

Uma breve revisão sobre métodos Meta-Heurísticos para a extração dos parâmetros Fotovoltaicos

Henrique Manuel Reis Patrício

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

Orientador: Prof. Doutor José Álvaro Nunes Pombo

outubro de 2022

Declaração de Integridade

Eu, Henrique Manuel Reis Patrício, que abaixo assino, estudante com o número de inscrição M10235 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

Henrique Manuel Reis Patrício

Agradecimentos

Em primeiro lugar um agradecimento especial aos meus pais e aos meus avós por toda a educação que me foi transmitida e por todo apoio que me foi dado. Agradeço também a toda a minha família pelo apoio e por todas as lições de vida que me foram dadas ao longo da minha vida.

Agradeço também as meus colegas de casa Bruno Gomes, João Portugal e Rui Charrinho pelos anos passados juntos cheios de desafios, brincadeiras e companheirismo.

Um agradecimento especial ao Hugo Antunes, Ricardo Mesquita, João Dinis; Virgílio Cruz, Diogo Verde, Renato Farinha e Francisco Rabaça pelos ensinamentos e ajuda durante o nosso percurso académico.

Um agradecimento especial, à Universidade da Beira Interior, à Faculdade de Engenharia e ao laboratório Power Systems por toda a ajuda prestada nestes anos.

A presente dissertação constituiu o maior desafio de todo o meu percurso académico, a qual só foi possível graças ao prestimoso apoio e conselhos de diversas pessoas.

Um agradecimento especial ao meu orientador, Professor Doutor José Álvaro Nunes Pombo pela ajuda na realização da presente dissertação.

Resumo

As mudanças climáticas, o aumento da poluição e as crescentes preocupações ambientais colocam a humanidade diante de um problema energético. É nesse contexto que as energias renováveis assumem um papel fundamental para alcançar a neutralidade carbónica. Assim, para reduzir a utilização dos combustíveis fósseis é indispensável que as fontes de energia renovável se afirmem como uma solução vantajosa e viável para a produção de energia elétrica. Este aumento de produção de energia elétrica a partir de fontes renováveis é vital para se cumprirem os vários acordos mundiais e europeus que foram assinados com o propósito de atingir os desígnios assinados. A fonte de energia renovável com o maior potencial no futuro é a energia solar. No entanto, para esta energia se consolidar é necessário que as tecnologias fotovoltaicas sejam mais eficientes.

A presente dissertação tem como objetivo analisar uma série de fatores que influenciam a determinação dos parâmetros e que caracterizam os respetivos modelos matemáticos. Concretamente, os fatores determinantes que foram analisados foram: os modelos matemáticos, as tecnologias PV, os métodos/algoritmos de otimização que foram utilizados para simular o comportamento de uma célula ou módulo fotovoltaico e, por último, a técnica aplicada para contornar a natureza implícita das equações que caracterizam o respetivo modelo fotovoltaico.

Palavras-chave

Energia renovável, Produção de energia, Tecnologias fotovoltaicas, Modelos matemáticos, Métodos Meta-heurísticos.

Abstract

Climate change, the increasing pollution, and growing environmental concerns place humanity in the face of an energetic problem. In this context, renewable energies play a key role in achieving carbon neutrality. Thus, in order to reduce the use of fossil fuels it is essential that renewable energy sources establish themselves as an advantageous and viable solution for the production of electricity. Increasing the production of electrical energy from renewable sources is crucial to meet the various global and European agreements that have been signed aiming the achievement of the proposed objectives. The renewable energy source with the highest potential for the future is solar energy. However, to consolidate this energy, photovoltaic technologies must be more efficient.

The present dissertation aims to analyse a series of factors that influence the determination of the parameters that characterize the respective mathematical models. Specifically, the determining factors that have been analysed are: the mathematical models, the PV technologies, the optimization methods/algorithms that were used to simulate the behavior of a photovoltaic cell or module, and the technique applied to avoid the implicit nature of the equations that characterize the respective photovoltaic model.

Keywords

Renewable energy, Energy production, Photovoltaic technologies, Mathematical models, Meta-heuristic methods.

Índice

Capítulo 1.....	1
1. Introdução	1
1.1. Enquadramento	1
1.2. Motivação e objetivos.....	4
1.3. Organização da dissertação.....	4
Capítulo 2	6
2. Modelos matemáticos.....	6
2.1. Modelo de um díodo (SDM)	6
2.2. Modelo de dois díodos (DDM).....	8
2.3. Modelo de três díodos (TDM)	8
2.4. Formulação do Problema.....	9
Capítulo 3	11
3. Algoritmos Meta-heurísticos.....	11
3.1. Algoritmos Evolucionários.....	12
3.1.1. <i>Diferencial Evolution</i>	12
3.1.2. <i>Jaya algorithm</i>	14
3.1.3. <i>Rao algorithm</i>	16
3.1.4. Revisão da literatura dos algoritmos evolucionários	18
3.2. Algoritmos de <i>swarm</i>	21
3.2.1. <i>Particle Swarm Optimizacion</i>	21
3.2.2. <i>Grey wolf optimizer</i>	23
3.2.3. <i>Flower Pollination Algorithm</i>	25
3.2.4. <i>Whale Optimization Algorithm</i>	27
3.3. Algoritmos baseados nos humanos	33
3.3.1. <i>Teaching-Learning-Based Optimization</i>	33
3.3.2. <i>Learning Search Algorithm</i>	35
3.3.3. <i>Gaining-Sharing Knowledgege</i>	38
3.3.4. Revisão da literatura dos algoritmos baseados nos humanos.....	40
3.4. Algoritmos baseados em fenómenos físicos.....	43
3.4.1. <i>Wind Driven Optimizacion</i>	43
3.4.2. <i>Equilibrium optimizer</i>	45
3.4.3. <i>Gravitational seach algorithm</i>	48
3.4.4. Revisão da literatura dos algoritmos físicos	51
3.5. Algoritmos meta-heurísticos híbridos	53
3.5.1. Revisão da literatura dos Outros Algorithm.....	55
Capítulo 4	59
4. Análise e conclusões da revisão bibliográfica	59
Referências	63

Lista de Figuras

Figura 2. 1 - Circuito equivalente do modelo de um díodo (SDM).....	7
Figura 2. 2 - Circuito equivalente do modelo de dois díodos (DDM).....	8
Figura 2. 3 - Circuito equivalente do modelo de três díodos (TDM).....	9
Figura 3. 1 – Fluxograma do algoritmo DE	14
Figura 3. 2 – Fluxograma do algoritmo Jaya	16
Figura 3. 3 – Fluxograma do algoritmo Rao 1,2,3	18
Figura 3. 4 – Fluxograma do algoritmo PSO	22
Figura 3. 5 – Fluxograma do algoritmo Grey Wolf.....	25
Figura 3. 6 – Fluxograma do algoritmo FPA.....	27
Figura 3. 7 – Fluxograma do algoritmo WOA	30
Figura 3. 8 – Fluxograma do algoritmo TLBO	35
Figura 3. 9 – Fluxograma do algoritmo LSA	37
Figura 3. 10 – Fluxograma do algoritmo GSK.....	40
Figura 3. 11 – Fluxograma do algoritmo WDO.....	45
Figura 3. 12 – Fluxograma do algoritmo EO	48
Figura 3. 13 – Fluxograma do algoritmo GSA	51
Figura 4. 1 - Percentagem de utilização dos modelos matemáticos.	60
Figura 4. 2 - Percentagem de utilização das tecnologias PV.	62

Lista de Tabelas

Tabela 3. 1 –Tabela dos algoritmos evolucionários.....	20
Tabela 3. 2 –Tabela dos algoritmos baseados em enxames.	32
Tabela 3. 3 –Tabela dos algoritmos baseados nos humanos.....	41
Tabela 3. 4 –Tabela dos algoritmos baseados nos fenómenos físicos.....	52
Tabela 3. 5 –Tabela dos métodos híbridos.	56

Lista de Acrónimos

AE	Erro absoluto
I-V	Corrente-tensão
MAE	Erro absolute médio
MDM	Modelo de díodo multidimensão
MHs	Metaheurísticos
MM	Modelo multidíodo
NRM	Método de Newton-Raphson
OF	Função objetivo
PSO	Particle Swarm Optimization
PV	Fotovoltaica
RMSE	Raiz quadrada do erro quadrático médio
SDM	Modelo de um díodo
SSE	Erro quadrático
STC	Condições de teste padrão
STD	Desvio padrão
TDM	Modelo de três díodos
IJAYA	Improved JAYA optimization algorithm
ATPBADE	A New Three-point-based Approach Differential evolution
PGJAYA	A performance-guided JAYA
MADE	Memetic adaptive differential evolution
GACCC	Genetic algorithm with convex combination crossover
LCJAYA	A logistic chaotic JAYA algorithm
R-II and R-III	Rao algorithms
EJADE	An enhanced adaptive differential evolution
MFEA	Evolutionary multi-task optimization
SEDE	Self-adaptive ensemble-based differential evolution
MJA	Modified JAYA algorithm
MLSHADE	Multi-Strategy Success-History-Based Adaptive Differential Evolution
DPDE	A state-of-the-art differential evolution algorithm
DEDCF	Differential evolution with dynamic control facts
CJAYA	Enhanced chaotic JAYA algorithm
EBLSHADE	Enhanced Success History Adaptive DE
MPPCEDE	Multi-population parallel co-evolutionary differential evolution
EJAYA	Opposition-based JAYA with population reduction Enhanced JAYA
MRao-1	Rao-1 optimization algorithm
CIABC	A Chaotic Improved Artificial Bee Colony
CWOA	Improved chaotic whale optimization algorithm
QPSO	Quantum particle swarm optimisation
MSSO	Modified simplified swarm optimization algorithm
FA	Firefly Algorithm
IWOA	Improved whale optimization algorithm
COA	Coyote optimization algorithm
MESWSA	Modified Elephant Swarm Water Search Algorithm

FPSO	Flexible particle swarm optimization algorithm
GWOCs	A new hybrid algorithm based on grey wolf optimizer and cuckoo search
COA	Coyote Optimization Algorithm
ALO	Ant Lion Optimization
SSA	Salp Swarm algorithm
PSOGWO	Hybrid Particle Swarm and Grey Wolf Optimization Algorithms
DEDIWPSO	Double Exponential Function-Based Dynamic Inertia Weight Particle Swarm Optimization
EHHO	Orthogonally adapted Harris hawks optimization
ICSO	Improved cuckoo search optimization
NPSOPC	Niche-based particle swarm optimization in parallel computing architecture
ISSA	Variables reduction and improved shark optimization technique
TGA	Tree Growth Based Optimization Algorithm
DDSFLA	Delayed dynamic step shuffling frog-leaping algorithm
IMPA	Improved marine predators algorithm
ESPO	Enhanced Particle Swarm Optimization
FPA	Modified FPA with Dynamic Switch Probability and Step Size Function;
Momentum-type PSO	Improved Metaheuristic Optimization Algorithm
ALO	Ant Lion Optimizer with LambertW function
WOAPSO	Hybrid WOAPSO Algorithm
SATLBO	Self-adaptive teaching-learning-based optimization
MLBSA	Multiple learning backtracking search algorithm
IBSO	An Improved Brain Storming Optimization Algorithm
SDO	Supply-Demand-Based Optimization
ITLBO	An improved teaching learning-based optimization
IMFO	Improved Moth-Flame Optimization
CBSA	Backtracking search algorithm with competitive learning
LFBSA	Backtracking search algorithm with Lévy flight
NLBMA	Conscious neighborhood scheme-based Laplacian barnacles mating algorithm
EOTLBO	Either-or teaching learning based algorithm
ILSA	Improved Learning Search Algorithm
TPTLBO	Triple-Phase Teaching-Learning-Based Optimization
FBIA	A Forensic-Based Investigation Algorithm
MTLBO	An efficient teaching-learning-based optimization algorithm
IGSK	Improved Gaining-Sharing Knowledge Algorithm
CGSA	A Chaos-Embedded Gravitational Search Algorithm
WDO	Wind driven optimization
ER-WCA	Evaporation Rate based Water Cycle Algorithm
BA	Brent's algorithm
COA	Chaotic Optimization Approach
SA	Simulated Annealing Optimization
ILCOA	Improved Lozi map based chaotic optimization Algorithm
pSFS	Perturbed stochastic fractal search
ACT	Simple and efficient estimation
SMA	Slime mould optimization algorithm

SMA	Slime mould algorithm
AEFA	Artificial electric field algorithm
PSDA	Parallelized Successive Discretization Algorithm
FFO	Farmland fertility optimizer
SA	Simulated annealing optimization
GM	Graphical method; EO- an improved equilibrium optimizer
EO	An improved equilibrium optimizer
GBO	Modified Gradient-Based Optimizer
GBO	Gradient-Based Optimizer
BPFPA	Bee pollinator flower pollination algorithm
RSS	Reduced-Space Search
GOFPANM	Hybrid flower pollination algorithm
HPSOSA	Particle Swarm Optimization and Simulated Annealing
ImCSA	Improved Cuckoo Search Algorithm
ELPSO	Enhanced leader particle swarm optimisation
OBWOA	An improved opposition-based whale optimization algorithm
TRR-ABC	A hybrid trust-region reflective algorithm
ISCE	Improved shuffled complex evolution algorithm
DE/WOA	Hybrid differential evolution with whale optimization algorithm
HFAPS	Hybrid Firefly and Pattern Search Algorithms
MPSO	Particle swarm optimisation with adaptive mutation strategy
TLABC	Teaching–learning–based artificial bee colony
ISA	Hybridized interior search algorithm
SDA	Successive discretization algorithm
BHCS	Cuckoo search algorithm with biogeography-based optimization
MCSWOA	Modified Search Strategies Assisted Crossover Whale Optimization Algorithm with Selection Operator
HCLPSO	Chaotic Heterogeneous Comprehensive Learning Particle Swarm Optimizer variants
ATLDE	Teaching–learning-based optimization and differential evolution
IBEXOPT	An interval branch and bound global optimization algorithm
BSARDVs	Backtracking search algorithm with reusing differential vectors
CPMPSO	Classified perturbation mutation based particle swarm optimization algorithm
CLJAYA	Comprehensive learning Jaya algorithm
EPSO	Fractional chaotic ensemble particle swarm optimizer
GNDO	Generalized normal distribution optimization
CCNMHHO	Horizontal and vertical crossover of Harris hawk optimizer with Nelder-Mead simplex
AEO	Recent artificial ecosystem-based optimization
RMSE	On the root mean square error (RMSE) calculation
NMSOLMFO	Orthogonal Nelder-Mead moth flame method
ELBA	An enhanced Lévy flight bat algorithm
SRFM	SYSTEMS BASED ON THE REDUCED FORM MODEL
EHHO	Diversification-enriched Harris hawks optimization with chaotic drifts
I-V	The three main points of the current–voltage characteristic
DE	Differential Evolution Algorithm
WLCSODGM	Winner-leading competitive swarm optimizer with dynamic Gaussian mutation

SFS	Stochastic fractal search optimization algorithm
AEO	Artificial ecosystem-based optimiser
LCROA	Improved Rao-based chaotic optimization technique
SFLA	Evolutionary shuffled frog leaping with memory pool
MWOA	Modified Whale Optimization Algorithm
MRao-1	modified Rao-1 optimization algorithm
ImSMA	Improved slime mould optimizer and Lambert W-function
TRDLA/ LSQM	Trust-Region-Dogleg algorithm based method/ Linear least squares method

Lista de Símbolos

d	Dimensão do problema de otimização
I_o, I_{o1}, I_{o2} e I_{o3}	Correntes de saturação inversa dos díodos
I_{ph}	Corrente fotoelétrica
\hat{I}	Corrente estimada [A]
I	Corrente de saída [A]
I_o, I_{o1}, I_{o2} e I_{o3}	Correntes de saturação inversa dos díodos [μ A]
I_H	Maior valor de corrente [A]
I_{ph}	Corrente fotoelétrica [A]
n, n_1, n_2 e n_3	Fatores de idealidade dos díodos
N_s	Número de células conectadas em série
q	Carga do elétron [C]
R	Resistência [Ω]
R_p	Resistência em paralelo [Ω]
R_s	Resistência em série [Ω]
S	Passo da amplitude
t	Iteração atual
T	Temperatura [K]
V	Tensão de saída [V]
V_t	Tensão térmica [V]
x_i	Posição do indivíduo i
LB	Limite inferior
UB	Limite superior
r_i	Número aleatório entre zero e um
v_i	Velocidade do indivíduo i
$x_{r1}, x_{r2}, x_{r3}, x_{r4},$ x_{r5}, x_{r6}	Indivíduo aleatório
x_{gbest}	Melhor posição global
F	Fator de cruzamento
u_i	Indivíduo gerado a partir do processo de cruzamento
CR	Taxa de cruzamento
x_{worst}	Pior posição da população
w	Fator de inércia
c_1	Coefficiente de aceleração cognitivo
c_2	Coefficiente de aceleração social
x_{pbest}	Melhor posição do indivíduo i
D_i	Distancia do indivíduo i para a melhor posição
x_α	Indivíduo <i>alfa</i>
x_β	Indivíduo <i>Beta</i>
x_δ	Indivíduo <i>Delta</i>
x_1, x_2, x_3	Posição auxiliar
L	Distribuição de <i>Lévy</i>
λ	Fator de escala
$\Gamma(\lambda)$	Função <i>gamma</i> com uma distribuição válida para $S > 0$
ε	Número aleatório entre zero e um
x_{mean}	Média do conhecimento da população

α_f	Fator de atração
S_{ar}	Taxa de autoaprendizagem
Mf	Fator médio que varia entre zero e um
k_{rt}	Taxa de conhecimento
x_m	Grupo intermédio
K_f	Fator de conhecimento
α	Aceleração
g	Força gravitacional
F	Fator exponencial
λ_e	Vetor gerado aleatoriamente entre zero e um
t_p	Variável tempo
α_2	Fator de controlo do mecanismo de diversificação
t_{po}	Valor inicial da variável tempo
R	Taxa de geração
R_o	Valor inicial da variável R
R_{cp}	Vetor controlo da taxa de geração
RP	Probabilidade entre zero e um
V_z	Variável constante
F_i	Força gravitacional total
m_i	Função objetivo normalizada
$f(x_i)$	Corresponde ao valor da função objetivo do indivíduo i
R_i	Distância Euclidiana
ε_g	Constante maior que zero
t_{max}	Número máximo de iterações
$d_{juniorphase}$	Dimensão da fase <i>junior gaining and sharing</i>
$d_{seniorphase}$	Dimensão da fase <i>senior gaining and sharing</i>
p_s	Probabilidade de troca $\in [0,1]$

Capítulo 1

1. Introdução

1.1. Enquadramento

Na atualidade, a humanidade ainda está muito dependente da utilização dos combustíveis fósseis (petróleo, carvão e gás natural) para inúmeras tarefas. De forma a reduzir a dependência deste tipo de combustíveis, que são esgotáveis e poluentes, é necessário que se alterem inúmeros comportamentos e mentalidades na sociedade atual. Devido ao uso excessivo deste tipo de combustíveis provocaram-se alterações no clima, na atmosfera e na própria natureza. Deste modo, a alteração deste comportamento torna-se uma prioridade, existindo a necessidade de implementar soluções mais limpas, caso contrário quem sai mais prejudicado é a sociedade atual, gerações futuras e, por último, o meio ambiente em que estamos inseridos.

Atualmente, a energia elétrica é considerada um bem de primeira necessidade para a sociedade atual. No entanto, a produção de energia elétrica a partir de fontes renováveis é hoje o nosso maior desafio. É fundamental diminuir a utilização de combustíveis fósseis e a libertação de gases com efeito estufa. Existem diversas fontes de energias renováveis tais como a energia eólica, hídrica, biomassa, geotérmica e solar. Em Portugal, a energia solar é a que tem mais potencial, devido às condições ideais que o nosso clima oferece. No entanto, a energia solar ainda precisa de ultrapassar alguns desafios tais como a imprevisibilidade e variabilidade.

Na literatura, existem dois modelos matemáticos que têm o intuito de simular com maior exatidão as novas tecnologias PV que se evidenciam no mercado. Um desses modelos é o modelo de díodo multidimensão [1] que é caracterizado por uma rede de díodos ajustável com o objetivo de tornar o modelo mais preciso. Além disso, existe outro modelo na literatura, o modelo multidíodo [2] que é constituído por vários díodos ligados em paralelo.

Além destes modelos matemáticos existem outros que também são capazes de simular o comportamento de uma célula ou de um módulo PV. Estes modelos têm um menor custo computacional, um menor grau de complexidade e uma maior exatidão. Portanto, os modelos que são mais utilizados na literatura pelos autores são o modelo de um díodo

(SDM), o modelo de dois díodos (DDM) e, por último, o modelo de três díodos (TDM). A grande diferença que estes modelos têm para além da sua exatidão, são os díodos que estão conectados em paralelo e o número de parâmetros que são desconhecidos. O modelo de um díodo é caracterizado apenas por cinco parâmetros desconhecidos, enquanto o modelo de dois díodos e o modelo de três díodos são caracterizados por sete e nove parâmetros desconhecidos.

Na literatura especializada, a extração dos parâmetros fotovoltaicos é um problema complexo e multimodal, isto é, o problema em questão pode conter várias soluções. Dependendo da informação disponível, este tipo de problema pode ser solucionado por duas abordagens diferentes. Tipicamente, se os dados dos fabricantes forem disponibilizados, os autores optam pela utilização de métodos analíticos. No entanto, se os dados forem medidos experimentalmente, a abordagem mais comum consiste na utilização de métodos meta-heurísticos.

A utilização dos métodos analíticos é a mais habitual quando os dados dos fabricantes são fornecidos, permitindo apenas a utilização de alguns pontos fulcrais da curva característica corrente- tensão (I-V). Os métodos analíticos geralmente são formulados através de equações elementares, que posteriormente serão aplicadas em pontos fulcrais da curva característica I-V. Assim, a precisão destes métodos está dependente dos pontos fulcrais que são selecionados. Além disso, estes pontos são retirados sobre condições de teste padrão (STC) o que vai limitar a precisão do método. Estes métodos analíticos têm um custo computacional baixo e são simples de implementar.

Geralmente, quando os dados experimentais são retirados os autores na literatura especializada optam pela escolha de métodos meta-heurísticos. Quando comparados com os métodos analíticos, os métodos meta-heurísticos são mais precisos, pois consideram todos os pontos disponíveis na curva característica I-V.

Neste tipo de abordagem, o problema da extração dos parâmetros fotovoltaicos é encarado como um problema de otimização, ou seja, ocorre a minimização do erro entre a curva característica I-V simulada e medida experimentalmente. Nos últimos anos, estes métodos meta-heurísticos têm estado em voga pois ultrapassam com relativa facilidade problemas não convexos e multimodais. Além disso, estes métodos conseguem com alguma facilidade solucionar problemas em que as equações são de origem implícita e não linear.

Os métodos meta-heurísticos têm como base uma população de indivíduos que vai interagir entre si no espaço de procura, com o intuito de encontrar a solução global para o problema da extração dos parâmetros fotovoltaicos. Além disso, a eficiência destes métodos depende fortemente do equilíbrio que tem de existir entre o mecanismo de intensificação e o mecanismo de diversificação. O mecanismo de intensificação consiste na procura de soluções à volta da região onde a melhor solução foi encontrada. Já o mecanismo de diversificação, tem o objetivo de procurar novas soluções em regiões que não foram exploradas e distanciadas da melhor solução.

Na literatura especializada, podem-se encontrar diversos algoritmos que sejam baseados nos métodos meta-heurísticos tais como: *Enhanced Success History Adaptive DE* (EBLSHADE) [3], *Rao algorithms* (R-II and R-III)[4], *A logistic chaotic JAYA algorithm* (LCJAYA) [5], *Multi-population parallel co-evolutionary differential evolution* (MPPCEDE) [6], *A state-of-the-art differential evolution algorithm* (DPDE) [7], *Opposition-based JAYA with population reduction Enhanced JAYA* (EJAYA) [8], *improved chaotic whale optimization algorithm* (CWOA) [9], *Firefly Algorithm* (FA) [10], *Ant Lion Optimization* (ALO)[11], *Coyote optimization algorithm* (COA) [12], *Tree Growth Based Optimization Algorithm* (TGA) [13], *improved marine predators algorithm* (IMPA) [14], *Improved Gaining-Sharing Knowledge Algorithm* (IGSK) [15], *Triple-Phase Teaching-Learning-Based Optimization* (TPTLBO) [16], *Improved Learning Search Algorithm* (ILSA) [17], *Supply-Demand-Based Optimization* (SDO) [18], *An Improved Brain Storming Optimization Algorithm* (IBSO) [19], *A Forensic-Based Investigation Algorithm* (FBIA) [20], *slime mould algorithm* (SMA) [21], *Artificial electric field algorithm* (AEFA) [22], *Parallelized Successive Discretization Algorithm* (PSDA) [23], *farmland fertility optimizer* (FFO) [24], *simulated annealing optimization* (SA) [25], *graphical method* (GM) [26].

