



**INSTITUTO LATINO-AMERICANO DE
CIÊNCIAS DA VIDA E DA NATUREZA
(ILACVN)**

ENGENHARIA FÍSICA

**ALGORITMO DE OTIMIZAÇÃO SHUFFLED FROG LEAPING APLICADO EM
SISTEMAS FOTOVOLTAICOS COM SOMBREAMENTO PARCIAL (SFLA-MPPT)**

FÁBIO JOSÉ RODRIGUES

Foz do Iguaçu
2023

**ALGORITMO DE OTIMIZAÇÃO SHUFFLED FROG LEAPING APLICADO EM
SISTEMAS FOTOVOLTAICOS COM SOMBREAMENTO PARCIAL (SFLA-MPPT)**

FÁBIO JOSÉ RODRIGUES

Trabalho de Conclusão de Curso apresentado ao Instituto Latino-Americano de Ciências da Vida e da Natureza, como requisito parcial à obtenção do título de Bacharel em Engenharia Física.

Orientador: Prof. Dr. Walber Ferreira Braga

Foz do Iguaçu
2023

**ALGORITMO DE OTIMIZAÇÃO SHUFFLED FROG LEAPING APLICADO EM
SISTEMAS FOTOVOLTAICOS COM SOMBREAMENTO PARCIAL (SFLA-MPPT)**

Trabalho de Conclusão de Curso apresentado ao Instituto Latino-Americano de Ciências da Vida e da Natureza, como requisito parcial à obtenção do título de Bacharel em Engenharia Física.

BANCA EXAMINADORA

Orientador: Prof. Dr. Walber Ferreira Braga
UNILA

Prof. Me. Fernando Marcos de Oliveira
PTI / UTFPR

Prof. Dr. Joylan Nunes Maciel
UNILA

Foz do Iguaçu, 15 de Junho de 2023.

*Afeto e conhecimento são duas coisas
que se você guardar,
você perde.*
(Mário Sergio Cortella)

Agradecimentos

Agradeço ao meu professor orientador Walber Ferreira, pelos ensinamentos para a realização deste trabalho.

Agradeço ao meu supervisor Fernando Oliveira, pela orientação, pelo apoio no desenvolvimento e validação dos algoritmos.

Agradeço os professores Dáfni Marchioro, Eduardo do Carmo e Raphael Fortes, por fornecerem o suporte necessário em momentos de dificuldade.

Agradeço a todos os professores que tive durante minha formação, por compartilharem seus conhecimentos da melhor forma possível.

Agradeço à Universidade Federal da Integração Latino-Americana (UNILA), pela oportunidade de cursar Engenharia Física.

Agradeço ao Parque Tecnológico Itaipu (PTI), pela oportunidade de estágio fornecida, onde este trabalho se iniciou.

Agradeço a minha família, meu pai Henrique e minha mãe Waldiva, e meus irmãos Clóvis e Daisy, pelo apoio e amor oferecido durante toda a vida.

Agradeço aos meus amigos, Ana Carolina, Henrique Plotegher, Leonardo Almeida, Mariana de Souza, Paula Lima, Pauline Pinto, Rafael Oliveira, Renan Ferreira e Vinícius Reis por estarem presentes durante a minha trajetória acadêmica, dentro e fora da universidade.

Agradeço a todos meus amigos de curso, pela oportunidade de convívio e aprendizagem nestes últimos anos.

Resumo

O aumento do consumo de energia elétrica em todo o mundo tem levado ao desenvolvimento de novas tecnologias para a redução de emissões de poluentes e a diminuição da degradação do meio ambiente. No Brasil, as dificuldades para implantação de novas unidades geradoras e a busca por fontes de energia alternativas têm impulsionado a geração de energia elétrica por fontes renováveis, especialmente a solar e a eólica. No entanto, é necessário buscar a otimização de performance e a resolução de problemas clássicos, como a perda de eficiência devido ao sombreamento parcial, no caso de geração fotovoltaica. O algoritmo Perturbe e Observe, mais utilizado comercialmente, pode falhar ao tentar localizar o ponto de operação de um arranjo de painéis solares. Visto isso foi realizada a implementação dos algoritmos Perturbe e Observe e também *Shuffled Frog Leaping Algorithm* aplicados no chaveamento um conversor de corrente contínua do tipo *boost*, utilizando o *software* de simulação PSim para avaliar as curvas de resposta da potência, e compará-las. Observa-se vantagens para cada um dos métodos dependendo da resposta desejada. O Perturbe e Observe mostra uma resposta de convergência mais rápida quando comparado com o *Shuffled Frog Leaping Algorithm*, porém apresenta uma oscilação de potência de saída e possui o risco de não alcançar a tensão de operação ideal. Já o *Shuffled Frog Leaping Algorithm* demonstrou sempre localizar a potência de operação desejada ao custo de um tempo de convergência mais lento.

Palavras chave: energia solar fotovoltaica, rastreamento do ponto de máxima potência, conversor boost, algoritmo bio-inspirado, algoritmo dos sapos.

Abstract

The increase in electricity consumption worldwide has led to the development of new technologies for the reduction of pollutant emissions and the reduction of environmental degradation. In Brazil, the difficulties in implementing new generating units and the search for alternative energy sources have driven the generation of electricity from renewable sources, especially solar and wind. However, it is necessary to seek performance optimization and the resolution of classic problems, such as efficiency loss due to partial shading. The most commercially used Perturb and Observe algorithm may fail when trying to locate the operating point of a solar panel arrangement. Therefore, the implementation of the Perturb and Observe and also the Shuffled Frog Leaping Algorithm algorithms applied to the switching of a direct current converter was performed, using the PSim simulation software to evaluate and compare the power response curves. Advantages are observed for each of the methods depending on the desired response. The Perturb and Observe shows a faster convergence response when compared to the *Shuffled Frog Leaping Algorithm*, but presents an output power oscillation and has the risk of not reaching the optimal operating voltage. The *Shuffled Frog Leaping Algorithm*, on the other hand, has been shown to always locate the desired operating power at the cost of a slower convergence time.

Keywords: photovoltaic solar energy, maximum power point tracking, boost converter, bio-inspired algorithm, shuffled frog leaping algorithm.

Resumen

El aumento del consumo de electricidad en todo el mundo ha llevado al desarrollo de nuevas tecnologías para reducir las emisiones contaminantes y reducir la degradación del medio ambiente. En Brasil, las dificultades para implantar nuevas unidades generadoras y la búsqueda de fuentes de energía alternativas han impulsado la generación de electricidad a partir de fuentes renovables, especialmente solar y eólica. Sin embargo, es necesario buscar la optimización del rendimiento y resolver problemas clásicos, como la pérdida de eficiencia debida al sombreado parcial. El algoritmo Perturbe y Observe, más utilizado comercialmente, puede fallar cuando se intenta localizar el punto de funcionamiento de una disposición de paneles solares, por ello se realizó la implementación de los algoritmos Perturbe y Observe y también *Shuffled Frog Leaping Algorithm* aplicados en la conmutación de un convertidor de corriente continua tipo *boost*, utilizando el *software* de simulación PSim para evaluar las curvas de respuesta de potencia, y compararlas. Se observan ventajas para cada uno de los métodos en función de la respuesta deseada. El Perturbe y Observe muestra una respuesta de convergencia más rápida en comparación con el *Shuffled Frog Leaping Algorithm*, sin embargo presenta una oscilación de la potencia de salida y tiene riesgo de no alcanzar la tensión óptima de funcionamiento. Por otro lado, se ha demostrado que el algoritmo *Shuffled Frog Leaping Algorithm* siempre localiza la potencia de funcionamiento deseada a costa de un tiempo de convergencia más lento.

Palabras clave: energía solar fotovoltaica, seguimiento del punto de máxima potencia, convertidor boost, algoritmo bio-inspirado, algoritmo de los sapos.

Lista de Figuras

2.1	Curvas características corrente-tensão para diferentes irradiâncias.	15
2.2	Curvas características corrente-tensão para diferentes temperaturas.	15
2.4	Fluxograma da Técnica Condutância Incremental	19
2.5	Fluxograma da Técnica Perturbe e Observe	21
2.6	Fluxograma do Algoritmo Genético	23
2.7	Fluxograma do Algoritmo dos Sapos.	25
3.1	Circuito simplificado utilizado para as simulações.	29
3.2	Arranjo de painéis fotovoltaicos utilizado para simulações.	30
3.3	Ambiente de simulação com algoritmo P&O	31
3.4	Ambiente de simulação com algoritmo SFLA	32
4.1	Arranjo de painéis fotovoltaicos sem sombreamento.	36
4.2	Curva PV do arranjo em condições ideais	36
4.3	Arranjo de painéis fotovoltaicos com um sombreamento.	37
4.4	Curva PV do arranjo com sombreamento parcial em um painel fotovoltaico	37
4.5	Arranjo de painéis fotovoltaicos com dois sombreamentos.	38
4.6	Curva PV do arranjo com sombreamento parcial em dois painéis fotovoltaicos	38
4.7	Curva de potência do arranjo em condições ideais para MPPT-P&O	39
4.8	Curva de potência do arranjo com sombreamento parcial em um painel fotovoltaico para MPPT-P&O	40
4.9	Curva de potência do arranjo com sombreamento parcial em dois painel fotovoltaico para MPPT-P&O	41
4.10	Curva de potência do arranjo em condições ideais para MPPT-SFLA	42
4.11	Curva de potência do arranjo com sombreamento parcial em um painel fotovoltaico para MPPT-SFLA	43
4.12	Curva de potência do arranjo com sombreamento parcial em dois painel fotovoltaico para MPPT-SFLA	44
4.13	Comparação entre os algoritmos quando submetidos a dois sombreamentos	45
4.14	Comparação entre os algoritmos quando submetidos a dois sombreamentos	46
4.15	Comparação entre os algoritmos quando submetidos a dois sombreamentos	47

Lista de Abreviações e Siglas

MPPT	<i>Maximum Power Point Tracking</i>
PV	Painel Fotovoltaico
P&O	Perturbe e Observe
CI	Condutância Incremental
AG	Algoritmo Genético
SFLA	<i>Shuffled Frog Leaping Algorithm</i>
MOSFET	<i>Metal-Oxide Semiconductor Field-Effect Transistors</i>
PWM	<i>Pulse-Width Modulation</i>
CI	Condutância Incremental
I	Corrente
V	Tensão
P	Potência
Δ	Variação
S	Variação de posição
P_B	Posição do melhor sapo
P_W	Posição do pior sapo
M_q	Nova posição do pior sapo
L	Indutância
R	Resistência
C	Capacitância
f_s	Frequência de chaveamento
V_{in}	Tensão de entrada
V_{out}	Tensão de saída
V_r	Ondulação de Tensão na saída
D	Ciclo de Trabalho
DC	<i>Direct Current</i>
CC	Corrente contínua
MPP	<i>Maximum Power Point</i>

