



UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
FACULDADE DE ENGENHARIAS, ARQUITETURA E URBANISMO E GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA



**Sistemas de Seguimento de Máxima Potência do tipo *Current*
Sensorless para Sistemas Fotovoltaicos em Condições de
Sombreamento Parcial**

Guilherme Mendonça dos Santos Martines

Campo Grande - MS

4 de agosto de 2024



UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
FACULDADE DE ENGENHARIAS, ARQUITETURA E URBANISMO E GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA



**Sistemas de Seguimento de Máxima Potência do tipo *Current*
Sensorless para Sistemas Fotovoltaicos em Condições de
Sombreamento Parcial**

Guilherme Mendonça dos Santos Martines

Dissertação de mestrado apresentada
como exigência para obtenção do título de
Mestre em Engenharia Elétrica na área de
Sistemas de Energia da Universidade
Federal de Mato Grosso do Sul – UFMS.

Orientador: Prof. Dr. Moacyr Aureliano Gomes de Brito

Campo Grande - MS

4 de agosto de 2024

Sistemas de Seguimento de Máxima Potência do tipo *Current Sensorless* para Sistemas Fotovoltaicos em Condições de Sombreamento Parcial

Dissertação de mestrado apresentada como exigência para obtenção do título de Mestre em Engenharia Elétrica na área de Sistemas de Energia da Universidade Federal de Mato Grosso do Sul – UFMS.

Banca Examinadora:

Prof. Dr. Moacyr Aureliano Gomes de Brito
Orientador

Prof. Dr. Luigi Galotto Junior
UFMS

Prof. Dr. Luiz Carlos Gomes de Freitas
UFU

Campo Grande - MS
4 de agosto de 2024

À Deus

Agradecimentos

À Deus, por me mostrar o caminho quando tudo parecia perdido.

Aos meus pais Claudio dos Santos Martines e Michelli Nirce Mendonça, e ao meu irmão Bruno da Silva Mendonça, agradeço pelo apoio incondicional e pelo amor ao longo desta jornada acadêmica.

À minha noiva, Iliana de Souza Mota, por seu amor constante, apoio incansável e inspiração. Com você ao meu lado, cada conquista se torna mais significativa.

Ao meu orientador, Prof. Dr. Moacyr Aureliano Gomes de Brito, expresso minha gratidão pela amizade e pelos esforços dedicados ao meu aprendizado, que foram fundamentais para o meu crescimento acadêmico e profissional.

Resumo

Impactos relacionados ao aquecimento global estão se tornando cada vez mais frequentes. Países de todo o globo buscam soluções para conter a elevação da temperatura terrestre. A previsão é que ocorra um acréscimo considerável na demanda de energia elétrica, impulsionada pelo setor de transportes e aparelhos eletroeletrônicos, agravando o problema. Nesse sentido, como forma de contribuir para suprir a demanda de energia de forma limpa e sustentável, os sistemas fotovoltaicos se destacaram com acréscimo de capacidade instalada em torno dos 345 Gigawatt (GW), no mundo, em 2023. Para a máxima extração da energia disponível dos sistemas fotovoltaicos, se deseja operar a geração sempre no ponto de máxima potência. Para isso, é necessário utilizar algoritmos de rastreamento do ponto de máxima potência, principalmente em situações com sombreamento parcial, quando o sistema passa a ter diversos pontos de máximos locais (LMPPs); o que dificulta a tarefa, uma vez que algoritmos convencionais como Perturba e Observa (P&O), geralmente convergem para os máximos locais. Nesse sentido, técnicas baseadas em inteligência artificial, metaheurísticas e híbridas são apresentadas na literatura, com intuito de obter sistemas capazes de encontrar o MPP global (GMPP). Outro ponto que merece destaque é que, normalmente, independentemente do método utilizado, se observa a dependência de sensores de corrente e tensão para funcionamento dos algoritmos. Assim, esse trabalho tem como objetivo abordar algoritmos inteligentes para rastrear o GMPP em sistemas fotovoltaicos com sombreamento parcial, utilizando apenas um sensor de tensão, visando a redução de custos e aumento de confiabilidade. O método proposto será comparado com o convencional que utiliza ambos sensores, métricas como tempo de busca pelo GMPP, oscilação de potência em estado estacionário e eficiência de rastreamento serão abordadas para resultados de simulação e experimentais. Por fim, nota-se que os algoritmos *sensorless* implementados conseguem manter eficiência bem próxima, ou até mesmo superior, em relação aos métodos que utilizam de ambos sensores, com destaque para o método Otimização por Enxame de Partículas (*Particle Swarm Optimization* - PSO) com metodologia *sensorless* que, experimentalmente, obteve Fator de Rastreamento (FR) igual a 99,08% em comparação com o PSO convencional com um FR de 99,03%, considerando o perfil de potência analisado neste trabalho.

Palavras-Chave: Sem Sensores de Corrente, MPPT, Metaheurísticos, Sistemas Fotovoltaicos, Sombreamento Parcial.

Abstract

The impacts related to global warming are becoming increasingly frequent. Countries around the globe are seeking solutions to contain the rise in Earth's temperature. The forecast predicts a considerable increase in the demand for electricity, driven by the transportation sector and electronic devices, exacerbating the problem. In this context, photovoltaic systems have emerged as a key solution to meet the energy demand in a clean and sustainable manner, with an increase in installed capacity around 345 Gigawatts (GW) worldwide in 2023. For the maximum extraction of the available energy from photovoltaic systems, it is desirable to always operate the generation at the maximum power point. To achieve this, it is necessary to use maximum power point tracking (MPPT) algorithms, especially in situations with partial shading when the system has multiple local maximum power points (LMPPs), which complicates the task since conventional algorithms like Perturb and Observe (P&O) usually converge to the local maxima. In this sense, techniques based on artificial intelligence, metaheuristics, and hybrid approaches are presented in the literature with the aim of developing systems capable of finding the global maximum power point (GMPP). Another point worth highlighting is that, typically, regardless of the method used, there is a dependency on current and voltage sensors for the algorithms to function. Therefore, this work aims to address intelligent algorithms for tracking the GMPP in photovoltaic systems with partial shading, using only a voltage sensor, aiming to reduce costs and increase reliability. The proposed method will be compared with the conventional one that uses both sensors, and metrics such as GMPP search time, steady-state power oscillation, and tracking efficiency will be addressed for simulation and experimental results. Finally, it is noted that the implemented sensorless algorithms can maintain efficiency very close to, or even superior to, the methods that use both sensors, with particular emphasis on the Particle Swarm Optimization (PSO) method with a sensorless methodology, which experimentally achieved a Tracking Factor (TF) of 99.08%, compared to conventional PSO with a TF of 99.03%, considering the power profile analyzed in this work.

Keywords: Current Sensorless, MPPT, Metaheuristics, Photovoltaic Systems, Partial Shading.

Lista de Figuras

<i>Número</i>	<i>Página</i>
Figura 1 — Comportamento da curva PxV de um módulo. (a) para diferentes valores de irradiância; (b) para diferentes valores de temperatura.....	12
Figura 2 — Representação do sombreamento em 1 das 4 células fotovoltaicas conectadas em série.....	13
Figura 3 — Módulo fotovoltaico com uma célula sombreada.....	14
Figura 4 — Comportamento da curva PxV para diferentes valores de irradiância em um arranjo fotovoltaico com sombreamento parcial.	14
Figura 5 — Técnicas de computação suave utilizadas para MPPT em sistemas fotovoltaicos	15
Figura 6 — Fluxograma do Algoritmo P&O.....	20
Figura 7 — Fluxograma algoritmo GSO.....	22
Figura 8 — Fluxograma do algoritmo PSO.	24
Figura 9 — Hierarquia dos lobos cinzentos (a dominância diminui de cima pra baixo)	25
Figura 10 — Fluxograma do algoritmo GWO.	27
Figura 11 — Fluxograma Algoritmo Vagalume.	29
Figura 12 — Fluxograma do Algoritmo Morcegos.....	32
Figura 13 — Fluxograma algoritmo Busca Cuco.....	35
Figura 14 — Fluxograma algoritmo ABC.....	38
Figura 15 — Diagrama de blocos do sistema de simulação.....	40
Figura 16 — Circuito equivalente de uma célula fotovoltaica	41
Figura 17 — Bloco programável para um módulo fotovoltaico.....	41
Figura 18 — Curvas PxV, com temperatura e irradiância uniforme (azul) e não uniforme (vermelho).....	42

Figura 19 — Interface do <i>software</i> da fonte programável terraSAS.....	44
Figura 20 — Layout do protótipo desenvolvido utilizando o software Altium	45
Figura 21 — Simulação implementada no software MATLAB/Simulink®	47
Figura 22 — Curvas de Potência x Tensão dos perfis avaliados.....	48
Figura 23 — Potência extraída dos métodos P&O sensorless e P&O com ambos sensores	49
Figura 24 — Potência extraída dos métodos GSO sensorless e GSO com ambos sensores	50
Figura 25 — Potência extraída dos métodos PSO sensorless e PSO com ambos sensores.	51
Figura 26 — Potência extraída dos métodos GWO sensorless e GWO com ambos sensores	52
Figura 27 — Potência extraída dos métodos FA sensorless e FA com ambos sensores	54
Figura 28 — Potência extraída dos métodos BAT sensorless e BAT com ambos sensores.	55
Figura 29 — Potência extraída dos métodos CS sensorless e CS com ambos sensores.....	56
Figura 30 — Potência extraída dos métodos ABC sensorless e ABC com ambos sensores	57
Figura 31 — Bancada experimental.....	60
Figura 32 — Curvas de Potência vs Tensão e Corrente vs Tensão dos perfis avaliadas por meio do simulador de arranjos fotovoltaicos	61
Figura 33 — Resposta do método P&O convencional.....	62
Figura 34 — Resposta do método P&O sensorless	63
Figura 35 — Resultados do método GSO convencional	65
Figura 36 — Resultados do método GSO sensorless.....	66
Figura 37 — Resultados do método PSO convencional.....	67
Figura 38 — Resultados do método PSO sensorless	68
Figura 39 — Resultados do método BAT ambos sensores	70
Figura 40 — Resultados do método BAT sensorless	71

Lista de Tabelas

<i>Número</i>	<i>Página</i>
Tabela 1 — Características do módulo fotovoltaico + conversor boost.....	42
Tabela 2 — Perfis de potência avaliados na simulação.....	48
Tabela 3 — Coeficientes utilizados na simulação para o algoritmo PSO	51
Tabela 4 — Coeficientes utilizados na simulação para o algoritmo FA.....	53
Tabela 5 — Avaliação dos resultados de simulação.....	59
Tabela 6 — Coeficientes utilizados no experimento para o algoritmo PSO	69
Tabela 7 — Avaliação dos resultados experimentais.....	72

Sumário

1. Introdução	11
1.1. Motivação.....	17
1.2. Objetivos	17
1.2.1. Objetivo Geral.....	17
1.2.2. Objetivos Específicos.....	18
1.3. Organização do Trabalho:.....	18
2. Algoritmos de MPPT	19
2.1. Perturba e Observa (P&O).....	19
2.2. Otimização por Seção Áurea (GSO).....	20
2.3. Otimização por Enxame de Partículas (PSO)	23
2.4. Otimização por Lobos Cinzentos (GWO)	25
2.5. Otimização por Vagalumes (FA).....	27
2.6. Algoritmo dos Morcegos (BAT).....	30
2.7. Otimização por Busca Cuco (CS)	33
2.8. Colônia Artificial de Abelhas (ABC)	35
2.9. Considerações do Capítulo	39
3. Materiais e métodos	40
3.1. Sistema implementado em simulação	40
3.2. Sistema experimental implementado.....	44
3.3. Considerações do capítulo.....	46
4. Resultados e discussões	47
4.1. Resultados de simulação	47
4.1.1. Perturba e Observa (P&O)	49
4.1.2. Otimização por Seção Áurea (GSO)	50
4.1.3. Otimização por enxame de partículas (PSO)	50
4.1.4. Otimização por lobos cinzentos (GWO).....	52
4.1.5. Otimização por Vagalumes (FA).....	53
4.1.6. Otimização por Morcegos (BAT)	54
4.1.7. Otimização por Busca Cuco (CS)	55
4.1.8. Otimização por Colônia de Abelhas (ABC).....	56

4.2.	Comparação dos resultados de simulação	57
4.3.	Resultados experimentais	59
4.3.1.	Perturba e Observa (P&O)	61
4.3.2.	Otimização por Seção Áurea (GSO)	64
4.3.3.	Otimização por enxame de partículas (PSO)	67
4.3.4.	Otimização por Morcegos (BAT)	69
4.4.	Comparação dos resultados experimentais	72
4.5.	Considerações do capítulo.....	72
5.	Conclusões e Considerações finais.....	73
6.	Referências	74
Apêndice A – Produção de Artigos Científicos		78
A.1	Artigo Publicado – Periódico Internacional	78
A.2	Artigo Publicado – Congresso Internacional.....	78

1. Introdução

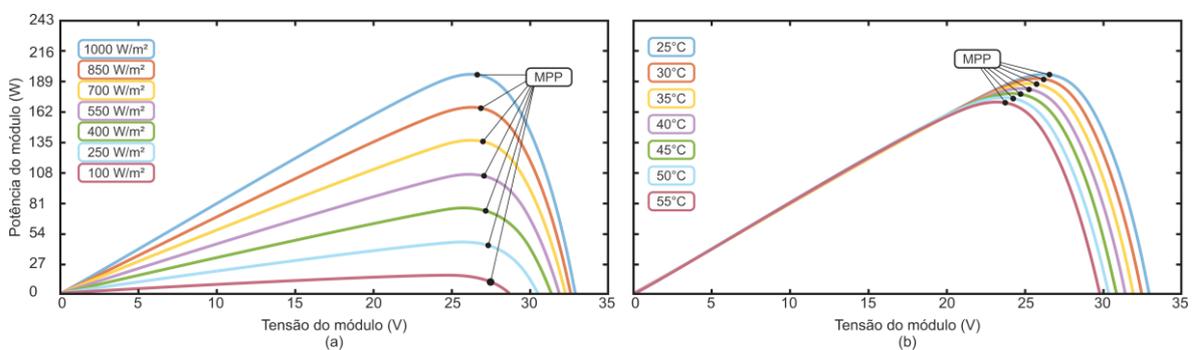
Registros de impactos relacionados às mudanças climáticas estão se tornando cada vez mais frequentes. Ondas de calor sem precedentes na Europa, inundações no Paquistão e secas históricas na África são alguns exemplos de danos associados ao aquecimento global. Para lidar com tais impactos, países de todo o globo comprometem-se, por meio de acordos, como o de Paris, buscando a redução das emissões de gases do efeito estufa, além de outros esforços necessários para manter o aumento da temperatura média da Terra abaixo dos 2°C, acima do níveis pré-industriais [1]. Para isso, um caminho promissor é a reestruturação na forma de como os países produzem e consomem eletricidade; é imprescindível que ocorram investimentos em energias renováveis, com sua utilização diretamente em mobilidade, indústrias e edifícios inteligentes.

