



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

DANILO DE OLIVEIRA PIMENTEL

**ESTIMAÇÃO DE PARÂMETROS DE MÓDULOS FOTOVOLTAICOS
UTILIZANDO MÉTODOS DE OTIMIZAÇÃO BASEADO EM
METAHEURÍSTICA**

Recife

2020

DANILO DE OLIVEIRA PIMENTEL

**ESTIMAÇÃO DE PARÂMETROS DE MÓDULOS FOTOVOLTAICOS
UTILIZANDO MÉTODOS DE OTIMIZAÇÃO BASEADO EM
METAHEURÍSTICA**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Pernambuco como requisito parcial para a obtenção do grau de mestre em Engenharia Elétrica. Área de Concentração: Processamento de Energia

Orientador: Prof. Dr. Marcelo Cabral Cavalcanti

Coorientador: Prof. Dr. Fabrício Bradaschia

Recife

2020

Catálogo na fonte
Bibliotecário Gabriel Luz CRB-4 / 2222

P664e Pimentel, Danilo de Oliveira.
Estimação de parâmetros de módulos fotovoltaicos utilizando métodos de
otimização baseado em metaheurística / Danilo de Oliveira Pimentel.
143 f.; figs., tabs., abrev. e siglas, símbol.

Orientador: Prof. Dr. Marcelo Cabral Cavalcanti.

Coorientador: Prof. Dr. Fabrício Bradaschia.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG.
Departamento de Engenharia Elétrica, Recife, 2020.

Inclui referências.

1. Engenharia Elétrica. 2. Modelagem de módulos fotovoltaicos. 3.
Otimização por enxame de partículas. 4. Otimização por enxame de partículas
evolutivas. 5. Otimização busca por padrões. I. Cavalcanti, Marcelo Cabral
(Orientador). II. Bradaschia, Fabrício (Coorientador). III. Título.

UFPE

621.3 CDD (22. ed.)

BCTG / 2022-39

DANILO DE OLIVEIRA PIMENTEL

**ESTIMAÇÃO DE PARÂMETROS DE MÓDULOS FOTOVOLTAICOS UTILIZANDO
MÉTODOS DE OTIMIZAÇÃO BASEADO EM METAHEURÍSTICA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Pernambuco, como um dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Processamento de Energia.

Aprovada em: 28 / 02 / 2020

BANCA EXAMINADORA

Prof. Dr. Marceo Cabral Cavalcanti (membro titular interno)

Universidade Federal de Pernambuco - UFPE

Prof. Dr. Fabricio Badraschia (membro titular interno)

Universidade Federal de Pernambuco - UFPE

Prof. Dr. Gustavo Medeiros de Souza Azevedo (membro titular interno)

Universidade Federal de Pernambuco - UFPE

Prof. Dr. Leandro Michels (membro titular externo)

Universidade Federal de Santa Maria - UFSM

AGRADECIMENTOS

Agradeço à Deus, primeiramente, que me deu forças para vencer os obstáculos e concluir este trabalho. Ao meu orientador Prof. Dr. Marcelo Cabral Cavalcanti e coorientador Prof. Dr. Fabrício Bradaschia pela paciência e valiosa colaboração. Agradeço ambos imensamente pela atenção dedicada nas orientações, nos conhecimentos transmitidos que foram imprescindíveis para a realização deste trabalho. Aos professores do DEE/UFPE, pelos conhecimentos que se tornaram a base para que este estudo fosse realizado. À aluna de graduação em Engenharia Elétrica Beatriz Rodrigues pela parceria desenvolvida na coleta de resultados deste trabalho. Agradeço à Universidade Federal de Pernambuco, pela estrutura fornecida aos estudos e no conhecimento transmitido ao longo dos anos de graduação e pós-graduação. Ao CNPq, pelo apoio financeiro que permitiram a minha exclusiva dedicação a este projeto. Agradeço aos membros da banca examinadora, pela disponibilidade de participar e pelas contribuições pessoais acerca deste trabalho. Aos meus pais Francisco da Silva Pimentel e Maria Ilda Alves de Oliveira Pimentel e minhas irmãs Danielle de Oliveira Pimentel e Gabriella de Oliveira Pimentel pelo incentivo e apoio incondicional. A minha namorada Fernanda Pedroza pela compreensão e apoio nos momentos difíceis. Enfim, agradeço a todas as pessoas que fizeram parte direta ou indiretamente para que fosse possível a realização deste trabalho.

RESUMO

O presente trabalho é justificado pelo aumento crescente nos últimos anos das aplicações e projetos de geração de energia elétrica através de sistemas fotovoltaicos. Para o estudo desses sistemas, é de fundamental importância o conhecimento e análise das características físicas, elétricas e princípio de funcionamento de células/módulos fotovoltaicos, de modo a identificar os parâmetros que influenciam a eficiência do processo de conversão de energia. Nesse cenário, o desenvolvimento de pesquisas vem sendo realizadas para definição de modelos matemáticos precisos para células e/ou módulos, visto que esses modelos possuem um papel fundamental na avaliação de desempenho e são usados para diversas finalidades como, por exemplo, para realizar previsões de geração de energia elétrica produzida a partir de arranjos fotovoltaicos, nas simulações de arranjos fotovoltaicos sob diferentes condições climáticas, na qualidade do dispositivo durante a fabricação, no projeto e otimização de técnicas de Seguimento de Ponto de Máxima Potência (*Maximum Power Point Tracking* – MPPT). A modelagem matemática e a representação através de circuitos elétricos das células fotovoltaicas são ferramentas bastante úteis para o cálculo dos parâmetros desconhecidos e na determinação do comportamento de uma célula/módulo fotovoltaico perante as mudanças ambientais. O principal objetivo deste trabalho consiste em estudar um modelo global não-linear baseado no circuito elétrico de um diodo para módulos FV e realizar um estudo comparativo de precisão ao aplicar os métodos de otimização Busca por Padrões (*Pattern Search* - PS), Enxame por Partículas (*Particle Swarm Optimization* - PSO) e Enxame por Partículas Evolutivas (*Evolutionary Particle Swarm Optimization* - EPSO) no processo de estimação dos parâmetros do modelo do módulo fotovoltaico. O modelo global não-linear foi inicialmente proposto com processo de estimação de seus parâmetros utilizando o método de otimização PS, logo, este trabalho teve como objetivo avaliar novas ferramentas de otimização no processo de estimação de parâmetros deste modelo. O estudo e a aplicação dos métodos de otimização utilizados no modelo para o processo de estimação dos parâmetros é de fundamental importância, pois os parâmetros estimados são responsáveis pela previsão do comportamento das curvas $I-V$ e $P-V$, daí a necessidade de eles serem os mais precisos possíveis. Portanto, neste trabalho serão avaliados a precisão do modelo global não-linear e métodos de otimização, ou seja, a sua capacidade em prever o comportamento das curvas $I-V$ e $P-V$ baseados na comparação com curvas experimentais, utilizando o Erro Médio Absoluto em Potência (EMAP) como indicador comparativo para as

tecnologias de silício monocristalino, silício policristalino, silício amorfo, telureto de cádmio e disseleneto de cobre, índio e gálio.

Palavras-chaves: modelagem de módulos fotovoltaicos; otimização por enxame de partículas; otimização por enxame de partículas evolutivas; otimização busca por padrões.

ABSTRACT

This study is justified by the growing increase in recent years of applications and projects of power generation through photovoltaic systems. The present work is justified by the growing increase in recent years in the applications and projects of electric power generation through photovoltaic systems. For the study of these systems, the knowledge and analysis of the physical, electrical characteristics and operating principle of photovoltaics cells/modules it is crucial, in order to identify the parameters that influence the efficiency of the energy conversion process. In this scenario, research development has been carried out to define precise mathematical models for cells and /or modules, since these models have a fundamental role in performance evaluation and are used for several purposes, such as, forecasting electricity generation produced from photovoltaic arrays, the simulation of photovoltaic arrays under different climatic conditions, the quality of the device during manufacturing, design and optimization of *Maximum Power Point Tracking* (MPPT) techniques. The mathematical modeling and representation through electrical circuits of photovoltaic cells are very useful tools for calculating unknown parameters and determining the behavior of a photovoltaic cell / module in the face of environmental changes. The main objective of this work is to study a global nonlinear model based on the electrical circuit of single diode for photovoltaic modules and to perform a comparative study of precision when applying the methods *Pattern Search* (PS), *Particle Swarm Optimization* (PSO) and *Evolutionary Particle Swarm Optimization* (EPSO) in the process of estimating the parameters of the model of the photovoltaic module. The study and application of the optimization methods used in the model for the parameter estimation process is of fundamental importance, since the estimated parameters are responsible for predicting the behavior of the $I-V$ and $P-V$ curves, hence the need for them to be as accurate as possible. The global nonlinear model was initially proposed with a process for estimating its parameters using the PS optimization method, therefore, this work aims to evaluate new optimization methods in the parameter estimation process of this model. Therefore, in this work, the precision of the global nonlinear model and optimization methods will be evaluated, that is, its ability to predict the behavior of $I-V$ and $P-V$ curves based on comparison with experimental curves, using the *Mean Absolute Error in Power* (MAEP) as a comparative indicator for the technologies of monocrystalline silicon, polycrystalline silicon, amorphous silicon, cadmium telluride and copper, indium and gallium diselenide.

Keywords: modeling of photovoltaic modules; particle swarm optimization; evolutionary particle swarm optimization; pattern search.

LISTA DE FIGURAS

Figura 1 – Modelos do módulo FV baseados em circuitos elétricos equivalentes de (a) um diodo e (b) dois diodos.	24
Figura 2 – Indicação dos ângulos dos raios solares incidentes no plano inclinado. . . .	31
Figura 3 – Componentes da radiação solar.	32
Figura 4 – Instrumentos de medição da radiação solar: (a) piranômetro e (b) pireliômetro.	33
Figura 5 – Definição de Massar de Ar.	34
Figura 6 – Composição do espectro da radiação solar.	34
Figura 7 – Distribuição espectral da irradiância no topo da atmosfera; da irradiância ao incidir perpendicularmente sobre uma superfície inclinada (37°) ao nível do mar e voltada para a linha do Equador; da irradiância após atravessar uma massa de ar de 1,5.	35
Figura 8 – Respostas espectrais para diferentes tecnologias de células FV.	36
Figura 9 – Módulos FV fabricados com células de silício Monocristalino e Policristalino.	38
Figura 10 – Células fotovoltaicas de silício amorfo.	38
Figura 11 – Estrutura de uma célula solar de CdS/CdTe.	39
Figura 12 – Módulo FV (telhado solar) formado por células de CIGS.	40
Figura 13 – Células, módulos e arranjos FV.	41
Figura 14 – Estrutura dos componentes de um módulo fotovoltaico de silício cristalino .	41
Figura 15 – Células FV ligadas em série na composição do módulo	42
Figura 16 – Células FV ligadas em paralelo na composição do módulo.	42
Figura 17 – Circuito equivalente de uma célula FV ideal.	43
Figura 18 – Uma célula fotovoltaica sob diversas condições de iluminação: (a) célula FV com as mesmas características elétricas de um diodo no escuro. (b) quando a célula FV é iluminada, sua curva $I-V$ se desloca para o 4º quadrante. (c) quanto maior a intensidade da radiação incidente, maior o deslocamento da curva $I-V$. (d) a curva é então representada, por convenção, através da rotação em relação ao eixo das tensões, sendo representada no 1º quadrante.	45
Figura 19 – Circuito equivalente de um diodo de uma célula solar com as resistências série e paralelo.	45
Figura 20 – Circuito equivalente de um módulo FV.	46

Figura 21 – Curvas características de um módulo FV: (a) corrente versus tensão; (b) potência versus tensão para o módulo xSi11246.	47
Figura 22 – Condição de curto-circuito de um módulo fotovoltaico	49
Figura 23 – Condição de circuito aberto de um módulo FV.	49
Figura 24 – Definição gráfica do fator de forma.	50
Figura 25 – Comportamento das curvas (a) corrente versus tensão ($I-V$) e (b) potência versus tensão ($P-V$) de acordo com a variação da irradiância.	51
Figura 26 – Comportamento das curvas (a) corrente versus tensão ($I-V$) e (b) potência versus tensão ($P-V$) de acordo com a variação da temperatura.	52
Figura 27 – Diagrama de bandas de energia em materiais (a) condutores, (b) semicondutores e (c) isolantes.	53
Figura 28 – Comportamento das curvas (a) corrente versus tensão ($I-V$) e (b) potência versus tensão ($P-V$) de acordo com a variação da corrente de saturação.	54
Figura 29 – Estrutura representativa da célula FV mostrando os principais elementos que dão origem a resistência série.	55
Figura 30 – Comportamento das curvas (a) corrente versus tensão ($I-V$) e (b) potência versus tensão ($P-V$) de acordo com a variação da resistência série.	56
Figura 31 – Comportamento das curvas (a) corrente versus tensão ($I-V$) e (b) potência versus tensão ($P-V$) de acordo com a variação da resistência paralela.	57
Figura 32 – Processo de conversão da radiação solar em corrente elétrica em células FV	57
Figura 33 – Comportamento das curvas (a) corrente versus tensão ($I-V$) e (b) potência versus tensão ($P-V$) de acordo com a variação do fator de idealidade.	58
Figura 34 – Fluxo do processo de otimização.	64
Figura 35 – Categorização dos algoritmos de otimização.	66
Figura 36 – Valores da função objetivo no ponto inicial e nos pontos da malha formada.	72
Figura 37 – Valores da função objetivo em x_1 e nos pontos da malha formada.	73
Figura 38 – Valores da função objetivo em x_3 e nos pontos da malha formada.	74
Figura 39 – Fluxograma do algoritmo de Busca Generalizada por Padrões (GPS).	75
Figura 40 – Diagrama vetorial do mecanismo de busca do PSO.	78
Figura 41 – Fluxograma do PSO	82
Figura 42 – Ilustração da regra do movimento no EPSO.	86
Figura 43 – Fluxograma do algoritmo EPSO.	88
Figura 44 – Região de maior importância do EMAP.	97

Figura 45 – Método de Busca por Padrões com algoritmo inicialização.	110
Figura 46 – Definição da estrutura de otimização PS com algoritmo de inicialização. . .	111
Figura 47 – Comparação entre as curvas obtidas na simulação da Tabela 9 e as curvas experimentais para diferentes irradiâncias.	117
Figura 48 – Comparação entre as curvas obtidas na simulação da Tabela 10 e as curvas experimentais para diferentes irradiâncias.	118
Figura 49 – Comparação entre as curvas obtidas na simulação da Tabela 11 e as curvas experimentais para diferentes irradiâncias.	119
Figura 50 – Comparação entre as curvas obtidas na simulação da Tabela 12 e as curvas experimentais para diferentes irradiâncias.	120
Figura 51 – Comparação entre as curvas obtidas na simulação da Tabela 13 e as curvas experimentais para diferentes irradiâncias.	121
Figura 52 – Comparação entre as curvas $I-V$ reproduzidas pelo modelo e as curvas experimentais para diferentes irradiâncias para o módulo xSi11246 utilizando o método (a) PS (GPS-2N) e (b) EPSO com taxa de mutação 0,001. . . .	129
Figura 53 – Comparação entre as curvas $I-V$ reproduzidas pelo modelo e as curvas experimentais, utilizando o método de otimização que gerou menor EMAP médio, em condições variáveis para os módulos (a) mSi460A8 e (b) CIGS39017.131	

LISTA DE TABELAS

Tabela 1 – Rendimento das melhores células FV produzidas em laboratório até 2019.	40
Tabela 2 – Curvas de referências experimentais utilizadas no processo de estimação dos parâmetros	108
Tabela 3 – Curvas experimentais (curvas de estimação) utilizadas no processo de estimação dos parâmetros.	108
Tabela 4 – Curvas experimentais utilizadas para validação do processo comparativo entre os métodos de otimização.	109
Tabela 5 – Estratégias de otimização do método PS avaliadas para o módulo mSi460A8.	113
Tabela 6 – Estratégias de otimização do método PS avaliadas para os módulos xSi11246, HIT05667, CdTe75368 e CIGS39017.	114
Tabela 7 – Ajuste dos parâmetros da equação da velocidade do PSO na primeira etapa do processo de estimação dos parâmetros.	114
Tabela 8 – Ajuste dos parâmetros da equação da velocidade do EPSO na primeira etapa do processo de estimação dos parâmetros.	115
Tabela 9 – Resultados da validação da estimação de parâmetros para o módulo mSi460A8, usando o método PS (MADS NP1) com tipo de pesquisa completa na malha para curvas diferentes do conjunto estimação.	117
Tabela 10 – Resultados da validação da estimação de parâmetros para o módulo mSi460A8, usando o método PS padrão (GPS 2N) para curvas diferentes do conjunto estimação.	118
Tabela 11 – Resultados da validação da estimação de parâmetros para o módulo mSi460A8, usando o método PSO para curvas diferentes do conjunto estimação.	119
Tabela 12 – Resultados da validação da estimação de parâmetros para o módulo mSi460A8, usando o método EPSO com taxa de mutação 0.001 para curvas diferentes do conjunto estimação.	120
Tabela 13 – Resultados da validação da estimação de parâmetros para o módulo mSi460A8, usando o método EPSO com taxa de mutação 1 para curvas diferentes do conjunto estimação.	121
Tabela 14 – Resultados dos erros médios do conjunto de curvas de validação para o módulo mSi460A8	122

Tabela 15 – Média e desvio padrão dos valores do $EMAP_{med}$ e $RMSD_{med}$ dos métodos estocásticos do conjunto de curvas de validação para o módulo mSi460A8 avaliadas em cinco estimativas de parâmetros.	123
Tabela 16 – Resultados dos erros médios do conjunto de curvas de validação para o módulo xSi11246	123
Tabela 17 – Média e desvio padrão dos valores do $EMAP_{med}$ e $RMSD_{med}$ dos métodos estocásticos do conjunto de curvas de validação para o módulo xSi11246 avaliadas em cinco estimativas de parâmetros.	124
Tabela 18 – Resultados dos erros médios do conjunto de curvas de validação para o módulo HIT05667.	124
Tabela 19 – Média e desvio padrão dos valores do $EMAP_{med}$ e $RMSD_{med}$ dos métodos estocásticos do conjunto de curvas de validação para o módulo HIT05667 avaliadas em cinco estimativas de parâmetros.	125
Tabela 20 – Resultados dos erros médios do conjunto de curvas de validação para o módulo CdTe75368.	126
Tabela 21 – Média e desvio padrão dos valores do $EMAP_{med}$ e $RMSD_{med}$ dos métodos estocásticos do conjunto de curvas de validação para o módulo CdTe75368 avaliadas em cinco amostras.	126
Tabela 22 – Resultados dos erros médios do conjunto de curvas de validação para o módulo CIGS39017.	127
Tabela 23 – Média e desvio padrão dos valores do $EMAP_{med}$ e $RMSD_{med}$ dos métodos estocásticos do conjunto de curvas de validação para o módulo CIGS39017 avaliadas em cinco estimativas de parâmetros.	127
Tabela 24 – Tempos de convergência total dos métodos avaliados.	128

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
AM	<i>Air Mass</i>
ANEEL	Agência Nacional de Energia Elétrica
CdTe	Telureto de Cádmio
CIGS	Disseleneto de Cobre, Gálio e Índio
DSSC	<i>Dye-Sensitized Solar Cell</i>
EMAP	Erro Médio Absoluto em Potência
EPSO	<i>Evolutionary Particle Swarm Optimization</i>
FV	fotovoltaico
GW	gigawatt
INMETRO	Instituto Nacional de Metrologia, Qualidade e Tecnologia
MAEP	<i>Mean Absolute Error in Power</i>
MPPT	<i>Maximum Power Point Tracking</i>
NREL	<i>National Renewable Energy Laboratory</i>
OPV	<i>Organic Photovoltaics</i>
PS	<i>Pattern Search</i>
PSO	<i>Particle Swarm Optimization</i>
STC	<i>Standard Test Conditions</i>
WRC	<i>World Radiation Center</i>

LISTA DE SÍMBOLOS

α	Altura ou elevação solar
α_i	Coefficiente de variação de I_g com a temperatura
β	Inclinação da superfície de captação
β_S	Coefficiente de variação de V_{oc} com a irradiância
β_T	Coefficiente de variação de V_{oc} com a temperatura
γ	Ângulo azimutal da superfície
γ_{R_s}	Coefficiente de variação de R_s com a irradiância
γ_{R_p}	Coefficiente de variação de R_p com a irradiância
γ_s	Ângulo azimutal do Sol
θ	Ângulo de incidência
θ_z	Ângulo zenital
$\sigma_{EMAP_{med}}$	Desvio padrão do $EMAP_{med}$
$\sigma_{RMSD_{med}}$	Desvio padrão do $RMSD_{med}$
ω	Coefficiente de peso inercial
A	Fator de idealidade A
A_{ref}	Fator de idealidade A de referência
A_{MF}	Área do módulo fotovoltaico
B	Constante independente da temperatura, usada para calcular $I_{sat}(T)$
c-Si	Silício cristalino
c_1	Constante de aceleração associada ao fator individual de cada partícula
c_2	Constante de aceleração associada ao fator social das partículas
E_g	Energia do gap

G_{best}	Melhor posição global da partícula
$I_{g,STC}$	Corrente fotogerada nominal
I_g	Corrente gerada sob uma dada irradiância (ou corrente fotogerada) do módulo fotovoltaico
I_{mp}	Corrente no ponto de máxima potência
$I_{sat,ref}$	Corrente de saturação reversa de referência
$I_{sat,STC}$	Corrente de saturação reversa nominal
I_{sat}	Corrente de saturação reversa
$I_{sc,ref}$	Corrente fotogerada para a condição de referência
$I_{sc,STC}$	Corrente nominal de curto-circuito
I_{sc}	Corrente de curto-circuito
k	Constante de Boltzmann
k_{R_p}	Coefficiente de variação de R_p com a temperatura
k_{R_s}	Coefficiente de variação de R_s com a temperatura
m-Si	Silício monocristalino
P_{best}	Melhor posição individual da partícula
P	Fator de comunicação
p-Si	Silício policristalino
r_1 e r_2	Números aleatórios
r_p	Resistência paralela da célula fotovoltaica
R_p	Resistência paralela do módulo fotovoltaico
$R_{p,ref}$	Resistência paralela para a condição de referência
r_s	Resistência série da célula fotovoltaica

R_s	Resistência série do módulo fotovoltaico
$R_{s,ref1}$	Parcela de R_s que é constante em relação à temperatura
$R_{s,ref2}$	Parcela de R_s que varia em relação à irradiância
S	Irradiância
T	Temperatura
V_{mp}	Tensão no ponto de máxima potência
$V_{oc,ref}$	Tensão de circuito aberto para a condição de referência
$V_{oc,STC}$	Tensão nominal de circuito aberto
V_{oc}	Tensão de circuito aberto
$V_{i,j}^k$	Vetor velocidade da partícula i na iteração atual k
$X_{i,j}^k$	Posição ou solução da partícula i na iteração k
ω_{i1}^*	Peso associado à inércia
ω_{i2}^*	Peso condicionado à memória da partícula
ω_{i3}^*	Peso condicionado à cooperação

SUMÁRIO

1	INTRODUÇÃO	21
1.1	OBJETIVOS E METODOLOGIA DA DISSERTAÇÃO DE MESTRADO	28
1.2	ORGANIZAÇÃO DO TEXTO	29
2	ASPECTOS GERAIS SOBRE MÓDULOS FOTOVOLTAICOS	30
2.1	ASPECTOS GERAIS	30
2.1.1	O Recurso Solar	30
2.1.2	Espectro Solar	34
2.1.3	Tipos de Células FV e Tecnologias de Fabricação	35
2.2	ASSOCIAÇÕES DE CÉLULAS E MÓDULOS FOTOVOLTAICOS	41
2.3	CARACTERÍSTICAS ELÉTRICAS DE MÓDULOS FOTOVOLTAICOS	42
2.3.1	Análise do Circuito Equivalente para Módulos Fotovoltaicos	43
2.3.2	Curvas Características: Corrente versus Tensão ($I-V$) e Potência versus Tensão ($P-V$)	47
2.3.3	Definição dos Parâmetros Elétricos	48
2.4	PARÂMETROS EXTERNOS QUE INFLUENCIAM AS CARACTERÍSTICAS ELÉTRICAS	50
2.4.1	Irradiância	50
2.4.2	Temperatura	51
2.5	PARÂMETROS INTERNOS QUE INFLUENCIAM AS CARACTERÍSTICAS ELÉTRICAS	53
2.5.1	Corrente de Saturação Reversa – I_{sat}	53
2.5.2	Resistência Série – R_s	54
2.5.3	Resistência Paralelo – R_p	55
2.5.4	Fator de Idealidade	56
2.6	MODELO GLOBAL NÃO-LINEAR DO MÓDULO FOTOVOLTAICO	58
2.7	CONCLUSÕES	62
3	TÉCNICAS DE OTIMIZAÇÃO UTILIZADAS NA ESTIMAÇÃO DE PARÂMETROS DE MÓDULOS FV	63
3.1	ASPECTOS GERAIS DO PROCESSO DE OTIMIZAÇÃO	63
3.1.1	Processo de Otimização	63

3.1.2	Formulação do Problema de Otimização	64
3.1.3	Classificação dos Problemas de Otimização	65
3.2	MÉTODOS DE OTIMIZAÇÃO PARA SOLUÇÃO DE PROBLEMAS	65
3.2.1	Métodos de Otimização Metaheurísticos	67
3.3	OTIMIZAÇÃO BASEADA EM BUSCA POR PADRÕES (<i>PATTERN SEARCH - PS</i>)	68
3.3.1	Algoritmo de Busca Generalizada por Padrões (<i>Generalized Pattern Search - GPS</i>)	69
3.4	OTIMIZAÇÃO BASEADA NO ENXAME DE PARTÍCULAS (<i>PARTICLE SWARM OPTIMIZATION - PSO</i>)	76
3.4.1	Equações da Velocidade e Posição do PSO	77
3.4.2	Ajuste dos Parâmetros	79
3.4.3	Algoritmo PSO	80
3.5	OTIMIZAÇÃO BASEADA EM ENXAME DE PARTÍCULAS EVOLUTIVO (<i>EVOLUTIONARY PARTICLE SWARM OPTIMIZATION - EPSO</i>)	82
3.5.1	Equação da Velocidade e Posição do EPSO	84
3.5.2	Ajuste dos Parâmetros	86
3.5.3	Algoritmo	86
3.6	CONCLUSÕES	89
4	PROCESSO DE ESTIMAÇÃO DE PARÂMETROS DE MÓDULOS FOTOVOLTAICOS E AVALIAÇÃO DOS RESULTADOS APLICANDO OS MÉTODOS DE OTIMIZAÇÃO METAHEURÍSTICOS	91
4.1	OBTENÇÃO DAS CURVAS <i>I-V</i>	92
4.1.1	Conjunto de Dados Obtidos em <i>Datasheets</i>	93
4.1.2	Conjunto de Dados Obtidos Experimentalmente	93
4.2	INTRODUÇÃO AO PROCESSO DE ESTIMAÇÃO DE PARÂMETROS DE MÓDULOS FOTOVOLTAICOS	94
4.3	FORMULAÇÃO DO PROBLEMA DE OTIMIZAÇÃO	96
4.3.1	Definição dos Erros	96
4.3.2	Descrição do Problema de Otimização	98
4.4	PROCESSO DE ESTIMAÇÃO DOS PARÂMETROS DO MODELO GLOBAL NÃO-LINEAR	98
4.4.1	1ª Etapa - Definição dos Parâmetros Vinculados à Curva de Referência	99

4.4.2	2ª Etapa - Definição das Expressões de I_{sc} e V_{oc}	101
4.4.3	3ª Etapa - Determinação das Expressões Restantes	104
4.5	CONDIÇÕES DAS SIMULAÇÕES	107
4.5.1	Critérios de Parada	109
4.5.2	Estratégia de Otimização	109
4.6	RESULTADOS DAS SIMULAÇÕES	115
4.7	CONCLUSÕES	131
5	CONCLUSÃO	133
5.1	TRABALHOS FUTUROS	134
	REFERÊNCIAS	136

1 INTRODUÇÃO

A geração de energia elétrica é essencial para a produção de riqueza e o consumo está inteiramente associado aos indicadores de desenvolvimento econômico e social de uma nação. Os avanços tecnológicos, o crescimento econômico e demográfico e os comportamentos socioculturais são alguns dos fatores que motivam a elevação da demanda mundial de energia e que determinam os padrões de consumo energético. Diante desse cenário, as estratégias de suprimento energético através das fontes renováveis de energia cresceram bastante nos últimos anos, tendo um grande destaque a fonte solar.

Basicamente, de todas as fontes de energia existentes, em sua maioria são provenientes da energia do Sol, ou seja, de forma direta ou indireta, o Sol é o grande responsável pela origem de praticamente todas as outras fontes de energia na Terra. Assim sendo, o recurso solar direto pode, simplificarmente em termos de aplicações em engenharia, ser classificado em energia solar fotovoltaica e energia solar térmica (CEPEL-CRESESB, 2014).

Em um breve histórico, o processo de conversão da energia solar para a produção de eletricidade teve início em 1839, quando o então cientista francês Edmond Becquerel descobriu o princípio do efeito fotovoltaico (FV). Em seus experimentos, Becquerel observou que a incidência de luz em uma solução ácida provocava uma diferença de potencial entre os terminais de eletrodos imersos nessa solução. Posteriormente, com o decorrer dos anos, diversas contribuições científicas e avanços no aperfeiçoamento do processo de conversão fotovoltaica foram alcançados, principalmente os relacionados ao material usado no processo de conversão. No ano de 1954, foi desenvolvido em laboratório, pelos cientistas Daryl Chapin, Calvin Fuller e Gerald Pearson, o primeiro protótipo de célula fotovoltaica com silício, executando a conversão da luz em eletricidade com eficiência de 6% e com capacidade de alimentar equipamentos. Nesse mesmo ano, deu-se início ao período que incentivaria de fato a aplicação em escala comercial de sistemas FV (PINHO et al., 2008).

A busca pela exploração e tecnologia espacial, conhecida como “corrida espacial” ocorrida na década de 1950 e a crise do petróleo na década de 1970, foram eventos que impulsionaram o desenvolvimento da tecnologia fotovoltaica, porém o alto custo das células impossibilitava a utilização da energia solar em grande escala nesse período (CEPEL-CRESESB, 2014).

Observa-se que nos últimos anos a indústria fotovoltaica teve um crescimento admirável, devido aos avanços na pesquisa e desenvolvimento de novas tecnologias, tendo como resultados

o aumento da eficiência na conversão, a diminuição de custos por unidade de energia gerada, a ampliação de mercados, o surgimento de várias empresas voltadas para produção de células/-módulos FV, as políticas governamentais de incentivo em âmbito mundial e a diversificação da aplicação.

No Brasil, um grande reflexo do crescimento da indústria FV pode ser notado no sistema elétrico nacional, que passa atualmente por um forte processo de transformação e diversificação de sua matriz energética. A fonte solar tem se destacado pela grande quantidade de sistemas FV conectados à rede elétrica. De acordo com a Agência Nacional de Energia Elétrica (ANEEL), o Brasil ultrapassou a marca de 1 gigawatt (GW) de potência instalada em micro e minigeração distribuída de energia elétrica em 2019, onde somente no primeiro trimestre foram realizadas 13.941 novas instalações com a rede elétrica das distribuidoras de energia, representando um crescimento de 134,97% em relação ao mesmo período de 2018, quando foram realizadas 5.933 instalações (AID-ANEEL, 2019).

Nos sistemas FV, a unidade fundamental do processo de conversão de energia é denominada de células FV. Elas podem ser ligadas eletricamente, para formar um conjunto de células e, através do encapsulamento e aplicação de moldura, produz o módulo FV que é projetado para gerar tensão e corrente específicas quando são expostas a incidência da luz solar. Os módulos FV podem ser conectados em série ou em paralelo, a fim de produzir tensões ou correntes maiores, onde podemos destacar algumas de suas aplicações diretas em sistemas de iluminação, monitoramento, bombeamento de água e carregamento de baterias.

Com o aumento crescente das aplicações e projetos de sistemas FV na atualidade, é de fundamental importância o conhecimento e análise das características físicas, elétricas e princípio de funcionamento de células/módulos FV, de modo a identificar os parâmetros que influenciam a eficiência do processo de conversão de energia. Conseqüentemente, o desenvolvimento de pesquisas vem sendo realizado para definição de modelos matemáticos precisos para células e/ou módulos. Visto que esses modelos possuem um papel fundamental na avaliação de desempenho, são usados para realizar previsões de geração de energia elétrica produzida a partir de arranjos FV, nas simulações de arranjos FV sob diferentes condições climáticas, na qualidade do dispositivo durante a fabricação, no projeto e otimização de técnicas de seguimento de ponto de máxima potência (MPPT). Por este motivo, é necessário estabelecer modelos matemáticos com alto grau de precisão e capazes de prever o comportamento dos módulos FV sob quaisquer condições ambientais.

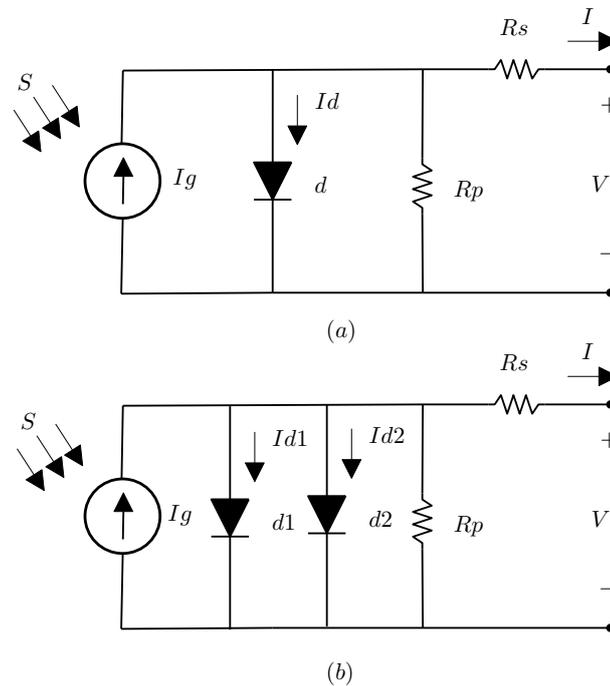
As informações sobre o comportamento elétrico do módulo FV é avaliado através da sua

curva característica que apresenta uma relação de corrente elétrica (I) versus tensão (V) nos terminais do dispositivo. As curvas características são determinadas em condições de teste padrão ou *Standard Test Conditions* (STC), em condições de ensaio especificadas na IEC 60904-3, no qual uma irradiância (S) de 1000 W/m^2 , uma temperatura (T) de $25 \text{ }^\circ\text{C}$ e um espectro solar médio de massa de ar ou *Air Mass* (AM) de 1,5 é utilizado. Entretanto, um módulo FV em condições de operação normal fica exposto a variações de irradiância e temperatura ao longo do dia. Nesse caso, as informações fornecidas nos datasheets pelos fabricantes, como a tensão de circuito aberto ($V_{OC,STC}$), corrente de curto-circuito ($I_{SC,STC}$), corrente (I_{mp}), tensão (V_{mp}) e potência (P_{mp}) no ponto de máxima potência (*Maximum Power Point* – MPP), deixam de ter validade, uma vez que os fabricantes fornecem esses valores para a STC. Outros parâmetros também podem influenciar no comportamento do módulo FV, porém, os fabricantes geralmente não fornecem essas informações.

Os modelos matemáticos mais usuais e pesquisados na literatura para descrever o comportamento dos módulos FV são: o modelo de um diodo (TSAI; HUAN-LIANG, 2010) e o modelo de dois diodos (ISHAQUE; SALAM; SYAFARUDDIN, 2011), representados pelos circuitos elétricos da Figura 1. Existem também estudos sendo realizado com modelos envolvendo três diodos (WEI et al., 2019),(KHANNA et al., 2015). Contudo, o modelo de um diodo é o mais utilizado na representação das células/módulos FV em estudos de simulação, em termos de simplicidade e precisão. Este modelo é composto pelos seguintes elementos: uma fonte de corrente fotogerada (I_g), um diodo (d) em paralelo com a fonte de corrente, uma resistência série (R_s) e uma resistência paralela (R_p).

Após a definição do modelo do módulo FV a ser utilizado, a próxima etapa consiste na obtenção dos parâmetros do modelo através de técnicas de estimação. Nas últimas décadas, muitas pesquisas foram realizadas para a estimação precisa de parâmetros desconhecidos para modelos de módulos FV. A estimação de parâmetros para os modelos dos módulos FV é em geral uma atividade complexa, devido a quantidade de parâmetros a serem estimados e por conta da não-linearidade presente na equação transcendental da junção p-n. Outro fator que pode dificultar o processo de estimação de parâmetros do modelo definido, é que estes parâmetros podem não ser constantes dependendo da proposta do modelo, e assim apresentarem dependência em relação a outros parâmetros (SILVA, 2019). Diversas técnicas para obter esses parâmetros foram propostas na literatura nos últimos anos (KHURSHEED et al., 2019). Geralmente, as técnicas de estimação dos parâmetros podem ser classificadas em quatro categorias:

Figura 1 – Modelos do módulo FV baseados em circuitos elétricos equivalentes de (a) um diodo e (b) dois diodos.



Fonte: O autor (2020)

- Técnicas analíticas (BATZELIS; PAPATHANASSIOU, 2016; SABADUS; PAULESCU; BADESCU, 2018; DONGUE; NJOMO; EBENGAI, 2013);
- Técnicas baseadas em métodos numéricos (BONKOUNGOU et al., 2015; BATZELIS; ROUT-SOLIAS; PAPATHANASSIOU, 2014; HEJRI et al., 2014);
- Técnicas metaheurísticas (DALI; BOUHARCHOUCHE; DIAF, 2015a; ZAGROUBA et al., 2010; ALHAJRI et al., 2012; XU; WANG, 2017);
- Técnicas híbridas (MAJDOUL et al., 2015; LINGYUN et al., 2011; TUTKUN; ELIBOL; MADEN, 2014).

As técnicas analíticas são geralmente baseadas na avaliação da equação transcendental e nas informações fornecidas nos datasheets dos fabricantes de módulo FV. A estimação de parâmetros para os modelos de células/módulos FV torna-se uma atividade complexa neste caso, pois as relações I - V são descritas por um conjunto de equações não-lineares cujos

parâmetros são acoplados reciprocamente. Como em (BATZELIS; PAPATHANASSIOU, 2016), em que um conjunto de expressões analíticas são obtidas a partir da equação transcendental para estimar os cinco parâmetros do modelo de diodo único para módulos FV. Entretanto, para identificar os parâmetros são necessários suposições, para simplificar as equações, causando assim imprecisões ao modelo (JUNIOR, 2018; JADLI; THAKUR; SHUKLA, 2018).

As técnicas baseadas em métodos numéricos aplicam um sistema de equações que é derivado para pontos de operação específicos fornecidos em *datasheets* de módulos comerciais, como os pontos de operação de curto-circuito (I_{sc}), de circuito aberto (V_{oc}) e máxima potência (P_{mp}) (SILVA, 2019). Nesse caso, os métodos numéricos de *Newton-Raphson* e *Gauss-Seidel* são geralmente utilizados para estimar os parâmetros dos modelos elétricos de um módulo FV. A aplicação dos métodos analíticos é útil quando temos somente informações do *datasheet*, enquanto os métodos numéricos têm aplicação mais adequada quando se possui dados experimentais (KHURSHEED et al., 2019). Uma das principais desvantagens dos métodos numéricos é a dependência em relação aos valores iniciais dos parâmetros, pois um erro nesses valores pode comprometer a convergência do algoritmo. Além disso, esses métodos exigem um alto esforço computacional na estimação dos parâmetros por apresentar grandes sistemas de equações (JADLI; THAKUR; SHUKLA, 2018).

As técnicas metaheurísticas são aplicadas quando um problema de estimação dos parâmetros do módulo FV é convertido em um problema de otimização. Essas técnicas geralmente são desenvolvidas a partir do comportamento da natureza e elas podem ter comportamentos determinísticos, bem como probabilísticos (KHURSHEED et al., 2019). Os parâmetros do módulo FV podem ser estimados através da definição de uma função objetivo, um algoritmo e a determinação das condições iniciais. Vários algoritmos de otimização metaheurísticos foram introduzidos para estimar os parâmetros dos módulos FV, entre os quais podemos destacar os algoritmos: o algoritmo genético (COTFAS; COTFAS; CATARON, 2018), a otimização por enxame de partículas (PSO) (YE; WANG; XU, 2009), otimização de colônia artificial de abelhas (OLIVA; CUEVAS; PAJARES, 2014), entre outros. As técnicas metaheurísticas estão se tornando bastante populares para estimar parâmetros de módulos FV devido a sua facilidade de implementação e não exigir a aplicação de derivadas (KHURSHEED et al., 2019). Porém, não garantem a convergência da solução para um mínimo ou máximo global (NI et al., 2018).

Uma quarta categoria são as técnicas híbridas, onde são aplicados duas ou mais técnicas mencionadas anteriormente (BENAHMIDA et al., 2019; KUMAR et al., 2017). Nesse caso, podemos formar uma técnica híbrida através da união dos métodos numérico e metaheurís-

tica, analítica e metaheurística ou metaheurística e outra metaheurística. A hibridização das técnicas é empregada para obter resultados superiores aos obtidos usando apenas uma única técnica para a estimação, pois uma técnica compensa as deficiências da outra (KHURSHEED et al., 2019).

Ao utilizar o modelo de um diodo com cinco parâmetros, a principal desvantagem na utilização das técnicas de estimação mencionadas anteriormente é que os parâmetros são estimados apenas para uma determinada condição, geralmente a condição de *STC*. Desta forma, para diferentes condições ambientais de irradiância e temperatura, o procedimento de estimação de parâmetros requer diferentes conjuntos de parâmetros para o modelo do módulo FV. Isso ocorre porque é necessário utilizar um método de extrapolação para a estimação dos parâmetros, não havendo interpretação física neste processo (SILVA, 2019). Diante deste problema, poucas são as referências que tratam a proposta de modelos em que os parâmetros são influenciados por fatores externos como a irradiância e temperatura e as explicações físicas para esta relação. Portanto, nesse trabalho, adotaremos como referência o modelo denominado de global não-linear, onde o mesmo é baseado no modelo de um diodo e foi proposto em (SILVA, 2019). Este modelo é adequado para determinar o comportamento do módulo FV com precisão para condições ambientais variáveis, ou seja, fora da *STC*. O modelo global não-linear consiste fundamentalmente nos seguintes parâmetros:

- quatro parâmetros ($R_{s,ref1}$, $R_{s,ref2}$, k_{Rs} e γ_{Rs}) que estão relacionados à variação da resistência série, R_s , com a irradiância e temperatura.
- três parâmetros ($R_{p,ref}$, k_{Rp} e γ_{Rp}) que estão relacionados à variação da resistência paralela, R_p , com a irradiância e temperatura;
- um parâmetro (A_{ref}) relacionado ao fator de idealidade A do diodo;
- dois parâmetros ($I_{sc,ref}$ e α_i) que estão relacionados à variação da corrente de curto-circuito, I_{sc} , com a irradiância e temperatura;
- três parâmetros ($V_{oc,ref}$, β_S e β_T) que estão relacionados à variação da tensão de circuito aberto, V_{oc} com a irradiância e temperatura e
- dois parâmetros (I_g e I_{sat}) restantes que são obtidos a partir dos parâmetros já mencionados.

Comparado ao modelo de um diodo, novos parâmetros são acrescentados para compor esse novo modelo, tornando o modelo global não-linear mais complexo de se trabalhar quando comparado aos modelos convencionais da literatura. No entanto, a complexidade do modelo global não-linear é justificada por sua precisão e capacidade de corresponder ao comportamento físico dos módulos FV, ou seja, os parâmetros do módulo FV estão relacionados com as variações de irradiância e temperatura. A relação dos parâmetros do modelo com os fenômenos físicos dos módulos FV abrange áreas de aplicação como confiabilidade, detecção de falhas e degradação prematura do módulo FV, assim como a observação do seu envelhecimento para manutenção preditiva e corretiva (JUNIOR, 2018). Em (SILVA, 2019), foi proposto também a técnica para estimar os parâmetros do modelo global não-linear, conhecida como PS-EMAP, no qual está baseada na ferramenta de otimização busca por padrões (*Pattern Search*-PS) e como função objetivo o erro absoluto em potência (EMAP). Esta técnica de estimação de parâmetros é realizado apenas uma vez e sendo válido para todas as condições ambientais, devido à natureza global do modelo.

