pior caso de 94.78% e o melhor de 96.71%. Mais uma vez, o PSO-M foi o algoritmo que apresentou o menor tempo de convergência e a menor oscilação durante a procura do GMPP, como se pode verificar na Figura 4.5 cenário 3.

Apesar da complexidade das condições de operação podemos verificar que o modelo aproximado e, conseqüentemente o modelo refinado conseguiram identificar e caracterizar a região onde se encontrava o GMPP. No entanto, não conseguiram representar com fiabilidade e precisão a forma das curvas características I-V e P-V. A precisão de ambos os modelos, vai depender fundamentalmente do histórico do PSO Estocástico, i.e., do número de avaliações permitidas no PSO Estocástico. Em ambos os cenários, nas Figuras

4.5(c) e (d) são apresentadas a laranja e a amarelo o histórico do PSO Estocástico e do PSO Determinístico, respetivamente. Os modelos aproximados das curvas características P-V, com base no histórico do PSO Estocástico, são mostrados nas Figuras 4.5(c) e (d) a verde tracejado. Já os modelos refinados das curvas características P-V gerados pela RBFNN, com base no histórico do PSO Estocástico e do PSO Determinístico, são apresentados nas Figuras 4.5(c) e (d) a azul.

No primeiro cenário, todos os algoritmos obtiveram uma taxa de sucesso de 100% com a exceção do DE, que obteve 74%. O PSO-M convergiu, em média, para uma potência de 320.68 W, o DE convergiu, em média, para uma potência de 319.71 W e o GWO e o PSOC convergiram, em média, para uma potência de 320.69 W. O PSO-M avaliou, em média, de 26 vezes a função objetivo, enquanto o DE, o GWO e o PSOC avaliaram, em média, 73, 81 e 53 vezes a função objetivo, respetivamente. Isto correspondeu a um tempo de convergência médio de 1.51 s, 4.34 s, 4.83 s, e 3.13 s para o PSO-M, DE, GWO e PSOC, respetivamente. Em termo de eficiência, o PSO-M obteve uma eficiência média de 94.90%, enquanto o DE, o GWO e o PSOC obtiveram 92.90%, 92.75% e 95.37%, respetivamente.

No segundo cenário, o PSO-M e o PSOC obtiveram uma taxa de sucesso de 100%, o DE obteve 80% e o GWO obteve 68%. O PSO-M e o PSOC convergiram, sempre para uma potência de 222.56 W, o DE convergiu, em média, para uma potencia de 221.89 W e o GWO convergiu, em média, para uma potencia de 219.36 W. O PSO-M avaliou, em média, de 26 vezes a função objetivo, enquanto o DE, o GWO e o PSOC avaliaram, em média, 71, 89 e 67 vezes a função objetivo, respetivamente.

Isto correspondeu a um tempo de convergência médio de 1.50 s, 4.24 s, 5.35 s, e 3.99 s para o PSO-M, DE, GWO e PSOC, respetivamente. Em termo de eficiência, o PSO-M obteve uma eficiência média de 95.81%, enquanto o DE, o GWO e o PSOC obtiveram 94.88%, 86.94% e 93.88%, respetivamente.

No terceiro cenário, apenas o PSO-M obteve uma taxa de sucesso de 100%. O DE, o GWO e o PSOC obtiveram 82%, 40% e 94%. O PSO-M convergiu, em média, para uma potência de 230.78 W, enquanto o DE, o GWO e o PSOC convergiram, em média, para uma potencia de 229.66 W, 225.55 W e 229.59 W, respetivamente. O PSO-M avaliou, em média, 26 vezes a função objetivo, enquanto o DE, o GWO e o PSOC avaliaram, em média, 71, 92 e 57 vezes a função objetivo, respetivamente. Isto correspondeu a um tempo de convergência médio de 1.51 s, 4.23 s, 5.50 s, e 3.41 s para o PSO-M, DE, GWO e PSOC, respetivamente. Em termo de eficiência, o PSO-M obteve uma eficiência média de 95.98%, enquanto o DE, o GWO e o PSOC obtiveram 93.91%, 86.03% e 95.34%, respetivamente.

Tabela 4-6: Comparação de resultados do quarto caso de estudo entre os diferentes algoritmos de MPPT considerados, com 50 execuções independentes

Caso de estudo 4: Variação da Irradiância Com Sombreamento Parcial															
Método	MPPT	GMPP [W]	Taxa de sucesso [%]	GMPP Médio [W]			Número de avaliações			Tempo de convergência [s]			Eficiência [%]		
				Mín	Média	Máx	Mín	Média	Máx	Mín	Média	Máx	Mín	Média	Máx
Cenário 1	DE	320,69	74	312,43	319,71	320,69	24	73	100	1,39	4,34	6,00	85,51	92,90	97,03
	GWO	320,69	100	320,69	320,69	320,69	72	81	86	4,30	4,83	5,15	90,57	92,75	94,56
	PSOC	320,69	100	320,69	320,69	320,69	41	53	71	2,42	3,13	4,24	93,56	95,37	96,54
	PSO-M	320,69	100	320,56	320,68	320,69	23	26	31	1,33	1,51	1,82	93,12	94,90	96,29
Cenário 2	DE	222,56	80	213,49	221,89	222,56	31	71	100	1,82	4,24	6,00	90,12	94,88	97,21
	GWO	222,56	68	210,65	219,36	222,56	76	89	100	4,55	5,35	6,00	76,65	86,94	93,38
	PSOC	222,56	100	222,56	222,56	222,56	42	67	99	2,48	3,99	5,94	88,67	93,88	96,56
	PSO-M	222,56	100	222,56	222,56	222,56	23	26	31	1,33	1,50	1,82	94,67	95,81	97,25
Cenário 3	DE	230,79	82	210,80	229,66	230,79	31	71	100	1,82	4,23	6,00	87,46	93,91	97,36
	GWO	230,79	40	209,58	225,55	230,79	72	92	100	4,30	5,50	6,00	75,59	86,03	94,60
	PSOC	230,79	94	210,80	229,59	230,79	40	57	100	2,36	3,41	6,00	86,58	95,34	96,97
	PSO-M	230,79	100	230,73	230,78	230,79	22	26	31	1,27	1,51	1,82	94,78	95,98	96,71

Capítulo 5

Resultados Experimentais e Discussão

Para validar o desempenho e a eficiência do PSO-M em condições de operação reais, foi implementado o *setup* experimental ilustrado na Figura 5.1. O *setup* experimental é constituído por um módulo PV Sharp ND-R250A5 orientado a 150° a sudeste com uma inclinação de 34° , cujas características encontram-se na Tabela 4.1. Além disso, é constituído por um sensor de irradiância e temperatura Ingenieurbüro Si-13TC-T, uma carga eletrónica DC IT8500+, um microcontrolador Atmega 2560 e um computador.