A previsão é que a demanda global de eletricidade aumente ente 5.900 e 7.000 Terawatt-hora (TWh) até 2030. O setor de transportes é responsável pela maior parcela dessa demanda, pois estima-se que o mercado de carros elétricos cresça de 8% em 2021 para uma faixa entre 32% e 50% até 2030. Outro fator impulsionador do consumo está relacionado à crescente busca por refrigeração; prevê-se que até a mesma data, a aquisição de aparelhos de ar condicionado aumente cerca de 40%, apenas na China. Como resposta a essa necessidade, as energias renováveis têm desempenhando um papel fundamental nos últimos anos, apresentando um crescimento expressivo na última década. Espera-se que até 2030, 43% da geração de energia mundial provenha de fontes limpas, em comparação com o cenário atual de 28%, com destaque para a solar fotovoltaica que teve um acréscimo de capacidade instalada de 345 GW, no mundo, no ano de 2023 [2].

A crescente comercialização dos sistemas de geração de energia solar fotovoltaica se deve também às diversas vantagens que oferecem, tais como sustentabilidade, menor custo de manutenção e operação, além da ausência de peças complexas, o que facilita a instalação. Pode-se dizer que o componente mais básico desses sistemas é a célula fotovoltaica, dispositivo que converte diretamente a radiação solar em energia elétrica. No entanto, a quantidade de energia gerada por uma célula é muito baixa, sendo necessário conectar várias células entre si resultando em um módulo fotovoltaico. Além disso, a associação em série e/ou paralelo de vários módulos é denominada de arranjo fotovoltaico, e cada sistema pode ser composto por diversos arranjos a fim de prover tensão e corrente necessárias à aplicação [3].

Um ponto que merece destaque é que a quantidade de energia gerada por um módulo é diretamente influenciada pelas condições meteorológicas [4]. As Figuras 1(a) e 1(b) apresentam o comportamento das curvas de potência versus tensão (PxV) em função da variação da irradiância (W/m^2) e temperatura ($^{\circ}\text{C}$), respectivamente. Observa-se que quanto maior a irradiância, maior a potência gerada, e quanto menor a temperatura, maior a tensão gerada pelo módulo. Além disso, nota-se que as grandezas elétricas apresentam características não lineares, o que dificulta a operação dos sistemas no MPP (do inglês, *Maximum power point*) [5].

Figura 1 — Comportamento da curva PxV de um módulo. (a) para diferentes valores de irradiância; (b) para diferentes valores de temperatura.



Fonte: Adaptado de [6].

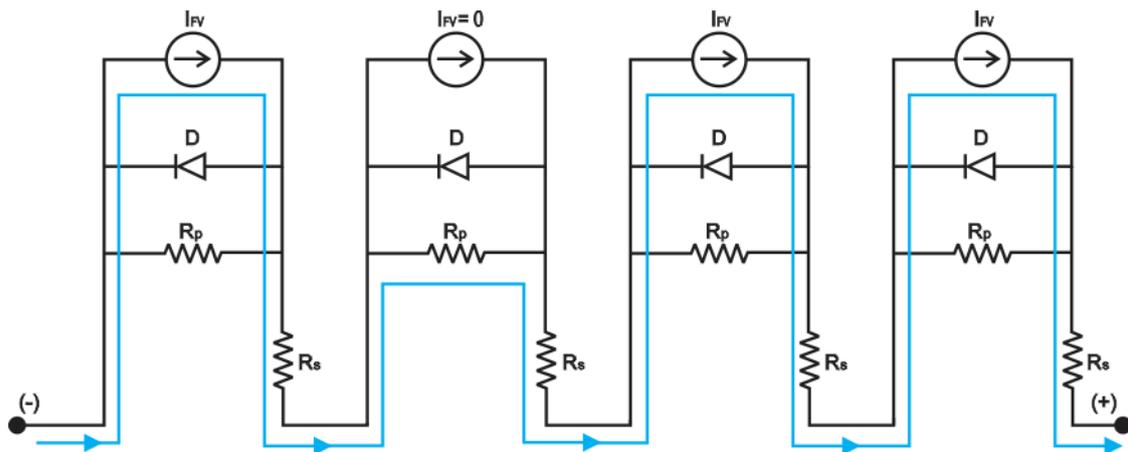
No decorrer do dia, a irradiância e temperatura incidentes nos módulos estão constantemente em alteração, conseqüentemente o MPP também. Para fazer com que o sistema opere sempre neste ponto é necessário o uso de algoritmos de MPPT (do inglês, *Maximum power point tracking*) para controlar um conversor eletrônico de potência, ajustando a impedância percebida pelo módulo, através da variação de tensão, corrente e/ou do ciclo de trabalho do conversor [7]. Nesse sentido, diversas técnicas são abordadas pela literatura, classificadas como convencionais, técnicas de inteligência artificial (IA), técnicas metaheurísticas e híbridas [8].

A escolha da técnica utilizada implica nas condições em que o sistema fotovoltaico será submetido, basicamente a irradiância e temperatura nos módulos pode ser definida como homogênea, quando todos os módulos de um mesmo arranjo recebem a mesma irradiação e temperatura, ou com sombreamento parcial, o que ocorre quando um mesmo arranjo possui módulos sombreados e outros não. Para as situações de irradiância uniforme, as técnicas convencionais como Perturba e Observa (P&O) [9] e Condutância Incremental (IC) [10] são capazes de rastrear o MPP com eficiência. Basicamente o método P&O trabalha lendo a corrente e tensão do sistema e comparando a potência do ciclo atual com a do ciclo anterior.

Então é aplicada uma perturbação, caso ocorra o aumento de potência, a perturbação é mantida no mesmo sentido, caso contrário a perturbação é alterada para o sentido oposto.

Observa-se que, em algumas situações, os sistemas fotovoltaicos sofrem com sombreamento parcial devido a folhas, pássaros e construções. Nota-se que apenas uma célula sombreada pode prejudicar todo o módulo fotovoltaico, causando drástica redução na quantidade de energia gerada, visto que todas as células estão conectadas em série. Conforme exemplificado pela Figura 2, a fonte de corrente representada no circuito elétrico de uma célula, passa a se comportar como um circuito aberto, fazendo com que a célula atue como uma carga, consumindo a energia gerada pelas demais células não sombreadas. Além da diminuição de geração de energia, o sombreamento também resulta em pontos quentes, pois a corrente fotovoltaica circulante na célula resulta em calor, o que pode aumentar a temperatura na superfície até que danifique o módulo [11,12].

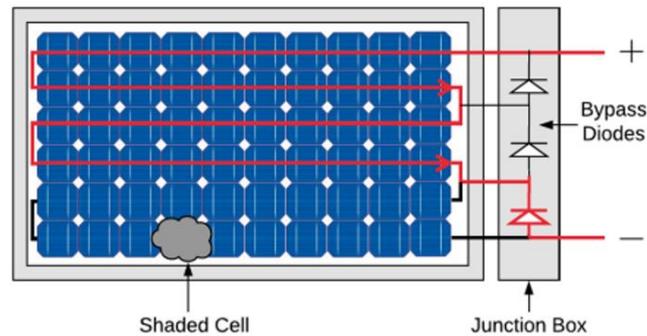
Figura 2 — Representação do sombreamento em 1 das 4 células fotovoltaicas conectadas em série



Fonte: Adaptado de [10].

A conexão de diodos em antiparalelo (*by-pass*) entre os terminais de saída de um conjunto de células é a solução utilizada pelos fabricantes de módulos fotovoltaicos para minimizar as consequências do sombreamento. A Figura 3 ilustra essa técnica, onde três conjuntos de 24 células cada, compõem um módulo; nesse caso, são utilizados três diodos de *by-pass*. Assim, quando uma célula de determinado conjunto é sombreada, a corrente circulante segue pelo caminho de menor resistência, fornecido pelo diodo do respectivo conjunto. Conseqüentemente, apenas uma célula sombreada ocasiona no corte de todo o conjunto de 24 células, dependendo do design e da configuração do módulo fotovoltaico. Ainda assim essa abordagem é capaz de minimizar as perdas do sombreamento e proteger o módulo de pontos quentes [13].

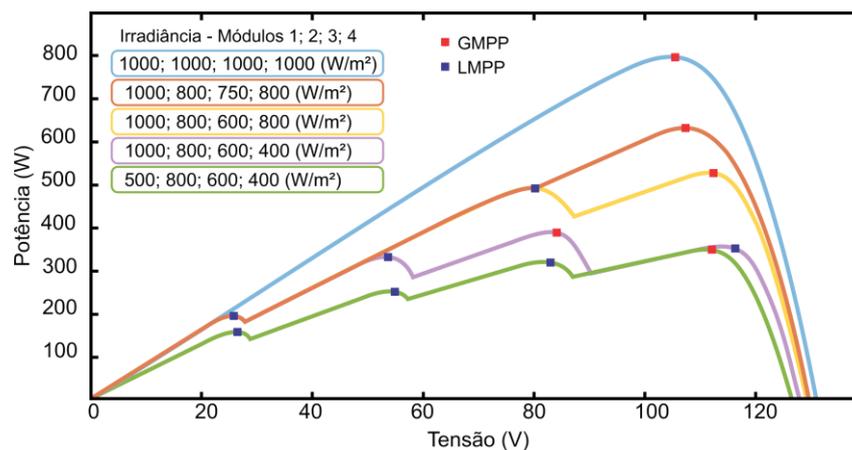
Figura 3 — Módulo fotovoltaico com uma célula sombreada



Fonte: [13]

Outro ponto que deve ser observado quando os sistemas fotovoltaicos sofrem com sombreamento parcial, é que as curvas características $P \times V$ deixam de ter apenas um MPP, passando a ter diversos LMPP (máximos locais) e apenas um GMPP (máximo global), conforme apresentado na Figura 4. Nesta Figura diferentes valores de irradiância são aplicadas à um arranjo fotovoltaico formado por quatro módulos associados em série. Assim, quando técnicas convencionais são aplicadas em arranjos com sombreamento parcial, comumente a operação converge para um máximo local [14].

Figura 4 — Comportamento da curva $P \times V$ para diferentes valores de irradiância em um arranjo fotovoltaico com sombreamento parcial.

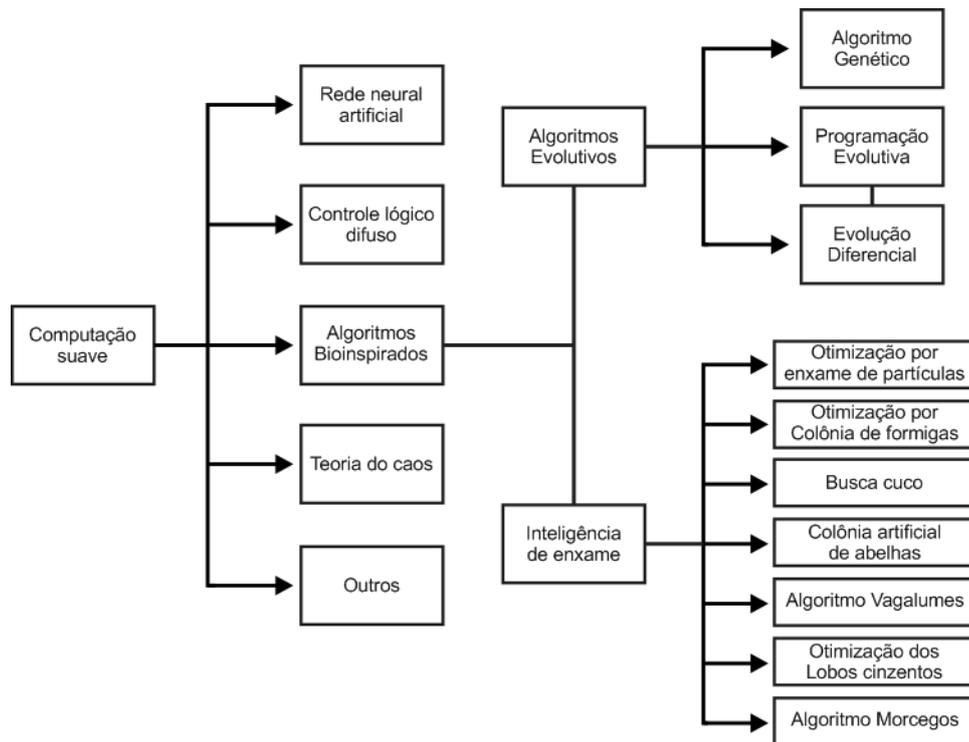


Fonte: Adaptado de [15].