Todas as técnicas de estimação citadas anteriormente, necessitam de diversos pontos *I-V* para estabelecer uma curva característica para cada módulo FV, que pode ser experimental ou fornecida pelos *datasheets* do fabricante. Assim sendo, neste trabalho é apresentada uma avaliação comparativa de três técnicas híbridas, utilizando os algoritmos de otimização metaheurísticos, busca por padrões (*Pattern Search* – PS), otimização por enxame de partículas (*Particle Swarm Optimization* - PSO) e evolução do enxame de partículas (*Evolutionary Particle Swarm Optimization* - EPSO) para definição do ponto ótimo (minimização da função objetivo) no processo de estimação de parâmetros das equações que descrevem a característica *I-V* dos módulos FV para o modelo global não-linear baseado na função objetivo EMAP, a partir da avaliação analítica de um banco de dados de curvas *I-V* obtidas experimentalmente e publicamente disponível pela *National Renewable Energy Laboratory* (NREL).

Portanto, o modelo global não-linear, por se apresentar como uma alternativa nova na literatura na modelagem de módulos FV, torna-se necessário estudar e avaliar o seu comportamento para uma gama maior de variações das condições de *S* e *T* durante o processo de validação, visto que em (SILVA, 2019), todo o estudo de validação dos módulos FV contemplou poucas variações das condições de *S* e *T*. Em (SILVA, 2019), não foram avaliadas também diferentes técnicas de otimização metaheurísticas no processo de estimação dos parâmetros, visto que novas técnicas podem ser uma boa alternativa na busca por melhores resultados otimizados dos parâmetros.

1.1 OBJETIVOS E METODOLOGIA DA DISSERTAÇÃO DE MESTRADO

A precisão dos parâmetros de um modelo elétrico para um módulo/célula FV é essencial para a previsão das características reais de desempenho sob condições ambientais variáveis. Sabendo que o modelo global não-linear foi inicialmente proposto com processo de estimação de seus parâmetros envolvendo uma avaliação analítica da equação transcendental, de curvas experimentais e a aplicação do método de otimização busca por padrões (*Pattern Search - PS*), o objetivo geral deste trabalho é avaliar os resultados da aplicação de novas ferramentas de otimização metaheurísticas (PSO e EPSO), no processo de estimação de parâmetros do modelo global não-linear proposto por (SILVA, 2019).

Como objetivos específicos são identificados:

1. Avaliar a eficácia do processo de estimação dos parâmetros decorrente da aplicação das novas ferramentas de otimização através da precisão ao comparar as curvas $I-V$ reproduzidas pelo modelo global não-linear e as curvas experimentais, isto é, a motivação para este trabalho é testar essas novas ferramentas e avaliar se elas melhoram os resultados já existentes com a aplicação do método PS-EMAP.
2. Avaliar os resultados em diferentes tecnologias de módulos FV, resultantes da aplicação do modelo junto com os métodos de otimização estudados neste trabalho na estimação dos parâmetros.

A metodologia desta Dissertação de Mestrado, apresenta a seguinte sequência:

1. Revisão bibliográfica sobre o estado da arte da modelagem de módulos FV.
2. Revisão bibliográfica dos métodos de otimização PS, PSO e EPSO.
3. Aplicação dos métodos de otimização PS, PSO e EPSO ao modelo global não-linear de módulos FV no processo de estimação de parâmetros; e
4. Realização de um estudo comparativo dos resultados fornecidos pela aplicação das técnicas de otimização ao modelo global não-linear e as curvas experimentais do banco de dados da NREL.

1.2 ORGANIZAÇÃO DO TEXTO

- **Capítulo 2** – Neste capítulo é apresentado uma análise dos conceitos teóricos da geração solar e os aspectos característicos de um módulo fotovoltaico. O objetivo deste capítulo é apresentar o modelo global não-linear, destacando inicialmente os principais tópicos referentes ao processo de modelagem de módulos FV.
- **Capítulo 3** – Neste capítulo são apresentados os principais conceitos, definições e características dos métodos de otimização. O objetivo é abordar de forma detalhada os métodos de otimização baseado em metaheurística, que são aplicados neste trabalho para a estimação dos parâmetros de módulos FV.
- **Capítulo 4** - Neste capítulo é apresentado a metodologia do processo de estimação de parâmetros para circuito equivalente de um módulo FV para o modelo global não-linear. Em seguida, são mostrados os resultados da simulação dos métodos de otimização aplicados no processo de estimação dos parâmetros dos módulos de silício monocristalino, silício policristalino, silício amorfo, telureto de cádmio e disseleneto cobre, índio e gálio - CIGS. O objetivo deste capítulo é realizar um comparativo dos resultados obtidos com a aplicação dos diferentes métodos de otimização.
- **Capítulo 5** – Neste capítulo é apresentado a conclusão da dissertação assim como as propostas de desenvolvimento de trabalhos futuros.

2 ASPECTOS GERAIS SOBRE MÓDULOS FOTOVOLTAICOS

Este capítulo tem como objetivo realizar uma análise dos conceitos teóricos da geração solar FV e detalhar os aspectos característicos de um módulo FV. Primeiramente, é abordado o recurso solar de modo a entender o Sol como fonte de produção de energia. Em seguida, os principais aspectos dos módulos FV são discutidos, como as principais tecnologias, características elétricas, influência de parâmetros na geração solar FV, para enfim apresentar o modelo global não-linear para os módulos FV.

2.1 ASPECTOS GERAIS

O Sol é a principal fonte de energia do planeta Terra, pois basicamente todas as formas de energia no mundo são de origem solar. É a partir da energia do Sol que se dá a evaporação, origem do ciclo das águas, que possibilita o acúmulo em barragens e a consequente geração de eletricidade (hidroeletricidade). A radiação solar é responsável pela circulação atmosférica, que ocorre em razão do desequilíbrio da radiação recebida pela Terra, provocando assim os ventos. Logo a energia eólica e a energia maremotriz são formas indiretas de produção de energia solar. Petróleo, carvão e gás natural são originalmente produzidos por meio de resíduos de plantas e animais que através do recurso solar obtiveram energia para sua formação (CEPEL-CRESESB, 2014).

A energia do Sol é transmitida ao planeta Terra através do espaço sob a forma de radiação eletromagnética, recebendo o nome de radiação solar. Ela sofre a influência do ar atmosférico, das nuvens, das vegetações e da poluição, fazendo com que os raios solares cheguem de todas as direções ao atingir o solo, devido aos efeitos de absorção, espalhamento e reflexão com as moléculas de ar, vapor, poeira e nuvens.

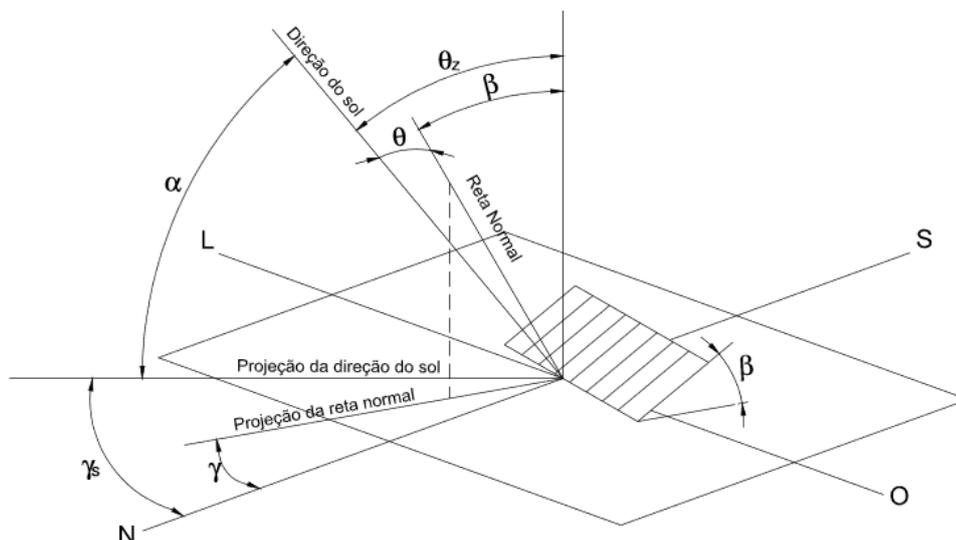
2.1.1 O Recurso Solar

De acordo com a norma ABNT-NBR-10899/2013, para compreender melhor o aproveitamento da energia solar para geração de energia, é necessário o conhecimento de algumas relações geométricas entre os raios solares e a superfície terrestre, mais especificamente sobre uma superfície inclinada qualquer. Essas relações são descritas através de vários ângulos

ilustrados na Figura 2 e definidos a seguir:

- Ângulo de incidência (θ): é o ângulo compreendido entre o raio solar e a normal (n) à superfície de captação;
- Altura solar (α): ângulo formado entre o raio solar e a sua projeção sobre o plano horizontal;
- Ângulo azimutal da Superfície (γ): ângulo compreendido entre a projeção da normal à superfície no plano horizontal e a direção Norte-Sul. O deslocamento angular é tomado a partir do Norte e está compreendido entre -180° e 180° , sendo considerado positivo quando a projeção se encontra à esquerda do Norte e negativo quando se encontra à sua direita;
- Ângulo azimutal do Sol (γ_s): ângulo formado entre a projeção do raio solar no plano horizontal e a direção Norte-Sul. Obedece à mesma convenção citada para o ângulo azimutal da superfície;
- Inclinação da superfície (β): ângulo formado entre o plano da superfície coletora e a horizontal;
- Ângulo zenital (θ_z): ângulo formado entre o raio solar e o Zênite; equivale à distância angular entre o feixe solar e a vertical do local de incidência.

Figura 2 – Indicação dos ângulos dos raios solares incidentes no plano inclinado.

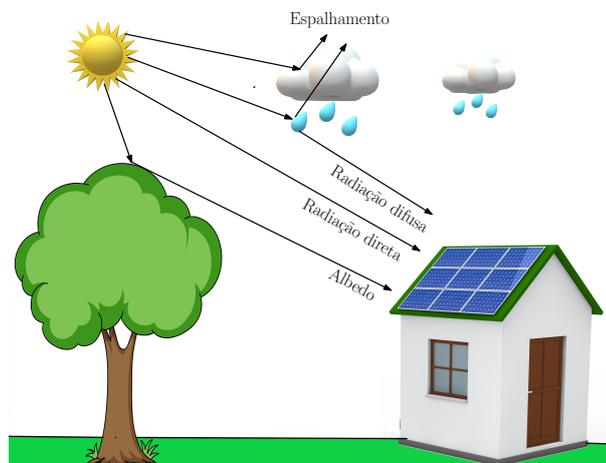


Fonte: NBR-10899/2013, Associação Brasileira de Normas Técnicas (ABNT)

A radiação solar incidente sobre uma superfície receptora, como por exemplo as células e módulos FV, pode ser decomposta por uma componente direta e por uma componente difusa. A radiação direta corresponde aos raios solares que chegam diretamente do Sol em linha reta e incidem sobre a superfície receptora com uma inclinação que depende do ângulo zenital do Sol. A radiação difusa corresponde aos raios solares que chegam indiretamente à superfície receptora, devido à difração na atmosfera e à reflexão da luz nas nuvens e em partículas no ar (VILLALVA, 2015). Uma terceira componente da radiação pode incidir sobre a superfície receptora, caso a mesma esteja inclinada em relação à horizontal, denominada de albedo, que ocorre em razão da reflexão no solo ou em outros elementos próximos no ambiente (vegetação, obstáculos, terrenos rochosos, etc.) (CEPEL-CRESESB, 2014).

As parcelas de radiação direta, difusa e albedo (caso a superfície seja inclinada) são representadas na Figura 3 por raios solares incidentes em uma superfície. A soma dessas parcelas é definida como radiação global.

Figura 3 – Componentes da radiação solar.



Fonte: Adaptado de (PINHO et al., 2008) e (FREEPIK, 2019)

A radiação global pode ser mensurada por um instrumento denominado piranômetro, ilustrado na Figura 4 (a), enquanto a radiação direta pode ser medida com um instrumento chamado pireliômetro, representado na Figura 4 (b). No mercado, existem também sensores baseados em células de silício que são utilizados em medidas da radiação solar, porém apresentam a desvantagem de não dissociarem as componentes de radiação direta e difusa.

A mensuração da radiação solar pode ser realizada por duas grandezas, uma em termos de fluxo de potência (W) por unidade de área (m^2) em um dado plano, onde temos a definição da irradiância solar (W/m^2), a outra em termos de energia (Wh) por unidade de área (m^2), sendo então definida a expressão irradiação solar (Wh/m^2).

Figura 4 – Instrumentos de medição da radiação solar: (a) piranômetro e (b) pireliômetro.



Fonte: (CEPEL-CRESESB, 2014)

O fluxo médio de irradiância, no espaço extraterrestre, na distância média entre o Sol e a Terra, é conhecido como constante solar, e o seu valor é de aproximadamente $1.367(\pm 3, 33\%)$ W/m^2 , adotado pela *World Radiation Center* (WRC). Na superfície terrestre, a parcela de radiação incidente é extremamente variável, isto ocorre devido ao movimento aparente do Sol, às modificações nas condições climáticas e à composição geral da atmosfera. Dessa forma, para a implantação de um projeto de sistema FV, tem-se a necessidade de dados de irradiância medidos em locais mais próximos possíveis daquele onde se pretende implantar o sistema (PINHO et al., 2008).

Conforme visto anteriormente, a radiação solar sofre diversas alterações quando atravessa a atmosfera terrestre. Um conceito que caracteriza o efeito da atmosfera sob a radiação solar é a “Massa de Ar” (AM, do inglês *Air Mass*), que é igual ao comprimento relativo que a radiação direta percorre através da atmosfera até atingir a superfície terrestre. A definição matemática é dada por:

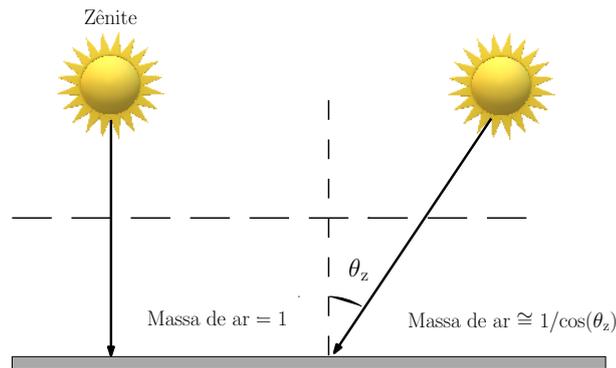
$$AM = \frac{1}{\cos(\theta_z)}, \quad (2.1)$$

e ilustrada na Figura 5, sendo θ_z ângulo zenital, ângulo formado entre o raio direto e o Zênite (PINHO et al., 2008).

Quando o Sol encontra-se no Zênite, $AM = 1$ e esta relação aumenta à medida que cresce o ângulo entre o feixe solar e a vertical. Assim, para um valor de θ_z de aproximadamente $48,2^\circ$, $AM = 1,5$, que é o valor considerado nas condições padrão de teste de células e módulos FV. Essa expressão é válida apenas para ângulos zenitais de 0° a 70° , pois para ângulos maiores, o efeito de curvatura da Terra torna-se significativo e deve ser considerado.

A irradiância de $1000 W/m^2$, massa de ar de 1,5 e $T = 25^\circ C$ são adotadas na indústria FV para a especificação e avaliação de células e módulos FV, sendo citadas praticamente na maioria dos catálogos de fabricantes e dispositivos FV, esses critérios caracterizam a *STC* (VILLALVA, 2015).

Figura 5 – Definição de Massar de Ar.

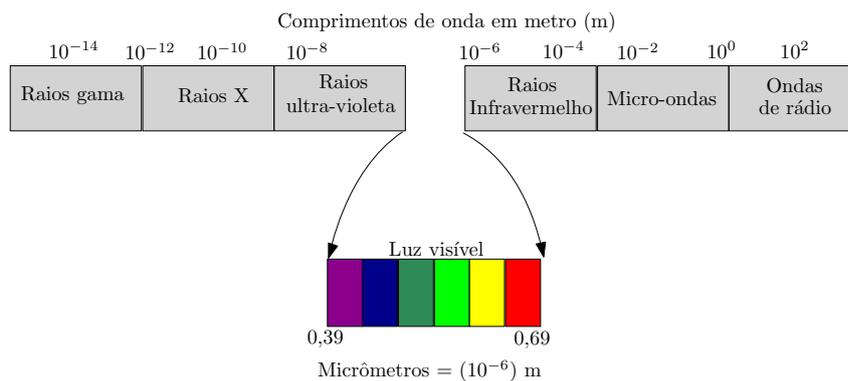


Fonte: (PINHO et al., 2008)

2.1.2 Espectro Solar

A radiação solar é constituída de ondas eletromagnéticas que possuem frequência e comprimento de ondas diferentes, conforme a representação da Figura 6. Uma pequena parte das ondas pode ser captada pelo olho humano e representa o que chamamos de luz visível. Outra parte da radiação solar não pode ser vista pelo olho humano e sua presença pode ser percebida de outra forma. O conjunto de todas as frequências de ondas eletromagnéticas emitidas pelo Sol é denominado de espectro da radiação (VILLALVA, 2015).

Figura 6 – Composição do espectro da radiação solar.

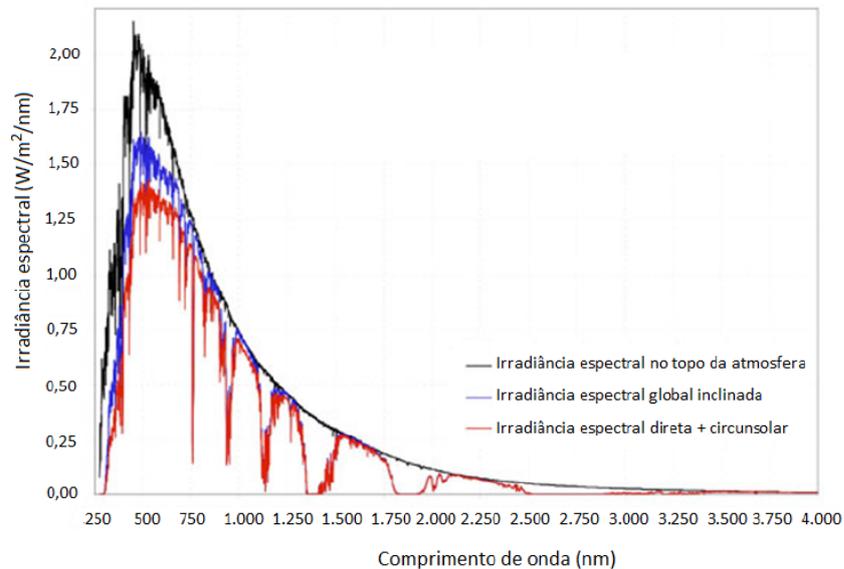


Fonte: (VILLALVA, 2015)

A Figura 7 mostra o espectro da irradiância solar em três condições: no topo da atmosfera da Terra ($AM = 0$); ao atingir perpendicularmente uma superfície ao nível do mar inclinada a 37° ($AM = 1,3$) e voltada para a linha do Equador (global inclinada); e após atravessar uma massa de ar de 1,5. De acordo com a Figura 7, nota-se as perdas de fluxo de potência entre o espectro da irradiância incidente no topo da atmosfera e o espectro que atinge a superfície

inclinada. O espectro solar típico na superfície terrestre em um dia claro em conjunto com a irradiância total de 1000 W/m^2 , $T = 25^\circ \text{ C}$ e $AM = 1,5$ são usados para realizar a calibração de células e módulos FV.

Figura 7 – Distribuição espectral da irradiância no topo da atmosfera; da irradiância ao incidir perpendicularmente sobre uma superfície inclinada (37°) ao nível do mar e voltada para a linha do Equador; da irradiância após atravessar uma massa de ar de 1,5.



Fonte: (CEPEL-CRESESB, 2014)

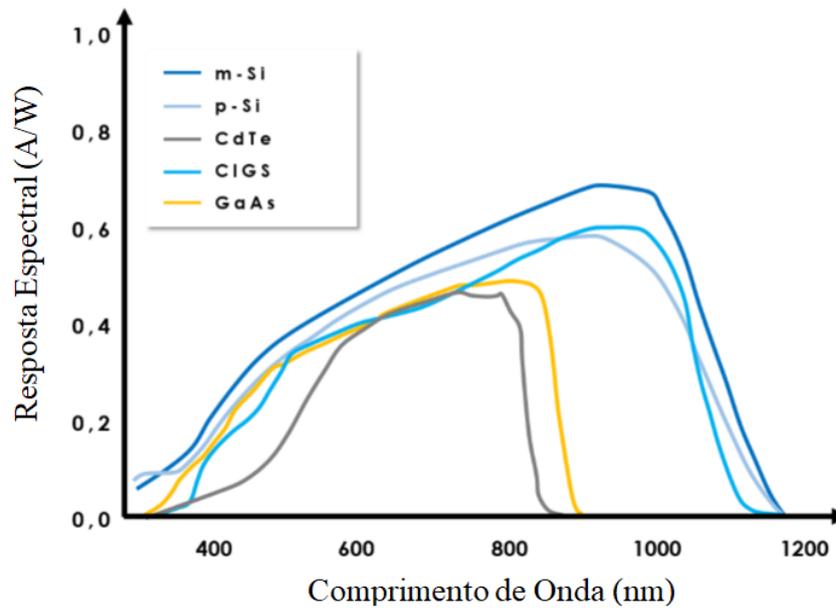
Portanto, a radiação que chega à superfície terrestre e, conseqüentemente, a energia disponível, varia segundo a sua posição incidente no planeta Terra e as características geográficas e meteorológicas locais (WANG et al., 2016).

A Resposta Espectral (RE) é definida como a razão entre a corrente produzida pelo dispositivo fotovoltaico e a potência da radiação que incide sobre ele. Ela descreve como que os fótons com diferentes comprimentos de onda (ou níveis de energia) contribuem para a corrente fotogerada. Conhecer a curva da Resposta Espectral é muito importante para a geração fotovoltaica, pois é através dela que se pode estimar o quanto que as variações do espectro solar irão afetar a energia elétrica gerada. Diferentes tecnologias de células solares possuem diferentes respostas espectrais (NEVES, 2016). Na Figura 8 são mostradas diversas curvas de respostas espectrais para algumas tecnologias de células FV.

2.1.3 Tipos de Células FV e Tecnologias de Fabricação

Existem diversas tecnologias de células e módulos FV no mercado atualmente, utilizando diferentes tipos de materiais. As principais tecnologias aplicadas na produção de células e

Figura 8 – Respostas espectrais para diferentes tecnologias de células FV.



Fonte: (NEVES, 2016)

módulos FV são classificadas em três gerações, conforme a matéria-prima e o nível de aceitação comercial.

- A primeira geração que é caracterizada pela utilização da tecnologia do silício cristalino (c-Si), no qual é dividida em duas categorias produtivas: silício monocristalino (m-Si) e silício policristalino (p-Si), que são as mais comuns encontradas no mercado, por ser considerada uma tecnologia consolidada e confiável, e por possuir melhor eficiência comercialmente disponível (CEPEL-CRESESB, 2014; LIMA et al., 2020);
- A segunda geração, comercialmente denominada filmes finos, é dividida em três categorias produtivas: silício amorfo (a-Si), disseleneto de cobre e índio (CIS) ou disseleneto de cobre, índio e gálio (CIGS) e telureto de cádmio (CdTe). Esta geração apresenta uma menor eficiência do que a primeira geração e tem uma menor participação no mercado. Uma das desvantagens associadas a sua aplicação está na disponibilidade dos materiais, como exemplo o caso do cádmio (Cd), em que sua toxicidade retardam sua utilização em maior escala (CEPEL-CRESESB, 2014; LIMA et al., 2020);
- A terceira geração de células solares compreende as novas tecnologias. Nesta geração, tem-se uma variedade de tipos de células constituídas à base de materiais orgânicos ou poliméricos (*Organic Photovoltaics* (OPV)), corantes (*Dye-Sensitized Solar Cell* (DSSC)), pontos quânticos ou perovskitas, células multi-junção, células de portadores

quentes e tecnologias de upconversion (RAPHAEL et al., 2018; CEPPEL-CRESESB, 2014; LIMA et al., 2020).

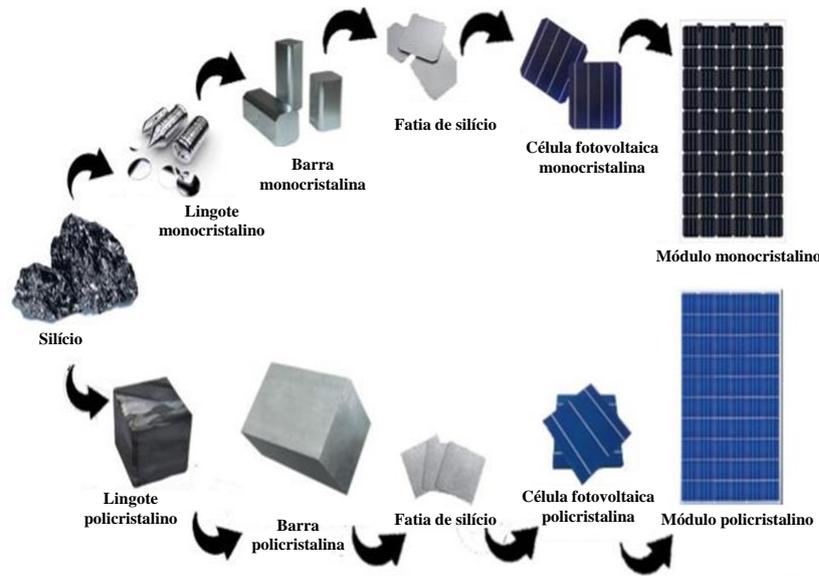
A seguir, são apresentadas brevemente, as principais tecnologias comercialmente disponíveis de células FV.

Células de Silício Monocristalino: O silício utilizado no processo de fabricação de células FV é extraído do mineral quartzo (VILLALVA, 2015). O silício monocristalino possui uma estrutura homogênea em todo o sólido, é obtido na maioria das vezes, pelo processo denominado de método de *Czochralski*, no qual blocos de silício puro são aquecidos em alta temperatura e submetidos a um processo de formação de cristal. O silício obtido nesse processo para funcionar como célula solar necessita de outros elementos semicondutores, logo as lâminas são fatiadas e submetidas a processos químicos (dopagem), formando as camadas P e N (SAMPAIO et al., 2019). Comercialmente, de acordo com os resultados divulgados pelo Instituto Nacional de Metrologia, Qualidade e Tecnologia (INMETRO) a eficiência média dos dispositivos com células solares de silício monocristalino é de 15,7% e a maior eficiência registrada é da ordem de 20% (ARAÚJO et al., 2018; INMETRO, 2018).

Células de Silício Policristalino ou Multicristalino: O processo de fabricação de células policristalinas é semelhante a de fabricação das células monocristalinas, porém com um menor custo, devido as exigências do processo de preparação das células serem menos rigorosas (SILVA, 2015). São constituídas de diversos cristais em contato entre si, com tamanhos e orientações diferentes, onde este procedimento tem por objetivo reduzir custos de fabricação, embora haja uma pequena perda de eficiência (PINHO et al., 2008). Geralmente, o silício policristalino é fornecido em forma de barras com 1,5 a 2,5 m de comprimento, que posteriormente são cortados para serem transformados em células FV (SAMPAIO et al., 2019). O rendimento médio das células de silício policristalino avaliadas pelo INMETRO é da ordem de 15,3 % e a maior eficiência registrada é de 19% (ARAÚJO et al., 2018; INMETRO, 2018). Na Figura 9, é apresentado simplificadamente o processo de fabricação dos módulos FV de silício.

Células de Silício Amorfo: Estas células são produzidas com silício que contém alto grau de desordem na sua estrutura atômica. Em seu processo de fabricação, utilizam-se filmes muito finos. Na produção das células, não existe a etapa de corte, elas são fabricadas na forma de fitas, conforme apresentado na Figura 10. Essas células possuem baixo custo de produção quando comparadas às células anteriores. Os filmes finos obtidos são depositados sobre substratos de baixo custo, como vidro ou aço inox (SAMPAIO et al., 2019). Esta propriedade permitiu que

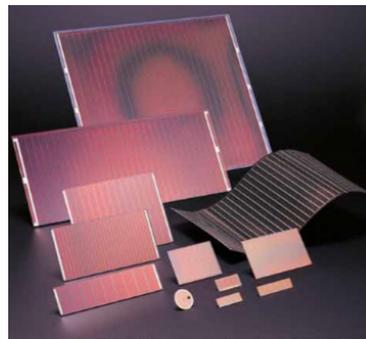
Figura 9 – Módulos FV fabricados com células de silício Monocristalino e Policristalino.



Fonte: (GONÇALVES, 2019)

os módulos ganhassem flexibilidade, semitransparência e superfícies curvas. Os módulos de silício amorfo apresentam eficiência reduzida, quando comparada aos dispositivos cristalinos, com valor comercial na faixa de 6-13%, sendo sua aplicação geralmente limitada a dispositivos de baixa potência (OGBOMO et al., 2016). Sua eficiência diminui durante os primeiros 6 a 12 meses de funcionamento, devido à degradação induzida pela luz até chegar a um valor estável (VILLALVA, 2015).

Figura 10 – Células fotovoltaicas de silício amorfo.

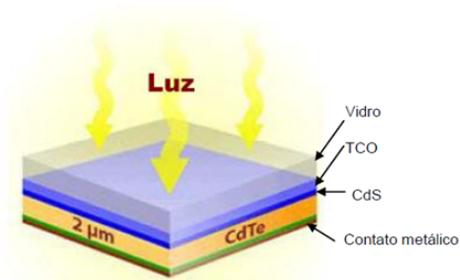


Fonte: (SANYO, 2019)

Células de Telureto de Cádmio (CdTe): São compostas por arranjos policristalinos de filmes finos. Uma célula típica de CdTe é produzida com cinco camadas: uma camada de vidro, um óxido transparente condutivo, que atua como contato frontal, um filme de CdS (sulfeto de cádmio) conhecido como camada de janela, um filme de CdTe conhecido como a camada

absorvedora e um contato traseiro que fica sobre o CdTe (LIMA, 2010). Esta tecnologia é pouco utilizada e possui a desvantagem do elemento químico cádmio, empregado na fabricação, ser tóxico e o elemento telúrio ter poucas reservas de minério na Terra (CEPEL-CRESESB, 2014). As células de CdTe representam cerca de 40% do mercado das células FV de filmes finos e apenas 6% do mercado de todas as tecnologias das células FV. Seu rendimento máximo pode alcançar até 21% (OGBOMO et al., 2016). Na Figura 11, é mostrado a estrutura de uma célula de CdTe.

Figura 11 – Estrutura de uma célula solar de CdS/CdTe.



Fonte: (LIMA, 2010)

Células de Disseleneto de Cobre, Gálio e Índio (CIGS): são compostas por um material policristalino e pertencem a família das células de filmes finos. As células FV baseadas no disseleneto de cobre e índio (CuInSe_2 , ou simplesmente CIS) e no disseleneto de cobre, gálio e índio (Cu(InGa)Se_2 , ou simplesmente CIGS) apresentam estruturas bastante semelhantes às do telureto de cádmio, em que a composição das células é feita com várias camadas ultra finas de diferentes semicondutores (SILVA, 2015). A célula é composta por: uma camada de vidro, uma fina camada de contato utilizando o elemento químico molibdênio (Mo), um filme de 50 nm de CdS (sulfeto de cádmio) que constitui a região n, uma camada de absorção de 100 nm de Cu(InGa)Se_2 que constitui a região p e duas camadas de ZnO (Óxido de Zinco) para aumentar a condutância (CEPEL-CRESESB, 2014). Apresentam eficiência máxima registrada na faixa de 20% (OGBOMO et al., 2016). Entretanto, seu custo é muito elevado e sua aceitação comercial ainda é pequena (VILLALVA, 2015). Uma das aplicações das células de CIGS, como mostrado na Figura 12, é na formação de módulos FV em formato de telhas, conhecidos como telhado solar.

Células Multijunção: essa tecnologia utiliza várias junções *P-N* conectadas em série para formar uma FV, empilhando diferentes camadas de materiais semicondutores. Os materiais mais comuns utilizados na sua composição são: arseneto de gálio (GaAs), silício amorfo (a-Si), silício microcristalino e germânio (Ge). A junção *P-N* de cada material semicondutor

Figura 12 – Módulo FV (telhado solar) formado por células de CIGS.



Fonte: (DHGATE.COM, 2019)

Tabela 1 – Rendimento das melhores células FV produzidas em laboratório até 2019.

Classificação	Tecnologia	Rendimento (%)
Silício	Silício Monocristalino (m-Si)	26,7 ± 0,5
	Silício Policristalino (p-Si)	22,3 ± 0,4
	Filmes Finos Transferidos	21,2 ± 0,4
Compostos III-A	GaAs (filme fino)	29,1 ± 0,6
	GaAs (policristalino)	18,4 ± 0,5
Filmes Finos	CIGS (filme fino)	23,35 ± 0,5
	CdTe (filme fino)	21,0 ± 0,4
Amorfo	Silício Amorfo (a-Si) (filme fino)	10,2 ± 0,3
Multijunção	GaAs/InP	32,8 ± 1,4
	(InGaP/GaAs/InGaAs)	37,9 ± 1,2

Fonte:(GREEN et al., 2019)

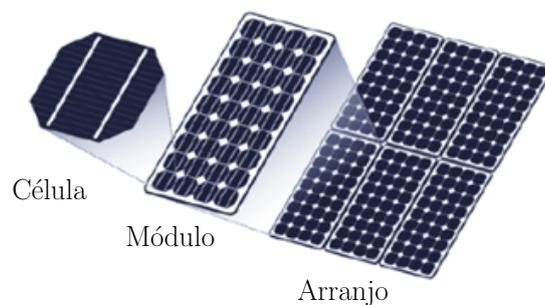
produz uma corrente elétrica em resposta a diferentes comprimentos de onda da luz, então as células multijunções possuem a característica de possuírem grande sensibilidade espectral (NÚÑEZ et al., 2018). A ideia fundamental para aplicação de células FV multijunção é melhorar a eficiência na conversão de energia solar em elétrica, otimizando a absorção de luz e a geração de corrente em cada junção (CORREIA, 2018).

O progresso da eficiência das células FV é acompanhado pela "*Progress in Photovoltaic*"(GREEN et al., 2019) desde o ano de 1993. Na Tabela 1, é apresentado o rendimento das melhores células FV com diferentes tecnologias até o ano de 2019 fabricadas em laboratórios.

2.2 ASSOCIAÇÕES DE CÉLULAS E MÓDULOS FOTOVOLTAICOS

Como visto anteriormente, a célula FV é o dispositivo básico da transformação da luz em eletricidade. Dado que uma célula produz pouca eletricidade, logo várias células são montadas sobre uma estrutura rígida, associadas eletricamente e revestidas para formar o módulo FV (Figura 13). Um módulo pode ser constituído geralmente de 36 a 216 células FV associadas em série e/ou paralelo, associação esta que depende dos parâmetros elétricos (tensão, corrente e potência) mais adequados à aplicação a que o módulo se destina (CEPEL-CRESESB, 2014).

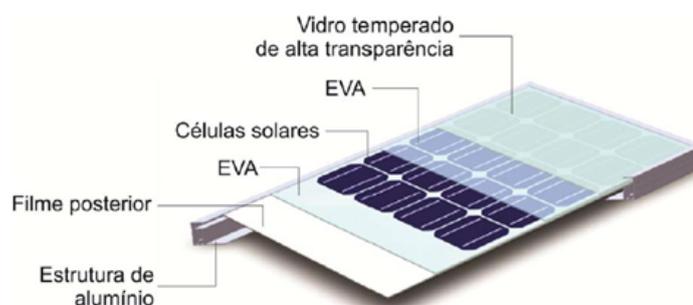
Figura 13 – Células, módulos e arranjos FV.



Fonte: (BEATRIZ et al., 2011)

A estrutura de um módulo FV comercial (Figura 14) de células de silício cristalino é constituída por camadas de vidro temperado de alta transparência, acetato de etil vinila (EVA, do inglês *Ethylene-Vinyl Acetate*), células fotovoltaicas, EVA e um filme isolante.

Figura 14 – Estrutura dos componentes de um módulo fotovoltaico de silício cristalino



Fonte: (CEPEL-CRESESB, 2014).

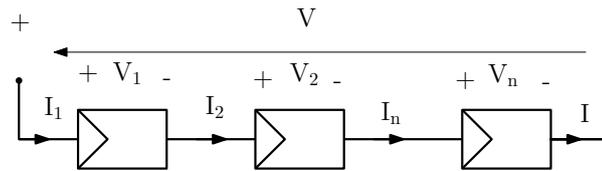
Na composição da estrutura do módulo FV, as células ligadas em série conectam o terminal positivo de uma célula com o negativo da célula seguinte. De acordo com a Figura 15, tem-se

que:

$$V = V_1 + V_2 + V_n, \quad (2.2)$$

onde V é a tensão do módulo e V_1, V_2, \dots, V_n são as tensões das células que compõem o módulo FV.

Figura 15 – Células FV ligadas em série na composição do módulo



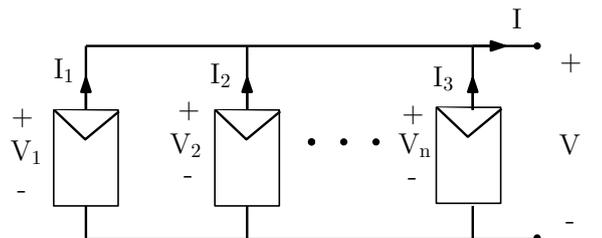
Fonte: O autor (2020)

As células ligadas em paralelo, tem os seus terminais positivos interligados entre si, assim como os terminais negativos. Portanto, o valor da corrente elétrica I fornecida pelo módulo é a soma das correntes de cada célula conectada em paralelo. Da Figura 16, tem-se que:

$$I = I_1 + I_2 + I_n \quad (2.3)$$

onde I_1, I_2, \dots, I_n são as correntes das células ligadas em paralelo que compõem o módulo FV.

Figura 16 – Células FV ligadas em paralelo na composição do módulo.



Fonte: O autor (2020)

2.3 CARACTERÍSTICAS ELÉTRICAS DE MÓDULOS FOTOVOLTAICOS

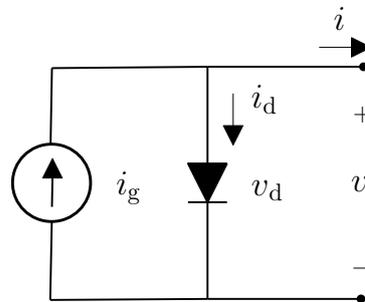
Em estudos de engenharia, uma prática bastante comum é a aplicação de modelos matemáticos para descrever o comportamento de um sistema. A modelagem matemática e a representação através de circuitos elétricos das células FV são ferramentas bastante úteis para o cálculo dos parâmetros desconhecidos e na determinação do comportamento de uma célula/módulo perante as mudanças ambientais. Nos últimos anos, o interesse em pesquisas na

área de modelagem de sistemas de energia solar FV aumentou significativamente de forma a melhorar sua utilização para atender as crescentes demanda de energia elétrica.

2.3.1 Análise do Circuito Equivalente para Módulos Fotovoltaicos

A célula FV é um dispositivo capaz de capturar e converter diretamente a energia da luz solar em eletricidade, no processo que é denominado de conversão FV. A Figura 17 mostra o circuito elétrico representativo simplificado de uma célula FV ideal. Este modelo é geralmente preferido para estudos em relação a outros modelos, como o de dois diodos, devido à sua simplicidade na análise, menor número de parâmetros e menor complexidade computacional (MEHTA et al., 2019). Já a aplicação do modelo com dois diodos é bastante útil quando deseja-se representar mais precisamente a junção p-n, pois o fenômeno da recombinação dos portadores de carga que ocorre nesta junção não é adequadamente representado nas aplicações com um diodo (JUNIOR, 2018). Em razão disso, o modelo de dois diodos é mais preciso na representação de célula/módulo FV.

Figura 17 – Circuito equivalente de uma célula FV ideal.



Fonte: O autor (2020)

No circuito elétrico da célula FV da Figura 17, uma fonte de corrente é usada para representar a corrente gerada pela radiação solar (fótons) e um diodo semicondutor conectado em antiparalelo a essa fonte a junção p-n (célula). Então, na condição de temperatura e irradiância fixas, a expressão da corrente elétrica fornecida por uma célula FV pode ser representada pela soma das correntes (SILVA, 2019):

$$i = i_g - i_d, \quad (2.4)$$

sendo:

- i – Corrente de saída da célula FV (em A);

- i_g - Corrente fotogerada da célula (em A);
- i_d - Corrente na junção p-n, representada pelo diodo (em A).

A corrente do diodo (i_d) pode ser determinada pela equação de *Shockley*, que neste caso é dada por:

$$i_d = i_{\text{sat}} \left(e^{\frac{qv_d}{AkT}} - 1 \right) \quad (2.5)$$

em que:

- i_{sat} - Corrente de saturação reversa do diodo (em A);
- v_d - Tensão no diodo (em V);
- A - Fator de idealidade do diodo;
- q - Carga do elétron (em C);
- k - Constante de Boltzmann (em $m^2 \cdot kg \cdot s^{-2} \cdot K^{-1}$);
- T - Temperatura (em K).

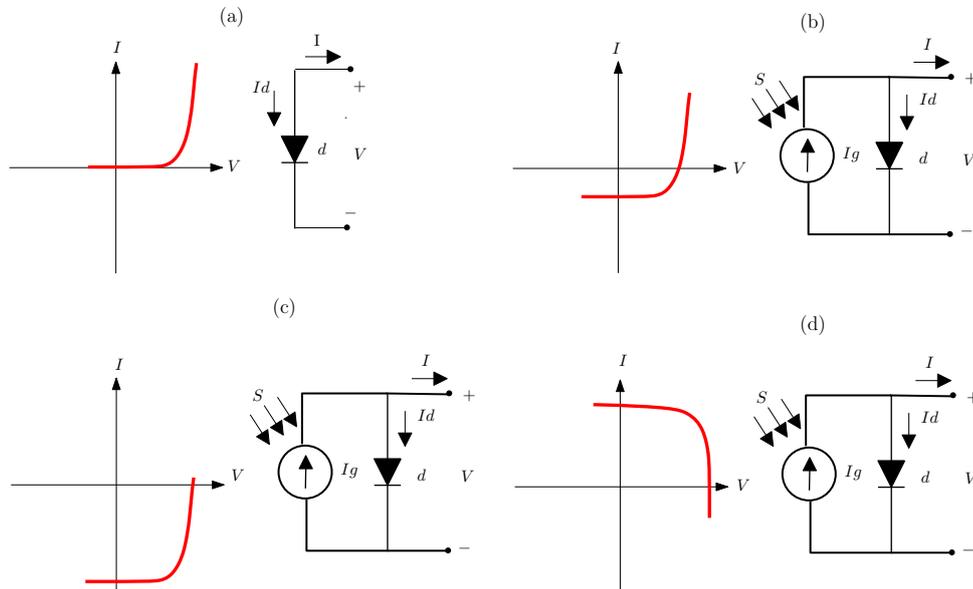
Através da Figura 17 e da Equação (2.4), reproduz-se a curva $I-V$ de uma célula FV, que é a resultante da superposição da corrente fotogerada com a curva do diodo no escuro. A luz tem o efeito de deslocar a curva $I-V$ para o quarto quadrante. A Figura 18 apresenta as curvas de uma célula FV sob diversas condições de iluminação, sendo que a curva da Figura 18-(d) mostra a curva $I-V$ sob a forma mais comumente encontrada, rebatida sobre o eixo das tensões.

Quando fatores que limitam a eficiência de conversão de uma célula FV são levados em consideração, no circuito elétrico equivalente são, então, acrescentadas as resistências série (r_s) e paralela (r_p) como mostrado na Figura 19. Para o modelo de uma célula ideal, os valores das resistências r_s e r_p são assumidos como zero e infinito respectivamente. A resistência série corresponde as perdas nas junções metal-semicondutor e a resistência em paralelo corresponde às fugas de corrente na junção p-n.