Figura 5.1: *Setup* experimental.

Para impor o ponto de funcionamento ao módulo PV foi utilizada uma carga eletrónica DC IT8500+ em substituição do típico conversor DC-DC boost e da respetiva carga. A carga eletrónica DC IT8500+ é uma carga eletrónica programável que pode ser controlada remotamente através de comunicação serial RS-232. A carga eletrónica foi colocada no modo de funcionamento de tensão constante (CV) para impor o nível de tensão ao módulo PV e, conseqüentemente, obter a correspondente/respetiva potência. O algoritmo PSO-M foi implementado em ambiente de programação Matlab, num ficheiro m-file, realizando amostragens periódicas da tensão e da corrente instantânea (com um período de amostragem de 0.6 s). Importa referir, que o período de amostragem foi selecionado função do tempo de resposta da carga eletrónica, i.e., a limitação imposta pela carga eletrónica impede a execução do PSO-M com uma frequência superior a 1.66 Hz. Para obter os níveis de temperatura e irradiância, dois conversores analógicos digitais (ADCs) de 10 bits, do microcontrolador Atmega 2560, foram configurados para digitalizar os dois sinais

analogicos provenientes do sensor Ingenieurbüro Si-13TC-T.

Para validar experimentalmente e analisar o desempenho do PSO-M em condições de operação reais, foram considerados dois casos de estudo. No primeiro caso de estudo, foi testado o desempenho do PSO-M em condições não uniformes de operação em termos de irradiância (com sombreamento parcial). Já no segundo caso de estudo foi analisado o desempenho do PSO-M numa situação de operação real, ao longo de um dia (24 horas), considerado diferentes índices de claridade. Os resultados obtidos, em ambos os casos de estudo, foram analisados em termos de convergência, do valor do GMPP alcançado, do número de avaliações e do tempo de convergência.

5.1 Caso de Estudo 1: Variação da irradiância com sombreamento parcial

O primeiro caso de estudo considerou uma sequência de três cenários com grandes variações nos níveis de irradiância. A cada 35 segundos, uma célula PV de cada grupo foi submetida a condições de sombreamento de forma a polarizar os respectivos diodos *bypass*. Em particular, no primeiro cenário nenhuma célula do módulo PV foi sombreada, no segundo cenário 30% de uma célula PV no primeiro grupo foi sombreada e, finalmente, no terceiro cenário 30% de uma célula do primeiro grupo e 70% de uma célula do segundo grupo, foram sujeitas a condições de sombreamento.

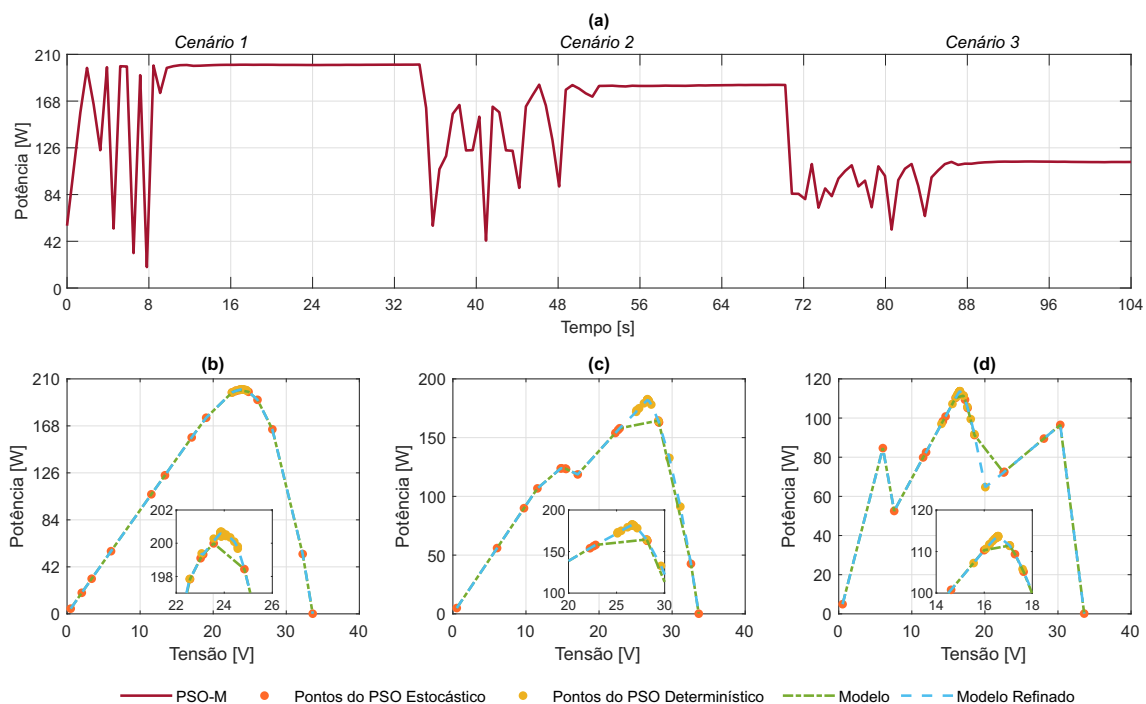


Figura 5.2: Resultados experimentais do PSO-M no primeiro caso de estudo: (a) Curva de convergência do PSO-M nos três cenários; (b), (c) e (d) Histórico das partículas e modelos do PSO-M nos três cenários, respetivamente.