Os métodos híbridos também podem ser utilizados para determinar os parâmetros que caracterizam o respetivo modelo PV. Estes métodos são caracterizados pela aplicação de duas estratégias diferentes. A primeira estratégia consiste na hibridização de um método determinístico com um ou vários algoritmos meta-heurísticos. No entanto, a segunda estratégia é a mais utilizada pelos autores da literatura especializada. Esta consiste na hibridização de dois ou mais algoritmos meta-heurísticos. A eficiência desta estratégia está dependente do equilíbrio entre o mecanismo de intensificação e o mecanismo de diversificação dos algoritmos de otimização envolvidos. No entanto, esta hibridização cria uma desvantagem, o elevado custo computacional.

Na literatura especializada, podem-se encontrar diversos algoritmos que sejam baseados nos métodos híbridos tais como: *bee pollinator flower pollination algorithm* (BPFPA) [27]; *Particle Swarm Optimization and Simulated Annealing* (HPSOSA) [28], *hybrid differential evolution with whale optimization algorithm* (DE/WOA) [29], *Teaching-learning-based artificial bee colony* (TLABC) [30], *teaching-learning-based optimization and differential evolution* (ATLDE) [31], *Horizontal and vertical crossover of Harris hawk optimizer with Nelder-Mead simplex* (CCNMHHO) [32], *Winner-leading competitive swarm optimizer with dynamic Gaussian mutation* (WLCSODGM) [33], *improved slime mould optimizer and Lambert W-function* (ImSMA) [34], *On the root mean square error (RMSE)* [35], *Evolutionary shuffled frog leaping with memory pool* (SFLA) [36], *Trust-Region-Dogleg algorithm based method/Linear least squares method* (TRDLA/LSQM) [37], *Chaotic Heterogeneous Comprehensive Learning Particle Swarm Optimizer variants* (HCLPSO) [38].

1.2. Motivação e objetivos

A motivação para a escolha deste tema prende-se com a importância da produção de energia PV e pelo facto da estimação dos parâmetros fotovoltaicos sob diferentes condições climáticas constituir um problema desafiador.

Apesar de existir uma grande variedade de abordagens e métodos para estimar os parâmetros PV o desenvolvimento de novas linhas de investigação, que visem promover a eficiência, a precisão e confiabilidade das técnicas e ferramentas de monitorização e controle dos sistemas PV, continua a justificar-se.

1.3. Organização da dissertação

A presente dissertação está organizada em quatro capítulos, onde no presente capítulo (Capítulo 1) é realizada a introdução e são expostos os objetivos. A restante dissertação está estruturada da seguinte forma:

No capítulo 2 é feita uma revisão bibliográfica aos modelos de um, dois e três díodos usados para descrever o comportamento das células e módulos PV.

No capítulo 3 é realizado um estudo sobre os diferentes algoritmos de otimização bio inspirados que vão ser utilizados no estudo comparativo.

No capítulo 4 é feita uma análise final da revisão bibliográfica realizada.

Capítulo 2

2. Modelos matemáticos

Na literatura podem encontrar-se diversos modelos matemáticos capazes de simular o comportamento de uma célula fotovoltaica ou um módulo PV, mas estes contêm graus de complexidade, precisão e custo computacional distintos. Atualmente, têm aparecido outros modelos matemáticos sempre com o intuito de representar com mais precisão os fenómenos que ocorrem na junção P-N, mas também com o objetivo de simular o comportamento das novas tecnologias que vão surgindo no mercado. Estes modelos são o modelo de diodo multidimensão, composto por uma rede de díodos variável onde os díodos, tanto estão ligados em série como em paralelo, outro modelo recente é o modelo multidíodo, composto por diversos díodos ligados em série e em paralelo. Porém, os modelos que são mais utilizados na literatura são o modelo de um diodo (SDM), o modelo de dois díodos (DDM) e o modelo de três díodos (TDM), os mesmos caracterizam-se por se desconhecer cinco, sete e nove parâmetros.

Para se modelar e simular o comportamento de uma célula ou um painel fotovoltaico, sobre diferentes tipos de condições (principalmente irradiância e temperatura), existem vários modelos que podem ser utilizados tais como: o modelo de um diodo (SDM), o modelo de dois díodos (DDM), o modelo de três díodos (TDM), o modelo de multidíodo e por fim o modelo de diodo multidimensão.

No entanto os modelos mais utilizados entre os investigadores na literatura são o modelo de um diodo (SDM), o modelo de dois díodos (DDM) e o modelo de três díodos (TDM).

2.1. Modelo de um diodo (SDM)

O modelo de um diodo, representado na Figura 2.1, é composto por uma fonte de corrente que representa a corrente fotoelétrica (I_{ph}), produzida pelo efeito fotovoltaico e que depende das condições climatéricas, sobretudo dos níveis de irradiância e temperatura. De forma a representar os fenómenos físicos que ocorrem na junção P-N é inserido um diodo, em paralelo com a fonte de corrente, para representar o processo de difusão (predominante em níveis de tensão elevado). Além disso, este modelo é composto por uma resistência em série (R_s) e uma resistência em paralelo (R_p). A resistência R_s considera, as perdas óhmicas nos semicondutores que compõem as células PV e nos contactos metálicos, i.e., perdas por efeito joule. Já a resistência colocada em

paralelo (R_p) permite representar a corrente de fuga resultante de correntes parasitas originadas por defeitos existentes nas células PV [39].




Figura 2. 1 - Circuito equivalente do modelo de um díodo (SDM).

Aplicando as leis de Kirchoff, ao circuito apresentado na Figura 2 1, a corrente do circuito (I) é determinada pela seguinte equação

$$I = I_{ph} - I_d - \frac{V + I * R_s}{R_p} \quad (2.1)$$

Onde a corrente do díodo (I_d) é expressa pela equação de Shockley, dada por

$$I_d = I_0 \left(\exp \left(\frac{V + I * R_s}{n * V_t} \right) - 1 \right) \quad (2.2)$$

Onde (I_0) representa a corrente inversa de saturação do díodo, n o fator de idealidade do díodo, V a tensão de saída da célula/ módulo e (V_t) a tensão térmica da junção dada pela seguinte equação,

$$V_t = \frac{k * T}{q} \quad (2.3)$$

Na qual, k representa a constante de Boltzmann ($1.3806503 \times 10^{-23}$ J/K), T refere-se á temperatura em Kelvin e q representa a carga do eletrão ($1.60217646 \times 10^{-19}$ C). Assim, e com base nas equações anteriores, a corrente (I) pode ser calculada através da seguinte equação

$$I = I_{ph} - I_0 \left(\exp \left(\frac{V + I \times R_s}{n \times V_t} \right) - 1 \right) - \frac{V + I \times R_s}{R_p} \quad (2.4)$$

O modelo de um díodo é definido por cinco parâmetros desconhecidos: a corrente fotoelétrica I_{ph} , a corrente inversa de saturação do díodo I_0 , o fator de idealidade do díodo n , a resistência em série R_s e a resistência em paralelo R_p .

2.2. Modelo de dois díodos (DDM)

O modelo de dois díodos, apresentado na Figura 2.2, é composto por dois díodos colocados em paralelo com a fonte de corrente, caracteriza-se por ser um modelo mais preciso que o modelo de um díodo, pois com a adição de mais um díodo este consegue representar com mais precisão os fenômenos físicos que ocorrem na junção PN, onde um díodo é responsável por representar o fenômeno de difusão, enquanto que o segundo díodo é encarregue pelo fenômeno de recombinação que acontece na região de espaço-carga [39].




Figura 2. 2 - Circuito equivalente do modelo de dois díodos (DDM).

Então a corrente de saída do modelo a dois díodos é calculada através da equação (2.5), por ter sete parâmetros que não são conhecidos, são eles a corrente fotoelétrica I_{ph} , a corrente inversa de saturação do díodo 1 (I_{01}) e do díodo 2 (I_{02}), fator idealidade tanto do díodo 1 (n_1) como díodo 2 (n_2), e por fim a resistência em série (R_s) e a resistência em paralelo (R_p).

$$I = I_{ph} - I_{01} \left(\exp \left(\frac{V + I * R_s}{n_1 * V_t} \right) - 1 \right) - I_{02} \left(\left(\exp \left(\frac{V + I * R_s}{n_2 * V_t} \right) - 1 \right) - \frac{V + I * R_s}{R_p} \right) \quad (2.5)$$

2.3. Modelo de três díodos (TDM)

O modelo de três díodos, apresentado na Figura 2.3, como o nome indica, possui três díodos ligados em paralelo com a fonte de corrente, este modelo consegue expressar com mais exatidão os fenômenos físicos que ocorrem na junção PN, no entanto apresenta um

maior grau de complexidade. O terceiro díodo, que é adicionado ao modelo tem a finalidade de replicar os fenômenos físicos de recombinação presentes nas zonas de defeito e a intenção de recriar as correntes de fuga existentes nos limites dos grãos [1].




Figura 2. 3 - Circuito equivalente do modelo de três díodos (TDM).

A equação (2.6) corresponde à corrente de saída do modelo, é caracterizada por ter nove parâmetros desconhecidos são eles a corrente fotoelétrica I_{ph} , a corrente inversa de saturação do díodo um (I_{d1}), do díodo dois (I_{d2}) e do díodo três (I_{d3}), o fator de idealidade do díodo um (n_1), do díodo dois (n_2), do díodo três (n_3), a resistência em série (R_s) e por fim a resistência em paralelo (R_p).

$$I = I_{ph} - I_{01} \left(\exp \left(\frac{V + I \times R_s}{n_1 \times V_t} \right) - 1 \right) - I_{02} \left(\exp \left(\frac{V + I \times R_s}{n_2 \times V_t} \right) - 1 \right) - I_{03} \left(\exp \left(\frac{V + I \times R_s}{n_3 \times V_t} \right) - 1 \right) - \frac{V + I \times R_s}{R_p} \quad (2.6)$$

2.4. Formulação do Problema

A extração dos parâmetros fotovoltaicos é condicionada pela informação disponível, logo para a resolução deste problema existem três métodos que podem ser aplicados Segundo a literatura especializada são eles os métodos analíticos, os métodos meta-heurísticos e os métodos híbridos. Quando se recorre aos *datasheets* disponibilizados pelos fabricantes, os métodos que são mais utilizados são os métodos analíticos. Estes métodos utilizam equações elementares aplicadas em pontos fulcrais da curva característica I-V, este processo é importante pois torna as equações explícitas. Todavia, os métodos analíticos têm uma condicionante, isto é, os pontos fulcrais que são retirados da curva característica I-V remontam a condições de teste padrão.

No entanto para a extração dos parâmetros fotovoltaicos existe outra abordagem que se pode utilizar, isto é, a minimização do erro entre os dados experimentais e os dados

estimados. Tipicamente neste tipo de abordagem segundo a literatura especializada os métodos meta-heurísticos ganham uma prevalência maior em relação aos métodos analíticos e aos métodos híbridos, pois estes têm alguma facilidade na resolução de problemas de otimização de origem não convexa e multimodal.

De forma a qualificar o erro existente entre os dados experimentais e os dados estimados existem vários índices de desempenho que se podem aplicar tais como: o erro absoluto (AE), o erro absoluto médio (MAE), o erro quadrático (SSE) e a raiz quadrada do erro quadrático médio (RMSE) [40].

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (I_i - \hat{I}_{(V_i, \tau)})^2} \quad (2.7)$$

$$AE = \sum_{i=1}^N |I_i - \hat{I}_{(V_i, \tau)}| \quad (2.8)$$

$$SSE = \sum_{i=1}^N (I_i - \hat{I}_{(V_i, \tau)})^2 \quad (2.9)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |I_i - \hat{I}_{(V_i, \tau)}| \quad (2.10)$$

No entanto, para ultrapassar a natureza implícita que caracteriza os modelos PV, alguns autores optam pela utilização do método de *Newton Raphson* (NRM) [41], ou a função *w* de *Lambert* [35] para tornar a equação explícita. Todavia, outros autores escolhem não utilizar nenhum destes métodos, e optam pela resolução da equação.

Capítulo 3

3. Algoritmos Meta-heurísticos

Na literatura especializada existem diversos métodos para a extração dos parâmetros fotovoltaicos tais como: os métodos analíticos, os métodos meta-heurísticos e os métodos híbridos.

Quando os dados dos fabricantes são fornecidos, os métodos mais utilizados são os métodos analíticos. Estes recorrem a equações matemáticas que vão ser aplicadas em pontos fulcrais da curva característica I-V. No entanto, estes pontos fornecidos pelos fabricantes são obtidos sob condições de teste padrão (STC), ou seja, em algumas situações existe a necessidade de se efetuar simplificações ou aproximações. Portanto a eficiência deste método está diretamente ligada à seleção dos pontos fulcrais da curva característica I-V e também ao posicionamento inicial dos indivíduos. Estes métodos caracterizam-se pela sua fácil implementação, o seu baixo custo computacional e a sua eficiência na procura local.

Na literatura especializada, nos últimos anos os métodos que têm sido mais utilizados são os métodos meta-heurísticos. Estes métodos são bio inspirados na natureza que nos rodeia, pois são compostos por uma população de indivíduos que interagem entre si de forma a encontrar soluções de elevada qualidade.

Nesta abordagem os métodos meta-heurísticos têm como finalidade a minimização do erro entre a curva experimental I-V e a curva simulada, através de uma função objetivo. Estes métodos são caracterizados pela sua versatilidade pois podem ser utilizados para a resolução de vários problemas, são simples de implementar e conseguem solucionar problemas multimodais e não lineares. No entanto, estes métodos necessitam de um elevado custo computacional e podem convergir prematuramente para mínimos locais. No entanto, de forma a ultrapassar a convergência prematura e conseguir a melhor eficiência possível, estes métodos dependem do equilíbrio entre o mecanismo de intensificação e o mecanismo de diversificação. O mecanismo de intensificação privilegia uma procura local e, em sentido inverso, o mecanismo de diversificação privilegia uma procura global.

Os métodos híbridos são caracterizados pela aplicação de duas estratégias disjuntas. A primeira estratégia passa pela hibridização de dois ou vários algoritmos meta-heurísticos. A segunda estratégia recai na aplicação de um método determinístico com um algoritmo meta-heurístico. Portanto, a hibridização que é mais utilizada na literatura especializada é a combinação dos algoritmos meta-heurísticos. No entanto, estas hibridizações contêm dois desafios. O primeiro desafio passa pelo equilíbrio entre o mecanismo de intensificação, que favorece uma procura local, e o mecanismo de diversificação que favorece uma procura global. O segundo desafio passa pelo ajuste dos parâmetros de controlo inerentes a cada método, pois estes podem interferir no desempenho dos algoritmos de otimização.

Nesta secção são descritos vários algoritmos meta-heurísticos utilizados na extração dos parâmetros fotovoltaicos. Estes podem ser classificados como algoritmos evolucionários, algoritmos baseados em enxames, algoritmos baseados no comportamento humano, algoritmos baseados em fenómenos físicos ou algoritmos híbridos.

3.1. Algoritmos Evolucionários

3.1.1. *Diferencial Evolution*

O algoritmo evolucionário *diferencial evolution* (DE) é inspirado na evolução e seleção das espécies. Para o desenvolvimento das espécies é necessário a geração de indivíduos que sejam capazes de evoluir e de se reproduzirem, de forma a transmitir essas evoluções e a sua informação genética às gerações futuras. Assim, para seleccionar os melhores indivíduos são aplicados processos de mutações, cruzamentos e de seleção para efetuar essa avaliação[42]. O mecanismo de mutação aplica a diferença vetorial entre os indivíduos que são escolhidos aleatoriamente.

No processo de inicialização utiliza-se a seguinte equação, de forma a posicionar os indivíduos de forma aleatória no espaço de procura multidimensional:

$$x_{i,d} = LB_d + r_{i,d} \cdot (UB_d - LB_d) \quad (3.1)$$

Onde, r_i corresponde a um número aleatório com uma distribuição uniforme entre zero e um, d representa a dimensão do espaço de procura e LB , UB representam o limite inferior e o limite superior da respetiva dimensão.

Após efetuado o processo de inicialização, efetua-se o processo de mutação. Esta estratégia é utilizada em cada indivíduo da população com o propósito de se obter o vetor de mutação (v_i). Na literatura especializada, existem várias estratégias de mutação que podem ser utilizadas, nomeadamente:

DE/Rand/1

$$v_{i,d}(t+1) = x_{r1,d}(t) + F(x_{r2,d}(t) - x_{r3,d}(t)) \quad (3.2)$$

DE/Rand/2

$$v_{i,d}(t+1) = x_{r1,d}(t) + F(x_{r2,d}(t) - x_{r3,d}(t)) + F(x_{r4,d}(t) - x_{r5,d}(t)) \quad (3.3)$$

DE/Best/1

$$v_{i,d}(t+1) = x_{gbest,d}(t) + F(x_{r1,d}(t) - x_{r2,d}(t)) \quad (3.4)$$

DE/Current-to-best/1

$$v_{i,d}(t+1) = x_{i,d}(t) + F(x_{gbest,d}(t) - x_{i,d}(t)) + F(x_{r1,d}(t) - x_{r2,d}(t)) \quad (3.5)$$

Onde, $x_{r1}, x_{r2}, x_{r3}, x_{r4}, x_{r5}$ correspondem a indivíduos selecionados aleatoriamente, o fator F representa um fator de cruzamento, x_{gbest} representa o melhor indivíduo da população na iteração t .

No processo de cruzamento e de forma a aumentar a diversidade da população é realizada uma combinação entre o indivíduo da população x_i com o indivíduo criado pelo processo de mutação (v_i). Este procedimento tem o objetivo de gerar um novo indivíduo u_i representado através da seguinte equação:

$$u_{i,d}(t+1) = \begin{cases} v_{i,d}(t+1), & \text{if } r_{i,d} \leq CR \text{ or } d = j_{rand} \\ x_{i,d}(t), & r_{i,d} > CR \end{cases} \quad (3.6)$$

Em que CR representa a taxa de cruzamento que é definida pelo utilizador, j_{rand} corresponde a número aleatório entre $[1,d]$.

Por último, o algoritmo DE aplica o processo de seleção para decidir qual dos indivíduos com maior aptidão prosseguem para a próxima geração. Tipicamente, o processo de seleção é definido pela seguinte equação,

$$x_{i,d}(t+1) = \begin{cases} u_{i,d}(t+1), & \text{if } f(u_{i,d}(t+1)) \leq f(x_{i,d}(t+1)) \\ x_{i,d}(t+1), & f(u_{i,d}(t+1)) > f(x_{i,d}(t+1)) \end{cases} \quad (3.7)$$

A Figura 3.1 ilustra, de forma resumida, as várias etapas e processos inerentes ao algoritmo meta-heurístico DE. Onde se pode constatar que inicialmente é realizado um posicionamento inicial dos indivíduos dentro do espaço de procura multidimensional. De seguida, a cada iteração, os indivíduos sofrem um processo de mutação e de cruzamento através das equações referidas anteriormente. Uma vez realizado o processo de cruzamento é aplicado o processo de seleção através da equação (3.7). A execução do algoritmo de otimização termina quando é alcançado o critério de paragem definido pelo utilizador (tipicamente o número de iterações máximo permitido).

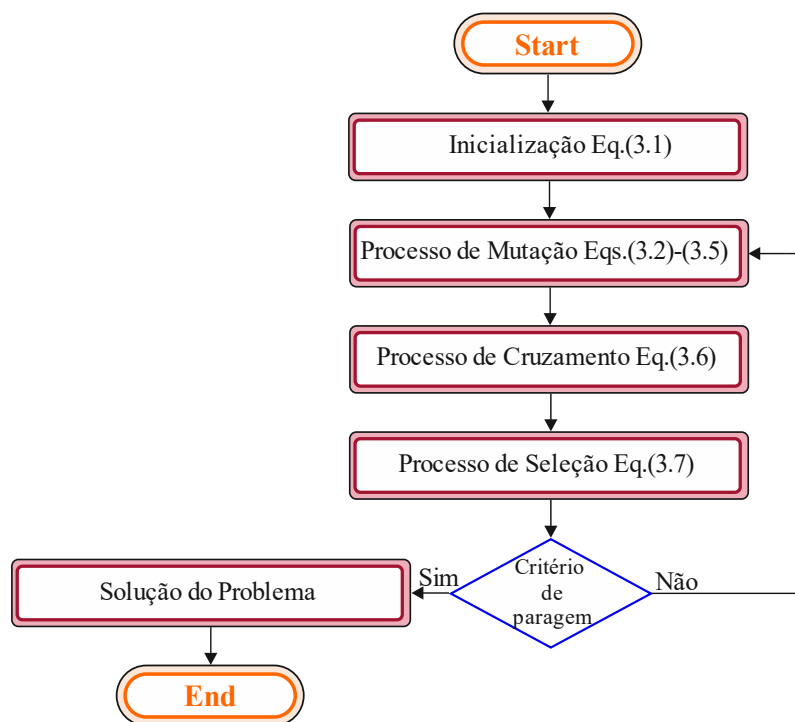


Figura 3. 1 – Fluxograma do algoritmo DE

3.1.2. *Jaya algorithm*

O algoritmo evolucionário *Jaya*, é um algoritmo de otimização inspirado numa população que contém três processos ao longo da sua execução, nomeadamente: os processos de inicialização, evolução e seleção. Este algoritmo tem como objetivo, aproximar-se da solução ideal do problema e em simultâneo afastar-se da pior solução.

Uma das vantagens do *Jaya* em relação a outros algoritmos é que este apenas está sujeito a dois parâmetros de controlo: o número de iterações e o número de indivíduos da população [43].

No processo de inicialização do Jaya aplica-se a seguinte equação de forma a distribuir de forma aleatória os indivíduos no espaço de procura.

$$x_{i,d} = LB_d + r_{i,d}(UB_d - LB_d) \quad (3.8)$$

Após o processo de inicialização, segue-se o processo de evolução que consiste em modificar todos os indivíduos da população através de uma estratégia de evolução representada pela seguinte equação:

$$v_{i,d}(t+1) = x_{i,d}(t) + r_{1,d}(x_{gbest,d}(t) - |x_{i,d}(t)|) + r_{2,d}(x_{worst,d}(t) - |x_{i,d}(t)|) \quad (3.9)$$

Em que r_1 e r_2 correspondem a dois valores aleatórios entre zero e um, $x_{worst,d}$ representa o pior indivíduo da população.

Caso algum indivíduo ultrapasse o espaço de procura o processo de inicialização será novamente efetuado. Na equação (3.9) os termos r_1 , r_2 são essenciais pois indicam se estamos a privilegiar a melhor solução ou a beneficiar a pior solução.

Depois de efetuado o processo de evolução, o algoritmo meta-heurístico Jaya implementa um processo de seleção. Este processo consiste na implementação de um operador de seleção, este vai determinar se o vetor alvo ou o vetor teste irão sobreviver na próxima geração, o operador de seleção é representado pela seguinte equação:

$$x_{i,d}(t+1) = \begin{cases} v_{i,d}(t+1), & \text{if } f(v_{i,d}(t+1)) < f(x_{i,d}(t)) \\ x_{i,d}(t), & f(v_{i,d}(t+1)) > f(x_{i,d}(t)) \end{cases} \quad (3.10)$$

A Figura 3.2 ilustra e sintetiza os vários processos/etapas que decorrem no algoritmo meta-heurístico Jaya. Primeiramente, é realizado um posicionamento inicial dos indivíduos dentro do espaço de procura multidimensional. Como já foi referido anteriormente e à semelhança do que acontece no algoritmo DE, neste algoritmo de otimização também se aplica o processo de evolução representado através da equação (3.8). Posteriormente, aplica-se o processo de seleção onde se define a manutenção ou substituição da solução anterior. A execução deste algoritmo termina quando o critério de paragem for atingido.