Neste caso, a equação que representa a corrente total produzida por uma célula FV pode ser expressa como:

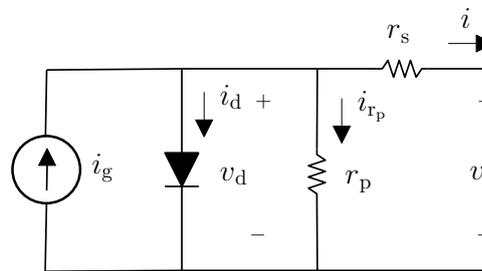
$$i = i_g - i_d - i_{r_p}. \quad (2.6)$$

Figura 18 – Uma célula fotovoltaica sob diversas condições de iluminação: (a) célula FV com as mesmas características elétricas de um diodo no escuro. (b) quando a célula FV é iluminada, sua curva I - V se desloca para o 4º quadrante. (c) quanto maior a intensidade da radiação incidente, maior o deslocamento da curva I - V . (d) a curva é então representada, por convenção, através da rotação em relação ao eixo das tensões, sendo representada no 1º quadrante.



Fonte: (PRIEB, 2002)

Figura 19 – Circuito equivalente de um diodo de uma célula solar com as resistências série e paralelo.



Fonte: O autor (2020)

Em uma breve análise do circuito equivalente da Figura 19, nota-se que:

$$v_d = v + ir_s \quad (2.7)$$

e

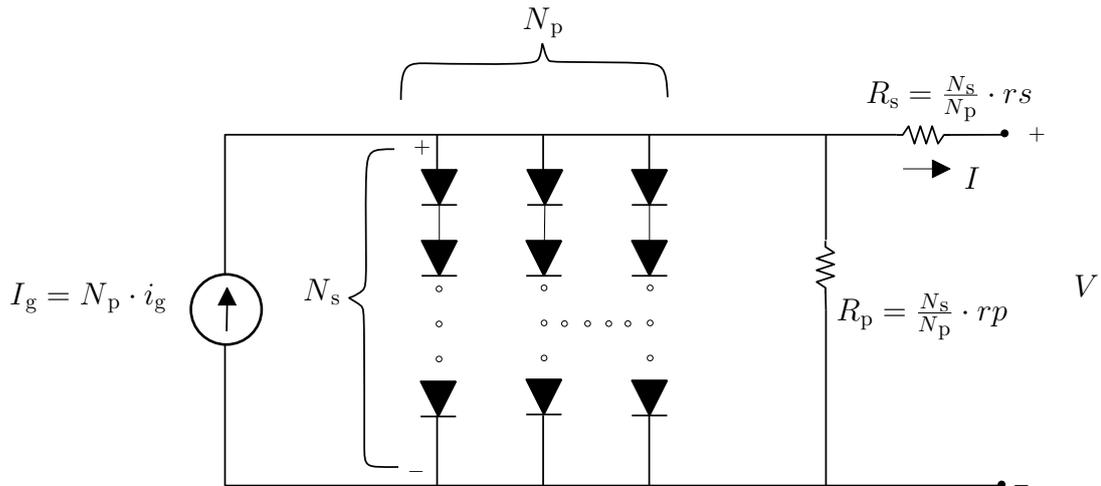
$$i_{r_p} = \frac{v + ir_s}{r_p}, \quad (2.8)$$

Logo, substituindo os termos das equações (2.5), (2.7) e (2.8) na equação (2.6), tem-se que:

$$i = i_g - i_{\text{sat}} \left(e^{\frac{q(v+ir_s)}{AkT}} - 1 \right) - \frac{v + ir_s}{r_p}. \quad (2.9)$$

Como visto anteriormente, as células solares são associadas para formar os módulos FV, onde são conectadas em série para fornecer tensões de saída maiores e em paralelo para obter

Figura 20 – Circuito equivalente de um módulo FV.



Fonte: O autor (2020)

maiores correntes de saída. Os módulos FV são associações de células, e pode-se representar o seu circuito equivalente de forma análoga ao da célula como na Figura 20. Considera-se que todas as células sejam iguais de um módulo com N_s células em série, N_p células em paralelo e sendo V_t , a tensão térmica do módulo FV, definida por:

$$V_t = \frac{N_s A k T}{q}, \quad (2.10)$$

a equação da corrente para um módulo FV pode ser reescrita como

$$I = I_g - I_{\text{sat}} \left(e^{\frac{V + I R_s}{V_t}} - 1 \right) - \frac{V + I R_s}{R_p}, \quad (2.11)$$

em que:

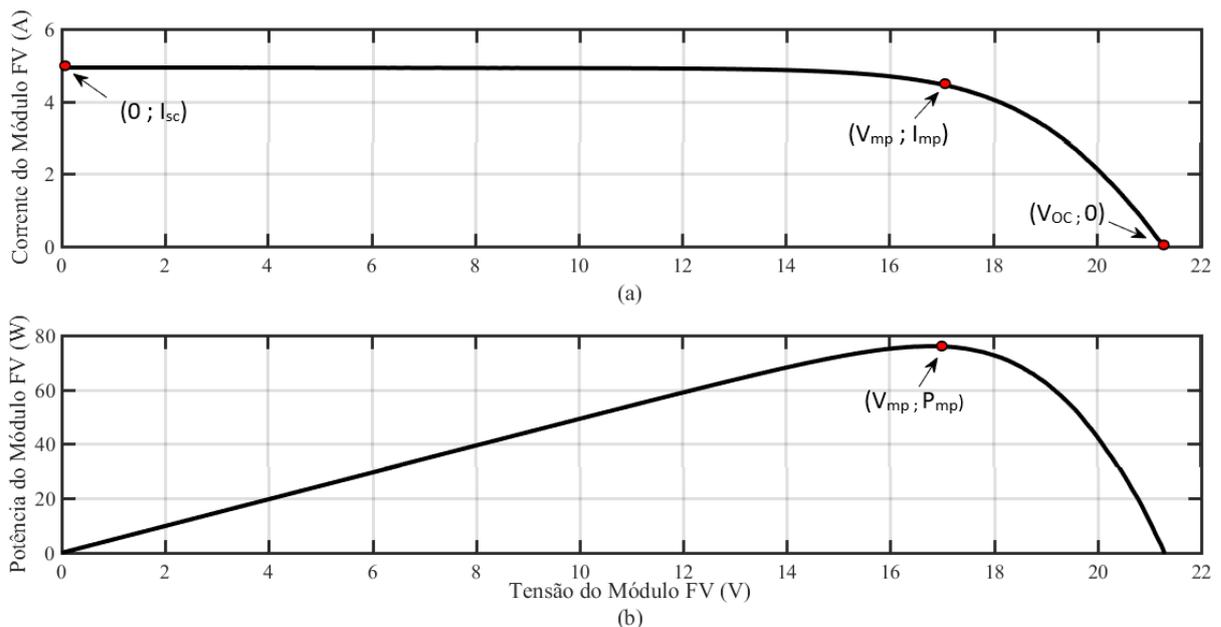
- I – Corrente de saída do módulo FV (em A);
- I_g - Corrente fotogerada do módulo FV(em A);
- I_{sat} - Corrente reversa de saturação do diodo do módulo FV (em A);
- V_t – Tensão térmica do módulo FV (em V);
- V – Tensão de saída do módulo FV (em V);
- R_s - Resistência série do módulo FV (em Ω);
- R_p - Resistência em paralelo ou resistência shunt do módulo FV (em Ω).

Neste trabalho, todas as análises tiveram como foco a modelagem do módulo FV e não das células. Além disso, todos os módulos FV avaliados são compostos por associações de células apenas em série, desconsiderando assim qualquer termo referente à associação em paralelo.

2.3.2 Curvas Características: Corrente versus Tensão ($I-V$) e Potência versus Tensão ($P-V$)

A equação (2.11) é também conhecida como equação da curva característica de um dispositivo FV, pois a partir dela podemos representar as curvas características típicas corrente versus tensão ($I-V$) e potência versus tensão ($P-V$) que é obtida pela multiplicação de cada valor de tensão pelo correspondente valor de corrente de uma célula, módulo ou arranjo. Para uma análise mais detalhada, apresenta-se, na Figura 21, as curvas características para o módulo fotovoltaico xSi11246 (silício monocristalino) do banco de dados da (NREL, 2014) que possui 36 células em série e nenhuma associação em paralelo. Os principais parâmetros elétricos destacados são: a corrente elétrica de curto-circuito (I_{sc}), a tensão de circuito aberto (V_{oc}), a potência máxima ou de pico (P_{mp}), a corrente no ponto de potência máxima (I_{mp}) e a tensão no ponto de potência máxima (V_{mp}).

Figura 21 – Curvas características de um módulo FV: (a) corrente versus tensão; (b) potência versus tensão para o módulo xSi11246.



Fonte: O autor (2020)

Na Figura 21(a), nota-se que a corrente de saída do módulo é aproximadamente constante

até valores anteriores a V_{mp} , a partir de onde a corrente do diodo (I_d) torna-se significativa, e conseqüentemente, provoca uma redução na corrente de saída do módulo. Na condição de circuito aberto (V_{oc}), toda a corrente foto gerada está passando através do diodo e da resistência em paralelo, R_p . Enquanto na Figura 21(b), a potência varia com a tensão, atingindo um valor máximo (P_{mp}) na região do joelho da curva $I-V$, correspondendo aos pontos I_{mp} e V_{mp} . As características elétricas dos módulos FV, fornecidas pelos fabricantes, são baseadas na *STC*: irradiância de 1000 W/m^2 , temperatura da célula de $25 \text{ }^\circ\text{C}$ e massa de ar (*AM*) igual a 1,5.

Idealmente, os geradores solares deveriam sempre operar no ponto de máxima potência; entretanto, na prática, eles operam em um ponto sobre a curva $I-V$ correspondente às características $I-V$ da carga.

2.3.3 Definição dos Parâmetros Elétricos

As curvas características $I-V$ e $P-V$ são importantes para a caracterização dos dispositivos FV, pois elas transmitem informações sobre o seu desempenho elétrico. A partir dessas curvas, podem ser determinados os principais parâmetros elétricos que caracterizam as células/módulos FV: tensão de circuito aberto (V_{oc}), corrente de curto-circuito (I_{sc}), fator de forma (*FF*) e eficiência (η), descritos a seguir.

Corrente de curto-circuito (I_{sc}): é a corrente de saída de um módulo FV, na condição de curto-circuito em seus terminais e para valores preestabelecidos de temperatura e irradiância. De acordo com o estado de curto-circuito mostrado no circuito equivalente da Figura 22 e através da avaliação da equação (2.11), a corrente de curto-circuito é expressa por:

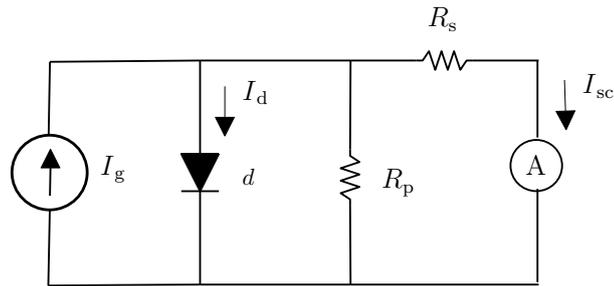
$$I_{sc} = I_g - I_{sat} \cdot \left[e^{\frac{(R_s \cdot I_{sc})}{V_t}} - 1 \right] - \frac{I_{sc} \cdot R_s}{R_p}. \quad (2.12)$$

Na condição de curto-circuito, o valor de I_{sc} é muito maior do que a soma das correntes que fluem através do diodo e de R_p , de modo que esses termos podem ser desprezados, e resultando na seguinte aproximação

$$I_{sc} \approx I_g. \quad (2.13)$$

Tensão de circuito aberto (V_{oc}): é a tensão gerada através de um módulo FV sem carga (em aberto), para valores pré-estabelecidos de temperatura e irradiância. Nesse caso, a

Figura 22 – Condição de curto-circuito de um módulo fotovoltaico



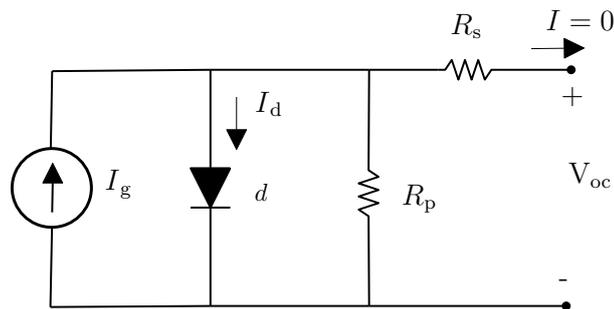
Fonte: O autor (2020)

Figura 23 ilustra a situação no circuito equivalente e de acordo com equação (2.11), tem-se:

$$I = 0 = I_g - I_{\text{sat}} \cdot \left(e^{\frac{V_{\text{oc}}}{V_t}} - 1 \right) - \frac{V_{\text{oc}}}{R_p}. \quad (2.14)$$

Considerando que o último termo da equação (2.14) é aproximadamente zero, encontra-se a seguinte expressão para V_{oc} :

Figura 23 – Condição de circuito aberto de um módulo FV.



Fonte: O autor (2020)

$$V_{\text{oc}} = V_t \cdot \ln\left(1 + \frac{I_g}{I_{\text{sat}}}\right). \quad (2.15)$$

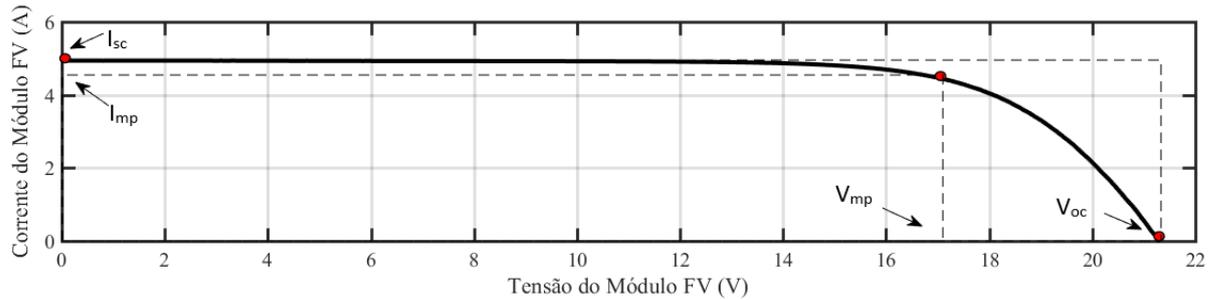
Logo, a tensão de circuito aberto depende da corrente de saturação, da corrente fotogerada e da temperatura. Por depender da corrente de saturação, a tensão de circuito aberto está relacionada com a recombinação dos portadores de carga minoritários no dispositivo. O valor de V_{oc} varia conforme a tecnologia utilizada nas células: c-Si (0,5 – 0,7 V), CdTe (0,857 V), a-Si (0,866 V), InGaP/GaAs/InGaAs (3,014 V) (CEPEL-CRESESB, 2014).

Fator de Forma (FF): é a razão entre a máxima potência (P_{mp}) do módulo FV e o produto da corrente de curto circuito (I_{sc}) com a tensão de circuito aberto (V_{oc}) relativos a mesma curva característica. Especificando em termos percentuais, tem-se que:

$$FF(\%) = \frac{P_{\text{mp}}}{V_{\text{oc}} \cdot I_{\text{sc}}} \cdot 100\%. \quad (2.16)$$

A definição de FF está representada graficamente na Figura 24, como a razão dos dois retângulos destacados. Quanto maior o fator de forma, mais próximo de um retângulo a curva será e, conseqüentemente, maior será a sua área. O fator de forma assume valores sempre menores que a unidade. Quanto menores forem as perdas resistivas série e paralelo, mais próxima da forma retangular será a curva I - V .

Figura 24 – Definição gráfica do fator de forma.



Fonte: O autor (2020)

Eficiência (η): é o parâmetro que mede o processo de conversão da energia solar incidente em um dispositivo FV em energia elétrica, ou seja, é definido pela relação entre a potência elétrica máxima produzida pelo dispositivo FV e a potência da energia solar incidente, onde esta é obtida pelo produto entre a área total do módulo FV (A_{MF}) e a irradiância total (S). Em termos percentuais a eficiência é calculada por:

$$\eta(\%) = \frac{P_{mp}}{P_{in}} \cdot 100\% = \frac{V_{mp} \cdot I_{mp}}{A_{MF} \cdot S} \cdot 100\%. \quad (2.17)$$

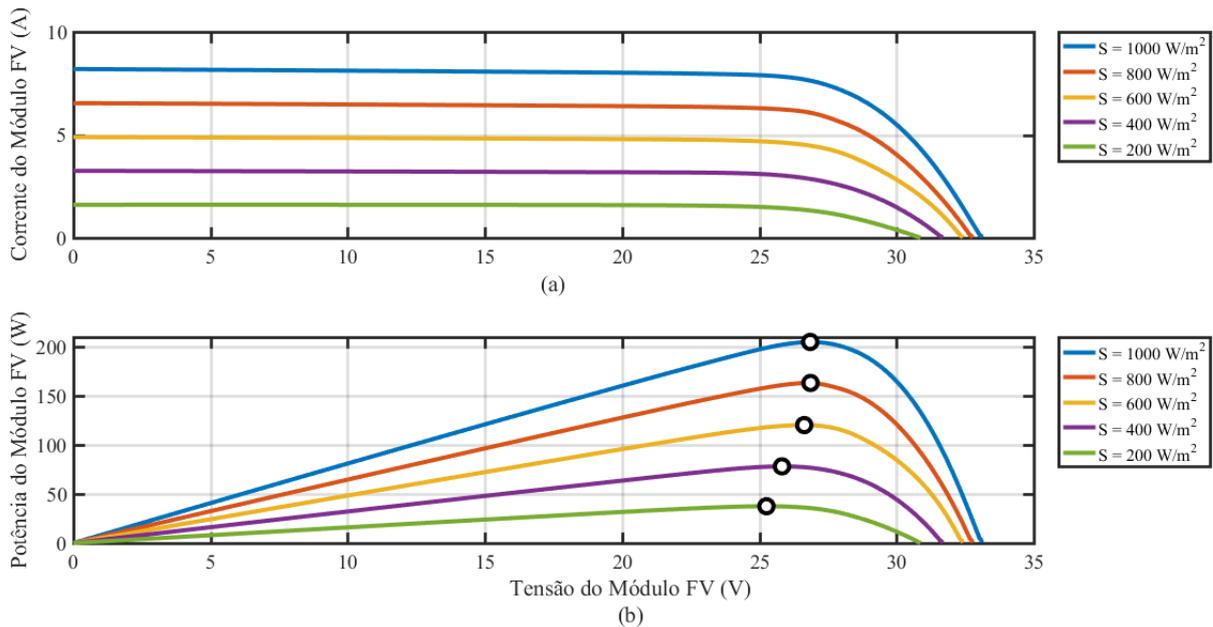
2.4 PARÂMETROS EXTERNOS QUE INFLUENCIAM AS CARACTERÍSTICAS ELÉTRICAS

As características elétricas dos módulos FV são influenciadas diretamente pela irradiância incidente e pelas variações de temperatura no ambiente.

2.4.1 Irradiância

Na Figura 25, pode-se observar como a irradiância solar incidente influencia as curvas I - V e P - V e, conseqüentemente, nas características do módulo FV KC200GT do fabricante (KYOCERA, 2019), medidas sob iluminação natural, correspondentes à temperatura de 25 °C.

Figura 25 – Comportamento das curvas (a) corrente versus tensão ($I-V$) e (b) potência versus tensão ($P-V$) de acordo com a variação da irradiância.



Fonte: O autor (2020)

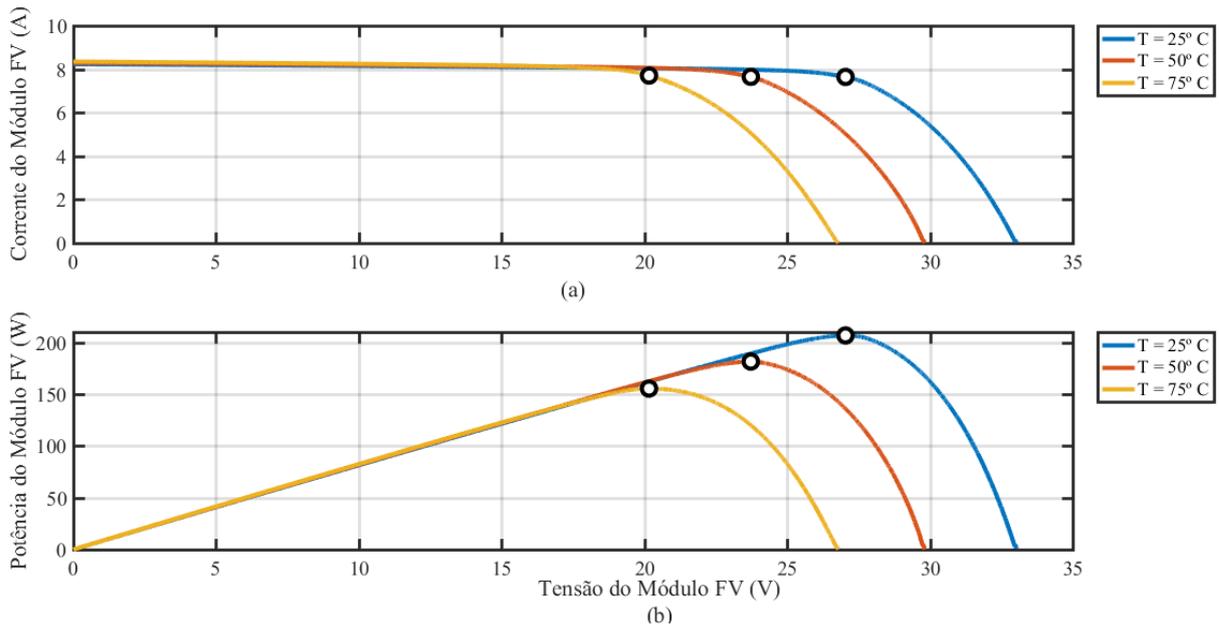
Nota-se que a elevação da irradiância provoca consequentemente o aumento da corrente fotogerada e potência máxima do módulo. Observa-se também uma elevação discreta na tensão de máxima potência e tensão de circuito aberto (SILVA, 2015; JUNIOR, 2018).

2.4.2 Temperatura

Um aumento de temperatura no ambiente acarreta em um aumento de temperatura do módulo, de modo que se verifica uma tendência de redução do seu ponto de máxima potência. Isso ocorre devido ao fato de que a tensão no módulo diminui de modo considerável com o aumento da temperatura, ao passo que a corrente fotogerada apresenta uma elevação muito pequena. O efeito da temperatura nas características elétricas dos módulos é avaliado através dos coeficientes de variação da corrente de curto-circuito com a temperatura (α_i) e de variação da tensão de circuito aberto com a temperatura (β_T). Cada célula de módulo FV de silício cristalino apresentam para α_i valores típicos na ordem de $0,03 \text{ mA}/^\circ\text{C}$, enquanto para β_T valores na ordem de $-2,3 \text{ mV}/^\circ\text{C}$ (JUNIOR, 2018).

Na Figura 26, observa-se o comportamento das curvas $I-V$ e $P-V$ para o módulo FV KC200GT do fabricante (KYOCERA, 2019), no estado de irradiância constante de $1000 \text{ W}/\text{m}^2$ e com variações de temperatura. Nota-se, então, o comportamento relatado, em que os valores

Figura 26 – Comportamento das curvas (a) corrente versus tensão ($I-V$) e (b) potência versus tensão ($P-V$) de acordo com a variação da temperatura.



Fonte: O autor (2020)

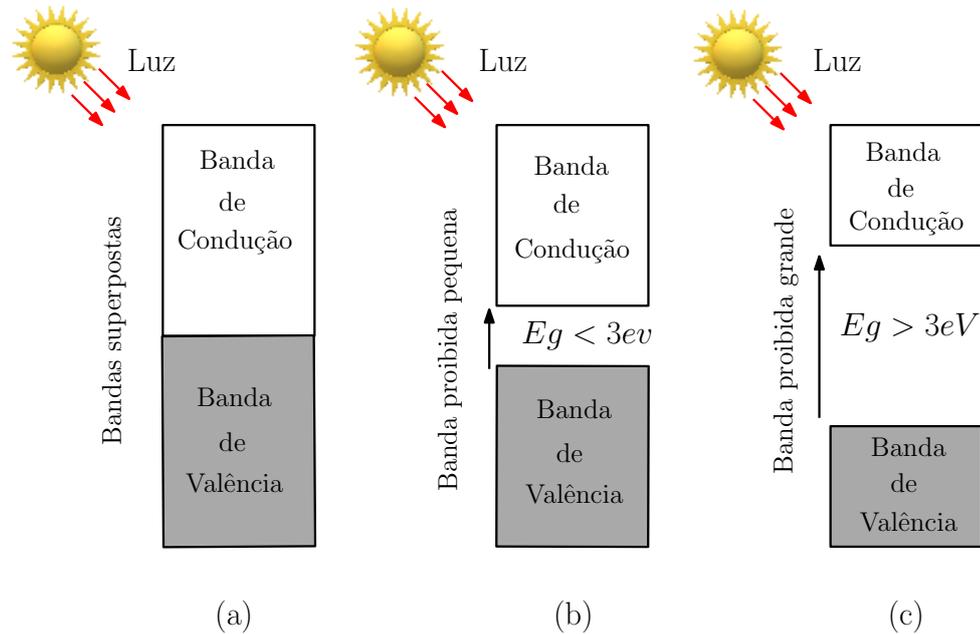
crecentes de temperatura do módulo reduzem a tensão em maiores proporções do que aumentam a corrente, deslocando assim o ponto de máxima potência para a esquerda. A discreta elevação de corrente é explicada pela diminuição da energia do gap do material, expressa por:

$$E_g(T) = E_g(0) - \frac{a \cdot T^2}{T + b}, \quad (2.18)$$

em que $E_g(T)$ é a energia do gap do material a uma dada temperatura, $E_g(0)$ é a energia de referência a 0 K e a e b são constantes do material. A Figura 27, apresenta a estrutura de separação de bandas de energia para os materiais condutores, semicondutores e isolantes. Nota-se que a divisão (gap) entre as bandas de valência e de condução podem ser superpostas (condutor), pequena (semicondutor) e grande (isolante). A energia necessária para que um elétron se desloque da banda de valência para a de condução é denominada de banda proibida (gap), sendo representada por E_g , nos semicondutores esse valor pode alcançar até 3 eV, enquanto nos isolantes o gap de energia é maior do que esse valor.

A diminuição da tensão de circuito aberto é justificada principalmente pela relação exponencial da corrente de saturação reversa. Essa corrente é fruto dos portadores de carga minoritários criados por excitação térmica (SILVA, 2015). Uma vez que a corrente de saturação reversa, originada por portadores de carga minoritários gerados por excitação térmica, aumenta

Figura 27 – Diagrama de bandas de energia em materiais (a) condutores, (b) semicondutores e (c) isolantes.



Fonte: O autor (2020)

exponencialmente com a temperatura, ocasionando a queda na tensão da junção, como pode ser avaliado na Equação (2.18), e por consequência, nos terminais do módulo FV, conforme a Equação (2.24).

2.5 PARÂMETROS INTERNOS QUE INFLUENCIAM AS CARACTERÍSTICAS ELÉTRICAS

A influência dos parâmetros internos dos módulos FV nas características elétricas está relacionada com a sua estrutura interna de composição.

2.5.1 Corrente de Saturação Reversa – I_{sat}

A corrente reversa de saturação é gerada termicamente pelos portadores minoritários da junção p-n, ou seja, quanto maior a temperatura na junção, maior a corrente de saturação. Esse comportamento da I_{sat} com relação à temperatura é representada por (SILVA, 2015; JUNIOR, 2018)

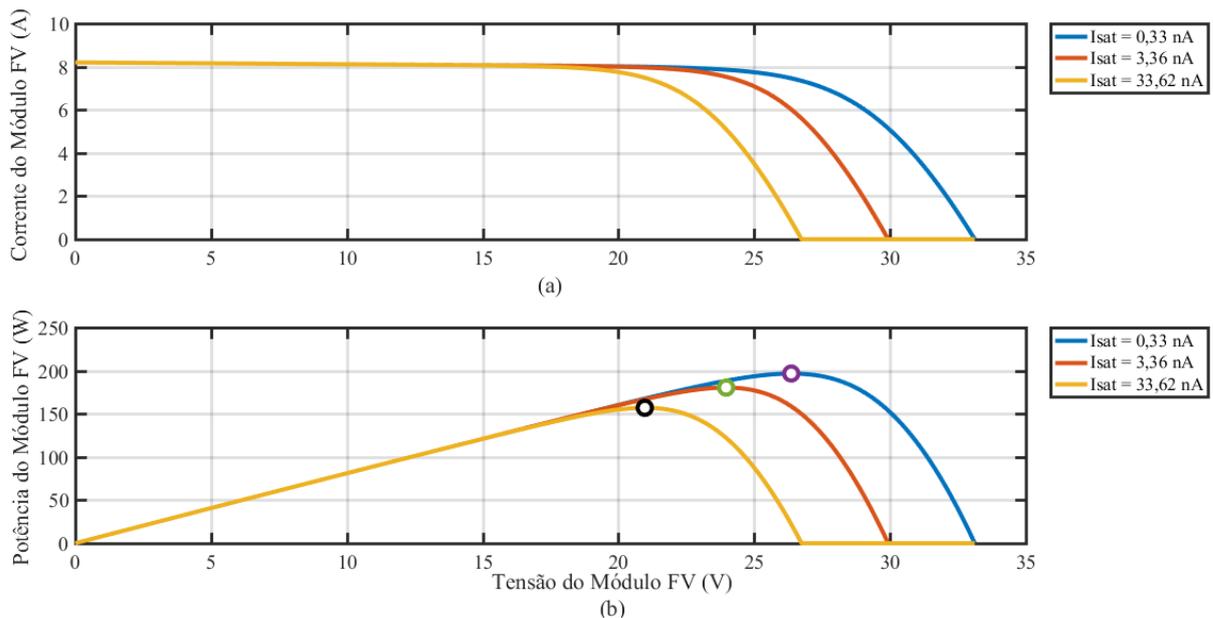
$$I_{sat}(T) = BT^3 e^{-\frac{E_g(T)}{kT}}, \quad (2.19)$$

onde T é a temperatura, k é a constante de Boltzmann, E_g é a energia do gap relativa a temperatura T , B é uma constante independente da temperatura e $I_{sat}(T)$ é a corrente de

saturação reversa em função da temperatura.

A Figura 28, mostra a variação da corrente de saturação e o efeito provocado nas curvas $I-V$ e $P-V$. Com o aumento de I_{sat} , nota-se alterações nas características elétricas como a redução da tensão de circuito aberto, provocada pela tensão reversa na junção, causando uma diminuição na potência, e uma queda na eficiência do módulo.

Figura 28 – Comportamento das curvas (a) corrente versus tensão ($I-V$) e (b) potência versus tensão ($P-V$) de acordo com a variação da corrente de saturação.



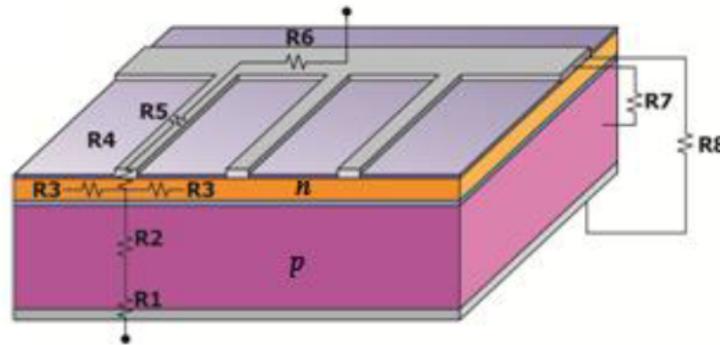
Fonte: O autor (2020)

2.5.2 Resistência Série – R_s

A resistência em série de uma célula solar é um fator importante que determina o fator de forma (FF) e, portanto, a eficiência de uma célula FV (Sharma et al., 2016). A estrutura física de uma célula FV explica a origem desse parâmetro. Como mostrado na Figura 29, os elementos que dão origem a esse parâmetro são:

- Resistências do contato metal-semicondutor na região da base (R_1 - posterior);
- Resistência do material semicondutor (R_2);
- Resistência lateral do emissor (R_3);
- Resistências do contato metal-semicondutor na região do emissor (R_4 - frontal);

Figura 29 – Estrutura representativa da célula FV mostrando os principais elementos que dão origem a resistência série.



Fonte: (CEPEL-CRESESB, 2014)

- Resistência das trilhas metálicas (R_5);
- Resistência da barra coletora (R_6);
- Resistência em paralelo entre o contato metálico frontal e a região tipo p (R_7);
- Resistência em paralelo entre o contato metálico frontal e traseiro (R_8).

Então, cada célula FV pode ser representada pela soma de todos os elementos resistivos citados que compõem a sua estrutura, resultando na resistência série (r_s) apresentada no modelo da Figura 19. No caso dos módulos, além da contribuição da resistência de cada célula, existem ainda as resistências de conexões entre as células.

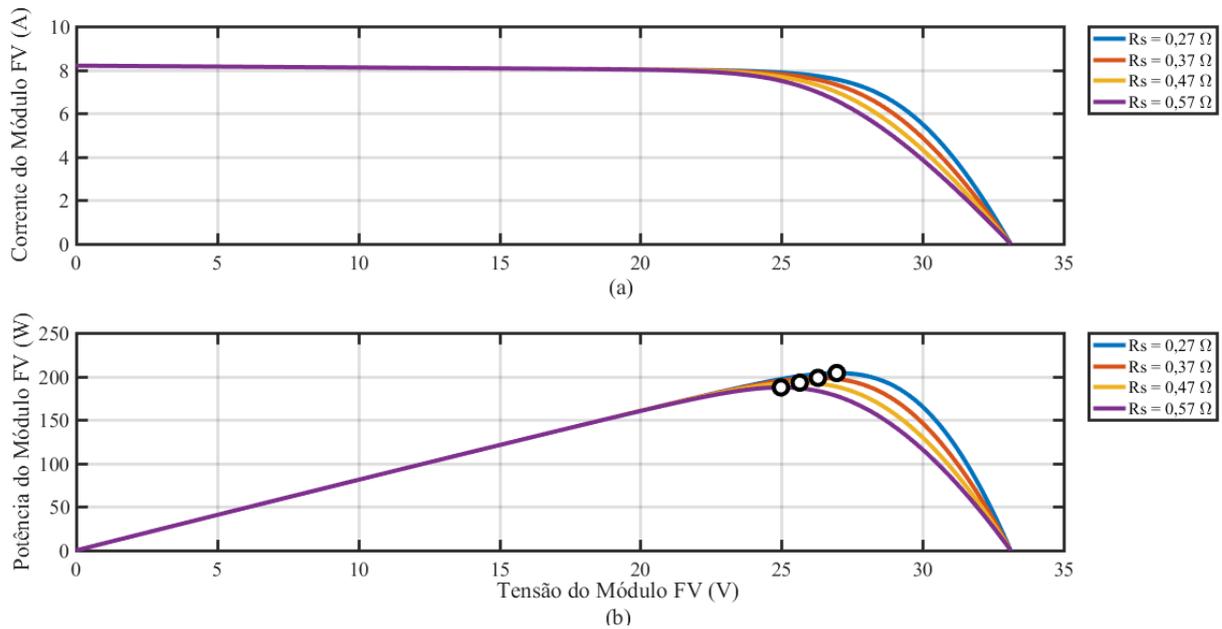
Na Figura 30, as curvas $I-V$ e $P-V$, representam o módulo KC200GT do fabricante (KYOCERA, 2019), para diferentes valores de R_s . Observa-se que aumentos de R_s contribuem para a redução da corrente de I_{sc} , sem afetar a tensão V_{oc} . Consequentemente, ocorre a redução no valor da potência máxima e na eficiência do módulo.

2.5.3 Resistência Paralelo – R_p

A resistência em paralelo também aparece no modelo do circuito da Figura 19, por motivos estruturais da célula FV. Ela é uma representação das impurezas e imperfeições existentes na estrutura, principalmente próximo às bordas, que produzem um caminho interno para uma corrente de fuga (CEPEL-CRESESB, 2014).

Idealmente, o módulo FV teria um valor de R_p infinito, o que representaria a inexistência de corrente de fuga. Valores baixos de R_p causam queda na potência fornecida pelo dispositivo FV, devido a um caminho alternativo que a corrente fotogerada tem para circular (SILVA,

Figura 30 – Comportamento das curvas (a) corrente versus tensão ($I-V$) e (b) potência versus tensão ($P-V$) de acordo com a variação da resistência série.



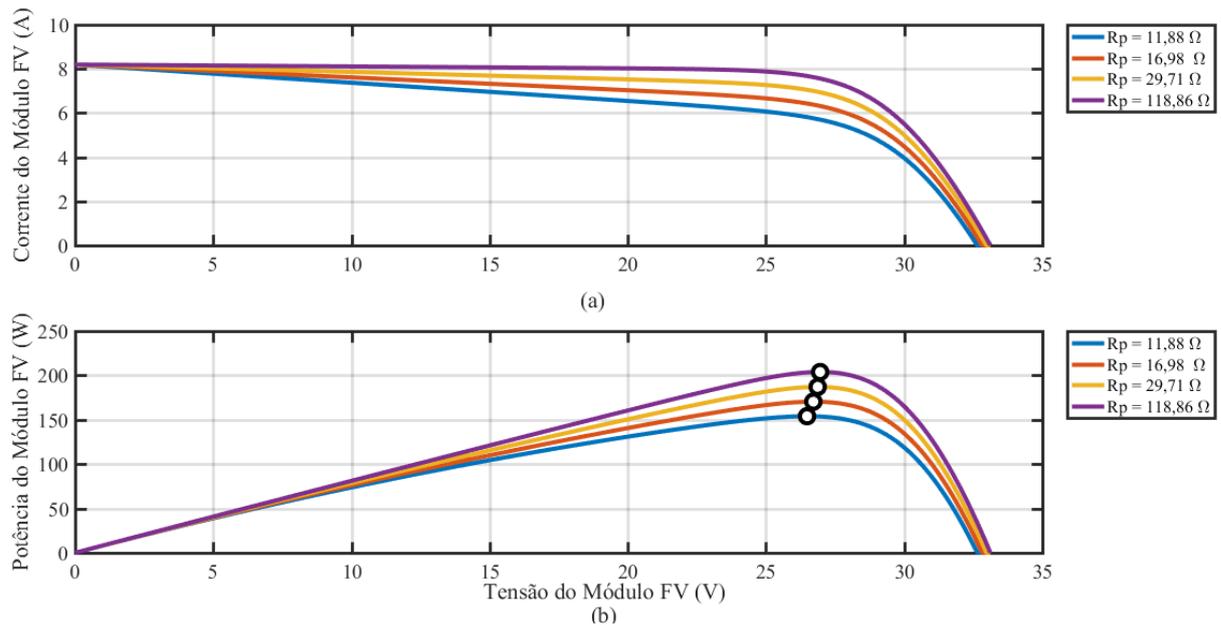
Fonte: O autor (2020)

2015; JUNIOR, 2018). Na Figura 31, as curvas $I-V$ e $P-V$ mostram a influência de R_p nas características elétricas do módulo KC200GT do fabricante (KYOCERA, 2019). Observa-se que valores baixos de R_p provocam uma redução no valor da tensão de circuito aberto e na corrente fornecida. Consequentemente, ocorre uma redução na potência máxima do módulo, influenciando assim a eficiência do módulo.

2.5.4 Fator de Idealidade

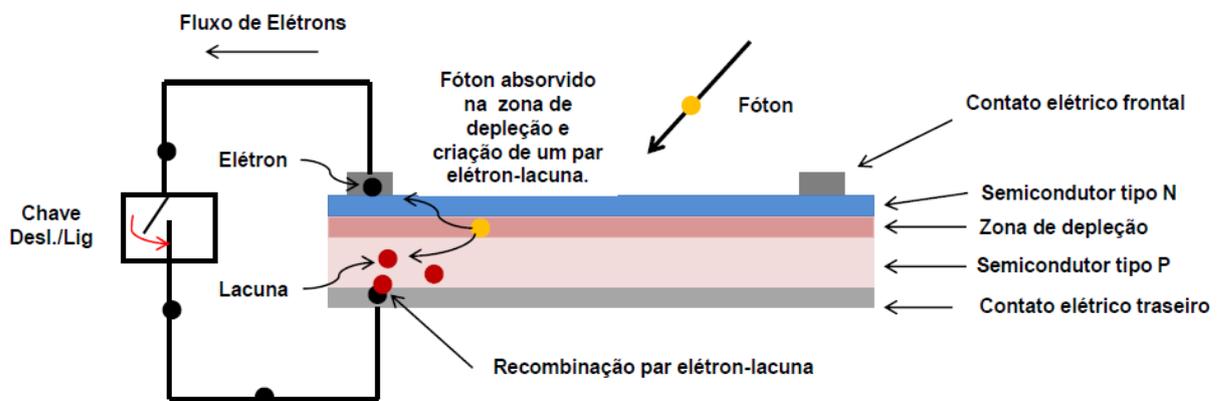
A luz ao incidir sobre a junção p-n, penetra no material e transfere sua energia gerando pares elétron-lacuna. Caso estes pares forem produzidos em uma região onde o campo elétrico não é nulo (zona de depleção), eles serão acelerados, dando origem a uma corrente através da junção e, por sua vez, a uma diferença de potencial entre as superfícies das regiões p e n. Este fenômeno é chamado de efeito fotovoltaico. Se a junção p-n for conectada um condutor formando um circuito fechado, como ilustrado na Figura 32, uma corrente elétrica será estabelecida e permanecerá enquanto estiver sob exposição da luz (fótons), isto é, os elétrons em excesso da região n tendem a se difundir para a região p e ao mesmo tempo as lacunas em excesso na região p tendem a se difundir para a região n. Ao passar para o

Figura 31 – Comportamento das curvas (a) corrente versus tensão ($I-V$) e (b) potência versus tensão ($P-V$) de acordo com a variação da resistência paralela.



Fonte: O autor (2020)

Figura 32 – Processo de conversão da radiação solar em corrente elétrica em células FV

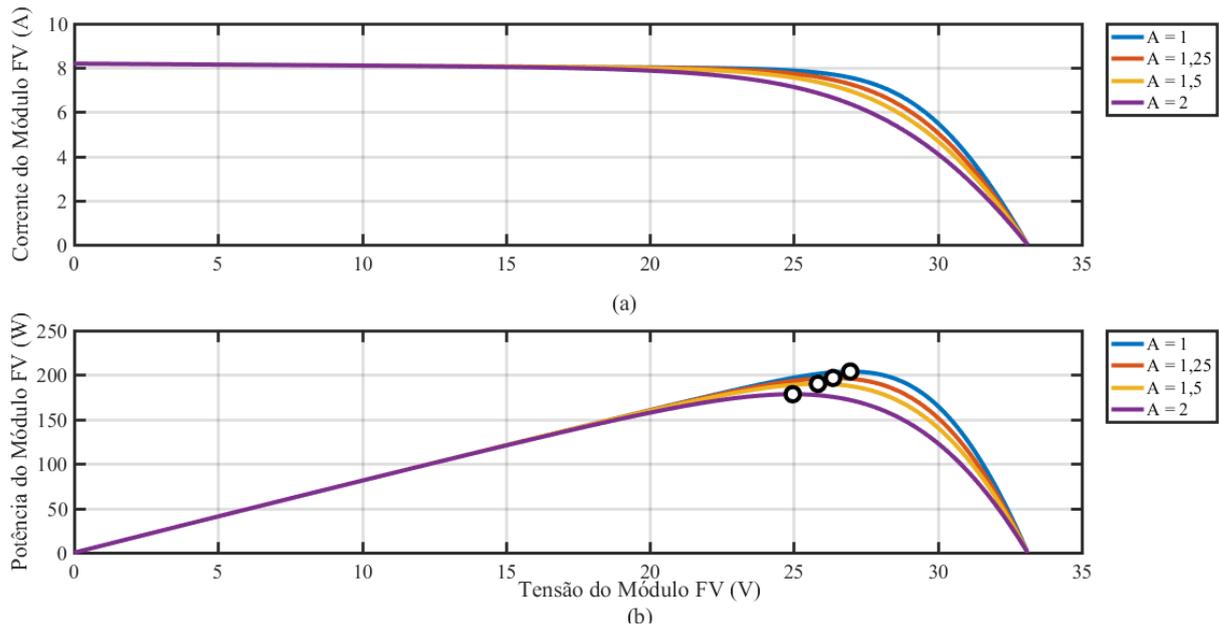


Fonte: (SI, 2020)

outro lado da junção, se recombinam (respectivamente) com as lacunas e elétrons inicialmente excedentes nas respectivas regiões.