Na Figura 5.2(a) é possível verificar que o PSO-M convergiu sempre para o GMPP nos três cenários. No primeiro cenário convergiu para 200 W, no segundo cenário para 181 W e no terceiro cenário para 113 W. O PSO-M avaliou 22, 32 e 31 vezes a função objetivo o que correspondeu a um tempo de convergência de 13.65, 20.8 e 20.15 segundos, respectivamente. O PSO-M apresentou um tempo de convergência relativamente baixo e com poucas oscilações durante a procura do GMPP, como se pode verificar na Figura 5.2(a). Nas Figuras 5.2(b), (c) e (d) são apresentadas a laranja e a amarelo o histórico do PSO Estocástico e do PSO Determinístico, respetivamente. Os modelos aproximados das curvas características P-V, com base no histórico do PSO Estocástico, são mostrados a verde tracejado. Por último, os modelos refinados das curvas características P-V gerados pela RBFNN, com base no histórico do PSO Estocástico e do PSO Determinístico, são apresentados a azul tracejado.

5.2 Caso de Estudo 2: Funcionamento em perfil *full day*

No segundo caso de estudo, o desempenho do PSO-M foi analisado durante 24 horas considerando diferentes índices de claridade. Em particular, foi considerado um cenário de operação real com um elevado índice de claridade (céu praticamente limpo) e, um segundo cenário real de operação, com um índice de claridade relativamente baixo, i.e., com períodos de nebulosidade no período da tarde. Além disso, para analisar com detalhe o desempenho do PSO-M também foram registadas as variações de irradiância e de temperatura durante as 24 horas correspondentes.




Figura 5.3: Resultados experimentais do PSO-M no segundo caso de estudo: (a) Curva de potência no primeiro dia; (b) Perfis de irradiância e temperatura no primeiro dia.

Na Figura 5.3(a) está representada a produção PV obtida no cenário de operação real com um elevado índice de claridade. A produção PV começou por volta das 5 horas e 45 minutos e terminou pelas 21 horas e 30 minutos. Podemos verificar que não ocorreu nenhuma reinicialização de todo o processo inerente ao PSO-M, visto que não houve grandes e repentinas variações na produção PV. No entanto, como é esperado, pequenos degraus/oscilações são visíveis na produção PV, pois reinicializações rápidas ocorreram durante toda produção PV por conta da variação lenta da irradiância. A Figura 5.3(b) apresenta os perfis de irradiância e de temperatura durante as 24 horas correspondentes.

Na Figura 5.4(a) está representada a produção PV obtida no cenário real de operação, com um índice de claridade relativamente baixo, i.e., com períodos de nebulosidade no período da tarde. A produção PV começou por volta das 5 horas e 30 minutos e terminou pelas 21 horas e 37 minutos. Podemos verificar que ocorreram muitas reinicializações totais do PSO-M entre as 12 h e as 17 h visto que houve grandes e repentinas variações na produção PV. No entanto, como é esperado, fora desses períodos pequenos degraus/oscilações são visíveis na curva, por ação das reinicializações rápidas. A Figura 5.4(b) apresenta os perfis de irradiância e de temperatura. É possível concluir que de facto existiu grandes variações dos níveis de irradiância entre as 12 h e 17 h. Em suma, o desempenho do PSO-M foi o esperado mesmo num cenário real de operação complexo, i.e., com um índice de claridade relativamente baixo.

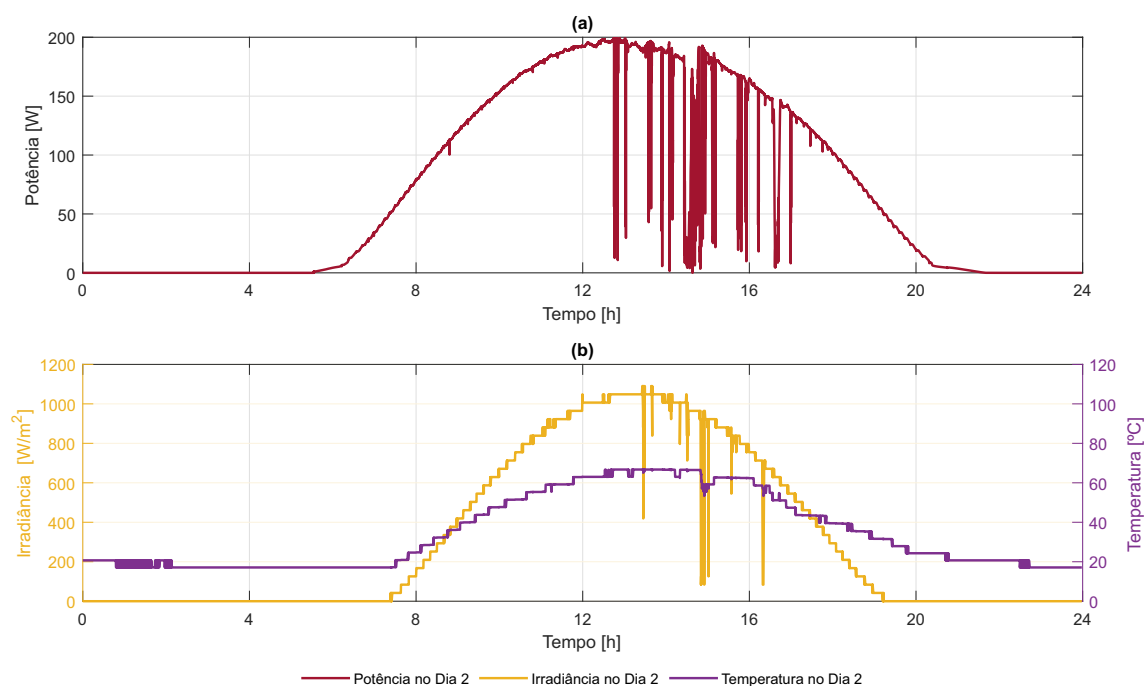


Figura 5.4: Resultados experimentais do PSO-M no segundo caso de estudo: (a) Curva de potência no segundo dia; (b) Perfis de irradiância e temperatura no segundo dia.

Capítulo 6

Conclusão

A energia PV é sem dúvida uma das fontes de energia elétrica com maior potencial de crescimento no futuro. Nos últimos anos, a produção PV apresentou a maior margem de crescimento a nível mundial, estando previsto que se torne na principal fonte renovável de energia elétrica. Embora a produção PV seja incentivada em todo o mundo, a mesma apresenta algumas desvantagens, tais como: o custo da instalação, a sua baixa eficiência de conversão de energia e, além disso, apresenta um comportamento elétrico não-linear entre a tensão e a corrente dependente das condições climáticas.