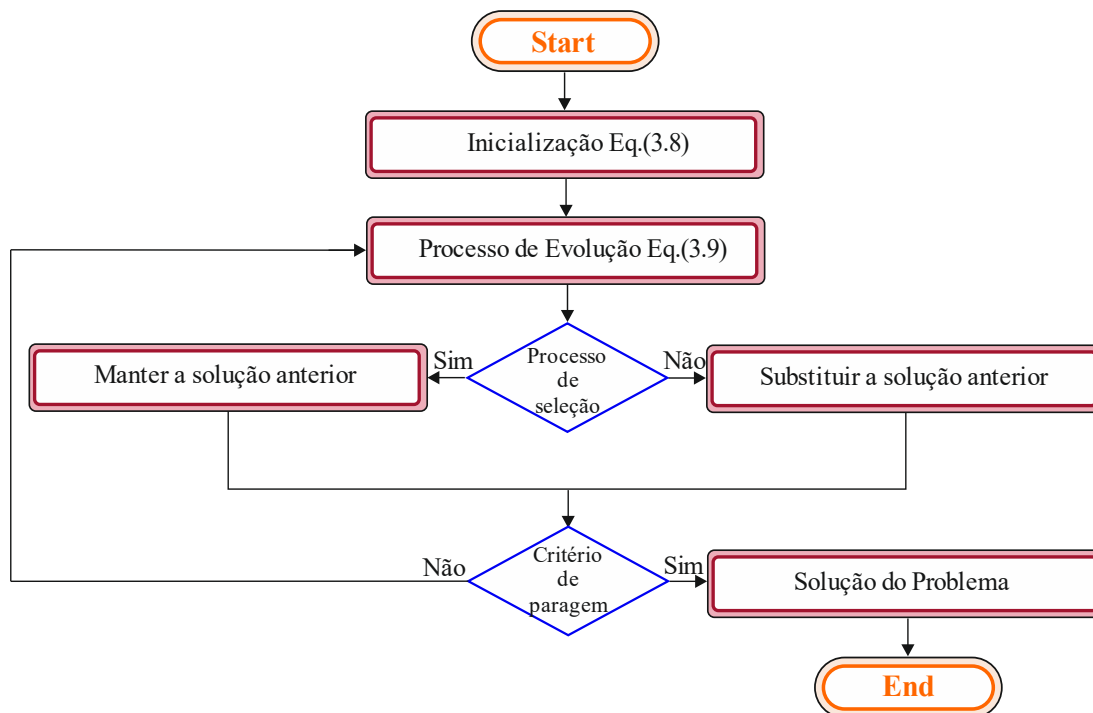


Figura 3. 2 – Fluxograma do algoritmo Jaya

3.1.3. Rao algorithm

O algoritmo *Rao*, é um algoritmo meta-heurístico baseado numa população. Este é simples e fácil de implementar para problemas de otimização. Este algoritmo tem uma grande vantagem em relação a outros algoritmos, pois este não necessita de parâmetros de controlo, ou seja, o único parâmetro geral que precisa de ser ajustado é o tamanho da população. Na literatura especializada o algoritmo meta-heurístico Rao contém três variantes: o Rao 1, Rao 2 e o Rao 3 [4] [44]. O algoritmo de otimização Rao 1 consiste na aplicação de dois processos, o de seleção que é formulado através da equação (3.11), o processo de seleção é expresso pela equação (3.16). Para o Rao 2 e Rao 3 o processo de evolução é formulado pelas equações (3.12,3.13,3.14,3.15). O processo de seleção para ambas variantes é definido através da equação (3.16).

$$x_{i,d}(t + 1) = x_{r1,d}(t) + r_{1,d}(x_{gbest,d}(t) - x_{worst,d}(t)) \quad (3.11)$$

$$x_{i,d}(t+1) = \begin{cases} & \text{if } f(x_{i,d}) < f(x_{r1,d}) \\ x_{i,d}(t) + r_{1,d} (x_{\text{gbest},d}(t) - x_{\text{worst},d}(t)) + r_{2,d} (|x_{i,d}| - |x_{r1,d}|) \end{cases} \quad (3.12)$$

$$x_{i,d}(t+1) = \begin{cases} & \text{if } f(x_{i,d}) > f(x_{r1,d}) \\ x_{i,d}(t) + r_{1,d} (x_{\text{gbest},d}(t) - x_{\text{worst},d}(t)) + r_{2,d} (|x_{r1,d}| - |x_{i,d}|) \end{cases} \quad (3.13)$$

$$x_{i,d}(t+1) = \begin{cases} & \text{if } f(x_{i,d}) < f(x_{r1,d}) \\ x_{i,d}(t) + r_{1,d} (x_{\text{gbest},d}(t) - |x_{\text{worst},d}(t)|) + r_{2,d} (|x_{i,d}| - |x_{r1,d}|) \end{cases} \quad (3.14)$$

$$x_{i,d}(t+1) = \begin{cases} & \text{if } f(x_{i,d}) > f(x_{r1,d}) \\ x_{i,d}(t) + r_{1,d} (x_{\text{gbest},d}(t) - |x_{\text{worst},d}(t)|) + r_{2,d} (|x_{r1,d}| - |x_{i,d}|) \end{cases} \quad (3.15)$$

Após o processo de evolução é iniciado o processo de seleção. Este processo tem o objetivo de selecionar os melhores indivíduos da população este é representado pela seguinte equação.

$$x_{i,d}(t+1) = \begin{cases} v_{i,d}(t+1), & \text{if } f(v_{i,d}(t+1)) < f(x_{i,d}(t)) \\ x_{i,d}(t), & f(v_{i,d}(t+1)) > f(x_{i,d}(t)) \end{cases} \quad (3.16)$$

A Figura 3.3 representa, de forma sucinta, as várias etapas/processos que estão presentes no algoritmo meta-heurístico Rao. Como é habitual nos algoritmos de otimização, inicialmente é efetuado um posicionamento inicial dos indivíduos dentro do espaço de procura multidimensional. No algoritmo meta-heurístico Rao (e nas suas variantes), no processo de evolução são aplicadas as seguintes equações (3.11)-(3.15). Finalizado o processo de evolução, segue-se o processo de seleção que é exatamente igual ao processo de seleção do algoritmo Jaya. Deste modo, vai-se determinar se a solução anterior vai ser mantida ou substituída, este processo é representado pela equação (3.16). Por último, como é habitual a execução do algoritmo de otimização termina quando o critério de paragem for alcançado.

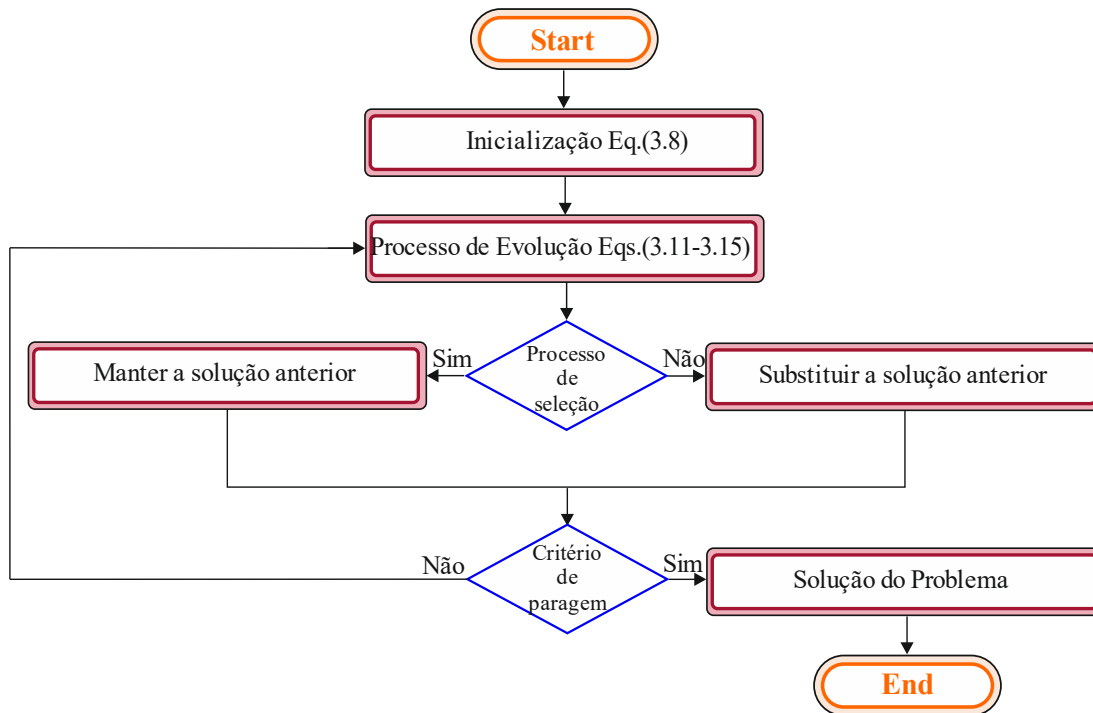


Figura 3. 3 – Fluxograma do algoritmo Rao 1,2,3

3.1.4. Revisão da literatura dos algoritmos evolucionários

Em relação aos algoritmos evolucionários é possível encontrar inúmeros algoritmos de otimização para a extração dos parâmetros fotovoltaicos, nomeadamente: *improved JAYA optimization algorithm* (IJAYA); *A New Three-point-based Approach Differential evolution* (ATPBADE); *A performance-guided JAYA* (PGJAYA); *memetic adaptive differential evolution* (MADE); *genetic algorithm with convex combination crossover* (GACCC); *An enhanced adaptive differential evolution* (EJADE); *Evolutionary multi-task optimization* (MFEA); *self-adaptive ensemble-based differential evolution* (SEDE); *modified JAYA algorithm* (MJA); *Multi-Strategy Success-History-Based Adaptive Differential Evolution* (MLSHADE); *Differential evolution with dynamic control facts* (DEDCF); *Enhanced chaotic JAYA algorithm* (CJAYA); *Rao-1 optimization algorithm* (Rao-1).

Através da revisão bibliográfica realizada verifica-se uma tendência para a utilização de algoritmos de otimização, como por exemplo, o Jaya e o DE. No entanto, nos últimos, também se verifica uma crescente utilização do algoritmo de otimização Rao (e suas variantes) para a extração dos parâmetros fotovoltaicos.

A Tabela 3.1 resume a revisão bibliográfica realizada em função de diversos aspetos que condicionam fortemente a precisão e confiabilidade do algoritmo de otimização para a extração dos parâmetros fotovoltaicos. Dos diversos aspetos que condicionam o desempenho e eficiência dos algoritmos de otimização, é possível destacar: os modelos matemáticos que permitem caracterizar a célula ou módulo PV, o *dataset* (tecnologias PV) utilizado para avaliar a eficiência e precisão do algoritmo de otimização, a função objetivo e, por último, a técnica aplicada para contornar a natureza implícita das equações que caracterizam o respetivo modelo matemático.

As tecnologias PV mais utilizadas para avaliar o desempenho e conseqüentemente a precisão do algoritmo de otimização para a extração dos parâmetros fotovoltaicos são, as tecnologias monocristalinas e policristalinas. Dentro das tecnologias policristalinas destacam-se os seguintes *datasets*, *R.T.C solar cell*, *Photowatt-PWP 201* e *STP6-120/36*. Já em relação às tecnologias monocristalinas pode-se destacar o seguinte *dataset* *STM6-40/36*.

No que diz respeito aos modelos matemáticos que permitem simular e caracterizar uma célula ou um módulo PV, verifica-se uma clara tendência para a aplicação dos modelos matemáticos SDM e DDM. No entanto, a utilização do modelo matemático TDM é residual (apenas 0.05% dos autores optam pela aplicação do modelo matemático TDM).

Existem dois métodos amplamente difundidos na literatura especializada para contornar a natureza implícita das equações que caracterizam os respetivos modelos matemáticos, nomeadamente: o método direto e o método indireto. O método direto consiste na resolução da equação que caracteriza o respetivo modelo PV. Já o método indireto tem o objetivo de ultrapassar a natureza implícita das equações, este método reside na utilização dos algoritmos determinísticos, como por exemplo, o método de *Newton Raphson* e a função *w* de *Lambert*. Assim, em função da revisão bibliográfica verifica-se que, os autores na sua maioria optaram pela aplicação do método direto que consiste na resolução da equação que caracteriza o respetivo modelo matemático.

Para minimizar o erro e avaliar o desempenho do algoritmo de otimização na extração dos parâmetros PV podem ser utilizados vários índices de desempenho, tais como: o erro absoluto (AE), o erro absoluto médio (MAE), o erro quadrático (SSE) e a raiz quadrada do erro quadrático médio (RMSE). No entanto, pode-se constatar que o índice de desempenho mais utilizado consiste no RMSE (100% dos autores preferem a utilização do RMSE).

Tabela 3. 1 –Tabela dos algoritmos evolucionários.

Algoritmo	Tecnologias PV	Modelo matemático	Função objetivo	Equation/NRP/LAMBERT
IJAYA[43]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
ATPBADE[45]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM	RMSE	Método direto (Equação)
PGJAYA[46]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
MADE[47]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
GACCC[48]	Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
LCJAYA[5]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
R-II and R-III[4]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM, TDM	RMSE	Método direto (Equação)
EJADE[49]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
SGDE[50]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
SEDE[51]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
MJA[52]	R.T.C solar cell	SDM, DDM	RMSE	Método direto (Equação)
MLSHADE[53]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
DPDE[7]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM, DDM, TDM	RMSE	Método direto (Equação)
DEDCF[54]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	NRP
CJAYA[55]	R.T.C solar cell STM6-40/36	SDM, DDM	RMSE	Método direto (Equação)

	STP6-120/36			
EBLSHADE[3]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
MPPCEDE[6]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
EJAYA[8]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
MRao-1[44]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)

3.2. Algoritmos baseados em Enxames

3.2.1. Particle Swarm Optimizacion

O algoritmo *Particle Swarm Optimizacion* (PSO) é um algoritmo bio inspirado na natureza, tem por base uma população, ou seja, foi motivado pela interação e comportamento social de várias espécies (cardumes de peixes e bandos de pássaros). O processo de inicialização do algoritmo passa por posicionar de forma aleatória os indivíduos no espaço de procura representada pela seguinte equação[56].

$$x_{i,d} = LB_d + r_{i,d} \cdot (UB_d - LB_d) \quad (3.17)$$

Além disso, o processo de otimização deste algoritmo passa pela constante avaliação da sua função de aptidão, ou seja, no PSO cada indivíduo pertencente à população pode vir a ser uma possível solução para o problema. Assim, cada indivíduo detém uma determinada posição e uma determinada velocidade que podem ser alteradas consoante a própria experiência do indivíduo e também pela experiência dos restantes indivíduos da população.

A atualização da velocidade e da posição dos indivíduos, vai ser alterada através das seguintes equações:

$$v_{i,d}(t+1) = w \times v_{i,d}(t) + r_{i,d} \times c_1 \times [x_{pbest,i,d} - x_{i,d}(t)] + r_{i,d} \times c_2 \times [x_{gbest,d}(t) - x_{i,d}(t)] \quad (3.18)$$

$$x_{i,d}(t + 1) = x_{i,d}(t) + v_{i,d}(t + 1) \quad (3.19)$$

Onde, w representa o fator de inércia, v_i ilustra a velocidade do indivíduo, c_1 e c_2 representam coeficientes de aceleração, x_{pbest_i} caracteriza a melhor posição do indivíduo i e x_i representa a posição do indivíduo na iteração (t) .

A Figura 3.4 representa, de forma sucinta, as várias etapas/processos do algoritmo meta-heurístico PSO. Como é comum nos algoritmos de otimização, é realizado um posicionamento inicial dos indivíduos dentro do espaço de procura multidimensional. Após a execução do posicionamento inicial dos indivíduos, através da equação (3.18), inicia-se outro processo neste algoritmo, no qual, são atualizadas as velocidades de todos os indivíduos da população. Posteriormente à realização deste processo é iniciado outro, ou seja, através da equação (3.19) a posição dos indivíduos vai ser atualizada. Posteriormente à realização deste processo, efetua-se a atualização do x_{gbest} e x_{pbest} . Por fim, como é familiar para o algoritmo de otimização terminar a sua execução o critério de paragem tem de ser cumprido.

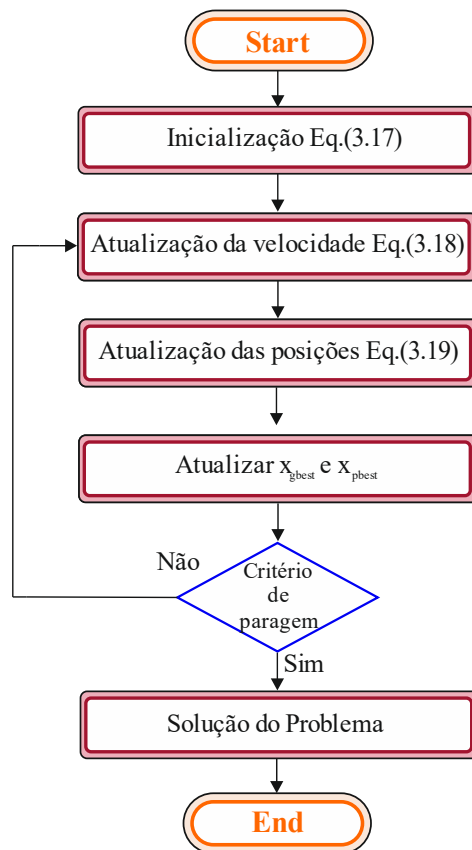


Figura 3. 4 – Fluxograma do algoritmo PSO

3.2.2. Grey wolf optimizer

O algoritmo *Grey wolf optimizer* (GWO) é um algoritmo bio, inspirado no comportamento e na interação dos lobos cinzentos (indivíduos) na sua estratégia de caça. A matilha de lobos (população) é conhecida por viver em pequenas populações, mas com uma hierarquia bem definida e rígida. Assim, a população está disposta em quatro níveis, *alfa*, *beta*, *delta* e *ômega*. O melhor indivíduo é designado por *alfa*, que corresponde à melhor solução para problema em questão, o segundo melhor indivíduo é o *beta*, o terceiro melhor será o *delta*, por último, os indivíduos *ômega* contêm as piores soluções para problema [56]. De forma resumida, este algoritmo pode ser dividido em três fases distintas, nomeadamente: cercar a presa, caçar a presa e atacar a presa.

A primeira fase do algoritmo de otimização, consiste nos indivíduos cercarem a presa que foi selecionada para posteriormente ser caçada. Esta fase pode ser expressa pelas seguintes equações:

$$D_{i,d} = |C * x_{gbest,d} - x_{i,d}(t)| \quad (3.20)$$

Onde $C = 2 * r_1$, x_{gbest} corresponde à posição da presa.

$$x_{i,d}(t+1) = |x_{gbest,d} - A_d * D_{i,d}| \quad (3.21)$$

Em que a variável A está expressa na equação seguinte.

$$A = a * (2 * r_1 - 1) \quad (3.22)$$

Onde variável A apresenta um comportamento linear e decrescente, i.e., um comportamento decrescente entre dois e zero em função do número de iterações.

Na segunda fase do algoritmo (caçar a presa) consiste na caça à presa. Assim como foi dito anteriormente o indivíduo que lidera a população é o indivíduo alfa, logo este vai liderar a caça à presa. No entanto este indivíduo vai contar com a ajuda do indivíduo beta e do indivíduo delta. Portanto a posição de todos os indivíduos da população vai ser atualizada consoante a posição dos três melhores indivíduos, isto é, o indivíduo alfa, beta e delta. Esta fase do algoritmo de otimização pode ser expressa através das seguintes equações (3.23)-(3.25), (3.26)-(3.28) e (3.29).

Para determinar a distância do indivíduo i para o indivíduo α (x_α), β (x_β) e δ (x_δ) é necessário aplicar as seguintes equações:

$$D_{\alpha,d} = |C_d * x_{\alpha,d} - x_{i,d}(t)| \quad (3.23)$$

$$D_{\beta,d} = |C_d * x_{\beta,d} - x_{i,d}(t)| \quad (3.24)$$

$$D_{\delta,d} = |C_d * x_{\delta,d} - x_{i,d}(t)| \quad (3.25)$$

Onde x_α , x_β e x_δ representam a posição dos indivíduos α , β e δ , respectivamente, x_i representa a posição do indivíduo i na iteração (t) e, por último, a variável C representa um número aleatório entre zero e dois.

A cada iteração (t) são determinadas as posições auxiliares x_1 , x_2 , x_3 que correspondem à distância entre o indivíduo i e as três melhores posições. Portanto, as posições auxiliares x_1 , x_2 , x_3 são caracterizadas pelas seguintes equações:

$$x_{1,d} = |x_{\alpha,d}(t) - A_d * D_{\alpha,d}| \quad (3.26)$$

$$x_{2,d} = |x_{\beta,d}(t) - A_d * D_{\beta,d}| \quad (3.27)$$

$$x_{3,d} = |x_{\delta,d}(t) - A_d * D_{\delta,d}| \quad (3.28)$$

A cada iteração, a nova posição do indivíduo i vai ser definida com base na média das posições auxiliares calculadas anteriormente. Este processo está representado através da seguinte equação.

$$x_{i,d}(t + 1) = \frac{x_{1,d} + x_{2,d} + x_{3,d}}{3} \quad (3.29)$$

A última fase do algoritmo de otimização (ataque à presa), consiste na investida à presa. Nesta fase do algoritmo este privilegia o mecanismo de intensificação através do decréscimo linear da variável a a cada iteração. Consequentemente, com o decréscimo de a a variável A vai decrescer também ao longo das iterações. Logo, os valores de a e A possibilitam que o GWO altere entre os mecanismos de intensificação e diversificação. Portanto, com o decréscimo da variável A metade das iterações são aplicadas para o mecanismo de intensificação, em contrapartida a outra metade é aplicada para o mecanismo de diversificação.

A Figura 3.5 ilustra, de forma resumida, as várias etapas/processos do método meta-heurístico *Grey Wolf Optimizer*. Em primeiro lugar, deve ser efetuado o posicionamento inicial dos indivíduos dentro do espaço de procura multidimensional. Em seguida, iniciam-se os parâmetros de controlo do algoritmo de otimização. Após a inicialização dos parâmetros de controlo, calcula-se a posição do indivíduo alfa, beta e delta. Concluído este processo, efetua-se a atualização dos parâmetros de controlo do algoritmo de otimização. Posto isto, através das equações (3.23) -(3.25), determina-se a distância do indivíduo alfa, beta e delta para o indivíduo i . Uma vez realizado o cálculo da distância, através das equações (3.26)-(3.28), calculam-se três posições auxiliares que representam a distância do indivíduo i para as três melhores posições. Posto isto atualiza-se a posição de todos os indivíduos da população. Por último para terminar a execução do algoritmo de otimização é necessário que o critério de paragem seja atingido.

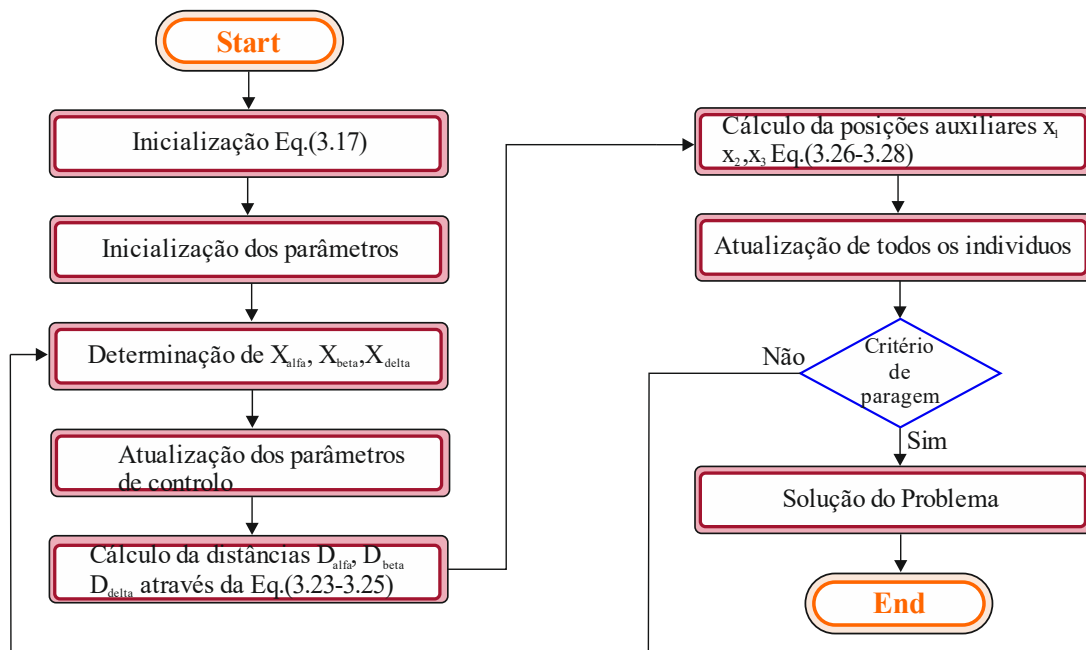


Figura 3. 5 – Fluxograma do algoritmo Grey Wolf

3.2.3. Flower Pollination Algorithm

O *Flower Pollination Algorithm* (FPA) é um algoritmo meta-heurístico inspirado na replicação do comportamento de polinização das espécies vegetais (flores e plantas). O processo de polinização é um procedimento natural que pode ocorrer de duas maneiras distintas: autopolinização e polinização cruzada. A autopolinização decorre na própria espécie vegetal e, tipicamente, só ocorre quando não se encontra disponível nenhum

agente polinizador[27]. Já a polinização cruzada, realiza-se quando existe uma troca de pólen entre duas espécies vegetais diferentes. O transporte do pólen pode ser feito segundo dois fatores, o fator biótico e o abiótico. Na polinização abiótica o pólen é transportado através do meio ambiente (água ou vento). Tipicamente, na polinização biótica o pólen é transportado através de animais.