Conteúdo

1	Introdução	12
1.1	Contextualização	12
1.2	Objetivo Geral	13
1.3	Objetivos Específicos	13
2	Revisão Teórica	14
2.1	Geração Fotovoltaica	14
2.1.1	Curvas Características de Painéis Fotovoltaicos	14
2.1.2	Conversor CC/CC	16
2.1.3	<i>Maximum Power Point Tracking</i>	16
2.1.4	Sombreamento Parcial	17
2.2	Algoritmos MPPT Tradicionais	17
2.2.1	Condutância incremental	18
2.2.2	Perturbe e Observe	20
2.3	Algoritmos MPPT Bioinspirados	22
2.3.1	Algoritmo Genético	22
2.3.2	<i>Shuffled Frog Leaping Algorithm</i>	24
3	Implementação	29
3.1	O sistema de estudo	29
3.2	Perturbe e Observe	31
3.3	<i>Shuffled Frog Leaping Algorithm</i>	31
4	Estudo de Caso	33
4.1	Variáveis de Simulação	33
4.1.1	Variáveis Similares	33
4.1.2	Variáveis Específicas	33
4.1.3	Variáveis Arbitradas	35
4.1.4	Curvas PV do arranjo fotovoltaico	35
4.2	Resultados	39
4.2.1	P&O	39
4.2.2	SFLA	41
4.3	Conclusão	45
5	Conclusão	48
	Referencias bibliograficas	49

Capítulo 1

Introdução

1.1 Contextualização

Devido ao grande aumento do consumo de energia elétrica em âmbito mundial, tem se investido muitos esforços em pesquisas e aplicações na área de fontes energéticas. O desenvolvimento de novas tecnologias em que se busca a redução da emissão de poluentes e a diminuição da degradação do meio ambiente aponta para o uso de fontes de energia renováveis como uma melhor opção. O sol, por sua vez, é uma fonte de energia inesgotável, tanto em forma de luz quanto em forma de calor (CEPEL, 2004).

O setor elétrico brasileiro encontra diversas dificuldades para implantação de novas unidades geradoras, principalmente, devido a problemas ambientais e custos de implantação, fazendo com que as empresas busquem por fontes de energia alternativas, como a geração eólica e solar fotovoltaica. Por isso, a geração de energia elétrica por fontes renováveis vem ganhando espaço na matriz energética, principalmente com a geração de energia eólica e solar fotovoltaica. Especificamente falando, com o crescimento da participação da energia solar fotovoltaica, é necessário a busca por otimização de performance e resolução de problemas clássicos como a perda de eficiência devido a temperatura e sombreamento parcial (CREPALDI; AMOROSO; ANDO, 2018).

Para fazer com que os painéis fotovoltaicos sejam capazes de ajustar sua tensão correspondente a potência máxima, é utilizado um rastreamento do máximo ponto de potência (MPPT), empregando algoritmos de otimização capazes de convergir para o pico máximo da curva potência x tensão. Entretanto, o MPPT se torna desafiador quando a superfície do painel fotovoltaico está parcialmente sombreada. O sombreamento parcial reduz significativamente a

potência de saída de um painel fotovoltaico devido à queda da corrente pelo módulo afetado. Para mitigar o efeito do sombreamento, diodos de escape são conectados na saída do painel fotovoltaico que bloqueiam as baixas correntes através dos módulos sombreados. Entretanto, ao incluir esses diodos introduz picos de potência na curva potência x tensão característica dos painéis, onde um dos picos está relacionado com o máximo global do sistema, e todos os outros estão relacionados com máximos locais que dificultam o rastreamento do ponto de máxima potência (PERVEZ; ANTONIADIS; MASSOUD, 2022).

O rastreamento do ponto de máxima potência requer algoritmos eficientes. Muitos dos avanços em problemas de otimização que têm sido alcançados ao longo do tempo inspiram-se em sistemas naturais, dada a sua adaptabilidade, vista como uma ótima estratégia para resolução de diversos tipos de problemas. Assim, os algoritmos bio-inspirados têm se transformado crescentemente em poderosas ferramentas para solução de problemas de otimização, ao abrir mão da solução exata ótima por um conjunto de soluções aproximadas que são viáveis e que resolvem o problema em tempo computacional finito (YANG, 2010).

1.2 Objetivo Geral

Este trabalho tem como objetivo realizar a comparação entre o algoritmo MPPT tradicional perturbe e observe com o algoritmo bio-inspirado *shuffled frog leaping* a fim de avaliar suas estabilidades, tempos de convergência e erros.

1.3 Objetivos Específicos

Para alcançar o objetivo geral, é necessário:

- Estudo bibliográfico dos métodos utilizados;
- Implementar e simular um conversor CC/CC do tipo boost, posteriormente explanados;
- Implementar e simular o algoritmo MPPT perturbe e observe;
- Implementar e simular o algoritmo MPPT *shuffled frog leaping*;
- Definir os parâmetros dos algoritmos quanto aplicados a sistemas PV;
- Fazer a comparação dos métodos.

Capítulo 2

Revisão Teórica

2.1 Geração Fotovoltaica

O aproveitamento da energia gerada pelo Sol, inesgotável na escala terrestre de tempo, tanto como fonte de calor quanto de luz, é hoje, sem sombra de dúvidas, uma das alternativas energéticas mais promissoras para enfrentarmos os desafios do novo milênio. A Energia Solar Fotovoltaica é a energia obtida através da conversão direta da luz em eletricidade (Efeito Fotovoltaico). O efeito fotovoltaico, relatado por Edmond Becquerel, em 1839, é o aparecimento de uma diferença de potencial nos extremos de uma estrutura de material semicondutor, produzida pela absorção da luz (CEPEL, 2004).


Apesar dos sistemas fotovoltaicos estarem se tornando importantes na matriz energética, eles apresentam alguns desafios, pois, os dispositivos utilizados para o condicionamento de energia, assim como as técnicas de controle empregadas para o funcionamento do sistema, devem garantir que o sistema forneça a máxima potência disponível, além de uma elevada eficiência. Devido a algumas características destes sistemas, isso se torna um desafio para a engenharia, pois estes apresentam curvas características de corrente-tensão não lineares, as quais são fortemente influenciadas pelos fatores de radiação solar e temperatura (CASARO; MATINS, 2008).

2.1.1 Curvas Características de Painéis Fotovoltaicos

As curvas características ditam como o sistema se comportará mediante as variáveis de entrada (tensão, corrente, irradiância solar e temperatura). Há duas curvas características que relacionam a corrente com a tensão, a primeira as relaciona com a variação de irradiância

solar nos painéis fotovoltaicos. Pode-se perceber a queda de corrente no painel com a diminuição da irradiância. Fabricantes de painéis fotovoltaicos utilizam a irradiância de $1000\text{W}/\text{m}^2$ como valor padrão.


Figura 2.1: Curvas características corrente-tensão para diferentes irradiâncias.



Fonte: Autor, 2023.

A segunda curva relaciona a corrente com a tensão para diferentes valores de temperatura, aqui, os fabricantes de painéis fotovoltaicos utilizando a temperatura de 25°C como padrão. É evidente que para temperaturas mais altas, a área sob a curva característica diminui, ou seja, a potência máxima disponível no arranjo também irá diminuir.

Figura 2.2: Curvas características corrente-tensão para diferentes temperaturas.



Fonte: Autor, 2023.

A terceira curva, que será a mais abordada, é a curva MPP (*maximum power point*), também chamada de curva PV. Ela é caracterizada pela potência em função da tensão do painel. A curva PV do arranjo nos mostra qual valor de potência máxima que pode ser extraída do sistema PV para as devidas condições de operação. O MPPT (*maximum power point tracking*) é um processo importante para aumentar a eficiência dos arranjos fotovoltaicos, é uma técnica para localizar o ponto máximo da curva PV com o máximo possível de precisão, e será explanado detalhadamente a seguir.

Figura 2.3: Curva potência por tensão para um módulo solar em condições ideais

2.1.2 Conversor CC/CC

O conversor CC/CC (também chamado de *chopper*) é utilizado para obter uma tensão CC variável a partir de uma fonte de tensão DC constante. O valor médio da tensão de saída varia quando se altera a proporção do tempo no qual a saída fica ligada à entrada. Essa conversão pode ser obtida pela combinação de um indutor, um capacitor e um dispositivo de estado sólido que opere no modo de chaveamento em alta frequência, como o MOSFET (*metal-oxide semiconductor field-effect transistors*). A técnica de chaveamento utilizada nos conversores CC/CC é denominada PWM (*pulse-width modulation* - modulação por largura de pulso). Há duas espécies fundamentais de circuitos *chopper*: *step-down* ou *buck* e *step-up* ou *boost*. O *chopper buck* produz uma tensão de saída menor ou igual à tensão de entrada; o *chopper boost* fornece uma tensão de saída maior ou igual à tensão de entrada (ASHFAQ, 2000).

2.1.3 *Maximum Power Point Tracking*

O ponto de operação de células PV é influenciado pela radiação solar, temperatura da célula solar e valores de carga do circuito. Para um dado valor de irradiação e temperatura, existe apenas um ponto de operação para o arranjo PV com saída de potência máxima. Por isso é necessário um MPPT (*Maximum Power Point Tracking*), que permitem que os painéis operem extraindo o máximo de potência disponível pelo arranjo PV independentemente das condições de irradiância e temperatura. O princípio de funcionamento das técnicas MPPT é pelo ajuste da impedância da carga, fazendo com que a geração solar trabalhe sempre nas proximidades no ponto de máxima potência (XUE; WANG, 2013). O MPPT é uma necessidade

em sistemas de conversão de energia oriundas de fontes renováveis, ou seja, também deve ser utilizado para sistemas eólicos, eletrolizadores e outros.

A localização do ponto de máxima potência de um arranjo de painéis operando em condições ideais pode ser facilmente localizada utilizando o que são chamados de métodos MPPT tradicionais. Entretanto, com a ocorrência de sombreamento parcial do sistema PV, tais métodos perdem sua eficiência, podendo indicar potências máximas que não correspondem ao máximo global do sistema.

O MPPT mais simples, e o primeiro utilizado em painéis fotovoltaicos é chamado de Método da Tensão Constante. Este método diz que podemos analisar a curva característica corrente-tensão para diferentes irradiâncias (figura 2.1), e a tensão de operação será de aproximadamente 80% da tensão de circuito aberto (LI et al., 2022).

2.1.4 Sombreamento Parcial

Quando o arranjo PV está operando sobre condições ideais, ou seja, todas as células com a mesma irradiância solar, teremos uma curva PV característica como visto na seção 2.1.1. Nessas condições o método da Tensão Constante era confiável para obter um ponto de operação satisfatório para o sistema. Porém, quando parte do arranjo PV está submetido ao sombreamento parcial, ou seja, nem todas as células fotovoltaicas estão sob a mesma irradiância solar, o método se mostra insatisfatório para a localização do ponto de máxima potência (LI et al., 2022).