Para contornar o comportamento não-linear da curva característica I-V e maximizar a produção PV em todo o instante de tempo é necessário garantir que o sistema fotovoltaico opere no ponto de máxima potência disponível. Assim, o uso de controladores de MPPT é obrigatório em sistemas PV de forma a determinar esse ponto de funcionamento e retirar o máximo de potência disponível, independentemente das condições de operação do sistema fotovoltaico. Embora robustos em condições uniformes, os algoritmos clássicos de MPPT apresentam algumas desvantagens que limitam o seu desempenho e eficiência, como por exemplo: a sua dependência em relação à amplitude de perturbação, dificuldade em lidar com problemas não-lineares e também dificuldade na exploração do espaço de procura, elevado tempo de convergência e oscilações estacionárias em torno do MPP. Para superar estas desvantagens dos algoritmos clássicos de MPPT, têm sido propostos na literatura especializada diversos algoritmos de MPPT com base em algoritmos de otimização meta-heurísticos. Estes algoritmos avançados, devido à sua robustez, flexibilidade, confiabilidade e capacidade de lidar com problemas não-lineares, são altamente eficientes para procurar e localizar o GMPP, sob condições de sombreamento parcial complexas.

A presente dissertação propôs um novo algoritmo de MPPT que combina as especificidades do PSO Estocástico e do PSO Determinístico de forma a aumentar a eficiência dos algoritmos de MPPT diminuindo o tempo de convergência e as oscilações na procura do GMPP. O principal fator diferenciador deste novo algoritmo é a utilização de uma Radial Basis Function Neural Network com o objetivo de construir modelos aproximados das curvas características I-V e P-V. Estes modelos aproximados permitem analisar, monitorizar e diagnosticar problemas ou avarias na instalação PV em tempo real. Mas a principal função deles é identificar as regiões promissoras, i.e., a região ou área onde se encontra o máximo global e/ou máximos locais em caso de sombreamento parcial. Uma vez identificadas e definidas essas regiões, as partículas são reposicionadas, e é acionado o PSO Determinístico para evitar um comportamento das partículas divergente e repetitivo, diminuindo assim o tempo de convergência e as oscilações na procura do GMPP.

Para validar o algoritmo proposto foram criados quatro casos de estudo: dois implementados em ambiente de simulação e dois casos de estudo implementados em ambiente real. O desempenho do algoritmo proposto foi comparado com o algoritmo clássico de MPPT perturba e observa (P&O) e com diferentes algoritmos de MPPT meta-heurísticos nomeadamente, o DE, GWO e PSOC. Os resultados mostram que o algoritmo proposto superou os algoritmos considerados em termos de taxa de sucesso, tempo de procura, eficiência e robustez. O algoritmo proposto conseguiu alcançar o GMPP com uma taxa de sucesso de 100%. Quando comparado com os restantes algoritmos de MPPT implementados, o algoritmo proposto apresentou um tempo de procura mais rápido (52-93%) e com menos oscilações durante a procura do ponto de máxima potência. Além disso, o algoritmo proposto apresentou uma eficiência superior (1-2%) quando comparado com os diversos algoritmos de MPPT implementados. Portanto, pode-se concluir que o algoritmo proposto apresenta um alto desempenho na procura do GMPP em condições uniformes ou não-uniformes, nomeadamente em condições de sombreamento parcial complexas.

Referências Bibliográficas

- [1] J. Li, X. Zhang, S. Ali, and Z. Khan, “Eco-innovation and energy productivity: New determinants of renewable energy consumption,” *Journal of Environmental Management*, vol. 271, p. 111028, 10 2020. 1
- [2] H. Zheng, M. Song, and Z. Shen, “The evolution of renewable energy and its impact on carbon reduction in china,” *Energy*, vol. 237, p. 121639, 12 2021. 1
- [3] T. S. Adebayo and D. Kirikkaleli, “Impact of renewable energy consumption, globalization, and technological innovation on environmental degradation in japan: application of wavelet tools,” *Environment, Development and Sustainability*, vol. 23, pp. 16 057–16 082, 11 2021. 1
- [4] M. W. Zafar, M. Shahbaz, A. Sinha, T. Sengupta, and Q. Qin, “How renewable energy consumption contribute to environmental quality? the role of education in oecd countries,” *Journal of Cleaner Production*, vol. 268, p. 122149, 9 2020. 1
- [5] C. Fetting, “The european green deal,” 2020. 1
- [6] P. A. Owusu and S. Asumadu-Sarkodie, “A review of renewable energy sources, sustainability issues and climate change mitigation,” vol. 3, 2016. 1
- [7] E. Kandemir, N. S. Cetin, and S. Borekci, “A comprehensive overview of maximum power extraction methods for pv systems,” *Renewable and Sustainable Energy Reviews*, vol. 78, pp. 93–112, 10 2017. 1, 2
- [8] R. Venkateswari and S. Sreejith, “Factors influencing the efficiency of photovoltaic system,” *Renewable and Sustainable Energy Reviews*, vol. 101, pp. 376–394, 3 2019. 2
- [9] A. R. Jordehi, “Maximum power point tracking in photovoltaic (pv) systems: A review of different approaches,” *Renewable and Sustainable Energy Reviews*, vol. 65, pp. 1127–1138, 11 2016. 2
- [10] A. O. Baba, G. Liu, and X. Chen, “Classification and evaluation review of maximum power point tracking methods,” *Sustainable Futures*, vol. 2, p. 100020, 1 2020. 2, 4
- [11] N. Karami, N. Moubayed, and R. Outbib, “General review and classification of different mppt techniques,” *Renewable and Sustainable Energy Reviews*, vol. 68, pp. 1–18, 2 2017. 2, 3
- [12] T. Noguchi, S. Togashi, and R. Nakamoto, “Short-current pulse-based maximum-power-point tracking method for multiple photovoltaic-and-converter module system,” *IEEE Transactions on Industrial Electronics*, vol. 49, pp. 217–223, 2 2002. 2
- [13] D. Baimel, S. Tapuchi, Y. Levron, and J. Belikov, “Improved fractional open circuit