Nesse sentido, a utilização de métodos de computação suave, como redes neurais artificiais, lógica difusa e inteligência de enxame, tornou-se uma abordagem popular na literatura, uma vez que tais técnicas possuem maior eficiência em rastrear o GMPP em arranjos fotovoltaicos com sombreamento parcial, quando comparado com as técnicas convencionais

[16]. A Figura 5 exemplifica a classificação de algumas das técnicas de computação abordadas pela literatura. Os métodos baseados em IA [17,18] possuem melhor desempenho ao rastrear o GMPP em situações de sombreamento, mas esses algoritmos requerem maior complexidade computacional e amplo treinamento. As técnicas baseadas em inteligência de enxame são capazes de processar com simplicidade computacional problemas de otimização não lineares, efetuando ampla busca do GMPP nas curvas características dos sistemas fotovoltaicos, reduzindo assim a probabilidade de convergir aos pontos máximos locais. Normalmente, os métodos híbridos são combinações entre os métodos de computação suave com os convencionais. Em [19] é proposto um novo algoritmo que relaciona o rápido tempo de resposta de um algoritmo convencional com o amplo espaço de busca de uma técnica baseada na inteligência de enxame, aumentando assim a eficiência de rastreamento em situações de sombreamento parcial.

Figura 5 — Técnicas de computação suave utilizadas para MPPT em sistemas fotovoltaicos



Fonte: Adaptado de [16].

Comumente, os algoritmos de MPPT iniciam efetuando a leitura da corrente e tensão do arranjo fotovoltaico. Posteriormente, a potência é calculada e cada método emprega uma abordagem diferente para rastreamento do GMPP. Assim, nota-se a dependência de sensores de

corrente e tensão para aquisição precisa dos dados e execução eficiente do algoritmo. Com intuito de reduzir custos, aumentar a confiabilidade do sistema e diminuir a carga computacional, torna-se interessante a eliminação do sensor de corrente, uma vez que tal sensor, se isolado e de alta precisão, possui alto custo. Além disso, com a retirada desse sensor, é possível reduzir a carga computacional necessária para uso do conversor analógico digital (ADC) de um determinado processador, além dos custos da implementação de buffers e circuitos de condicionamento de sinais. Outra vantagem observada é para os sistemas que utilizam sensores de efeito Hall, uma vez que estes podem causar interferência eletromagnética e cuja precisão depende da posição do núcleo magnético do sensor, além de possuírem vida útil limitada.

A literatura apresenta diversas técnicas para estimar a corrente do sistema fotovoltaico. Em [20] a predição da corrente é realizada através do curto-circuito dos terminais do arranjo, conseqüentemente ao custo de reduzir a vida útil do sistema, devido ao estresse elétrico e térmico gerado nos componentes. Em [21] é proposto um método simples e de baixo custo baseado no equacionamento do conversor buck-boost. No entanto, para situações de sombreamento parcial, torna-se necessário conhecer as características dos módulos fotovoltaicos, como a resistência de carga e o número de diodos de *by-pass*. No trabalho de [22], um controle preditivo é utilizado para observar a corrente do arranjo fotovoltaico, entretanto, o algoritmo requer dois sensores de tensão, um para ler a tensão fotovoltaica e outro para a leitura de tensão no capacitor de saída. Em [23] a predição da corrente é baseada no treinamento de uma rede neural artificial (RNA) de forma *offline*, posteriormente a rede é utilizada, juntamente com uma função pré-definida para rastreamento do MPP. No entanto, a qualidade do treinamento impactará na efetividade do algoritmo proposto, uma vez que a abordagem pode ser limitada por sua incapacidade de se adaptar rapidamente a variações dinâmicas nas condições ambientais.

A proposta deste trabalho é realizar a predição de corrente do arranjo fotovoltaico a partir da modelagem matemática do conversor CC-CC boost, avaliando técnicas de MPPT e comparando o método proposto com o convencional que utiliza de ambos sensores. A comparação será feita por meio de métricas como tempo de busca pelo GMPP, oscilação de potência em estado estacionário e eficiência de rastreamento, utilizando simulações no software MATLAB/Simulink® e a implementação física do sistema. Assim, espera-se obter resultados demonstrando que as técnicas de MPPT com predição de corrente conseguem manter a eficiência próxima ou até mesmo superior aos métodos que utilizam dos sensores de corrente e tensão.

1.1. Motivação

Os sistemas fotovoltaicos desempenham papel fundamental na transição para fontes de energia mais limpas e sustentáveis. Sabe-se que a eficiência na conversão de energia solar em eletricidade é a chave para maximizar o proveito do potencial energético disponível. Nesse contexto, os algoritmos de MPPT são essenciais para otimizar o desempenho dos sistemas fotovoltaicos, o que impulsiona a busca por soluções mais eficientes e economicamente viáveis, resultando em pesquisas e desenvolvimento de diferentes métodos para realizar o rastreamento do GMPP.

A fim de contribuir com o desenvolvimento e a melhorar a eficiência dos sistemas fotovoltaicos, a implementação de técnicas de MPPT sem sensores de corrente é objeto de estudo deste trabalho. Têm-se que a eliminação dos sensores de corrente reduz consideravelmente a complexidade do sistema, uma vez que ao eliminar este sensor, é possível obter uma implementação mais simples e de custo reduzido, conseqüentemente tornando a tecnologia mais acessível e contribuindo para maior viabilidade econômica de sistemas fotovoltaicos, em escala, principalmente em situações nas quais a contenção de custos é essencial para o projeto.

Além disso, essa abordagem não apenas simplifica a implementação dos sistemas fotovoltaicos mas também colabora para uma adoção mais ampla e rápida dessas tecnologias, permitindo que uma variedade mais extensa de usuários e comunidades se beneficie da energia solar. Assim, ao tornar os sistemas fotovoltaicos mais acessíveis e economicamente viáveis, essa pesquisa busca contribuir para aceleração da transição global para fontes de energias mais sustentáveis.

1.2. Objetivos

1.2.1. *Objetivo Geral*

O objetivo geral deste trabalho é avaliar, por meio de simulações no *software* MATLAB/Simulink® e implementação experimental, o comportamento de técnicas de MPPT em sistemas fotovoltaicos com sombreamento parcial, utilizando métodos sem sensor de corrente, formulando novos algoritmos do tipo *current sensorless*. Além disso, espera-se que os algoritmos sem sensor de corrente, tenham o mesmo desempenho que os algoritmos que utilizam de ambos sensores, tensão e corrente. Nesse sentido, os algoritmos implementados

serão avaliados de acordo com tempo de busca pelo GMPP, oscilação de potência em estado estacionário e eficiência de rastreamento. Dessa forma, buscando contribuir para uma escolha mais assertiva do algoritmo a ser utilizado de acordo com a especificidade da aplicação.

1.2.2. *Objetivos Específicos*

- Desenvolver e implementar algoritmos de MPPT sem sensor de corrente utilizando o método proposto no *software* MATLAB/Simulink®.
- Realizar simulações computacionais para avaliar o desempenho dos algoritmos de MPPT em sistemas fotovoltaicos com sombreamento parcial.
- Conduzir experimentos práticos para validar as simulações e verificar a eficácia dos algoritmos propostos em condições reais.
- Comparar o desempenho dos algoritmos sem sensor de corrente com os algoritmos tradicionais que utilizam sensores de tensão e corrente.
- Analisar a quantidade de energia extraída, tempo de busca pelo GMPP, oscilação de potência em estado estacionário e eficiência de rastreamento de cada algoritmo.
- Propor recomendações para seleção e aplicação dos algoritmos de MPPT *sensorless* em função das características específicas de cada aplicação.

1.3. Organização do Trabalho:

No Capítulo 1 foi apresentada a contextualização do problema, os objetivos da pesquisa, a justificativa para o estudo e a organização do trabalho.

No Capítulo 2 será abordado uma revisão sobre técnicas de MPPT, incluindo uma descrição do fluxograma de trabalho de algoritmos convencionais e de computação suave.

No Capítulo 3 serão apresentadas as especificações do sistema implementado, os detalhes das simulações e dos testes experimentais, além de informações relevantes sobre a metodologia *sensorless* adotada.

No Capítulo 4 serão apresentados os resultados e análises das simulações digitais e experimentos laboratoriais.

No Capítulo 5 são apresentadas as considerações finais do trabalho, discutindo-se as implicações dos resultados para a área de MPPT em sistemas fotovoltaicos, e, sugerindo possíveis direções para trabalhos futuros.

2. Algoritmos de MPPT

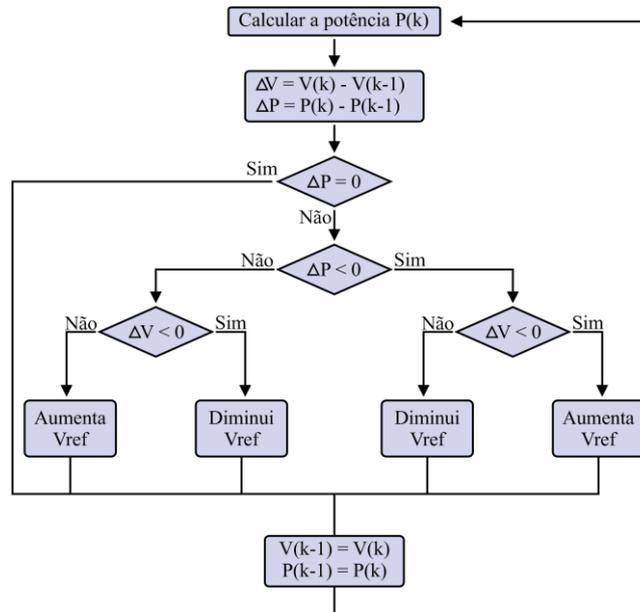
A eficiência na conversão de energia em sistemas fotovoltaicos é essencial para maximizar a quantidade de energia extraída. Neste capítulo serão abordadas diversas técnicas de MPPT, cujo objetivo é otimizar continuamente o desempenho do sistema, garantindo a operação no GMPP. Inicialmente será realizada uma revisão de uma técnica convencional, P&O, que servirá como base para comparação com técnicas de computação suave, que também serão discutidas. Além disso, serão apresentados fluxogramas ilustrativos de cada técnica, destacando os passos essenciais envolvidos no processo de rastreamento do GMPP, permitindo uma compreensão aprofundada do funcionamento de cada algoritmo.

2.1. Perturba e Observa (P&O)

O método Perturba e Observa (P&O) trata-se de uma técnica convencional, amplamente utilizada na literatura, de fácil implementação e baixo custo computacional. Quando aplicada em sistemas fotovoltaicos, o algoritmo trabalha movendo o ponto de operação em direção ao MPP, aplicando uma perturbação na tensão do arranjo fotovoltaico e comparando as potências entre a iteração atual e a iteração anterior [24].

O fluxograma do algoritmo P&O é apresentado na ura 6, o método inicia sua operação avaliando a potência gerada pelo arranjo fotovoltaico. Em seguida, procede-se ao ajuste da tensão do arranjo, aumentando ou diminuindo-a. Após esse ajuste, uma nova avaliação é realizada e a potência resultante é comparada com o valor obtido na iteração anterior. Se a potência na iteração atual, representada por $P(k)$, for maior que a potência na iteração anterior, $P(k - 1)$, isso indica que a perturbação realizada foi eficaz, e a mesma direção de perturbação é mantida para continuar a busca pelo MPP. Caso contrário, se a potência na iteração atual for menor que a potência na iteração anterior, então a perturbação deve ser alterada para a direção oposta [25].

Figura 6 — Fluxograma do Algoritmo P&O.



Fonte: Próprio autor.

Nota-se que o passo de perturbação é um coeficiente essencial para a eficiência do método, relacionado diretamente com a velocidade de resposta e precisão. Observa-se que com um pequeno passo de perturbação, o algoritmo apresenta uma perturbação precisa, embora lenta para atingir o MPP. Em contraste, um passo de perturbação elevado proporciona uma resposta rápida, mas resulta em uma grande oscilação em torno do MPP, tornando o método menos preciso. Para mitigar essas desvantagens, em [26] é proposto a utilização da perturbação com passo variável, aumentando a velocidade de rastreamento com menor oscilação em regime permanente. Entretanto, as oscilações não podem ser suprimidas pela própria característica do método.

2.2.Otimização por Seção Áurea (GSO)

O método de Otimização por Seção Áurea (do inglês, *Golden Section Optimization – GSO*), comumente é utilizado em problemas de otimização unimodais, ou seja, aqueles que possuem apenas um mínimo ou máximo dentro de um determinado intervalo $[a, b]$. O princípio do método é reduzir gradualmente o intervalo que contém o ponto máximo ou mínimo até que uma precisão especificada seja alcançada. Para ilustrar o funcionamento do método, considera-se um segmento de linha delimitado pelo intervalo $[a, b]$, com comprimento total igual a L . Este intervalo é então dividido em dois segmentos, sendo o maior

denotado como L_1 e o menor de L_2 , de modo que a equação (1) seja satisfeita, onde φ representa a proporção áurea [27,28].

$$\frac{L_1 + L_2}{L_1} = \frac{L_1}{L_2} = \varphi \quad (1)$$

Reescrevendo (1) em uma equação quadrática em termos de φ , encontra-se (2).

$$\varphi^2 - \varphi - 1 = 0 \quad (2)$$

Uma solução positiva para a equação (2) é expressa em (3).

$$\varphi = \frac{1 + \sqrt{5}}{2} = 1,618 \quad (3)$$

Além disso, em (4) define-se α como a seção áurea, que é a recíproca da razão áurea, além de ser a razão entre o subsegmento menor e o maior.

$$\alpha = \frac{1}{\varphi} = \varphi - 1 = 0,618 \quad (4)$$

Desse modo, baseados na seção áurea, dois pontos são gerados, X_1 e X_2 , ambos pertencentes ao intervalo $[a, b]$.