O fenômeno do sombreamento parcial reduz a potência de saída do painel devido à queda de corrente nas células afetadas. Para mitigar este efeito, diodos de escape são conectados em paralelo com cada painel PV, juntamente com um capacitor. Este arranjo bloqueia as baixas correntes indesejadas nos módulos sombreados. Essa nova configuração sob condições de sombreamento parcial faz com que seja formado novos picos de potência na curva PV, onde apenas uma está relacionada com a tensão de operação ideal do sistema (PERVEZ; ANTONIADIS; MASSOUD, 2022).

2.2 Algoritmos MPPT Tradicionais

Com a formação de novos picos de potência na curva PV, o método MPPT da Tensão Constante deixa de ser uma boa alternativa para a otimização de sistemas PV. Devido

a isso, novos métodos MPPT foram desenvolvidos a fim de melhorar a resposta dos arranjos PV. Alguns desses métodos são: condutância incremental (CI), perturba e observa (P&O), método beta, e método baseado em controle de temperatura.

Aqui destaca-se dois dos métodos mais utilizados atualmente, o condutância incremental e o perturba e observe. Ambos os métodos são bem consolidados comercialmente e se baseiam no cálculo de derivadas para levar a tensão de operação para o valor ideal.

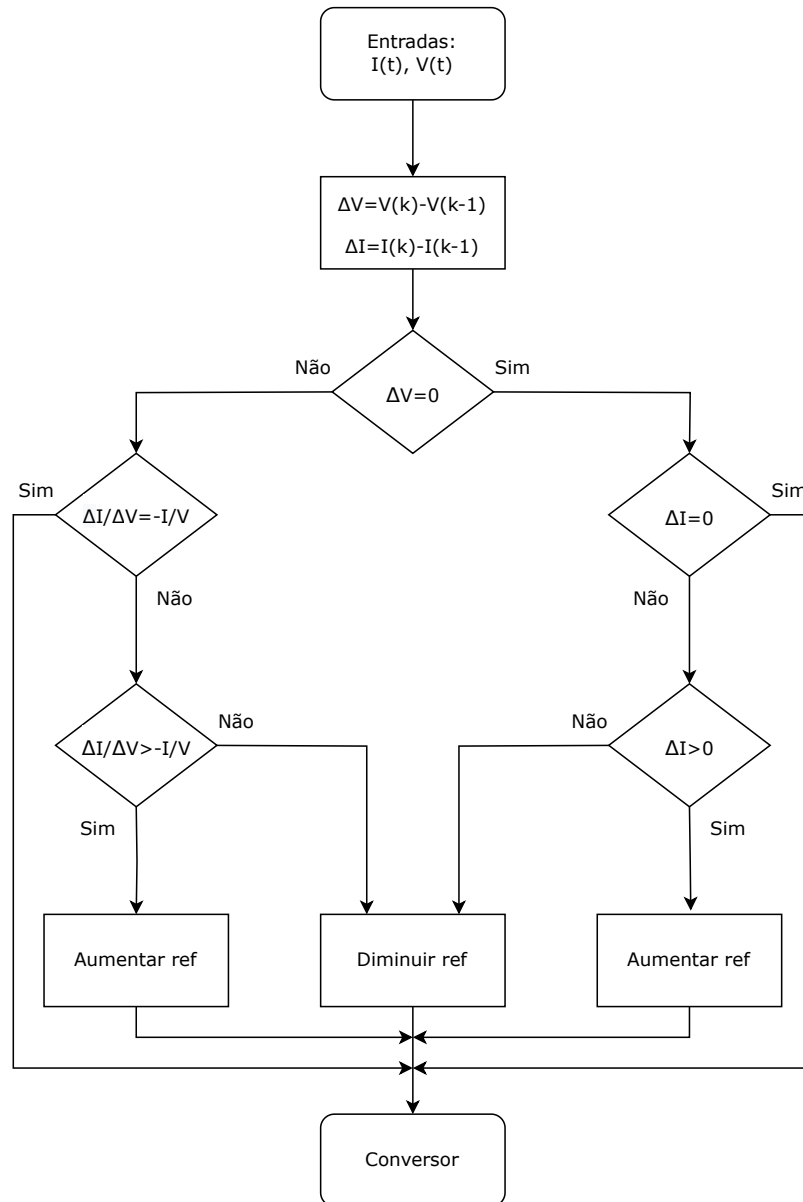
2.2.1 Condutância incremental

A técnica da condutância incremental se baseia no fato da derivada da potência em relação a tensão no ponto de máxima potência da curva PV ser nula. Além disso, ela é positiva para pontos à esquerda, e negativo para pontos à direita. Neste método verifica-se a potência do painel em dois instantes de tempo subsequentes para realizar a comparação entre potência e tensão.

$$\frac{dP}{dV} = \frac{d(V \times I)}{dV} = I + V \times \frac{dI}{dV} \quad (2.1)$$

Aproximando a derivada por um intervalo de tempo teremos então que $\frac{\Delta I}{\Delta V} = -\frac{I}{V}$ no ponto de máxima potência. Da mesma forma $\frac{\Delta I}{\Delta V} > -\frac{I}{V}$ à esquerda do ponto de máxima potência e $\frac{\Delta I}{\Delta V} < -\frac{I}{V}$ à direita. O fluxograma da técnica MPPT-CI segue a seguir.

Figura 2.4: Fluxograma da Técnica Condutância Incremental



Fonte: Autor, 2023.

Deve-se inicializar o algoritmo fornecendo as tensões e correntes nos dois instantes de tempo como citado acima para o cálculo de variações de tensão e corrente. Em seguida segue uma quantidade de comparações, primeiramente verifica-se se a variação de tensão é nula. Caso positivo, verifica-se se a variação de corrente é nula: caso positivo o sistema já está operando no MPP, caso negativo deve-se alterar o valor de referência dependendo do sinal da variação de corrente. No primeiro passo, caso a variação de tensão não seja nula,

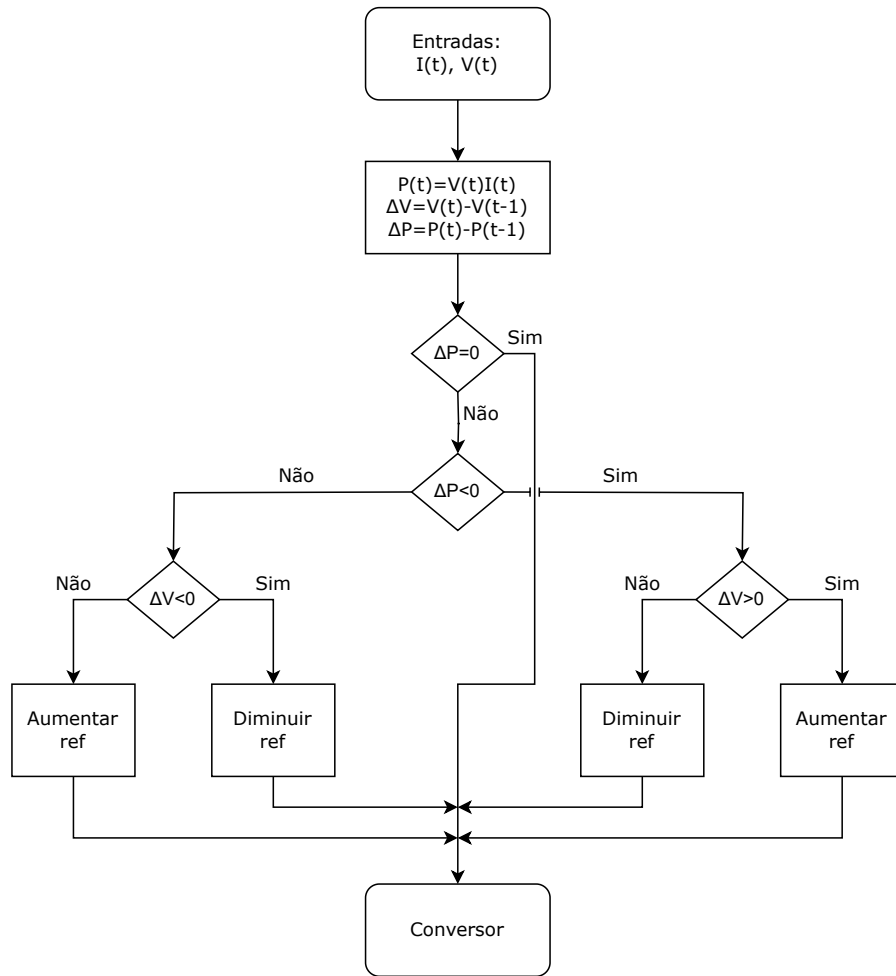
deve-se utilizar as equações previamente mostradas para alterar, ou não, o valor de referência até encontrar o MPP (RAEDANI; HANIF, 2014).

2.2.2 Perturbe e Observe

O algoritmo perturbe e observe (P&O) se destaca por não necessitar de uma base de dados, treinamento ou estudo sobre a irradiância ou temperatura do local de operação da planta solar. Isso garante a versatilidade deste método, com aplicação direta no sistema, sem necessidade de informações prévias ou de sensores de temperatura e irradiância, o que permite uma implementação mais barata quando comparado a outros métodos. Por sua versatilidade e fácil aplicação, esta técnica é a mais utilizada comercialmente como técnica MPPT de painéis fotovoltaicos (MENDONÇA et al., 2019).

O algoritmo Perturbe e Observe parte do princípio de induzir pequenas perturbações no sistema e observar como que isso afetará a variação de tensão e potência. A partir dessa variação de potência, pode-se então alterar o ciclo de trabalho a fim de maximizar a potência do sistema (OLIVEIRA, 2015).

Em cada ciclo de operação, o controlador monitora a corrente e a tensão do sistema PV, e calcula qual é a potência naquele instante de tempo. Então o ponto de operação (ciclo de trabalho, conseqüentemente tensão de operação) é perturbado por um valor pré-determinado, e no novo instante de tempo o monitoramento e cálculo de potência é realizado novamente. Caso a potência aumente, a próxima perturbação deve ser realizada na mesma direção que a anterior. Porém, caso a potência diminua, a perturbação deve ser feita na direção oposta que a anterior, e este cenário é repetido até o método alcançar o MPP. O fluxograma para este método está representado na figura 2.5 (KARAMI; MOUBAYED; OUTBIB, 2017).

Figura 2.5: Fluxograma da Técnica Perturbe e Observe

Fonte: Autor, 2023.

De forma similar ao método CI, deve-se inicializar o algoritmo fornecendo as tensões e correntes nos dois instantes de tempo iniciais, para o cálculo da potência nos dois instantes de tempo. Em seguida verifica-se se houve variação de potência entre os dois instantes de tempo, em caso negativo, o sistema já estará operando no MPP e não é necessário alterar o ponto de operação. Caso a variação de potência exista, verifica-se a variação de tensão entre os dois instantes de tempo e deve-se alterar o ponto de operação de acordo como descrito acima até que se alcance o MPP.