O fator de idealidade (A) do diodo é um parâmetro de ajuste e é usado para equiparar o comportamento prático da junção p-n da célula FV com o comportamento ideal de um diodo. A teoria da recombinação *Shockley-Read-Hall*, na análise de desempenho da célula solar, assume este fator igual a 2 no predomínio do fenômeno de recombinação e tende ao valor 1 para o predomínio do fenômeno de difusão (OTAEGI et al., 2017). Nos materiais semicondutores,

Figura 33 – Comportamento das curvas (a) corrente versus tensão (I - V) e (b) potência versus tensão (P - V) de acordo com a variação do fator de idealidade.



Fonte: O autor (2020)

sempre vai haver uma mistura dos dois fenômenos, resultando em uma condição do fator de idealidade, tal que $1 < A < 2$. Tal parâmetro está diretamente associado com a curvatura do joelho da curva I - V , influenciando dessa forma a potência máxima do dispositivo FV (SILVA, 2015). A Figura 33 apresenta curvas I - V e P - V , do módulo KC200GT do fabricante (KYOCERA, 2019), relativas a diferentes valores de A , destacando-se a sua influência na potência máxima gerada no módulo FV.

2.6 MODELO GLOBAL NÃO-LINEAR DO MÓDULO FOTOVOLTAICO

O modelo de um diodo para módulos FV da Figura 20 é representado pelos parâmetros intrínsecos R_s , R_p , I_g , A e I_{sat} que são considerados fixos para uma dada condição de S e T , ou seja, não sofrem influência de outros parâmetros. A aplicação das técnicas de estimação de parâmetros a esse modelo geralmente é realizada na STC , visto que os fabricantes de módulos FV fornecem em seus *datasheets* apenas um conjunto de parâmetros relacionados à STC , como V_{oc} , I_{sc} , V_{mp} , I_{mp} e P_{mp} . Entretanto, em condições reais de operação, o módulo FV fica submetido estatisticamente a maior parte do tempo a condições fora da STC , e nesse caso, as informações fornecidas pelos fabricantes perdem a validade.

Experimentalmente, podem ser obtidos alguns desses parâmetros, porém existem outros

parâmetros que atuam simultaneamente influenciando o desempenho do módulo FV e, em geral, não são fornecidos pelo fabricante. Neste caso, para estimar os parâmetros, é necessário usar um método de extrapolação baseado nos *datasheets* dos módulos FV para determinar os parâmetros intrínsecos para diferentes condições ambientais. Dessa forma, diferentes conjuntos de parâmetros intrínsecos são obtidos para cada curva $I-V$. Uma vez que os algoritmos estimam os parâmetros de forma independente de uma curva $I-V$ para outra, ou seja, são baseados apenas em um ajuste matemático, não há interpretação física para a variação nos parâmetros, o que também ocorre em algumas técnicas baseadas em algoritmos de otimização conforme simulações realizadas em (SILVA, 2019), que são executadas para todas as combinações de S e T .

Visto as dificuldades e limitações encontradas no processo de estimação dos parâmetros do módulo FV para condições ambientais variáveis (fora da STC) para o modelo de um diodo com parâmetros fixos, tem-se, portanto, uma complexa atividade de desenvolvimento de modelos matemáticos com alto grau de precisão, que dependam da variação de irradiância e temperatura e que possuam explicações físicas para os efeitos observados.

Neste trabalho, foi utilizado nas simulações o modelo do módulo FV proposto em (SILVA, 2019). O modelo global não-linear tem como base o modelo de um diodo, diferenciando na alteração de alguns parâmetros, pois agora passam a incluir os efeitos da irradiância e da temperatura simultaneamente para tornar o modelo mais próximo de descrever o módulo FV real.

Com base nos estudos de comportamento dos parâmetros de um módulo FV em função da irradiância e temperatura realizado por (SILVA, 2019) fundamentadas no modelo de um diodo, as equações que descrevem o modelo global não-linear são dadas por:

▪ **Resistência série – R_s**

$$R_s = R_{sref2}[1 + k_{Rs}(T - T_{ref})] + R_{sref1} \left(\frac{S}{S_{ref}} \right)^{\gamma_{Rs}}, \quad (2.20)$$

em que:

- R_{sref1} - Parcela de R_s que está relacionada com a variação da irradiância (em Ω);
- R_{sref2} - Parcela de R_s que está relacionada com a variação da temperatura (em Ω);

- k_{R_s} - Coeficiente de variação de R_s com a temperatura (em %/°C), podendo ser maior ou menor que zero;
- T - Temperatura local (em °C);
- T_{ref} - Temperatura local de referência (em °C);
- γ_{R_s} - Coeficiente de variação de R_s com a irradiância, sendo $\gamma_{R_s} \leq 0$;
- S - Irradiância local (em W/m²);
- S_{ref} - Irradiância de referência (em W/m²).

▪ **Resistência paralela – R_p**

$$R_p = R_{pref}[1 + k_{Rp}(T - T_{ref})] \left(\frac{S}{S_{ref}} \right)^{\gamma_{Rp}}, \quad (2.21)$$

em que:

- R_{pref} - Resistência paralela para a condição de referência (em Ω);
- k_{Rp} - Coeficiente de variação de R_p com a temperatura (em %/°C), sendo $k_{Rp} \leq 0$;
- γ_{Rp} - Coeficiente de variação de R_p com a irradiância, sendo $\gamma_{Rp} \leq 0$.

▪ **Fator de idealidade - A**

$$A = A_{ref}, \quad (2.22)$$

em que:

- A_{ref} - Fator de idealidade de referência, sendo $1 \leq A_{ref} \leq 2$.

▪ **Corrente de curto-circuito - I_{sc}**

$$I_{sc} = [I_{scref} + \alpha_i(T - T_{ref})] \left(\frac{S}{S_{ref}} \right), \quad (2.23)$$

em que:

- I_{scref} - Corrente de curto-circuito de referência (em A);
- α_i - Coeficiente de variação da corrente de curto-circuito com a temperatura (em A/°C), sendo $\alpha_i > 0$;

▪ **Tensão de circuito aberto - V_{oc}**

$$V_{oc} = V_{oc,ref} + \beta_T(T - T_{ref}) + \beta_S V_t \ln\left(\frac{S}{S_{ref}}\right), \quad (2.24)$$

em que:

- $V_{oc,ref}$ - Tensão de circuito aberto para a condição de referência (em V).
- β_T - Coeficiente de variação de V_{oc} com a temperatura;
- β_S - Coeficiente de variação de V_{oc} com a irradiância;
- V_t - Tensão térmica (em V);

▪ **Corrente fotogerada - I_g**

$$I_g = I_{sc} \left(1 + \frac{R_s}{R_p}\right) \quad (2.25)$$

em que:

- I_{sc} - Corrente de curto-circuito (em A);
- R_s - Resistência série (em Ω);
- R_p - Resistência em paralelo (em Ω).

▪ **Corrente de saturação - I_{sat}**

$$I_{sat} = \frac{I_g - \frac{V_{oc}}{R_p}}{e^{\frac{V_{oc}}{V_t}} - 1}, \quad (2.26)$$

De acordo com a proposição do modelo, as equações (2.20), (2.21), (2.23) e (2.24) apresentam dependência direta com a irradiância e temperatura, enquanto as equações (2.25) e (2.26), obtidas de (2.11) na condição de curto-circuito e circuito aberto, apresentam dependência indireta com a irradiância e temperatura, pois os efeitos de S e T estão incluídos nas suas variáveis dependentes. Logo, somente A não depende de S e T direta ou indiretamente. Dessa forma, as equações do modelo global não-linear extrapolam os parâmetros em função da irradiância e temperatura através da aplicação de algoritmos de otimização, conforme será visto no Capítulo 4.

O modelo global não-linear foi validado através de resultados obtidos com a estimação de parâmetros aplicando a técnica de otimização busca por padrões (PS) baseada na função objetivo EMAP em quatro módulos de tecnologias diferentes. Logo, pode-se concluir que o comportamento físico dos parâmetros do módulo FV pode ser aproximado pelo conjunto de equações visto nesta seção, resultando em um modelo preciso nas condições investigadas, pois pode ser aplicado em mais de uma condição ambiental sem precisar executar o algoritmo que estima os parâmetros diversas vezes, diferentemente do modelo de diodo único baseado nas técnicas de estimação existentes na literatura. Entretanto, por se tratar de um modelo novo na literatura, é necessário estudar e avaliar o comportamento para uma gama maior de variações das condições de S e T durante o processo de validação, visto que em (SILVA, 2019), todo o estudo de validação dos módulos FV contemplou poucas variações das condições de S e T . Outro ponto é que na validação do modelo, não foram avaliadas diferentes técnicas de otimização metaheurísticas, que possuem a característica de coordenação de processos de otimização com estratégias de alto nível e podem ser uma boa alternativa para a técnica de estimação de parâmetros do modelo.

2.7 CONCLUSÕES

Neste capítulo, foi visto a teoria dos módulos FV que servirá de base para o desenvolvimento deste trabalho, abordando inicialmente o recurso solar como fonte de geração de energia, o princípio de funcionamento de células/módulos e os seus tipos e tecnologias de fabricação.

Posteriormente, uma breve discussão de como as células se associam para formar o módulo fotovoltaico foi realizada, para em seguida, apresentar um circuito equivalente simples de um diodo contendo cinco parâmetros que representa o comportamento elétrico através das curvas $I-V$ e $P-V$ dos módulos fotovoltaicos. Na sequência, uma análise da influência de parâmetros externos e internos nas características elétricas foi apresentada de forma a compreender os fatores que afetam o rendimento dos módulos fotovoltaicos.

Finalmente, foi apresentado o modelo global não-linear que é um modelo baseado no modelo clássico de diodo único, e será o modelo adotado nos estudos subsequentes dessa dissertação, em que sua escolha deve-se principalmente pela capacidade de adaptar os valores dos seus parâmetros, baseado no comportamento físico dos mesmos, de acordo as variações nas condições ambientais (irradiância e temperatura).

3 TÉCNICAS DE OTIMIZAÇÃO UTILIZADAS NA ESTIMAÇÃO DE PARÂMETROS DE MÓDULOS FV

Neste capítulo, são apresentados os principais conceitos, definições e características dos métodos de otimização. O termo otimização refere-se ao estudo de problemas em que se busca a maximização ou minimização de uma função de uma ou mais variáveis num determinado domínio, sendo que, geralmente, existe um conjunto de restrições nas variáveis. Serão abordados de forma mais detalhada os métodos de otimização baseados em metaheurística, os quais são utilizados neste trabalho para estimação dos parâmetros de módulos FV.

3.1 ASPECTOS GERAIS DO PROCESSO DE OTIMIZAÇÃO

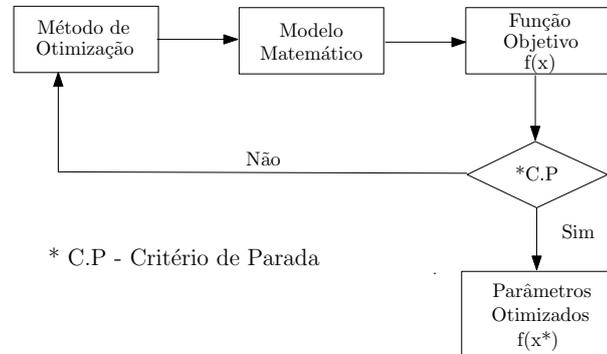
A otimização é definida como o processo pelo qual é possível encontrar uma solução ou um conjunto de soluções ótimas para uma determinada função ou um conjunto de funções. Uma solução é considerada ótima quando o melhor resultado é encontrado para o problema avaliado, isto é, aquele que atingiu melhor o objetivo e respeitou todas as condições que foram impostas no problema.

3.1.1 Processo de Otimização

Em problemas de engenharia, uma prática muito comum é a aplicação de modelos matemáticos para descrever o comportamento de um sistema. Segundo (OGATA, 2000), "a modelagem matemática de um sistema dinâmico é definida como um conjunto de equações que representam a dinâmica do sistema com precisão ou, pelo menos, de forma bastante aceitável". Para o caso específico da modelagem de módulos FV, foi visto que uma das alternativas para estimação dos parâmetros do modelo dos módulos FV, consiste na otimização de uma função objetivo previamente definida. Como ilustrado na Figura 34, em que a otimização é aplicada para ajuste do modelo com sistema físico real. Sendo assim, ao determinar modelos matemáticos representativos para esses sistemas em estudo, é possível aplicar os métodos de otimização para ajustar um modelo a um sistema físico em que se busca encontrar valores ótimos dos parâmetros internos do modelo, ou seja, os métodos de otimização buscam encontrar pontos que provocam a maximização ou minimização de uma função previamente definida como função objetivo ($f(x)$), buscando os parâmetros dentro do conjunto \mathbf{X} de soluções viáveis, onde $x \in$

X (GOMES, 2017). No caso de estimação paramétrica, a função ($f(x)$) geralmente representa o quão bom o modelo representa o sistema físico.

Figura 34 – Fluxo do processo de otimização.



Fonte: adaptado de (GOMES, 2017)

3.1.2 Formulação do Problema de Otimização

De acordo com (BOYD; VANDENBERGHE, 2004), um problema de otimização matemática pode ser representado pela minimização (ou maximização) de uma função da seguinte forma:

$$\text{minimize : } f(x) \quad (3.1)$$

$$\text{sujeito a : } f_i(x) \leq b_i, i = 1, \dots, m.$$

Aqui o valor de $x = (x_1, \dots, x_n)$ é a variável de otimização do problema, a função $f(x)$: $R^n \rightarrow R$ é a função objetivo, as funções $f_i(x)$, $i = 1, \dots, m$, são funções das restrições de desigualdade, e as constantes b_1, \dots, b_m são os limites, ou fronteiras, das desigualdades. O valor de x^* é chamado de ótimo, ou solução do problema, se tiver o menor valor objetivo entre todos os vetores que satisfazem as restrições.

O problema de otimização em (3.1), consiste basicamente em realizar a melhor escolha possível (com certa precisão) de um vetor x em R^n , a partir de um conjunto **X** de opções candidatas, geralmente especificado por um conjunto de restrições, igualdades ou desigualdades que os membros de R^n devem satisfazer. O domínio R de $f(x)$ é chamado de espaço de busca, enquanto os elementos de R^n são chamados de soluções candidatas ou soluções viáveis. Uma solução é considerada ótima quando minimiza (ou maximiza, se esta é a intenção) a função objetivo do problema.

3.1.3 Classificação dos Problemas de Otimização

Um método de solução para problemas de otimização são os algoritmos que calculam uma solução do problema (com certa precisão), dada uma classificação específica do problema. A eficácia desses algoritmos, ou seja, a capacidade de resolver o problema de otimização em (Equação 3.1) varia consideravelmente e depende de fatores que classificam o problema de otimização (LUENBERGER; YE, 2008a).

Segundo (BAUDIN; COUVERT; STEER, 2019), várias propriedades, que classificam o problema de otimização a ser resolvido devem ser levadas em consideração pelos algoritmos, como:

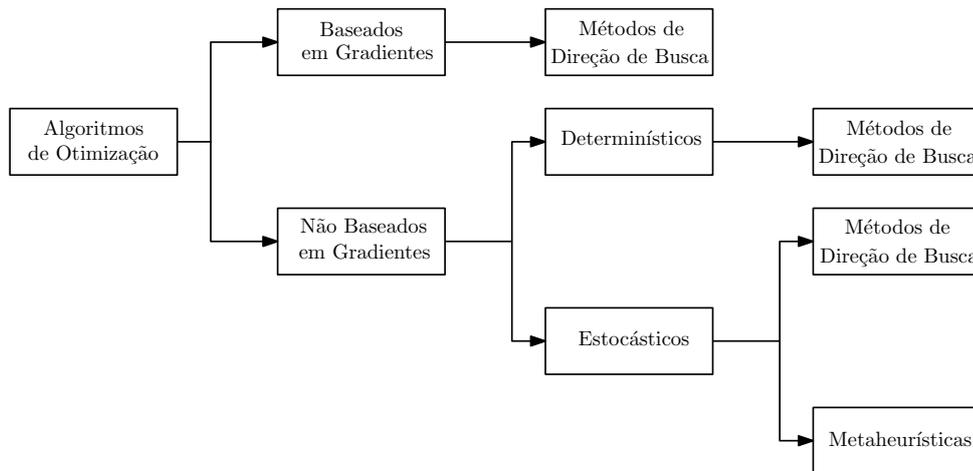
- O tipo de variável (parâmetro), que pode ser discreto ou contínuo. Uma variável contínua é aquela que pode assumir qualquer valor dentro de um intervalo de variação, enquanto que uma variável discreta é aquela que pode assumir valores específicos;
- A quantidade de funções objetivo, onde o problema pode ser mono-objetivo (uma função) ou multiobjetivo (várias funções);
- A função objetivo pode ser suave (diferenciável) ou não suave (não diferenciável);
- O problema de otimização pode ter restrições ou nenhuma restrição. As restrições são equações de igualdade ou de desigualdade que determinam os limites dos parâmetros.

Portanto, uma análise prévia em relação as características do problema de otimização é de extrema importância para aplicação e definição dos algoritmos. No caso do problema de estimação de parâmetros do modelo global não-linear, a técnica aplicada em (SILVA, 2019), caracteriza o problema de otimização como sendo de parâmetros contínuos, função mono-objetiva e com restrições. Com relação ao comportamento do gradiente (derivada) da função não se tem maiores informações.

3.2 MÉTODOS DE OTIMIZAÇÃO PARA SOLUÇÃO DE PROBLEMAS

A utilização de algoritmos para problemas de otimização em geral também são classificados de acordo com a natureza do problema. Existe um grande número de métodos de otimização baseado em algoritmos e várias maneiras diferentes de categorizá-los. Em (BENGLARS; VAL-JAMETS, 2014), os algoritmos são categorizados dependendo da sua estratégia de pesquisa em busca pelo ponto ótimo, conforme apresentado na Figura 35.

Figura 35 – Categorização dos algoritmos de otimização.



Fonte: adaptado de (BENGLARS; VALJAMETS, 2014)

Alguns métodos são capazes de lidar com valores discretos e outros são restritos a valores contínuos. Assim sendo, os algoritmos de otimização podem ser subdivididos em:

- Métodos baseados em gradientes: são métodos que utilizam o cálculo de gradientes (derivadas) da função objetivo para direcionar a busca pela solução ótima. Como exemplos, o algoritmo de Newton-Raphson e o Método do Gradiente (LUENBERGER; YE, 2008b), são baseados em gradiente ou derivada, pois usam os valores das funções e seus gradientes (derivadas) e funcionam bem para os problemas de otimização mono-objetivo onde a função objetivo apresenta um comportamento suave. No entanto, se houver alguma descontinuidade na função objetivo, esses métodos não funcionam bem. Nesse caso, os algoritmos que não utilizam gradiente ou derivadas são preferidos, pois apresentam melhores resultados no processo de otimização.
- Métodos não baseados em gradientes: são métodos que não utilizam o cálculo de gradientes (derivadas) para direcionar a busca pela solução ótima, utilizando somente o valor da função objetivo.

Os métodos estocásticos usam estratégias de aleatoriedade para ajudar na busca pelo ponto ótimo, enquanto os métodos determinísticos usam um procedimento predeterminado, que resulta sempre na mesma solução.

Geralmente, os problemas de estimação de parâmetros dos módulos FV são de natureza mono-objetiva, contínua e com restrições. Logo, uma estratégia para aplicação de métodos de otimização no processo de estimação de parâmetros é aplicar os métodos não baseados

em gradientes (derivadas), conforme visto na classificação da Figura 35, pois tem-se poucas informações sobre o problema.

3.2.1 Métodos de Otimização Metaheurísticos

Os métodos de otimização metaheurísticos são aplicados para encontrar respostas a problemas sobre os quais há poucas informações. O propósito desses métodos é encontrar soluções de boa qualidade em um tempo computacional adequado para problemas com alto grau de complexidade, sem a garantia de convergência para ótimos globais. Dois componentes principais de qualquer algoritmo metaheurístico são: a intensificação e a diversificação. Diversificação significa gerar soluções diversas para explorar o espaço em escala global, enquanto intensificação significa focar na pesquisa em uma região local, onde se encontra a atual solução global do problema. A boa combinação desses componentes principais geralmente garante que a otimização global seja alcançável (YANG, 2010).

As propriedades fundamentais que caracterizam os métodos de otimização metaheurísticos são (BLUM; ROLI, 2001):

- Metaheurísticas são estratégias que “guiam” o processo de busca pelo ótimo global;
- O objetivo é explorar com eficácia o espaço de busca para encontrar soluções ótimas, sem garantia de fornecer o ótimo global;
- As técnicas que constituem os algoritmos metaheurísticos variam de simples procedimentos de busca local para processos complexos de aprendizagem;
- Os algoritmos metaheurísticos podem ser estocásticos (não determinísticos) e geralmente fornecem diferentes soluções a cada execução;
- Podem incorporar mecanismos para evitar que a solução do problema fique estagnada em pontos de mínimo locais no espaço de busca;
- Metaheurísticas mais avançadas utilizam as experiências de pesquisa para orientar o processo de busca pelo ótimo global (incorporada em alguma forma de memória).

Segundo (BLUM; ROLI, 2001), existem diferentes maneiras de classificar e descrever algoritmos metaheurísticos. Geralmente a classificação tem como base a origem do algoritmo. Um

dos algoritmos metaheurísticos mais populares é o Algoritmo Genético (AG) (HOLLAND, 1975; GOLDBERG, 1989), baseado na Teoria de Evolução de Darwin, que teve origem em um comportamento da natureza. Outros algoritmos, são baseados em população e no comportamento da natureza, utilizam um grupo de soluções no processo de busca pelo ótimo, como Otimização Baseada no Enxame de Partículas (*Particle Swarm Optimization* – PSO) (KENNEDY; EBERHART, 1995) e Colônia de Formigas (*Ant Colony Optimization*) (Dorigo; Maniezzo; Coloni, 1996). As técnicas metaheurísticas podem também utilizar um único ponto (solução) para o processo de busca pelo ótimo, conhecidos como métodos baseados na direção de busca, como por exemplo o Busca Tabu (GLOVER; LAGUNA, 1997), GRASP (*Greedy Randomized Adaptive Search Procedure*) (FEO; RESENDE, 1995) e o Busca por Padrões (*Pattern Search* - PS) de (HOOKE; JEEVES, 1961). Sendo assim, tem-se uma série de algoritmos que podem ser: (i) inspirados ou não inspirados na natureza, (ii) métodos que utilizam uma única solução (métodos de trajetória) e métodos baseado em população, (iii) métodos que utilizam função objetivo estática ou dinâmica, (iv) métodos de única ou várias estruturas vizinhas, (v) métodos com memória ou sem memória.

Neste trabalho, o estudo estará direcionado a aplicação dos métodos de otimização metaheurísticos que não utilizam a derivada da função objetivo. Especificamente, neste trabalho é abordado a aplicação do algoritmo de PS, do método PSO e do algoritmo proposto em (MIRANDA; FONSECA, 2002), que consiste em um algoritmo híbrido que combina as estratégias de evolução com o PSO, denominado EPSO (*Evolutionary Particle Swarm Optimization*).

O algoritmo PS é aplicado no processo de estimação de parâmetros do modelo global não-linear de módulos FV em (SILVA, 2019). Porém, por se tratar de um modelo novo na literatura, decidiu-se aplicar outros métodos de otimização baseado em metaheurística, de forma a avaliar os resultados obtidos com o método PS inicialmente proposto. No presente trabalho, optou-se pela escolha da aplicação do EPSO por este incorporar as vantagens dos métodos PSO e dos Algoritmos Genéticos em um único método de otimização. Neste caso, o PSO foi escolhido para aplicação também no processo de estimação de parâmetros como uma ferramenta para compreensão do método EPSO.

3.3 OTIMIZAÇÃO BASEADA EM BUSCA POR PADRÕES (*PATTERN SEARCH* - PS)

Como visto anteriormente, existem algoritmos de otimização para resolver problemas que não requerem qualquer informação sobre a derivada ou gradiente da função objetivo, ou

seja, a aplicação deste método é adequado para problemas em que a função objetivo é não-diferenciável ou não é contínua. Diferentemente dos métodos de otimização mais tradicionais que usam informações sobre derivadas ou gradientes para procurar um ponto ideal (máximo ou mínimo), um algoritmo não baseado em derivadas pesquisa um conjunto de pontos em torno do ponto inicial, procurando um ponto em que o valor da função objetivo seja menor que o valor no ponto inicial (KOLDA; TORCZON, 2003).

Dentre os métodos de otimização que não utilizam derivadas, tem-se o algoritmo de otimização Busca por Padrões (*Pattern Search*) que foi introduzido pela primeira vez no ano de 1961 por (HOOKE; JEEVES, 1961). O termo "Busca por Padrões" ou "*Pattern Search*" tem sido utilizado como uma referência geral a todos os métodos que realizam a busca pelo ponto ótimo a partir de um ponto inicial predeterminado, direcionando a busca pelo ponto ótimo através da comparação de valores da função objetivo (MØLLER, 2016).

Diferentes métodos de otimização baseada na Busca por Padrões foram desenvolvidos ao longo dos anos e ajustados para os problemas de otimização em que eles são aplicados para resolver. Os métodos de Busca por Padrões tendem a ter uma tática muito simples e, portanto, fácil de usar como primeira abordagem de otimização (MØLLER, 2016). Na subseção seguinte, é apresentado o algoritmo de Busca Generalizada por Padrões (*Generalized Pattern Search - GPS*), considerado o algoritmo padrão da classe de Busca Direta do pacote de otimização *Global Optimization Toolbox* do software MATLAB®, que foi utilizado na aplicação do processo de estimação de parâmetros do modelo global não-linear proposto por (SILVA, 2019) para módulos FV. Outros dois algoritmos de otimização idênticos ao Busca Generalizada por Padrões (GPS), conhecidos como: Algoritmo de Busca por Conjunto Gerador (*Generating Set Search - GSS*) e Algoritmo de Busca Direta com Malha Adaptável (*Mesh Adaptive Search - MADS*) estão incluídos na ferramenta das versões mais atuais do MATLAB® e são aplicados nas simulações de estimação de parâmetros.

3.3.1 Algoritmo de Busca Generalizada por Padrões (*Generalized Pattern Search - GPS*)

O algoritmo de Busca Generalizada por Padrões (GPS), foi definido e analisado por (TORCZON, 1997) para problemas de otimização com restrições e sem restrições lineares (AUDET; DENNIS, 2003). O algoritmo pode ser brevemente explicado da seguinte forma: a partir de um ponto inicial \mathbf{x}^k , buscamos em um conjunto determinado de direções definidas por $\Delta\vec{\mathbf{x}}$,

chamado de vetor padrão, um novo ponto \mathbf{x}^{k+1} , em que o valor da função objetivo diminui (no caso de um problema de minimização) em comparação com o valor no ponto atual $f(\mathbf{x}^{k+1}) < f(\mathbf{x}^k)$, ou seja, o algoritmo calcula o valor da função objetivo em uma sequência de pontos que se aproximam de um ponto ótimo. Em cada etapa, o algoritmo busca em um conjunto de pontos, chamado de malha, que é formada em torno do ponto inicial. A malha é formada pela adição do ponto inicial a um múltiplo escalar de um conjunto de vetores chamado padrão. Se o algoritmo de Busca por Padrões encontrar um ponto na malha que melhore a função objetivo em relação ao ponto inicial, o novo ponto se tornará o ponto onde a nova malha será gerada na próxima etapa do algoritmo.

O algoritmo é declarado da seguinte maneira (GÜNEŞ; TOKAN, 2010):

1. Definições:

1.1 Definição da função objetivo $f(x)$ e do espaço de solução da variável de otimização x_j ; onde $j = 1, \dots, n$ e suas limitações inferiores (x_{jI}) e superiores (x_{jU}); onde $j = 1, \dots, n$, sendo n o número de variáveis independentes.

1.2 Definição dos parâmetros de busca: vetor padrão $\Delta\vec{x}_j$, onde $j = 1, \dots, n$; dos fatores de contração (η_{cont}) e expansão (η_{exp}) para formar malha em torno do ponto atual. *Observação:* Um vetor padrão $\Delta\vec{x}_j$ é um conjunto de vetores que o algoritmo GPS usa para determinar quais pontos procurar em cada iteração. O conjunto $\Delta\vec{x}_j$ é definido pelo número de variáveis independentes na função objetivo, n , e o conjunto de bases positivas. Dois conjuntos de bases positivas comumente usados nos algoritmos de Busca por Padrões são a base máxima, com $2n$ vetores, e a base mínima, com vetores $n+1$ (MATHWORKS®, 2019a).

Por exemplo, se houver três variáveis independentes no problema de otimização, o padrão para uma base positiva de $2n$ consistirá nos seguintes vetores padrão:

$$\begin{aligned}\Delta\vec{x}_1 &= [1 \ 0 \ 0] ; \Delta\vec{x}_2 = [0 \ 1 \ 0] ; \Delta\vec{x}_3 = [0 \ 0 \ 1] \\ \Delta\vec{x}_4 &= [-1 \ 0 \ 0] ; \Delta\vec{x}_5 = [0 \ -1 \ 0] ; \Delta\vec{x}_6 = [0 \ 0 \ -1]\end{aligned}$$

Se houver duas variáveis na base máxima $2n$, tem-se:

$$\Delta\vec{x}_1 = [1 \ 0] ; \Delta\vec{x}_2 = [0 \ 1] ; \Delta\vec{x}_3 = [-1 \ 0] ; \Delta\vec{x}_4 = [0 \ -1]$$

1.3 Definição do ponto inicial $P_{inicial}$ (x_{j0}); onde $j = 1, \dots, n$. O ponto inicial no espaço de solução deve ser definido para o algoritmo iniciar o processo de busca.

Esse processo também pode ser chamado como inicialização. Um conjunto de inicialização pode também ser obtido executando diferentes algoritmos que podem ser estocásticos ou determinísticos.

Por exemplo, supondo que o ponto inicial seja $x_0 = [2,1 \ 1,7]$, isto é, tem-se duas variáveis no problema, logo um conjunto com 4 vetores são formados para o surgimento da malha. Na primeira iteração, o tamanho da malha é 1 e o algoritmo GPS adiciona os vetores padrão ao ponto inicial $x_0 = [2,1 \ 1,7]$ para calcular os seguintes pontos de malha:

- $[1 \ 0] + x_0 = [3,1 \ 1,7]$
- $[0 \ 1] + x_0 = [2,1 \ 2,7]$
- $[-1 \ 0] + x_0 = [1,1 \ 1,7]$
- $[0 \ -1] + x_0 = [2,1 \ 0,7]$

2. Processo de busca

2.1 Avaliar a função objetivo nos pontos de malha M_j ; onde $j = 1, \dots, n$;

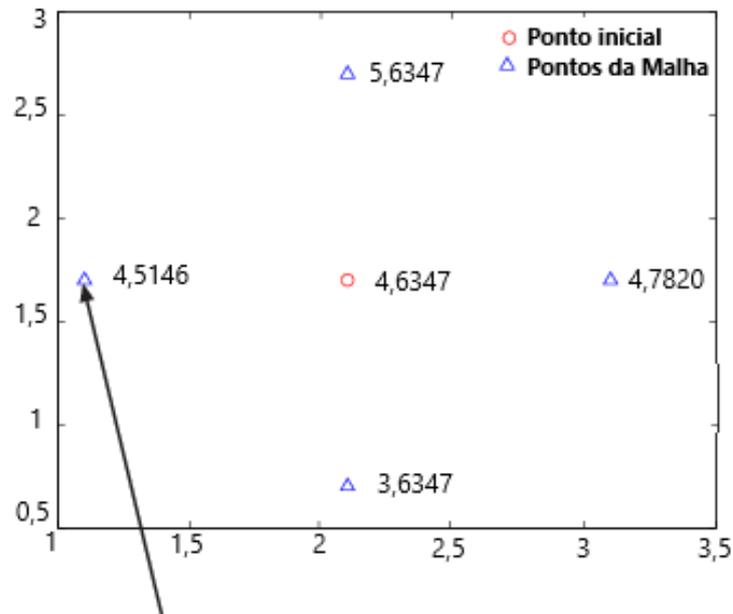
Ao analisar o exemplo do passo anterior, o algoritmo calcula a função objetivo nos pontos da malha na ordem mostrada acima. O algoritmo pesquisa os pontos na malha (Figura 36) computando seus valores na função objetivo até encontrar um cujo valor seja menor que 4,6347, que corresponde ao valor da função objetivo em x_0 .

2.2 Comparar a função objetivo no ponto P_{atual} com os pontos da malha M_j ; $j = 1, \dots, n$;

Observação: onde $P_{\text{atual}} = P_{\text{inicial}}$ na primeira iteração do método. No exemplo, o primeiro ponto encontrado, cujo valor é menor que x_0 é $[1,1 \ 1,7]$, no qual o valor da função objetivo é 4,5146. Portanto, a pesquisa na iteração 1 é bem-sucedida. O algoritmo define o próximo ponto na sequência igual a $x_1 = [1,1 \ 1,7]$.

Por convenção padrão, o algoritmo GPS interrompe a iteração atual assim que encontra um ponto de malha cujo valor da função objetivo é menor que o P_{atual} . Conseqüentemente, o algoritmo pode não realizar a pesquisa em todos os pontos da malha. Entretanto, é possível escolher que o algoritmo faça a pesquisa em todos os pontos da malha .

Figura 36 – Valores da função objetivo no ponto inicial e nos pontos da malha formada.



Fonte: adaptado de (MATHWORKS®, 2020)

2.3 Se algum ponto da malha M_j é menor que o ponto P_{atual} , primeiramente expandir o vetor padrão, $\eta_{\text{exp}} \Delta \vec{x}_j$, $j = 1, \dots, n$; e logo após somar o vetor resultante ao P_{atual} (x_{atual} , $j = 1, \dots, n$) para criar uma nova malha neste ponto P_{atual} , $M_j \iff x_{\text{atual}} + \eta_{\text{exp}} \Delta \vec{x}_j$ e ir para o passo 2.1.

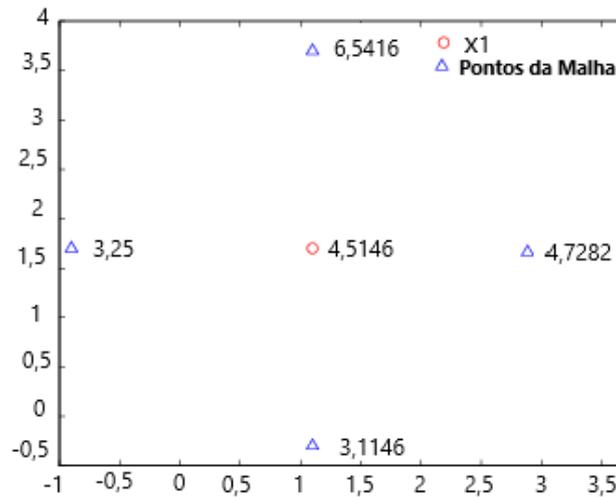
Como visto nessa etapa, após uma pesquisa bem-sucedida, o algoritmo multiplica o tamanho da malha atual por um fator de expansão definido previamente, neste exemplo adotando esse fator igual a 2. Logo, a malha formada, tem os seguintes pontos:

- $2[1 \ 0] + x_1 = [3,1 \ 1,7]$
- $2[0 \ 1] + x_1 = [1,1 \ 3,7]$
- $2[-1 \ 0] + x_1 = [-0,9 \ 1,7]$
- $2[0 \ -1] + x_1 = [1,1 \ -0,3]$

A Figura 37 a seguir mostra o ponto x_1 e os pontos da malha,

O algoritmo pesquisa os pontos de malha até encontrar um cujo valor seja menor que 4,5146, o valor da função objetivo em x_1 . O primeiro ponto encontrado é $[-0,9 \ 1,7]$, no qual o valor da função objetivo é 3,25. Portanto, a pesquisa na iteração 2 é novamente bem-sucedida e o algoritmo define o segundo ponto na sequência igual a $x_2 = [-0,9 \ 1,7]$. Como a pesquisa é bem-sucedida, o algoritmo multiplica o

Figura 37 – Valores da função objetivo em x_1 e nos pontos da malha formada.



Fonte: adaptado de (MATHWORKS®, 2020)

tamanho da malha atual por 2 novamente para obter um tamanho de malha 4 na terceira iteração.

- 2.4 Se o ponto P_{atual} é menor do que todos os pontos da malha $M_j; j = 1, \dots, N$; verificar se algum critério de parada foi atendido. Caso atendido, então o ponto solução P_{sol} e seu valor calculado na função objetivo são emitidos. Caso contrário, os próximos passos são seguidos.
- 2.5 Nesta etapa, primeiramente contrair o vetor padrão $\iff \eta_{\text{cont}} \Delta \vec{x}_j, j = 1, \dots, n$; somando este vetor resultante ao ponto atual $P_{\text{atual}}(x_{\text{atual}}, j = 1, \dots, N)$ e, finalmente, criar uma nova malha neste ponto $P_{\text{atual}}, M_j \iff x_{\text{atual}} + \Delta \vec{x}_j$ e ir para o passo 2.1.

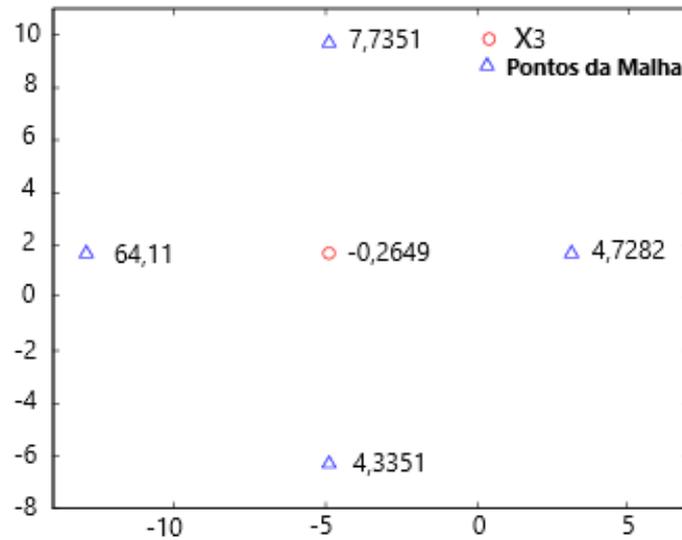
Como exemplo neste passo, considere que o algoritmo encontra-se na quarta iteração e o ponto atual seja $x_3 = [-4,9 \ 1,7]$. O tamanho da malha é 8 (quarta expansão), então a malha consiste nos pontos:

- $8[1 \ 0] + x_3 = [3,1 \ 1,7]$;
- $8[0 \ 1] + x_3 = [-4,9 \ 9,7]$;
- $8[-1 \ 0] + x_3 = [-12,9 \ 1,7]$;
- $8[0 \ -1] + x_3 = [-4,9 \ -1,3]$.

A Figura 38 a seguir mostra os pontos de malha e seus valores de função objetivo.

Nesta iteração, nenhum dos pontos de malha tem um valor de função objetivo menor

Figura 38 – Valores da função objetivo em x_3 e nos pontos da malha formada.



Fonte: adaptado de (MATHWORKS®, 2020)

que o valor em x_3 . Portanto, a pesquisa não obteve sucesso. Nesse caso, o algoritmo não altera o ponto atual na próxima iteração, isso é, $x_4 = x_3$.

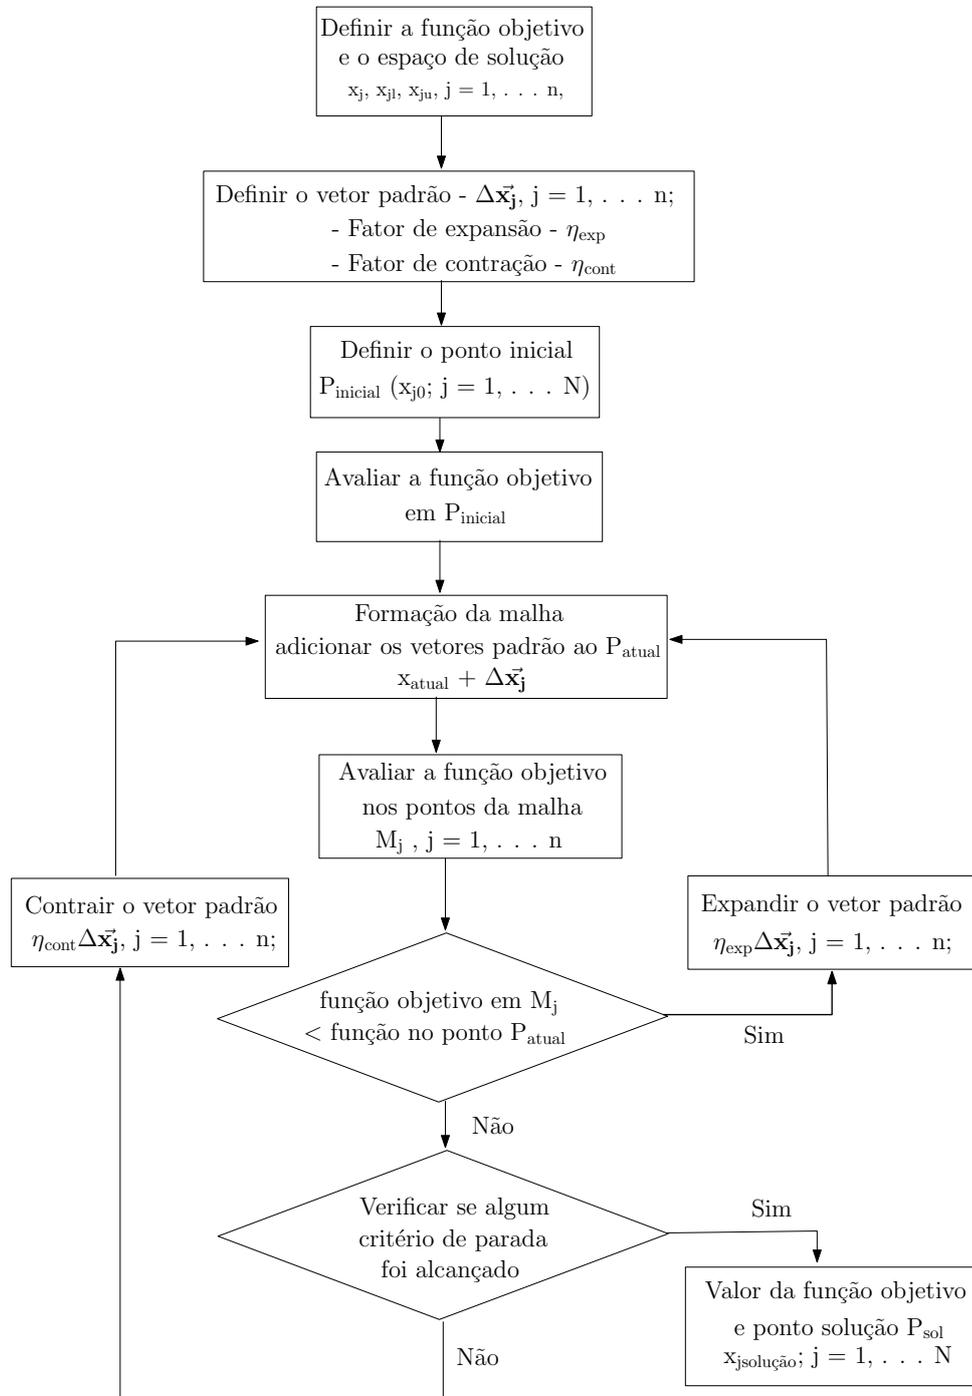
Na próxima iteração, o algoritmo multiplica o tamanho da malha atual por um fator de contração, por exemplo 0,5, para que o tamanho da malha na próxima iteração seja 4. Logo, o algoritmo reinicia o processo de pesquisa com um tamanho de malha menor.

- Os seguintes critérios podem ser usados para finalizar a execução do algoritmo: i) tolerância da malha, que é a tolerância mínima para o tamanho da malha; (ii) número máximo de iterações, que é o número máximo de iterações que o algoritmo executa; (iii) número máximo de avaliações da função objetivo; (iv) tempo limite, tempo máximo em segundos que o algoritmo é executado antes de parar; e finalmente (v) tolerância da função, no qual representa que o valor mínimo da função objetivo foi alcançado.

O fluxograma do algoritmo de Busca Generalizada por Padrões (GPS) é apresentado na Figura 39. De acordo com o fluxograma, o algoritmo pode ser dividido em três etapas principais: definições, processo de busca pelo ótimo e parada.