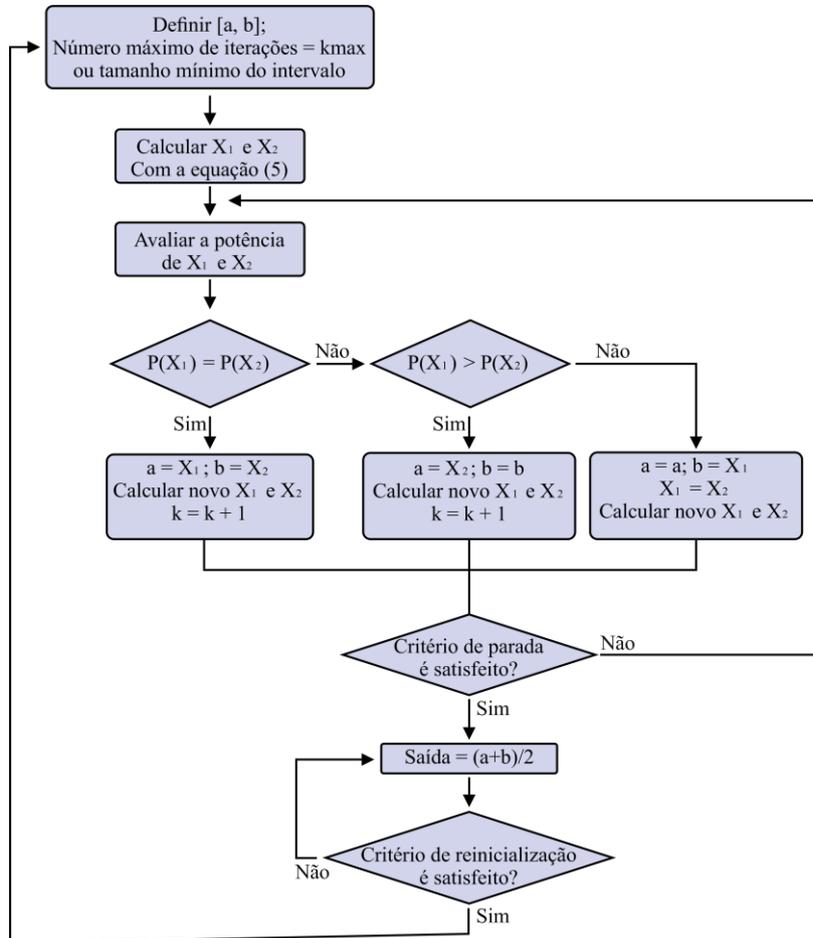
$$\begin{aligned} X_1 &= a + 0,618(b - a) \\ X_2 &= b - 0,618(b - a) \end{aligned} \quad (5)$$

Assim, a função objetivo $f(x)$ é avaliada, e para encontrar o máximo de um intervalo, são seguidos os seguintes critérios:

- 1) Se $f(X_1) > f(X_2)$, o novo espaço de busca passa a ser $[X_2, b]$, ou seja, remove-se a parte do comprimento $[a, X_2]$ do intervalo inicial. Então o processo é repetido até o critério de parada ser atingido.
- 2) Se $f(X_1) < f(X_2)$, o novo espaço de busca passa a ser $[a, X_1]$, ou seja, remove-se a parte do comprimento $[X_1, b]$ do intervalo inicial. Então o processo é repetido até o critério de parada ser atingido.
- 3) Se $f(X_1) = f(X_2)$, o novo espaço de busca passa a ser $[X_1, X_2]$, ou seja, remove-se a parte do comprimento $[a, X_1]$ e $[X_2, b]$ do intervalo inicial. Então o processo é repetido até o critério de parada ser atingido.

O fluxograma do algoritmo GSO baseado em MPPT para sistemas fotovoltaicos é apresentado na Figura 7.

Figura 7 — Fluxograma algoritmo GSO



Fonte: Próprio autor.

O método inicia definindo o intervalo de busca como $[15, V_{oc}]$, onde V_{oc} representa a tensão de circuito aberto do arranjo fotovoltaico e 15 V é definido como um limite inferior de operação. Além disso, é estabelecido um número máximo de iterações e um tamanho mínimo para o intervalo final, que está relacionado à precisão do ponto encontrado. Em seguida, utiliza-se a equação (5) para determinar os pontos X_1 e X_2 . Posteriormente, calcula-se a potência em cada um desses pontos, empregando a corrente e tensão do arranjo fotovoltaico, e avalia-se de acordo com os critérios predefinidos para encontrar o valor máximo da função, ou seja, o GMPP. O processo é repetido até que o número máximo de iterações seja alcançado ou que o intervalo final atinja o tamanho mínimo desejado. Nesse momento, o ponto de operação passa a ser a média entre os dois extremos do intervalo final. Além disso, um critério de reinicialização é avaliado por meio da equação (6).

$$\frac{P_{best} - P_{last}}{P_{last}} > \Delta P(\%) \quad (6)$$

Onde P_{best} e P_{last} são respectivamente a potência obtida no intervalo final do algoritmo e a potência obtida em cada iteração após o critério de parada ter sido atingido. Além disso, ΔP é o limite de variação aceitável entre as duas potências.

2.3. Otimização por Enxame de Partículas (PSO)

Inspirado no forrageamento de bando de pássaros e cardumes de peixes, o método Otimização por Enxame de Partículas (PSO) é modelado considerando uma população de N partículas, onde cada uma representa uma solução em potencial para o problema de otimização. O algoritmo inicia definindo aleatoriamente a velocidade e posição de cada partícula, as quais representam, respectivamente, o impulso para o movimento de busca e a própria possível solução do problema. Posteriormente, o método avalia cada solução na função objetivo e atualiza a posição de toda a população em cada iteração. Para isso, são utilizados dois dos melhores resultados obtidos, denominados g_{best} e p_{best} . O primeiro representa o melhor valor encontrado ao longo de todas as iterações anteriores, enquanto o segundo refere-se à melhor solução obtida na iteração atual [29,30]. As equações (7) e (8) definem o algoritmo PSO:

$$x_i(k + 1) = x_i(k) + v_i(k + 1) \quad (7)$$

$$v_i(k + 1) = \omega v_i(k) + c_1 r_1 \cdot (p_{best,i} - x_i(k)) + c_2 r_2 \cdot (g_{best} - x_i(k)) \quad (8)$$

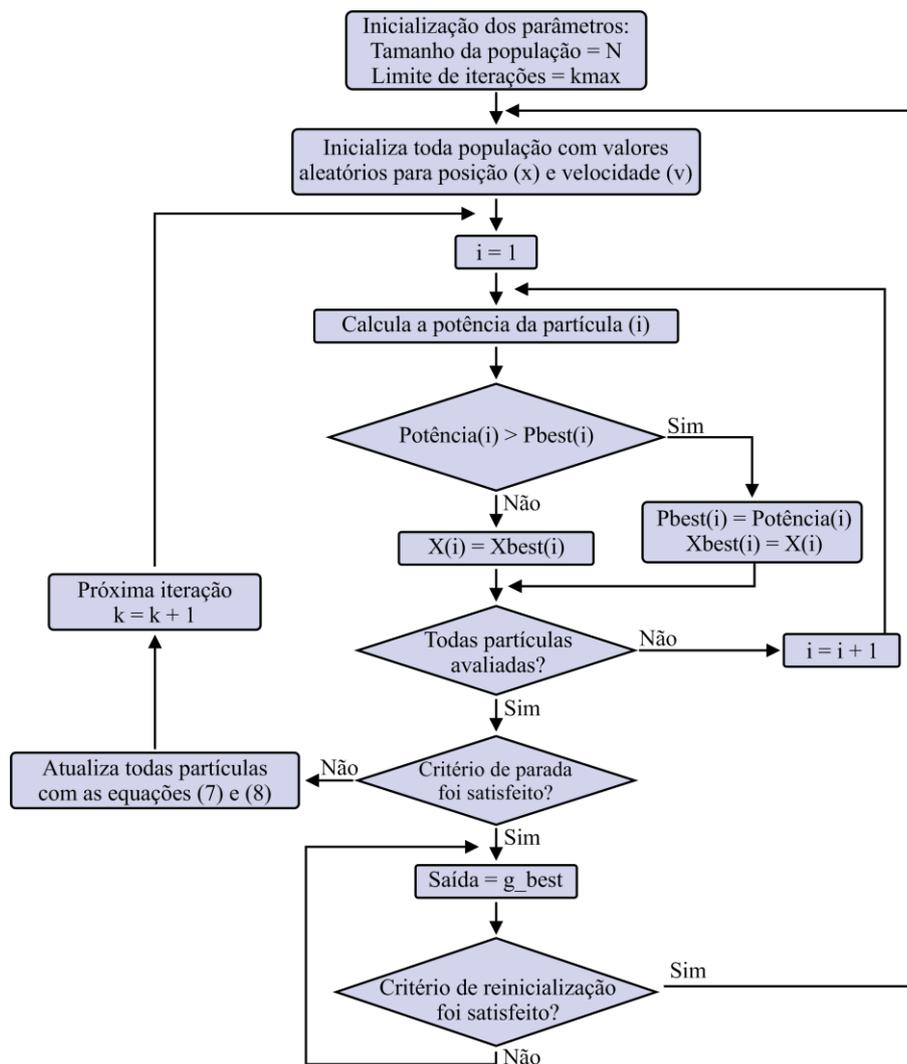
Estas equações são utilizadas para atualização da posição x_i e velocidade v_i , com k representando o número da iteração e i a partícula avaliada. Além disso, c_1 e c_2 são constantes de aceleração que mensuram a importância dos valores de g_{best} e p_{best} . Para exemplificar, quando $c_1 = c_2$ ambos valores são considerados de igual modo para definir a velocidade da partícula. Ademais r_1 e r_2 são números aleatórios definidos entre 0 e 1, empregados para introduzir um certo grau de aleatoriedade no processo, possibilitando explorar todo o espaço de busca de forma mais eficiente. O parâmetro ω , por sua vez, representa o peso de inércia, o qual é utilizado para ponderar a velocidade da partícula em direção ao GMPP [31].

A Figura 8 apresenta o fluxograma do método PSO aplicado ao MPPT para sistemas fotovoltaicos. Inicialmente, determina-se a quantidade de partículas e o número limite de

iterações. Em seguida, para cada partícula, são atribuídos valores aleatórios para velocidade dentro do intervalo $[0,1]$ e para posição dentro do intervalo $[15, V_{oc}]$. Posteriormente, calcula-se a potência de cada partícula. A função objetivo do método é representada pela equação (9), onde V_i^k e I_i^k denotam respectivamente a tensão e a corrente do arranjo fotovoltaico da partícula i na iteração k .

$$f(x_i) = P_i^k = V_i^k \cdot I_i^k \quad (9)$$

Figura 8 — Fluxograma do algoritmo PSO.



Fonte: Próprio autor.

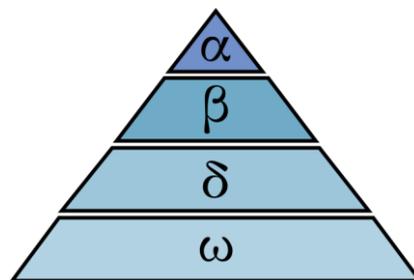
Em seguida, a potência da iteração atual P_i^k é comparada com a potência obtida na iteração anterior P_i^{k-1} , se P_i^k for maior, então P_i^k é definido como $P_{best,i}$ e a posição $X_{best,i}$ é definida como X_i ; caso contrário, a posição da partícula permanece a mesma que na iteração anterior. Após a comparação de todas as partículas, ocorre o processo de atualização utilizando as equações (7) e (8), até que o critério de parada seja satisfeito, ou seja, o número de iterações

máximo é atingido. Nesse caso, o sistema continua operando na posição g_{best} até que o critério de reinicialização seja satisfeito, o qual é avaliado por meio da equação (6).

2.4.Otimização por Lobos Cinzentos (GWO)

O método Otimização por Lobos Cinzentos (do inglês, *Grey Wolf Optimization – GWO*), é inspirado no comportamento hierárquico da matilha de lobos cinzentos. Conforme exemplificado na Figura 9, existem quatro classificações de lobos. O Alfa (α) é o melhor posicionado na matilha, também chamado de dominante, é responsável por ditar as regras que devem ser seguidas pelos demais lobos. Em segundo no comando está o Beta (β), seu dever é auxiliar o α na tomada de decisões e comandar os lobos de nível inferior; o lobo Delta (δ) é o que tem menor poder de decisão, estes devem manter a estrutura da matilha e cuidar do grupo para que não ocorram brigas internas. Os demais lobos são classificados como Ômegas (ω), sem poder de decisão para movimentar a matilha, desempenham as demais tarefas, que vão desde cuidadores de lobos doentes e feridos até alertar sinais de perigo para a matilha [32].

Figura 9 — Hierarquia dos lobos cinzentos (a dominância diminui de cima pra baixo)



Fonte: Adaptado de [31].