- voltage mppt methods for pv systems,” *Electronics 2019, Vol. 8, Page 321*, vol. 8, p. 321, 3 2019. 2
- [14] L. E. Mentaly, A. Amghar, and H. Sahсах, “Comparison between hc, focv and tg mppt algorithms for pv solar systems using buck converter,” *2017 International Conference on Wireless Technologies, Embedded and Intelligent Systems (WITS)*, pp. 1–5, 4 2017. 2
- [15] R. Faranda, S. Leva, and V. Maugeri, “Mppt techniques for pv systems: Energetic and cost comparison,” *IEEE Power and Energy Society 2008 General Meeting: Conversion and Delivery of Electrical Energy in the 21st Century, PES*, 2008. 2
- [16] K. Kobayashi, H. Matsuo, and Y. Sekine, “An excellent operating point tracker of the solar-cell power supply system,” *IEEE Transactions on Industrial Electronics*, vol. 53, pp. 495–499, 4 2006. 2
- [17] V. R. Kota and M. N. Bhukya, “A simple and efficient mppt scheme for pv module using 2-dimensional lookup table,” *2016 IEEE Power and Energy Conference at Illinois, PECCI 2016*, 4 2016. 3
- [18] C. T. Pan, J. Y. Chen, C. P. Chu, and Y. S. Huang, “Fast maximum power point tracker for photovoltaic power systems,” *IECON Proceedings (Industrial Electronics Conference)*, vol. 1, pp. 390–393, 1999. 3
- [19] M. Sarvi and A. Azadian, “A comprehensive review and classified comparison of mppt algorithms in pv systems,” *Energy Systems*, vol. 13, pp. 281–320, 5 2022. 3
- [20] P. T. szemes and M. Melhem, “Analyzing and modeling pv with “p&o” mppt algorithm by matlab/simulink,” *2020 3rd International Symposium on Small-scale Intelligent Manufacturing Systems (SIMS)*, pp. 1–6, 6 2020. 3
- [21] J. J. Nedumgatt, K. B. Jayakrishnan, S. Umashankar, D. Vijayakumar, and D. P. Kothari, “Perturb and observe mppt algorithm for solar pv systems-modeling and simulation,” *Proceedings - 2011 Annual IEEE India Conference: Engineering Sustainable Solutions, INDICON-2011*, 2011. 3
- [22] N. Femia, G. Petrone, G. Spagnuolo, and M. Vitelli, “Optimization of perturb and observe maximum power point tracking method,” *IEEE Transactions on Power Electronics*, vol. 20, pp. 963–973, 7 2005. 3
- [23] X. Liu and L. A. Lopes, “An improved perturbation and observation maximum power point tracking algorithm for pv arrays,” *PESC Record - IEEE Annual Power Electronics Specialists Conference*, vol. 3, pp. 2005–2010, 2004. 3
- [24] N. Femia, G. Petrone, G. Spagnuolo, and M. Vitelli, “Optimizing duty-cycle perturbation of p&o mppt technique,” *PESC Record - IEEE Annual Power Electronics Specialists Conference*, vol. 3, pp. 1939–1944, 2004. 3
- [25] T. Esram and P. L. Chapman, “Comparison of photovoltaic array maximum power

- point tracking techniques,” *IEEE Transactions on Energy Conversion*, vol. 22, pp. 439–449, 6 2007. 3
- [26] K. S. Tey and S. Mekhilef, “Modified incremental conductance mppt algorithm to mitigate inaccurate responses under fast-changing solar irradiation level,” *Solar Energy*, vol. 101, pp. 333–342, 3 2014. 3
- [27] S. Necaibia, M. S. Kelaiaia, H. Labar, A. Necaibia, and E. D. Castronuovo, “Enhanced auto-scaling incremental conductance mppt method, implemented on low-cost microcontroller and sepic converter,” *Solar Energy*, vol. 180, pp. 152–168, 3 2019. 3
- [28] S. Jain and V. Agarwal, “A new algorithm for rapid tracking of approximate maximum power point in photovoltaic systems,” *IEEE Power Electronics Letters*, vol. 2, pp. 16–19, 3 2004. 3
- [29] X. Li, H. Wen, L. Jiang, W. Xiao, Y. Du, and C. Zhao, “An improved mppt method for pv system with fast-converging speed and zero oscillation,” *IEEE Transactions on Industry Applications*, vol. 52, pp. 5051–5064, 11 2016. 3
- [30] M. A. D. Brito, L. P. Sampaio, G. Luigi, G. A. E. Melo, and C. A. Canesin, “Comparative analysis of mppt techniques for pv applications,” *3rd International Conference on Clean Electrical Power: Renewable Energy Resources Impact, ICCEP 2011*, pp. 99–104, 2011. 3
- [31] S. M. Ferdous, G. M. Shafiullah, M. A. M. Oninda, M. A. Shoeb, and T. Jamal, “Close loop compensation technique for high performance mppt using ripple correlation control,” *2017 Australasian Universities Power Engineering Conference, AUPEC 2017*, vol. 2017-November, pp. 1–6, 2 2018. 3
- [32] A. Trivedi, A. Gupta, R. K. Pachauri, and Y. K. Chauhan, “Comparison of perturb & observe and ripple correlation control mppt algorithms for pv array,” *1st IEEE International Conference on Power Electronics, Intelligent Control and Energy Systems, ICPEICES 2016*, 2 2017. 3
- [33] M. Mao, L. Cui, Q. Zhang, K. Guo, L. Zhou, and H. Huang, “Classification and summarization of solar photovoltaic mppt techniques: A review based on traditional and intelligent control strategies,” *Energy Reports*, vol. 6, pp. 1312–1327, 11 2020. 4
- [34] S. Issaadi, W. Issaadi, and A. Khireddine, “New intelligent control strategy by robust neural network algorithm for real time detection of an optimized maximum power tracking control in photovoltaic systems,” *Energy*, vol. 187, p. 115881, 11 2019. 4
- [35] L. Bouselham, M. Hajji, B. Hajji, and H. Bouali, “A new mppt-based ann for photovoltaic system under partial shading conditions,” *Energy Procedia*, vol. 111, pp. 924–933, 3 2017. 4
- [36] S. Messalti, A. Harrag, and A. Loukriz, “A new variable step size neural networks