O algoritmo Busca Generalizada por Padrões (GPS) combina duas operações chamadas de movimentos exploratórios e movimentos padrão que foram inicialmente propostas no algoritmo de (HOOKE; JEEVES, 1961). Essas operações podem ser consideradas estratégias para o algoritmo avançar na busca pelo ponto ótimo (MØLLER, 2016). Conforme visto no algoritmo da Figura 39, através do ponto inicial ($P_{inicial}$), o algoritmo realiza movimentos exploratórios

Figura 39 – Fluxograma do algoritmo de Busca Generalizada por Padrões (GPS).



Fonte: adaptado de (GüNEŞ; TOKAN, 2010)

para analisar o espaço de busca (malha) que foi formada em torno do ponto. Caso um melhor valor para a função objetivo for encontrado durante os movimentos exploratórios, o algoritmo realiza um movimento padrão na direção bem-sucedida.

Os algoritmos Busca por Conjunto Gerador (*Generating Set Search - GSS*) (LEWIS; SHEPHERD; TORCZON, 2007) e Busca Direta com Malha Adaptável (*Mesh Adaptive Search - MADS*) (AUDET; DENNIS, 2006) são idênticos ao GPS, diferindo apenas na forma como o conjunto vetor padrão é gerado. O GPS utiliza um conjunto do vetor padrão fixo, com as direções de busca na malha também sendo fixas. O GSS é similar ao GPS, mas usa um conjunto de vetor padrão que é gerado de forma diferente do GPS, onde permite que cada movimento de busca pelo ponto ótimo seja feito de maneira independente dos demais. O MADS usa uma seleção de vetores aleatórios para definir o conjunto do vetor padrão, que é modificado a cada nova iteração (KASHANI, 2014). Os algoritmos GPS e GSS são métodos determinísticos, enquanto o MADS é um método estocástico (BENGLARS; VALJAMETS, 2014).

3.4 OTIMIZAÇÃO BASEADA NO ENXAME DE PARTÍCULAS (*PARTICLE SWARM OPTIMIZATION - PSO*)

O algoritmo de Otimização por Enxame de Partículas (*Particle Swarm Optimization - PSO*) foi proposto por (KENNEDY; EBERHART, 1995) e pertence aos algoritmos da classe metaheurística. O algoritmo surgiu através de inspirações no comportamento social e cooperativo demonstrado por várias espécies da natureza, como por exemplo pássaros e peixes. A vantagem de utilizar o PSO é que ele não emprega o cálculo de derivadas ou gradientes no processo de otimização, sendo um método facilmente aplicado a uma série de problemas de otimização (VALLE et al., 2008).

A resolução de um problema por PSO pode ser brevemente explicada pela criação de uma população de soluções candidatas, denominadas de partículas ou indivíduos. Logo após, as partículas são movimentadas em torno do espaço de busca na pesquisa pelo ponto ótimo, de acordo com as equações matemáticas da posição e velocidade da partícula. O movimento de cada partícula é ditado pelas experiências individuais e, como as partículas em uma população se socializam, elas adquirem conhecimentos sobre como seus vizinhos se comportam. Sendo assim, o algoritmo é caracterizado pela aprendizagem individual e social, ou seja, uma partícula da população toma uma decisão relacionando o comportamento de alguns de seus vizinhos e do seu comportamento individual no passado, com o objetivo de mover a população em

direção da melhor solução (AO, 2009).

Nos últimos anos, alguns autores propuseram o uso da técnica PSO para identificação dos parâmetros da célula/módulo FV (DALI; BOUHARCHOUHE; DIAF, 2015b);(YE; WANG; XU, 2009), porém a maioria das abordagens é com modelos em que os parâmetros são estimados para uma única condição ambiental.

3.4.1 Equações da Velocidade e Posição do PSO

No algoritmo PSO, as partículas ou indivíduos de uma população são representados por pontos no espaço R^D . A população inicial (enxame) de tamanho N e dimensão D é denotada como $\mathbf{X} = [X_1, X_2, \dots, X_N]^T$. Cada partícula (indivíduo) X_i ($i = 1, 2, \dots, N$) é dado como $X_i = [X_{i,1}, X_{i,2}, \dots, X_{i,D}]$. Além disso, a velocidade inicial da população é dada por $\mathbf{V} = [V_1, V_2, \dots, V_N]^T$. Sendo assim, a velocidade de cada partícula X_i ($i = 1, 2, \dots, N$) é dada como $V_i = [V_{i,1}, V_{i,2}, \dots, V_{i,D}]$. O índice i varia de 1 a N , enquanto o índice j varia de 1 a D (ALAM, 2016).

Dada uma iteração específica " k ", cada partícula X_i está associada a uma velocidade V_i^k , uma posição X_i^k e uma memória, $P_{best,i}$, da sua melhor posição durante o processo de busca pelo ponto ótimo. As coordenadas da melhor posição de uma iteração atual de toda a população, ou seja, aquela que fornece o menor valor para a função objetivo entre todas as partículas no caso de um problema de minimização, são armazenadas no vetor $G_{best,i}$ (SHI; RC, 1998). A velocidade de cada partícula é calculada a cada iteração de acordo com a Equação 3.2, dada por:

$$V_{i,j}^{k+1} = \omega V_{i,j}^k + c_1 r_1 (P_{best,i,j}^k - X_{i,j}^k) + c_2 r_2 (G_{best,i,j}^k - X_{i,j}^k), \quad (3.2)$$

em que:

- ω - chamado de coeficiente de peso inercial, representa a influência do movimento da própria partícula, fornece uma memória da direção dos movimentos anteriores da partícula;
- $V_{i,j}^k$ - vetor velocidade da partícula i na iteração atual k ;
- c_1 e c_2 - são constantes de aceleração positivas associadas aos fatores de cognição individual e social, respectivamente;

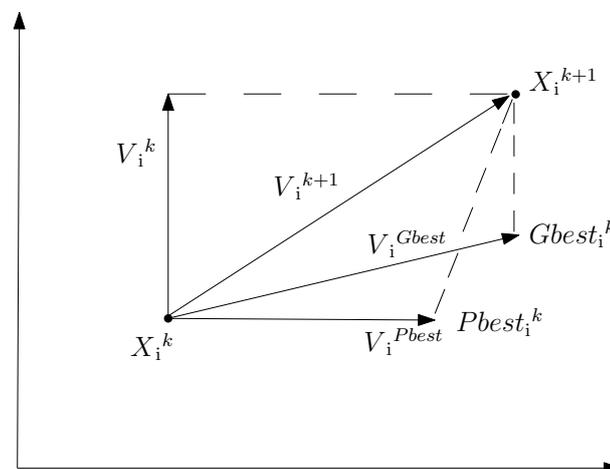
- r_1 e r_2 - são números aleatórios obtidos de uma distribuição uniforme na faixa de $[0,1]$;
- P_{best} - Melhor posição da partícula sob avaliação que gerou melhor valor da função objetivo dentre todas as suas iterações;
- G_{best} - Melhor posição da partícula que gerou melhor valor da função objetivo dentre todos os indivíduos em todas as iterações;
- $X_{i,j}^k$ - posição ou solução da partícula i na iteração k .

O mecanismo de pesquisa do PSO no espaço de busca multidimensional incorpora, na Equação (3.2), os conceitos de (VALLE et al., 2008):

- Inércia ($\omega V_{i,j}$): essa componente está relacionada a memória dos movimentos anteriores da partícula e guia a partícula para a direção que esta vinha apresentando;
- Fator cognitivo individual ($c_1 r_1 (P_{best,i,j}^k - X_{i,j}^k)$): essa componente está relacionada a tendência das partículas de serem atraídas para a melhor posição encontrada por ela durante sua trajetória (memória);
- Fator cognitivo social ($c_2 r_2 (G_{best,i,j}^k - X_{i,j}^k)$): essa componente é responsável por conduzir a partícula para a melhor posição até então encontrada pela população.

A interpretação vetorial para o mecanismo de pesquisa do PSO no espaço multidimensional é representada na Figura 40.

Figura 40 – Diagrama vetorial do mecanismo de busca do PSO.



Fonte: adaptado de (ALAM, 2016)

Calculada a velocidade da partícula, a posição da partícula X_i na iteração seguinte é definida pela adição da posição anterior da partícula com a velocidade calculada, sendo expressa por (SHI; RC, 1998):

$$X_{i,j}^{k+1} = X_{i,j}^k + V_{i,j}^{k+1} \quad (3.3)$$

Ao final de cada iteração k , um valor da função objetivo é calculado para cada partícula. Caso o valor da função objetivo associado a X_i^{k+1} for melhor que o valor da função objetivo de $P_{\text{best}i}$, logo $P_{\text{best}i} = X_i^{k+1}$. Se o valor da função objetivo de X_i^{k+1} for melhor que o valor da função objetivo em $G_{\text{best}i}^k$, o valor de $G_{\text{best}i}^k = X_i^{k+1}$.

3.4.2 Ajuste dos Parâmetros

Em aplicações do algoritmo PSO, deve-se ajustar os parâmetros presentes na Equação 3.2 da velocidade do PSO para que o problema de otimização seja resolvido de forma eficiente. Um ajuste incorreto pode comprometer a precisão da solução no processo de busca pelo ponto ótimo (PERES, 2016).

Inicialmente, deve ser escolhido o número de partículas (N) que forma a população do problema de otimização. Na literatura, não existe uma regra geral que define o tamanho da população, porém seu valor afeta a taxa de convergência (SHI; EBERHART, 1999). O tamanho da população depende muito da natureza do problema, logo uma regra prática bastante utilizada para definir o tamanho da população é executar o algoritmo com uma população pequena e depois aumentar o número. Esse método dará uma idéia do número ideal de partículas. Outra regra bastante utilizada é começar o processo de busca com 10 vezes o número de variáveis do problema. O software MATLAB® 2016a adota essa medida como padrão para o algoritmo PSO.

De acordo com (PERES, 2016), a constante de inércia ω reflete diretamente no processo de busca de ótimo local e global das partículas. Com valor de ω pequeno, o algoritmo PSO é mais apto a realizar buscas por ótimos locais, enquanto um valor de ω alto impulsiona as partículas a realizarem buscas por ótimos globais. A constante de inércia pode ser implementada como um valor fixo ou pode ser variada dinamicamente. Normalmente, $\omega = 0,9$ é considerado um valor alto e $\omega = 0,4$ um valor baixo. A fim de encontrar o ponto ótimo global, a constante de inércia é implementada variando de modo decrescente, pois no processo de otimização uma vez que a região ideal é encontrada, o valor da constante de inércia é reduzido com a finalidade

de restringir a pesquisa em uma região (VALLE et al., 2008).

As constantes de aceleração c_1 e c_2 são responsáveis por controlar o fluxo de informações entre a população e a partícula atual. Se $c_1 > c_2$, a partícula é mais influenciada pelo fator individual, podendo levar a uma convergência lenta do algoritmo; caso contrário, $c_2 > c_1$, as partículas tenderão a seguir a melhor posição global, podendo ocasionar uma convergência prematura do algoritmo (SANTOS, 2018). Usualmente, a literatura recomenda usar c_1 e $c_2 = 2$ com $c_1 + c_2 \leq 4$ de forma a manter o equilíbrio entre a capacidade de busca global e local do algoritmo (KENNEDY; EBERHART, 1995; SANTOS, 2013; SANTOS, 2018).

3.4.3 Algoritmo PSO

A rotina de funcionamento do algoritmo PSO possui a seguinte sequência (ALAM, 2016):

1. Definir a função objetivo $f(x)$ do problema, as variáveis do problema e inicializar os parâmetros do algoritmo;
2. Definir iteração $k = 1$;
3. Definir os parâmetros ω_{\min} , ω_{\max} , c_1 e c_2 ;
4. Definir a população das partículas com posições \mathbf{X} e suas respectivas velocidades \mathbf{V} ;

Observação: Para limitar a velocidade de uma partícula para que o sistema não extrapole o espaço de busca, são impostos limites para seus valores em cada dimensão (D) do espaço de busca.

$$\text{Se } V_i > V_{\max}, \text{ então } V_i = V_{\max}.$$

$$\text{Senão } V_i < V_{\min}, \text{ então } V_i = V_{\min}.$$

O movimento de uma partícula no espaço de busca e os limites das variáveis de otimização que a nova posição X_i^{k+1} está submetida são:

$$\text{Se } X_i^{k+1} > X_{\max}, \text{ então } X_i^{k+1} = X_{\max}.$$

$$\text{Senão } X_i^{k+1} < X_{\min}, \text{ então } X_i^{k+1} = X_{\min}.$$

5. Calcular a função objetivo associada a cada partícula, $F_i^k = f(X_i^k)$, \forall_i ;
6. Para todas as partículas fazer $P_{best,i}^k = X_i^k$, \forall_i e encontrar a melhor posição global G_{best}^k ;
7. Calcular o peso inercial ω , de acordo com a expressão:

$$\omega = \omega_{\max} - k \frac{(\omega_{\max} - \omega_{\min})}{Maxite} \quad (3.4)$$

em que *Maxite* é o número máximo de iterações;

8. Atualizar a velocidade e posição das partículas:
 - 8.1. $V_{i,j}^{k+1} = \omega V_{i,j}^k + c_1 r_1 (P_{best,i,j}^k - X_{i,j}^k) + c_2 r_2 (G_{best,i,j}^k - X_{i,j}^k)$;
 - 8.2. $X_{i,j}^{k+1} = X_{i,j}^k + V_{i,j}^{k+1}$;
9. Avaliar a função objetivo $F_i^{k+1} = f_{(X_i^{k+1})}$, \forall_i , ($i = 1, \dots, N$), e encontrar a posição da melhor partícula b_1 ;
10. Atualizar P_{best} da população \forall_i , ($i = 1, \dots, N$), logo:

$$\text{Se } F_i^{k+1} < P_{best,i}^k, \text{ então } P_{best,i}^{k+1} = X_i^{k+1}, \text{ se não } P_{best,i}^{k+1} = P_{best,i}^k;$$

11. Atualizar G_{best} de toda a população:

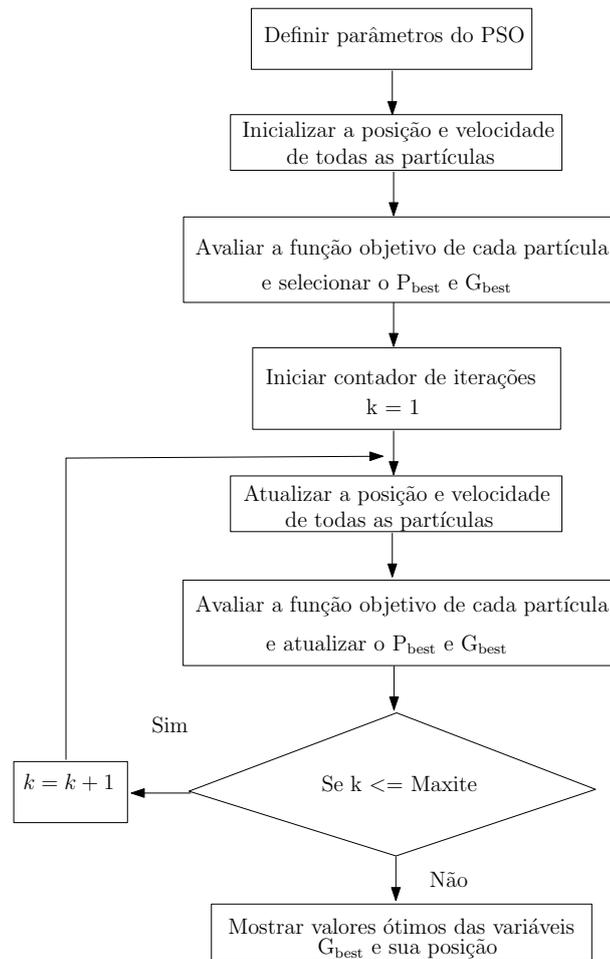
$$\text{Se } F_{b1}^{k+1} < G_{best,i}^k \text{ então } G_{best,i}^{k+1} = P_{best,b1}^{k+1},$$

$$\text{e definir } b = b1 \text{ se não } G_{best,i}^{k+1} = G_{best,i}^k;$$

12. Se $k < Maxite$, então $k = k + 1$, e vá ao passo 7, se não ir para o passo 13;
13. Mostrar a solução ótima G_{best}^k e sua posição e sua posição.

Na Figura 41, é apresentado um fluxograma com os passos do algoritmo PSO.

Figura 41 – Fluxograma do PSO



Fonte: adaptado de (ALAM, 2016)

3.5 OTIMIZAÇÃO BASEADA EM ENXAME DE PARTÍCULAS EVOLUTIVO (*EVOLUTIONARY PARTICLE SWARM OPTIMIZATION - EPSO*)

De forma a evitar as ocorrências do algoritmo PSO convergir para pontos de mínimos locais prematuramente durante o processo de busca pelo ponto ótimo global, foram propostas modificações após a sua introdução por (KENNEDY; EBERHART, 1995). Em (POLI; KENNEDY; BLACKWELL, 2007) e (VALLE et al., 2008), são apresentadas as diversas versões ou variações propostas no algoritmo PSO (AO, 2009). Neste trabalho, será aplicada uma variante do PSO, denominada EPSO (*Evolutionary Particle Swarm Optimization*), no processo de estimação dos parâmetros do modelo global não-linear para módulos FV.

O algoritmo EPSO foi desenvolvido por (MIRANDA; FONSECA, 2002), sendo considerada uma versão híbrida do PSO, pois é uma ferramenta de otimização baseada nos conceitos de Computação Evolucionária (EC - *Evolutionary Computation*) e de Otimização Baseada por

Enxame de Partículas (PSO). De acordo com (MIRANDA; FONSECA, 2002), similarmente ao PSO, o algoritmo EPSO é baseado em um conjunto de partículas, porém o método é visto como um algoritmo evolutivo com auto adaptação, onde a operação de recombinação é substituída por uma nova operação chamada de movimento das partículas. Entretanto, do posto de vista conceitual, o EPSO permite duas interpretações em relação ao seu funcionamento, pois pode ser visto como uma variante do PSO ou uma variante da Computação Evolucionária e essa concepção híbrida tem a vantagem de reunir características positivas de ambos os métodos (LEITE; BARROS; MIRANDA, 2010). Assim, o EPSO agrupa as seguintes características dos dois métodos:

- PSO: a cooperação das partículas (comportamento social) e a memória na busca pelo melhor histórico global (G_{best}) e individual (P_{best}).
- Computação Evolucionária: ação dos operadores de replicação, mutação e recombinação para gerar novas partículas (soluções) no espaço de busca para serem avaliadas e selecionadas as "melhores partículas", ou seja, selecionam as boas características das partículas que conseguem bons resultados no espaço de busca.

Os métodos PSO e EPSO apresentam similaridade em relação a Equação 3.2 do movimento das partículas, pois em uma determinada iteração k , cada partícula da população possui: uma posição (X_i^k), uma velocidade (V_i^k) e uma memória associada aos seus movimentos no espaço de busca caracterizado pelo parâmetro $P_{best,i}$. A diferença básica entre os algoritmos está na inclusão do PSO das operações de seleção e de auto adaptação dos parâmetros (SANTOS, 2018).

As alterações propostas no EPSO podem ser listadas nas seguintes operações (MIRANDA; FONSECA, 2002):

- Replicação: cada partícula é replicada r vezes;
- Mutação: cada partícula sofrerá mudança em seus pesos (w);
- Recombinação: cada partícula após o processo de mutação, gerará um sucessor de acordo com a regra do movimento;
- Avaliação: cada nova partícula será avaliada com a função objetivo do problema;

- Seleção: por meio de algum processo estocástico, as “melhores” partículas irão sobreviver para formar a nova geração.

Portanto, no método EPSO, o conjunto de partículas evolui pelo espaço de busca de acordo com as operações descritas anteriormente. A seleção atuará na manutenção das partículas que possuem maior ou menor valor da função objetivo dependendo da finalidade do problema, ou seja, as mais bem “adaptadas” se sobressairão e se propagarão (SANTOS, 2013).

3.5.1 Equação da Velocidade e Posição do EPSO

Considerando um conjunto de partículas (soluções) como no PSO e uma iteração específica “ k ”, a velocidade das partículas no EPSO é calculada. Dada uma partícula $X_{i,j}^k$, a velocidade e a posição da nova partícula $X_{i,j}^{k+1}$ é dada por:

$$V_{i,j}^{k+1} = \omega_{i1}^* V_{i,j}^k + \omega_{i2}^* (P_{\text{best},i,j}^k - X_{i,j}^k) + \omega_{i3}^* \mathbf{P}(G_{\text{best},i,j}^k - X_{i,j}^k) \quad (3.5)$$

$$X_{i,j}^{k+1} = X_{i,j}^k + V_{i,j}^{k+1}, \quad (3.6)$$

em que:

- ω_{i1}^* - peso associado à inércia, ou seja, a partícula tende a se mover na mesma direção que o movimento anterior;
- ω_{i2}^* - peso condicionado à memória da partícula, ou seja, a partícula é atraída pela sua melhor posição histórica;
- ω_{i3}^* - peso condicionado à cooperação ou troca de informações (a partícula é atraída para a melhor solução encontrada pela população);
- * - este símbolo indica que as variáveis com essa marcação sofrem mutações, ou seja, pode ser compreendida como uma perturbação ou alteração nas variáveis;
- $P_{\text{best},i,j}^k$ - melhor solução encontrada pela partícula em seu histórico de busca pelo ponto ótimo;
- $G_{\text{best},i,j}^k$ - melhor solução encontrada pela população (enxame) em seu histórico de busca pelo ponto ótimo;

- \mathbf{P} - é o fator de comunicação, um parâmetro que induz uma topologia estocástica em estrela para a comunicação entre as partículas. É uma matriz diagonal que influencia todas as dimensões da partícula, contendo variáveis binárias de valor 1 com probabilidade p e valor 0 com probabilidade $(1-p)$. Portanto, a probabilidade p controla a passagem de informações dentro da população;
- $X_{i,j}^k$ - partícula i , na iteração k ;
- $V_{i,j}^k$ - velocidade da partícula i , na iteração k .

Ao avaliar a Equação (3.5) do movimento das partículas no EPSO, observamos semelhanças em relação a Equação (3.2) no PSO. A diferença encontra-se nos pesos ω_{ik}^* , que sofrem mutação obedecendo a:

$$w_{ik}^* = w_{ik}[1 + \tau N(0, 1)], \quad (3.7)$$

em que $N(0,1)$ é uma variável aleatória com distribuição Gaussiana, de média zero e variância unitária, e τ é um parâmetro de controle das mutações ou parâmetro de aprendizagem fixo.

Outra diferença em relação ao PSO clássico, é que o ótimo global G_{best} também sofre mutação. A ideia por trás dessa operação é de orientar o movimento das partículas para uma região em torno da melhor solução da iteração atual (SANTOS, 2018). A melhor solução global G_{best} é aleatoriamente perturbada por:

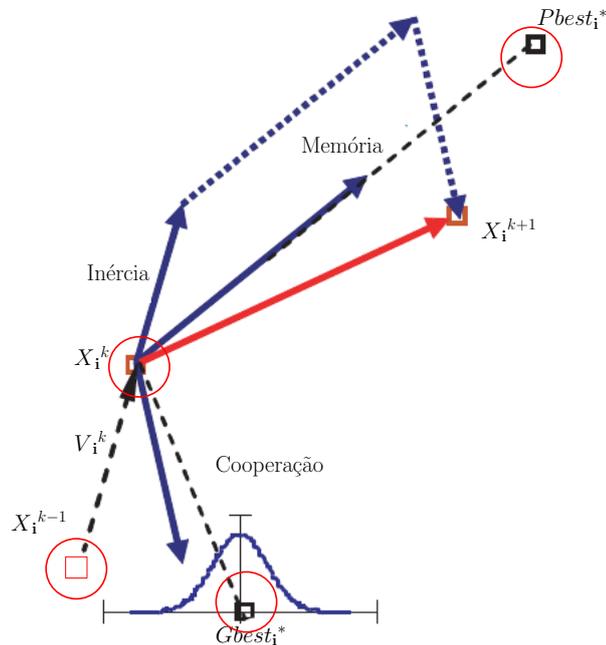
$$G_{best,i,j}^* = G_{best,i,j} + \omega_{i4}^* N(0, 1), \quad (3.8)$$

onde o peso ω_{i4}^* sofre mutação de acordo com a Equação (3.7).

Do ponto de vista da computação evolucionária, o EPSO é um algoritmo evolutivo com auto-adaptação em que a operação recombinação é expressa pela regra do movimento da partícula, ou seja, quatro antecessores geram uma nova partícula como pode ser visto na Figura 42 (LEITE; BARROS; MIRANDA, 2010). Podemos observar que o vetor associado ao fator de cooperação não aponta exatamente para o valor ótimo global $G_{best,i}^*$, mas para uma localização mutada.

A interpretação do EPSO como variante do PSO é explicada pelo movimento executado pela partícula na Figura 42. Inicialmente, em uma iteração k , a partícula encontra-se em X_i^k e movimenta-se em direção a X_i^{k+1} , na iteração $k+1$, sob influência das três componentes: inércia, memória e cooperação, que neste caso, sofre mutação (perturbação) conforme a Equação 3.7.

Figura 42 – Ilustração da regra do movimento no EPSO.



Fonte: adaptado de (JAIN; (EDS.), 2007)

3.5.2 Ajuste dos Parâmetros

Conforme visto na seção anterior, o método EPSO possui característica de auto adaptação de seus parâmetros, pois realiza o processo de mutação e seleção de parâmetros estratégicos (MIRANDA; FONSECA, 2002). Porém, para execução do processo de busca pelo algoritmo, é necessária a definição de apenas dois parâmetros. Inicialmente, deve-se escolher o número de partículas (N) que forma a população e o parâmetro de aprendizado ou parâmetro estratégico (τ) que controla a taxa das mutações.

O valor do tamanho da população (N) depende da natureza do problema, logo os mesmos requisitos para definição utilizados no PSO são aplicados ao EPSO. Já o valor de (τ) é tipicamente baixo, usualmente valores por volta de 0,001 (Leite; Barros; Miranda, 2009; MARTINS, 2013).

3.5.3 Algoritmo

A rotina de funcionamento do algoritmo EPSO possui a seguinte sequência:

1. Definir a função objetivo $f(x)$ do problema, as variáveis do problema e inicializar os

parâmetros do algoritmo;

2. Definir iteração $k = 1$;
3. Definir a população das partículas com posições X_i^k e suas respectivas velocidades V_i^k , dentro dos limites estabelecidos;
4. Adicionar os pesos iniciais a um vetor de pesos $w_i^k \leftarrow [w_i^1, w_i^2, w_i^3, w_i^4]$;
5. Calcular a função objetivo associada a cada partícula, $F_i^k = f(X_{(i)})^k, \forall_i$;
6. Selecionar $P_{\text{best},i}^k = X_i^k, \forall_i$ e a melhor posição global $G_{\text{best},i}^k = X_b^k$;
7. Para todas as partículas X_i^k , criar clones das posições $X_i^k \rightarrow X_{ic}^k$ e da sua velocidade $V_i^k \rightarrow V_{ic}^k$.
Criar clone dos pesos $w_i^k \rightarrow w_{ic}^k$;
8. Realizar mutação dos pesos dos clones w_{ic}^k ;
9. Atualizar a velocidade V_{ic}^{k+1} e testar a viabilidade do clone e atualizar a posição X_{ic}^{k+1} e testar a viabilidade do clone;
10. Atualizar a velocidade V_i^{k+1} e testar a viabilidade da população progenitora corrente .
Atualizar a posição X_i^{k+1} e testar a viabilidade da população progenitora corrente;
11. Calcular a função objetivo associada as partículas clonadas;
12. Calcular a função objetivo associada as partículas (população progenitora corrente);
13. Se o valor da função objetivo associada as partículas clonadas for menor que a da função objetivo associada as partículas, substituir:

função objetivo clone_i \rightarrow função objetivo_i

$$X_{ic} \rightarrow X_i;$$

$$V_{ic} \rightarrow V_i;$$

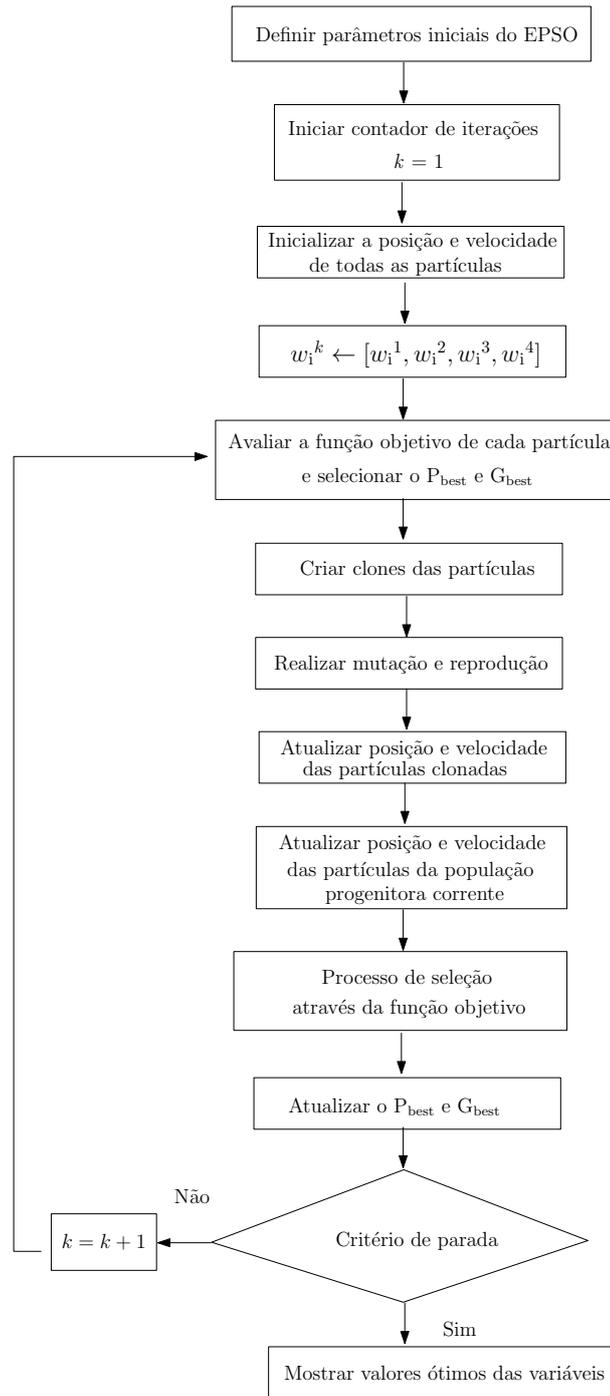
$$w_{ic} \rightarrow w_i;$$

14. Caso o valor da função objetivo for menor que o da melhor posição individual atual, fazer $P_{\text{best},i}^k = X_i^{k+1}$;

15. Encontrar a melhor solução corrente G_{besti}^k .
16. Critério de parada atingido? Se sim, mostrar G_{besti}^k e sua posição; se não ir para o passo 5.

Na Figura 43 é apresentado um fluxograma apresentando os passos do algoritmo EPSO.

Figura 43 – Fluxograma do algoritmo EPSO.



Fonte: O autor (2020)

3.6 CONCLUSÕES

Neste capítulo, foi realizada uma introdução breve aos métodos e processo de otimização, para em seguida, serem apresentados os algoritmos baseados em metaheurísticas, com a finalidade de aplicação no processo de estimação dos parâmetros dos módulos FV. Com isto, foram vistos neste capítulo os algoritmos:

1. Busca por Padrões (*Pattern Search* - PS);
2. Otimização por Enxame de Partículas (*Particle Swarm Optimization* - PSO);
3. Otimização por Enxame de Partículas Evolucionárias (*Evolutionary Particle Swarm Optimization* - EPSO).

A característica principal do algoritmo PS é que, a partir de um ponto inicial estabelecido, a busca pelo ponto ótimo é direcionada através da comparação de valores da função objetivo, ou seja, o PS é uma família de métodos de otimização que não requer a aplicação de gradientes (derivadas) para realizar o processo e busca pela solução ideal (otimização).

O algoritmo PSO é baseado no comportamento social e cooperativo exibido por várias espécies da natureza, onde esses comportamentos são reproduzidos pelo algoritmo na pesquisa pelo ponto ótimo no espaço de busca. Além disso, o PSO é classificado como um método metaheurístico, pois necessita de poucas ou nenhuma informação sobre o problema a ser otimizado. Entretanto, métodos metaheurísticos como o PSO não garantem a convergência para um ponto de mínimo ou máximo global. Em termos gerais, o algoritmo guia-se pela experiência pessoal (P_{best}), experiência geral (G_{best}) e o movimento das partículas na iteração corrente para decidir as posições seguintes no espaço de busca. O PSO resolve um problema de otimização através da definição de uma população de soluções candidatas, também conhecidas como partículas, e movendo estas partículas em torno do espaço de pesquisa, de acordo com equações da posição e velocidade da partícula avaliadas neste capítulo, com o objetivo de mover as partículas em direção da solução ideal.

O algoritmo EPSO envolve os conceitos de Computação Evolucionária (*Evolutionary Computation* - EC) e PSO. Como no PSO, foi visto que o algoritmo EPSO é baseado em um conjunto de partículas que evoluem no espaço de busca tentando encontrar a solução ideal (ótimo), destacando a característica da baixa dependência em relação aos parâmetros para execução do algoritmo, sendo os parâmetros auto adaptáveis.

Devido as naturezas distintas destes três métodos, eles serão aplicados no problema de estimação dos parâmetros dos módulos FV. Sendo avaliado qual é o método mais adequado para este tipo de problema. Sabe-se que diferentes tipos de módulos podem gerar diferentes problemas, logo os métodos serão avaliados para os módulos FV de xSi11246 (tecnologia silício monocristalino), mSi460A8 (tecnologia silício policristalino), HIT05667 (tecnologia silício amorfo), CdTe75368 (tecnologia telureto de cádmio) e CIGS39017 (tecnologia disseleneto cobre, índio e gálio - CIGS).

4 PROCESSO DE ESTIMAÇÃO DE PARÂMETROS DE MÓDULOS FOTOVOLTAICOS E AVALIAÇÃO DOS RESULTADOS APLICANDO OS MÉTODOS DE OTIMIZAÇÃO METAHEURÍSTICOS

Os modelos representativos dos módulos FV possuem inerentemente parâmetros que devem ser determinados para entender o comportamento do módulo sob diferentes condições operacionais. Portanto, com a finalidade de representar corretamente os módulos FV, a estimativa precisa dos parâmetros é crucial. Sendo assim, diversas técnicas de estimação de parâmetros para os modelos de um e dois diodos de módulos FV foram propostos na literatura (KHURSHEED et al., 2019).

Entretanto, na literatura, encontram-se poucos trabalhos que avaliam e levam em consideração os comportamentos físicos dos módulos FV e os efeitos nos parâmetros dos módulos pela temperatura e irradiância. Conforme visto no Capítulo 2, o modelo global não-linear, embora complexo pela quantidade de equações que definem os parâmetros, é um modelo global para a representação de módulos FV, pois as influências da irradiância e temperatura inseridas em seus parâmetros o tornam mais próximo do comportamento físico dos módulos FV reais.

Neste capítulo, é abordada toda a metodologia de estimação de parâmetros para circuito equivalente de um diodo para módulos FV usando o modelo global não-linear proposto por (SILVA, 2019). Primeiramente, são introduzidas as ferramentas básicas do processo de estimação como: obtenção e caracterização das curvas $I-V$ do módulo FV, processo de simulação computacional, definição de erros. Em seguida, defini-se as etapas do processo de estimação dos parâmetros do módulo utilizando os algoritmos PS, PSO e EPSO.

Em seguida, é apresentado a comparação dos resultados da simulação dos métodos de otimização avaliadas no Capítulo 3 aplicadas no processo de estimação dos parâmetros. O estudo comparativo da precisão dos métodos de otimização são aplicados aos módulos fotovoltaicos xSi11246 (tecnologia silício monocristalino), mSi460A8 (tecnologia silício policristalino), HIT05667 (tecnologia silício amorfo), CdTe75368 (tecnologia telureto de cádmio) e CIGS39017 (tecnologia disseleneto cobre, índio e gálio - CIGS). Para a realização do processo de comparação da precisão dos métodos de otimização, as simulações foram realizadas para cada um dos módulos citados anteriormente, utilizando para determinado tipo de módulo FV o mesmo conjunto de curvas $I-V$ e $P-V$ de estimação e após a estimação dos parâmetros, foi avaliado o processo de validação do modelo global não-linear ao aplicar os métodos de otimização estudados. Na validação dos métodos, foi escolhido um conjunto para cada módulo de

seis curvas e avaliado o erro entre as curvas $I-V$ geradas pelo modelo matemático e as curvas $I-V$ experimentais.

4.1 OBTENÇÃO DAS CURVAS $I-V$

A Equação (2.11) descreve o comportamento $I-V$ do modelo de um diodo dos módulos FV, ou seja, caso todos os parâmetros envolvidos na equação do módulo fossem conhecidos, sua curva $I-V$ é completamente definida, nas condições de irradiância e temperatura pré-estabelecidas. Porém, conforme discutido no Capítulo 2, a maioria dos parâmetros da equação sofre alterações, de acordo com as condições ambientais. Por outro lado, os fabricantes de módulos FV fornecem em seus *datasheets* apenas um conjunto de parâmetros relacionado à *STC*, como:

- Tensão nominal de circuito aberto ($V_{oc,STC}$);
- Corrente nominal de curto-circuito ($I_{sc,STC}$);
- Tensão nominal no ponto de máxima potência ($V_{mp,STC}$);
- Corrente nominal no ponto de máxima potência ($I_{mp,STC}$);
- Coeficiente de temperatura de V_{oc} (β);
- Coeficiente de temperatura de I_{sc} (α_i);
- Potência nominal máxima ($P_{max,STC}$).

Nos *datasheets*, os parâmetros intrínsecos não são informados e sequer podem ser visualmente estimados (JUNIOR, 2018).

A análise das curvas $I-V$ dos módulos FV é bastante importante, pois pode ser considerada um certificado de qualidade e desempenho dos módulos FV, permitindo avaliar, com precisão, os parâmetros elétricos de um módulo. Uma das maneiras de identificar falhas em módulos FV é pela avaliação da curva $I-V$ atual com o histórico de curvas $I-V$, identificando o processo degradativo dos mesmos (TRETER; MICHELS, 2018).

Para realizar o processo de estimação dos parâmetros de módulos FV, é necessário ter informações dos pontos de operação (V,I). Nesse contexto, pode-se obter as curvas $I-V$ de

duas maneiras: através dos *datasheets* fornecidos pelos fabricantes de módulos FV, geralmente na condição de *STC*, ou por meio de realização experimental.

As curvas características *I-V* dos módulos FV são obtidas na fase de fabricação dos módulos pelas empresas. No seu processo de fabricação, sempre existem diferenças físicas entre os módulos FV fabricados e devido a diversos fatores, como a degradação com tempo de uso e operação sob condições de sombreamento parcial, as curvas *I-V* dos módulos se distanciam dos valores originais de fábrica. Portanto, é importante testar e obter as características *I-V* dos módulos experimentalmente para definição real de suas características (HOCAOGLU et al., 2018).

4.1.1 Conjunto de Dados Obtidos em *Datasheets*

Em relação ao uso de curvas de *datasheets*, questiona-se o quão precisas são as informações contempladas nestes documentos. Com isto, é adotado como critério de escolha, os *datasheets* cujos fabricantes apresentem alguma "Certificação de Módulos e Serviços Comerciais" (SILVA, 2019). Em (SILVA, 2015), é apresentada uma técnica de extração de curvas de módulos FV que se baseia nas curvas fornecidas pelos *datasheets*, onde foi desenvolvido um algoritmo para conversão das curvas *I-V* dos *datasheets* em pontos *I* e *V* no MATLAB®. Esse método torna-se interessante para aplicação quando não se tem disponível as curvas experimentais dos módulos.

As curvas *I-V* obtidas por *datasheets* com certificação comprovada podem ser aplicadas em estudos de viabilidade, de comparação entre módulos de um mesmo fabricante e comparação entre técnicas de estimação de parâmetros. Entretanto, de um modo geral, a utilização de curvas *I-V* obtidas experimentalmente são mais recomendadas para o processo de estimação de parâmetros e validação de modelos (SILVA, 2019).

4.1.2 Conjunto de Dados Obtidos Experimentalmente

Neste trabalho, para o processo de estimação dos parâmetros do modelo global não-linear do módulo FV foram utilizadas curvas experimentais através de um banco de dados da NREL (*National Renewable Energy Laboratory*) disponível em (Marion et al., 2014). Este conjunto de dados foi coletado com o objetivo de ser utilizado na validação de modelos que estimam o comportamento de módulos FV. Os dados foram coletados no período de um ano, repre-

sentando três climas diferentes (Cocoa, Flórida; Eugene, Oregon; e Golden, Colorado) e para todas as tecnologias de módulos FV disponíveis no ano de 2010.

A temperatura, nebulosidade, vapor de água atmosférico, aerossóis atmosféricos, latitude e altitude são elementos climáticos que variam no tempo e no espaço. Todos esses fatores influenciam o desempenho de módulos FV e os dados medidos para os três locais oferecem diversidade climática para avaliar a sensibilidade dos modelos de módulos FV ao clima.

Os mesmos fabricantes e modelos de módulos FV foram testados em todos os locais mencionados e foram usados sistemas comuns de aquisição de dados com as calibrações realizadas na NREL. De forma a verificar a integridade das medições e dos módulos FV, a NREL realizou medições de desempenho em ambientes internos nas *STC* para cada módulo FV antes e depois da implantação no campo. Depois da implantação, foram coletadas medições mais extensas para fornecer dados em potencial submetidos à validação de modelos. O laboratório de Teste Solar CFV, Albuquerque, Novo México, mediu as características de temperatura e de irradiância conforme a IEC 61853 e os coeficientes de temperatura conforme a IEC 61215 e a IEC 61646.

4.2 INTRODUÇÃO AO PROCESSO DE ESTIMAÇÃO DE PARÂMETROS DE MÓDULOS FOTOVOLTAICOS

Ao analisarmos o modelo de um diodo para representação dos módulos FV da Figura 20 e a Equação (2.11), depara-se com o problema de determinação de cinco parâmetros: corrente fotogerada (I_g), corrente de saturação (I_{sat}), fator de idealidade (A), resistência série (R_s) e resistência em paralelo (R_p). O problema torna-se ainda mais complexo quando utilizamos então o modelo global não-linear para representação do módulo FV conforme apresentado no Capítulo 2, pois agora há uma quantidade maior de parâmetros a serem estimados.

Após a realização do processo de estimação dos parâmetros do modelo global não-linear do módulo FV, isto é, estando de posse de todos os valores de parâmetros estimados, é possível representar o comportamento do módulo (traçar curvas características $I-V$). Porém, devido a natureza transcendental da Equação 2.11, isto é, não ser possível isolar I em função de V , são necessárias ferramentas computacionais para obter a corrente I em função da tensão V ou vice-versa (DONGUE; NJOMO; EBENGAI, 2013). Métodos numéricos são exemplos de ferramentas para a resolução desse equacionamento. Em (SILVA, 2015), mostra-se que uma boa solução para resolver esta equação é a utilização da técnica de Newton-Raphson, que tem o objetivo

de estimar as raízes de uma função através da expressão:

$$x^{k+1} = x^k - \frac{f(x)^k}{f'(x)^k}. \quad (4.1)$$

Onde x^k é uma aproximação inicial dada, k indica a k -ésima iteração do algoritmo e $f'(x)^k$ é a derivada da função f em x^k . Repetindo-se o processo de cálculo de (4.1), cria-se um método iterativo para encontrarmos a raiz da função. Sendo assim, a convergência do método é garantida para um intervalo específico $[a,b]$ contendo a raiz de $f(x)$, desde que $f(x)$ e $f'(x)$ sejam contínuas nesse intervalo e que $f(\alpha) = 0$, em que α é a raiz de $f(x)$ (REIS, 2018).

Logo, a partir da Equação (2.11), é formulada uma nova função, dada por

$$I = f(I) \longrightarrow g(I) = f(I) - I = 0. \quad (4.2)$$

Então, usando o método de Newton-Raphson para encontrar o zero dessa função, tem-se

$$I^{k+1} = I^k - \frac{g(I)^k}{g'(I)^k}, \quad (4.3)$$

onde, no processo de estimação das raízes, é importante escolher uma aproximação inicial para esta, sendo que quão mais próximo da solução o valor inicial for, mais rápida é a convergência. Em (SILVA, 2015), foi definida uma tolerância de $|I^{k+1} - I^k| \leq 1\mu A$ como critério de parada do método, ou seja, quando I^{k+1} estiver convergindo, $g(I^{k+1}) \approx 0$. A escolha desse valor de parada permite garantir a convergência do algoritmo para um valor correto de corrente. Em relação ao valor do passo de tensão para reproduzir a curva I - V , foi adotado, por convenção, um valor de 10 mV, mas qualquer outro valor poderia ter sido adotado.