A modelagem matemática do comportamento de cercar as presas durante a caça é dada pelas equações (10) e (11).

$$\vec{D} = |\vec{C} \cdot \vec{X}_p - \vec{X}(k)| \quad (10)$$

$$\vec{X}(k+1) = \vec{X}_p(k) - \vec{A} \cdot \vec{D} \quad (11)$$

Onde \vec{X}_p representa o vetor posição da presa, $\vec{X}(k)$ é a posição do lobo na iteração k , \vec{A} e \vec{C} são coeficientes calculados de acordo com as equações (12) e (13) respectivamente, onde r_1 e r_2 são vetores de aleatoriedade definidos entre $[0,1]$; a é utilizado como fator de

convergência que diminui de 2 a 0, relacionado ao número de iterações, conforme mostra a equação (14).

$$\vec{A} = 2a \cdot \vec{r}_1 - a \quad (12)$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad (13)$$

$$a = 2 \left(1 - \frac{k}{k_{max}} \right) \quad (14)$$

Nesse sentido, como apenas os lobos α , β e δ , possuem poder de decisão para movimentação da matilha, o processo de atualização da posição é baseado nas equações (15) à (21)

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}_{wolf,i}^k| \quad (15)$$

$$\vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}_{wolf,i}^k| \quad (16)$$

$$\vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}_{wolf,i}^k| \quad (17)$$

$$\vec{X}_{wolf,\alpha} = \vec{X}_\alpha - \vec{A}_1 \cdot \vec{D}_\alpha \quad (18)$$

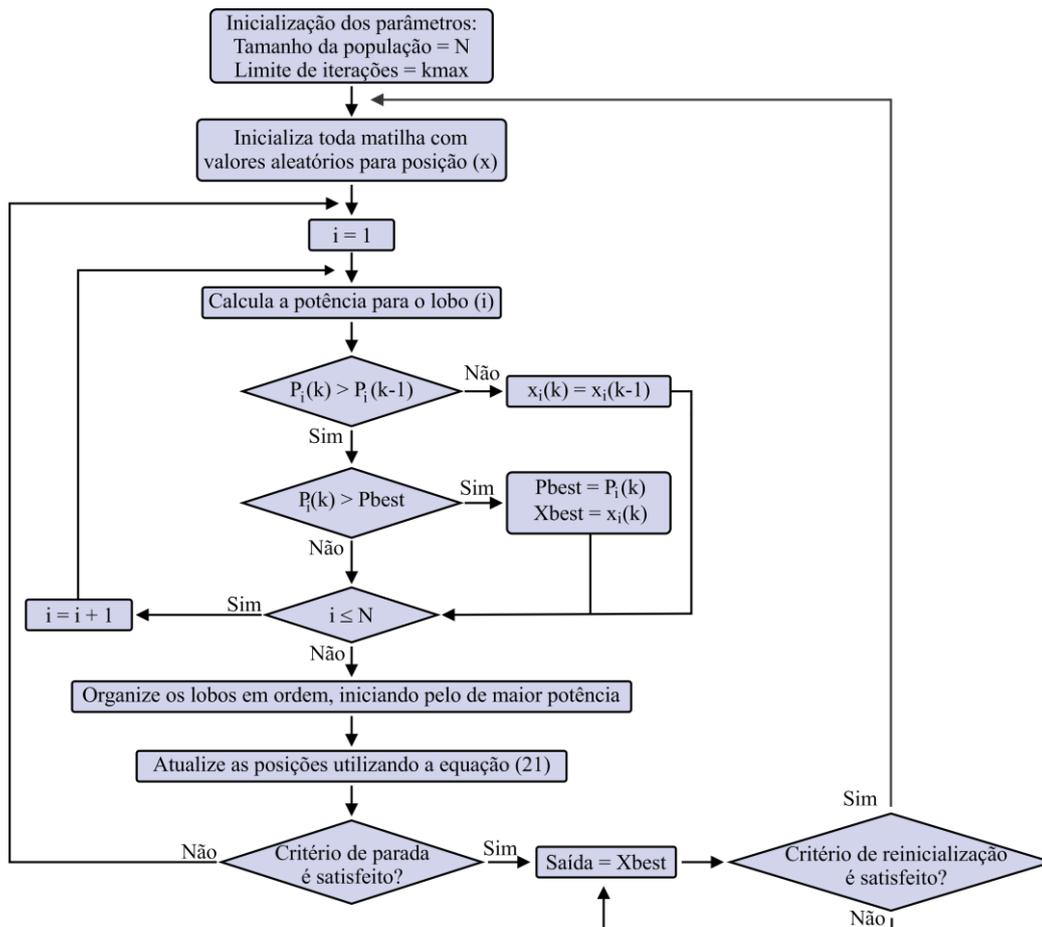
$$\vec{X}_{wolf,\beta} = \vec{X}_\beta - \vec{A}_2 \cdot \vec{D}_\beta \quad (19)$$

$$\vec{X}_{wolf,\delta} = \vec{X}_\delta - \vec{A}_3 \cdot \vec{D}_\delta \quad (20)$$

$$\vec{X}_{wolf,i}^{k+1} = \frac{\vec{X}_{wolf,\alpha} + \vec{X}_{wolf,\beta} + \vec{X}_{wolf,\delta}}{3} \quad (21)$$

Aqui \vec{D}_α , \vec{D}_β e \vec{D}_δ são as distâncias entre o lobo i , avaliado na iteração k , $\vec{X}_{wolf,i}^k$, e cada lobo com poder de decisão, respectivamente representados por \vec{X}_α , \vec{X}_β e \vec{X}_δ . Além disso, a posição do lobo avaliado, na iteração seguinte, é dada por $\vec{X}_{wolf,i}^{k+1}$.

Figura 10 — Fluxograma do algoritmo GWO.



Fonte: Próprio autor.

A Figura 10 ilustra o fluxograma de trabalho do algoritmo GWO aplicado para MPPT em sistemas fotovoltaicos. Inicialmente, estabelecem-se o número máximo de iterações e a matilha por N lobos, cada um posicionado aleatoriamente dentro do espaço de busca entre $[15, V_{oc}]$. Após avaliar a potência obtida por cada lobo, eles são classificados em ordem decrescente, sendo os três melhores posicionados designados como lobos α , β e δ , respectivamente. Em seguida, a posição de cada lobo é atualizada por meio da equação (21). Este processo é repetido até que o número máximo de iterações seja alcançado. Por fim, o critério de reinicialização é definido por meio da equação (6).

2.5. Otimização por Vagalumes (FA)

O Algoritmo Vagalume (do inglês, *Firefly Algorithm – FA*), é uma abordagem inspirada no mecanismo de emissão de luz dos vagalumes, os flashes curtos e rítmicos produzidos por meio de um processo de bioluminescência formam a base de sua reprodução,

caça e sinalização de situações de perigo. Observa-se que cada indivíduo tem uma intensidade de luz diferente, diretamente relacionada com suas características físicas, conferindo vantagens aos vagalumes mais brilhantes sobre os menos luminosos. O algoritmo se baseia no princípio de que a luz diminui à medida que a distância da fonte luminosa aumenta. Portanto, a luz intermitente dos vagalumes é modelada de forma que esteja associada a uma função objetivo, possibilitando a solução de problemas de otimização [33,34]. Nesse sentido, a formulação do algoritmo parte de três pressupostos:

- 1) Todos os vagalumes são unissex, então um vagalume será atraído pelo mais brilhante até ser comparado a todos os vagalumes;
- 2) A atratividade está proporcionalmente relacionada ao brilho relativo;
- 3) O brilho de cada vagalume é determinado pela função objetivo.

Para a avaliação da atratividade entre os vagalumes, utiliza-se a equação (22). Observa-se que quanto maior a distância, menor o brilho e conseqüentemente a atração. Aqui β_0 representa a atratividade inicial, normalmente definida como 1, r_{ij} é a distância cartesiana entre os dois vagalumes, calculada pela equação (23). Além disso, γ é um coeficiente de absorção que controla a diminuição da intensidade do brilho conforme a distância aumenta.

$$\beta = \beta_0 e^{-\gamma r_{ij}^2} \quad (22)$$

$$r_{ij} = \|x_i - x_j\| = \sqrt{\sum_{k=1}^d (x_{i,k} - x_{j,k})^2} \quad (23)$$

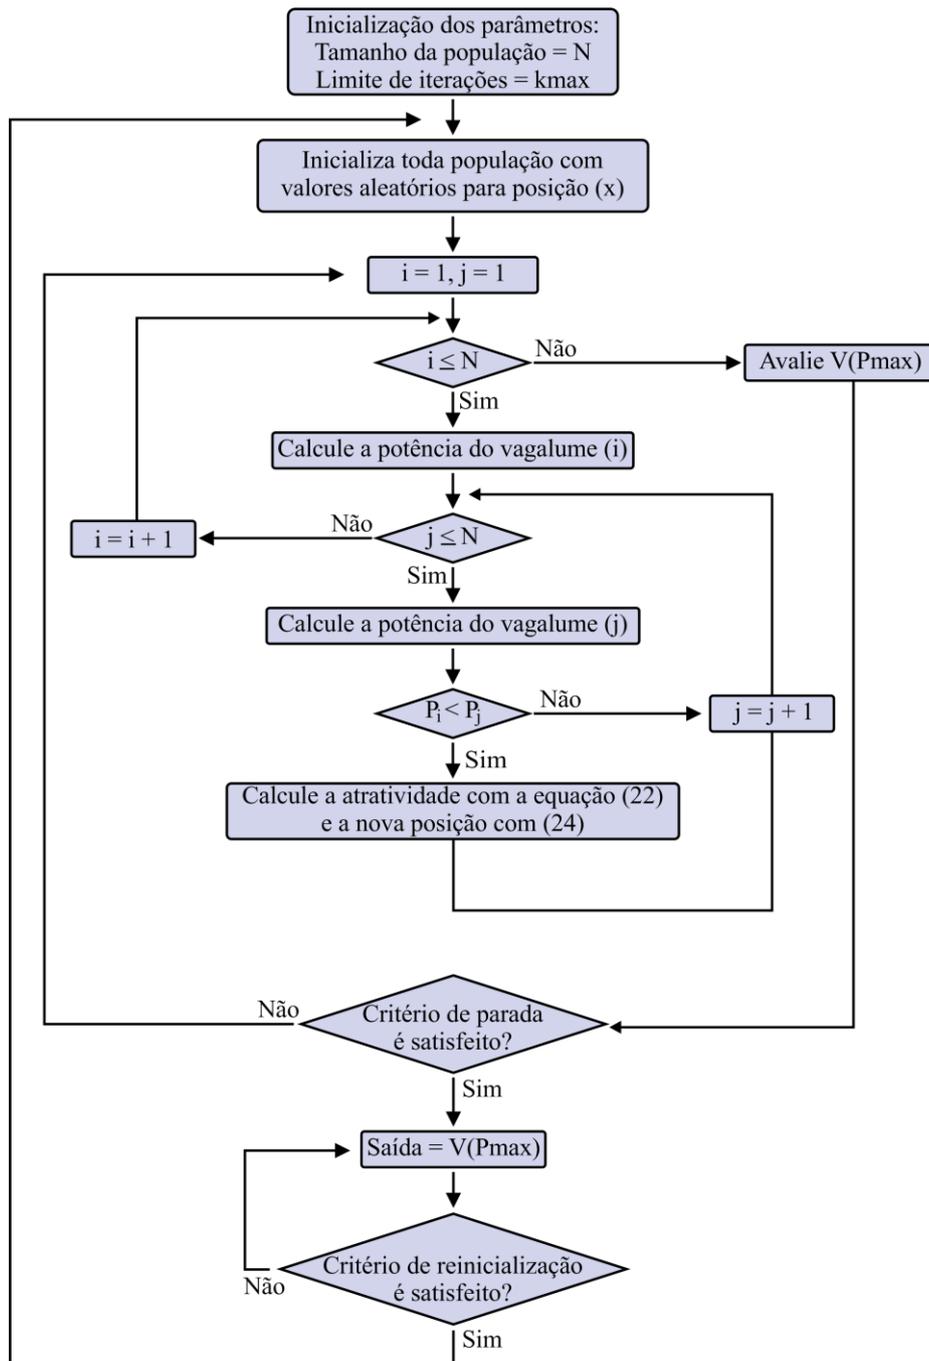
O movimento dos vagalumes é governado pela equação (24), onde x_i^{k+1} é a nova posição do vagalume i . O segundo termo da equação representa a atração entre os vagalumes i e j . Além disso, um número aleatório entre $[0, 1]$, denotado por ($rand$), é utilizado para introduzir uma certa aleatoriedade ao algoritmo, auxiliando na exploração do espaço de busca.

$$x_i^{k+1} = x_i^k + \beta \cdot (x_j^k - x_i^k) + \alpha \cdot \left(rand - \frac{1}{2} \right) \quad (24)$$

A Figura 11 mostra o fluxograma de trabalho do algoritmo aplicado para MPPT em sistemas fotovoltaicos. O método inicia definindo o número máximo de iterações e uma população com N vagalumes. O brilho avaliado é representado pela potência obtida do arranjo fotovoltaico, conforme a equação (9). Posteriormente, cada vagalume é comparado com os demais, movendo-se sempre em direção ao mais brilhante, ou seja, com maior potência avaliada. Para ilustrar, considera-se os vagalumes i e j , respectivamente posicionados em x_i e

x_j . Se o brilho do vaga-lume j for maior que o brilho de i , x_i é atualizado em direção a x_j , e uma nova potência é avaliada. Caso contrário, a posição do vaga-lume i permanece inalterada. O processo de comparação continua até que todos os vaga-lumes tenham sido comparados entre si, e uma nova iteração seja iniciada. O algoritmo é finalizado ao final das iterações e reiniciado quando a equação (6) for satisfeita.