- mppt controller: Review, simulation and hardware implementation,” *Renewable and Sustainable Energy Reviews*, vol. 68, pp. 221–233, 2 2017. 4
- [37] M. M. Algazar, H. Al-Monier, H. A. El-Halim, and M. E. E. K. Salem, “Maximum power point tracking using fuzzy logic control,” *International Journal of Electrical Power & Energy Systems*, vol. 39, pp. 21–28, 7 2012. 4
- [38] M. Rakhshan, N. Vafamand, M. H. Khooban, and F. Blaabjerg, “Maximum power point tracking control of photovoltaic systems: A polynomial fuzzy model-based approach,” *IEEE Journal of Emerging and Selected Topics in Power Electronics*, vol. 6, pp. 292–299, 3 2018. 4
- [39] A. Messai, A. Mellit, P. A. Massi, A. Guessoum, and H. Mekki, “Fpga-based implementation of a fuzzy controller (mppt) for photovoltaic module,” *Energy Conversion and Management*, vol. 52, pp. 2695–2704, 7 2011. 4
- [40] A. F. Mirza, M. Mansoor, Q. Ling, B. Yin, and M. Y. Javed, “A salp-swarm optimization based mppt technique for harvesting maximum energy from pv systems under partial shading conditions,” *Energy Conversion and Management*, vol. 209, p. 112625, 4 2020. 4
- [41] A. Fathy, “Butterfly optimization algorithm based methodology for enhancing the shaded photovoltaic array extracted power via reconfiguration process,” *Energy Conversion and Management*, vol. 220, p. 113115, 9 2020. 4
- [42] M. Mansoor, A. F. Mirza, Q. Ling, and M. Y. Javed, “Novel grass hopper optimization based mppt of pv systems for complex partial shading conditions,” *Solar Energy*, vol. 198, pp. 499–518, 3 2020. 4
- [43] A. M. Agwa, A. A. El-Fergany, and H. A. Maksoud, “Electrical characterization of photovoltaic modules using farmland fertility optimizer,” *Energy Conversion and Management*, vol. 217, p. 112990, 8 2020. 4
- [44] M. Mansoor, A. F. Mirza, and Q. Ling, “Harris hawk optimization-based mppt control for pv systems under partial shading conditions,” *Journal of Cleaner Production*, vol. 274, p. 122857, 11 2020. 4
- [45] A. M. Eltamaly, “An improved cuckoo search algorithm for maximum power point tracking of photovoltaic systems under partial shading conditions,” *Energies 2021, Vol. 14, Page 953*, vol. 14, p. 953, 2 2021. 4
- [46] K. Guo, L. Cui, M. Mao, L. Zhou, and Q. Zhang, “An improved gray wolf optimizer mppt algorithm for pv system with bfbic converter under partial shading,” *IEEE Access*, vol. 8, pp. 103 476–103 490, 2020. 4
- [47] M. Xiang, J. Duan, X. Wang, T. Song, Y. Wang, and T. Song, “Research of photovoltaic systems mppt based on improved grey wolf algorithm under partial shading conditions,” *2nd IEEE Conference on Energy Internet and Energy System Integra-*

tion, *EI2 2018 - Proceedings*, 12 2018. 4

- [48] N. Priyadarshi, V. K. Ramachandaramurthy, S. Padmanaban, and F. Azam, "An ant colony optimized mppt for standalone hybrid pv-wind power system with single cuk converter," *Energies 2019, Vol. 12, Page 167*, vol. 12, p. 167, 1 2019. 4
- [49] A. M. Eltamaly, M. S. Al-Saud, and A. G. Abokhalil, "A novel bat algorithm strategy for maximum power point tracker of photovoltaic energy systems under dynamic partial shading," *IEEE Access*, vol. 8, pp. 10 048–10 060, 2020. 4
- [50] A. M. Eltamaly, M. S. Al-Saud, A. G. Abokhalil, and H. M. Farh, "Simulation and experimental validation of fast adaptive particle swarm optimization strategy for photovoltaic global peak tracker under dynamic partial shading," *Renewable and Sustainable Energy Reviews*, vol. 124, p. 109719, 5 2020. 4
- [51] P. Zhang and H. Sui, "Maximum power point tracking technology of photovoltaic array under partial shading based on adaptive improved differential evolution algorithm," *Energies 2020, Vol. 13, Page 1254*, vol. 13, p. 1254, 3 2020. 4
- [52] M. A. Ramli, K. Ishaque, F. Jawaaid, Y. A. Al-Turki, and Z. Salam, "A modified differential evolution based maximum power point tracker for photovoltaic system under partial shading condition," *Energy and Buildings*, vol. 103, pp. 175–184, 9 2015. 4
- [53] T. Chakrabarti, U. Sharma, S. Manna, T. Chakrabarti, and S. K. Sarkar, "Design of intelligent maximum power point tracking (mppt) technique based on swarm intelligence based algorithms," *Proceedings of the 2015 IEEE International Conference on Power and Advanced Control Engineering, ICPACE 2015*, pp. 173–177, 9 2015. 4
- [54] D. Pilakkat and S. Kanthalakshmi, "An improved p&o algorithm integrated with artificial bee colony for photovoltaic systems under partial shading conditions," *Solar Energy*, vol. 178, pp. 37–47, 1 2019. 4
- [55] M. Seyedmahmoudian, R. Rahmani, S. Mekhilef, A. M. T. Oo, A. Stojcevski, T. K. Soon, and A. S. Ghandhari, "Simulation and hardware implementation of new maximum power point tracking technique for partially shaded pv system using hybrid depso method," *IEEE Transactions on Sustainable Energy*, vol. 6, pp. 850–862, 7 2015. 5
- [56] D. K. Mathi and R. Chinthamalla, "A hybrid global maximum power point tracking of partially shaded pv system under load variation by using adaptive salp swarm and differential evolution – perturb & observe technique," vol. 43, pp. 2471–2495, 2020. 5
- [57] V. J. Chin, Z. Salam, and K. Ishaque, "Cell modelling and model parameters estimation techniques for photovoltaic simulator application: A review," *Applied Energy*, vol. 154, pp. 500–519, 9 2015. 7, 8