Para a geração dos pontos I - V do modelo do módulo FV, é necessário o fornecimento de valores de tensão e um valor inicial de corrente para que o modelo funcione de forma adequada. Para a corrente, é considerado um valor inicial igual à corrente de curto-circuito (I_{sc}) e $V=0$ e, logo após, os próximos valores de corrente são calculados a partir de valores de corrente que convergiram nas iterações anteriores. Já para a tensão, foi criado um vetor linearmente espaçado de 0 a V_{oc} , com incrementos de 10 mV.

Nas próximas subseções, são avaliadas as ferramentas para compreender o processo de estimação de parâmetros dos módulos FV utilizando o modelo global não-linear. Este modelo, foi escolhido por representar o módulo FV de forma mais aproximada do módulo FV real, pois os efeitos da irradiância e da temperatura agora estão incluídos nos parâmetros intrínsecos do módulo, característica não presente na grande parte dos métodos da literatura. Outro motivo pela sua preferência está no fato do mesmo eliminar as limitações das técnicas de estimação de

parâmetros de módulos FV existentes na literatura, dentre as quais se destaca a necessidade de terem que ser executadas a cada mudança das condições ambientais, conforme visto nas análises realizadas em (SILVA, 2015) e (SILVA, 2019), acarretando em um novo conjunto de parâmetros elétricos, a cada nova condição de irradiância e temperatura.

4.3 FORMULAÇÃO DO PROBLEMA DE OTIMIZAÇÃO

O processo de estimação dos parâmetros do modelo de um módulo FV pode ser transformado em um problema de otimização que será executado por cada um dos métodos de otimização apresentados no Capítulo 3. Para compreender a formulação do problema de otimização é necessário primeiramente definir os erros.

4.3.1 Definição dos Erros

Conforme discutido no Capítulo 2, o modelo global não-linear para módulos FV pode ajudar a prever as características $I-V$ e $P-V$ dos módulos para qualquer condição de irradiância e temperatura. Para isso, é necessário obter parâmetros para o modelo que garantam que os erros de potência e corrente calculados entre o modelo e o módulo FV sejam pequenos. Por este motivo, surgem os conceitos de erro absoluto em potência e o desvio médio quadrático da corrente adotados em (SILVA, 2015; JUNIOR, 2018), que permitem a comparação entre as curvas $I-V$ geradas pelo modelo matemático e as curvas $I-V$ reais (obtidas por experimento).

O erro absoluto em potência para um ponto de operação específico é calculado por:

$$erro_{abs} = | P_{curvareal} - P_{modelo} |, \quad (4.4)$$

em que $P_{curvareal}$ é o produto de V e $I_{curvareal}$, do par obtido a partir da curva $I-V$ real e P_{modelo} é o produto de V e I_{modelo} , do par $I-V$ obtido a partir da simulação do modelo elétrico com os parâmetros estimados por um método específico no ponto V .

Deste modo, o erro médio absoluto em potência ($EMAP$) pode ser calculado pela seguinte expressão:

$$EMAP = \frac{\sum_{j=1}^{N_{pontos}} erro_{abs}}{N_{pontos}}, \quad (4.5)$$

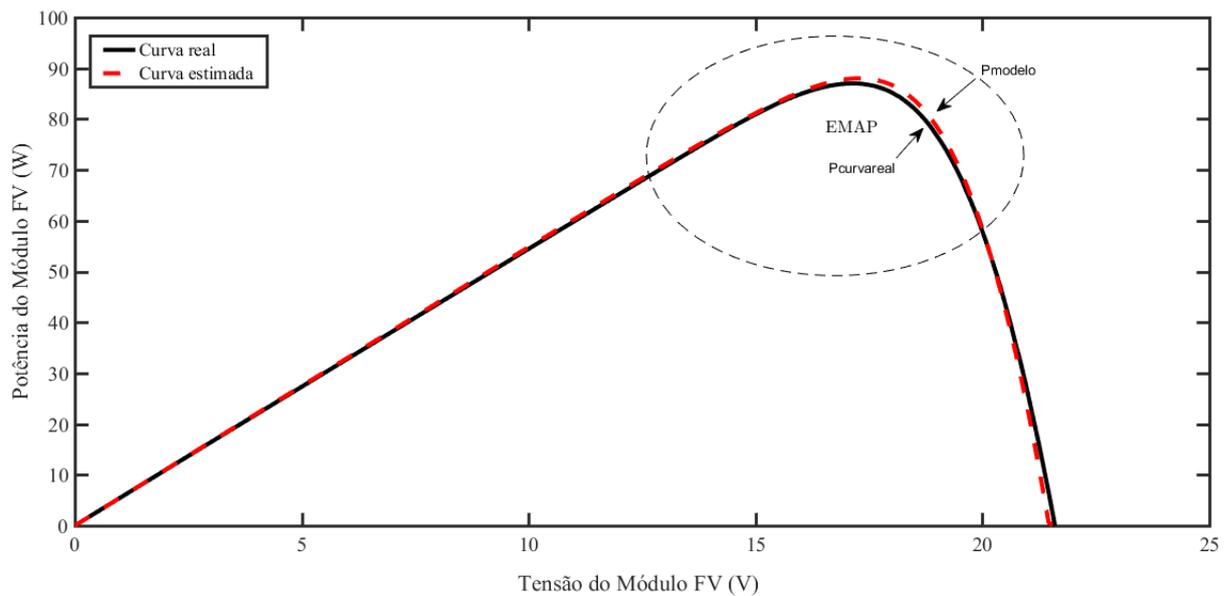
em que $erro_{abs}$ é calculado para todos os pontos de tensão da curva $I-V$ ou $P-V$, iniciando em zero até a condição de circuito aberto, V_{oc} , e N_{pontos} é o número total de pontos da curva real $I-V$ ou $P-V$ do módulo FV.

Em (SILVA, 2019), com a proposta de uniformizar os erros em potência, de modo que dois ou mais módulos FV possam ser comparados, é definido o *EMAP* normalizado (*EMAPN*), sendo calculado por

$$EMAPN = \frac{EMAP}{P_{mp}} \cdot 100\%, \quad (4.6)$$

em que P_{mp} representa o ponto de máxima potência do módulo FV. Conforme definido em (SILVA, 2015; Silva et al., 2016), o *EMAP* como parâmetro de avaliação principal pode ser entendido através da Figura 44. Por ser calculado em termos do erro absoluto em potência, há uma tendência de apresentar maior importância para regiões onde o $erro_{abs}$ tende a ser maior, geralmente na região de máxima potência, onde os sistemas FV operam a maior parte do tempo.

Figura 44 – Região de maior importância do EMAP.



Fonte: adaptado de (SILVA, 2015).

Outros critérios utilizados para comparar os métodos avaliados neste trabalho são: o desvio médio quadrático da corrente (*Root Mean Square Deviation - RMSD*) e o desvio médio quadrático da corrente normalizado (*NRMSD*) (Mahmoud; Xiao; Zeineldin, 2013). Ambos relacionam a corrente FV gerada pelo modelo, I_{modelo} , ao valores medidos, $I_{\text{curvareal}}$, e podem ser expressos por:

$$RMSD = \sqrt{\frac{\sum_{j=1}^{N_{\text{pontos}}} (I_{j\text{curva}} - I_{j\text{modelo}})^2}{N_{\text{pontos}}}} \quad (4.7)$$

$$NRMSD = \frac{RMSD}{I_{sc}} \cdot 100\%. \quad (4.8)$$

4.3.2 Descrição do Problema de Otimização

Com todos os parâmetros do modelo do módulo FV determinados, através da Equação (2.11), consegue-se produzir uma curva característica I - V do modelo. Porém, o objetivo é escolher o melhor conjunto de parâmetros com base no erro médio absoluto em potência ($EMAP$), que é escolhido como critério para quantificar a diferença entre os resultados produzidos pelo modelo e os resultados experimentais da base de dados da NREL (Marion et al., 2014), isto é, o problema de otimização tem por finalidade minimizar uma função objetivo baseada no $EMAP$.

Nesse caso, o processo de estimação dos parâmetros é dividido em etapas. Onde, primeiramente escolhe-se uma curva I - V de referência, geralmente na STC ou próximo, para estimar os parâmetros de referência do modelo. Em seguida, um conjunto de curvas, denominado conjunto de estimação, com valores distintos de S e T é utilizada para a estimação dos parâmetros restantes do modelo.

Com o modelo do módulo FV totalmente definido através da estimação dos parâmetros, escolheu-se neste trabalho um conjunto de curvas com valores de S e T distintos do conjunto de estimação, responsáveis por validar a capacidade do modelo. Para isso, foi reproduzido pelo modelo cada uma dessas curvas e comparada a cada uma das curvas de validação, através do $EMAP$. Para avaliação do melhor método de otimização aplicado a determinada tecnologia, considera-se o método que reproduziu o menor $EMAP_{med}$ do conjunto de curvas reproduzidas pelo modelo.

4.4 PROCESSO DE ESTIMAÇÃO DOS PARÂMETROS DO MODELO GLOBAL NÃO-LINEAR

De acordo com (SILVA, 2019), o algoritmo que realiza o processo de estimação dos parâmetros do módulo FV baseado no modelo global não-linear é dividido em três etapas:

- 1ª Etapa
 - É fornecida como entrada uma curva I - V de referência, em condição ambiental de referência (geralmente a STC ou próximo);

- Os dados de saída obtidos serão: R_{pref} , A_{ref} , $I_{sc,ref}$ e $V_{oc,ref}$.
- 2ª Etapa
 - São fornecidas como entradas todas as curvas $I-V$ do conjunto de estimação (ou otimização);
 - Os dados de saída obtidos serão: α_i , β_S e β_T .
- 3ª Etapa
 - São fornecidas como entradas todas as curvas $I-V$ do conjunto de estimação;
 - Os dados de saída obtidos serão: R_{sref1} , R_{sref2} , k_{Rs} , k_{Rp} , γ_{Rs} e γ_{Rp} .

As equações (2.20) - (2.26) que descrevem o modelo global não-linear são reescritas, com as indicações das etapas nas quais os parâmetros são determinados:

Desta forma, dois parâmetros são determinados somente observando a curva de referência da 1ª etapa ($I_{sc,ref}$ e $V_{oc,ref}$), onze parâmetros são efetivamente estimados via processo de otimização (R_{pref} , A_{ref} , α_i , β_S , β_T , R_{sref1} , R_{sref2} , k_{Rs} , k_{Rp} , γ_{Rs} , γ_{Rp}) e dois parâmetros (I_g e I_{sat}) são calculados após a determinação dos outros parâmetros.

4.4.1 1ª Etapa - Definição dos Parâmetros Vinculados à Curva de Referência

Na primeira etapa, são definidos os parâmetros vinculados à curva $I-V$ escolhida como referência do modelo global não-linear, ou seja, no conjunto de equações que descrevem o modelo, quatro parâmetros com índice "ref" são obtidos. O ponto de partida para a definição dos parâmetros desta etapa é a inserção, como dado de entrada, de uma curva $I-V$ adotada como referência (geralmente essa curva representa as condições médias de irradiância e temperatura do conjunto de curvas de estimação ou a condição *STC*).

Assim sendo, a primeira etapa é processada da seguinte forma:

- 1 Definir as constantes do módulo FV, k , q e N_s (encontradas no *datasheet* do fabricante).
 - 2 Entrar com os dados da curva $I-V$ de referência. São definidos S_{ref} e T_{ref} associados à curva de referência e os seus pontos (I, V).
- Observação: neste trabalho, foi adotado, como critério de escolha, a curva de referência que representa o valor médio das condições de irradiância e temperatura;

$$R_s = R_{sref2} [1 + k_{Rs}(T - T_{ref})] + R_{sref1} \left(\frac{S}{S_{ref}}\right)^{\gamma_{Rs}} \quad (2.20)$$

$$R_p = R_{pref} [1 + k_{Rp}(T - T_{ref})] \left(\frac{S}{S_{ref}}\right)^{\gamma_{Rp}} \quad (2.21)$$

$$A = A_{ref} \quad (2.22)$$

$$I_{sc} = [I_{scref} + \alpha_i(T - T_{ref})] \left(\frac{S}{S_{ref}}\right) \quad (2.23)$$

$$V_{oc} = V_{ocref} + \beta_T(T - T_{ref}) + \beta_S V_t \ln\left(\frac{S}{S_{ref}}\right) \quad (2.24)$$

$$I_g = I_{sc} \left(1 + \frac{R_s}{R_p}\right) \quad (2.25)$$

$$I_{sat} = \frac{I_g - \frac{V_{oc}}{R_p}}{e^{\frac{V_{oc}}{V_t}} - 1} \quad (2.26)$$

- 3 A partir dos pontos da curva I - V de referência, definir os valores de $I_{sc,ref}$, $V_{oc,ref}$, V_{mp} e I_{mp} .
- 4 Calcular os valores da resistência série máxima ($R_{s,max}$) e da resistência paralela mínima ($R_{p,min}$), usando:

$$R_{s,max} = \frac{(V_{oc,ref} - V_{mp})}{I_{mp}}. \quad (4.9)$$

$$R_{p,min} = \frac{V_{mp}}{(I_{sc} - I_{mp})}. \quad (4.10)$$

- 5 Definir a função-objetivo baseada no *EMAP* (Equação (4.5)) e:

- Especificar o ponto de partida (inicial) do processo de otimização - $X_o = [R_{so}; R_{po}; A_o]$. Como o método PS é dependente de um ponto inicial quando aplicado para resolver

problemas de otimização, como é o caso deste problema, em (SILVA, 2019) recomenda-se utilizar como ponto inicial (X_o), o resultado obtido de outro método previamente simulado.

- Dado o vetor de variáveis a serem estimadas, $X = [R_s, R_p, A]$, especificar o limite inferior de busca - $LB = [0; R_{pmin}; 1]$.
- Dado o vetor de variáveis a serem estimadas, $X = [R_s, R_p, A]$, especificar o limite superior de busca - $UB = [R_{smax}; 10k\Omega; 2]$.

6 . Definir o método de otimização (PS, PSO e EPSO), descrito no Capítulo 3. De acordo com as condições do processo de otimização, o método escolhido deve ser mantido nas três etapas.

- Ao aplicar o método de otimização escolhido nas condições estabelecidas no item 5, o ponto inicial X_o define os valores de I_g , V_t e I_{sat} , conseguindo assim, completar os termos da Equação (2.11) que é resolvida através do método descrito pela Equação 4.1. Assim, para o ponto inicial X_o , são calculados todos os valores de corrente correspondentes da curva $I-V$ do modelo. Calcula-se, então, todos os pontos de potência do modelo (P_{modelo}), baseados na corrente do modelo (I_{modelo}) e na tensão de operação (V);
- Com as definições dos pontos de potência do modelo (P_{modelo}), é então, calculado o erro absoluto de potência de cada ponto e o *EMAP* da curva de referência. Em seguida, o método de otimização começa a buscar um vetor X (conjunto de valores), que produza o menor valor possível do *EMAP*, ou seja, a curva $P-V$ do modelo mais próxima possível da curva $P-V$ de referência (experimental);

7 Após a finalização do processo de otimização, os dados de saída são: R_{sref} , R_{pref} , A_{ref} , $I_{sc,ref}$ e $V_{oc,ref}$;

4.4.2 2ª Etapa - Definição das Expressões de I_{sc} e V_{oc}

Na segunda etapa, são obtidos os parâmetros (α_i , β_s e β_T). A estimação desses parâmetros é dividido em duas etapas, primeiramente estima-se, α_i , e em seguida β_s e β_T). Esses parâmetros, junto com os parâmetros $I_{sc,ref}$ e $V_{oc,ref}$ obtidos da curva de referência da primeira etapa, definem as expressões de I_{sc} e V_{oc} para extrapolação de seus valores para quaisquer condições

ambientais, conforme a Equação (2.23) e (2.14). O processo de obtenção dos parâmetros da segunda etapa é caracterizado por:

- 1 Definir um conjunto de curvas $I-V$ (ou $P-V$), denominado conjunto de estimação, de forma a englobar uma boa variação de irradiação e temperatura;
 - Observação: de acordo com o estudo de sensibilidade realizado em (SILVA, 2019), utilizando até cinco curvas no conjunto de estimação, existem erros elevados em todos os parâmetros. Porém, a partir de um conjunto de estimação de seis curvas, os erros dos parâmetros se tornam baixos. Portanto, nas simulações realizadas neste trabalho, ficou definido o número mínimo de seis curvas de estimação, pois quanto maior o número de curvas, maior será o custo computacional no processo de determinação dos parâmetros.
- 2 Definir a função-objetivo baseada no somatório do erro absoluto ($erro_{abs}$) das curvas de estimação, calculado entre a corrente $I_{sc,modelo}$ do modelo e a corrente real $I_{sc,real}$, obtida das curvas de estimação:

$$\sum_{n=1}^{N_c} erro_{abs} = \sum_{n=1}^{N_c} | I_{sc,mod} - I_{sc,real} |. \quad (4.11)$$

Na estimação de $X_o=[\alpha_i]$ deve-se:

- Especificar o limite inferior de busca - $LB = [1 \cdot 10^{-4}]$.
 - Especificar o limite superior de busca - $UB = [1 \cdot 10^{-2}]$.
 - Especificar o ponto de partida (inicial) do processo de otimização - $X_{o,lsc} = [\text{fornecido pelos } datasheets]$.
- 3 Aplicar o mesmo método de otimização (PS, PSO e EPSO) da primeira etapa de acordo com as condições do item anterior;
 - Ao aplicar o método de otimização escolhido nas condições estabelecidas no item 2, o ponto inicial $X_{o,lsc}$ e a curva de referência (S_{ref} e T_{ref}) definem a Equação (2.23), onde é permitido calcular a corrente de curto-circuito para qualquer condição de irradiação e temperatura. O método de otimização então carrega todas as curvas de estimação e realiza o cálculo da corrente de curto I_{sc} para cada uma das curvas de estimação, comparando através do erro absoluto a diferença entre $I_{sc,modelo}$ e $I_{sc,real}$. O método

busca então um valor de $X_{Isc} = [\alpha_i]$ que provoca o menor somatório dos erros entre os valores calculados e os valores das curvas de estimação carregadas.

Nesta etapa, ocorre também a estimação de $(\beta_s$ e $\beta_T)$ em processo similar ao descrito anteriormente, conforme a sequência descrita a seguir.

- 1 Definir a função-objetivo baseada no somatório dos erro absoluto ($erro_{abs}$) das curvas de estimação, Equação (4.8), calculado entre a tensão de circuito aberto $V_{oc,modelo}$ do modelo e a tensão de circuito aberto real $V_{oc,real}$, obtida das curvas de estimação:

$$\sum_{n=1}^{N_c} erro_{V_{oc}} = \sum_{n=1}^{N_c} | V_{oc,mod} - V_{oc,real} |. \quad (4.12)$$

- Dado o vetor das variáveis a serem estimadas $X = [\beta_s, \beta_T]$, especificar o limite inferior de busca - $LB = [-1, 0]$.
 - Dado o vetor das variáveis a serem estimadas $X = [\beta_s, \beta_T]$, especificar o limite superior de busca - $UB = [1 \cdot 10^{-3}, 2]$.
 - Especificar o ponto de partida (inicial) do processo de otimização - $X_{o,V_{oc}} =$ [fornecido pelos datasheets].
- 2 Aplicar o mesmo método de otimização (PS, PSO e EPSO) da primeira etapa de acordo com as condições do item anterior;
 - Ao aplicar o método de otimização escolhido nas condições estabelecidas no item 2, o ponto inicial $X_{o,V_{oc}}$ e a curva de referência (S_{ref} e T_{ref}) definem a Equação (2.24), onde é permitido calcular a tensão de circuito aberto para qualquer condição de irradiância e temperatura. O método de otimização então carrega todas as curvas de estimação e realiza o cálculo da tensão de circuito aberto V_{oc} para cada uma das curvas de estimação, comparando através do erro absoluto a diferença entre $V_{oc,modelo}$ e $V_{oc,real}$. O método busca então um valor de $X_{V_{oc}} = [\beta_T; \beta_S]$ que provoca o menor somatório dos erros entre os valores calculados e os valores das curvas de estimação carregadas;
 - 3 Após a finalização do processo de otimização, os dados de saída são: α_i , β_T e β_S .

4.4.3 3ª Etapa - Determinação das Expressões Restantes

Definidos os parâmetros R_{pref} , A_{ref} , $I_{sc,ref}$ e $V_{oc,ref}$ na primeira etapa e α_i , β_T e β_S na segunda etapa, na terceira etapa, são obtidos os parâmetros restantes $R_{s,ref1}$, $R_{s,ref2}$, k_{Rs} , k_{Rp} , γ_{Rs} , γ_{Rp} que extrapolam os valores para R_s , R_p , I_g e I_{sat} para todas as condições ambientais.

A terceira etapa segue a mesma lógica de obtenção dos parâmetros das outras etapas, onde neste caso, é realizada uma busca simultânea em um universo de seis parâmetros, de modo a minimizar a função-objetivo. O processo de estimação, é definido por:

- 1 Carregar os valores da primeira etapa.
- 2 Carregar os valores da segunda etapa.
- 3 Carregar as curvas de estimação definidas na segunda etapa.
- 4 Calcular os valores correspondentes de $R_{s,max}$ e $R_{p,min}$, dado nas Equações (4.9) e (4.10).
- 5 Criar os vetores $\gamma_{Rs,vet}$, $\gamma_{Rp,vet}$, $k_{Rs,vet}$ e $k_{Rp,vet}$ que contêm valores estimados destes parâmetros para cada curva de estimação. Faça:
 - Calcule uma estimativa para γ_{Rs} em uma curva $I-V$ específica, obtida através da Equação (2.20), fazendo $k_{Rs} = 0$:

$$\gamma_{Rs} = \log \left(\frac{S}{S_{ref}} \right) \left(\frac{R_s - R_{s,ref2}}{R_{s,ref1}} \right). \quad (4.13)$$

Entretanto, estima-se inicialmente um valor máximo para $\gamma_{Rs,max}$, através da Equação (4.13), substituindo na mesma R_s por $R_{s,max}$, $R_{s,ref2}$ e $R_{s,ref1}$ pela metade de $R_{s,ref}$ respectivamente. Resultando, no seguinte vetor em termos de valores absoluto:

$$\gamma_{Rs,vet} = [abs(\gamma_{Rs,i}), \dots, abs(\gamma_{Rs,Ncurva})] \quad (4.14)$$

- Calcule uma estimativa para γ_{Rp} em uma uma curva $I-V$ específica, obtida através da Equação (2.21), fazendo $k_{Rp} = 0$:

$$\gamma_{Rp} = \log \left(\frac{S}{S_{ref}} \right) \left(\frac{R_p}{R_{p,ref}} \right). \quad (4.15)$$

Entretanto, estima-se inicialmente um valor mínimo para γ_{Rp} , através da Equação (4.15), substituindo na mesma R_p por $R_{p,\min}$. Resultando, no seguinte vetor em termos de valores absoluto:

$$\gamma_{Rs,\text{vet}} = [\text{abs}(\gamma_{Rp,i}), \dots, \text{abs}(\gamma_{Rp,N\text{curva}})]. \quad (4.16)$$

- Calcule uma estimativa para k_{Rs} em uma curva I - V específica, obtida através da Equação (2.20), fazendo $\gamma_{Rs} = 0$:

$$k_{Rs} = \frac{\left(\frac{R_s - R_{s,\text{ref1}}}{R_{s,\text{ref2}}}\right) - 1}{T - T_{\text{ref}}}. \quad (4.17)$$

Entretanto, estima-se inicialmente um valor máximo para $k_{Rs,\max}$, através da Equação (4.17), substituindo na mesma R_s por $R_{s,\max}$, $R_{s,\text{ref2}}$ e $R_{s,\text{ref1}}$ por $R_{s,\text{ref}}$. Resultando, no seguinte vetor em termos de valores absoluto:

$$k_{Rs,\text{vet}} = [\text{abs}(k_{Rs,i}), \dots, \text{abs}(k_{Rs,N\text{curva}})]. \quad (4.18)$$

- Calcule uma estimativa para k_{Rp} em uma curva I - V específica, obtida através da Equação (2.21), fazendo $\gamma_{Rp} = 0$:

$$k_{Rp} = \frac{\left(\frac{R_p}{R_{p,\text{ref}}}\right) - 1}{T - T_{\text{ref}}}. \quad (4.19)$$

Entretanto, estima-se inicialmente um valor mínimo para $k_{Rp,\min}$, através da Equação (4.19), substituindo na mesma R_p por $R_{p,\min}$. Resultando, no seguinte vetor em termos de valores absoluto:

$$k_{Rp,\text{vet}} = [\text{abs}(k_{Rp,i}), \dots, \text{abs}(k_{Rp,N\text{curva}})]. \quad (4.20)$$

- 6 . Determinar os valores limites de γ_{Rs} , γ_{Rp} , k_{Rs} e k_{Rp} , através dos vetores de estimativas destes parâmetros:

- De acordo com o modelo, $\gamma_{Rs} \leq 0$. O estudo de sensibilidade deste parâmetro mostra que valores muito negativos para γ_{Rs} são incoerentes fisicamente (SILVA, 2019), pois o

valor do FF, especificamente em curvas de irradiância baixa, torna-se muito baixo, se distanciando do comportamento da curva $I-V$ na região de máxima potência, resultando em um valor mínimo:

$$\gamma_{R_s, \min} = -\min(\gamma_{R_s, \text{vet}}); \quad (4.21)$$

em que $\gamma_{R_s, \text{vet}}$ é obtido na Equação (4.14).

- De acordo com o modelo, $\gamma_{R_p} \leq 0$. O estudo de sensibilidade deste parâmetro mostra que valores muito negativos para γ_{R_p} são incoerentes fisicamente (SILVA, 2019), porém, o impacto provocado por valores muito negativos no formato das curvas $I-V$ é pequeno, resultando em um valor mínimo:

$$\gamma_{R_p, \min} = -\max(\gamma_{R_p, \text{vet}}); \quad (4.22)$$

em que $\gamma_{R_p, \text{vet}}$ é obtido na Equação (4.16).

- De acordo com o modelo, $k_{R_s} \leq 0$ ou $k_{R_s} \geq 0$. O estudo de sensibilidade deste parâmetro mostra que mesmo para valores altos k_{R_s} , em torno de 1%C, o impacto no FF das curvas $I-V$ é pequeno, resultando assim em uma boa escolha a limite superior e inferior para o valor de k_{R_s} , então

$$k_{R_s, \max} = \min(k_{R_s, \text{vet}}); \quad (4.23)$$

em que $k_{R_s, \text{vet}}$ é obtido na Equação (4.18).

- De acordo com o modelo, $k_{R_p} \leq 0$. O estudo de sensibilidade deste parâmetro mostra que mesmo para valores muito negativos de k_{R_p} , em torno de -9%C, o impacto no FF das curvas $I-V$ é pequeno, resultando assim em uma boa escolha a limite inferior para o valor de k_{R_p} , então

$$k_{R_p, \min} = -\min(k_{R_p, \text{vet}}); \quad (4.24)$$

em que $k_{R_p, \text{vet}}$ é obtido na Equação (4.20).

7 Definir a função-objetivo baseada no erro médio em potência das curvas de estimação, logo:

$$EMAP_{\text{médio}} = \frac{\sum_{n=1}^{N_{\text{curva}}} EMAP_i}{N_{\text{curva}}} \quad (4.25)$$

em que $EMAP_i$ é o valor do EMAP de cada curva e N_{curva} é o número de curvas.

- Dado o vetor de variáveis a serem estimadas, $X = [\gamma_{Rs}, \gamma_{Rp}, k_{Rs}, k_{Rp}, R_{s,ref1}; R_{s,ref2}]$.
 - Especificar o limite inferior de busca - $LB = [\gamma_{Rs,min}, \gamma_{Rp,min}, -k_{Rs,max}, k_{Rp,min}; 0; 0]$.
 - Especificar o limite superior de busca - $UB = [0, 0, k_{Rs,max}, 0, R_{s,ref}, R_{s,ref}]$.
 - Especificar o ponto de partida (inicial) do processo de otimização - $X_o = \frac{(UB+LB)}{2} + LB$;
- 8 Aplicar o mesmo método de otimização (PS, PSO e EPSO) das etapas anteriores de acordo com as condições do item anterior;
- Ao aplicar o método de otimização escolhido nas condições estabelecidas no item 7, o ponto inicial X_o e os valores dos parâmetros obtidos nas etapas anteriores completam os parâmetros das equações que formam o modelo global não-linear. O método busca encontrar o vetor X que gera o menor $EMAP_{\text{médio}}$, conforme a Equação (4.25), ou seja, para todas as curvas (referência e estimação).
- 9 Após a finalização do processo de otimização, os dados de saída: $R_{s,ref1}$, $R_{s,ref2}$, k_{Rs} , k_{Rp} , γ_{Rs} e γ_{Rp} .

4.5 CONDIÇÕES DAS SIMULAÇÕES

As condições de realização das simulações obedeceram as seguintes etapas:

1. A escolha da curva de referência, apresentada na Tabela 2, teve como critério a curva que represente o valor médio de potência dentre as curvas que representam o conjunto de estimação, pois como visto em (SILVA, 2019), a escolha da curva de referência pode ser arbitrária, pois não irá afetar os resultados globais.
2. Um conjunto de curvas de estimação, apresentada na Tabela 3, é selecionada para definição dos parâmetros do modelo global não-linear, onde escolha da faixa de valores

Tabela 2 – Curvas de referências experimentais utilizadas no processo de estimação dos parâmetros

Módulo	Localidade	S(W/m ²)	T (°C)
xSi11246	Golden	754	51
mSi460A8	Cocoa	687	37
HIT05667	Eugene	918	27
CdTe75368	Cocoa	951	47
CIGS39017	Cocoa	640	41

Fonte: O autor (2020)

Tabela 3 – Curvas experimentais (curvas de estimação) utilizadas no processo de estimação dos parâmetros.

Módulos FV									
xSi11246		mSi460A8		HIT05667		CdTe75368		CIGS39017	
S(W/m ²)	T (°C)								
1122	58	1270	36	1121	24	1310	42	1201	43
964	57	1102	40	918	27	1106	40	960	54
754	51	828	35	653	19	951	47	810	47
595	46	687	37	330	16	715	44	720	45
392	43	491	33	247	12	565	33	521	29
283	42	277	29	41	9	356	36	200	24

Fonte: O autor (2020)

de S e T pode ser arbitrária, desde que contenha, no mínimo, três valores distintos de irradiância e temperatura (SILVA, 2019);

- São selecionadas curvas *I-V* diferentes das utilizadas no conjunto de estimação, apresentadas na Tabela 4, para que possam ser comparadas com as curvas *I-V* produzidas pelo modelo global não-linear utilizando os métodos de otimização estudados.

Na próxima seção, são mostrados os resultados comparativos entre os métodos de otimização avaliados aplicados ao modelo do módulo FV referente a cada uma das tecnologias citadas anteriormente. O critério utilizado para avaliação dos métodos foram baseados nos resultados obtidos em relação aos Erros Médio Absoluto em Potência (EMAP), visto que os métodos aplicados possuem o EMAP como função objetivo em cada uma das etapas de estimação dos parâmetros. Desta forma, o método de otimização mais preciso para estimação dos parâmetros é considerado aquele que possui menor valor médio de EMAP do conjunto de curvas de validação. Desta forma, neste trabalho foi realizado a comparação do método PS-EMAP (GPS 2N) padrão (SILVA, 2019) com as outras variantes dos métodos PS, PSO e EPSO.

4.5.1 Critérios de Parada

Para equiparar as condições de simulação no processo de estimação de parâmetros dos métodos avaliados neste trabalho, foram adotados critérios de parada para os algoritmos de maneira que estes tivessem condições aproximadamente idênticas. Desta maneira, como o método padrão PS (GPS 2N) com um número máximo de iterações igual a 1000 atinge a convergência como avaliado em (SILVA, 2019), foi adotado para os demais métodos (PSO e EPSO) o mesmo critério de parada para que as condições de avaliação dos resultados obtidos sejam iguais. Vale ressaltar que, nem todos os métodos avaliados atingem o valor máximo de 1000 iterações, podendo convergir para uma solução antes deste valor limite estabelecido.

4.5.2 Estratégia de Otimização

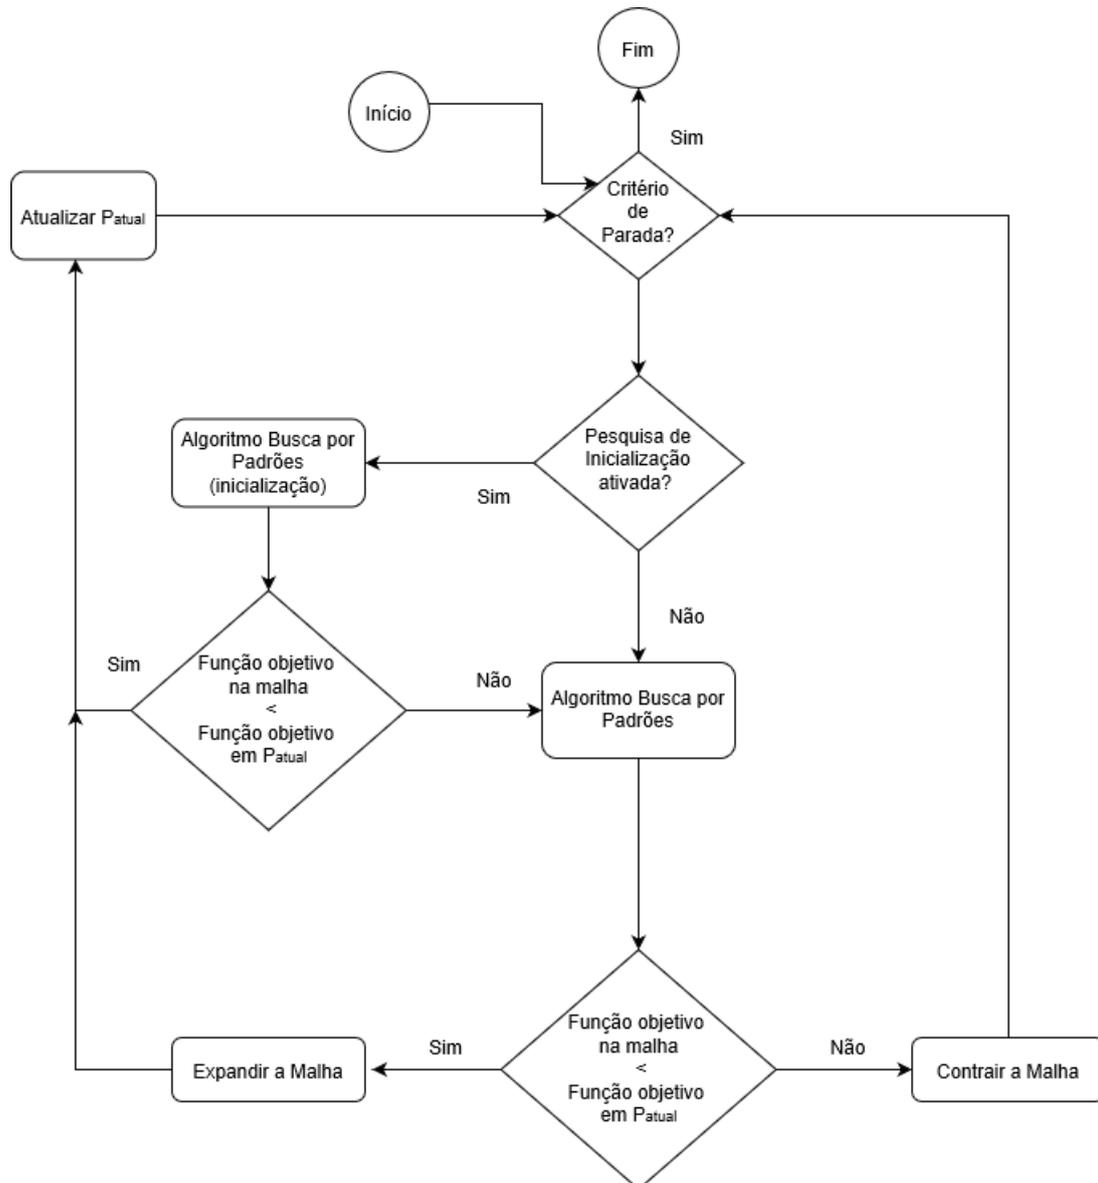
Três métodos de otimização baseado em Busca por Padrões (PS) denominados de algoritmo de Busca Generalizada por Padrões (GPS), algoritmo de Busca de Conjuntos Geradores (GSS) e algoritmo de Busca Adaptativa de Malha (MADS) foram aplicados no processo de otimização de estimação dos parâmetros dos módulos FV. Além de pesquisar os pontos na malha formada como na Figura 39, o algoritmo de Busca por Padrões (PS) pode executar uma etapa opcional a cada iteração, denominada pesquisa de inicialização. A cada iteração, a etapa de pesquisa de inicialização (opcional) aplica outro método de otimização baseado em busca por padrões ao ponto atual. Se esta pesquisa de inicialização não melhorar (minimizar ou maximizar) a função objetivo no ponto atual (P_{atual}), a etapa de busca pelo melhor ponto é realizada apenas com um método PS previamente definido. O método de otimização PS

Tabela 4 – Curvas experimentais utilizadas para validação do processo comparativo entre os métodos de otimização.

Módulos FV									
xSi11246		mSi460A8		HIT05667		CdTe75368		CIGS39017	
(S(W/m ²))	T (°C)	S(W/m ²)	T (°C)						
1085	25	1110	26	1082	25	1236	34	1000	43
825	25	915	25	965	25	1074	28	850	45
685	25	710	25	671	25	929	44	780	43
431	25	517	25	348	25	673	43	600	43
335	25	317	25	248	25	520	24	315	21
234	25	272	25	45	25	420	36	275	34

Fonte: próprio autor.

Figura 45 – Método de Busca por Padrões com algoritmo inicialização.

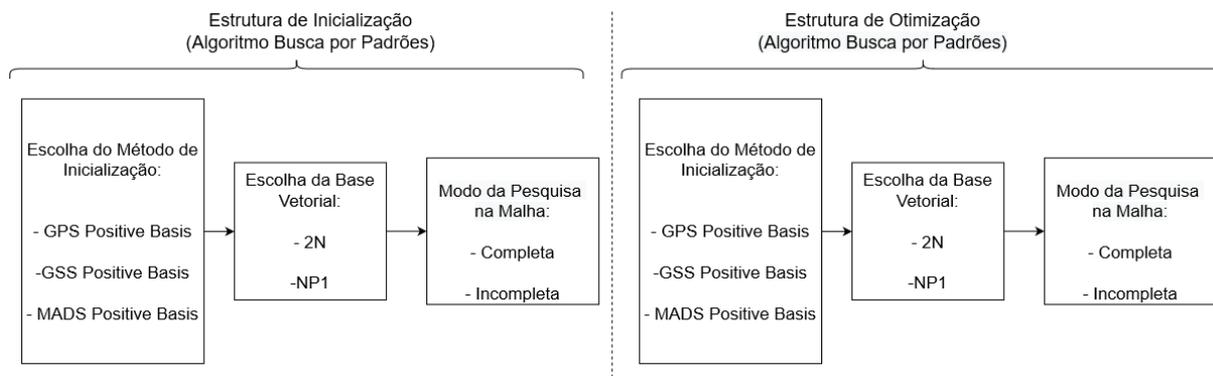


Fonte: adaptado de (MATHWORKS®, 2019b).

com pesquisa de inicialização pode ser visto na Figura 45 e tem por objetivo fazer com que o método obtenha melhores resultados na busca pelo ponto mínimo ou máximo.

A estratégia de otimização do método PS utilizando algoritmo de inicialização consiste portanto na escolha de dois métodos a ser aplicado no algoritmo da Figura 45, conforme ilustrado na Figura 46.

Figura 46 – Definição da estrutura de otimização PS com algoritmo de inicialização.



Fonte: próprio autor.

Sendo assim, ao analisar a estrutura de formação do método PS com algoritmo de inicialização temos um total de 144 configurações de estratégias de otimização. Sem o algoritmo de inicialização, temos um total de 12 configurações de estratégias para aplicação do método PS. Sendo assim, a utilização do método PS, permite um total de 156 configurações para aplicação.

Devido a grande quantidade de configurações a serem comparadas como estratégias de otimização para o método PS e ao notar que muitos valores de $EMAP_{med}$ e $RMSD_{med}$ do conjunto de curvas avaliadas dessas configurações são iguais ou diferem muito pouco, neste trabalho foi adotado o módulo mSi460A8 como referência e conseguiu-se avaliar um total de 84 configurações conforme a Tabela 5 dentre as 156 configurações para aplicação. Essas 84 configurações foram escolhidas por representar uma boa amostra da população de 156 configurações do método PS, em que todos os algoritmos da estrutura de otimização foram avaliados e dando uma boa noção se as estruturas de inicialização aplicadas na estrutura de otimização melhoram ou não os resultados para o método PS.

Para os demais módulos apresentados, foram avaliados um total de 24 configurações de estratégias, apresentadas na Tabela 6. Essas 24 configurações foram escolhidas, por dentre elas estarem todas as variações da estrutura de otimização do método PS (GPS, GSS e MADS), e os algoritmos de inicialização de identidade igual ao da estrutura de otimização escolhida, não sendo avaliadas os algoritmos de inicialização com característica distinta da estrutura de otimização, pois dependeria muito tempo para tal avaliação. Além disso, nota-se que os resultados obtidos durante o processo de otimização para definição do $EMAP_{med}$ e $RMSD_{med}$ do conjunto de curvas avaliadas, diferem muito pouco quando comparado entre os membros da população de 24 e 84 configurações. Portanto, com a avaliação dessas estratégias do método

PS, tem-se uma noção considerável pelo quantitativo de estratégias avaliadas se ao aplicá-las no processo de estimação elas melhoram ou não os resultados.

Para o trabalho comparativo de precisão das estratégias do método PS, foi definido que a configuração mais precisa na estimativa dos parâmetros do módulo referência (mSi460A8) seria avaliado nos outros módulos. O objetivo neste processo de comparação é comprovar que estratégias de otimização baseados no método PS ou em outros métodos na estimação dos parâmetros do módulo, podem produzir resultados mais precisos na estimação de parâmetros em relação a estratégia padrão PS-EMAP (GPS 2N) adotada em (SILVA, 2019).

No método PSO para encontrar os melhores resultados, a estratégia de otimização consiste em ajustar os parâmetros da equação da velocidade do PSO, definidas no Capítulo 3. Neste trabalho, os parâmetros da equação da velocidade do PSO foram ajustados para todos os módulos avaliados, realizando uma análise da sensibilidade de variação do EMAP referente a cada etapa de estimação dos parâmetros. Seguindo as referências vistas no Capítulo 3, como exemplo desse ajuste, observa-se para o módulo xSi11246 na Tabela 7 o ajuste dos parâmetros da Equação 3.2 relacionado ao processo de otimização da primeira etapa do processo de estimação de parâmetros do módulo FV. Logo, podemos observar que o algoritmo foi executado com uma população pequena e depois aumentando o número da população. Observa-se que o menor EMAP é 0,04045. Logo, nota-se que uma população de 10 partículas, com $w = 0,6495$, $c_1 = 2$ e $c_2 = 2$, já garante o menor EMAP para essa etapa. O mesmo processo foi avaliado para as outras etapas e para os outros módulos e de forma a manter um padrão de ajuste para as três etapas de estimação dos parâmetros para todos os módulos avaliados, nota-se que ao considerar uma população com 10 vezes o número de variáveis do problema, realizando uma variação dinâmica de $w = 0,9$ a $w = 0,4$ e $c_1 = 2$ e $c_2 = 2$ garante um bom ajuste no processo de otimização, verificando assim que os valores recomendados para ajuste dos parâmetros citados no Capítulo 3 são uma boa referência.

Tabela 5 – Estratégias de otimização do método PS avaliadas para o módulo mSi460A8.