Figura 11 — Fluxograma Algoritmo Vagalume.



Fonte: Próprio autor.

2.6. Algoritmo dos Morcegos (BAT)

O Algoritmo dos Morcegos (do inglês, *Bat Algorithm – BA*) é baseado no sistema de ecolocalização dos morcegos, especialmente os micro morcegos, que utilizam essa habilidade de forma mais ampla. As características do pulso sonoro variam entre as espécies. A maioria dos morcegos são capazes de gerar sinais modulados, enquanto outras espécies emitem pulsos de frequência constante. Cada pulso tem duração na faixa de milésimos de segundo e pode atingir até 150 kHz. Esse mecanismo é empregado pelos morcegos para detectar presas, evitar obstáculos e até mesmo localizar fendas para empoleiramento [35].

Para a formulação do algoritmo, são consideradas as seguintes premissas [36]:

- 1) Todos os morcegos utilizam a ecolocalização para avaliar a distância e são capazes de distinguir entre comida/presa e barreiras de fundos.
- 2) Os morcegos voam aleatoriamente e podem ajustar a frequência de seus pulsos emitidos.
- 3) Embora o volume possa variar de diferentes maneiras, assume-se que o volume passe de um valor grande para um valor mínimo.

Dessa forma, o movimento dos morcegos pode ser descrito pelas equações (25), (26) e (27).

$$f_i = f_{min} + (f_{max} - f_{min}) \cdot \beta \quad (25)$$

$$v_i^{k+1} = v_i^k + (x_i^k - x_{best}) \cdot f_i \quad (26)$$

$$x_i^{k+1} = x_i^k + v_i^{k+1} \quad (27)$$

Na equação (25), f_{min} e f_{max} representam uma frequência mínima e máxima respectivamente, associadas ao domínio do problema, geralmente definidas como 0 e 1. O parâmetro β é uma constante aleatória pertencendo ao intervalo $[0, 1]$, utilizado para garantir a aleatoriedade do movimento e ajustar a velocidade do morcego em direção à presa. Além disso, x_i^k denota a posição do morcego i na iteração k que se move, com uma velocidade v_i^k em direção do morcego melhor posicionado, referido como x_{best} .

Ademais, outras duas características são utilizadas no processo de busca do algoritmo dos morcegos. A primeira é o volume A , que pode ser associado à intensidade de busca dos morcegos, enquanto a segunda característica é a frequência do pulso r , ou seja, a taxa de emissão de pulsos em busca da presa. Uma taxa de pulso alta significa que os morcegos emitem

os pulsos com mais frequência, aumentando a capacidade de busca e velocidade de convergência. No entanto, uma taxa de pulso baixa permite o refinamento da busca, realizando passos menores em busca do ponto ótimo. Essas duas características são representadas pelas equações (28) para o volume e (29) para a taxa de pulso.

$$A_i^{k+1} = \alpha \cdot A_i^k \quad (28)$$

$$r_i^{k+1} = r_i^0 \cdot [1 - e^{(-\gamma \cdot k)}] \quad (29)$$

Onde α e γ representam constantes que controlam a redução do volume e da frequência de pulso ao longo das iterações. No processo de busca, a frequência de pulso é comparada com um valor aleatório entre 0 e 1. Se a frequência de pulso for menor que este valor, uma nova posição é gerada utilizando a equação (30). Caso contrário, não ocorrem alterações na posição do morcego.

$$x_i^{k+1} = x_{best} + \mu_A \cdot randn \quad (30)$$

Na equação (30), μ_A representa a média dos volumes calculados de toda população dos morcegos, x_{best} denota a posição do morcego que obteve o melhor valor na função objetivo e, $randn$, um número aleatório entre [-1, 1]. Assim, o fluxograma de trabalho do algoritmo dos morcegos é mostrado na Figura 12.

atualizados, caso contrário, a nova posição é descartada. Em seguida, o volume é comparado com um valor aleatório entre 0 e 1, (*rand*). Se o volume calculado for maior que o *rand*, uma nova posição é gerada a partir da equação (30). Assim, a potência obtida por essa nova posição é então comparada com a potência da iteração anterior, e, se for superior, torna-se a nova posição do morcego *i*; caso contrário, a posição permanece inalterada. Por fim, é verificado se a nova potência é a melhor obtida em toda população até o momento, e inicia-se uma nova iteração até que o limite seja atingido. Além disso, semelhantemente aos demais métodos, o processo de reinicialização ocorre de acordo com a equação (6).

2.7.Otimização por Busca Cuco (CS)

Inspirado pela agressiva estratégia de reprodução dos pássaros cucos, o algoritmo Busca Cuco, (do inglês, *Cuckoo Search – CS*), emprega o conceito de parasitismo de ninho para resolver problemas de otimização. A estratégia utilizada por essas aves consiste em depositar seus ovos em ninhos de outras espécies, especialmente quando a ave hospedeira acaba de pôr seus próprios ovos. Observa-se que geralmente o processo de eclosão dos ovos cuco é menor, o que fornece uma vantagem para os filhotes ao nascer, permitindo que empurrem para fora do ninho os ovos da espécie hospedeira. Este comportamento visa assegurar uma maior parcela de alimento, que será fornecido pela ave hospedeira aos filhotes cucos [37].

Aqui, a implementação do algoritmo é caracterizada pelo fato de que cada cuco pode depositar apenas um único ovo, escolhendo um ninho que representa uma possível solução. O objetivo principal é encontrar soluções potencialmente melhores, substituindo aquelas que não são tão promissoras nos ninhos. Para isso, a movimentação dos pássaros cuco é baseada nas características dos vôos de Lévy, que descreve uma classe de movimentos aleatórios. Esses voos são caracterizados por comprimentos de passos que seguem uma distribuição semelhante à lei da potência, isso implica que eventos raros, mas significativos, ocorrem com maior frequência do que seria esperado em uma distribuição normal, o que auxilia os problemas de otimização na exploração do espaço de busca. Para isso, a equação (31) é utilizada para calcular o tamanho do passo (*s*), por meio das distribuições gaussianas *U* e *V* [38,39].

$$s = \frac{U}{|V|^{\frac{1}{\beta}}} \quad (31)$$

Onde,

$$U \sim N(0, \sigma^2), \quad V \sim N(0,1) \quad (32)$$

Aqui $U \sim N(0, \sigma^2)$, significa que as amostras são extraídas de uma distribuição normal gaussiana com média zero e variância de σ^2 , calculada pela equação (33).

$$\sigma = \left(\frac{\Gamma(1 + \beta) \cdot \text{sen}\left(\frac{\pi \cdot \beta}{2}\right)}{\Gamma\left(\frac{1 + \beta}{2}\right) \cdot \beta \cdot 2^{\frac{\beta-1}{2}}}\right)^{\frac{1}{\beta}} \quad (33)$$

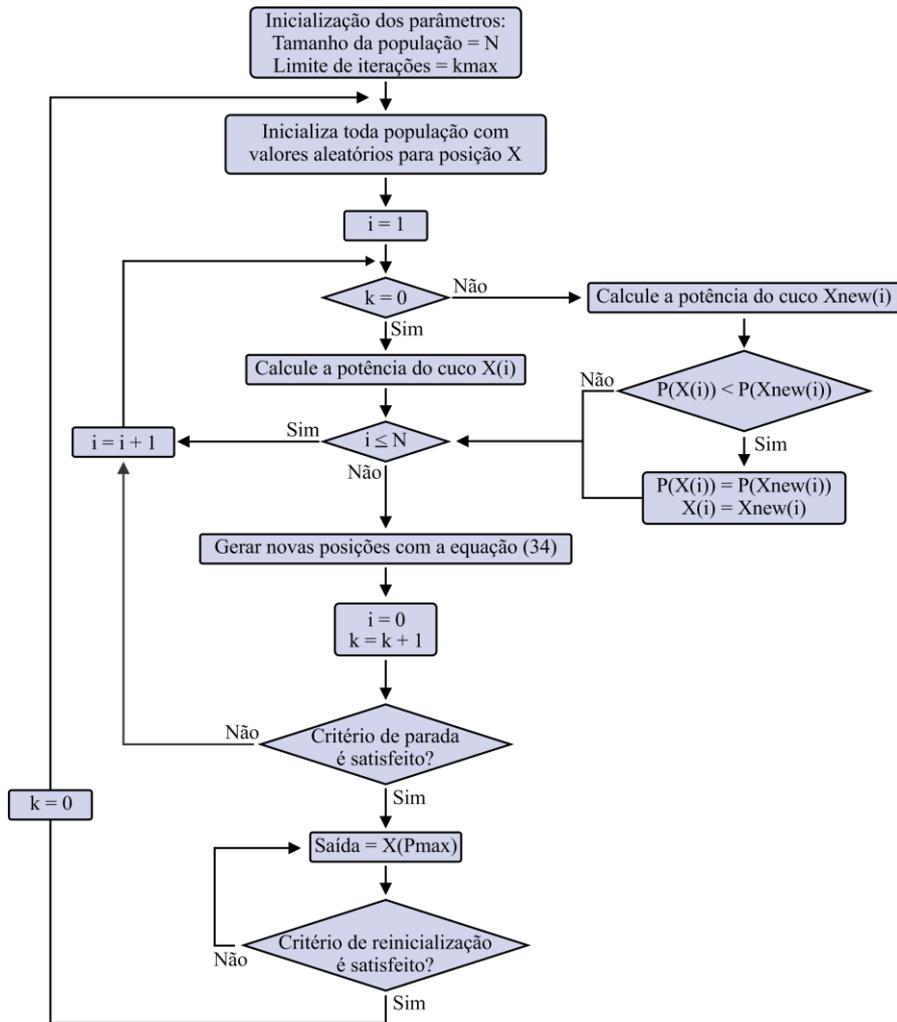
Conforme descrito em [37], para a maioria dos problemas, β é utilizado como 1,5. Nesse sentido, o tamanho do passo (s) é utilizado para mover as novas soluções em direção ao pássaro melhor posicionado, por meio da equação (34).

$$X_{new,i} = X_i + randn \cdot K \cdot s \cdot (X_i - X_{best}) \quad (34)$$

Onde $X_{new,i}$ representa a nova posição do pássaro i e X_{best} é o cuco melhor localizado. Além disso, K é utilizado como um coeficiente de degrau, normalmente definido entre 0,01 e 0,05 e $randn$ é um número aleatório entre [-1, 1] [39].

A Figura 13 mostra o fluxograma do algoritmo Busca Cuco baseado em MPPT para sistemas fotovoltaicos. Semelhante aos outros métodos, o processo começa definindo o tamanho da população e o número máximo de iterações, seguido pelo posicionamento aleatório de cada cuco dentro do intervalo $[15, V_{oc}]$. Durante a primeira iteração, todas as posições são avaliadas com base na potência obtida por cada pássaro. Em seguida, novas posições são calculadas de acordo com a equação (34). Na iteração seguinte, a potência de cada cuco é avaliada para a nova posição e comparada com o valor da iteração anterior. A posição com melhor resultado é armazenada para comparação na próxima iteração, juntamente com novas posições geradas. Esse processo é repetido até que o número de iterações atinja o limite, então o sistema ficará operando na posição do cuco que obteve a melhor potência (X_{best}). Além disso, o processo de reinicialização ocorre de forma idêntica aos demais métodos, por meio da equação (6).

Figura 13 — Fluxograma algoritmo Busca Cuco.



Fonte: Próprio autor.

2.8. Colônia Artificial de Abelhas (ABC)

Proposto por D. Karaboga em 2005, o método Colônia Artificial de Abelhas (do inglês, *Artificial Bee Colony – ABC*), é inspirado na organização das colônias de abelhas. Este algoritmo incorpora três tipos distintos de abelhas: as empregadas, as observadoras e as batedoras. Cada fonte de alimento, que representa uma possível solução para o problema de otimização, é atribuída a uma abelha empregada, também encarregada de avaliar novas soluções caso a atual seja descartada pelas batedoras. Além disso, com base nas informações fornecidas pelas abelhas empregadas, as observadoras utilizam de probabilidade para avaliar as fontes de alimento e realizar ajustes em suas posições. Por outro lado, as batedoras são

responsáveis por eliminar as fontes de alimento que não se aprimorarem após número determinado de ciclos, substituindo-as por novas soluções aleatórias [40,41].