Nota-se um problema no método perturbe e observe, como a perturbação do sistema é um valor fixo, e pela natureza do algoritmo ser discreta, o valor de operação encontrado irá oscilar. A amplitude desta oscilação irá variar dependendo do valor da perturbação indu-

zido no sistema, porém o tempo de convergência também irá depender deste valor, sendo necessário encontrar um balanço entre as duas implicações.

2.3 Algoritmos MPPT Bioinspirados

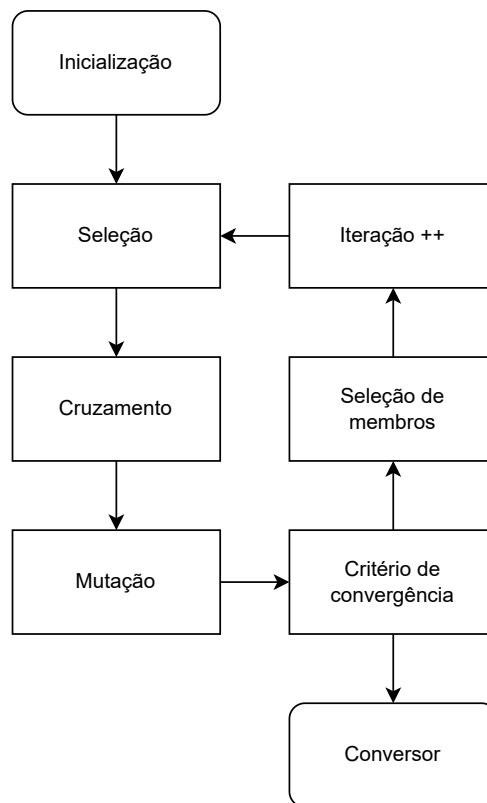
Métodos de otimização bioinspirados são algoritmos desenvolvidos a partir de princípios como a evolução biológica, comportamento de coletivos de animais além de processos físicos ou químicos. Esses métodos de otimização incorporam inteligência nos códigos computacionais através de ciclos de varreduras de valores máximos, e modelos estocásticos a partir de números aleatórios. O métodos tradicionais de otimização nem sempre garantem o máximo global, visto que dependem das condições iniciais a qual estão submetidos. Devido aos métodos tradicionais serem determinísticos, eles dependem do formato das curvas que está sendo otimizada, ao contrário dos métodos bio-inspirados, que não necessitam o cálculo de derivadas, e conseqüentemente não dependem do gradiente, ou formato da curva em análise (VASUKI, 2020).

Além da componente aleatória associada com os métodos bio-inspirados, um parâmetro importante é a função objetivo. Ela deve ser selecionada cuidadosamente para cada problema que será resolvido, e é a principal forma de avaliar as variáveis aleatórias do sistema, e verificar se os valores encontrados estão convergindo (EDUARDO; BARBOSA, 2017).

2.3.1 Algoritmo Genético

O algoritmo genético é baseado no processo de seleção natural de Charles Darwin, e utiliza uma população inicial aleatória para encontrar a solução de boa qualidade para o problema, assim como os outros métodos bio-inspirados. Neste caso, a população é comparada a cromossomos, e ela representa possíveis soluções dentro do espaço de busca do problema (EDUARDO; BARBOSA, 2017).

O fluxograma do algoritmo pode ser visto na figura a seguir, ele é iniciado definindo qual será seus parâmetros: tamanho da população, percentual de cruzamentos e mutações, além da taxa de mutação. A função objetivo também é definida nesta etapa, e já utilizada para calcular a aptidão de cada um dos cromossomos que foi criado de forma aleatória.

Figura 2.6: Fluxograma do Algoritmo Genético

Fonte: Autor, 2023.

A partir da população inicial é feita uma seleção que irá selecionar uma porção menor e irá realizar o cruzamento de material genético, que será onde há a troca de informações entre a população. Alguns dos membros também sofrerão mutação (alteração de alguns valores dos cromossomos de forma aleatória), de acordo com os valores especificados na inicialização, após a etapa do cruzamento como uma outra forma de evitar o algoritmo a ficar preso em máximos locais (OKWU; TARTIBU, 2021).

Após isso é verificado um critério de convergência, que pode ser definido com uma quantidade máxima de iterações permitida ou uma comparação direta entre os valores da população, quando se sabe com mais precisão onde o algoritmo será aplicado. Caso o critério seja satisfatório a otimização será finalizada. Caso contrário ele deve voltar para uma nova seleção de membros e repetir o processo entre pares diferentes de cromossomos.

2.3.2 *Shuffled Frog Leaping Algorithm*

O SFLA - *Shuffled Frog Leaping Algorithm*, ou algoritmo dos sapos, é baseado no comportamento destes animais para a busca de localidades com maior quantidade de alimentos. Diferentemente do método do Algoritmo Genético, e também vários outros algoritmos bioinspirados, ele conta com duas etapas: o embaralhamento dos sapos na busca da otimização global, e a busca localizada quando divididos em grupos menores.

Inicialmente os sapos são alocados em posições aleatórias dentro do espaço de procura. Após isso, são separados em grupos e cada um dos grupos evolui de forma independente um dos outros. A ideia por trás dessa separação se deve aos sapos poderem ser influenciados pelo sapo que está na melhor posição de cada grupo, favorecendo a convergência para os máximos locais. Posteriormente, quando os sapos se reencontram e novamente se separam em grupos diferentes para uma nova iteração, a convergência começa a alcançar o máximo global (RAJIBB KUMARR BHATTACHARJYA, 2020). O fluxograma para o algoritmo dos sapos está apresentado na figura 2.7:

A metodologia do SFLA

A explicação do algoritmo segue a seguir:

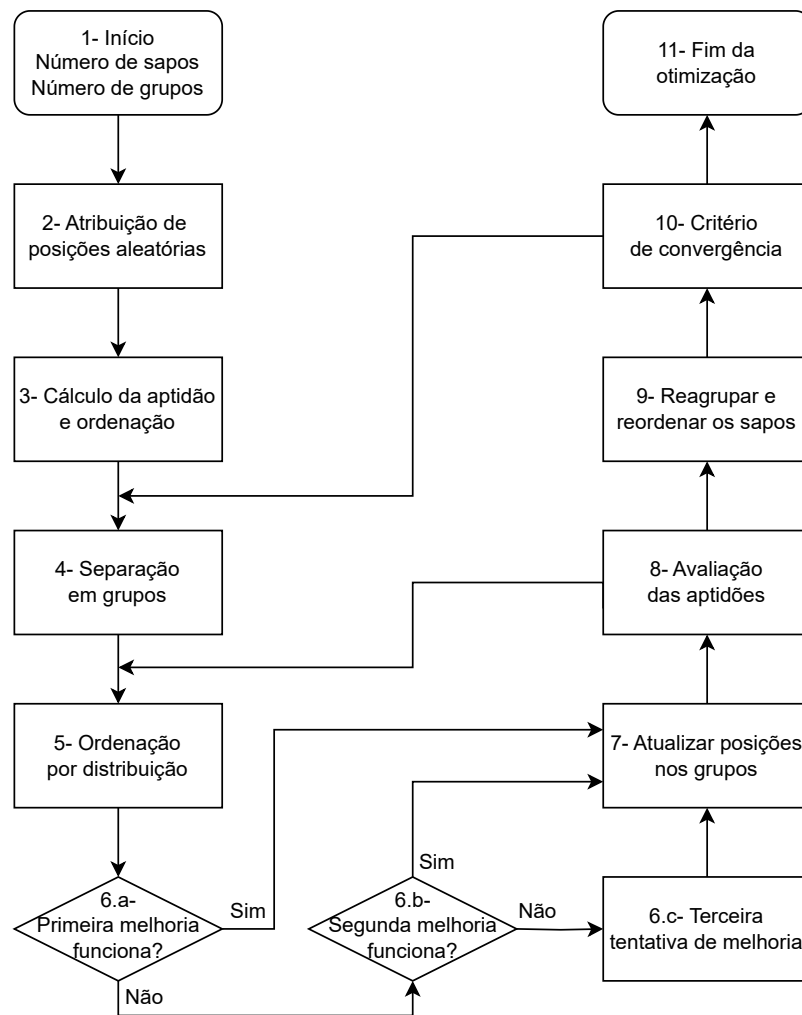
1. Ao iniciar o algoritmo, devemos escolher a quantidade de grupos que teremos, assim como a quantidade de sapos que haverá em cada um deles. Conseqüentemente essa escolha implica que estamos decidindo a quantidade total de sapos que estarão participando da otimização.

Essa escolha deve ser feita de forma cuidadosa, pois representa uma variável que influencia diretamente no tempo de convergência do método. A escolha de uma quantidade pequena de sapos pode fazer com que a busca global ocorra de forma mais lenta, assim como aumentar o erro devido à baixa população para comparar a aptidões.

Por outro lado, escolher uma grande quantidade de sapos também é prejudicial, isso pode aumentar a velocidade da localização do máximo global, mas o critério de convergência não será satisfeito enquanto os sapos de cada grupo não estiverem em posições muito próximas, ou iguais, e assim perde-se eficiência sem nenhum ganho em troca.

2. Deve-se definir qual será o espaço de procura do algoritmo, e atribuir para cada um dos sapos uma posição inicial aleatória dentro desse espaço.

Figura 2.7: Fluxograma do Algoritmo dos Sapos.



Fonte: Adaptado de (RAJIBB KUMARR BHATTACHARJYA, 2020)

3. Uma função de aptidão deve ser cuidadosamente selecionada para atingir uma boa eficiência do algoritmo. Uma má escolha dessa função pode gerar complicações posteriores na hora de comparar a qualidade da posição de cada um dos sapos, ou no próprio critério de convergência. Aplica-se essa função a cada um dos sapos em suas posições aleatórias, gerando um valor de aptidão para cada um deles, que está relacionado com a posição onde ele se encontra. De posse do valor de aptidão, é feita uma ordenação para saber quais são os sapos que estão nas melhores, e piores posições.
4. Após a atribuição de posições e cálculo de aptidões, é necessária fazer a separação dos sapos nos grupos escolhidos no item 1. A separação é feita distribuindo os sapos que já estão ordenados, em um grupo de cada vez. Ou seja, caso tenhamos três grupos,

os primeiros três sapos com aptidões mais alta estarão em grupos distintos, e o quarto sapo estará no mesmo grupo que o primeiro, e assim sucessivamente.

5. Dentro de cada grupo deve-se fazer uma nova ordenação, ou até a remoção de sapos. Isso normalmente é realizada a partir de algum tipo de distribuição, como a distribuição normal, binomial ou a distribuição de Poisson. Uma muito comum de se utilizar é a distribuição triangular, onde os sapos são novamente ordenados por aptidões do mais alto ao mais baixo.
6. Os subgrupos estão prontos para iniciar o processo de melhoria de posição (e consequentemente aptidão). Os sapos com melhor e pior posição de cada grupo são selecionados e nomeados P_B e P_W , respectivamente. As duas primeiras tentativas de melhora serão feitas de forma semelhante, seguindo a equação:

$$S = A(P_B - P_W) \quad (2.2)$$

Onde S é a variação da posição e A um número aleatório. Esse valor será adicionado a posição do sapo com aptidão mais baixa, como segue:

$$M_q = P_W + S \quad (2.3)$$

Sendo M_q a nova posição do pior sapo.