Estrutura de Inicialização		Estrutura de Otimização	
Algoritmo	Pesquisa Completa	Algoritmo	Pesquisa Completa
-	-	MADS NP1	SIM
GSS NP1	SIM	GPS NP1	SIM
GPS NP1	SIM	GSS NP1	SIM
-	-	GPS NP1	-
-	-	GSS NP1	-
GPS NP1	-	GPS NP1	-
GSS NP1	-	GSS NP1	-
-	-	GPS NP1	SIM
GPS NP1	SIM	GPS NP1	SIM
GSS NP1	SIM	GSS NP1	SIM
-	-	GSS NP1	SIM
GSS NP1	-	GPS NP1	-
GPS NP1	-	GSS NP1	-
-	-	MADS NP1	-
GSS NP1	SIM	MADS 2N	SIM
GPS NP1	SIM	MADS 2N	SIM
GSS 2N	-	GPS 2N	-
GPS 2N	-	GSS 2N	-
GPS 2N	-	GSS NP1	-
GSS 2N	-	GSS NP1	-
GPS 2N	-	GPS NP1	-
GSS 2N	-	GPS NP1	-
MADS 2N	-	GSS NP1	-
MADS 2N	SIM	GSS 2N	SIM
GPS NP1	SIM	GPS 2N	SIM
GSS NP1	SIM	GPS 2N	SIM
GPS NP1	SIM	GSS 2N	SIM
GSS NP1	SIM	GSS 2N	SIM
GPS NP1	-	GPS 2N	-
GSS NP1	-	GPS 2N	-
GPS NP1	-	GSS 2N	-
GSS NP1	-	GSS 2N	-
GSS 2N	SIM	GPS 2N	SIM
GPS 2N	SIM	GPS NP1	SIM
GSS 2N	SIM	GPS NP1	SIM
GPS 2N	SIM	GSS 2N	SIM
GPS 2N	SIM	GSS NP1	SIM
GSS 2N	SIM	GSS NP1	SIM
GSS 2N	SIM	MADS 2N	SIM
MADS NP1	-	GPS NP1	-
MADS NP1	SIM	GSS NP1	SIM
MADS NP1	-	GSS 2N	-
-	-	MADS 2N	-
MADS NP1	-	GPS 2N	-
MADS NP1	SIM	GPS 2N	SIM
MADS NP1	SIM	MADS 2N	SIM
MADS NP1	-	GSS NP1	-
MADS 2N	SIM	MADS NP1	SIM
MADS 2N	SIM	GSS 2N	SIM
MADS NP1	SIM	GSS 2N	SIM
MADS 2N	SIM	GPS 2N	SIM
MADS 2N	-	MADS 2N	-
MADS 2N	SIM	MADS 2N	SIM
-	-	GSS 2N	-
GSS 2N	-	GSS 2N	-
GSS 2N	SIM	GSS 2N	SIM
-	-	GSS 2N	SIM
-	-	GPS 2N	SIM
-	-	GPS 2N	-
GPS 2N	-	GPS 2N	-
GPS 2N	SIM	GPS 2N	SIM
GSS NP1	SIM	MADS NP1	SIM
-	-	MADS 2N	SIM
MADS 2N	SIM	GPS NP1	SIM
MADS 2N	-	GPS 2N	-
MADS NP1	SIM	GPS NP1	SIM
MADS 2N	-	GSS 2N	-
MADS 2N	-	GPS NP1	-
GSS 2N	SIM	MADS NP1	SIM
GPS 2N	SIM	MADS NP1	SIM
MADS NP1	-	MADS 2N	-
GPS 2N	SIM	MADS 2N	SIM
GPS NP1	-	MADS NP1	-
GSS 2N	-	MADS NP1	-
GSS 2N	-	MADS 2N	-
GPS 2N	-	MADS 2N	-
GPS 2N	-	MADS NP1	-
GSS NP1	-	MADS 2N	-
GPS NP1	-	MADS 2N	-
GPS NP1	SIM	MADS NP1	SIM
GSS NP1	-	MADS NP1	-
MADS NP1	-	MADS NP1	-
MADS 2N	-	MADS NP1	-
MADS NP1	SIM	MADS NP1	SIM

Fonte: O autor (2020)

Tabela 6 – Estratégias de otimização do método PS avaliadas para os módulos xSi11246, HIT05667, CdTe75368 e CIGS39017.

Estrutura de Inicialização		Estrutura de Otimização	
Algoritmo	Pesquisa Completa	Algoritmo	Pesquisa Completa
MADS NP1	SIM	MADS NP1	SIM
GPS NP1	-	GPS NP1	-
GSS NP1	SIM	GSS NP1	SIM
GPS NP1	SIM	GPS NP1	SIM
GSS NP1	-	GSS NP1	-
-	-	GSS NP1	SIM
GSS NP1	SIM	GPS NP1	SIM
-	-	MADS 2N	SIM
MADS 2N	-	MADS 2N	-
MADS 2N	SIM	MADS 2N	SIM
-	-	MADS NP1	SIM
GSS 2N	SIM	GSS 2N	SIM
MADS NP1	-	MADS NP1	-
GPS 2N	SIM	GPS 2N	SIM
GSS 2N	-	GSS 2N	-
GPS 2N	-	GPS 2N	-
-	-	GSS 2N	SIM
-	-	GPS 2N	SIM
-	-	GPS 2N	-
-	-	MADS 2N	-
-	-	GSS 2N	-
-	-	GSS NP1	-
-	-	GPS NP1	-
-	-	MADS NP1	-

Fonte: O autor (2020)

Tabela 7 – Ajuste dos parâmetros da equação da velocidade do PSO na primeira etapa do processo de estimação dos parâmetros.

1ª Etapa						
População (n)	w_{max}	w_{min}	w	c_1	c_2	EMAP
5	0.9	0.4	0,6780	0.5	0.5	0,04198154
5	0.9	0.4	0,4	2	2	0,0416759
5	0.9	0.4	0,8070	3	3	0,05078864
10	0.9	0.4	0,6290	0.5	0.5	0,11286478
10	0.9	0.4	0,6340	1	1	0,04045938
10	0.9	0.4	0,6495	2	2	0,04045155
30	0.9	0.4	0,6860	0.1	0.1	0,04048263
30	0.9	0.4	0,6205	0.5	0.5	0,04045156
30	0.9	0.4	0,4555	1.5	1.5	0,04045155
30	0.9	0.4	0,4000	1.8	2.2	0,04045155
30	0.9	0.4	0,4000	2	2	0,04045155
30	0.9	0.4	0,8270	3	3	0,05547921
30	0.9	0.4	0,8480	10	10	0,1349899
50	0.9	0.4	0,6550	0.5	0.5	0,04045155
50	0.9	0.4	0,6155	1	1	0,04045155
50	0.9	0.4	0,5680	1.5	1.5	0,04045155
50	0.9	0.4	0,4000	1.8	2.2	0,04045155
50	0.9	0.4	0,7890	2	2	0,04045155
50	0.9	0.4	0,8405	5	5	0,13169319

Fonte: O autor (2020)

A estratégia para o método EPSO consiste em ajustar apenas o número de partículas (população) e o parâmetro de aprendizado ou parâmetro estratégico (τ) que controla a taxa das mutações. Pois, como visto no Capítulo 3, o método EPSO possui característica de auto adaptação de seus parâmetros, pois realiza o processo de mutação e seleção de parâmetros estratégicos. Seguindo os mesmos passos do PSO, na Tabela 8 é realizado uma avaliação na primeira etapa de estimação dos parâmetros do módulo xSi11246. Nota-se que uma população de 10 partículas e $\tau = 1$ já é suficiente para produzir o menor EMAP. O mesmo processo foi avaliado para as outras etapas e para os outros módulos e de forma a manter um padrão de ajuste para as três etapas de estimação dos parâmetros para todos os módulos avaliados, nota-se que ao considerar uma população com 10 vezes o número de variáveis do problema e $\tau = 1$, consiste em uma boa estratégia de otimização para o problema. Na aplicação do método EPSO avaliaremos dois parâmetros estratégico, $\tau = 1$ de acordo com o ajuste realizado e $\tau = 0.001$ conforme valor tipicamente utilizado nos problemas de otimização com EPSO.

Tabela 8 – Ajuste dos parâmetros da equação da velocidade do EPSO na primeira etapa do processo de estimação dos parâmetros.

1ª Etapa		
População (n)	Taxa de mutação	EMAP
5	1	0,040546675941
5	0.01	0,108335199731
5	0.001	0,043215994355
10	1	0,040451553934
10	0.01	0,040521907837
10	0.001	0,040454840199
30	1	0,040451553934
30	0.01	0,040470991757
30	0.001	0,040509959160
50	1	0,040451657
50	0.01	0,040456554
50	0.001	0,040459220

Fonte: O autor (2020)

4.6 RESULTADOS DAS SIMULAÇÕES

Nesta seção, são apresentados em detalhes os resultados em termos dos erros entre as curvas experimentais e as geradas pelo modelo nas simulações para estimativa dos parâmetros do modelo do módulo FV. Como todo o processo de estimação de parâmetros do modelo apresentado utiliza como função objetivo a ser otimizada a minimização do EMAP, na avaliação

do melhor resultado dos métodos de otimização aqui apresentados utilizou-se o mesmo como critério. Para isto, a metodologia utilizada neste trabalho consiste em estimar os parâmetros do modelo usando cada um dos métodos de otimização apresentados e logo após realizar uma avaliação de um conjunto de seis curvas $I-V$ e $P-V$ experimentais, como visto na Tabela 4, escolhidas aleatoriamente denominadas de conjunto de validação, no qual o objetivo consiste em avaliar a capacidade do modelo e método de otimização aplicados na previsão de comportamento do módulo para determinada condição de S e T , onde o EMAP médio entre as curvas experimentais e as geradas pelo modelo é tomado como indicador principal para esta avaliação.

Primeiramente, são avaliados para o módulo mSi460A8 um total de 84 configurações de estratégias de otimização utilizando o método PS, incluindo a técnica padrão GPS 2N e aplicação dos métodos PSO e EPSO. A estratégia MADS NP1 com pesquisa completa na malha obteve o menor EMAP médio do conjunto de curvas de validação e foi utilizada na avaliação dos outros módulos, de forma a verificar se essa estratégia se repetiria com o menor EMAP médio, visto que o grupo de avaliação de estratégias do método PS foi reduzido para os outros módulos.

Na Tabela 9 é apresentado em detalhes os resultados da estratégia PS(MADS NP1-Completo), mostrando os valores de irradiância (S), temperatura (T), resistência série (R_s), resistência paralelo (R_p), fator de idealidade (A), corrente fotogerada (I_g), corrente de saturação (I_{sat}), EMAP normalizado ($EMAPN$), desvio médio quadrático da corrente normalizado ($NRMSD$) para as condições avaliadas. Em seguida, são mostrados também os parâmetros estimados e os erros médio das curvas de validação.

Dentre as estratégias de otimização avaliadas, o menor EMAP médio das curvas de validação para o módulo mSi460A8 foi obtido pelo método PS(MADS NP1-Completo), onde Tabela 9 é apresentado o resultado gerado pelo modelo comparado as curvas $I-V$ e $P-V$ experimental.

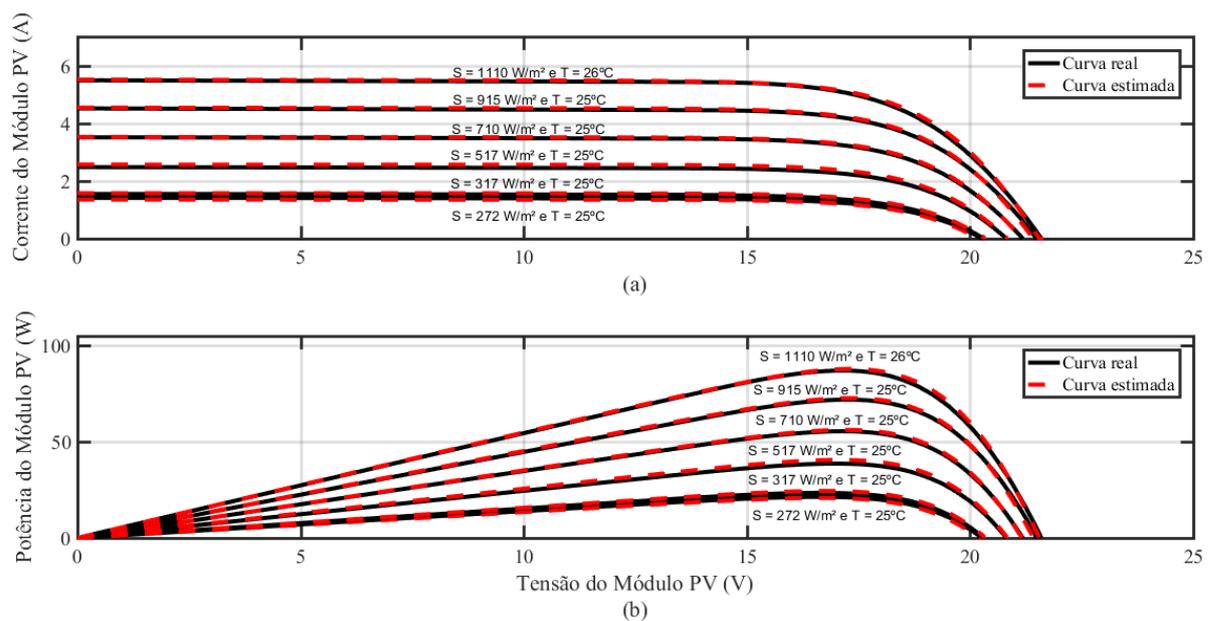
Avaliação similar é realizado também para o método padrão PS(GPS 2N) na Tabela 10 e Figura 48, para o método PSO na Tabela 11 e Figura 49, método EPSO na Tabela 13 e Figura 50 para uma taxa de mutação 0.001 e na Tabela 13 e Figura 51 para uma taxa de mutação 1.

Tabela 9 – Resultados da validação da estimação de parâmetros para o módulo mSi460A8, usando o método PS (MADS NP1) com tipo de pesquisa completa na malha para curvas diferentes do conjunto estimação.

Módulo mSi460A8								
S(W/m ²)	T(°C)	R _s (Ω)	R _p (Ω)	A	I _g (A)	I _{sat} (A)	EMAPN(%)	NRMSD (%)
1110	26	0,18	235,07	1,29	5,51	$8,34 \cdot 10^{-8}$	0,59	0,93
915	25	0,18	272,41	1,29	4,54	$7,23 \cdot 10^{-8}$	0,64	0,95
710	25	0,18	330,61	1,29	3,52	$6,94 \cdot 10^{-8}$	0,52	0,82
517	25	0,18	421,17	1,29	2,56	$6,60 \cdot 10^{-8}$	2,44	3,49
317	25	0,18	611,78	1,29	1,57	$6,10 \cdot 10^{-8}$	1,69	2,23
272	25	0,18	687,61	1,29	1,35	$5,95 \cdot 10^{-8}$	2,50	4,30
Parâmetros Estimados								
$\gamma_{R_s} = 0,00;$			$k_{R_s} = 4,1710 \text{ \%}/\check{z}C ;$					
$\gamma_{R_p} = -0,76;$			$k_{R_p} = -6,94 \cdot 10^{-14} \text{ \%}/\check{z}C ;$					
$I_{sc,ref} = 3,44 \text{ A} ;$			$\beta_S = 0,8434 ;$					
$\alpha_i = 2,64 \text{ mA/K} ;$			$\beta_T = -0,0617 \text{ V/K} ;$					
			$V_{oc,ref} = 20,3667 \text{ V} ;$					
$R_{pref} = 339,02 \text{ } \Omega ;$			$A_{ref} = 1,29 ;$					
$R_{sref1} = 0,1211 \text{ } \Omega ;$			$I_g = 3,44 \text{ A} ;$					
$R_{sref2} = 0,1211 \text{ } \Omega ;$			$I_{sat} = 251,50 \text{ nA} ;$					
Erros Médio das Curvas de Validação								
$EMAPN_{med} = 1,40 \text{ \%}$				$NRMSD_{med} = 2,12 \text{ \%}$				
$EMAP_{med} = 0,52 \text{ W}$				$RMSD_{med} = 0,05 \text{ A}$				

Fonte: autor próprio.

Figura 47 – Comparação entre as curvas obtidas na simulação da Tabela 9 e as curvas experimentais para diferentes irradiâncias.



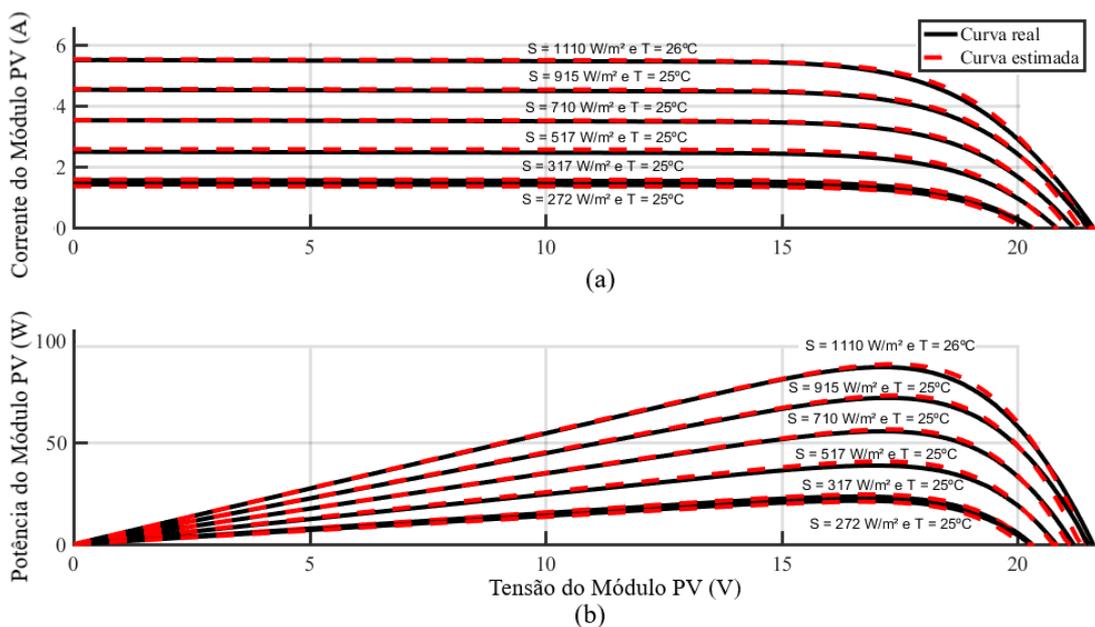
Fonte: O autor (2020)

Tabela 10 – Resultados da validação da estimação de parâmetros para o módulo mSi460A8, usando o método PS padrão (GPS 2N) para curvas diferentes do conjunto estimação.

Módulo mSi460A8								
S(W/m ²)	T(°C)	R _s (Ω)	R _p (Ω)	A	I _g (A)	I _{sat} (A)	EMAPN(%)	NRMSD (%)
1110	26	0,17	355,72	1,29	5,51	$9,28 \cdot 10^{-8}$	0,85	1,25
915	25	0,16	477,41	1,29	4,54	$2,61 \cdot 10^{-7}$	0,99	1,49
710	25	0,16	664,96	1,29	3,52	$7,80 \cdot 10^{-8}$	0,82	1,17
517	25	0,16	1006,38	1,29	2,56	$7,43 \cdot 10^{-8}$	2,61	3,81
317	25	0,16	1906,60	1,29	1,57	$6,89 \cdot 10^{-8}$	1,85	2,54
272	25	0,16	2328,71	1,29	1,35	$6,73 \cdot 10^{-8}$	2,42	4,12
Parâmetros Estimados								
$\gamma_{R_s} = -3,33 \cdot 10^{-15};$			$k_{R_s} = 5,49 \text{ \%}/\text{°C};$					
$\gamma_{R_p} = -1,31;$			$k_{R_p} = -8,07 \text{ \%}/\text{°C};$					
$I_{sc,ref} = 3,44 \text{ A};$			$\beta_S = 0,8437;$					
$\alpha_i = 2,64 \text{ mA/K};$			$\beta_T = -0,0551 \text{ V/K};$					
			$V_{oc,ref} = 20,3667 \text{ V};$					
$R_{pref} = 352,63 \text{ } \Omega;$			$A_{ref} = 1,29;$					
$R_{sref1} = 0,1207 \text{ } \Omega;$			$I_g = 3,44 \text{ A};$					
$R_{sref2} = 0,1207 \text{ } \Omega;$			$I_{sat} = 261 \text{ nA};$					
Erros Médio das Curvas de Validação								
$EMAPN_{med} = 1,59\%$				$NRMSD_{med} = 2,40 \text{ } \%$;				
$EMAP_{med} = 0,64 \text{ W};$				$RMSD_{med} = 0,06 \text{ A}$				

Fonte: O autor (2020)

Figura 48 – Comparação entre as curvas obtidas na simulação da Tabela 10 e as curvas experimentais para diferentes irradiâncias.



Fonte: O autor (2020)

Tabela 11 – Resultados da validação da estimação de parâmetros para o módulo mSi460A8, usando o método PSO para curvas diferentes do conjunto estimação.

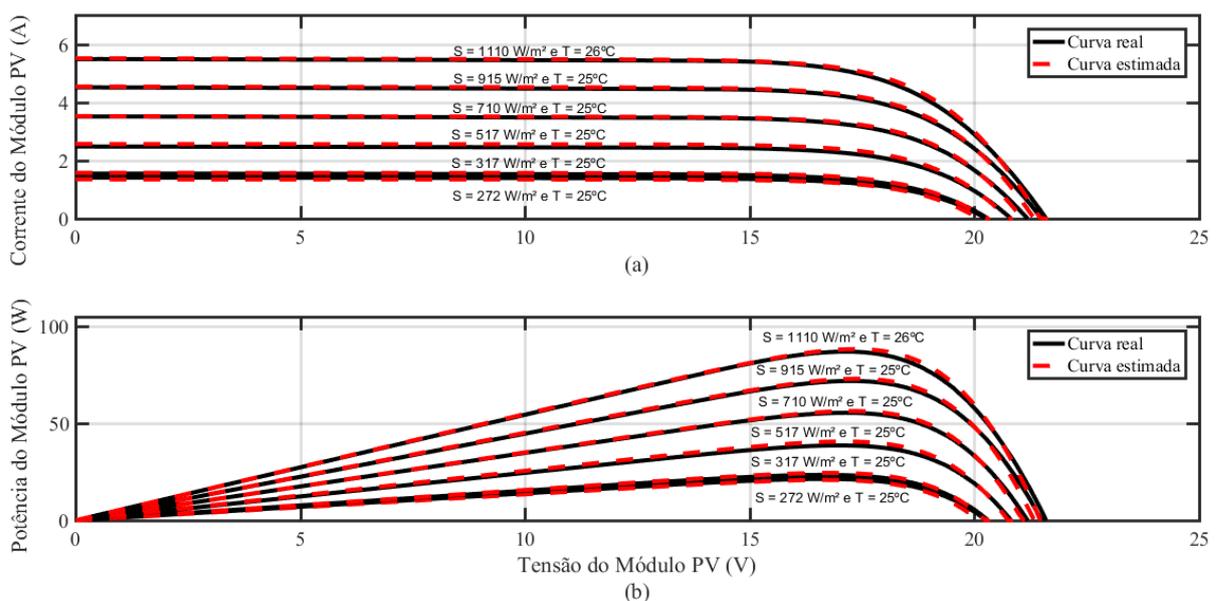
Módulo mSi460A8								
S (W/m ²)	T (°C)	R _s (Ω)	R _p (Ω)	A	I _g (A)	I _{sat} (A)	EMAPN (%)	NRMSD (%)
1110	26	0,1736	354,88	1,30	5,51	$9,76 \cdot 10^{-8}$	0,79	1,15
915	25	0,1676	482,91	1,30	4,54	$8,54 \cdot 10^{-8}$	0,94	1,43
710	25	0,1676	684,68	1,30	3,52	$8,22 \cdot 10^{-8}$	0,78	1,11
517	25	0,1676	1059,49	1,30	2,56	$7,84 \cdot 10^{-8}$	2,59	3,80
317	25	0,1676	2077,16	1,30	1,57	$7,28 \cdot 10^{-8}$	1,83	2,53
272	25	0,1676	2564,37	1,30	1,35	$7,11 \cdot 10^{-8}$	2,43	4,11

Parâmetros Estimados	
$\gamma_{R_s} = 0,00;$	$k_{R_s} = 2,51 \text{ \%}/\text{°C};$
$\gamma_{R_p} = -1,38;$	$k_{R_p} = -8,18 \text{ \%}/\text{°C};$
$I_{sc,ref} = 3,44 \text{ A};$	$\beta_s = 0.8464;$
$\alpha_i = 2,64 \text{ mA/K};$	$\beta_T = -0.0558 \text{ V/K};$
	$V_{oc,ref} = 20,3667 \text{ V};$
$R_{pref} = 361,52 \text{ } \Omega;$	$A_{ref} = 1,30;$
$R_{sref1} = 0 \text{ } \Omega;$	$I_g = 3,44 \text{ A};$
$R_{sref2} = 0.2399 \text{ } \Omega;$	$I_{sat} = 276,31 \text{ nA};$

Erros Médio das Curvas de Validação	
$EMAPN_{med} = 1,56\%;$	$NRMSD_{med} = 2,36 \text{ } \%;$
$EMAP_{med} = 0,62 \text{ W};$	$RMSD_{med} = 0,06 \text{ A};$

Fonte: O autor (2020)

Figura 49 – Comparação entre as curvas obtidas na simulação da Tabela 11 e as curvas experimentais para diferentes irradiâncias.



Fonte: O autor (2020)

Tabela 12 – Resultados da validação da estimação de parâmetros para o módulo mSi460A8, usando o método EPSO com taxa de mutação 0.001 para curvas diferentes do conjunto estimação.

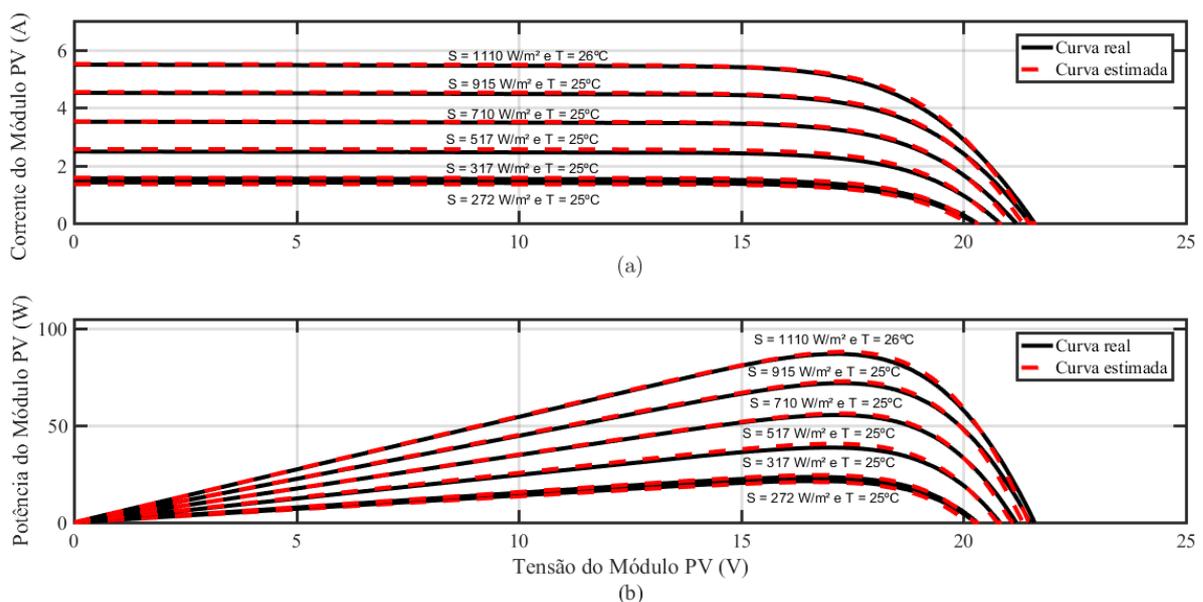
Módulo mSi460A8								
S(W/m ²)	T(°C)	R _s (Ω)	R _p (Ω)	A	I _g (A)	I _{sat} (A)	EMAPN(%)	NRMSD (%)
1110	26	0,1793	361,48	1,30	5,51	$1,05 \cdot 10^{-7}$	0,71	1,06
915	25	0,1793	502,70	1,30	4,54	$9,19 \cdot 10^{-8}$	0,91	1,42
710	25	0,1793	732,77	1,30	3,52	$8,84 \cdot 10^{-8}$	0,74	1,07
517	25	0,1793	1173,89	1,30	2,56	$8,42 \cdot 10^{-8}$	2,55	3,78
317	25	0,1793	2427,78	1,30	1,57	$7,81 \cdot 10^{-8}$	1,81	2,52
272	25	0,1793	3047,79	1,30	1,35	$7,63 \cdot 10^{-8}$	2,45	4,12

Parâmetros Estimados	
$\gamma_{R_s} = -2,86;$	$k_{R_s} = 2,25 \%/\check{z}C ;$
$\gamma_{R_p} = -1,49;$	$k_{R_p} = -8,42 \%/\check{z}C ;$
$I_{sc,ref} = 3,44 A ;$	$\beta_S = 0.8429 ;$
$\alpha_i = 2,64 mA/K;$	$\beta_T = -0.0558 V/K;$
	$V_{oc,ref} = 20,3667 V ;$
$R_{pref} = 382,75 \Omega ;$	$A_{ref} = 1,29 ;$
$R_{sref1} = 4,50 \cdot 10^{-18} \Omega ;$	$I_g = 3,44 A;$
$R_{sref2} = 0.2383 \Omega;$	$I_{sat} = 295,83 nA ;$

Erros Médio das Curvas de Validação	
$EMAPN_{med} = 1,53\%;$	$NRMSD_{med} = 2,33 \%;$
$EMAP_{med} = 0,60 W;$	$RMSD_{med} = 0,06 A;$

Fonte: O autor (2020)

Figura 50 – Comparação entre as curvas obtidas na simulação da Tabela 12 e as curvas experimentais para diferentes irradiâncias.



Fonte: O autor (2020)

Tabela 13 – Resultados da validação da estimação de parâmetros para o módulo mSi460A8, usando o método EPSO com taxa de mutação 1 para curvas diferentes do conjunto estimação.

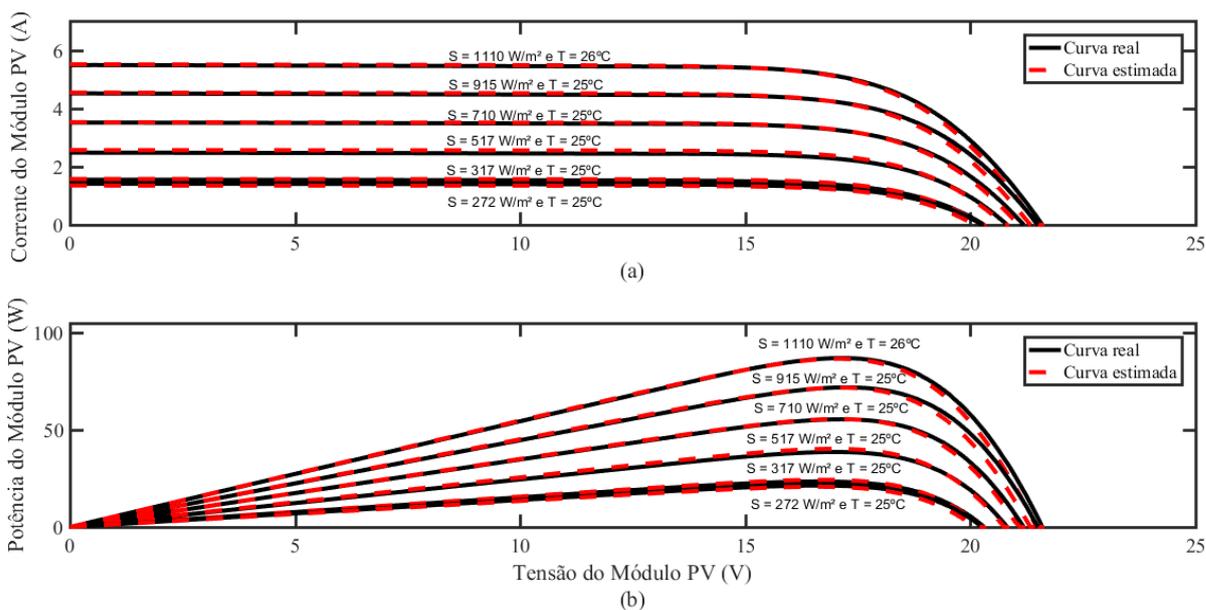
Módulo mSi460A8								
S (W/m ²)	T (°C)	R _s (Ω)	R _p (Ω)	A	I _g (A)	I _{sat} (A)	EMAPN (%)	NRMSD (%)
1110	26	0,2399	368,34	1,30	5,51	$9,77 \cdot 10^{-8}$	0,92	1,50
915	25	0,2399	493,77	1,30	4,54	$8,54 \cdot 10^{-8}$	1,21	2,00
710	25	0,2399	686,43	1,30	3,52	$8,22 \cdot 10^{-8}$	0,44	1,33
517	25	0,2399	1036,38	1,30	2,56	$7,83 \cdot 10^{-8}$	2,25	3,53
317	25	0,2399	1956,17	1,30	1,57	$7,28 \cdot 10^{-8}$	1,59	2,28
272	25	0,2399	2386,49	1,30	1,35	$7,11 \cdot 10^{-8}$	2,72	4,39

Parâmetros Estimados	
$\gamma_{R_s} = 0;$	$k_{R_s} = -55,20 \%/^{\circ}C;$
$\gamma_{R_p} = -1,30;$	$k_{R_p} = -8,18 \%/^{\circ}C;$
$I_{sc,ref} = 3,44 \text{ A};$	$\beta_S = 0.8464;$
$\alpha_i = 2,64 \text{ mA/K};$	$\beta_T = -0.0558 \text{ V/K};$
	$V_{oc,ref} = 20,3667 \text{ V};$
$R_{pref} = 361,52 \Omega;$	$A_{ref} = 1,30;$
$R_{sref1} = 0,2399 \Omega;$	$I_g = 3,44 \text{ A};$
$R_{sref2} = 0 \Omega;$	$I_{sat} = 276,31 \text{ nA};$

Erros Médio das Curvas de Validação	
$EMAPN_{med} = 1,52\%;$	$NRMSD_{med} = 2,51 \%;$
$EMAP_{med} = 0,72 \text{ W};$	$RMSD_{med} = 0,07 \text{ A};$

Fonte: O autor (2020)

Figura 51 – Comparação entre as curvas obtidas na simulação da Tabela 13 e as curvas experimentais para diferentes irradiâncias.



Fonte: O autor (2020)

Na Tabela 14 é apresentado um comparativo dos resultados dos menores erros médios obtidos para cinco amostras consecutivas de estimativas de parâmetros para o módulo mSi460A8 com a aplicação dos métodos apresentados. Logo, os menores $EMAP_{med}$ e $RMSD_{med}$ apresentados foram pelo método PS (MADS NP1 - Completo), verificando assim que pode-se obter resultados mais precisos na estimação de parâmetros utilizando uma estratégia de otimização diferente do método PS padrão (GPS 2N) utilizado no modelo proposto por (SILVA, 2019). Graficamente, um menor $EMAP$ médio reflete em uma melhor aproximação das curvas geradas pelo modelo e as curvas experimentais.

Tabela 14 – Resultados dos erros médios do conjunto de curvas de validação para o módulo mSi460A8 .

Módulo mSi460A8 - Tecnologia Silício Policristalino		
Método	$EMAP_{med}$ (W)	$RMSD_{med}$ (A)
PS (MADS NP1 - Completo)	0,52	0,05
PS (GPS 2N)	0,64	0,06
PSO	0,62	0,06
EPSO Taxa de Mutação = 1	0,72	0,06
EPSO Taxa de Mutação = 0,001	0,60	0,06

Fonte: O autor (2020)

Nas cinco estimativas de parâmetros, os métodos estocásticos avaliados na Tabela 14, apresentam valores de $EMAP_{med}$ e $RMSD_{med}$ e os seus respectivos desvio padrão apresentados na Tabela 15. Nota-se que, apesar do método PS (MADS NP1 - Completo) apresentar valores menores de $EMAP_{med}$ e $RMSD_{med}$ no processo de estimação dos parâmetros, ele apresenta valores maiores de desvio padrão das grandezas avaliadas. Um desvio padrão alto significa que os valores amostrais estão bem distribuídos em torno da média, enquanto que um desvio padrão pequeno indica que eles estão condensados próximos da média.

Nesta análise, o método PSO e PS (MADS NP1 - Completo) possuem as menores média, porém o PSO caracteriza-se por apresentar menor desvio padrão. Além disso, quando comparado ao método padrão PS (GPS 2N), os métodos PSO e PS (MADS NP1 - Completo) atingem erros médios menores. Sendo assim, uma boa alternativa devido a estabilidade nos resultados obtidos é aplicar o método PSO na estimativa de parâmetros para este módulo.

Na Tabela 16, é apresentado os resultados dos menores erros médios obtidos para o módulo xSi11246 avaliados em cinco estimativas de parâmetros. Neste módulo, o método PS (MADS

Tabela 15 – Média e desvio padrão dos valores do $EMAP_{med}$ e $RMSD_{med}$ dos métodos estocásticos do conjunto de curvas de validação para o módulo mSi460A8 avaliadas em cinco estimativas de parâmetros.

Módulo mSi460A8 - Tecnologia Silício Policristalino				
Método	$EMAP_{med}$ (W)	Desvio Padrão ($\sigma_{EMAP_{med}}$)	$RMSD_{med}$ (A)	Desvio Padrão ($\sigma_{RMSD_{med}}$)
PS (MADS NP1 - Completo)	0,63	0,05	0,05	0,004
PSO	0,63	0,01	0,06	0,002
EPSO Taxa de Mutação = 1	0,66	0,01	0,06	0,004
EPSO Taxa de Mutação = 0,001	0,67	0,04	0,06	0,005

Fonte: O autor (2020)

Tabela 16 – Resultados dos erros médios do conjunto de curvas de validação para o módulo xSi11246 .

Módulo xSi11246 - Tecnologia Silício Monocristalino		
Método	$EMAP_{med}$ (W)	$RMSD_{med}$ (A)
Inicialização: PS(MADS NP1 - Completo) Otimização: PS(MADS NP1 - Completo)	0,82	0,07
PS (MADS NP1 - Completo)	0,58	0,06
PS (GPS 2N)	1,95	0,17
PSO	1,09	0,09
EPSO Taxa de Mutação = 1	0,84	0,07
EPSO Taxa de Mutação = 0,001	0,81	0,07

Fonte: O autor (2020)

NP1 - Completo) apresentou os menores erros.

O método PS (MADS NP1 - Completo) apesar de alcançar os menores erros ($EMAP_{med}$ e $RMSD_{med}$) no processo de estimação, ao realizar um comparativo dos métodos estocásticos observa-se um maior desvio padrão deste método, como apresentado na Tabela 17. Nesta avaliação com cinco amostras, o método EPSO com taxa de mutação 0,001 apresenta menor média dos valores de $EMAP_{med}$ e $RMSD_{med}$ e menor desvio padrão quando comparado ao método PS (MADS NP1-Completo). Quando comparado com o método padrão PS (GPS 2N) no módulo xSi11246, os métodos estocásticos apresentam menores erros e o método EPSO com taxa de mutação 0,001, é uma boa alternativa para estimativa de parâmetros nesse

Tabela 17 – Média e desvio padrão dos valores do $EMAP_{med}$ e $RMSD_{med}$ dos métodos estocásticos do conjunto de curvas de validação para o módulo xSi11246 avaliadas em cinco estimativas de parâmetros.

Módulo xSi11246 - Tecnologia Silício Monocristalino				
Método	$EMAP_{med}$ (W)	Desvio Padrão ($\sigma_{EMAP_{med}}$)	$RMSD_{med}$ (A)	Desvio Padrão ($\sigma_{RMSD_{med}}$)
Inicialização: PS(MADS NP1 - Completo) Otimização: PS(MADS NP1 - Completo)	1,09	0,22	0,09	0,02
PS (MADS NP1 - Completo)	1,11	0,40	0,08	0,04
PSO	0,98	0,15	0,08	0,01
EPSO Taxa de Mutação = 1	1,12	0,16	0,09	0,01
EPSO Taxa de Mutação = 0,001	0,91	0,16	0,08	0,01

Fonte: O autor (2020)

módulo, por apresentar menor média e desvio padrão baixo quando comparado aos outros métodos.

Para o módulo HIT05667, o método PS (MADS NP1 - Completo) apresentou os menores erros médio avaliados em cinco estimativas de parâmetros, conforme apresentado na Tabela 18.

Tabela 18 – Resultados dos erros médios do conjunto de curvas de validação para o módulo HIT05667.

Módulo HIT05667 - Tecnologia de Silício Amorfo		
Método	$EMAP_{med}$ (W)	$RMSD_{med}$ (A)
Inicialização: PS (MADS NP1 - Completo) Otimização: PS (MADS NP1 - Completo)	1,39	0,06
PS (MADS NP1 - Completo)	1,13	0,05
PS (GPS 2N)	1,40	0,06
PSO	1,40	0,06
EPSO Taxa de Mutação = 1	1,50	0,06
EPSO Taxa de Mutação = 0,001	1,40	0,04

Fonte: O autor (2020)

De acordo com a Tabela 19, nota-se que o método PS (MADS NP1 - Completo) apresentou o segundo maior valor de desvio padrão. Na avaliação do módulo HIT05667 com cinco amostras de estimação dos parâmetros, o método PSO apresenta a menor média e o segundo menor

desvio padrão. Ao realizar a comparação com o método padrão PS (GPS 2N) a média dos erros das cinco amostras de estimação dos métodos estocásticos avaliados são superiores. Desta forma, apesar de ter o segundo maior valor de desvio padrão, o método PS (MADS NP1 - Completo) consegue estimar parâmetros que resultam em menores valores de erros.

Tabela 19 – Média e desvio padrão dos valores do $EMAP_{med}$ e $RMSD_{med}$ dos métodos estocásticos do conjunto de curvas de validação para o módulo HIT05667 avaliadas em cinco estimativas de parâmetros.

Módulo HIT05667 - Tecnologia de Silício Amorfo				
Método	$EMAP_{med}$ (W)	Desvio Padrão ($\sigma_{EMAP_{med}}$)	$RMSD_{med}$ (A)	Desvio Padrão ($\sigma_{RMSD_{med}}$)
Inicialização: PS (MADS NP1 - Completo) Otimização: PS (MADS NP1 -Completo)	1,64	0,26	0,06	0,002
PS (MADS NP1 - Completo)	1,45	0,18	0,06	0,007
PSO	1,42	0,04	0,06	0,002
EPSO Taxa de Mutação = 1	1,51	0,00	0,06	0,000
EPSO Taxa de Mutação = 0,001	1,51	0,01	0,06	0,001

Fonte: O autor (2020)

As simulações realizadas para o módulo CdTe75368 mostram que o método EPSO com taxa de mutação 0,001 conduzem a menores erros, conforme apresentado na Tabela 20. Entretanto, a média e a variabilidade dos resultados de $EMAP_{med}$ e $RMSD_{med}$ apresentadas por este método é a maior.

Tabela 20 – Resultados dos erros médios do conjunto de curvas de validação para o módulo CdTe75368.

Módulo CdTe75368 - Tecnologia Telureto de Cádmio		
Método	EMAP_{med} (W)	RMSD_{med} (A)
Inicialização: PS (MADS 2N - Completo) Otimização: PS (MADS 2N - Completo)	1,02	0,02
PS (MADS NP1 - Completo)	0,98	0,02
PS (GPS 2N)	1,29	0,03
PSO	1,19	0,03
EPSO Taxa de Mutação = 1	1,12	0,02
EPSO Taxa de Mutação = 0,001	0,88	0,02

Fonte: O autor (2020)

No módulo CdTe75368, uma boa alternativa para estimação dos parâmetros é aplicar o método EPSO com taxa de mutação 1, pois a média dos valores dos erros para cinco estimativas é menor do que o valor do método padrão PS (GPS 2N) e apresenta o menor desvio padrão para os valores dos erros.

Tabela 21 – Média e desvio padrão dos valores do EMAP_{med} e RMSD_{med} dos métodos estocásticos do conjunto de curvas de validação para o módulo CdTe75368 avaliadas em cinco amostras.

Módulo CdTe75368 - Tecnologia Telureto de Cádmio				
Método	EMAP_{med} (W)	Desvio Padrão ($\sigma_{EMAP_{med}}$)	RMSD_{med} (A)	Desvio Padrão ($\sigma_{RMSD_{med}}$)
Inicialização: PS (MADS 2N - Completo) Otimização: PS (MADS 2N - Completo)	1,13	0,08	0,02	0,001
PS (MADS NP1 - Completo)	1,06	0,08	0,02	0,001
PSO	1,27	0,04	0,03	0,001
EPSO Taxa de Mutação = 1	1,13	0,006	0,02	0,00
EPSO Taxa de Mutação = 0,001	1,63	0,48	0,03	0,006

Fonte: O autor (2020)

Os resultados avaliados para o módulo CIGS39017 na Tabela 22, mostram proximidade nos valores do EMAP_{med}, com destaque para o método PS (GPS 2N), que apresentou os

menores erros. Entretanto, os resultados mostram valores de EMAP médio bem superiores quando comparado com as tecnologias das Tabelas 14 e 16.