Após cada abelha empregada avaliar sua respectiva fonte de alimento, a equação (35) é utilizada para calcular a probabilidade associada, onde N representa a quantidade de abelhas empregadas.

$$p_i = \frac{fit_i}{\sum_{n=1}^N fit_n} \quad (35)$$

Observa-se que o fit_i é avaliado da seguinte maneira:

$$fit_i = \begin{cases} \frac{1}{1 + fitness_i}, & se \ fitness_i \geq 0 \\ 1 + |fitness_i|, & se \ fitness_i < 0 \end{cases} \quad (36)$$

Onde $fitness_i$ representa a quantidade de néctar encontrada em cada posição inicial. Em seguida, a equação (37) é aplicada para gerar uma nova solução para cada abelha empregada.

$$x_{new,i} = x_i + \varphi \cdot (x_i - x_k) \quad (37)$$

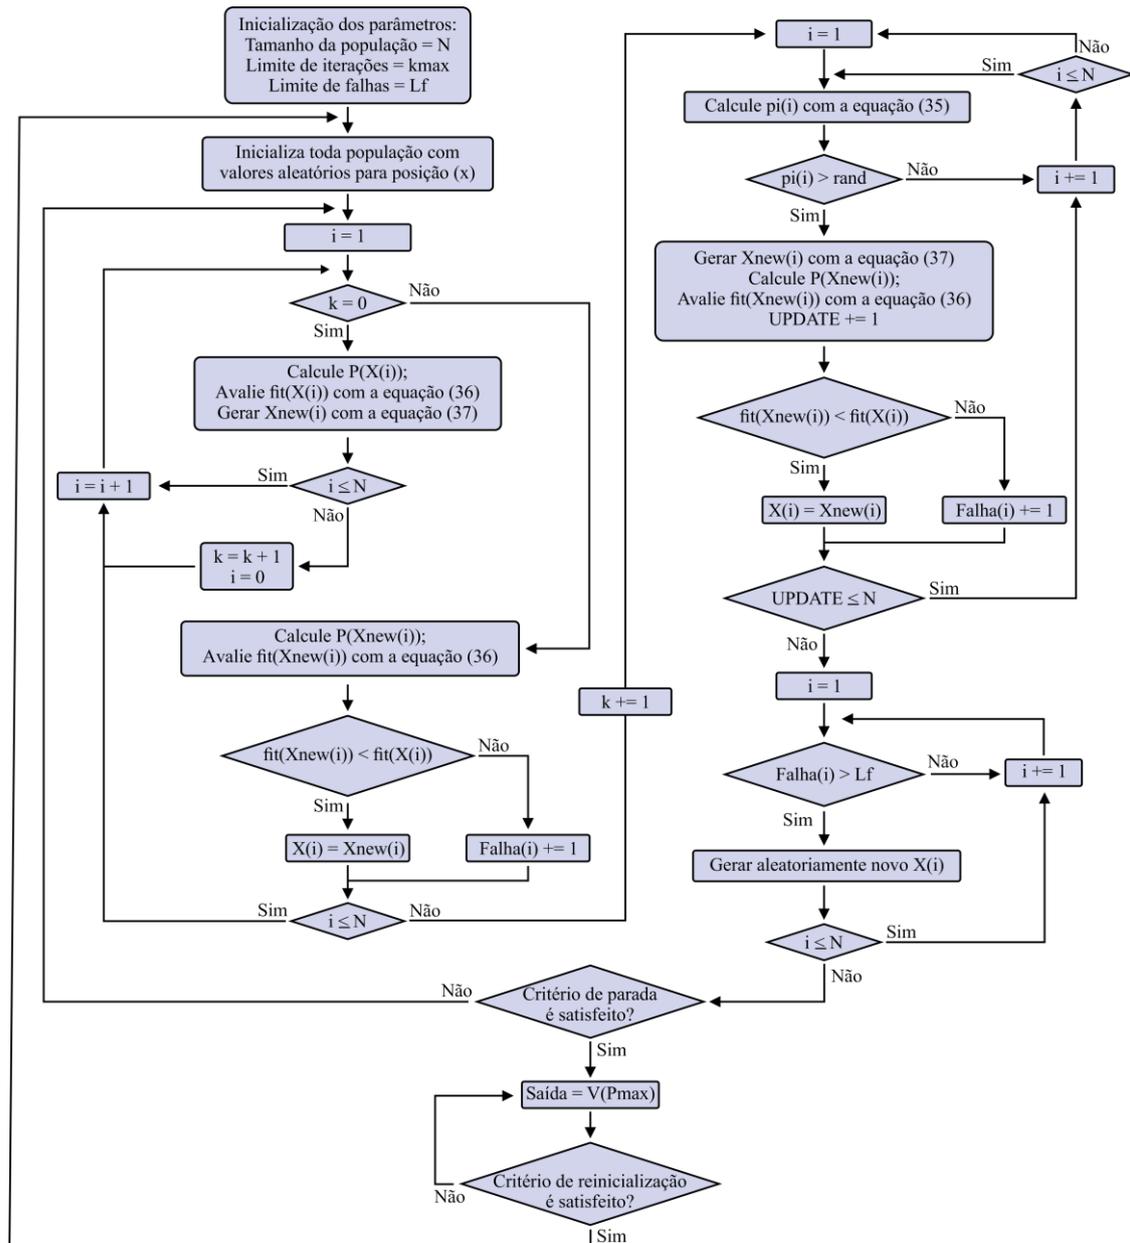
Aqui, $x_{new,i}$ representa a nova solução gerada para abelha i , φ é uma constante aleatória no intervalo $[-1, 1]$, x_i é a posição atual da abelha i e x_k é a posição de uma outra abelha da colônia, escolhida aleatoriamente. Após avaliar as novas posições de todas as abelhas empregadas, a probabilidade $p_{new,i}$ é comparada com p_i . Se p_i for maior, a abelha i retorna para posição x_i e conta-se um ciclo em que a abelha i não conseguiu melhorar sua fonte de comida, caso contrário, ela permanece em $x_{new,i}$. Após receber essas informações, as abelhas observadoras realizam a comparação entre a probabilidade atual e uma constante aleatória que irá controlar se a posição atual de cada abelha empregada será alterada ou não. Caso alguma posição seja alterada, o processo de avaliação é repetido. Por fim, as abelhas batedoras avaliam a quantidade de ciclos em que as abelhas empregadas não tiveram progresso; caso o número de ciclos seja superior à um limite estabelecido, uma nova posição é gerada aleatoriamente para a respectiva abelha empregada e soma-se uma iteração, caso contrário, novas posições são geradas de acordo com a equação (37) e computa-se uma iteração. O processo de avaliação ocorre até que o número de iterações limites seja atingido ou algum outro critério de parada seja estabelecido.

A Figura 14 ilustra o fluxograma de trabalho do algoritmo ABC baseado em MPPT para sistemas fotovoltaicos. Inicialmente é definida uma população composta por N abelhas,

juntamente com o limite de iterações para o algoritmo e um limite de falhas para determinar quando as abelhas batedoras devem escolher uma nova posição para as empregadas. Cada abelha empregada é posicionada aleatoriamente no espaço de busca entre $[15, Voc]$. Em seguida a potência de toda população é avaliada. Posteriormente, são calculadas novas posições para cada abelha, que devem ter a potência medida igualmente. Então o fit_i de cada posição é calculado por meio da equação (36). Caso o $fit_{new,i}$ seja menor que fit_i , a posição anterior assume o valor da nova posição, caso contrário x_i permanece inalterada e uma falha é registrada para abelha i .

Em seguida, as abelhas observadoras avaliam a probabilidade associada em cada abelha empregada, por meio da equação (35), caso a probabilidade seja maior que um número aleatório entre $[0,1]$, uma nova posição para respectiva abelha é gerada e soma-se um na contagem de atualizações (*UPDATE*). Então a nova posição tem a potência medida e o valor $fit_{new,i}$ é comparado com fit_i . Da mesma forma que na etapa anterior, a posição x_i pode assumir $x_{new,i}$ ou então uma falha adicional é registrada para abelha i . Esse processo das abelhas observadoras é repetido até que o valor de *UPDATE* seja maior que N .

Figura 14 — Fluxograma algoritmo ABC.



Fonte: Próprio autor.

Finalmente, inicia-se a etapa das abelhas batedoras que avaliam se alguma abelha tem o número de falhas superior ao limite escolhido pelo projetista, em caso afirmativo é definido um novo valor aleatório para x_i e o valor de falhas dessa abelha é zerado, em seguida verifica-se o processo de parada, caso seja satisfeito, o sistema opera na melhor posição encontrada até que o processo de reinicialização seja atendido, caso contrário o algoritmo retorna para etapa das abelhas empregadas. Além disso, o processo de reinicialização também ocorre de acordo com a equação (6).

2.9.Considerações do Capítulo

As técnicas de MPPT são fundamentais para garantir a eficiência na conversão de energia em sistemas fotovoltaicos. Neste capítulo, foram abordados diversos algoritmos de MPPT, incluindo tanto técnicas convencionais como a Perturba e Observa (P&O) quanto abordagens mais avançadas, baseadas em computação suave, como Otimização por Seção Áurea (GSO), Otimização por Enxame de Partículas (PSO), Otimização por Lobos Cinzentos (GWO), Algoritmo dos Morcegos (BAT), Otimização por Vagalumes (FA), Busca Cuco (CS) e Colônia Artificial de Abelhas (ABC). Cada técnica foi detalhadamente discutida, apresentando fluxogramas ilustrativos e a descrição de cada etapa de operação.

Nota-se que embora o método P&O seja simples e de baixo custo para implementação, este apresenta limitações para rastreamento do ponto GMPP, com maior probabilidade de convergência para um LMPP. Observa-se também que as técnicas baseadas em computação suave oferecerem maior eficiência em rastrear o GMPP em situações com sombreamento parcial. Assim, a implementação desses métodos pode resultar em uma extração de energia mais eficiente e uma maior estabilidade operacional dos sistemas fotovoltaicos.

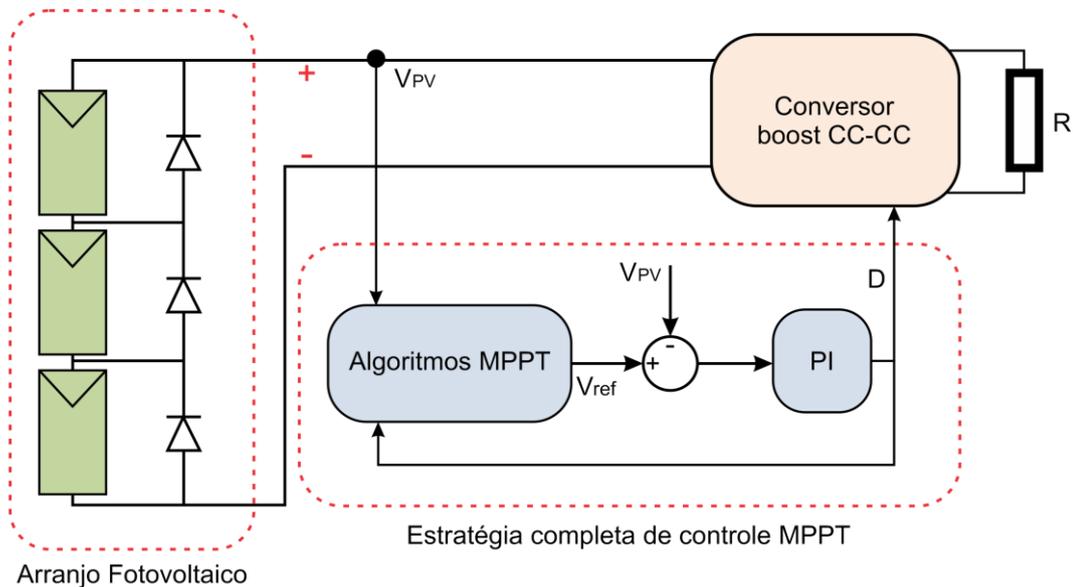
3. Materiais e métodos

Neste capítulo serão apresentadas as especificações, os detalhes das simulações e dos testes experimentais do sistema implementado, além de informações sobre a metodologia utilizada. O objetivo é desenvolver algoritmos baseados em computação suave sem a necessidade do uso de sensores de corrente. Para isso, um sistema composto por um arranjo fotovoltaico, um conversor CC-CC boost e uma carga resistiva foi utilizado para avaliar o desempenho das técnicas de MPPT apresentadas na seção anterior. A seguir serão descritos os procedimentos e materiais utilizados nas etapas de simulação e experimental.

3.1. Sistema implementado em simulação

Inicialmente, a modelagem do sistema, ilustrada esquematicamente na Figura 15, foi desenvolvida no ambiente de simulação do software MATLAB/Simulink®.

Figura 15 — Diagrama de blocos do sistema de simulação.

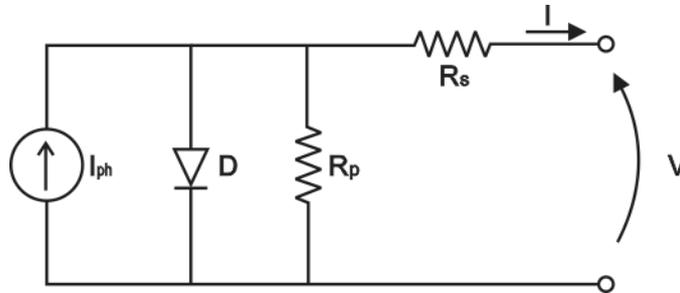


Fonte: Próprio autor.

Para a construção da simulação do arranjo fotovoltaico utilizou-se da modelagem matemática da célula, descrita em [6]. O modelo é desenvolvido a partir do circuito elétrico equivalente mostrado na Figura 16, composto por uma fonte de corrente em antiparalelo com um diodo, e resistências em série e paralelo, utilizadas para considerar as não idealidades da

célula. Neste circuito, a corrente I e a tensão V são, respectivamente, a corrente e a tensão de saída da célula.

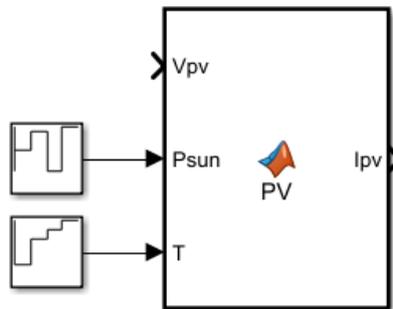
Figura 16 — Circuito equivalente de uma célula fotovoltaica.



Fonte: [6].

Implementado no ambiente do software MATLAB/Simulink®, a Figura 17 apresenta o bloco programável PV, onde a corrente I_{pv} é calculada a partir de dados de entrada do sistema, com os valores de temperatura [$^{\circ}\text{C}$] e irradiância [W/m^2]. O modelo foi adaptado de acordo com [6] para a partir de uma célula reproduzir o efeito de um módulo.