- [58] H. G. Nunes, J. A. Pombo, P. M. Bento, S. J. Mariano, and M. R. Calado, "Collaborative swarm intelligence to estimate pv parameters," *Energy Conversion and Management*, vol. 185, pp. 866–890, 4 2019. 7, 9, 10, 11, 12, 13, 16
- [59] H. G. Nunes, J. A. Pombo, S. J. Mariano, M. R. Calado, and J. A. F. de Souza, "A new high performance method for determining the parameters of pv cells and modules based on guaranteed convergence particle swarm optimization," *Applied Energy*, vol. 211, pp. 774–791, 2 2018. 9, 16
- [60] A. M. Ajmal, T. S. Babu, V. K. Ramachandaramurthy, D. Yousri, and J. B. Ekanayake, "Static and dynamic reconfiguration approaches for mitigation of partial shading influence in photovoltaic arrays," *Sustainable Energy Technologies and Assessments*, vol. 40, p. 100738, 8 2020. 11
- [61] B. Yang, T. Zhu, J. Wang, H. Shu, T. Yu, X. Zhang, W. Yao, and L. Sun, "Comprehensive overview of maximum power point tracking algorithms of pv systems under partial shading condition," *Journal of Cleaner Production*, vol. 268, p. 121983, 9 2020. 11
- [62] J. C. Teo, R. H. Tan, V. H. Mok, V. K. Ramachandaramurthy, and C. K. Tan, "Impact of bypass diode forward voltage on maximum power of a photovoltaic system under partial shading conditions," *Energy*, vol. 191, p. 116491, 1 2020. 11
- [63] J. Ma, D. Hong, K. Wang, Z. Bi, X. Zhu, and J. Zhang, "Analytical modeling and parameter estimation of photovoltaic strings under partial shading conditions," *Solar Energy Materials and Solar Cells*, vol. 235, p. 111494, 1 2022. 11
- [64] A. Wang and Y. Xuan, "Close examination of localized hot spots within photovoltaic modules," *Energy Conversion and Management*, vol. 234, p. 113959, 4 2021. 11
- [65] J. Kennedy and R. Eberhart, "Particle swarm optimization," *Proceedings of ICNN'95 - International Conference on Neural Networks*, vol. 4, pp. 1942–1948. 15
- [66] Y. Fan, P. Wang, A. A. Heidari, H. Chen, HamzaTurabieh, and M. Mafarja, "Random reselection particle swarm optimization for optimal design of solar photovoltaic modules," *Energy*, vol. 239, p. 121865, 1 2022. 15
- [67] F. Wang, H. Zhang, and A. Zhou, "A particle swarm optimization algorithm for mixed-variable optimization problems," *Swarm and Evolutionary Computation*, vol. 60, p. 100808, 2 2021. 15
- [68] J. B. Fermeiro, J. A. Pombo, M. R. Calado, and S. J. Mariano, "A new controller for dc-dc converters based on particle swarm optimization," *Applied Soft Computing*, vol. 52, pp. 418–434, 3 2017. 16
- [69] J. Liang, S. Ge, B. Qu, K. Yu, F. Liu, H. Yang, P. Wei, and Z. Li, "Classified perturbation mutation based particle swarm optimization algorithm for parameters extraction of photovoltaic models," *Energy Conversion and Management*, vol. 203, p.

- [70] R. Kumar, “Fuzzy particle swarm optimization control algorithm implementation in photovoltaic integrated shunt active power filter for power quality improvement using hardware-in-the-loop,” *Sustainable Energy Technologies and Assessments*, vol. 50, p. 101820, 3 2022. 16
- [71] F. V. den Bergh and A. P. Engelbrecht, “A new locally convergent particle swarm optimiser,” *Proceedings of the IEEE International Conference on Systems, Man and Cybernetics*, vol. 3, pp. 94–99, 2002. 17
- [72] A. R. Jordehi, “Enhanced leader particle swarm optimisation (elpso): An efficient algorithm for parameter estimation of photovoltaic (pv) cells and modules,” *Solar Energy*, vol. 159, pp. 78–87, 1 2018. 17
- [73] E. García-Gonzalo and J. L. Fernández-Martínez, “Convergence and stochastic stability analysis of particle swarm optimization variants with generic parameter distributions,” *Applied Mathematics and Computation*, vol. 249, pp. 286–302, 12 2014. 17
- [74] I. C. Trelea, “The particle swarm optimization algorithm: convergence analysis and parameter selection,” *Information Processing Letters*, vol. 85, pp. 317–325, 3 2003. 17
- [75] T. Braconnier, M. Ferrier, J. C. Jouhaud, M. Montagnac, and P. Sagaut, “Towards an adaptive pod/svd surrogate model for aeronautic design,” *Computers & Fluids*, vol. 40, pp. 195–209, 1 2011. 21
- [76] J. Zhang, S. Chowdhury, and A. Messac, “An adaptive hybrid surrogate model,” *Structural and Multidisciplinary Optimization*, vol. 46, pp. 223–238, 8 2012. 21
- [77] J. T. Hwang and J. R. Martins, “A fast-prediction surrogate model for large datasets,” *Aerospace Science and Technology*, vol. 75, pp. 74–87, 4 2018. 21
- [78] M. Rashki, H. Azarkish, M. Rostamian, and A. Bahrpeyma, “Classification correction of polynomial response surface methods for accurate reliability estimation,” *Structural Safety*, vol. 81, p. 101869, 11 2019. 21
- [79] I. Kaymaz, “Application of kriging method to structural reliability problems,” *Structural Safety*, vol. 27, pp. 133–151, 4 2005. 21
- [80] D. Zhang, N. Zhang, N. Ye, J. Fang, and X. Han, “Hybrid learning algorithm of radial basis function networks for reliability analysis,” *IEEE Transactions on Reliability*, vol. 70, pp. 887–900, 9 2021. 21
- [81] M. Sharifzadeh, A. Sikinioti-Lock, and N. Shah, “Machine-learning methods for integrated renewable power generation: A comparative study of artificial neural networks, support vector regression, and gaussian process regression,” *Renewable and Sustainable Energy Reviews*, vol. 108, pp. 513–538, 7 2019. 21