A equação (3.30) favorece o mecanismo de diversificação com a inclusão de um número aleatório que obedece à distribuição de *Lévy*. A distribuição de *Lévy* é uma distribuição estável de variância infinita que obriga a construção de novas posições em regiões afastadas da melhor posição encontrada até o momento. Através desta distribuição é possível alcançar uma maior exploração do espaço de procura e evitar a convergência prematura.

$$x_{i,d}(t+1) = x_{i,d}(t) + L(S, \lambda) \left(x_{i,d}(t) - x_{gbest,d}(t) \right) \quad (3.30)$$

Onde $L(S, \lambda)$ representa um número aleatório segundo a distribuição de *Lévy* calculada através da seguinte equação:

$$L(S, \lambda) \sim \frac{\lambda \Gamma(\lambda) \sin\left(\frac{\pi\lambda}{2}\right)}{\pi} \frac{1}{S^{1+\lambda}} \quad (S \gg S_0 > 0) \quad (3.31)$$

Em que λ corresponde a um fator de escala que permite controlar o tamanho do passo e $\Gamma(\lambda)$ representa a função *gamma* consoante a distribuição válida para $S > 0$.

De forma a possibilitar a construção de novas posições junto da melhor solução encontrada até ao momento (mecanismo de intensificação) é aplicada a seguinte equação:

$$x_{i,d}(t+1) = x_{i,d}(t) + \varepsilon(x_{r_1,d}(t) - x_{r_2,d}(t)) \quad (3.32)$$

Onde ε corresponde a um valor aleatório entre 0 e 1.

A figura 3.6 representa, o fluxograma das várias etapas do algoritmo de otimização meta-heurístico FPA. Como é comum nestes algoritmos de otimização, em primeiro lugar é necessário posicionar os indivíduos dentro do espaço de procura multidimensional. Após a determinação da melhor solução global é realizada uma comparação entre a probabilidade p_s e um número aleatório entre zero e um. Esta comparação vai determinar qual dos processos vai ser efetuado pelo FPA. Portanto, se r_1 for maior que p_s o algoritmo de otimização favorece a procura global, representada através da equação

(3.30). No entanto, se p_s for maior que r_1 o FPA beneficia uma procura local, representada através da equação (3.32). Por último, como é normal a execução do algoritmo de otimização termina quando o critério de paragem for atingido.

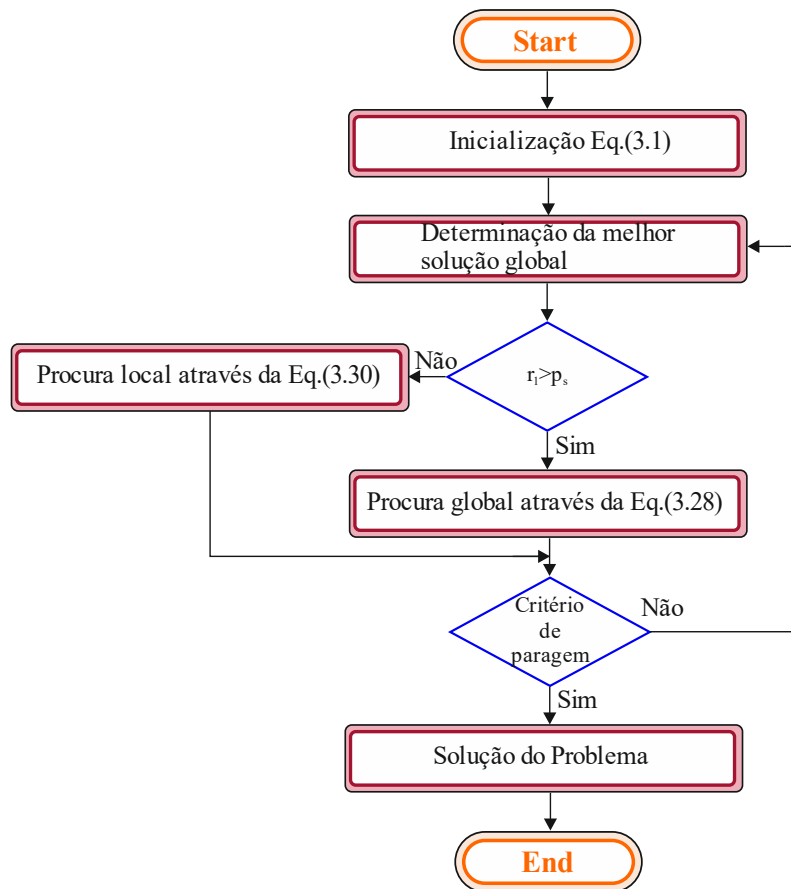


Figura 3. 6 – Fluxograma do algoritmo FPA

3.2.4. Whale Optimization Algorithm

O *Whale Optimization Algorithm* (Woa) é um algoritmo meta-heurístico inspirado no comportamento de caça das baleias. A estratégia de caça destas baleias consiste na formação de uma espiral de bolhas para direcionar e circunscrever a fonte de alimento (peixes de pequeno porte ou grande cardumes). O algoritmo de otimização WOA, possui três fases distintas: cercar a presa, caça com rede de bolhas e procura das presas. Nas duas primeiras fases o algoritmo de otimização vai favorecer o mecanismo de intensificação. Com estas técnicas de caça o WOA permite que os indivíduos se movimentem no espaço de procura multidimensional de forma a encontrarem a melhor solução possível para o problema em questão [57]. Através do movimento dos indivíduos ocorre uma procura aleatória, ou seja, com a melhor posição do indivíduo até ao momento. Assim, outros indivíduos são obrigados a procurar novas soluções, próximas da melhor solução encontrada.

A primeira fase (cerco da presa), consiste no cerco da presa que foi selecionada como alvo. Em seguida o WOA determina o indivíduo que está mais próximo da presa. Após isto todos os restantes indivíduos da população vão atualizar a sua posição através das seguintes equações.

$$D_{i,d} = |C_d \cdot x_{\text{gbest},d}(t) - x_{i,d}(t)| \quad (3.33)$$

Onde C_d representa um número aleatório entre zero e dois.

$$x_{i,d}(t + 1) = x_{\text{gbest},d}(t) - A_d \cdot D_{i,d} \quad (3.34)$$

Em que a variável A é determinada através da equação seguinte.

$$A = 2 \cdot a \cdot r - a \quad (3.35)$$

Onde, a é uma variável linear e decrescente que diminui linearmente de dois para zero ao longo das iterações.

A segunda fase do algoritmo (caça com rede de bolhas), divide-se em duas estratégias: a redução da espiral e a atualização da posição da espiral. A escolha da estratégia vai depender de uma probabilidade p . Portanto, se a probabilidade $p \geq 0.5$ os indivíduos vão atualizar a sua posição através da equação seguinte.

$$x_{i,d}(t + 1) = D'_{i,d} \cdot \exp(bl) \cdot \cos(2\pi l) + x_{\text{gbest},d}(t) \text{ if } p \geq 0.5 \quad (3.36)$$

Onde, $D'_{i,d} = |x_{\text{gbest}} - x_i|$, b corresponde a uma constante que define a forma da função logarítmica, l e p são números reais aleatórios entre zero e um.

No entanto, se a probabilidade $p < 0.5$ os indivíduos vão atualizar a sua posição através da seguinte equação.

$$x_{i,d}(t + 1) = x_{\text{gbest},d}(t) - A_d \cdot D_{i,d} \text{ if } p < 0.5 \quad (3.37)$$

A terceira fase do algoritmo (procura de presas) é expressa pelas seguintes equações que têm o objetivo de beneficiar o mecanismo de diversificação, ou seja, favorecer a procura

global. Em contrapartida nesta fase a nova posição dos indivíduos não vai ser em função do melhor indivíduo, mas sim em função de um indivíduo aleatório.

$$D_{i,d} = |C_d \cdot x_{r1,d}(t) - x_{i,d}(t)| \quad (3.38)$$

$$x_{i,d}(t + 1) = x_{r1,d}(t) - A_d \cdot D_{i,d} \quad (3.39)$$

A Figura 3.7 ilustra, de forma sucinta, as várias etapas/processos do algoritmo meta-heurístico WOA. Como já é habitual, nestes algoritmos de otimização é efetuado um posicionamento inicial dos indivíduos, dentro do espaço de procura multidimensional. Depois do posicionamento inicial dos indivíduos é efetuada a inicialização dos parâmetros de controlo do algoritmo de otimização. Após a inicialização dos parâmetros de controlo é determinada a melhor solução. Logo após a determinação da melhor solução é realizada uma comparação para avaliar se a variável p é menor que 0.5. Portanto se a condição não se verificar a posição do indivíduo vai ser atualizada através da equação (3.37). No entanto se a condição se verificar o próximo processo passa por avaliar a variável A , ou seja, se A for maior ou igual a um a posição do indivíduo vai ser atualizada através das equações (3.38) e (3.39). Além disso se a variável A for menor que um a posição do indivíduo vai ser atualizada através das equações (3.33) e (3.34). Por fim a o algoritmo de otimização acaba quando o critério de paragem for alcançado.

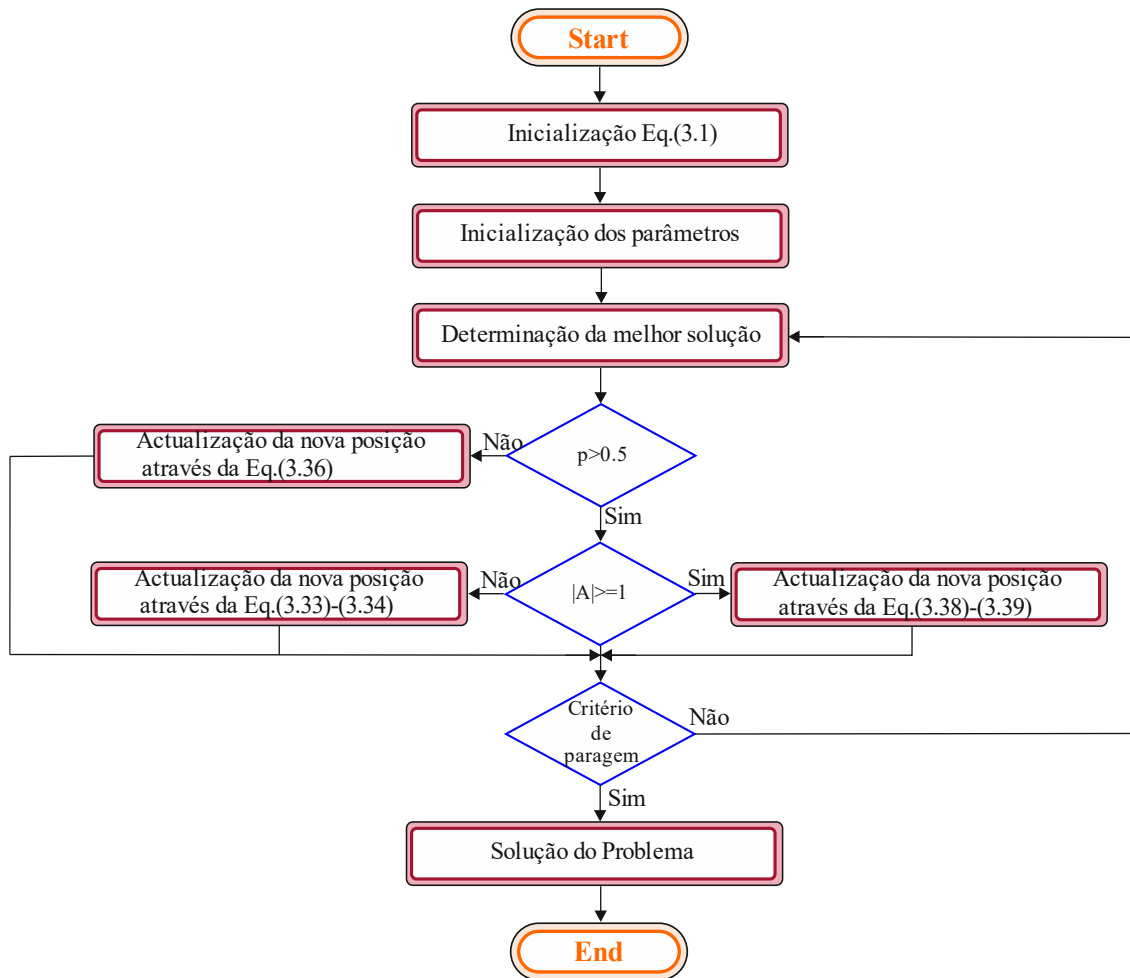


Figura 3. 7 – Fluxograma do algoritmo WOA

3.2.4. Revisão da literatura dos algoritmos baseados em Enxames

No que diz respeito aos algoritmos de *swarm*, na literatura especializada é possível encontrar vários algoritmos de otimização para a extração de parâmetros fotovoltaicos nomeadamente: *A Chaotic Improved Artificial Bee Colony* (CIABC); *Quantum particle swarm optimization* (QPSO); *modified simplified swarm optimization algorithm* (MSSO); *improved whale optimization algorithm* (IWOA); *Modified Elephant Swarm Water Search Algorithm* (MESWSA); *flexible particle swarm optimization algorithm* (FPSO); *A new hybrid algorithm based on grey wolf optimizer and cuckoo search* (GWOCS); *Coyote Optimization Algorithm* (COA); *Salp Swarm algorithm* (SSA); *Hybrid Particle Swarm and Grey Wolf Optimization Algorithms* (PSOGWO); *Double Exponential Function-Based Dynamic Inertia Weight Particle Swarm Optimization* (DEDIWPSO); *Orthogonally adapted Harris hawks optimization* (EHHO); *improved cuckoo search optimization* (ICSO); *niche-based particle swarm optimization in parallel computing architecture* (NPSOPC); *variables reduction and improved shark optimization technique* (ISSA); *Delayed dynamic step shuffling frog-leaping algorithm*

(DDSFLA); *Enhanced Particle Swarm Optimization* (ESPO); *Modified FPA with Dynamic Switch Probability and Step Size Function* (FPA); *Improved Metaheuristic Optimization Algorithm* (Momentum-type PSO); *Ant Lion Optimizer with LambertW function* (ALO); *Hybrid WOAPSO Algorithm* (WOAPSO).

Durante a revisão bibliográfica elaborada, comprova-se que os algoritmos de otimização estão em voga como por exemplo, o PSO, WOA, GWO e FPA. Além disso nos últimos anos existem outros algoritmos de otimização que têm vindo a ganhar a sua relevância tais como: ALO, SSA, COA, CSO e entre outros.

A Tabela 3.2 retrata, de forma sucinta, os vários fatores que podem influenciar o desempenho e precisão dos algoritmos de otimização. Portanto, os vários fatores que podem interferir são os modelos matemáticos aplicados, as tecnologias PV utilizadas, a função objetivo e a técnica aplicada para ultrapassar a natureza implícita das equações.

Em relação aos modelos matemáticos que permitem simular/caracterizar uma célula ou módulo PV, constata-se que os autores dão preferência à aplicação do modelo de um diodo com aproximadamente 96%. A par do modelo de um diodo o modelo de dois também reúne as preferências de vários autores com cerca de 87%. Em sentido inverso encontra-se o modelo de três diodos com apenas 0.08%.

Consoante a revisão bibliográfica realizada nestes últimos anos, os autores da literatura especializada continuam a optar pela aplicação do método direto, mas neste caso em alguns algoritmos *swarm* a decisão não foi unanime, pois, alguns autores optaram pela aplicação de métodos indiretos como é o caso do *Newton Raphson* e o método de *w* de *Lambert*.

Relativamente às tecnologias PV, estas permitem classificar tanto a precisão como o desempenho do algoritmo de otimização. Portanto no que diz respeito às tecnologias policristalinas é possível salientar a utilização *R.T.C solar cell*, *Photowatt-PWP 201* e *STP6-120/36*. No entanto, no que diz respeito às tecnologias monocristalinas, é possível realçar a utilização *STM6-40/36*. Além disso outras tecnologias têm vindo a ganhar alguma relevância nos últimos anos como *PVM 752*, *Solarex MSX 60*, *Organic a-Si* e *SS2018P PV module*.

Contudo, para minimizar o erro e classificar o desempenho do algoritmo de otimização, a função objetivo que é aplicada por todos os autores é o RMSE.

Tabela 3. 2 –Tabela dos algoritmos baseados em enxames.

Algoritmo	Tecnologias PV	Modelo matemático	Função objetivo	Equation/NRP/LAMBERT
CIABC[58]	R.T.C solar cell STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
CWOA[9]	R.T.C solar cell	SDM, DDM	RMSE	Método direto (Equação)
QPSO[59]	R.T.C solar cell Solarex MSX 60	SDM	RMSE	Método direto (Equação)
MSSO[60]	R.T.C solar cell	SDM, DDM	RMSE	Método direto (Equação)
FA[10]	R.T.C solar cell Photowatt-PWP 201 Organic a-Si	SDM, DDM	RMSE	Método direto (Equação)
IWOA[57]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
COA[12]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
MESWSA[61]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
FPSO[61]	R.T.C solar cell STM6-40/36	SDM, DDM	RMSE	Método direto (Equação)
GWOCs[62]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36	SDM, DDM	RMSE	Método direto (Equação)
COA[63]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM, TDM	RMSE	Método direto (Equação)
ALO[11]	R.T.C solar cell	DDM	RMSE	Método direto (Equação)
SSA[64]	R.T.C solar cell STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
PSOGWO[56]	Photowatt-PWP 201 STE4/100 PV Solar FSM PV Module	SDM, DDM	RMSE	Método direto (Equação)
DEDIWPSO[65]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	NRP
EHHO[66]	R.T.C solar cell Photowatt-PWP 201 PVM 752	SDM, DDM	RMSE	Método direto (Equação)
ICSO[67]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)/LAMBERT
NPSOPC[68]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
ISSO[69]	R.T.C solar cell STM6-40/36	SDM	RMSE	Método direto (Equação)

	STP6-120/36			
TGA[13]	R.T.C solar cell Photowatt-PWP 201 PVM 752	SDM, DDM	RMSE	NRP
DDSFLA[70]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
IMPA[14]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
EPSO[71]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM, TDM	RMSE	Método direto (Equação)
FPA[72]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	NRP
Momentum-type PSO[73]	R.T.C solar cell	SDM	RMSE	Método direto (Equação)
ALO[74]	R.T.C solar cell Photowatt-PWP 201	SDM	RMSE	<i>LAMBERT</i>
WOAPSO[75]	R.T.C solar cell SS2018P PV module	SDM, DDM	RMSE	Método direto (Equação)

3.3. Algoritmos baseados no comportamento humano

3.3.1. *Teaching-Learning-Based Optimization*

O *Teaching-Learning-Based Optimization* (TLBO), é um algoritmo de otimização baseado no ensino aprendizagem que surge da interação entre professores e alunos. A principal ideia por detrás deste algoritmo é, representar o ambiente de aprendizagem que ocorre dentro de uma sala de aula. Este algoritmo de otimização pode dividir-se em duas fases: a fase do professor e a fase de aprendizagem [16].

Tipicamente, uma sala de aula é constituída por um professor e vários alunos. O indivíduo com maior fonte de conhecimento é o professor, este tem como missão de transmitir o seu conhecimento para os alunos. Na fase do professor, primeiramente, tem de ser definida a média de conhecimento dos alunos (indivíduos), através da seguinte equação:

$$x_{\text{mean}} = \frac{1}{NP} \sum_{i=1}^{NP} x_i \quad (3.40)$$

Onde, NP corresponde ao número de indivíduos.

De forma a atualizar a posição dos alunos é utilizada a seguinte equação:

$$x_{i,d}(t+1) = x_{i,d}(t) + r_{1,d} \cdot (x_{\text{gbest},d}(t) - T_F \cdot x_{\text{mean},d}(t)) \quad (3.41)$$

Em que, T_F representa o fator de ensino e o seu valor pode variar entre $[1,2]$.

Na fase de aprendizagem, o objetivo passa por os alunos interagirem entre si, para que o seu nível de conhecimento possa melhorar. Este processo é formulado através das seguintes equações:

$$x_{i,d}(t+1) = x_{r_1,d}(t) + r_{1,d} \cdot (x_{r_1,d}(t) - x_{r_2,d}(t)), \text{if } f(x_{r_1}(t)) \leq f(x_{r_2}(t)) \quad (3.42)$$

$$x_{i,d}(t+1) = x_{r_1,d}(t) + r_{1,d} \cdot (x_{r_2,d}(t) - x_{r_1,d}(t)), \text{if } f(x_{r_1}(t)) > f(x_{r_2}(t)) \quad (3.43)$$

A Figura 3.8 representa, de forma resumida, as várias etapas/processos do algoritmo meta-heurístico TLBO. Como habitual no início dos algoritmos de otimização, é realizado o posicionamento dos indivíduos dentro do espaço de procura multidimensional. Em seguida, através da equação (3.40) é determinada a média de conhecimento dos indivíduos da turma. Após a determinação da média de conhecimento da turma, identifica-se a melhor solução e calcula-se uma nova posição através equação (3.41). Após o cálculo da nova posição, os indivíduos vão sofrer um processo de seleção, no qual, a solução anterior vai ser mantida ou substituída. Depois de ultrapassado o processo de seleção, são escolhidos dois indivíduos aleatoriamente de forma a serem comparados. Portanto, se a posição do primeiro indivíduo for melhor que a do segundo indivíduo a sua posição vai ser atualizada através da equação (3.43). Em sentido inverso, se a posição do segundo indivíduo for melhor que a do primeiro a sua posição vai ser alterada através da equação (3.42). Além deste processo, como já é normal para se dar por terminado o algoritmo de otimização o critério de paragem tem de ser atingido.

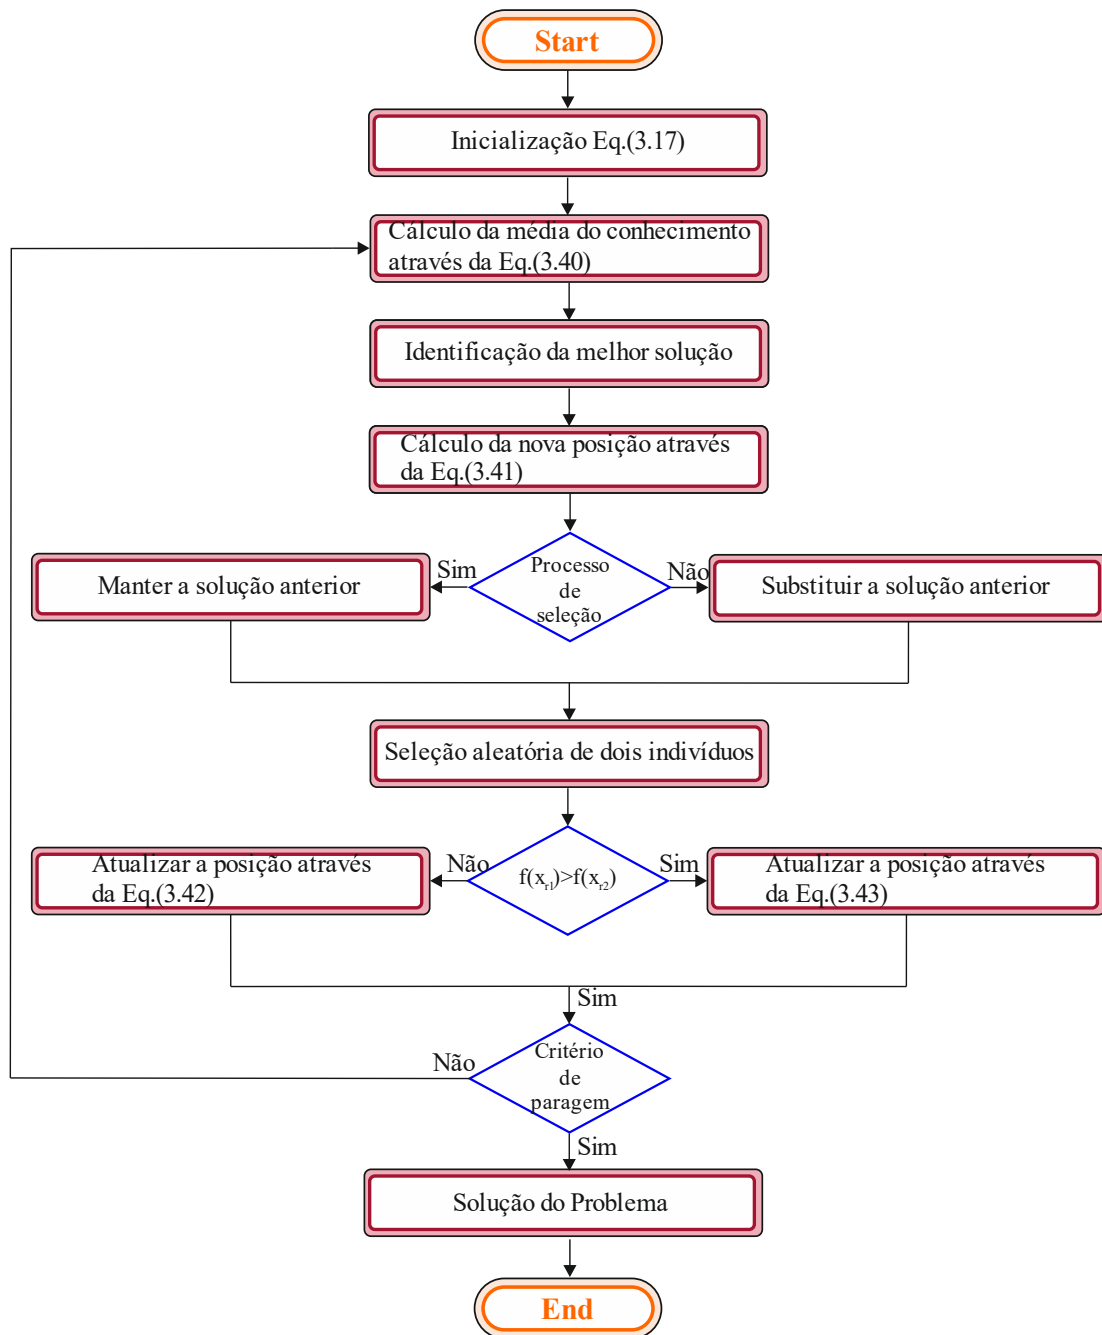


Figura 3. 8 – Fluxograma do algoritmo TLBO

3.3.2. Learning Search Algorithm

O *Learning Search Algorithm* (LSA) é um algoritmo de otimização meta- heurístico populacional (grupo de alunos) que consiste na aprendizagem e na partilha de conhecimento que ocorre dentro de uma sala de aula. Este algoritmo consiste na geração de um grupo de estudantes e a cada iteração, é avaliado o seu nível de conhecimento[17].