- (a) A primeira tentativa de melhora será feita dentro do mesmo grupo, ou seja, tanto o melhor e quanto o pior sapo estão no mesmo grupo. Se a nova posição for válida dentro do espaço delimitado no início do algoritmo, não será realizada as próximas duas tentativas de melhoria de posição.
- (b) Caso a posição não esteja dentro dos limites, a segunda tentativa de melhoria agora envolve sapos de grupos diferentes. A nova tentativa agora irá comparar o pior sapo do grupo em questão, e comparar com o sapo que está na melhor posição entre todos os outros, ou seja, o sapo com melhor aptidão global. O método é o mesmo já citado, e novamente deve-se validar a posição dentro do espaço delimitado.
- (c) Por fim, caso nenhuma das duas tentativas tenha sucesso em melhorar a posição do sapo, deve-se apenas substituí-lo por outro cuja posição será atribuída de forma aleatória, da mesma forma realizada no início do algoritmo.

7. Após todas as tentativas deve-se novamente atualizar as posições dos sapos de acordo com a aptidão nova que foi encontrado após a etapa anterior. Aqui provavelmente o sapo que antes estava na pior posição possível de cada grupo se encontrará em uma posição mais favorável, e não participará novamente no ciclo de atualização de posições na próxima iteração, a não ser que sua posição nova seja a de maior aptidão.
8. Compara-se se houve uma variação positiva na aptidão com as novas posições encontradas em comparação com as posições antigas. Caso haja melhoria, o algoritmo continua para o próximo passo, mas caso contrário, deve-se voltar à etapa 5.
9. Os grupos são desfeitos e os sapos são unificados, após isso são ordenados novamente por aptidões da melhor posição, para a pior.
10. O critério de convergência necessita ser implementado para avaliar a melhoria do sistema. Assim como na função objetivo, aqui há uma liberdade para escolher uma forma de avaliação adequada para o sistema em estudo. Caso o critério de convergência seja aprovado, o método passa para a etapa 11. Mas caso o critério não seja satisfeito, deve-se retomar à etapa 4.
11. A otimização é finalizada, com resultado do máximo global do sistema em estudo (EU-SUFF; LANSEY; PASHA, 2006).

Resumidamente, o algoritmo consiste de três diferentes etapas:

- A inicialização, com sapos posicionados em posições aleatórias;
- A pesquisa local, com a pesquisa em cada grupo para a otimização em máximos locais;
- A pesquisa global, com o embaralhamento dos sapos para misturar as soluções encontradas anteriormente.

Cada sapo apresenta uma possível solução para o sistema e o algoritmo é realizado até que alcance um número pré-determinado de iterações, ou uma solução satisfatória seja encontrada.

Aqui foram apresentados detalhadamente os dois algoritmos que foram implementados, testados e comparados entre si. Percebe-se que o algoritmo perturbe e observa possui uma facilidade de implementação maior, quando comparado com o algoritmo *shuffled frog leaping*. O algoritmo P&O também terá uma dependência das condições iniciais do sistema, apresentando sempre a mesma resposta para o mesmo sistema de estudo. Enquanto o SFLA

irá mostrar curvas diferentes, devido à natureza do algoritmo envolver números aleatórios, para todas as suas aplicações em iguais condições do circuito. Porém seu resultado não depende das condições iniciais do sistema, localizando com confiabilidade o resultado esperado.

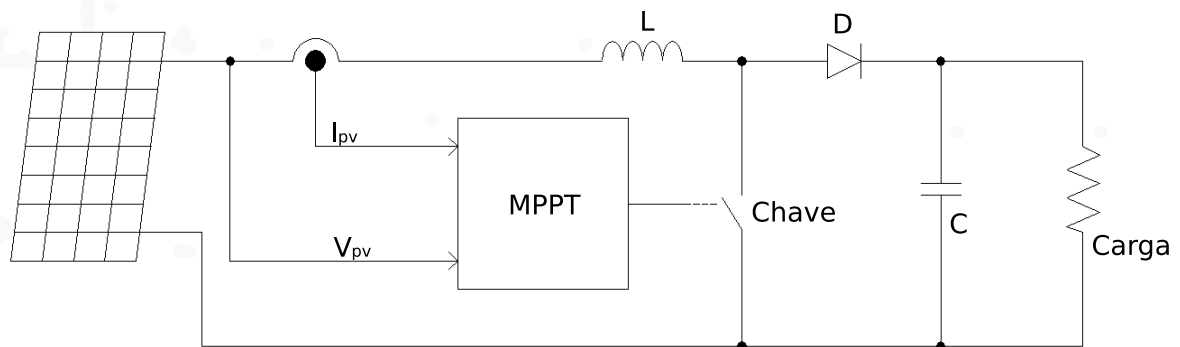
Capítulo 3

Implementação

3.1 O sistema de estudo


Para realizar o estudo dos algoritmos MPPT é necessário um circuito para análise, visto que necessitamos de uma carga para analisar o ponto de operação de um sistema fotovoltaico. Para a análise em questão foi selecionado, arbitrariamente, um conversor CC/CC do tipo *boost* devido a sua facilidade de implementação e simulação. Como ambiente de simulação foi utilizado o software PSIM da empresa PowerSim Tech.

Figura 3.1: Circuito simplificado utilizado para as simulações.



Fonte: Autor, 2023.

A figura 3.1 mostra, simplificada, o circuito utilizado para a análise dos algoritmos. O painel solar representa um arranjo de 7 módulos fotovoltaicos de modelo HiKu-450MS da empresa Canadian Solar, como mostra a figura a seguir. A curva PV característica deste arranjo será mostrada na figura 4.1 do próximo capítulo.

Figura 3.2: Arranjo de painéis fotovoltaicos utilizado para simulações.

Fonte: Autor, 2023.

O objeto de estudo, MPPT, alimentará um sistema de chaveamento para o conversor *boost* que será executado utilizando o método de PWM. Os parâmetros iniciais do conversor são apresentados na tabela a seguir.

Tabela 3.1: Tabela de parâmetros do circuito utilizados na simulação.

Parâmetro	Valor
Frequência de Chaveamento (f_s)	$20kHz$
Tensão de Entrada (V_{in})	$294,63V$
Tensão de Saída (V_{out})	$500V$
Potência (P)	$3115,49W$
Ondulação de Tensão na Saída (V_r)	1% de V_{out}

Primeiramente foi realizado o cálculo da razão cíclica:

$$D = 1 - \frac{V_{in}}{V_{out}} \rightarrow D = 0,41074 \quad (3.1)$$

Após isso, foi calculado o valor da carga utilizada:

$$R = \frac{V_{out}^2}{P} \rightarrow R = 80,244\Omega \quad (3.2)$$

Podemos calcular a indutância com a seguinte equação:

$$L = \frac{(1 - D)^2 DR}{2f_s} \rightarrow L = 0,286mH \quad (3.3)$$

Por fim, o cálculo da capacitância:

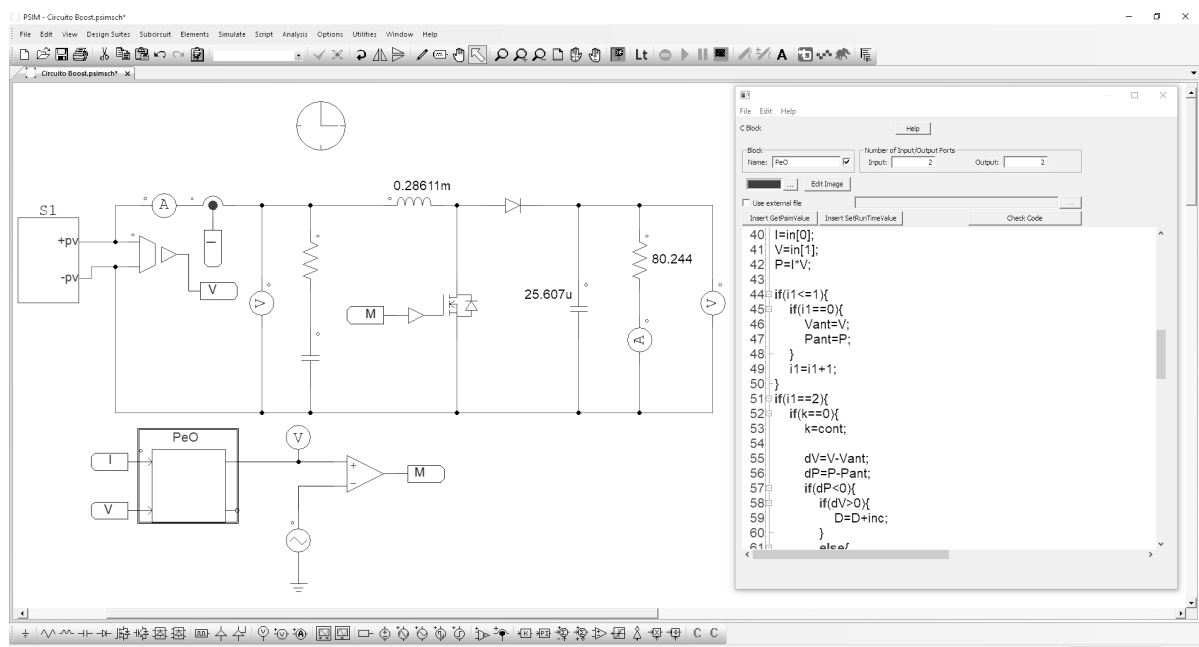
$$C = \frac{DV_{out}}{Rf_sV_r} \rightarrow C = 25,6\mu F \quad (3.4)$$

3.2 Perturbe e Observe

A implantação do algoritmo P&O é simples, visto que possuímos apenas duas variáveis que temos controle sob, o valor da perturbação induzida no sistema, aqui chamada de *inc*, e a posição inicial do sistema. Porém também deve ser levado em conta o valor do ciclo de trabalho, embora ele esteja relacionado com o valor de perturbação, deverá ser limitado para que não haja a saturação do conversor.

Segue a seguir uma imagem do algoritmo perturbe e observe implementado no *software* de simulação:

Figura 3.3: Ambiente de simulação com algoritmo P&O



Fonte: Autor, 2023.