- [82] A. H. Fath, F. Madanifar, and M. Abbasi, "Implementation of multilayer perceptron (mlp) and radial basis function (rbf) neural networks to predict solution gas-oil ratio of crude oil systems," *Petroleum*, vol. 6, pp. 80–91, 3 2020. 21
- [83] D. Karamichailidou, V. Kaloutsas, and A. Alexandridis, "Wind turbine power curve modeling using radial basis function neural networks and tabu search," *Renewable Energy*, vol. 163, pp. 2137–2152, 1 2021. 21
- [84] J. Määttä, V. Bazaliy, J. Kimari, F. Djurabekova, K. Nordlund, and T. Roos, "Gradient-based training and pruning of radial basis function networks with an application in materials physics," *Neural Networks*, vol. 133, pp. 123–131, 1 2021. 21
- [85] Z. Zainuddin and O. Pauline, "Function approximation using artificial neural networks." 22
- [86] F. Schwenker, H. A. Kestler, and G. Palm, "Three learning phases for radial-basis-function networks," *Neural Networks*, vol. 14, pp. 439–458, 5 2001. 23
- [87] M. V. da Rocha, L. P. Sampaio, and S. A. O. da Silva, "Comparative analysis of mppt algorithms based on bat algorithm for pv systems under partial shading condition," *Sustainable Energy Technologies and Assessments*, vol. 40, p. 100761, 8 2020. 28

Anexo A - Artigo Científico

Publicação de Artigo Científico em Conferência
Internacional

Comparative study of MPPT metaheuristics for PV systems under partial shading conditions

H.G.G. Nunes
University of Beira Interior
and IT - Instituto de Telecomunicações
Covilhã, Portugal
hugo.nunes@ubi.pt

D.M.R. Duarte
University of Beira Interior
and IT - Instituto de Telecomunicações
Covilhã, Portugal
diogo.miguel.duarte@ubi.pt

J.A.N. Pombo
University of Beira Interior
and IT - Instituto de Telecomunicações
Covilhã, Portugal
jose.pombo@ubi.pt

S.J.P.S. Mariano
University of Beira Interior
and IT - Instituto de Telecomunicações
Covilhã, Portugal
sm@ubi.pt

M.R.A. Calado
University of Beira Interior
and IT - Instituto de Telecomunicações
Covilhã, Portugal
rc@ubi.pt

Abstract—Given the rapidly changing operating conditions of photovoltaic (PV) systems, the maximum power point tracking (MPPT) controllers that respond quickly to adverse operating conditions are crucial. The design of those controllers is considered a complex task and several approaches have been proposed. In this paper different MPPT controllers via metaheuristic algorithm for PV systems are compared. With the purpose of evaluate the performance of MPPT controllers that use evolutionary, physics-based, swarm-based, and human-based metaheuristic algorithms to reach the global maximum power point (GMPP), a comparative study of eight MPPT metaheuristics was carried out under partial shading conditions (PSC), considering the number of evaluations, tracking time, efficiency and successful rate. The classical perturb and observe (P&O) method was also considered for comparative purposes. For the simulation analysis three case studies under partial shading with different complexity (multiple power peaks) were considered. Overall, the results showed that MPPT metaheuristics perform very competitively to find the GMPP. Moreover, considering the several indicators, evolutionary and swarm-based metaheuristic algorithms showed the best performance, namely particle swarm optimization (PSO).

Keywords—maximum power point tracking, metaheuristic algorithms, MPPT controller, partial shading, PV system

I. INTRODUCTION

To maximize the conversion efficiency of a photovoltaic (PV) system, it is necessary to extract the maximum power available at every moment, operating the system at maximum power point (MPP). However, PV modules are greatly affected by external environment factors, such as irradiance, temperature, weather conditions and shadows. These external factors impose a non-linear voltage-current characteristic resulting in low conversion efficiency of PV system [1]. To overcome this issue and to ensure that the system operates at the MPP it is mandatory the use of maximum power point tracking (MPPT) controllers [2], [3]. There are several MPPT controllers in the literature which can be roughly divided into conventional and metaheuristics (advanced methods), or even hybrids that combine both [4]. Conventional MPPT controllers can be subdivided into indirect and direct [5]. Indirect MPPT controllers, such as open-circuit and short-circuit methods [6], require a prior knowledge of the PV system characteristics or are based on mathematical relationships that do not meet all weather conditions [7]. On the other hand, direct MPPT controllers do not require a prior knowledge of the PV system and work under any weather condition. The perturb and observe (P&O) [8] and incremental

conductance (IC) [9] are among the most used direct MPPT controllers. Other commonly used methods use parasitic capacitance, constant voltage and constant current [4]. However, conventional MPPT controllers have many difficulties in reaching the global maximum power point (GMPP) under partial shading conditions (PSC). Particularly, in the presence of complex shading patterns with several local maximum power points (LMPPs) that translate the multiple power peaks resulting from the activation of bypass diodes. Regarding the metaheuristic MPPT controllers, there are numerous approaches in the literature based on soft computing, nature-inspired or artificial intelligence. These approaches are relatively complex and have superior tracking performance when compared with conventional methods [4]. Due to their ability to handle complex and multimodal problems (non-linear), robustness, flexibility and reliability, they can be highly suitable for GMPP tracking in PV systems under PSC. In recent years, they have been preferred by many researchers to track GMPP. Some successful metaheuristics include search and rescue (SRA) optimization algorithm [10], improved squirrel search algorithm (ISSA) [11], horse herd optimization algorithm (HOA) [12], chaotic flower pollination algorithm (C-FPA) [13], social group optimization (SGO) [14] and Harris hawk optimization (HHO) [15]. Despite their relevance to track GMPP, metaheuristic MPPT controllers can converge in LMPPs and require an unsuitable computational cost. To overcome these drawbacks some researchers have adopted hybrid MPPT controllers. For example, in [16] an improved P&O assisted by ant-colony optimization (ACO) was developed. In [17] an enhanced leader particle swarm optimization (ELPSO) assisted by P&O was used. And in [18], P&O assisted flower pollination algorithm (FPA) was proposed to ensure operation in GMPP. Tracking in real-time GMPP with accuracy and reliability is still a challenge for many researchers, specifically under rapid irradiance variations. Therefore, robust MPPT controllers are really needed to operate PV systems in GMPP.

This paper assesses the performance of metaheuristic MPPT controllers to track GMPP considering eight distinct nature-inspired metaheuristic algorithms and classified in four groups: evolutionary, physics-based, swarm-based and human-based. The main contribution is a comparative study of the different metaheuristics to help other researchers in the future to choose an accurate and reliable method to track the GMPP. The comparative study was carried out under different PSC scenarios, and considered the number of evaluations, tracking time, efficiency and successful rate. P&O controller was also considered for comparative purposes. Three case studies with different PSC scenarios were simulated, and the

This work is funded by FCT/MCTES through national funds and when applicable co-funded EU funds under the project UIDB/50008/2020.