O conceito do algoritmo passa por escolher os melhores e os piores alunos da turma e em seguida calcular a média de conhecimento dos mesmos. Assim, o LSA divide-se em duas estratégias: uma de padrão positivo e outra de padrão negativo.

No padrão positivo, o procedimento baseia-se no melhor indivíduo do grupo. Este vai partilhar o seu conhecimento de forma a ajudar e promover o conhecimento dos restantes indivíduos. Este procedimento pode ser formulado através da seguinte equação:

$$x_{i,d}(t+1) = x_{i,d}(t) + r_{1,d} \times \left(a_f \times x_{gbest,d}(t) - x_{mean}(t) \right), \text{if } r_{3,d} > S_{ar} \quad (3.44)$$

$$x_{i,d}(t+1) = LB_d + r_{2,d} \times (UB_d - LB_d), \text{if } r_{3,d} \leq S_{ar} \quad (3.45)$$

Onde, S_{ar} , representa a taxa de autoaprendizagem, a_f corresponde a um fator de atração que varia entre [1,2], e $x_{i,d}$ representa um indivíduo pertencente ao grupo de alunos.

No padrão negativo, cada indivíduo partilha o seu conhecimento com o pior aluno. Esta estratégia permite diversificar a construção de novas soluções (posições) e simultaneamente, aumentar o nível de conhecimento dos piores alunos. Este procedimento é expresso pelas seguintes equações:

$$u_{i,d}(t+1) = x_{i,d}(t) + r_{4,d} \times \left(x_{worst,d}(t) - Mf \times x_{mean}(t) \right), \text{if } r_{6,d} > S_{ar} \quad (3.46)$$

$$u_{i,d}(t+1) = LB_d + r_{5,d} \times (UB_d - LB_d), \text{if } r_{6,d} \leq S_{ar} \quad (3.47)$$

Em que Mf representa um fator médio que varia entre [1,2].

De forma resumida, a Figura 3.9 ilustra, as várias etapas/processos do algoritmo meta-heurístico LSA. Como já é comum, no início dos algoritmos de otimização realiza-se o posicionamento dos indivíduos dentro do espaço de procura multidimensional. Depois do posicionamento dos indivíduos é identificada a melhor solução. Depois da identificação da melhor solução é calculada a média de conhecimento dos indivíduos da turma. Depois do cálculo da média de conhecimento dos indivíduos é realizada uma comparação entre r_3 e S_{ar} . Portanto, se r_3 for maior que S_{ar} a atualização da posição dos indivíduos vai ser efetuada através da equação (3.44). No entanto se S_{ar} for maior que r_3

a posição dos indivíduos vai ser atualizada através da equação (3.45). Após este processo de comparação, vai ser determinada qual a melhor (x_{gbest}) e a pior solução (x_{worst}). Posteriormente à determinação, vai ocorrer outro processo de comparação entre r_6 e S_{ar} . Portanto se r_6 for maior que S_{ar} a posição dos indivíduos vai ser atualizada através da equação (3.46). No entanto se S_{ar} for maior que r_6 a posição dos indivíduos vai ser atualizada através da equação (3.47). Por último o algoritmo é finalizado quando o critério de paragem for alcançado.

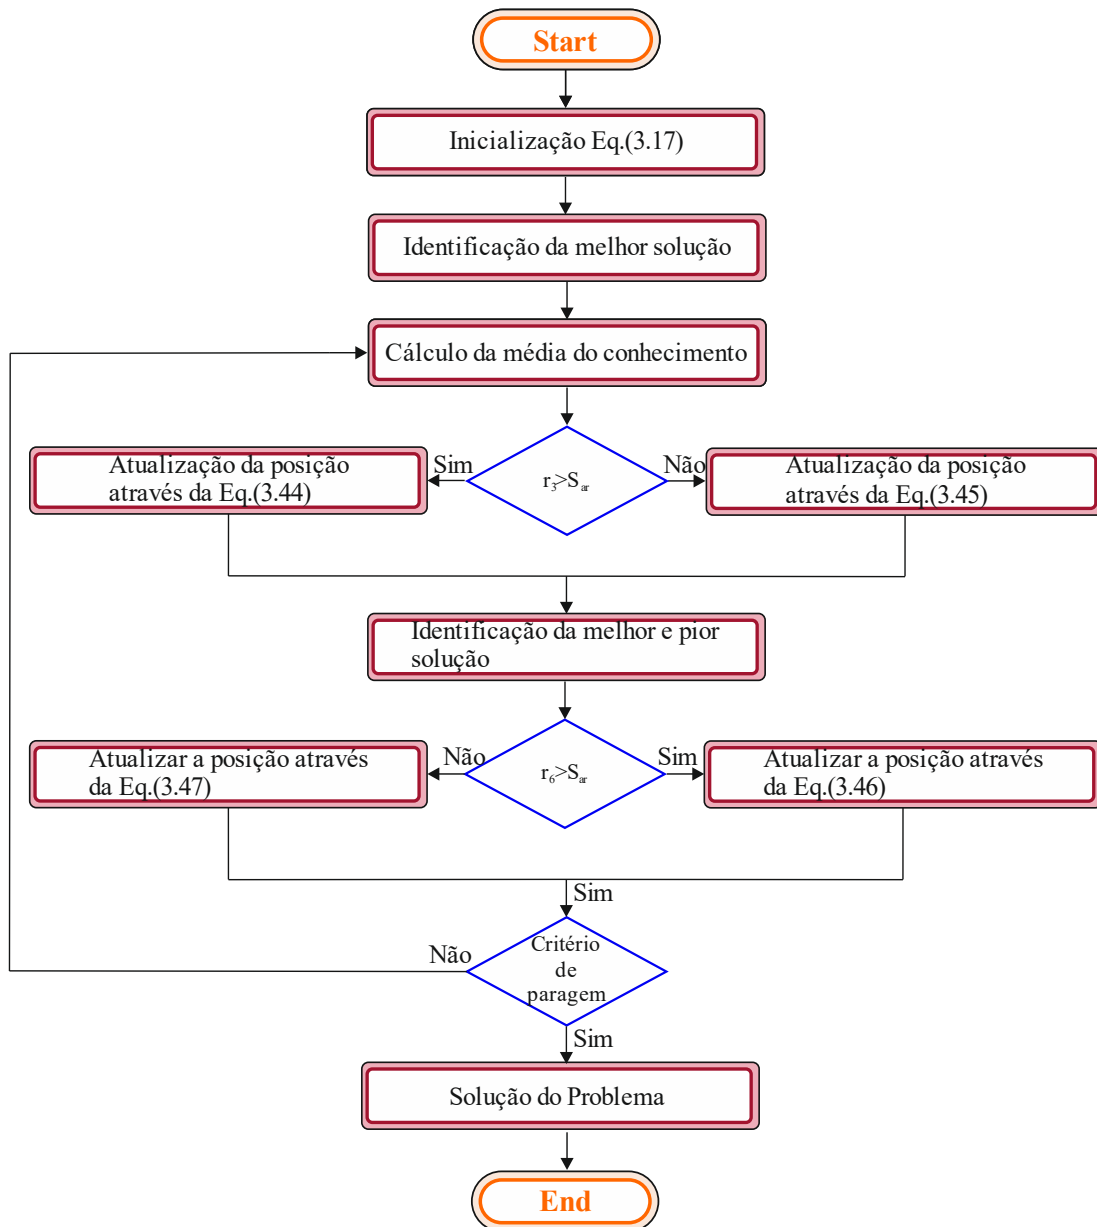


Figura 3. 9 – Fluxograma do algoritmo LSA

3.3.3. *Gaining-Sharing Knowledge*

O *Gaining-Sharing Knowledge* (GSK) é um algoritmo meta-heurístico populacional inspirado na partilha e recolha de conhecimento durante o seu ciclo de vida enquanto ser humano. Numa sociedade, todos os indivíduos que nela estejam inseridos vão relacionar-se, ou seja, cooperar entre si, partilhar conhecimentos/experiências durante o seu ciclo de vida[76].

Com base nisto, o GSK divide-se em duas fases: *junior gaining and sharing* e *senior gaining sharing*.

No início o GSK considera todos os indivíduos juniores, pois estes não possuem qualquer tipo de conhecimento nem experiência. Com a recolha de conhecimento efetuada pelos indivíduos, estes passam a ser considerados seniores. De forma a atualizar o seu conhecimento consoante o avanço das iterações são utilizadas as seguintes equações:

$$d_{juniorphase}(t) = d \left(1 - \frac{t}{t_{max}}\right)^{k_{rt}} \quad (3.48)$$

$$d_{seniorphase}(t) = d - d_{juniorphase}(t) \quad (3.49)$$

Na qual, $d_{juniorphase}$ representa a fase de *junior gaining and sharing*, t_{max} representa o número de iterações máximo, k_{rt} representa a taxa de conhecimento que corresponde a um número real maior que zero, d representa a dimensão do problema e $d_{seniorphase}$ representa a fase *senior gaining and sharing*.

Portanto, na fase *junior gaining sharing* os indivíduos têm como objetivo a recolha e partilha de conhecimento com outros indivíduos que possam ou não pertencer ao mesmo grupo. Tipicamente os indivíduos são colocados por ordem decrescente consoante a função objetivo, ou seja, a primeira posição será ocupada pelo melhor indivíduo (x_{gbest}) e a pior posição será ocupada pelo pior indivíduo (x_{worst}). Além disso, para cada indivíduo determinam-se dois indivíduos que estejam o mais próximo possível dos mesmos, com o objetivo de estes serem a sua fonte de conhecimento e um terceiro indivíduo é definido aleatoriamente, com a finalidade do conhecimento ser partilhado entre todos, de forma a atualizar os indivíduos nesta fase é aplicada a seguinte equação:

$$x_{i,d}(t+1) = x_{i,d}(t) + k_f \left((x_{i-1,d}(t) - x_{i+1,d}(t)) + (x_{r1,d}(t) - x_{i,d}(t)) \right), \text{ se } f(x_i) > f(x_{r1}) \quad (3.50)$$

$$x_{i,d}(t+1) = x_{i,d}(t) + k_f \left((x_{i-1,d}(t) - x_{i+1,d}(t)) + (x_{i,d}(t) - x_{r1,d}(t)) \right), \text{ se } f(x_i) \leq f(x_{r1}) \quad (3.51)$$

$$x_{i,d}(t+1) = x_{i,d}(t) + k_f \left((x_{\text{gbest},d}(t) - x_{\text{worst},d}(t)) + (x_m(t) - x_{i,d}(t)) \right), \text{ se } f(x_i) > f(x_m) \quad (3.52)$$

$$x_{i,d}(t+1) = x_{i,d}(t) + k_f \left((x_{\text{gbest},d}(t) - x_{\text{worst},d}(t)) + (x_{i,d}(t) - x_m(t)) \right), \text{ se } f(x_i) \leq f(x_m) \quad (3.53)$$

Em que, x_m representa grupo intermédio, k_f é um fator de conhecimento que corresponde a um número real maior que zero.

A Figura 3.10 representa, de forma sucinta, as várias etapas/processos do algoritmo meta-heurístico GSK. Como já é normal, inicialmente é realizado um posicionamento inicial dos indivíduos, dentro do espaço de procura multidimensional. Em seguida deste posicionamento inicial dos indivíduos é também efetuada a inicialização dos parâmetros de controlo do algoritmo de otimização. Depois da inicialização dos parâmetros de controlo é determinada a melhor solução. Em seguida o algoritmo é dividido em duas etapas distintas. Portanto a primeira etapa corresponde à atualização da *junior gaining and sharing* através da equação (3.48), além disso a atualização da nova posição vai ser calculada através das equações (3.50) e (3.51). No entanto a segunda fase corresponde à *senior gaining and sharing*, a dimensão desta fase vai atualizada segundo a equação (3.49), além disto a atualização da nova posição vai ser calculada através das equações (3.52) e (3.53). Após a realização destas duas fases a nova posição vai ser avaliada e por consequência a população vai sofrer uma atualização. Por fim o algoritmo de otimização é finalizado quando o critério de paragem for atingido.

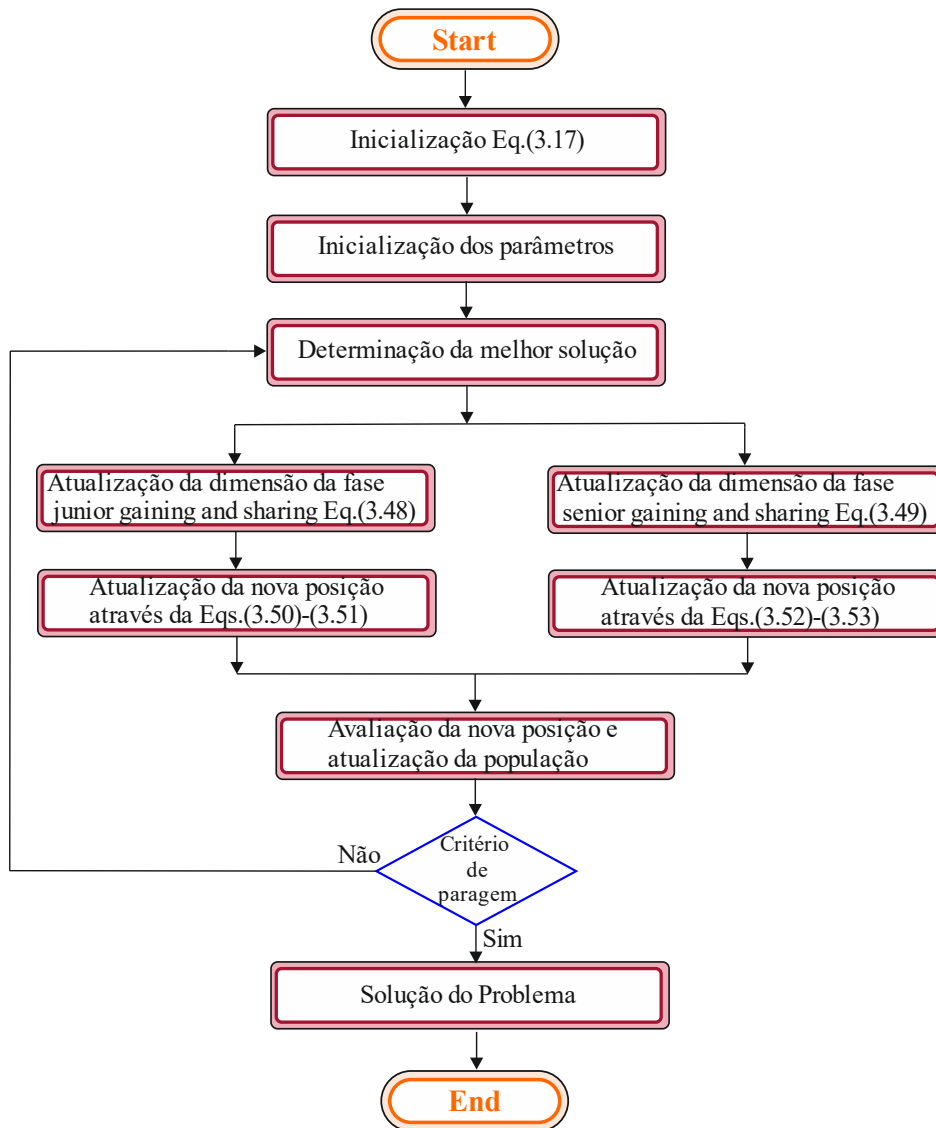


Figura 3. 10 – Fluxograma do algoritmo GSK

3.3.4. Revisão da literatura dos algoritmos baseados no comportamento humano

Em relação aos algoritmos humanos é possível encontrar imensos algoritmos de otimização para a extração dos parâmetros fotovoltaicos nomeadamente: self-adaptive teaching-learning-based optimization (SATLBO); Multiple learning backtracking search algorithm (MLBSA); an improved teaching learning-based optimization (ITLBO); Improved Moth-Flame Optimization (IMFO); Backtracking search algorithm with competitive learning (CBSA); Backtracking search algorithm with Lévy flight (LFBSA); Conscious neighborhood scheme-based Laplacian barnacles mating algorithm (NLBMA); either-or teaching learning based algorithm (EOTLBO); An efficient teaching-learning-based optimization algorithm (MTLBO).

Consoante a revisão bibliográfica efetuada, observa-se uma maior tendência para a utilização de algoritmos de otimização, como por exemplo, o TLBO. No entanto, nos últimos anos também se constata um aumento gradual na utilização do algoritmo de otimização LSA e GSK.

A Tabela 3.3 resume de forma sucinta os diferentes fatores que condicionam o rendimento e precisão do algoritmo de otimização para a extração dos parâmetros fotovoltaicos. Portanto, os fatores que afetam o rendimento dos algoritmos de otimização são: os modelos matemáticos que têm o objetivo de simular e caracterizar uma célula ou módulo PV, as tecnologias PV que são aplicadas pois estas permitem qualificar o desempenho do algoritmo, a função objetivo e por fim a técnica que permite superar a natureza implícita das equações que retrata os respetivos modelos matemáticos.

No que diz respeito aos modelos matemáticos os quais permitem simular e caracterizar uma célula ou módulo PV, verifica-se que na literatura especializada, como forma de comparação, o modelo de um diodo e dois díodos são de longe os modelos mais utilizados (100%). No entanto o modelo de três díodos não surge com tanta frequência como os modelos acima mencionados (0.06%).

Segundo a revisão bibliográfica realizada nos últimos anos, os autores preferiram a utilização do método direto, para ultrapassar as dificuldades impostas pela natureza implícita das equações, que caracterizam os modelos matemáticos.

Quanto às tecnologias PV mais aplicadas para analisar o desempenho e precisão do algoritmo de otimização para a extração dos parâmetros PV, são as tecnologias policristalinas e monocristalinas. Assim, na categoria da tecnologia policristalina pode-se realçar a utilização da *R.T.C solar cell, Photowatt-PWP 201* e *STP6-120/36*. No que diz respeito às tecnologias monocristalinas pode-se evidenciar a utilização *STM6-40/36*.

De forma a classificar o desempenho do algoritmo de otimização para a extração dos parâmetros fotovoltaicos, e apesar de existirem outros índices de desempenho os autores acabam por priorizar a utilização do RMSE (100%)

Tabela 3. 3 –Tabela dos algoritmos baseados nos humanos.

Algoritmo	Tecnologias PV	Modelo matemático	Função objetivo	Equation/NRP/LAMBERT
SATLBO[77]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
MLBSA[78]	R.T.C solar cell	SDM, DDM	RMSE	Método direto (Equação)

	Photowatt-PWP 201			
IBSO[19]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
SDO[18]	R.T.C solar cell STM6-40/36 STP6-120/36 PVM 752	SDM, DDM	RMSE	Método direto (Equação)
ITLBO[79]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
IMFO[80]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
CBSA[81]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
LFBSA[82]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
NLBMA[83]	R.T.C solar cell Photowatt-PWP 201 KC200GT	SDM, DDM	RMSE	NRP
EOTLBO[84]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
ILSA[17]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
TPTLBO[16]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
FBIA[20]	Photowatt-PWP 201 KC-200GT Module	SDM, DDM, TDM	RMSE	Método direto (Equação)
MTLBO[85]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
IGSK[15]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)

3.4. Algoritmos baseados em fenômenos físicos

3.4.1. *Wind Driven Optimizacion*

O *Wind Driven Optimizacion* (WDO) é um algoritmo de otimização inspirado na variação e na difusão das massas de ar, que acontecem devido às variações de pressão existentes na atmosfera[86]. Assim, o constante movimento destas massas de ar (indivíduos) é fundamentado na segunda lei de *Newton*, que consiste na aplicação de quatro forças são elas: a de atrito (\vec{F}_F), a gravitacional (\vec{F}_G), a de *Coriolis* (\vec{F}_C) e por último o gradiente de pressão (\vec{F}_{RC}).

O primeiro e o quarto termo, que representam a força de atrito e a força de *Coriolis*, privilegiam o mecanismo de diversificação do algoritmo de otimização, sem ter em conta a iteração (t). A força de atrito determina a tendência do movimento do indivíduo. Enquanto a força de atrito (\vec{F}_F) for a única força aplicada, o indivíduo conserva o seu movimento a uma velocidade determinada pelo coeficiente de atrito. Este coeficiente pode assumir um valor constante ou um valor que varia em função da velocidade do indivíduo. Já na força de *Coriolis* (\vec{F}_C), o movimento de cada indivíduo é manipulado pela velocidade de outro indivíduo, posicionado noutra dimensão e escolhido aleatoriamente. Esta força tem maior intervenção em indivíduos com menor pressão atmosférica, isto é, nos melhores indivíduos até o momento.

O segundo e o terceiro termo da equação (3.52), correspondem à força gravitacional e à força do gradiente de pressão, estes, privilegiam o mecanismo de intensificação do algoritmo de otimização. Assim, na força gravitacional, a deslocação de um determinado indivíduo é efetuada em direção à posição da melhor solução obtida até ao momento, consequentemente através da constante gravitacional. Este termo favorece os casos em que os indivíduos estão restringidos aos limites do espaço de procura. Em contrapartida, a força do gradiente de pressão atua mais fortemente nos indivíduos mais distantes da melhor solução encontrada até ao momento.

Portanto, de forma a originar este movimento do ar são necessárias estas quatro forças: força de gradiente de pressão (\vec{F}_{RC}), força de atrito (\vec{F}_F), força gravitacional (\vec{F}_G) e força de coriolis (\vec{F}_C).

Tendo por base estas quatro forças é possível definir a equação de um gás ideal na força. Perante a equação (3.52), a velocidade do ar está diretamente dependente do valor da pressão, ou seja, se o valor da pressão diminuir a velocidade também irá diminuir.

Portanto, de forma a atualizar a posição e velocidade a cada iteração (t) consoante os valores de pressão, as parcelas de ar vão ser classificadas por ordem decrescente utilizando as seguintes equações:

$$v_{i,d}(t+1) = \overbrace{(1-\alpha)v_{i,d}(t)}^{\text{Primeiro termo}} - \overbrace{gx_{i,d}(t)}^{\text{segundo termo}} + \dots \quad (3.54)$$

$$\dots + \overbrace{\left(\left| 1 - \frac{1}{j} \right| (x_{max} - x_{i,d}(t)) RT \right)}^{\text{Terceiro termo}} + \overbrace{\left(\frac{c \cdot v_{i,d}^{other\ dir}(t)}{j} \right)}^{\text{Quarto termo}}$$

$$x_{i,d}(t+1) = x_{i,d}(t) + (v_{i,d}(t+1) * \Delta t) \quad (3.55)$$

Onde, x_{max} corresponde à distância do ponto de pressão mais alto que foi encontrado, $v_i^{other\ dir}$ representa a velocidade em uma das outras dimensões por fim, Δt corresponde a um passo unitário com o valor 1.