3.3 Shuffled Frog Leaping Algorithm

A implementação do algoritmo *shuffled frog leaping* requer uma quantidade superior de variáveis de controle, são algumas delas:

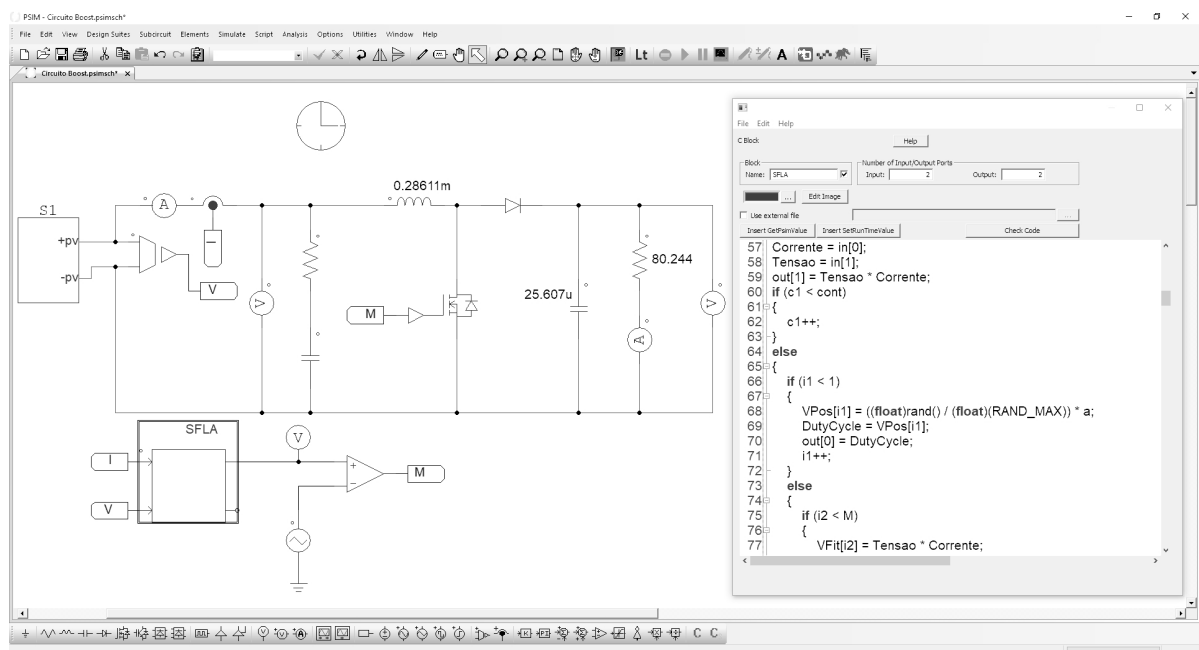
- Número de grupos de sapos;
- Número de sapos em cada grupo;
- Número máximo de tentativas de melhoria das posições dos sapos;

- A função de aptidão do sistema;
- O critério de convergência do sistema.

Da mesma forma que para o método do P&O, o valor do ciclo de trabalho deve ser limitado para que não haja a saturação do conversor.

Segue a seguir uma imagem do *shuffled frog leaping algorithm* implementado no *software* de simulação:

Figura 3.4: Ambiente de simulação com algoritmo SFLA



Fonte: Autor, 2023.

Capítulo 4

Estudo de Caso

4.1 Variáveis de Simulação

Para realizar a comparação dos dois métodos, a única alteração a ser feita será o MPPT, ou seja, todo o dimensionamento do circuito deverá se manter igual, e as variáveis em comum dos algoritmos também devem ser iguais. Aqui estão apresentadas todas as variáveis utilizadas nas simulações.

4.1.1 Variáveis Similares

Uma semelhança entre os dois tipos de simulação será a limitação do valor do ciclo de trabalho para que não haja a saturação do conversor. Para isso, o valor do ciclo de trabalho terá um limite inferior a igual a 0,1 e um limite superior igual 0,9.

Outra semelhança é a necessidade de um tempo de espera nos algoritmos após cada alteração do ciclo de trabalho, devido à dinâmica do sistema. Por isso, após cada alteração de ciclo de trabalho, são realizadas 20.000 iterações sem alteração, que se mostra uma quantidade suficiente para que a potência se estabilize.

4.1.2 Variáveis Específicas

Como discutido anteriormente, para o método P&O, as únicas duas variáveis na qual temos controle é a *inc* e o ciclo de trabalho inicial do sistema. O incremento foi selecionado após realizar simulações com diversos valores possíveis, e o valor selecionado para as simulações foi $inc = 0,02$.

Para o método SFLA, as variáveis selecionadas foram:

- Os algoritmos MPPT buscam maximizar a potencia fornecida pelos geradores intermitentes, então a função de aptidão para o sistema será $P = V * I \rightarrow \text{máximo}$. Como temos acesso tanto a tensão quanto a corrente, é uma tarefa fácil de se realizar.
- Várias combinações de quantidade de sapos, e quantidade de grupos foram testadas: 2 grupos com 3 sapos cada, 2 grupos com 4 sapos cada, 3 grupos com 2 sapos cada, 3 grupos com 3 sapos cada, 3 grupos com 4 sapos cada, 4 grupos com 3 sapos cada. O melhor tempo de resposta foi encontrado quando trabalhamos com 9 sapos no total. Quantidades inferiores a esta mostraram um tempo de resposta equivalente, porém o erro foi superior.

Já quantidades superiores mostraram um tempo de resposta mais demorado, com erros semelhantes aos encontrados com 9 sapos. Portanto, neste estudo foi selecionado a quantidade de 9 sapos, como segue:

- A quantidade de grupos selecionados foi 3;
- A quantidade de sapos por grupo selecionado foi 3;

Ressalta-se que, devido a limitação de tempo, não foram testadas todas as possibilidades de grupos e quantidade de sapos por grupo para quantidades acima de 12 sapos, que podem trazer resultados superiores aos aqui encontrados.

- Como a tensão de operação do sistema fotovoltaico é dependente do ciclo de trabalho, o espaço de procura do algoritmo também está limitado a valores entre 0 e 1. Com isso, os números aleatórios de posição para cada sapo no início do algoritmo também se encaixam nesse intervalo, dependendo da limitação da geração de números aleatórios do software de simulação.
- Como visto no item 5 de 2.3.2, é necessário uma distribuição para realizar a ordenação dos sapos no grupo. Para esta atividade foi utilizada a distribuição triangular devido a baixa quantidade de sapos necessárias para este algoritmo (RAJIBB KUMARR BHATTACHARJYA, 2020).

4.1.3 Variáveis Arbitradas

Para o algoritmo P&O, o ciclo de trabalho inicial do sistema foi escolhido $D = 0$ em todos os casos. Algumas das variáveis do SFLA também foram escolhidas arbitrariamente, são elas:


- O critério de convergência do sistema foi selecionado de forma que o erro do sistema fique inferior a 1%. Este valor foi selecionado após observar a curva de resposta do método P&O, de modo a garantir que na pior situação a precisão do algoritmo ainda seja superior ao P&O;
- O número máximo de tentativas de melhoria das posições dos sapos foi selecionado para ser 100 tentativas. Observou-se nas simulações que, normalmente, o número máximo de tentativas para melhorar as posições era uma quantia inferior a 80, então o valor foi selecionado com um pequeno espaço a mais de tentativas, caso seja necessário;
- Da mesma forma que o número de tentativas, o número máximo de iterações do algoritmo foi selecionado arbitrariamente. Nas simulações foi observado que o número total de iterações, ou seja, vezes que o algoritmo fechou um ciclo completo, sempre foi inferior a 25 vezes. Com isso, novamente foi deixado uma quantia a mais caso alguma tarefa de otimização necessitasse um pouco a mais de tempo, o valor selecionado foi de 50 iterações.

4.1.4 Curvas PV do arranjo fotovoltaico

A análise dos algoritmos foi realizada em três condições distintas: condições ideais, sombreamento em apenas um dos painéis fotovoltaicos, e com sombreamento em dois painéis fotovoltaicos. O estudo poderia envolver uma quantidade maior de sombreamentos, porém a partir de dois sombreamentos, as curvas de resposta já serão semelhantes. Todas as curvas e simulações foram realizadas à temperatura de $25^{\circ}C$.

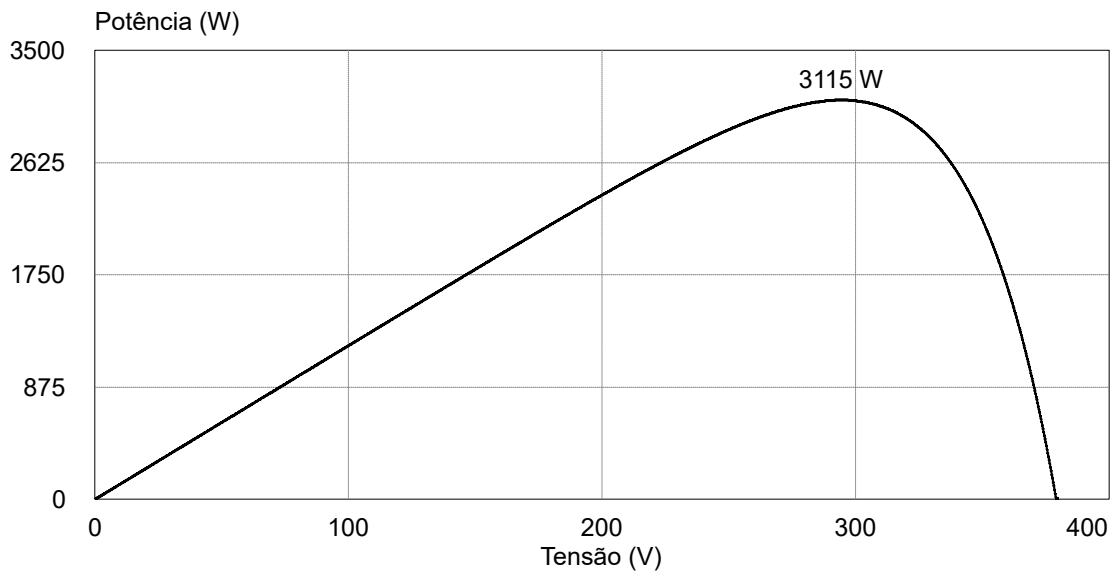
A imagem a seguir representa a configuração de sombreamento no arranjo fotovoltaico.

Figura 4.1: Arranjo de painéis fotovoltaicos sem sombreamento.



Fonte: Autor, 2023.

Figura 4.2: Curva PV do arranjo em condições ideais




Fonte: Autor, 2023.

Em condições ideais, ou seja, $1000W/m^2$ de irradiação solar, o arranjo de painéis solares terá a curva PV mostrada a seguir. Seu valor máximo é $3115,56W$ à uma tensão de $294,6V$, então espera-se que os métodos MPPT sejam capazes de alcançar este valor de potência.


A imagem a seguir representa a configuração de sombreamento no arranjo fotovoltaico.

Figura 4.3: Arranjo de painéis fotovoltaicos com um sombreamento.



Fonte: Autor, 2023.

Figura 4.4: Curva PV do arranjo com sombreamento parcial em um painel fotovoltaico



Fonte: Autor, 2023.


Quando um dos 7 painéis fotovoltaicos do arranjo está funcionando a 30% da sua capacidade máxima, a curva PV irá se dividir em dois picos. O pico associado a máxima potência, que desejamos localizar, com $2670,29W$ de potência em $252,5V$ de tensão. E o novo máximo local possui potência de $1194W$ com uma tensão de $375V$. Aqui nota-se que a potência máxima disponível diminuiu em 14,28% com a aparição da sombra em um módulo.