Tabela 22 – Resultados dos erros médios do conjunto de curvas de validação para o módulo CIGS39017.

Módulo CIGS39017 - Tecnologia CIGS		
Método	EMAP_{med} (W)	RMSD_{med} (A)
PS (MADS NP1 - Completo)	2,65	0,13
PS (GPS 2N)	2,38	0,11
PSO	2,38	0,11
EPSO Taxa de Mutação = 1	2,70	0,13
EPSO Taxa de Mutação = 0,001	2,80	0,13

Fonte: O autor (2020)

Em um comparativo entre os métodos estocásticos nota-se proximidade entre os valores dos erros, entretanto, todos os métodos apresentam valores médios superiores de EMAP_{med} e RMSD_{med} avaliados em cinco amostras de estimativas em relação ao método PS (GPS 2N).

Tabela 23 – Média e desvio padrão dos valores do EMAP_{med} e RMSD_{med} dos métodos estocásticos do conjunto de curvas de validação para o módulo CIGS39017 avaliadas em cinco estimativas de parâmetros.

Módulo CIGS39017 - Tecnologia CIGS				
Método	EMAP_{med} (W)	Desvio Padrão ($\sigma_{EMAP_{med}}$)	RMSD_{med} (A)	Desvio Padrão ($\sigma_{RMSD_{med}}$)
PS (MADS NP1 - Completo)	2,87	0,25	0,13	0,01
PSO	2,80	0,24	0,13	0,01
EPSO Taxa de Mutação = 1	2,73	0,06	0,17	0,07
EPSO Taxa de Mutação = 0,001	2,80	0,002	0,13	0,00

Fonte: O autor (2020)

A avaliação de desempenho dos métodos baseados nos tempos de execução (convergência do método) contemplando as três etapas do processo estimação dos parâmetros estão registrados na Tabela 24. A plataforma utilizada para as simulações foi um computador com a seguinte configuração: (a) Processador Intel Core i3, 2,00 GHz e (b) Memória instalada

(RAM), 4,00 GB. O maior tempo registrado na execução dos métodos estocásticos é justificado pela estratégia de executar cinco vezes o algoritmo e captar o melhor resultado (menor valor de $EMAP_{med}$ e $RMSD_{med}$). A execução dos algoritmos estocásticos em cinco vezes foi definida com base em uma série de simulações, em que foi comparado os valores de EMAP e RMSD das curvas dos módulos para execuções desses algoritmos variando de 1 até 10 vezes. Com isto, constatou-se que em média com cinco execuções o algoritmo já apresentava repetições do menor valor de EMAP e RMSD, sendo deste modo o valor padrão utilizado para a estimação de parâmetros para os métodos estocásticos.

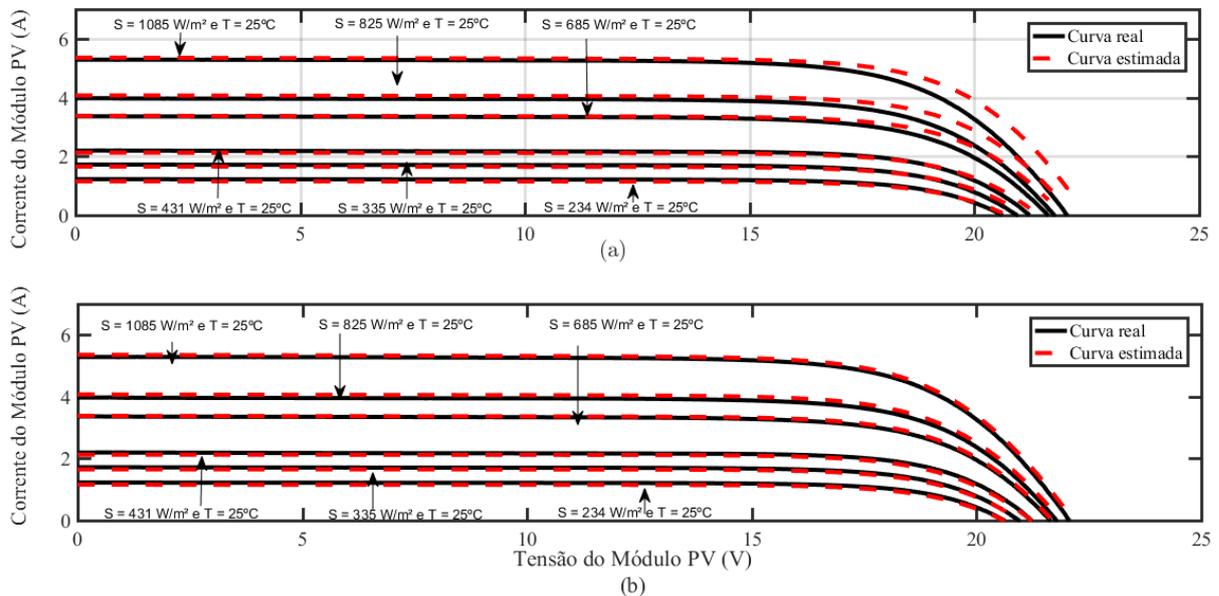
A partir dos resultados apresentados para todas as tecnologias de módulos avaliadas neste trabalho, pode-se concluir que a escolha de um método de otimização, para qualquer tipo de tecnologia deve ser avaliada, pois de acordo com os resultados obtidos podemos notar que a definição do método de otimização a ser implementado no modelo do módulo, influência no processo de estimação de parâmetros, como pode ser visto no exemplo da Figura 52.

Tabela 24 – Tempos de convergência total dos métodos avaliados.

Desempenho dos Métodos	
Método	Tempo Médio de Convergência (minutos)
PS (MADS NP1 - Completo)	12
PS (GPS 2N)	2
PSO	11
EPSO Taxa de Mutação = 1	95
EPSO Taxa de Mutação = 0,001	85

Fonte: O autor (2020)

Figura 52 – Comparação entre as curvas I - V reproduzidas pelo modelo e as curvas experimentais para diferentes irradiancias para o módulo xSi11246 utilizando o método (a) PS (GPS-2N) e (b) EPSO com taxa de mutação 0,001.



Fonte: O autor (2020)

Na Figura 52, nota-se que ao aplicar o método EPSO com taxa de mutação 0,001, tem-se os parâmetros do modelo do módulo mais precisos, pois quando comparado ao método PS (GPS 2N) na reprodução de um conjunto de curvas pelo modelo do módulo, o método EPSO consegue uma melhor aproximação das curvas experimentais, ou seja, menor EMAP médio. Neste caso, o método PS (GPS 2N) aplicado ao módulo xSi11246 não é uma boa escolha para a estimação dos parâmetros, pois por ser um método determinístico, o resultado obtido na estimação dos parâmetros será sempre o mesmo. Como visto anteriormente, os métodos de otimização aqui avaliados são técnicas inteligentes, que com processos bem definidos, são capazes de solucionar problemas de otimização matemática. Através de informações iniciais e com a definição de uma função objetivo pesquisam em um espaço definido uma solução de qualidade. Porém, é válido lembrar que mesmo apresentando soluções de boa qualidade, a convergência dos métodos aqui estudados para um ponto de ótimo global do sistema não é garantida.

Sendo assim, nota-se nas simulações que os métodos GPS e GSS são determinísticos, ou sejam, na execução do processo de estimação dos parâmetros eles sempre apresentam os mesmos resultados, podendo ou não convergir para um ponto de ótimo global. Já as técnicas aleatórias PS(MADS), PSO e EPSO apresentam variações nos resultados do processo de estimação dos parâmetros. Para contornar essa aleatoriedade foi adotado a estratégia de executar

automaticamente cinco vezes o algoritmo e captar o melhor resultado para representação dos parâmetros. Essa estratégia é uma boa alternativa para tentar fazer com que os métodos estocásticos "escapem" de um ponto de mínimo local e convirjam para um ponto de mínimo global.

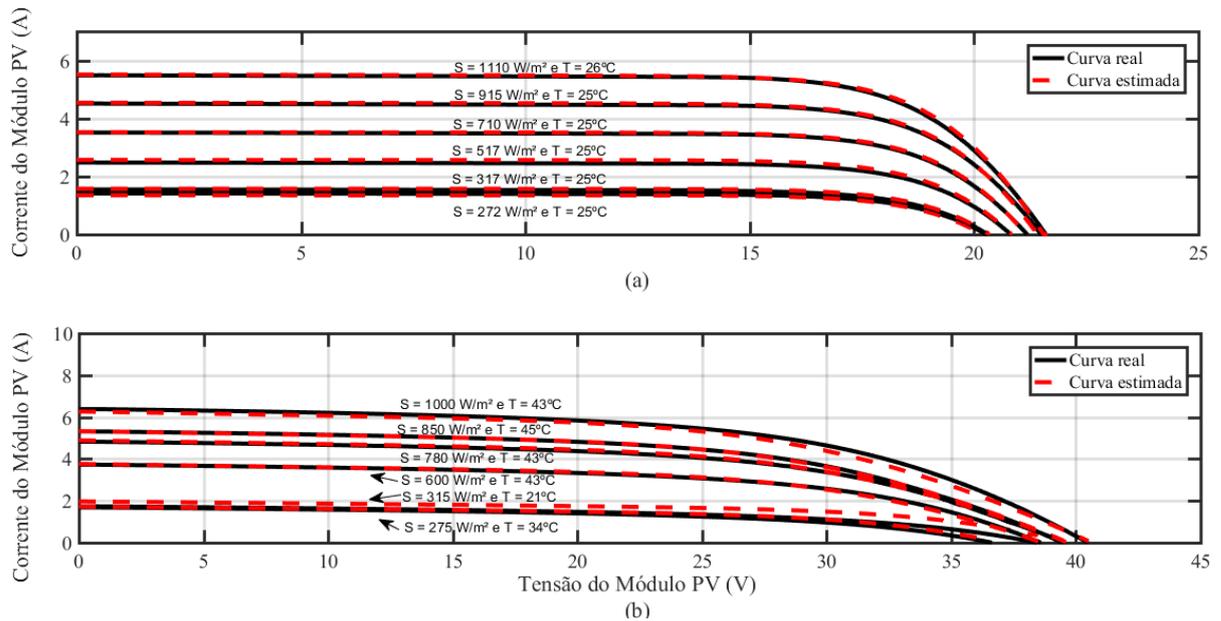
Ao analisar todas as tecnologias o método PS (MADS NP1 - Completo) apresenta bons resultados quando avaliado, pois ao ser aplicado no processo de estimação, em três tecnologias das cinco avaliadas, ele reproduziu o menor EMAP médio do conjunto de curvas experimentais selecionadas para a validação. Entretanto, nota-se que em dois módulos (mSi460A8 e xSi11246), os resultados dos erros apresentados apresentaram um desvio padrão maior, quando comparado com os outros métodos.

A partir dos resultados obtidos nas Tabelas 14, 16, 18, 20 e 22, nota-se que os métodos de otimização avaliados neste trabalho quando aplicados ao modelo do módulo FV na estimação dos parâmetros, apresentam os resultados mais precisos na reprodução de curvas em condições condições variáveis para os módulos avaliados de tecnologias de silício monocristalino (xSi11246) e silício policristalino (mSi460A8), visto que o valores de $EMAP_{med}$ do conjunto de curvas avaliadas são menores do que 1 W, ou seja, quando comparamos um conjunto de curvas $I-V$ e $P-V$ experimentais com as curvas $I-V$ e $P-V$ reproduzidas pelo modelo, estas possuem o comportamento mais próximo dos valores experimentais para esses dois módulos. Essa diferença torna-se nítida quando comparamos o comportamento das curvas $I-V$ do modelo do módulo FV para as tecnologias de silício policristalino e de CIGS (CIGS39017) conforme a Figura 53.

Da Figura 53, nota-se a diferença do fator de forma das duas tecnologias, onde as curvas $S = 1000 \text{ W/m}^2$ e $T = 43 \text{ }^\circ\text{C}$, $S = 315 \text{ W/m}^2$ e $T = 21 \text{ }^\circ\text{C}$ e $S = 275 \text{ W/m}^2$ e $T = 34 \text{ }^\circ\text{C}$ reproduzidas pelo modelo para o módulo CIGS39017 se distanciam em vários trechos das curvas experimentais. Devido a essa diferença, tem-se um $EMAP_{med}$ elevado comparado aos outros módulos avaliados.

Em uma análise preliminar, como as curvas da Figura 53 estão em uma faixa bem próxima e os mesmos métodos de otimização foram utilizados em ambas tecnologias, ao comparar todos os erros das duas tecnologias observa-se uma diferença considerável, onde aparentemente o modelo global não-linear mostra-se mais preciso na aplicação das tecnologias de silício monocristalino e policristalino. Como visto no Capítulo 2, as duas tecnologias possuem diferentes processos de fabricação e composições físicas e químicas diferentes, podendo o modelo global não-linear estar melhor representando as tecnologias de silício monocristalino e policristalino,

Figura 53 – Comparação entre as curvas $I-V$ reproduzidas pelo modelo e as curvas experimentais, utilizando o método de otimização que gerou menor EMAP médio, em condições variáveis para os módulos (a) mSi460A8 e (b) CIGS39017.



Fonte: próprio autor.

desta forma, como uma das sugestão de trabalhos futuros deve-se avaliar uma quantidade maior de módulos das mesmas tecnologias e estudar as sensibilidades paramétricas da tecnologia de CIGS para verificar se as equações do modelo global não-linear necessitam de alterações para uma representação mais precisa.

4.7 CONCLUSÕES

Neste capítulo, foi abordado todo o processo de estimação de parâmetros do modelo global não-linear. O modelo que é baseado no modelo clássico de um diodo, possui a capacidade de adaptar os valores dos seu parâmetros, baseado nas variações ambientais de irradiância e temperatura. Este modelo tem seus parâmetros estimados com o auxílio de uma curva de referência, no mínimo seis curvas de estimação e a aplicação de um método de otimização nas três etapas que compõem o processo de estimação dos parâmetros.

Com os parâmetros estimados, as equações que formam o modelo são capazes de reproduzir, de forma aproximada, o comportamento da curva experimental $I-V$ dos módulos FV. Logo, para avaliar a influência da escolha do método de otimização no processo de estimação dos parâmetros, foram avaliados três métodos PS, PSO e EPSO, de acordo com estratégias

de otimização definidas e aplicados cada um dos métodos nos cinco módulos de tecnologias diferentes.

Através dos resultados obtidos, foi possível notar que:

- A escolha do método de otimização na estimativa dos parâmetros influencia na precisão do modelo em reproduzir curvas para condições ambientais variáveis quando comparado as curvas experimentais. Logo, um método de otimização pode estimar parâmetros que produzem valores menores de $EMAP_{med}$ quando comparados por exemplo a técnica PS-EMAP padrão (GPS 2N) aplicada em (SILVA, 2019).
- Os métodos classificados como estocásticos quando aplicados com estratégias de otimização bem definidas conduzem a bons resultados na estimativa dos parâmetros do modelo global não-linear, apresentando em quatro dos cinco módulos avaliados resultados de erros menores do que o método padrão PS (GPS 2N).
- Nas avaliações do conjunto de curvas reproduzidas pelo modelo global não-linear ao aplicar os métodos de otimização, observa-se que as tecnologias de silício cristalino e silício policristalino apresentam os menores erros quando comparados às outras tecnologias. Os menores valores de $EMAP_{med}$ registrados para as tecnologias de silício cristalino e silício policristalino são menores do que 1W, enquanto para as outras tecnologias são maiores do que 1W. Portanto, essa análise leva a conclusão que o modelo global não-linear se adapta melhor as tecnologias de silício cristalino e policristalino.

5 CONCLUSÃO

O trabalho desenvolvido nesta dissertação apresentou os resultados obtidos através da aplicação de diferentes métodos de otimização no processo de estimação de parâmetros de módulos FV através do modelo global não-linear.

Para isto, primeiramente foi avaliado Capítulo 2, a teoria do recurso solar como fonte de geração de energia, o princípio de funcionamento de células/módulos FV e os seus tipos e tecnologias de fabricação. Logo em seguida, foi apresentada a estruturação das células/módulos FV com o objetivo de compreender a modelagem clássica de um diodo dos dispositivos fotovoltaicos e através de uma análise dos parâmetros que influenciam no rendimento de células/módulos FV, realizar a introdução do modelo global não-linear, que foi adotado como referência neste trabalho pela sua capacidade de representar os fenômenos físicos que ocorrem nos parâmetros de células/módulos FV quando ocorrem variações de irradiância e temperatura.

Sabendo que o modelo global não-linear foi inicialmente proposto com processo de estimação de seus parâmetros utilizando o método de otimização Busca por Padrões (*Pattern Search* - PS) utilizando a Busca Generalizada por Padrões (GPS 2N), este trabalho teve como objetivo avaliar novas ferramentas de otimização no processo de estimação de parâmetros deste modelo e verificar a eficácia dessa estimação através da precisão ao comparar as curvas *I-V* reproduzidas pelo modelo e as curvas experimentais. Portanto, no Capítulo 3 são estudados os métodos de otimização baseados na Direção de Busca (Algoritmo de Busca por Padrões - *Pattern Search*-PS) e metaheurísticas (Otimização por Enxame de Partículas - *Particle Swarm Optimization*-PSO e Otimização por Enxame de Partículas Evolucionárias - *Evolutionary Particle Swarm Optimization*-EPSO), com a finalidade de aplicação no processo de estimação dos parâmetros dos módulos fotovoltaicos.

No Capítulo 4, foi mostrado todo o processo de estimação de parâmetros do modelo global não-linear, onde através da aplicação dos métodos de otimização em conjunto com estratégias definidas, foram obtidos os resultados para cinco tecnologias de módulos FV. Um comparativo da precisão da estimação pelos métodos de otimização foi realizado através do erro entre as curvas do modelo e curvas experimentais, mostrando que a escolha do método de otimização na estimativa dos parâmetros influencia na precisão do modelo em reproduzir curvas para condições ambientais variáveis quando comparado as curvas experimentais.

Os resultados mostraram que os métodos estocásticos podem conduzir a bons resultados

(menor valor dos erros $EMAP_{med}$ e $RMSD_{med}$) na estimativa dos parâmetros do modelo global não-linear na maioria dos módulos de tecnologias distintas avaliadas quando comparados ao método padrão PS (GPS 2N). O método PS (MADS NP1-Completo), apresentou bons resultados em três dos cinco módulos avaliados, porém em dois módulos apresentou desvio padrão maior quando comparados com outros módulos. Portanto, ao avaliar um módulo específico deve-se realizar um estudo com os métodos a serem aplicados e verificar quais deles pode-se obter os melhores resultados na estimação de parâmetros, pois conforme os resultados obtidos constatou-se que a aplicação de algoritmos de otimização alternativos ao método padrão PS(GPS 2N) podem ser efetivamente considerados na estimação de parâmetros do modelo global não-linear para a obtenção de melhores resultados.

De acordo com os resultados, pode-se inferir também que o modelo global não-linear representa melhor as tecnologias de silício cristalino e silício policristalino, pois os valores de $EMAP_{med}$ são menores do que 1W, enquanto para as outras tecnologias são maiores do que 1W. Esse resultado pode ser verificado em uma melhor aproximação das curvas geradas pelo modelo global não-linear em relação às curvas experimentais, ao estimar os parâmetros para essas tecnologias.

5.1 TRABALHOS FUTUROS

A seguir são enumeradas algumas sugestões de trabalhos futuros relacionados à esta dissertação:

1. Avaliar a aplicação de métodos de otimização multiobjetivo, visto que no processo de estimação de parâmetros do modelo global não-linear consiste em otimizar várias funções objetivo e os objetivos são conflitantes, ou seja, ao otimizar uma função pode afetar as outras funções.
2. Avaliar detalhadamente o modelo global não-linear aplicado a tecnologia de disseleneto de cobre, índio e gálio (CIGS), pois como visto em sua avaliação, além de apresentar o maior valor de $EMAP_{med}$ em relação às demais tecnologias, nota-se que as curvas reproduzidas pelo modelo apresentaram distorções relevantes quando comparado a curva experimental, sendo necessário verificar se as equações que definem o modelo se mantêm as mesmas ou se necessitam de modificações, ou até mesmo a proposição de um novo modelo.

3. Investigar o comportamento da aplicação do modelo global não-linear com os métodos de otimização para outras tecnologias não abordadas neste trabalho.

REFERÊNCIAS

- AID-ANEEL. *Geração Distribuída - Brasil ultrapassa 1GW em geração distribuída*. 2019. Disponível em: <https://www.aneel.gov.br/sala-de-imprensa-exibicao/-/asset_publisher/XGPXSqdMFHrE/content/brasil-ultrapassa-marca-de-1gw-em-geracao-distribuida/656877>. Acesso em: 15 nov. 2019.
- ALAM, M. Particle swarm optimization: Algorithm and its codes in matlab. Março 2016.
- ALHAJRI, M.; EL-NAGGAR, K.; ALRASHIDI, M.; AL-OTHMAN, A. Optimal extraction of solar cell parameters using pattern search, renewable energy. *Renewable Energy*, v. 44, Agosto 2012.
- AO, A. B. de S. S. Fundamentos de otimização por inteligência de enxames: Uma visão geral. *Controle e Automacao*, v. 20, p. 271–304, Julho 2009.
- ARAÚJO, G. P.; RAMANAUSKAS, L. F. da C.; ZANESCO, I.; MOEHLECKE, A. Comparação e análise de módulos fotovoltaicos com células de silício cristalino. *VII Congresso Brasileiro de Energia Solar*, 2018.
- AUDET, C.; DENNIS, J. Mesh adaptive direct search algorithms for constrained optimization. *SIAM Journal on Optimization*, v. 17, p. 188–217, Janeiro 2006.
- AUDET, C.; DENNIS, J. J. E. Analysis of generalized pattern searches. *SIAM Journal on Optimization*, v. 13, p. 889–903., 2003.
- BATZELIS, E. I.; PAPATHANASSIOU, S. A. A method for the analytical extraction of the single-diode pv model parameters. *IEEE Transactions on Sustainable Energy*, v. 7, n. 2, p. 504–512, Abril 2016.
- BATZELIS, E. I.; Routsolias, I. A.; PAPATHANASSIOU, S. A. An explicit PV string model based on the Lambert W function and simplified MPP expressions for operation under partial shading. *IEEE Transactions on Sustainable Energy*, v. 5, n. 1, p. 301–312, Janeiro 2014.
- BAUDIN, M.; COUVERT, V.; STEER, S. Optimization in scilab. Outubro 2019.
- BEATRIZ, P.; REBOLLAR, M.; RODRIGUES, P.; GUERRA, J. B. A.; YOUSSEF, Y. *Energia Solar*. [S.l.: s.n.], 2011.
- BENAHMIDA, A.; MAOUHOUB, N.; SAHSAH, H.; MOKHLISS, H.; RAIS, K. Parameter identification of photovoltaic generators using an analytical approach and iterative method. In: *2019 International Conference of Computer Science and Renewable Energies (ICCSRE)*. [S.l.: s.n.], 2019. p. 1–5.
- BENGTJARS, A.; VALJAMETS, E. *Optimization of Pile Groups - A practical study using Genetic Algorithm and Direct Search with four different objective functions*. Dissertação (Mestrado) — KTH Royal Institute of Technology, Sweden, 2014.
- BLUM, C.; ROLI, A. Metaheuristics in combinatorial optimization: Overview and conceptual comparison. *ACM Comput. Surv.*, v. 35, p. 268–308, Janeiro 2001.

- BONKOUNGOU, D.; KOALAGA, Z.; NJOMO, D.; ZOUGMORé, F. An improved numerical approach for photovoltaic module parameters acquisition based on single diode model. *International Journal of Current Engineering and Technology*, Dezembro 2015.
- BOYD, S. P.; VANDENBERGHE, L. *Convex Optimization*. 1ª edição. ed. [S.l.]: Cambridge University Press, 2004.
- CEPEL-CRESESB. *Manual de Engenharia para Sistemas Fotovoltaicos*. Rio de Janeiro: [s.n.], 2014.
- CORREIA, J. R. L. S. *Estudo e aplicação de um sistema de Concentração Fotovoltaica (CPV) com utilização de células Multijunção*. Dissertação (Mestrado) — Instituto Superior de Lisboa, Lisboa, 2018.
- COTFAS, D. T.; COTFAS, P. A.; CATARON, A. Using the genetic algorithm to determine the parameters of photovoltaic cells and panels. In: *2018 International Symposium on Electronics and Telecommunications (ISETC)*. [S.l.: s.n.], 2018. p. 1–4.
- DALI, A.; BOUHARCHOUCHE, A.; DIAF, S. Parameter identification of photovoltaic cell/module using genetic algorithm (GA) and particle swarm optimization (PSO). In: *2015 3rd International Conference on Control, Engineering Information Technology (CEIT)*. [S.l.: s.n.], 2015. p. 1–6.
- DALI, A.; BOUHARCHOUCHE, A.; DIAF, S. Parameter identification of photovoltaic cell/module using genetic algorithm (GA) and particle swarm optimization (PSO). In: *2015 3rd International Conference on Control, Engineering Information Technology (CEIT)*. [S.l.: s.n.], 2015. p. 1–6.
- DHGATE.COM. 2019. Disponível em: <<https://pt.dhgate.com/product/hanergy-solar-tile-american-cigs-solar-cells/436305636.html>>. Acesso em: 17 nov. 2019.
- DONGUE, S. B.; NJOMO, D.; EBENGAI, L. An improved nonlinear five-point model for photovoltaic modules. *Environmental Energy Technologies Laboratory (EETL), Faculty of Sciences, University of Yaoundé 1, P.O. Box 812, Yaoundé, Cameroon*, p. 11, Setembro 2013.
- Dorigo, M.; Maniezzo, V.; Coloni, A. Ant system: optimization by a colony of cooperating agents. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, v. 26, p. 29–41, Fevereiro 1996.
- FEO, T.; RESENDE, M. Greedy randomized adaptive search procedures. *Journal of Global Optimization*, v. 6, p. 109–133, Março 1995.
- FREEPIK. *Imagens vetoriais*. 2019. Disponível em: <<https://br.freepik.com/home>>. Acesso em: 16 set. 2019.
- GLOVER, F.; LAGUNA, M. *Tabu Search*. [S.l.]: Kluwer Academic Publishers, 1997.
- GOLDBERG, D. E. *Genetic Algorithms in Search, Optimization, and Machine Learning*. New York: Addison-Wesley, 1989.
- GOMES, P. H. G. *Geometria de dutos de escape otimizada para aplicação na cogeração da produção de energia elétrica*. 120 f. Dissertação (Mestrado) — Universidade Federal de Goiás, 2017.

- GONÇALVES, M. B. *Energia Fotovoltaica no Brasil*. 2019. Disponível em: <<https://www.institutodeengenharia.org.br/site/wp-content/uploads/2018/02/arqnot11130.pdf>>. Acesso em: 01 jan. 2020.
- GREEN, M. A.; DUNLOP, E. D.; LEVI, D. H.; HOHL-EBINGER, J.; YOSHITA, M.; HO-BAILLIE, A. W. Solar cell efficiency tables. *Progress in Photovoltaics: Research and Applications*, Junho 2019.
- GÜNEŞ, F.; TOKAN, F. Pattern search optimization with applications on synthesis of linear antenna arrays. *Expert Systems with Applications*, v. 37, n. 6, p. 4698 – 4705, 2010.
- HEJRI, M.; MOKHTARI, H.; AZIZIAN, M. R.; GHANDHARI, M.; SÖDER, L. On the parameter extraction of a five-parameter double-diode model of photovoltaic cells and modules. *IEEE Journal of Photovoltaics*, v. 4, n. 3, p. 915–923, Maio 2014.
- HOCAOGLU, F. O.; SERTTAS, F.; KUREKCI, M.; AKARSLAN, E.; CINAR, S. M.; DOGAN, R.; YONETKEN, A. Comparison of experimentally obtained i-v curves of different PV modules. In: *2018 9th International Renewable Energy Congress (IREC)*. [S.l.: s.n.], 2018. p. 1–4.
- HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. Ann Arbor, MI: University of Michigan Press, 1975.
- HOOKE, R.; JEEVES, T. Direct search solution of numerical and statistical problem. *J. ACM*, v. 8, p. 212–229, Abril 1961.
- INMETRO. *Tabela de Eficiência Energética - Sistema de Energia Fotovoltaica - Módulos - Edição 2017*. 2018. Disponível em: <http://www.inmetro.gov.br/consumidor/pbe/tabela_fotovoltaico_modulo.pdf>. Acesso em: 17 nov. 2019.
- ISHAQUE, K.; SALAM, Z.; SYAFARUDDIN. A comprehensive matlab simulink pv system simulator with partial shading capability based on two-diode model. *Solar Energy*, v. 85, n. 9, p. 2217 – 2227, 2011. ISSN 0038-092X.
- JADLI, U.; THAKUR, P.; SHUKLA, R. D. A new parameter estimation method of solar photovoltaic. *IEEE Journal of Photovoltaics*, v. 8, n. 1, p. 239–247, Janeiro 2018.
- JAIN, V. P. L. C.; (EDS.), D. S. *Studies in Computational Intelligence - Advances in Evolutionary Computing for System Design*. [S.l.]: Springer, 2007. v. 66.
- JUNIOR, A. J. do N. *Contribuição à Modelagem de Módulos Fotovoltaicos e Proposta de uma Técnica Híbrida de Seguimento do Ponto de Máxima Potência com Estimador de Irradiância*. Tese (Doutorado) — Universidade Federal de Pernambuco, 2018.
- KASHANI, M. G. *Análise Exergo-Econômica-Ambiental de uma Planta de Cogeração de Lucro Máximo*. 85 p. Dissertação (Mestrado) — UFRJ/COPPE/Programa de Engenharia Mecânica, Rio de Janeiro, 2014.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: *Proceedings of ICNN'95 - International Conference on Neural Networks*. [S.l.: s.n.], 1995. v. 4, p. 1942–1948.
- KHANNA, V.; DAS, B.; SINGH, P.; PANWAR, V.; BISHT, D. A three diode model for industrial solar cells and estimation of solar cell parameters using PSO algorithm. *Renewable Energy*, v. 78, p. 105–113, Junho 2015.

- KHURSHEED, M. un N.; KHAN, M. F. N.; ALI, G.; KHAN, A. K. A review of estimating solar photovoltaic cell parameters. *International Conference on Computing, Mathematics and Engineering Technologies (iCoMET)*, v. 44, p. 1–6, 2019.
- KOLDA, R. M. L. T. G.; TORCZON, V. Optimization by direct search: New perspectives on some classical and modern methods. *SIAM Review*, v. 45, p. 385–482, 2003.
- KUMAR, P. J.; BABU, S.; DRAGICEVIC, T.; NATARAJAN, R. A new hybrid bee pollinator flower pollination algorithm for solar PV parameter estimation. *Energy Conversion and Management*, v. 135, p. 463–476, Março 2017.
- KYOCERA. 2019. Disponível em: <<https://www.kyocerasolar.com/dealers/product-center/archives/spec-sheets/KC200GT.pdf>>. Acesso em: 18 nov. 2019.
- Leite, H.; Barros, J.; Miranda, V. Evolutionary algorithm EPSO helping doubly-fed induction generators in ride-through-fault. In: *2009 IEEE Bucharest PowerTech*. [S.l.: s.n.], 2009. p. 1–8.
- LEITE, H.; BARROS, J.; MIRANDA, V. The evolutionary algorithm EPSO to coordinate directional overcurrent relays. In: *10th IET International Conference on Developments in Power System Protection (DPSP 2010). Managing the Change*. [S.l.: s.n.], 2010. p. 1–5.
- LEWIS, R.; SHEPHERD, A.; TORCZON, V. Implementing generating set search methods for linearly constrained minimization. *SIAM J. Scientific Computing*, v. 29, p. 2507–2530, Janeiro 2007.
- LIMA, A. A.; MENEZES, N. P.; SANTOS, S.; AMORIM, B.; THOMAZI, F.; ZANELLA, F.; HEILMANN, A.; BURKARTER, E.; DARTORA, C. A. Uma revisão dos princípios da conversão fotovoltaica de energia. *Revista Brasileira de Ensino de Física*, scielo, v. 42, 2020. ISSN 1806-1117.
- LIMA, F. A. de S. *Eletrodeposição de filmes finos de CdTe para aplicação em células solares fotovoltaicas*. 114 f. Dissertação (Mestrado) — Universidade Estadual do Ceará, 2010.
- LINGYUN, X.; LEFEI, S.; WEI, H.; CONG, J. Solar cells parameter extraction using a hybrid genetic algorithm. In: *2011 Third International Conference on Measuring Technology and Mechatronics Automation*. [S.l.: s.n.], 2011. v. 3, p. 306–309.
- LUENBERGER, D. G.; YE, Y. *Linear and Nonlinear Programming*. 3ª edição. ed. New York, NY: (Springer Science and Business Media, 2008).
- LUENBERGER, D. G.; YE, Y. *Linear and Nonlinear Programming. International Series in Operations Research Management Science*. 3ª edição. ed. [S.l.]: Springer, 2008.
- Mahmoud, Y. A.; Xiao, W.; Zeineldin, H. H. A parameterization approach for enhancing PV model accuracy. *IEEE Transactions on Industrial Electronics*, v. 60, n. 12, p. 5708–5716, Dezembro 2013.
- MAJDOUL, R.; ABDELMOUNIM, E.; ABOULFATAH, M.; TOUATI, A. W.; MOUTABIR, A.; ABOULOIFA, A. Combined analytical and numerical approach to determine the four parameters of the photovoltaic cells models. In: *2015 International Conference on Electrical and Information Technologies (ICEIT)*. [S.l.: s.n.], 2015. p. 263–268.

Marion, B.; Anderberg, A.; Deline, C.; del Cueto, J.; Muller, M.; Perrin, G.; Rodriguez, J.; Rummel, S.; Silverman, T. J.; Vignola, F.; Kessler, R.; Peterson, J.; Barkaszi, S.; Jacobs, M.; Riedel, N.; Pratt, L.; King, B. New data set for validating PV module performance models. In: *2014 IEEE 40th Photovoltaic Specialist Conference (PVSC)*. [S.l.: s.n.], 2014. p. 1362–1366.

MARTINS, J. L. R. de C. M. *Adaptação do modelo dinâmico de sistemas de excitação recorrendo a uma meta-heurística do tipo EPSO*. Dissertação (Mestrado) — Faculdade de Engenharia - Universidade do Porto, 2013.

MATHWORKS®. 2019. Disponível em: <<https://www.mathworks.com/help/gads/pattern-search-terminology.html>>. Acesso em: 07 dez. 2019.

MATHWORKS®. 2019. Disponível em: <<https://www.mathworks.com/help/gads/searching-and-polling.html>>. Acesso em: 07 dez. 2019.

MATHWORKS®. 2020. Disponível em: <<https://www.mathworks.com/help/gads/how-pattern-search-polling-works.html>>. Acesso em: 07 dez. 2019.

MEHTA, H. K.; WARKE, H.; KUKADIYA, K.; PANCHAL, A. K. Accurate expressions for single-diode-model solar cell parameterization. *IEEE Journal of Photovoltaics*, v. 9, p. 803–809, 2019.

MIRANDA, V.; FONSECA, N. EPSO - evolutionary particle swarm optimization, a new algorithm with applications in power systems. In: . [S.l.: s.n.], 2002. v. 2, p. 745 – 750 vol.2. ISBN 0-7803-7525-4.

MØLLER, S. *Study of Pattern Search Optimization and Implementation of Hooke-Jeeves Direct Search for Production Optimization using Perforations*. Dissertação (Mestrado) — Norwegian University of Science and Technology, 2016.

NEVES, G. M. *Influência do Espectro da Radiação Solar em Módulo Fotovoltaicos*. Dissertação (Mestrado) — Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos, 2016.

NI, B.; ZOU, P.; CHEN, Y.; ZHANG, Z. Identification of solar cell model parameters based on PSO with adaptive elite mutation. In: . [S.l.: s.n.], 2018. p. 1340–1344.

NREL. *User's Manual for Data for Validating Models for PV Module Performance*. [S.l.: s.n.], 2014.

NÚÑEZ, R.; Victoria, M.; Askins, S.; Antón, I.; Domínguez, C.; Herrero, R.; Sala, G. Spectral impact on multijunction solar cells obtained by means of component cells of a different technology. *IEEE Journal of Photovoltaics*, v. 8, n. 2, p. 646–653, Março 2018.

OGATA, K. *Engenharia de Controle Moderno*. 3ª edição. ed. Rio de Janeiro, RJ: LTC - Livros Técnicos e Científicos Editora S.A, 2000.

OGBOMO, O.; AMALU, D. E.; EKERE, N.; OLAGBEGI, P. A review of photovoltaic module technologies for increased performance in tropical climate. *Renewable and Sustainable Energy Reviews*, Novembro 2016.

OLIVA, D.; CUEVAS, E.; PAJARES, G. Parameter identification of solar cells using artificial bee colony optimization. *Energy*, v. 72, Agosto 2014.

- OTAEGI, A.; FANO, V.; AZKONA, N.; GUTIÉRREZ, J. R.; JIMENO, J. C. On the different explanations of the recombination currents with high ideality factor in silicon solar cells. In: *2017 IEEE 44th Photovoltaic Specialist Conference (PVSC)*. [S.l.: s.n.], 2017. p. 2740–2743.
- PERES, W. *Projeto de Controladores de Sistemas de Potência Utilizando Otimização Bioinspirada*. 306 f. Tese (Doutorado) — Universidade Federal de Juiz de Fora, 2016.
- PINHO, J. T.; BARBOSA, C. F. O.; PEREIRA, E. J. da S.; SOUZA, H. M. S.; BLASQUES, L. C. M.; GALHARDO, M. A. B.; MACÊDO, W. N. *Sistemas Híbridos - Soluções energéticas para a Amazônia*. 1ª edição. ed. Brasília: Ministério de Minas e Energia, 2008.
- POLI, R.; KENNEDY, J.; BLACKWELL, T. Particle swarm optimization: An overview. *Swarm Intelligence*, v. 1, Outubro 2007.
- PRIEB, C. W. M. *Desenvolvimento de um Sistema de Ensaio de Módulos Fotovoltaicos*. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Sul, Porto Alegre, 2002.
- RAPHAEL, E.; SILVA, M. N.; SZOSTAK, R.; SCHIAVON, M. A.; NOGUEIRA, A. F. Células solares de perovskitas: Uma nova tecnologia emergente. *Química Nova*, scielo, v. 41, p. 61 – 74, Janeiro 2018. ISSN 0100-4042.
- REIS, L. R. de D. *Determinação de Parâmetros de Módulos Fotovoltaicos Utilizando o Método de Newton-Raphson e Algoritmos Genéticos*. Dissertação (Mestrado) — Universidade Federal de Uberlândia-UFU, Uberlândia-MG, 2018.
- SABADUS, A.; PAULESCU, M.; BADESCU, V. Extracting the I-V characteristics of the PV modules from the manufacture's datasheet. In: . [S.l.: s.n.], 2018. p. 434–442. ISBN 978-3-319-63214-8.
- SAMPAIO, J. A.; AMADO, R. S.; MARQUES, P. S. G.; SOARES, L. G. L. *Silício Grau Solar – Uma Revisão das Tecnologias de Produção. Série Rochas e Minerais Industriais*. Rio de Janeiro: CETEM/MCTIC, 2019.
- SANTOS, A. S. dos. *Projeto de Estabilizadores de Sistemas de Potência utilizando EPSO Híbrido*. 124 p. Dissertação (Mestrado) — Universidade Federal de São João Del-Rei, São João Del-Rei, 2018.
- SANTOS, F. M. de P. *Algoritmo Enxame de Partículas Evolutivo para o Problema de Coordenação de Relés de Sobrecorrente Direcionais em Sistemas Elétricos de Potência*. Dissertação (Mestrado) — Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, 2013.
- SANYO. *Amorphous Silicon Solar Cells / Amorphous Photosensors*. 2019. Disponível em: <<https://www.datasheetarchive.com/>>. Acesso em: 17 nov. 2019.
- Sharma, A. K.; Kalasua, H.; Kumbhar, S.; Narasimhan, K. L.; Arora, B. M. Imaging of series resistance and ideality factor in c-si solar cells. In: *2016 3rd International Conference on Emerging Electronics (ICEE)*. [S.l.: s.n.], 2016. p. 1–3.
- SHI, Y.; EBERHART, R. Empirical study of particle swarm optimization. In: . [S.l.: s.n.], 1999. v. 3, p. 1950 Vol. 3. ISBN 0-7803-5536-9.
- SHI, Y.; RC, E. A modified particle swarm optimizer. In: . [S.l.: s.n.], 1998. v. 6, p. 69 – 73.

SI, I. 2020. Disponível em: <<https://www.imagesco.com/articles/photovoltaic/photovoltaic-pg4.html>>. Acesso em: 21 mar. 2020.

Silva, E. A.; Bradaschia, F.; Cavalcanti, M. C.; Nascimento, A. J. Parameter estimation method to improve the accuracy of photovoltaic electrical model. *IEEE Journal of Photovoltaics*, v. 6, n. 1, p. 278–285, Janeiro 2016. ISSN 2156-3403.

SILVA, E. A. da. *Técnicas de estimação de parâmetros de módulos fotovoltaicos*. Dissertação. 87 f. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2015.

SILVA, E. A. da. *Micro-Convertor c.c.-c.c. de alto ganho e eficiência integrado a um módulo fotovoltaico com algoritmo de MPPT baseado em um modelo adaptativo de 15 parâmetros*. Tese (Doutorado) — Universidade Federal de Pernambuco, 2019.

TORCZON, V. On the convergence of pattern search algorithms. *SIAM Journal on Optimization*, v. 7, p. 1–25, 1997.

TRETER, M. E.; MICHELS, L. *SEPOC 2018 - 11th Seminar on Power Electronics and Control*, n. 6, 2018.

TSAI; HUAN-LIANG. Insolation-oriented model of photovoltaic module using matlab/simulink. *Solar Energy - SOLAR ENERG*, v. 84, Julho 2010.

TUTKUN, N.; ELIBOL, E.; MADEN, D. Basic parameter extraction from an organic solar cell through the single diode model and a metaheuristic technique with the lambert w function. In: *2014 International Renewable and Sustainable Energy Conference (IRSEC)*. [S.l.: s.n.], 2014. p. 554–558.

VALLE, Y.; VENAYAGAMOORTHY, G.; MOHAGHEGHI, S.; MEJIA, J. H.; HARLEY, R. Particle swarm optimization: Basic concepts, variants and applications in power systems. *Evolutionary Computation, IEEE Transactions on*, v. 12, p. 171 – 195, Maio 2008.

VILLALVA, M. G. *Energia Solar Fotovoltaica - Conceitos e Aplicações*. 2ª edição. ed. [S.l.]: Saraiva, 2015.

WANG, L.; KISI, O.; ZOUNEMAT-KERMANI, M.; SALAZAR, G. A.; ZHU, Z.; GONG, W. Solar radiation prediction using different techniques: model evaluation and comparison. *Renewable and Sustainable Energy Reviews*, v. 61, p. 384 – 397, 2016. ISSN 1364-0321. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1364032116300417>>.

WEI, T.; Yu, F.; HUANG, G.; XU, C. A particle-swarm-optimization-based parameter extraction routine for three-diode lumped parameter model of organic solar cells. *IEEE Electron Device Letters*, v. 40, n. 9, p. 1511–1514, Setembro 2019.

XU, S.; WANG, Y. Parameter estimation of photovoltaic modules using a hybrid flower pollination algorithm. *Energy Conversion and Management*, v. 144, p. 53–68, Abril 2017.

YANG, X.-S. *Nature-Inspired Metaheuristic Algorithms*. 2ª edição. ed. [S.l.]: Luniver Press, 2010.

YE, M.; WANG, X.; XU, Y. Parameter extraction of solar cells using particle swarm optimization. *Journal of Applied Physics*, v. 105, p. 094502 – 094502, Junho 2009.

ZAGROUBA, M.; SELLAMI, A.; BOUAÏCHA, M.; KSOURI, M. Identification of PV solar cells and modules parameters using the genetic algorithms: Application to maximum power extraction. *Solar Energy*, v. 84, n. 5, p. 860 – 866, 2010.