A Figura 3.11 ilustra, de forma resumida, as várias etapas/processos do método meta-heurístico WDO. Em primeiro lugar é novamente realizado o posicionamento inicial dos indivíduos dentro do espaço de procura multidimensional. Depois do posicionamento inicial dos indivíduos, iniciam-se os parâmetros de controlo do algoritmo de otimização. Concluído o processo de iniciação dos parâmetros de controlo é determinada a melhor solução. Após o cálculo da melhor solução, a velocidade e posição dos indivíduos vai ser atualizada através das equações (3.52) e (3.53). Finalizado este processo, dá-se início a outro, onde os parâmetros de controlo vão ser atualizados. Finalmente, para completar o algoritmo de otimização é necessário que o critério de paragem seja atingido.

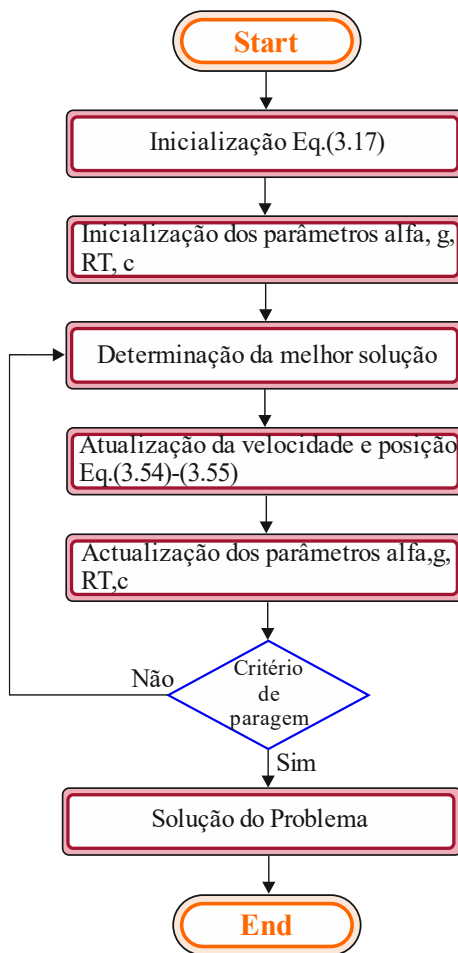


Figura 3. 11 – Fluxograma do algoritmo WDO

3.4.2. *Equilibrium optimizer*

O *equilibrium optimizer* (EO) é um algoritmo meta-heurístico, inspirado em fenómenos físicos que simulam o comportamento de um volume em equilíbrio. Ao longo de um certo período de tempo, este algoritmo vai contabilizar a quantidade de massa que entra e sai do respetivo volume. O algoritmo de otimização EO, utiliza um grupo de indivíduos que têm como objetivo replicar o vetor de concentração da massa sobre o volume. Desta forma, o vetor de concentração vai corresponder à melhor solução para o problema de otimização[87].

No início do processo de otimização, o estado de equilíbrio é desconhecido. Assim, o EO utiliza os quatro melhores indivíduos até ao momento e, além disso, é utilizado um quinto indivíduo que corresponde à média dos quatro indivíduos referidos anteriormente. Os primeiros quatro indivíduos têm como função ajudar o algoritmo no mecanismo de intensificação e, simultaneamente encontrar o ponto de equilíbrio. No entanto, o quinto indivíduo tem a responsabilidade de beneficiar o mecanismo de

diversificação, obrigando a construção de novas soluções afastadas da melhor solução encontrada até ao momento.

Portanto de forma a manter um equilíbrio entre o mecanismo de diversificação e intensificação, o EO utiliza o seguinte fator exponencial F , que diminui em função do avanço das iterações. Este fator exponencial pode ser expresso pela seguinte equação:

$$F = e^{-\lambda_e(t_p - t_{p0})} \quad (3.56)$$

Onde, λ representa um vetor gerado aleatoriamente entre zero e um, t_p representa a variável tempo que vai sendo diminuída com o incremento das iterações segundo a seguinte equação:

$$t_p = \left(1 - \frac{t_p}{t_{max}}\right) \left(a_2 * \frac{t_p}{t_{max}}\right) \quad (3.57)$$

Na qual, a_2 corresponde ao fator de controlo do mecanismo de diversificação e a variável t_{p0} é representada pela seguinte equação:

$$t_{p0} = \frac{1}{\lambda_e} \ln \left(-a_1 \text{sig} n(R - 0.5) [1 - e^{-\lambda_e t_p}] + t_p\right) \quad (3.58)$$

Onde, a_1 representa o fator de controlo do mecanismo de intensificação. Além disso outro fator que influencia o mecanismo de intensificação é o vetor R (Taxa de geração) expresso pela seguinte equação:

$$R = R_0 * e^{-\lambda_e * (t_p - t_{p0})} \quad (3.59)$$

Em que, R_0 corresponde a um valor inicial expresso através da seguinte expressão:

$$R_0 = R_{cp} * (x_{r1} - \lambda_e * x_i) \quad (3.60)$$

Onde, R_{cp} corresponde ao vetor de controlo da taxa de geração expresso na seguinte expressão:

$$R_{cp} = \begin{cases} 0.5 * r_1, & r_2 > RP \\ 0, & r_2 < RP \end{cases} \quad (3.61)$$

Este vetor R_{cp} , determina a taxa de geração que será aplicada à atualização da posição, que depende da probabilidade RP . Por último, a atualização da posição dos indivíduos pode ser expressa através da seguinte equação:

$$x_i = x_{r1} + (x_i - x_{r1}) * F + \frac{R}{\lambda * Vr} = (1 - F), Vr = 1 \quad (3.62)$$

A Figura 3.12 representa, de forma sucinta, as várias etapas/processos do algoritmo meta-heurístico LSA. Realiza-se de novo o posicionamento inicial dos indivíduos dentro do espaço de procura multidimensional. Depois do posicionamento inicial dos indivíduos, são iniciados os parâmetros de controlo. Após terminar o processo dos parâmetros de controlo, determina-se o melhor indivíduo da população. Posteriormente, através da equação (3.56) o termo exponencial F vai ser atualizado. Concluído o processo de atualização da variável F , chega a vez da variável R ser atualizada. Finalizado este processo de atualização, segundo a equação (3.62) a posição dos indivíduos vai ser atualizada. Logo depois da atualização da posição dos indivíduos a execução do algoritmo de otimização, chega ao fim desde que o critério de paragem seja alcançado.

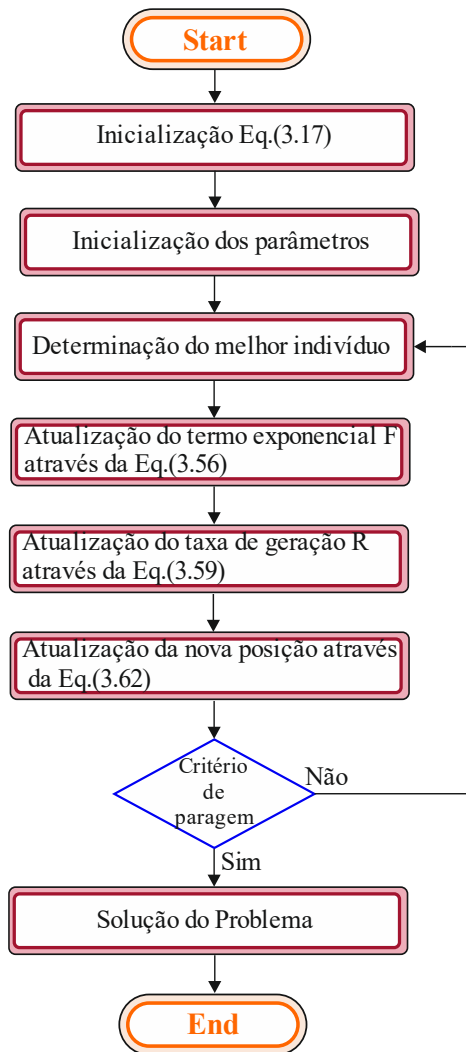


Figura 3. 12 – Fluxograma do algoritmo EO

3.4.3. Gravitational search algorithm

O *Gravitational search algorithm* (GSA) é um algoritmo meta-heurístico, inspirado na lei da gravidade. Neste algoritmo, os indivíduos são considerados objetos e a eficiência deste algoritmo é avaliada através das suas massas.

Portanto todos os indivíduos são atraídos pela força gravitacional, esta força vai causar um movimento a todos indivíduos em direção a outros que contenham massas mais pesadas, ou seja, os indivíduos são incentivados a cooperar entre si através da força gravitacional. Os indivíduos que contêm as massas mais pesadas são considerados como as melhores soluções do problema, no sentido inverso, os indivíduos que contêm as massas mais leves são considerados as piores soluções do problema. Assim, as melhores soluções movem-se mais lentamente em comparação com as piores soluções, isto é, o

indivíduo que contenha a massa mais pesada é a solução global do problema e tem como objetivo atrair o resto dos indivíduos para junto da sua posição[88].

No GSA, cada individuo é representado por quatro parâmetros: a posição, a massa gravitacional ativa, a massa gravitacional passiva e a inércia[89].

Para atualizar a posição dos indivíduos utiliza-se a seguinte equação:

$$x_{i,d}(t+1) = x_{i,d}(t) + v_{i,d}(t+1) \quad (3.63)$$

De forma a atualizar a velocidade dos indivíduos é aplicada a seguinte equação:

$$v_{i,d}(t+1) = r_{i,d} \times v_{i,d}(t) + a_i(t) \quad (3.64)$$

Denota-se que, $a_i(t)$ corresponde à aceleração de cada indivíduo e pode ser calculada através da seguinte equação:

$$a_i(t) = \frac{\text{Force}_i(t)}{\text{Mass}_i(t)}, \quad (3.65)$$

Onde, $\text{Force}_i(t)$ representa a força, $\text{Mass}_i(t)$ corresponde à massa representadas nas seguintes equações:

$$\text{Force}_i(t) = \sum_{j=1, j \neq i}^K r_{i,d} F_i(t) \quad (3.66)$$

$$\text{Mass}_i(t) = \frac{m_i(t)}{\sum_{j=1}^P m_d(t)} \quad (3.67)$$

Nas quais, r_i corresponde a um indivíduo aleatório, F_i representa a força gravitacional total que é exercida nos indivíduos, m_d corresponde ao valor da função objetivo num determinado momento por dimensão, já m_i representa o valor da função objetivo normalizada de um indivíduo num determinado momento, esta é definida através da equação (3.67) por fim a variável K é calculada através da seguinte equação:

$$K(t) = p + \left(\frac{1-t}{t_{max}}\right) \times (100 - p) \quad (3.68)$$

$$m_i(t) = \frac{f_i(t) - x_{\text{worst},d}(t)}{x_{\text{gbest},d}(t) - x_{\text{worst},d}(t)} \quad (3.69)$$

Em que $f_i(t)$ corresponde ao valor da função objetivo do individuo e p corresponde à percentagem de indivíduos que são aplicados na força.

Consecutivamente, através da equação seguinte é calculada a força gravitacional entre dois indivíduos específicos da população.

$$F_{ij}^r(t) = G(t) \frac{\text{Mass}_i(t) \times \text{Mass}_d(t)}{R_{i,d}(t) + \epsilon_g} (x_d(t) - x_i(t)) \quad (3.71)$$

Onde, G corresponde à constante gravitacional, $R_{i,d}$ representa a distância Euclidiana entre dois indivíduos, isto é, $R_{i,d} = \|x_i - x_d\|_2$, ϵ representa um valor muito pequeno prevenindo que o denominador seja diferente de zero.

A Figura 3.13 ilustra, de forma resumida, as várias etapas/processos do método meta-heurístico GSA. No qual, se pode constatar que primeiramente é efetuado um posicionamento inicial dos indivíduos dentro do espaço de procura multidimensional. Após este processo de inicialização, determina-se qual é o melhor (x_{gbest}) e pior (x_{worst}) indivíduo da população. Finalizado este processo, outro se inicia no seu lugar de forma a atualizar os parâmetros de controlo do algoritmo de otimização. Uma vez finalizado este processo de atualização dos parâmetros de controlo, através da equação (3.66) é determinada a força. Concluído o cálculo da força, segundo as equações (3.67) (3.65) é efetuada a determinação da Massa e aceleração. Realizada a determinação da Massa e da aceleração, segundo as equações (3.64) e (3.63) a velocidade e posição dos indivíduos vão ser atualizadas. A execução do algoritmo de otimização é finalizada quando o critério de paragem é alcançado.

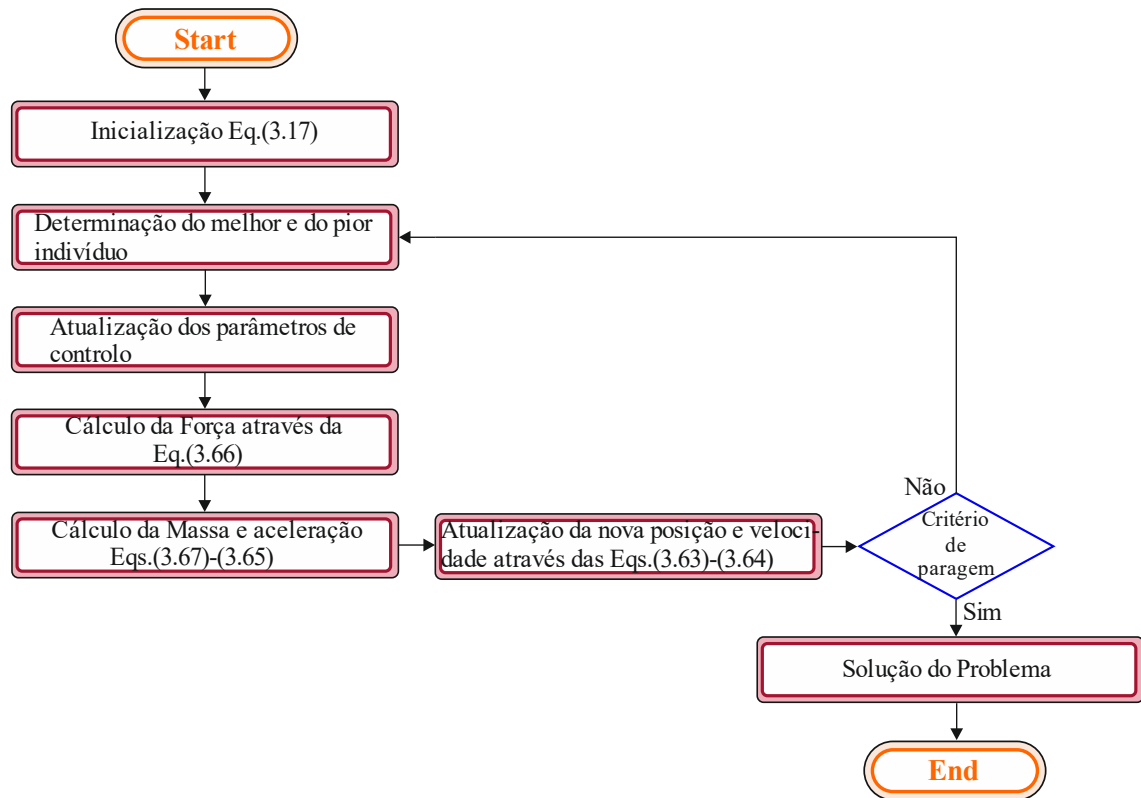


Figura 3. 13 – Fluxograma do algoritmo GSA

3.4.4. Revisão da literatura baseados em fenómenos físicos

No que diz respeito aos algoritmos baseados em fenómenos físicos é possível constatar que existem vários algoritmos de otimização para a extração dos parâmetros fotovoltaicos nomeadamente: A Chaos-Embedded Gravitational Search Algorithm (CGSA); Wind driven optimization (WDO); Evaporation Rate based Water Cycle Algorithm (ER-WCA); Brent's algorithm (BA); Chaotic Optimization Approach (COA); Simulated Annealing Optimization (SA); improved Lozi map based chaotic optimization Algorithm (ILCOA); Perturbed stochastic fractal search (Psfs); Simple and efficient estimation (ACT); slime mould optimization algorithm (SMA); an improved equilibrium optimizer (EO); Modified Gradient-Based Optimizer (GBO); Gradient-Based Optimizer (GBO).

Consoante a revisão bibliográfica realizada nos últimos anos, verifica-se uma preferência na utilização de certos algoritmos tais como: SA e SMA. No entanto outros algoritmos têm ganho alguma importância como por exemplo o GSA, WDO e EO.

A Tabela 3.4 ilustra, de forma sucinta, os diversos fatores que podem interferir no desempenho e precisão dos algoritmos de otimização. Assim, os fatores que condicionam

fortemente o desempenho destes algoritmos são: os modelos matemáticos utilizados, as tecnologias PV aplicadas, a função objetivo, e por último a técnica que permite contornar a natureza implícita das equações.

No que diz respeito aos modelos matemáticos que permitem simular/caracterizar uma célula ou módulo PV, verifica-se que, os autores optam pela utilização do modelo de um diodo (89%). No entanto, a par do modelo de um diodo o modelo de dois continua a ser muito requisitado pelos autores (74%). Além disso, o modelo de três diodos continua a ser o modelo menos aplicado (0.16%) pelos autores.

No que respeita à resolução das equações implícitas caracterizadas pelos modelos matemáticos utilizados, os autores da literatura especializada optaram na sua maioria pela utilização do método direto, no entanto outros autores decidiram utilizar o método indireto *Newton Raphson*.

No que diz respeito à função objetivo os autores optaram novamente pela utilização do RMSE, para avaliar o desempenho do algoritmo de otimização no problema da extração dos parâmetros fotovoltaicos.

Relativamente às tecnologias PV, estas têm como objetivo avaliar o desempenho e a precisão do algoritmo de otimização. Logo, verifica-se no que toca às tecnologias policristalinas a utilização da *R.T.C solar cell*, *Photowatt-PWP 201* e *STP6-120/36*. Já na tecnologia monocristalina verifica-se a utilização da *STM6-40/36*. No entanto, outras tecnologias como *KC200GT*, *Sharp ND-R250A5*, *LSM 20*, *STE 4/100* também reuniram as escolhas dos autores e têm vindo a ganhar alguma importância na extração dos parâmetros PV.

Tabela 3. 4 –Tabela dos algoritmos baseados nos fenómenos físicos.

Algoritmo	Tecnologias PV	Modelo matemático	Função objetivo	Equation/NRP/LAMBERT
CGSA[90]	R.T.C solar cell KC200GT SM55	SDM, DDM	RMSE	Método direto (Equação)
WDO[86]	R.T.C solar cell KC200GT	SDM, DDM	RMSE	Método direto (Equação)
ER-WCA[91]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	NRP
BA[92]	R.T.C solar cell Photowatt-PWP 201 PVM 752	SDM	RMSE	Método direto (Equação)
COA[93]	R.T.C solar cell	SDM, DDM	RMSE	Método direto (Equação)

SA[25]	STM6-40/36 Sharp ND-R250A5	SDM, DDM	RMSE	Método direto (Equação)
ILCOA[94]	R.T.C solar cell	SDM, DDM	RMSE	Método direto (Equação)
pSFS[95]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
ACT[96]	R.T.C solar cell Photowatt-PWP 201 PVM 752	SDM	RMSE	Método direto (Equação)
SMA[21]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM, TDM	RMSE	Método direto (Equação)
SMA[97]	Photowatt-PWP 201 LSM 20 PV	SDM, DDM	RMSE	Método direto (Equação)
AEFA[22]	Photowatt-PWP 201 STM6-40/36	TDM	RMSE	NRP
PSDA[23]	R.T.C solar cell Photowatt-PWP 201 KC200GT LSM 20 STE 4/100	DDM	RMSE	Método direto (Equação)
FFO[24]	R.T.C solar cell Photowatt-PWP 201 Solarland SLP	SDM, DDM	RMSE	NRP
SA[98]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM	RMSE	Método direto (Equação)
GM[26]	Photowatt-PWP 201	SDM	RMSE	Método direto (Equação)
EO[87]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
GBO[99]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
GBO[39]	R.T.C solar cell	SDM, DDM, TDM	RMSE	Método direto (Equação)

3.5. Algoritmos meta-heurísticos híbridos

Nos últimos anos, na literatura especializada, os métodos híbridos têm ganho muita relevância na extração dos parâmetros fotovoltaicos. Estes métodos são caracterizados pela utilização de duas estratégias diferentes. Portanto a primeira estratégia recai pela

combinação de dois ou mais algoritmos meta-heurísticos. A segunda estratégia consiste na utilização de um método determinístico e um algoritmo meta-heurístico. No entanto, na literatura a hibridização que é mais utilizada para a criação deste tipo de métodos é a combinação de dois algoritmos meta-heurísticos.

A principal adversidade deste tipo de combinação passa por criar um equilíbrio entre o mecanismo de intensificação que beneficia uma procura local e o mecanismo de diversificação que privilegia uma procura global. Outra adversidade que este tipo de combinação cria é o controlo/ajuste dos parâmetros de controlo, pois estes podem influenciar o desempenho dos algoritmos de otimização. No entanto outra desvantagem que esta hibridização provoca é o elevado custo computacional.

No que diz respeito aos métodos híbridos é possível constatar que existem várias combinações com algoritmos meta-heurísticos e outro tipo de métodos para o problema da extração dos parâmetros fotovoltaicos nomeadamente: *Reduced-Space Search* (RSS); *hybrid flower pollination algorithm* (GOFPANM); *Improved Cuckoo Search Algorithm* (ImCSA); *Enhanced leader particle swarm optimization* (ELPSO); *an improved opposition-based whale optimization algorithm* (OBWOA); *a hybrid trust-region reflective algorithm* (TRR-ABC); *improved shuffled complex evolution algorithm* (ISCE); *Hybrid Firefly and Pattern Search Algorithms* (HFAPS); *Particle swarm optimisation with adaptive mutation strategy* (MPSO); *Hybridized interior search algorithm* (ISA); *successive discretization algorithm* (SDA); *cuckoo search algorithm with biogeography-based optimization* (BHCS); *Modified Search Strategies Assisted Crossover Whale Optimization Algorithm with Selection Operator* (MCSWOA); *An interval branch and bound global optimization algorithm* (IBEXOPT); *Backtracking search algorithm with reusing differential vectors* (BSARDVs); *Classified perturbation mutation based particle swarm optimization algorithm* (CPMPSO); *Comprehensive learning Jaya algorithm* (CLJAYA); *Fractional chaotic ensemble particle swarm optimizer* (EPSO); *Generalized normal distribution optimization* (GNDO); *recent artificial ecosystem-based optimization* (AEO); *Orthogonal Nelder-Mead moth flame method* (NMSOLMFO); *an enhanced Lévy flight bat algorithm* (ELBA); *SYSTEMS BASED ON THE REDUCED FORM MODEL* (SRFM); *diversification-enriched Harris hawks optimization with chaotic drifts* (EHHO); *the three main points of the current-voltage characteristic* (I-V); *Differential Evolution Algorithm* (DE); *stochastic fractal search optimization algorithm* (SFS); *Artificial ecosystem-based optimiser* (AEO); *improved Rao-based chaotic optimization technique* (LCROA); *Modified Whale Optimization Algorithm* (MWOA).

3.5.1. Revisão da literatura dos algoritmos meta-heurísticos híbridos

Segundo a revisão bibliográfica realizada, verifica-se uma tendência para a utilização da combinação de dois meta-heurísticos. No entanto nos últimos, a combinação de métodos determinísticos com métodos meta-heurísticos também tem ganho alguma relevância na literatura especializada.

Segundo a Tabela 3.5, que demonstra de forma sucinta os vários fatores que interferem no rendimento e precisão dos algoritmos de otimização para a extração dos parâmetros fotovoltaicos. Dentro dos inúmeros fatores que podem influenciar o rendimento e precisão dos algoritmos de otimização é possível salientar: os modelos matemáticos que consistem na simulação e caracterização de uma célula ou módulo PV, as tecnologias PV utilizadas, pois estas, permitem avaliar o rendimento e precisão do algoritmo de otimização, a função objetivo e por último a técnica utilizada para ultrapassar a natureza implícita das equações que definem os modelos matemáticos.

No que diz respeito, às tecnologias PV que permitem avaliar o desempenho e precisão dos algoritmos de otimização para a extração dos parâmetros fotovoltaicos. Conclui-se que, as tecnologias mais utilizadas são as tecnologias policristalinas e monocristalinas. Assim, dentro das tecnologias policristalinas é possível realçar os seguintes *datasets* *R.T.C solar cell*, *Photowatt-PWP 201* e *STP6-120/36*. No entanto em relação às tecnologias monocristalinas é possível realçar o seguinte *dataset* *STM6-40/36*. Além disso é possível destacar outras tecnologias PV que nos últimos têm ganho alguma relevância tais como: *PVM 752*, *mSi photovoltaic cell*, *mSiPV panel*, *Sharp ND-R250A5*, *FSM PV Module*, *FSM-25 PV*, *ESP-160 PPW PV*, *MSX60*.

Nos modelos matemáticos que têm como objetivo, caracterizar e simular uma célula ou um módulo PV, constata-se mais uma vez a tendência para a utilização dos modelos matemáticos SDM e DDM. O modelo matemático TDM mais uma vez é o modelo menos utilizado pelos autores da literatura especializada.