Por fim, mantendo um painel fotovoltaico com a sombra previamente alocada sobre o painel, e introduzindo um segundo sombreamento em outro painel, agora funcionando a 70% de sua capacidade máxima, a curva PV sofrerá novamente uma separação em outro pico. Esse valor de sombreamento parcial foi selecionado para ficar próximo do máximo global intencionalmente, para dificultar a convergência dos métodos MPPT selecionados. Quando

comparamos a sua potência máxima disponível com o caso sem sombreamento, vemos que o máximo que podemos extrair do arranjo fotovoltaico com essa configuração de sombreamento é 27,71% mais baixa que o caso ideal.


A imagem a seguir representa a configuração de sombreamento no arranjo fotovoltaico.

Figura 4.5: Arranjo de painéis fotovoltaicos com dois sombreamentos.



Fonte: Autor, 2023.

Figura 4.6: Curva PV do arranjo com sombreamento parcial em dois painéis fotovoltaicos



Fonte: Autor, 2023.

Nessa configuração temos o máximo global em 2225,22W de potência com 210,39V de tensão, o segundo pico mais alto, máximo local com potência igual a 2207,50W e tensão igual a 269,97V e por fim o pico local de potência mais baixa de 1182,88W e 334,44V de tensão.

4.2 Resultados

Com todas as informações em mãos agora é possível realizar as simulações dos dois métodos MPPT propostos. Iniciamos com a simulação do algoritmo perturbe e observe para os três casos de radiância solar previamente descrito, e posteriormente o algoritmo *shuffled frog leaping*.

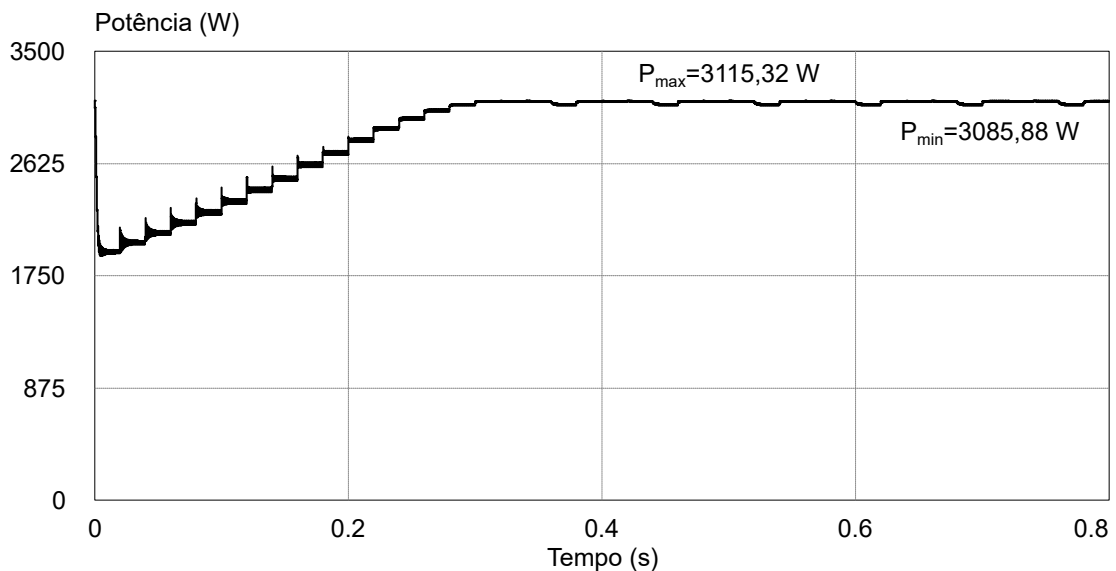
4.2.1 P&O

Condições ideais de irradiância

Para o MPPT-P&O em condições ideais de irradiância, há a convergência para o MPP, como esperado. A convergência ocorre após $0,34s$ e atinge um valor máximo de potência de $3115,32W$. Após a convergência, o ciclo de trabalho oscila entre $0,38$ e $0,42$, onde a potência mais baixa de oscilação é de $3085,88W$.

A oscilação de potência na saída então possui o valor de $29,44W$, ou seja, levemente inferior a 1% da potência máxima fornecida por este algoritmo, como pode ser visto na figura a seguir.

Figura 4.7: Curva de potência do arranjo em condições ideais para MPPT-P&O




Fonte: Autor, 2023.

Um sombreamento parcial

Quando o primeiro sombreamento é adicionado, o MPP ainda é localizado pelo método MPPT-P&O, como pode ser visto na figura 4.5.

Figura 4.8: Curva de potência do arranjo com sombreamento parcial em um painel fotovoltaico para MPPT-P&O



Fonte: Autor, 2023.

O tempo de convergência é de aproximadamente $0,4s$, com potência máxima alcançada de $2670,28W$ e uma flutuação de $31W$ de potência, o que equivale a uma variação de potência de $1,16\%$ do valor máximo. Neste caso a potência mínima encontrada após a convergência é de $2639,28W$, e o ciclo de trabalho varia entre $0,44$ e $0,48$.

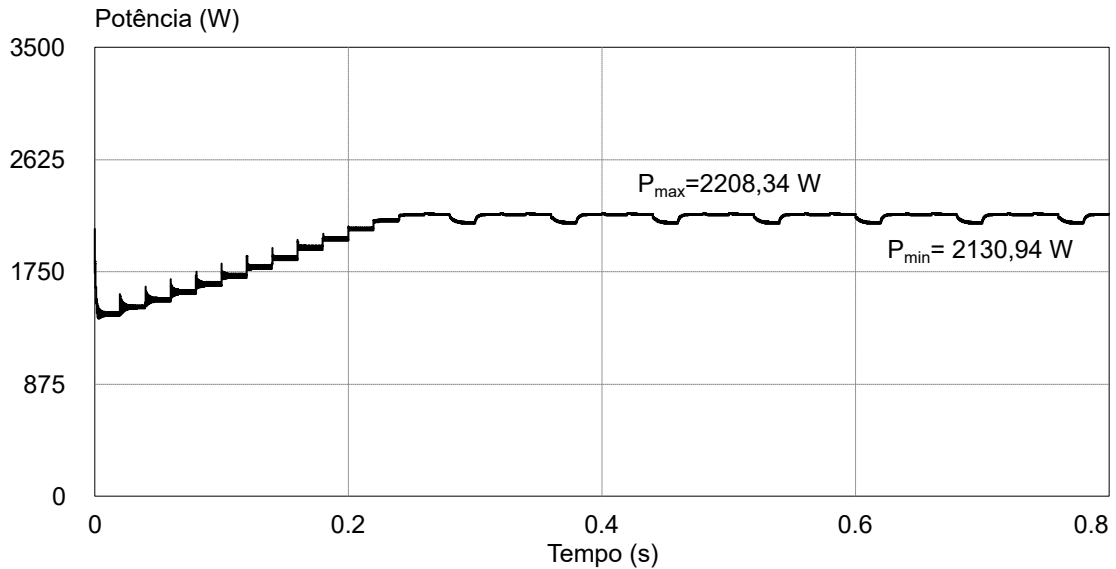
Embora a potência máxima ainda tenha sido encontrada neste caso, isso se deve as condições iniciais do algoritmo, porém nota-se um aumento da oscilação de potência em relação à máxima, isso se deve a diminuição da potência máxima disponível devido ao sombreamento, enquanto o passo de ciclo de trabalho permanece constante.

Dois sombreamentos parciais

No terceiro caso, com dois painéis sob influência do sombreamento parcial, independentemente das condições iniciais propostas, o algoritmo irá localizar um máximo local e deixará de fornecer toda a potência disponível pelo sistema PV. Neste caso, a potência máxima encontrada é de $2208,34W$, a mínima após a convergência é de $2130,94W$ com flutuação de

77W, equivalente à 3,5% da potência máxima encontrada. A potência máxima disponível neste caso, como visto, é de 2225,22W.

Figura 4.9: Curva de potência do arranjo com sombreamento parcial em dois painel fotovoltaico para MPPT-P&O



Fonte: Autor, 2023.

Conclusão sobre P&O

Percebe-se que o algoritmo P&O é eficaz em encontrar o ponto de máxima potência em condições ideais, porém começa a falhar quando há a introdução de sombreamento parcial, devido a dependência das condições iniciais do sistema que os métodos tradicionais possuem.

A escolha de sombreamentos foi realizada para dificultar a convergência dos métodos, por isso a perda de potência do valor encontrado no pior caso, e a potência máxima disponível não é tão elevada, mas ela poderia ser um valor mais expressivo dependendo das condições de sombreamento aplicadas no arranjo PV.


4.2.2 SFLA

Condições ideais de irradiância

Para o MPPT-SFLA em condições ideais de irradiância, também há a localização do MPP. A potência máxima de 3115,54W é encontrada e a flutuação 0,66 intrínseca do

dimensionamento do conversor CC/CC tipo *boost*. A curva de potência pelo tempo dos painéis fotovoltaicos podem ser vistos na figura a seguir:

Figura 4.10: Curva de potência do arranjo em condições ideais para MPPT-SFLA




Fonte: Autor, 2023.

O tempo de convergência para este caso é de $0,68s$, e aqui nota-se a principal vantagem do SFLA: não há alteração do ciclo de trabalho após a localização do MPP.

Um sombreamento parcial

Quando inserido o primeiro sombreamento, o método novamente localiza o MPP com um tempo para a convergência de aproximadamente $0,66s$, como pode ser visto na figura 4.8.

Figura 4.11: Curva de potência do arranjo com sombreamento parcial em um painel fotovoltaico para MPPT-SFLA



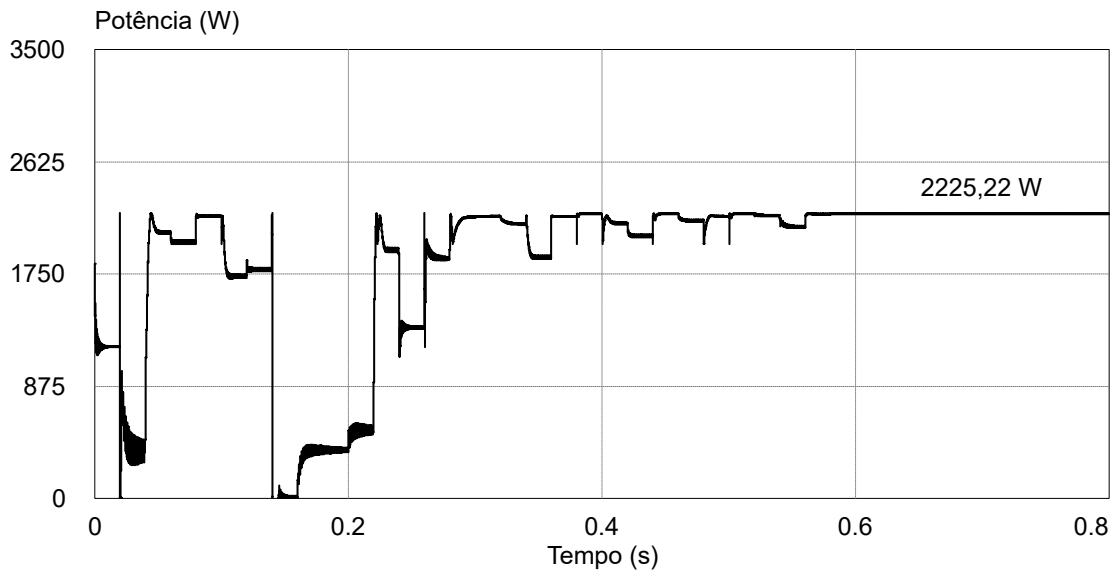
Fonte: Autor, 2023.