Na literatura especializada existem dois métodos que permitem contornar a natureza implícita das equações, que tanto caracterizam os respetivos modelos matemáticos tais como: o método direto e método indireto. O método direto consiste na resolução das equações que caracterizam os modelos matemáticos. O método indireto consiste na utilização de métodos determinísticos como o *Newton Rapshon* ou *W de Lambert*, de forma a ultrapassar a natureza implícita das equações dos respetivos modelos

matemáticos. Portanto nos métodos híbridos houve um aumento na utilização dos métodos indiretos (*Newton Rapshon* e *W de Lambert*), no entanto outros autores preferiram aplicar o método direto.

De forma a minimizar o erro e classificar o desempenho que o algoritmo de otimização tem no problema da extração dos parâmetros PV. Na literatura especializada existem vários índices de desempenho que podem ser utilizados, no entanto verifica-se que o índice de desempenho mais utilizado foi o RMSE.

Tabela 3. 5 –Tabela dos métodos híbridos.

Algoritmo	Tecnologias PV	Modelo matemático	Função objetivo	Equation/NRP/LAMBERT
BPFPA[27]	R.T.C solar cell	SDM, DDM	RMSE	Método direto (Equação)
RSS[100]	R.T.C solar cell Photowatt-PWP 201 aSiMicro03036	SDM	RMSE	LAMBERT
GOFPANM[101]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
HPSOSA[28]	R.T.C solar cell	SDM, DDM	RMSE	Método direto (Equação)
ImCSA[102]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
ELPSO[103]	R.T.C solar cell STM6-40/36 PVM 752	SDM, DDM	RMSE	NRP
OBWOA[104]	R.T.C solar cell	SDM, DDM, TDM	RMSE	Método direto (Equação)
TRR-ABC[105]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
ISCE[106]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
DE/WOA[29]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
HFAPS[107]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
MPSO[108]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
TLABC[30]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)

HISA[41]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36 PVM752	SDM, DDM	RMSE	NRP
SDA[109]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 mSi photovoltaic cell mSiPV panel	SDM, DDM	RMSE	Método direto (Equação)
BHCS[110]	R.T.C solar cell STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
MCSWOA[111]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36 Sharp ND-R250A5	SDM, DDM	RMSE	Método direto (Equação)
HCLPSO[38]	R.T.C solar cell	SDM, DDM	RMSE	Método direto (Equação)
ATLDE[31]	R.T.C solar cell STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
IBEXOPT[112]	R.T.C solar cell	SDM, DDM, TDM	RMSE	Método direto (Equação)
BSARDVs[113]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
CPMPSO[114]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM, DDM	RMSE	Método direto (Equação)
CLJAYA[115]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
EPSO[116]	R.T.C solar cell STM6-40/36	SDM, DDM, TDM	RMSE	Método direto (Equação)
GNDO[117]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
CCNMHFO[32]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
AEO[118]	R.T.C solar cell FSM-25 PV	SDM, DDM, TDM	RMSE	LAMBERT/NRP
RMSE[35]	R.T.C solar cell	SDM	RMSE	LAMBERT
NMSOLMFO[119]	Photowatt-PWP 201 STE4/100 PV FSM PV Module	SDM, DDM	RMSE	Método direto (Equação)
ELBA[120]	R.T.C solar cell	SDM, DDM	RMSE	Método direto (Equação)

	STM6-40/36 PVM 752			
SRFM[121]	XSI PV module msi PV module	SDM, DDM	RMSE	LAMBERT
EHHO[122]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
I-V[123]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36	SDM	RMSE	LAMBERT
DE[124]	R.T.C solar cell STP6-120/36	SDM	RMSE	Método direto (Equação)
WLCSODGM[33]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
SFS[125]	R.T.C solar cell STP6-120/36 ESP-160 PPW PV	SDM, DDM	RMSE	NRP
AEO[126]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	NRP
LCROA[127]	R.T.C solar cell Photowatt-PWP 201 STM6-40/36 STP6-120/36 PVM-752	SDM, DDM	RMSE	Método direto (Equação)
SFLA[36]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM, TDM	RMSE	Método direto (Equação)
MWOA[128]	R.T.C solar cell Photowatt-PWP 201	SDM, DDM	RMSE	Método direto (Equação)
ImSMA[34]	R.T.C solar cell STP6-120/36	SDM	RMSE	LAMBERT
TRDLA/ LSQM[37]	MSX60	SDM	RMSE	NRP

Capítulo 4

4. Conclusões da revisão bibliográfica

A utilização das energias renováveis, em detrimento da utilização dos combustíveis fósseis para a produção de energia elétrica, é uma solução bastante confiável e vantajosa em muitos aspetos. Estas fontes de energia renovável são inesgotáveis e o seu impacto na atmosfera e a nível ambiental é muito baixo em comparação com o impacto dos combustíveis fósseis. O desenvolvimento desta chamada energia “limpa” é crucial para combater as alterações climáticas e conter os seus efeitos mais devastadores para o meio ambiente. Uma das fontes que tem crescido mais em termos de potência instalada e inovação é a energia solar. Portanto é de extrema importância que os fatores que influenciam a sua produção sejam otimizados.

Para a extração dos parâmetros fotovoltaicos existem três métodos que podem ser utilizados para solucionar este problema são eles: os métodos analíticos, os métodos meta-heurísticos e os métodos híbridos. A escolha do método a utilizar está dependente da informação que está disponível. Se os dados dos fabricantes estiverem disponíveis o método mais utilizado para a resolução deste problema são os métodos analíticos. Os métodos analíticos recorrem a equações elementares que vão ser aplicadas apenas a pontos fulcrais da curva característica I-V. No entanto estes pontos fulcrais têm uma contrariedade, estes são fornecidos sob condições padrão (STC). Logo a eficiência destes métodos está dependente dos pontos fulcrais que foram escolhidos da curva característica I-V. Além disto, estes métodos são fáceis de implementar, são eficientes na procura local e possuem um baixo custo computacional.

Os métodos meta-heurísticos são métodos bio inspirados na natureza e são formados por uma população de indivíduos que interage entre si com o objetivo de solucionar o problema de otimização. Estes métodos têm o propósito de minimizar o erro entre a curva experimental I-V e a curva simulada. Os métodos meta-heurísticos são conhecidos pela sua flexibilidade pois são simples de implementar, podem ser aplicados em diversos problemas e possuem a capacidade de solucionar problemas multimodais e não lineares. Para estes métodos meta-heurísticos serem eficientes tem de existir um equilíbrio entre dois mecanismos: o mecanismo de intensificação e o mecanismo de diversificação. O mecanismo de intensificação é responsável por uma procura local, enquanto o mecanismo de diversificação está encarregue da procura global.

No que diz respeito aos métodos híbridos são definidos pela aplicação de duas estratégias distintas. A primeira estratégia é caracterizada pelo uso de um método determinístico combinado com um ou vários métodos meta-heurísticos. No entanto a hibridização que é mais utilizada, combina dois ou mais algoritmos meta-heurísticos. No entanto a eficiência deste método está dependente do equilíbrio entre o mecanismo de intensificação e o mecanismo de diversificação e o ajuste dos parâmetros de controlo dos algoritmos de otimização.

Para a resolução do problema da extração dos parâmetros fotovoltaicos, os modelos matemáticos cumprem um papel fundamental, pois estes conseguem simular e caracterizar uma célula ou módulo fotovoltaico. Na literatura especializada existem vários modelos matemáticos que podem ser aplicados para a resolução deste problema tais como: modelo de um diodo, modelo de dois diodos, modelo de três diodos, modelo multidiodo e modelo multidimensão. No entanto, os modelos que acabam por ser mais utilizados são o SDM, DDM e TDM.

Perante a Figura 4.1 é possível constatar que o modelo de um diodo é aplicado em 14% das vezes, enquanto o modelo de dois diodos é aplicado apenas em 3% das vezes. Além disso os autores também optam pela utilização do modelo de três diodos em 5% das ocasiões. Contudo os modelos mais utilizados na literatura para a comparação dos algoritmos de otimização são os modelos de um diodo juntamente com o modelo de dois diodos estes são utilizados em 72% das ocasiões. No entanto os autores também optam pela utilização do SDM, DDM e TDM em 5% das ocasiões.

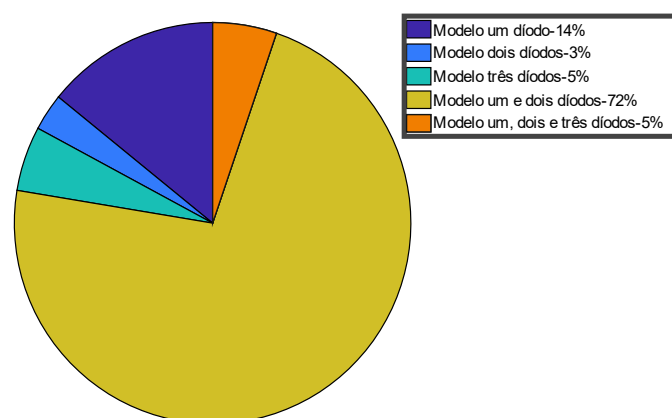


Figura 4. 1 - Percentagem de utilização dos modelos matemáticos.

A função objetivo tem o propósito de avaliar o erro existente entre os dados experimentais e estimados. De forma a avaliar o desempenho dos algoritmos meta-heurísticos existem vários índices de desempenho que podem ser aplicados,

nomeadamente: o erro quadrático (SSE), a raiz quadrada do erro quadrático médio (RMSE), o erro absoluto (AE) e por último o erro absoluto médio (MAE). No entanto, a função objetivo que é mais utilizada na literatura especializada é a raiz quadrada do erro quadrático médio (RMSE).

Para ultrapassar a natureza implícita das equações que caracteriza os modelos matemáticos na extração dos parâmetros fotovoltaicos, podem ser aplicados dois métodos distintos, o método indireto e o método direto. O método indireto de forma a ultrapassar a natureza implícita das equações, tem por base a aplicação de métodos determinísticos, tais como: o método de *Newton Raphson* e a função de *w de Lambert*. No que diz respeito ao método direto consiste na resolução da equação que caracteriza os modelos matemáticos. O método direto é o método mais aplicado na literatura especializada, apesar de outros autores optarem pela aplicação de métodos indiretos, mais concretamente, o método de *Newton Raphson* e a função *w de Lambert*.

Em relação às tecnologias PV, estas avaliam o desempenho e precisão do algoritmo de otimização na extração dos parâmetros fotovoltaicos. Na literatura especializada existem inúmeras tecnologias que podem ser aplicadas para a resolução deste problema. No entanto, os autores da literatura especializada de forma a haver uma comparação justa entre os algoritmos de otimização acabam por optar pela utilização das chamadas “tecnologias padrão”, tais como: *R.T.C solar cell*, *Photowatt-PWP 201*, *STM6-40/36* e *STP6-120/36*. Além destas tecnologias PV outras têm vindo a ganhar alguma relevância, nomeadamente *PVM-752*, *Sharp ND-R250A5*, entre outras.

Perante a Figura 4.2, é possível constatar que os *datasets* mais utilizados para a extração dos parâmetros fotovoltaicos são a *R.T.C solar cell* e o *Photowatt-PWP 201* estes são aplicados em 38% das vezes. Além disso com 15% das escolhas surgem as tecnologias padrão, isto é, *R.T.C solar cell*, *Photowatt-PWP 201*, *STM6-40/36* e *STP6-120/36*. Uma das tecnologias mais requisitadas pelos autores para solucionar este problema é a *R.T.C solar cell* com 11% das ocasiões. Outra opção muito solicitada é a utilização da *R.T.C solar cell*, *Photowatt-PWP 201* com outras tecnologias emergentes que reúne 7% das escolhas. Por último resta salientar duas opções que também reúnem as preferências dos autores tais como a utilização da *R.T.C solar cell* com outros *datasets* emergentes e a aplicação da *R.T.C solar cell*, *STM6-40/36* e *STP6-120/36* ambas utilizadas em 4% das ocasiões.




Figura 4. 2 - Percentagem de utilização das tecnologias PV.

Referências

- [1] J. J. Soon and K. S. Low, “Optimizing Photovoltaic Model for Different Cell Technologies Using a Generalized Multidimension Diode Model,” *IEEE Trans. Ind. Electron.*, vol. 62, no. 10, pp. 6371–6380, 2015, doi: 10.1109/TIE.2015.2420617.
- [2] L. H. I. Lim, Z. Ye, J. Ye, D. Yang, and H. Du, “A linear identification of diode models from single I-V characteristics of PV panels,” *IEEE Trans. Ind. Electron.*, vol. 62, no. 7, pp. 4181–4193, 2015, doi: 10.1109/TIE.2015.2390193.
- [3] Y. Song, D. Wu, A. Wagdy Mohamed, X. Zhou, B. Zhang, and W. Deng, “Enhanced Success History Adaptive de for Parameter Optimization of Photovoltaic Models,” *Complexity*, vol. 2021, 2021, doi: 10.1155/2021/6660115.
- [4] M. Premkumar, T. S. Babu, S. Umashankar, and R. Sowmya, “A new metaphor-less algorithms for the photovoltaic cell parameter estimation,” *Optik (Stuttg.)*, vol. 208, no. March, p. 164559, 2020, doi: 10.1016/j.ijleo.2020.164559.
- [5] X. Jian and Z. Weng, “A logistic chaotic JAYA algorithm for parameters identification of photovoltaic cell and module models,” *Optik (Stuttg.)*, vol. 203, no. December 2019, p. 164041, 2020, doi: 10.1016/j.ijleo.2019.164041.
- [6] Y. Song *et al.*, “MPPCEDE: Multi-population parallel co-evolutionary differential evolution for parameter optimization,” *Energy Convers. Manag.*, vol. 228, no. August 2020, p. 113661, 2021, doi: 10.1016/j.enconman.2020.113661.
- [7] S. Gao, K. Wang, S. Tao, T. Jin, H. Dai, and J. Cheng, “A state-of-the-art differential evolution algorithm for parameter estimation of solar photovoltaic models,” *Energy Convers. Manag.*, vol. 230, no. October 2020, p. 113784, 2021, doi: 10.1016/j.enconman.2020.113784.
- [8] X. Yang and W. Gong, “Opposition-based JAYA with population reduction for parameter estimation of photovoltaic solar cells and modules,” *Appl. Soft Comput.*, vol. 104, p. 107218, 2021, doi: 10.1016/j.asoc.2021.107218.
- [9] D. Oliva, M. Abd El Aziz, and A. Ella Hassanien, “Parameter estimation of photovoltaic cells using an improved chaotic whale optimization algorithm,” *Appl. Energy*, vol. 200, pp. 141–154, 2017, doi: 10.1016/j.apenergy.2017.05.029.
- [10] M. Louzazni, A. Khouya, K. Amechnoue, A. Gandelli, M. Mussetta, and A. Craciunescu, “Metaheuristic algorithm for photovoltaic parameters: Comparative study and prediction with a Firefly algorithm,” *Appl. Sci.*, vol. 8, no.

- 3, 2018, doi: 10.3390/app8030339.
- [11] R. Ben Messaoud, "Extraction of uncertain parameters of double-diode model of a photovoltaic panel using Ant Lion Optimization," *SN Appl. Sci.*, vol. 2, no. 2, pp. 1–8, 2020, doi: 10.1007/s42452-020-2013-z.
- [12] V. J. Chin and Z. Salam, "Coyote optimization algorithm for the parameter extraction of photovoltaic cells," *Sol. Energy*, vol. 194, no. February, pp. 656–670, 2019, doi: 10.1016/j.solener.2019.10.093.
- [13] A. A. Z. Diab, H. M. Sultan, R. Aljendy, A. S. Al-Sumaiti, M. Shoyama, and Z. M. Ali, "Tree Growth Based Optimization Algorithm for Parameter Extraction of Different Models of Photovoltaic Cells and Modules," *IEEE Access*, vol. 8, pp. 119668–119687, 2020, doi: 10.1109/ACCESS.2020.3005236.
- [14] M. Abdel-Basset, D. El-Shahat, R. K. Chakraborty, and M. Ryan, "Parameter estimation of photovoltaic models using an improved marine predators algorithm," *Energy Convers. Manag.*, vol. 227, no. May 2020, p. 113491, 2021, doi: 10.1016/j.enconman.2020.113491.
- [15] K. M. Sallam, M. A. Hossain, R. K. Chakraborty, and M. J. Ryan, *An improved gaining-sharing knowledge algorithm for parameter extraction of photovoltaic models*, vol. 237, no. March. 2021.
- [16] Z. Liao, Z. Chen, and S. Li, "Parameters Extraction of Photovoltaic Models Using Triple-Phase Teaching-Learning-Based Optimization," *IEEE Access*, vol. 8, pp. 69937–69952, 2020, doi: 10.1109/ACCESS.2020.2984728.
- [17] T. Huang, C. Zhang, H. Ouyang, G. Luo, S. Li, and D. Zou, "Parameter Identification for Photovoltaic Models Using an Improved Learning Search Algorithm," *IEEE Access*, vol. 8, pp. 116292–116309, 2020, doi: 10.1109/ACCESS.2020.3003814.
- [18] G. Xiong, J. Zhang, D. Shi, and X. Yuan, "Application of Supply-Demand-Based Optimization for Parameter Extraction of Solar Photovoltaic Models," *Complexity*, vol. 2019, 2019, doi: 10.1155/2019/3923691.
- [19] Z. Yan, C. Li, Z. Song, L. Xiong, and C. Luo, "An Improved Brain Storming Optimization Algorithm for Estimating Parameters of Photovoltaic Models," *IEEE Access*, vol. 7, pp. 77629–77641, 2019, doi: 10.1109/ACCESS.2019.2922327.
- [20] A. M. Shaheen, A. R. Ginidi, R. A. El-Sehiemy, and S. S. M. Ghoneim, "A Forensic-Based Investigation Algorithm for Parameter Extraction of Solar Cell Models," *IEEE Access*, vol. 9, pp. 1–20, 2021, doi:

10.1109/ACCESS.2020.3046536.

- [21] C. Kumar, T. D. Raj, M. Premkumar, and T. D. Raj, “A new stochastic slime mould optimization algorithm for the estimation of solar photovoltaic cell parameters,” *Optik (Stuttg.)*, vol. 223, no. July, p. 165277, 2020, doi: 10.1016/j.ijleo.2020.165277.
- [22] S. I. Selem, A. A. El-Fergany, and H. M. Hasanien, “Artificial electric field algorithm to extract nine parameters of triple-diode photovoltaic model,” *Int. J. Energy Res.*, vol. 45, no. 1, pp. 590–604, 2021, doi: 10.1002/er.5756.
- [23] A. M. Deaconu, D. T. Cotfas, and P. A. Cotfas, “Calculation of Seven Photovoltaic Cells Parameters Using Parallelized Successive Discretization Algorithm,” *Int. J. Photoenergy*, vol. 2020, 2020, doi: 10.1155/2020/6669579.
- [24] A. M. Agwa, A. A. El-Fergany, and H. A. Maksoud, “Electrical characterization of photovoltaic modules using farmland fertility optimizer,” *Energy Convers. Manag.*, vol. 217, no. May, p. 112990, 2020, doi: 10.1016/j.enconman.2020.112990.
- [25] R. Ben Messaoud, “Extraction of Uncertain Parameters of Double-Diode Model of a Photovoltaic Panel Using Simulated Annealing Optimization,” *J. Phys. Chem. C*, vol. 123, no. 48, pp. 29096–29103, 2019, doi: 10.1021/acs.jpcc.9b07064.
- [26] M. Bencherif and T. Benouaz, “Parameter extraction of solar panels using the graphical method,” *Int. J. Ambient Energy*, vol. 41, no. 8, pp. 927–944, 2020, doi: 10.1080/01430750.2018.1501735.
- [27] J. P. Ram, T. S. Babu, T. Dragicevic, and N. Rajasekar, “A new hybrid bee pollinator flower pollination algorithm for solar PV parameter estimation,” *Energy Convers. Manag.*, vol. 135, pp. 463–476, 2017, doi: 10.1016/j.enconman.2016.12.082.
- [28] M. A. Mughal, Q. Ma, and C. Xiao, “Photovoltaic cell parameter estimation using hybrid particle swarm optimization and simulated annealing,” *Energies*, vol. 10, no. 8, pp. 1–14, 2017, doi: 10.3390/en10081213.
- [29] G. Xiong, J. Zhang, X. Yuan, D. Shi, Y. He, and G. Yao, “Parameter extraction of solar photovoltaic models by means of a hybrid differential evolution with whale optimization algorithm,” *Sol. Energy*, vol. 176, no. October, pp. 742–761, 2018, doi: 10.1016/j.solener.2018.10.050.
- [30] X. Chen, B. Xu, C. Mei, Y. Ding, and K. Li, “Teaching–learning–based artificial bee colony for solar photovoltaic parameter estimation,” *Appl. Energy*, vol. 212,

- no. December 2017, pp. 1578–1588, 2018, doi: 10.1016/j.apenergy.2017.12.115.
- [31] S. Li, W. Gong, L. Wang, X. Yan, and C. Hu, “A hybrid adaptive teaching–learning-based optimization and differential evolution for parameter identification of photovoltaic models,” *Energy Convers. Manag.*, vol. 225, no. June, p. 113474, 2020, doi: 10.1016/j.enconman.2020.113474.
- [32] Y. Liu *et al.*, “Horizontal and vertical crossover of Harris hawk optimizer with Nelder-Mead simplex for parameter estimation of photovoltaic models,” *Energy Convers. Manag.*, vol. 223, no. July, p. 113211, 2020, doi: 10.1016/j.enconman.2020.113211.
- [33] G. Xiong, J. Zhang, D. Shi, L. Zhu, X. Yuan, and Z. Tan, “Winner-leading competitive swarm optimizer with dynamic Gaussian mutation for parameter extraction of solar photovoltaic models,” *Energy Convers. Manag.*, vol. 206, no. December 2019, p. 112450, 2020, doi: 10.1016/j.enconman.2019.112450.
- [34] A. A. El-Fergany, “Parameters identification of PV model using improved slime mould optimizer and Lambert W-function,” *Energy Reports*, vol. 7, pp. 875–887, 2021, doi: 10.1016/j.egyr.2021.01.093.
- [35] M. Čalasan, S. H. E. Abdel Aleem, and A. F. Zobaa, “On the root mean square error (RMSE) calculation for parameter estimation of photovoltaic models: A novel exact analytical solution based on Lambert W function,” *Energy Convers. Manag.*, vol. 210, no. March, p. 112716, 2020, doi: 10.1016/j.enconman.2020.112716.
- [36] Y. Liu *et al.*, “Evolutionary shuffled frog leaping with memory pool for parameter optimization,” *Energy Reports*, vol. 7, pp. 584–606, 2021, doi: 10.1016/j.egyr.2021.01.001.
- [37] A. Hali and Y. Khelifi, “Photovoltaic panel parameters determination using two numerical methods,” *Mater. Today Proc.*, vol. 45, no. xxxx, pp. 7377–7382, 2021, doi: 10.1016/j.matpr.2021.01.313.
- [38] D. Yousri, D. Allam, M. B. Eteiba, and P. N. Suganthan, “Static and dynamic photovoltaic models’ parameters identification using Chaotic Heterogeneous Comprehensive Learning Particle Swarm Optimizer variants,” *Energy Convers. Manag.*, vol. 182, no. April 2018, pp. 546–563, 2019, doi: 10.1016/j.enconman.2018.12.022.
- [39] A. A. K. Ismaeel, E. H. Houssein, D. Oliva, and M. Said, “Gradient-based optimizer for parameter extraction in photovoltaic models,” *IEEE Access*, vol. 9, pp. 13403–13416, 2021, doi: 10.1109/ACCESS.2021.3052153.

- [40] S. Li, W. Gong, and Q. Gu, "A comprehensive survey on meta-heuristic algorithms for parameter extraction of photovoltaic models," *Renew. Sustain. Energy Rev.*, vol. 141, no. February, p. 110828, 2021, doi: 10.1016/j.rser.2021.110828.
- [41] D. Kler, Y. Goswami, K. P. S. Rana, and V. Kumar, "A novel approach to parameter estimation of photovoltaic systems using hybridized optimizer," *Energy Convers. Manag.*, vol. 187, no. July 2018, pp. 486–511, 2019, doi: 10.1016/j.enconman.2019.01.102.
- [42] X. Yang, W. Gong, and L. Wang, "Comparative study on parameter extraction of photovoltaic models via differential evolution," *Energy Convers. Manag.*, vol. 201, no. May, p. 112113, 2019, doi: 10.1016/j.enconman.2019.112113.
- [43] K. Yu, J. J. Liang, B. Y. Qu, X. Chen, and H. Wang, "Parameters identification of photovoltaic models using an improved JAYA optimization algorithm," *Energy Convers. Manag.*, vol. 150, no. July, pp. 742–753, 2017, doi: 10.1016/j.enconman.2017.08.063.
- [44] X. Jian and Y. Zhu, "Parameters identification of photovoltaic models using modified Rao-1 optimization algorithm," *Optik (Stuttg.)*, vol. 231, no. February, p. 166439, 2021, doi: 10.1016/j.ijleo.2021.166439.
- [45] V. J. Chin and Z. Salam, "A New Three-point-based Approach for the Parameter Extraction of Photovoltaic Cells," *Appl. Energy*, vol. 237, no. August 2018, pp. 519–533, 2019, doi: 10.1016/j.apenergy.2019.01.009.
- [46] K. Yu, B. Qu, C. Yue, S. Ge, X. Chen, and J. Liang, "A performance-guided JAYA algorithm for parameters identification of photovoltaic cell and module," *Appl. Energy*, vol. 237, no. August 2018, pp. 241–257, 2019, doi: 10.1016/j.apenergy.2019.01.008.
- [47] S. Li, W. Gong, X. Yan, C. Hu, D. Bai, and L. Wang, "Parameter estimation of photovoltaic models with memetic adaptive differential evolution," *Sol. Energy*, vol. 190, no. August, pp. 465–474, 2019, doi: 10.1016/j.solener.2019.08.022.
- [48] N. Hamid, R. Abounacer, M. Idali Oumhand, M. Feddaoui, and D. Agliz, "Parameters identification of photovoltaic solar cells and module using the genetic algorithm with convex combination crossover," *Int. J. Ambient Energy*, vol. 40, no. 5, pp. 517–524, 2019, doi: 10.1080/01430750.2017.1421577.
- [49] S. Li, Q. Gu, W. Gong, and B. Ning, "An enhanced adaptive differential evolution algorithm for parameter extraction of photovoltaic models," *Energy Convers. Manag.*, vol. 205, no. December 2019, p. 112443, 2020, doi:

- 10.1016/j.enconman.2019.112443.
- [50] J. Liang *et al.*, “Evolutionary multi-task optimization for parameters extraction of photovoltaic models,” *Energy Convers. Manag.*, vol. 207, no. December 2019, p. 112509, 2020, doi: 10.1016/j.enconman.2020.112509.
- [51] J. Liang *et al.*, “Parameters estimation of solar photovoltaic models via a self-adaptive ensemble-based differential evolution,” *Sol. Energy*, vol. 207, no. February, pp. 336–346, 2020, doi: 10.1016/j.solener.2020.06.100.
- [52] T. V. Luu and N. S. Nguyen, “Parameters extraction of solar cells using modified JAYA algorithm,” *Optik (Stuttg.)*, vol. 203, no. December 2019, p. 164034, 2020, doi: 10.1016/j.ijleo.2019.164034.
- [53] Q. Hao, Z. Zhou, Z. Wei, and G. Chen, “Parameters Identification of Photovoltaic Models Using a Multi-Strategy Success-History-Based Adaptive Differential Evolution,” *IEEE Access*, vol. 8, pp. 35979–35994, 2020, doi: 10.1109/ACCESS.2020.2975078.
- [54] S. M. Parida and P. K. Rout, “Differential evolution with dynamic control factors for parameter estimation of photovoltaic models,” *J. Comput. Electron.*, vol. 20, no. 1, pp. 330–343, 2021, doi: 10.1007/s10825-020-01617-z.
- [55] M. Premkumar, P. Jangir, R. Sowmya, R. M. Elavarasan, and B. S. Kumar, “Enhanced chaotic JAYA algorithm for parameter estimation of photovoltaic cell/modules,” *ISA Trans.*, vol. 116, no. xxxx, pp. 139–166, 2021, doi: 10.1016/j.isatra.2021.01.045.
- [56] H. Rezk, J. Arfaoui, and M. R. Gomaa, “Optimal parameter estimation of solar pv panel based on hybrid particle swarm and grey wolf optimization algorithms,” *Int. J. Interact. Multimed. Artif. Intell.*, vol. 6, no. 6, pp. 145–155, 2021, doi: 10.9781/ijimai.2020.12.001.
- [57] G. Xiong, J. Zhang, D. Shi, and Y. He, “Parameter extraction of solar photovoltaic models using an improved whale optimization algorithm,” *Energy Convers. Manag.*, vol. 174, no. August, pp. 388–405, 2018, doi: 10.1016/j.enconman.2018.08.053.
- [58] D. Oliva, A. A. Ewees, M. A. El Aziz, A. E. Hassanien, and M. P. Cisneros, “A chaotic improved artificial bee colony for parameter estimation of photovoltaic cells,” *Energies*, vol. 10, no. 7, pp. 1–19, 2017, doi: 10.3390/en10070865.
- [59] R. Muralidharan, “Parameter extraction of solar photovoltaic cells and modules using current–voltage characteristics,” *Int. J. Ambient Energy*, vol. 38, no. 5, pp. 509–513, 2017, doi: 10.1080/01430750.2016.1144525.

- [60] P. Lin, S. Cheng, W. Yeh, Z. Chen, and L. Wu, "Parameters extraction of solar cell models using a modified simplified swarm optimization algorithm," *Sol. Energy*, vol. 144, pp. 594–603, 2017, doi: 10.1016/j.solener.2017.01.064.
- [61] S. M. Ebrahimi, E. Salahshour, M. Malekzadeh, and Francisco Gordillo, "Parameters identification of PV solar cells and modules using flexible particle swarm optimization algorithm," *Energy*, vol. 179, pp. 358–372, 2019, doi: 10.1016/j.energy.2019.04.218.
- [62] W. Long, S. Cai, J. Jiao, M. Xu, and T. Wu, "A new hybrid algorithm based on grey wolf optimizer and cuckoo search for parameter extraction of solar photovoltaic models," *Energy Convers. Manag.*, vol. 203, no. October 2019, p. 112243, 2020, doi: 10.1016/j.enconman.2019.112243.
- [63] A. A. Z. DIab, H. M. Sultan, T. D. Do, O. M. Kamel, and M. A. Mossa, "Coyote Optimization Algorithm for Parameters Estimation of Various Models of Solar Cells and PV Modules," *IEEE Access*, vol. 8, pp. 111102–111140, 2020, doi: 10.1109/ACCESS.2020.3000770.
- [64] R. Ben Messaoud, "Extraction of uncertain parameters of single and double diode model of a photovoltaic panel using Salp Swarm algorithm," *Meas. J. Int. Meas. Confed.*, vol. 154, p. 107446, 2020, doi: 10.1016/j.measurement.2019.107446.
- [65] A. T. Kiani, M. F. Nadeem, A. Ahmed, I. Khan, R. M. Elavarasan, and N. Das, "Exponential Function-Based Dynamic Inertia Weight Particle Swarm Optimization."
- [66] S. Jiao *et al.*, "Orthogonally adapted Harris hawks optimization for parameter estimation of photovoltaic models," *Energy*, vol. 203, p. 117804, 2020, doi: 10.1016/j.energy.2020.117804.
- [67] S. Gude and K. C. Jana, "Parameter extraction of photovoltaic cell using an improved cuckoo search optimization," *Sol. Energy*, vol. 204, no. February, pp. 280–293, 2020, doi: 10.1016/j.solener.2020.04.036.
- [68] X. Lin and Y. Wu, "Parameters identification of photovoltaic models using niche-based particle swarm optimization in parallel computing architecture," *Energy*, vol. 196, p. 117054, 2020, doi: 10.1016/j.energy.2020.117054.
- [69] S. Chen, S. Gholami Farkoush, and S. Leto, "Photovoltaic cells parameters extraction using variables reduction and improved shark optimization technique," *Int. J. Hydrogen Energy*, vol. 45, no. 16, pp. 10059–10069, 2020, doi: 10.1016/j.ijhydene.2020.01.236.

- [70] Y. Fan, P. Wang, A. A. Heidari, X. Zhao, H. Turabieh, and H. Chen, “Delayed dynamic step shuffling frog-leaping algorithm for optimal design of photovoltaic models,” *Energy Reports*, vol. 7, pp. 228–246, 2021, doi: 10.1016/j.egy.2020.12.013.
- [71] R. Wang, “Parameter identification of photovoltaic cell model based on enhanced particle swarm optimization,” *Sustain.*, vol. 13, no. 2, pp. 1–25, 2021, doi: 10.3390/su13020840.
- [72] M. U. N. Khursheed *et al.*, “PV Model Parameter Estimation Using Modified FPA with Dynamic Switch Probability and Step Size Function,” *IEEE Access*, vol. 9, pp. 42027–42044, 2021, doi: 10.1109/ACCESS.2021.3064757.
- [73] E. J. Liu, Y. H. Hung, and C. W. Hong, “Improved metaheuristic optimization algorithm applied to hydrogen fuel cell and photovoltaic cell parameter extraction,” *Energies*, vol. 14, no. 3, pp. 1–16, 2021, doi: 10.3390/en14030619.
- [74] G. Kanimozhi and Harish Kumar, “Modeling of solar cell under different conditions by Ant Lion Optimizer with LambertW function,” *Appl. Soft Comput. J.*, vol. 71, pp. 141–151, 2018, doi: 10.1016/j.asoc.2018.06.025.
- [75] A. Sharma, A. Sharma, A. Moshe, N. Raj, and R. K. Pachauri, “An Effective Method for Parameter Estimation of Solar PV Cell Using Grey-Wolf Optimization Technique,” *Int. J. Math. Eng. Manag. Sci.*, vol. 6, no. 3, pp. 911–931, 2021, doi: 10.33889/ijmems.2021.6.3.054.
- [76] A. W. Mohamed, H. F. Abutarboush, A. A. Hadi, and A. K. Mohamed, “Gaining-Sharing Knowledge Based Algorithm with Adaptive Parameters for Engineering Optimization,” *IEEE Access*, vol. 9, no. May, pp. 65934–65946, 2021, doi: 10.1109/ACCESS.2021.3076091.
- [77] K. Yu, X. Chen, X. Wang, and Z. Wang, “Parameters identification of photovoltaic models using self-adaptive teaching-learning-based optimization,” *Energy Convers. Manag.*, vol. 145, pp. 233–246, 2017, doi: 10.1016/j.enconman.2017.04.054.
- [78] K. Yu, J. J. Liang, B. Y. Qu, Z. Cheng, and H. Wang, “Multiple learning backtracking search algorithm for estimating parameters of photovoltaic models,” *Appl. Energy*, vol. 226, no. June, pp. 408–422, 2018, doi: 10.1016/j.apenergy.2018.06.010.
- [79] S. Li *et al.*, “Parameter extraction of photovoltaic models using an improved teaching-learning-based optimization,” *Energy Convers. Manag.*, vol. 186, no. February, pp. 293–305, 2019, doi: 10.1016/j.enconman.2019.02.048.

- [80] H. Sheng *et al.*, “Parameters extraction of photovoltaic models using an improved moth-flame optimization,” *Energies*, vol. 12, no. 18, 2019, doi: 10.3390/en12183527.
- [81] Y. Zhang, M. Ma, and Z. Jin, “Backtracking search algorithm with competitive learning for identification of unknown parameters of photovoltaic systems,” *Expert Syst. Appl.*, vol. 160, p. 113750, 2020, doi: 10.1016/j.eswa.2020.113750.
- [82] Y. Zhang, Z. Jin, X. Zhao, and Q. Yang, “Backtracking search algorithm with Lévy flight for estimating parameters of photovoltaic models,” *Energy Convers. Manag.*, vol. 208, no. February, p. 112615, 2020, doi: 10.1016/j.enconman.2020.112615.
- [83] R. M. Rizk-Allah and A. A. El-Fergany, “Conscious neighborhood scheme-based Laplacian barnacles mating algorithm for parameters optimization of photovoltaic single- and double-diode models,” *Energy Convers. Manag.*, vol. 226, no. June, p. 113522, 2020, doi: 10.1016/j.enconman.2020.113522.
- [84] G. Xiong, J. Zhang, D. Shi, L. Zhu, and X. Yuan, “Parameter extraction of solar photovoltaic models with an either-or teaching learning based algorithm,” *Energy Convers. Manag.*, vol. 224, no. January, p. 113395, 2020, doi: 10.1016/j.enconman.2020.113395.
- [85] M. Abdel-Basset, R. Mohamed, R. K. Chakraborty, K. Sallam, and M. J. Ryan, “An efficient teaching-learning-based optimization algorithm for parameters identification of photovoltaic models: Analysis and validations,” *Energy Convers. Manag.*, vol. 227, no. August 2020, p. 113614, 2021, doi: 10.1016/j.enconman.2020.113614.
- [86] M. Derick, C. Rani, M. Rajesh, M. E. Farrag, Y. Wang, and K. Busawon, “An improved optimization technique for estimation of solar photovoltaic parameters,” *Sol. Energy*, vol. 157, pp. 116–124, 2017, doi: 10.1016/j.solener.2017.08.006.
- [87] M. Abdel-Basset, R. Mohamed, S. Mirjalili, R. K. Chakraborty, and M. J. Ryan, “Solar photovoltaic parameter estimation using an improved equilibrium optimizer,” *Sol. Energy*, vol. 209, no. September, pp. 694–708, 2020, doi: 10.1016/j.solener.2020.09.032.
- [88] E. Rashedi, H. Nezamabadi-pour, and S. Saryazdi, “GSA: A Gravitational Search Algorithm,” *Inf. Sci. (Ny)*, vol. 179, no. 13, pp. 2232–2248, 2009, doi: 10.1016/j.ins.2009.03.004.
- [89] H. Mittal, A. Tripathi, A. C. Pandey, and R. Pal, “Gravitational search algorithm:

- a comprehensive analysis of recent variants,” *Multimed. Tools Appl.*, vol. 80, no. 5, pp. 7581–7608, 2021, doi: 10.1007/s11042-020-09831-4.
- [90] A. Valdivia-González, D. Zaldívar, E. Cuevas, M. Pérez-Cisneros, F. Fausto, and A. González, “A chaos-embedded Gravitational Search Algorithm for the identification of electrical parameters of photovoltaic cells,” *Energies*, vol. 10, no. 7, 2017, doi: 10.3390/en10071052.
- [91] D. Kler, P. Sharma, A. Banerjee, K. P. S. Rana, and V. Kumar, “PV cell and module efficient parameters estimation using Evaporation Rate based Water Cycle Algorithm,” *Swarm Evol. Comput.*, vol. 35, no. July 2016, pp. 93–110, 2017, doi: 10.1016/j.swevo.2017.02.005.
- [92] F. F. Muhammadsharif *et al.*, “Brent’s algorithm based new computational approach for accurate determination of single-diode model parameters to simulate solar cells and modules,” *Sol. Energy*, vol. 193, no. November 2018, pp. 782–798, 2019, doi: 10.1016/j.solener.2019.09.096.
- [93] M. Čalasan, D. Jovanović, V. Rubežić, S. Mujović, and S. Dukanović, “Estimation of single-diode and two-diode solar cell parameters by using a chaotic optimization approach,” *Energies*, vol. 12, no. 21, 2019, doi: 10.3390/en12214209.
- [94] N. Pourmoussa, S. M. Ebrahimi, M. Malekzadeh, and M. Alizadeh, “Parameter estimation of photovoltaic cells using improved Lozi map based chaotic optimization Algorithm,” *Sol. Energy*, vol. 180, no. July 2018, pp. 180–191, 2019, doi: 10.1016/j.solener.2019.01.026.
- [95] X. Chen, H. Yue, and K. Yu, “Perturbed stochastic fractal search for solar PV parameter estimation,” *Energy*, vol. 189, p. 116247, 2019, doi: 10.1016/j.energy.2019.116247.
- [96] F. F. Muhammad, A. W. Karim Sangawi, S. Hashim, S. K. Ghoshal, I. K. Abdullah, and S. S. Hameed, “Simple and efficient estimation of photovoltaic cells and modules parameters using approximation and correction technique,” *PLoS One*, vol. 14, no. 5, pp. 1–19, 2019, doi: 10.1371/journal.pone.0216201.
- [97] M. Mostafa, H. Rezk, M. Aly, and E. M. Ahmed, “A new strategy based on slime mould algorithm to extract the optimal model parameters of solar PV panel,” *Sustain. Energy Technol. Assessments*, vol. 42, no. June, p. 100849, 2020, doi: 10.1016/j.seta.2020.100849.
- [98] R. Ben Messaoud, “Extraction of uncertain parameters of single-diode model of a photovoltaic panel using simulated annealing optimization,” *Energy Reports*,

- vol. 6, pp. 350–357, 2020, doi: 10.1016/j.egy.2020.01.016.
- [99] M. H. Hassan, S. Kamel, M. A. El-Dabah, and H. Rezk, “A novel solution methodology based on a modified gradient-based optimizer for parameter estimation of photovoltaic models,” *Electron.*, vol. 10, no. 4, pp. 1–23, 2021, doi: 10.3390/electronics10040472.
- [100] A. A. Cardenas, M. Carrasco, F. Mancilla-David, A. Street, and R. Cardenas, “Experimental Parameter Extraction in the Single-Diode Photovoltaic Model via a Reduced-Space Search,” *IEEE Trans. Ind. Electron.*, vol. 64, no. 2, pp. 1468–1476, 2017, doi: 10.1109/TIE.2016.2615590.
- [101] S. Xu and Y. Wang, “Parameter estimation of photovoltaic modules using a hybrid flower pollination algorithm,” *Energy Convers. Manag.*, vol. 144, pp. 53–68, 2017, doi: 10.1016/j.enconman.2017.04.042.
- [102] T. Kang, J. Yao, M. Jin, S. Yang, and T. Duong, “A novel improved cuckoo search algorithm for parameter estimation of photovoltaic (PV) models,” *Energies*, vol. 11, no. 5, 2018, doi: 10.3390/en11051060.
- [103] A. Rezaee Jordehi, “Enhanced leader particle swarm optimisation (ELPSO): An efficient algorithm for parameter estimation of photovoltaic (PV) cells and modules,” *Sol. Energy*, vol. 159, no. March 2017, pp. 78–87, 2018, doi: 10.1016/j.solener.2017.10.063.
- [104] M. Abd Elaziz and D. Oliva, “Parameter estimation of solar cells diode models by an improved opposition-based whale optimization algorithm,” *Energy Convers. Manag.*, vol. 171, no. May, pp. 1843–1859, 2018, doi: 10.1016/j.enconman.2018.05.062.
- [105] L. Wu *et al.*, “Parameter extraction of photovoltaic models from measured I-V characteristics curves using a hybrid trust-region reflective algorithm,” *Appl. Energy*, vol. 232, no. September, pp. 36–53, 2018, doi: 10.1016/j.apenergy.2018.09.161.
- [106] X. Gao *et al.*, “Parameter extraction of solar cell models using improved shuffled complex evolution algorithm,” *Energy Convers. Manag.*, vol. 157, no. August 2017, pp. 460–479, 2018, doi: 10.1016/j.enconman.2017.12.033.
- [107] A. M. Beigi and A. Maroosi, “Parameter identification for solar cells and module using a Hybrid Firefly and Pattern Search Algorithms,” *Sol. Energy*, vol. 171, no. June, pp. 435–446, 2018, doi: 10.1016/j.solener.2018.06.092.
- [108] M. Merchaoui, A. Sakly, and M. F. Mimouni, “Particle swarm optimisation with adaptive mutation strategy for photovoltaic solar cell/module parameter

- extraction,” *Energy Convers. Manag.*, vol. 175, no. June, pp. 151–163, 2018, doi: 10.1016/j.enconman.2018.08.081.
- [109] D. T. Cotfas, A. M. Deaconu, and P. A. Cotfas, “Application of successive discretization algorithm for determining photovoltaic cells parameters,” *Energy Convers. Manag.*, vol. 196, no. April, pp. 545–556, 2019, doi: 10.1016/j.enconman.2019.06.037.
- [110] X. Chen and K. Yu, “Hybridizing cuckoo search algorithm with biogeography-based optimization for estimating photovoltaic model parameters,” *Sol. Energy*, vol. 180, no. October 2018, pp. 192–206, 2019, doi: 10.1016/j.solener.2019.01.025.
- [111] G. Xiong, J. Zhang, D. Shi, L. Zhu, X. Yuan, and G. Yao, “Optimization Algorithm with Selection Operator for Parameter Extraction of Solar Photovoltaic Models,” *Remote Sens.*, vol. 11, no. 23, p. 2795, 2019.
- [112] R. Chenouard and R. A. El-Sehiemy, “An interval branch and bound global optimization algorithm for parameter estimation of three photovoltaic models,” *Energy Convers. Manag.*, vol. 205, no. December 2019, p. 112400, 2020, doi: 10.1016/j.enconman.2019.112400.
- [113] Y. Zhang, C. Huang, and Z. Jin, “Backtracking search algorithm with reusing differential vectors for parameter identification of photovoltaic models,” *Energy Convers. Manag.*, vol. 223, no. July, p. 113266, 2020, doi: 10.1016/j.enconman.2020.113266.
- [114] J. Liang *et al.*, “Classified perturbation mutation based particle swarm optimization algorithm for parameters extraction of photovoltaic models,” *Energy Convers. Manag.*, vol. 203, no. November 2019, p. 112138, 2020, doi: 10.1016/j.enconman.2019.112138.
- [115] Y. Zhang, M. Ma, and Z. Jin, “Comprehensive learning Jaya algorithm for parameter extraction of photovoltaic models,” *Energy*, vol. 211, p. 118644, 2020, doi: 10.1016/j.energy.2020.118644.
- [116] D. Yousri, S. B. Thanikanti, D. Allam, V. K. Ramachandaramurthy, and M. B. Eteiba, “Fractional chaotic ensemble particle swarm optimizer for identifying the single, double, and three diode photovoltaic models’ parameters,” *Energy*, vol. 195, p. 116979, 2020, doi: 10.1016/j.energy.2020.116979.
- [117] Y. Zhang, Z. Jin, and S. Mirjalili, “Generalized normal distribution optimization and its applications in parameter extraction of photovoltaic models,” *Energy Convers. Manag.*, vol. 224, no. July, p. 113301, 2020, doi:

10.1016/j.enconman.2020.113301.

- [118] D. Yousri, H. Rezk, and A. Fathy, "Identifying the parameters of different configurations of photovoltaic models based on recent artificial ecosystem-based optimization approach," *Int. J. Energy Res.*, vol. 44, no. 14, pp. 11302–11322, 2020, doi: 10.1002/er.5747.
- [119] H. Zhang, A. A. Heidari, M. Wang, L. Zhang, H. Chen, and C. Li, "Orthogonal Nelder-Mead moth flame method for parameters identification of photovoltaic modules," *Energy Convers. Manag.*, vol. 211, no. March, 2020, doi: 10.1016/j.enconman.2020.112764.
- [120] L. M. P. Deotti, J. L. R. Pereira, and I. C. da Silva Júnior, "Parameter extraction of photovoltaic models using an enhanced Lévy flight bat algorithm," *Energy Convers. Manag.*, vol. 221, no. May, p. 113114, 2020, doi: 10.1016/j.enconman.2020.113114.
- [121] Z. Lang and Y. Zhang, "Parameter identification and performance estimation for PV modules based on reduced forms model," *J. Renew. Sustain. Energy*, vol. 12, no. 5, 2020, doi: 10.1063/5.0019511.
- [122] H. Chen, S. Jiao, M. Wang, A. A. Heidari, and X. Zhao, "Parameters identification of photovoltaic cells and modules using diversification-enriched Harris hawks optimization with chaotic drifts," *J. Clean. Prod.*, vol. 244, p. 118778, 2020, doi: 10.1016/j.jclepro.2019.118778.
- [123] M. Bencherif and N. Brahmi, "Solar cell parameter identification using the three main points of the current-voltage characteristic," *Int. J. Ambient Energy*, pp. 1–26, 2020, doi: 10.1080/01430750.2020.1789739.
- [124] R. Herbazi, Y. Kharchouf, K. Amechnoue, A. Khouya, and A. Chahboun, "Solar Photovoltaic Cell Parameters Extraction Using Differential Evolution Algorithm," p. 43, 2020, doi: 10.3390/proceedings2020063043.
- [125] H. Rezk, T. S. Babu, M. Al-Dhaifallah, and H. A. Ziedan, "A robust parameter estimation approach based on stochastic fractal search optimization algorithm applied to solar PV parameters," *Energy Reports*, vol. 7, pp. 620–640, 2021, doi: 10.1016/j.egyr.2021.01.024.
- [126] "2021_Artificial ecosystem-based optimiser to electrically characterise PV generating systems under various operating conditions reinforced by experimental validations.pdf." .
- [127] B. Lekouaghet, A. Boukabou, and C. Boubakir, "Estimation of the photovoltaic

cells/modules parameters using an improved Rao-based chaotic optimization technique,” *Energy Convers. Manag.*, vol. 229, no. August 2020, p. 113722, 2021, doi: 10.1016/j.enconman.2020.113722.

- [128] X. Ye *et al.*, “Modified Whale Optimization Algorithm for Solar Cell and PV Module Parameter Identification,” *Complexity*, vol. 2021, 2021, doi: 10.1155/2021/8878686.