A potência máxima encontrada quando há um sombreamento é de $2669,92W$, $0,37W$ abaixo da potência máxima disponível pelo arranjo PV. Este erro é inferior ao 1% definido pelo algoritmo.

Dois sombreamentos parciais

Segue a curva de potência para o arranjo PV quando há dois sombreamentos parciais:

Figura 4.12: Curva de potência do arranjo com sombreamento parcial em dois painéis fotovoltaicos para MPPT-SFLA



Fonte: Autor, 2023.

Por fim, quando há o sombreamento parcial em dois painéis fotovoltaicos, o ponto de operação novamente é encontrado, desta vez em $2225,22W$ e o tempo de convergência é de $5,8s$. Aqui é relevante mostrar que o algoritmo localizou o máximo local de valor mais alto, $2206,7W$, nos instantes de tempo $90ms$, $370ms$ e $480ms$, porém conseguiu localizar o máximo global posteriormente, como pôde ser visto na figura 4.9.

Conclusão sobre SFLA

O *shuffled frog leaping algorithm* é um algoritmo capaz de localizar o ponto de máxima potência independentemente da quantidade de sombreamento na qual é submetido, isso se deve à sua natureza probabilística, ou seja, de uso de números aleatórios, e ao fato de não depender das condições iniciais do sistema.

Mesmo com a escolha dos sombreamentos, o algoritmo conseguiu otimizar o sistema, demonstrando sua eficiência. Outra característica vantajosa deste método é que não haverá variação de ciclo de trabalho após a convergência, como previamente mencionado, isso diminui a variação de potência nos painéis após a localização do MPP.

4.3 Conclusão

O método MPPT-P&O possui um tempo de convergência inferior ao MPPT-SFLA quando as condições de operação são ideais, e sua facilidade de implementação justifica o seu grande uso comercial. Porém quando as condições climáticas deixam de ser favoráveis, este método deixa de localizar o ponto de operação ideal e passa a indicar valores de potência máxima que não são reais, limitando a eficiência dos arranjos fotovoltaicos.


Já o método MPPT-SFLA é capaz de localizar o ponto de operação ideal consistentemente, com a vantagem de não haver flutuação no valor de potência após a convergência do método. Porém a seus pontos negativos são o tempo de convergência mais demorado quando comparado com o MPPT-P&O, e o algoritmo mais complexo de ser desenvolvido.

A tabela e figura a seguir mostra uma comparação entre os dois algoritmos utilizados quando não há qualquer tipo de sombreamento afetando o sistema.

Tabela 4.1: Tabela comparativa entre os algoritmos sem sombreamento.

Parâmetro	P&O	SFLA
Tempo de Convergência	0,34s	0,68s
Erro Médio	14,96W	0,02W
Eficiência	99,52%	99,99%
Oscilação	29,44W	nula

Figura 4.13: Comparação entre os algoritmos quando submetidos a dois sombreamentos



A curva azul se refere ao algoritmo P&O

A curva vermelha se refere ao algoritmo SFLA


Fonte: Autor, 2023.

A tabela e figura a seguir mostra uma comparação entre os dois algoritmos utilizados quando não há um sombreamento afetando o sistema.

Tabela 4.2: Tabela comparativa entre os algoritmos com um sombreamento.

Parâmetro	P&O	SFLA
Tempo de Convergência	0,4s	0,66s
Erro Médio	15,51W	0,37W
Eficiência	99,42%	99,99%
Oscilação	31,00W	nula

Figura 4.14: Comparação entre os algoritmos quando submetidos a dois sombreamentos



A curva azul se refere ao algoritmo P&O

A curva vermelha se refere ao algoritmo SFLA


Fonte: Autor, 2023.

A tabela e figura a seguir mostra uma comparação entre os dois algoritmos utilizados quando não há um sombreamento afetando o sistema.

Tabela 4.3: Tabela comparativa entre os algoritmos com dois sombreamentos.

Parâmetro	P&O	SFLA
Tempo de Convergência	0,36s	0,58s
Erro Médio	55,58W	nulo
Eficiência	97,50%	100%
Oscilação	77,00W	nula

Figura 4.15: Comparação entre os algoritmos quando submetidos a dois sombreamentos



A curva azul se refere ao algoritmo P&O

A curva vermelha se refere ao algoritmo SFLA

Fonte: Autor, 2023.

Quando comparados, vemos que a convergência do SFLA acontece após pouco menos que o dobro de tempo que o P&O, porém a sua potência máxima encontra é superior e constante. Esta diferença de potências se torna mais expressiva com outros valores de sombreamento nos painéis.

Capítulo 5

Conclusão

Este trabalho apresentou o estudo, implementação e comparação de dois algoritmos MPPT de naturezas distintas: o tradicional P&O e o bioinspirado SFLA, com a finalidade de maximizar a extração de energia disponível em sistemas fotovoltaicos.

Foram abordados as curvas características dos painéis e arranjos fotovoltaicos, o funcionamento do conversor CC/CC, o método MPPT, e o fenômeno do sombreamento parcial. Além disso, foram citados os diferentes tipos de métodos MPPT, com exemplos e explicação das variáveis utilizadas nos métodos comparados.

Com a simulação dos métodos foi realizada a comparação dos mesmos, cumprindo assim os objetivos propostos nesse trabalho.

Como continuidade do presente trabalho, podem ser sugerido os seguintes tópicos:

- Estudar a dinâmica de sombreamento após a primeira convergência dos algoritmos;
- Realizar mais simulações utilizando diferentes parâmetros, a fim de explorar combinações que não foram aqui testadas;
- Comparar o *Shuffled Frog Leaping Algorithm* com outros algoritmos MPPT bioinspirados;
- Realizar um estudo sobre a durabilidade dos componentes eletrônicos durante o transiente de potência, e compará-lo com equipamentos utilizados comercialmente;
- Construir um conversor *boost* para realizar testes reais da implementação do algoritmo em um microcontrolador. Comparar as respostas obtidas com outros algoritmos e com as simulações.

Referencias bibliograficas

ASHFAQ, A. **Eletrônica de Potência**. [S.l.: s.n.], 2000.

CASARO, M. M.; MATINS, D. C. Modelo de Arranjo Fotovoltaico Destinado a Análises em Eletrônica de Potência via Simulação. **Revista Eletrônica e Potência**, v. 13, n. 3, p. 141–146, 2008. DOI: 10.18618/REP.2008.3.141146.

CEPEL. Manual de engenharia para sistemas fotovoltaicos. Rio de Janeiro, 2004.

CREPALDI, J.; AMOROSO, M.; ANDO, O. Analysis of the Topologies of Power Filters Applied in Distributed Generation Units - Review. **IEEE Latin America Transactions**, v. 16, n. 7, p. 1892–1897, 2018. DOI: 10.1109/TLA.2018.8447354.

EDUARDO, C.; BARBOSA, M. **Algoritmos Bio-inspirados para Problemas de Otimização**. 2017. Diss. (Mestrado). Disponível em: <www.cin.ufpe.br/~posgraduacaoRECIFE2017>.

EUSUFF, M.; LANSEY, K.; PASHA, F. Shuffled frog-leaping algorithm: A memetic meta-heuristic for discrete optimization. **Engineering Optimization**, v. 38, n. 2, p. 129–154, mar. 2006. ISSN 0305215X. DOI: 10.1080/03052150500384759.

KARAMI, N.; MOUBAYED, N.; OUTBIB, R. General review and classification of different MPPT Techniques. **Renewable and Sustainable Energy Reviews**, v. 68, p. 1–18, 2017. ISSN 1364-0321. DOI: <https://doi.org/10.1016/j.rser.2016.09.132>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1364032116306438>>.

LI, J.; WU, Y.; MA, S.; CHEN, M.; ZHANG, B.; JIANG, B. Analysis of photovoltaic array maximum power point tracking under uniform environment and partial shading condition: A review. **Energy Reports**, v. 8, p. 13235–13252, 2022. ISSN 2352-4847. DOI: <https://doi.org/10.1016/j.egyr.2022.09.192>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352484722019199>>.

MENDONÇA, B. D.; ROCHA, T.; RIBEIRO, R.; COSTA, F. Algoritmo MPPT P&O com Perturbação Variável Aplicado a um Sistema de Geração PV Conectado à Rede Elétrica Trifásica. Natal, Rio Grande do Norte, 2019.

OKWU, M. O.; TARTIBU, L. K. **Studies in Computational Intelligence 927 Metaheuristic Optimization: Nature-Inspired Algorithms Swarm and Computational Intelligence, Theory and Applications**. [S.l.: s.n.], 2021. Disponível em: <<http://www.springer.com/series/7092>>.

OLIVEIRA, F. M. d. **Rastreamento da máxima potência em arranjos fotovoltaicos sob efeito de sombreamento parcial baseado no método de otimização por enxame de partículas**. 2015. Diss. (Mestrado) – Universidade Tecnológica Federal do Paraná.

PERVEZ, I.; ANTONIADIS, C.; MASSOUD, Y. Advanced Limited Search Strategy for Enhancing the Performance of MPPT Algorithms. **Energies**, v. 15, n. 15, 2022. ISSN 1996-1073. DOI: 10.3390/en15155650. Disponível em: <<https://www.mdpi.com/1996-1073/15/15/5650>>.

RAEDANI, R.; HANIF, M. Design, testing and comparison of P&O, IC and VSSIR MPPT techniques. In: 2014 International Conference on Renewable Energy Research and Application (ICRERA). [S.l.: s.n.], 2014. P. 322–330. DOI: 10.1109/ICRERA.2014.7016404.

RAJIBB KUMARR BHATTACHARJYA, F. B. **Modeling and Optimization in Science and Technologies Nature-Inspired Methods for Metaheuristics Optimization Algorithms and Applications in Science and Engineering**. [S.l.: s.n.], 2020.

VASUKI, A. **Nature-Inspired Optimization Algorithms**. [S.l.: s.n.], 2020.

XUE, Y.; WANG, S. Photovoltaic cell modeling and the maximum power point tracking simulation. In: p. 119–123. DOI: 10.1109/ICMREE.2013.6893628.

YANG, X.-S. **Nature-inspired metaheuristic algorithms**. [S.l.]: Luniver Press, 2010. ISBN 9781905986286.