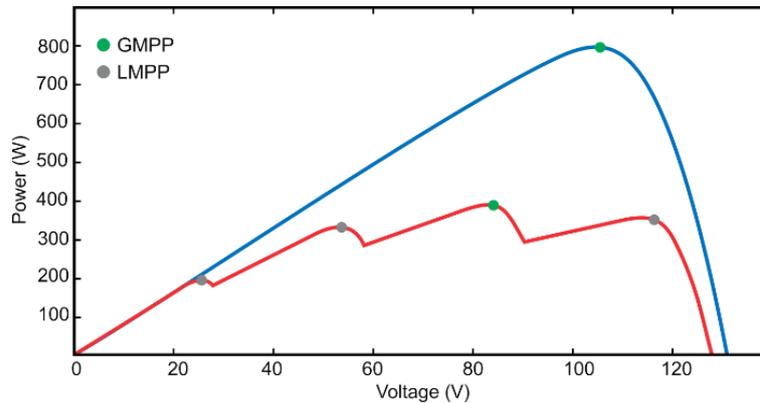
Figura 17 — Bloco programável para um módulo fotovoltaico.



Fonte: Próprio autor.

A formação de um arranjo fotovoltaico consiste na associação de diversos módulos conectados em série e/ou paralelo. Nesse sentido, para o modelo de simulação, será utilizado um arranjo composto por 4 módulos conectados em série, nomeados como M1, M2, M3 e M4. Observa-se que para cada módulo é possível definir valores de temperatura e irradiância como parâmetros de entrada. Desse modo, duas situações são consideradas, a primeira ocorre quando todos os módulos recebem os mesmos valores de irradiância e temperatura, enquanto a segunda situação é resultado de valores diferentes entre estes. Assim, para cada situação é possível gerar uma curva característica $P \times V$, conforme exemplo da Figura 18.

Figura 18 — Curvas P_xV, com temperatura e irradiância uniforme (azul) e não uniforme (vermelho).



Fonte: Adaptado de [9].

Na Figura 18, a curva em azul mostra a condição homogênea, onde os quatro módulos fotovoltaicos recebem a mesma irradiância e temperatura, resultando em um único MPP. Em contraste, a curva vermelha ilustra a condição de sombreamento parcial, com três LMPPs e um GMPP. Dessa forma, a simulação do arranjo fotovoltaico permite obter curvas P_xV para diferentes valores de irradiância e temperatura, destacando como o desempenho do sistema é influenciado pelas condições meteorológicas.

Outro ponto a ser observado é a necessidade de definição das características do módulo fotovoltaico. Nesse sentido, escolheu-se o módulo comercial modelo KC200GT da Kyocera e as suas principais especificações, utilizadas na simulação, juntamente com as características de dimensionamento do conversor CC-CC boost, estão detalhadas na Tabela 1. O dimensionamento dos elementos do conversor boost segue a metodologia encontrada em [42].

Tabela 1 — Características do módulo fotovoltaico + conversor boost

Parâmetros	Valores
Potência máxima	$P_{MAX} = 200 \text{ Wp}$
Tensão no MPP	$V_{MPP} = 26,3 \text{ V}$
Corrente no MPP	$I_{MPP} = 7,61 \text{ A}$
Tensão de circuito aberto	$V_{OC} = 32,9 \text{ V}$
Corrente de curto circuito	$I_{SC} = 8,21 \text{ A}$
Coefficiente de temperatura para I_{SC}	$\alpha = 3,18 \times 10^{-3} \text{ A/}^\circ\text{C}$
Capacitância de Desacoplamento	$C_{IN} = 100 \mu\text{F}$
Indutância boost	$L_{IN} = 2 \text{ mH}$
Capacitância boost	$C_b = 42 \mu\text{F}$
Carga boost	$R_L = 34 \Omega$
Frequência de chaveamento boost	$F_s = 30 \text{ kHz}$

Fonte: Próprio autor.

O conversor CC-CC boost é responsável pela adaptação da energia do arranjo fotovoltaico para ser entregue à carga. Além disso, a partir da modelagem matemática do conversor, é realizado a predição de corrente e, portanto, a eliminação deste sensor. Para isso, observa-se que a tensão do arranjo é a tensão de entrada V_{in} , e que a carga R deve dissipar a máxima potência em uma tensão de saída V_o desejada. Além disso, a relação do ciclo de trabalho D do conversor e seu ganho estático G , é expressa na equação (38). Na sequência, as equações (39) e (40) são utilizadas para descrever a corrente que flui através da carga R e pelo indutor L , respectivamente.

$$G = \frac{V_o}{V_{in}} = \frac{1}{1 - D} \quad (38)$$

$$I_R = \frac{V_o}{R} \quad (39)$$

$$L = \frac{I_D}{1 - D} \quad (40)$$

Com I_D representando a corrente no diodo do conversor. Observa-se que, em termos médios, essa corrente é igual a I_R . Assim, ao isolar I_D em (40) e igualar com (39), obtêm-se (41).

$$I_L = \frac{V_o}{R(1 - D)} \quad (41)$$

Ao utilizar um sensor de tensão para medir a tensão do arranjo fotovoltaico V_{in} , é possível isolar V_o de (38) e substituir em (41) para obter (42). Esta equação é utilizada para a predição de corrente do arranjo, ou seja, I_{pv} .

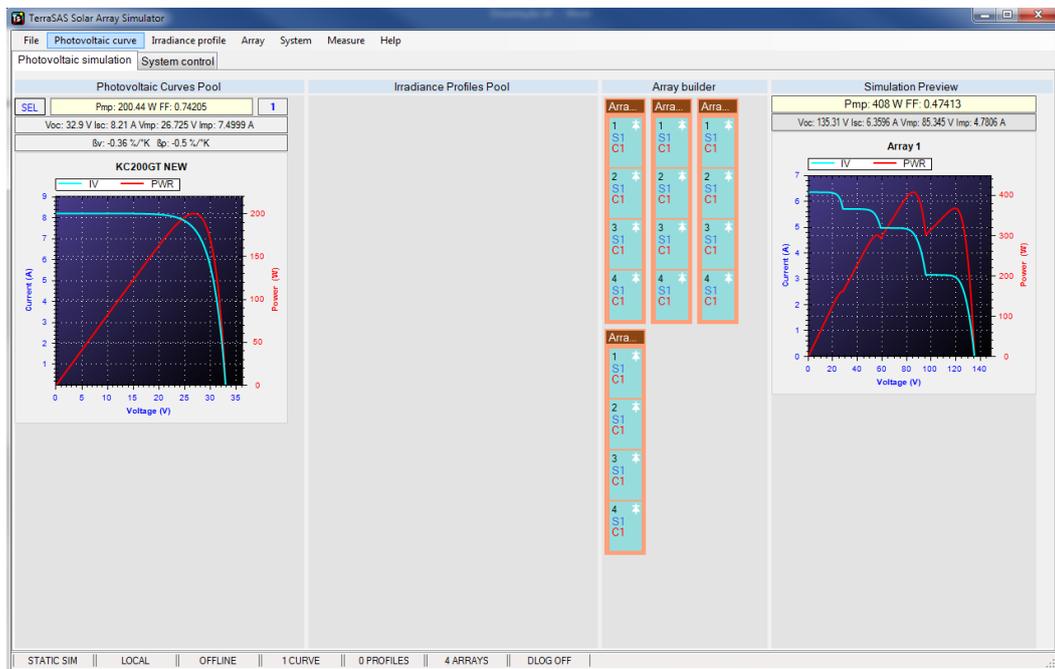
$$I_L = \frac{V_{in}}{R(1 - D)^2} = I_{PV} \quad (42)$$

Por fim, utiliza-se de outro bloco programável para o MPPT, que engloba a predição de corrente e cada algoritmo implementado juntamente com um controlador PI integrado, que são responsáveis por ajustar o ciclo de trabalho do conversor para alcançar o GMPP sob diferentes níveis de irradiância e temperatura. Observa-se que o tempo de amostragem é essencial para avaliação dos algoritmos, uma vez que o sistema fotovoltaico precisa atingir o estado estacionário antes do início da próxima amostragem. Para as simulações realizadas, a amostragem foi definida em 1 kHz [43].

3.2. Sistema experimental implementado

Para a alimentação do sistema é utilizado uma fonte de energia programável para simular o comportamento elétrico dos módulos fotovoltaicos, modelo TerraSAS ETS 600/17 da Elgar. Esse simulador também oferece soluções em *software*, permitindo a configuração das características dos módulos e a formação de arranjos fotovoltaicos. Além disso, este possibilita a representação de curvas com sombreamento parcial e a avaliação rápida e eficiente do desempenho dos algoritmos de MPPT. A interface do *software* é apresentada na Figura 19, onde se observa que é possível definir os valores de irradiância e temperatura para cada módulo, além das características do módulo escolhido, que são exibidas à esquerda [44].

Figura 19 — Interface do *software* da fonte programável terraSAS.

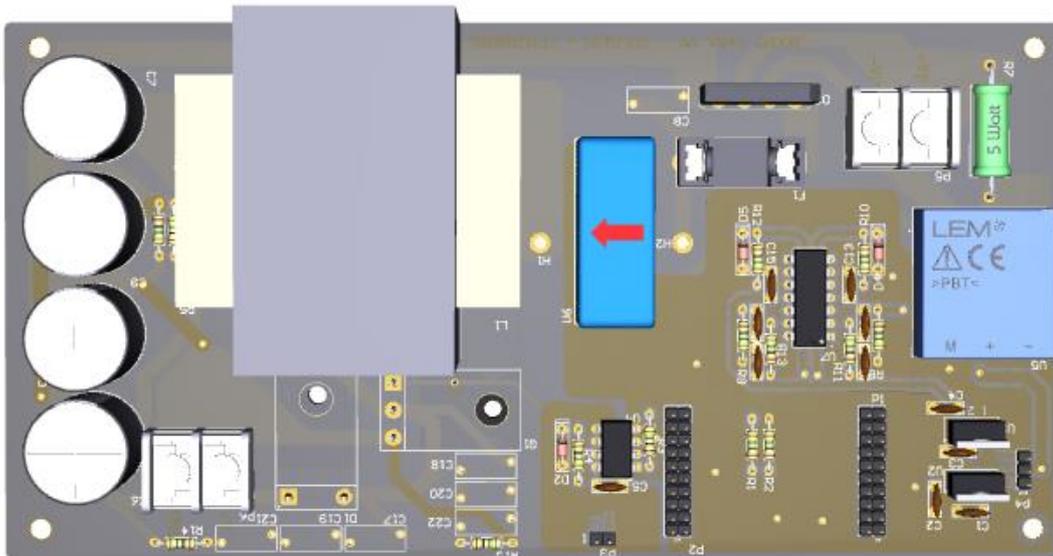


Fonte: Próprio autor.

Com relação ao protótipo, este é composto pelo conversor CC-CC boost, circuitos de condicionamento de sinal e de ataque de *gate*. O *layout* do protótipo foi desenvolvido no *software* Altium, e é apresentado na Figura 20. Os terminais do simulador fotovoltaico são conectados à entrada do conversor, que, por sua vez, está conectado à uma carga resistiva. Observa-se que tanto o arranjo fotovoltaico, programado no *software* TerraSAS, quanto os parâmetros construtivos do conversor boost, apresentam as mesmas características da simulação. Nota-se, também, que um sensor de corrente e outro de tensão são utilizados para

leitura da saída do TerraSAS. Em seguida, após o condicionamento, o DSP recebe os sinais por meio das entradas A/D (analógica/digital) e realiza o processamento para controle do ciclo de trabalho do conversor. É válido ressaltar que a construção do experimento conta com um sensor de corrente apenas para comparação dos algoritmos convencionais, que utilizam ambos os sensores, com os algoritmos *sensorless* propostos.

Figura 20 — Layout do protótipo desenvolvido utilizando o software Altium.



Fonte: [45].

A programação do DSP é realizada via *software* Code Composer Studio (CCS) e o modelo utilizado é o LAUCHXL-F28379D, produzido pela Texas Instruments, contendo o microcontrolador TMS320F28379D. Este apresenta excelente performance, com operação em até 200 MHz e até 24 saídas PWM [46]. Além disso, utilizou-se também de fontes auxiliares para alimentação simétrica de 15 V dos sensores e para os circuitos de condicionamento e ataque de *gate* do IGBT da Infineon, modelo IRG4PH50UD. Para a leitura das formas de onda, foi utilizado um osciloscópio DSOX3054T da KEYSIGHT, o qual possibilitou salvar e avaliar os resultados obtidos de cada algoritmo.

3.3. Considerações do capítulo

Neste capítulo, são detalhadas as especificações dos sistemas implementados, incluindo a simulação realizada por meio do software MATLAB/Simulink® e os testes experimentais conduzidos em laboratório. A modelagem de cada componente do sistema é discutida e as especificações do conversor CC-CC boost são apresentadas, o qual foi implementado em simulação por meio do método de espaço de estados médios. Além disso, a estratégia de estimação da corrente é desenvolvida por meio do equacionamento do próprio conversor. Vale destacar como contribuição da pesquisa proposta, o desenvolvimento e implementação de algoritmos que utilizam apenas um sensor de tensão, possibilitando a redução de custo e aumento de confiabilidade do sistema. Observa-se que o protótipo teve a inserção de um sensor de corrente para que seja possível avaliar os métodos com e sem sensor de corrente, assim comparando os resultados obtidos por meio de simulação e experimento, os quais são apresentados no capítulo 4.

4. Resultados e discussões

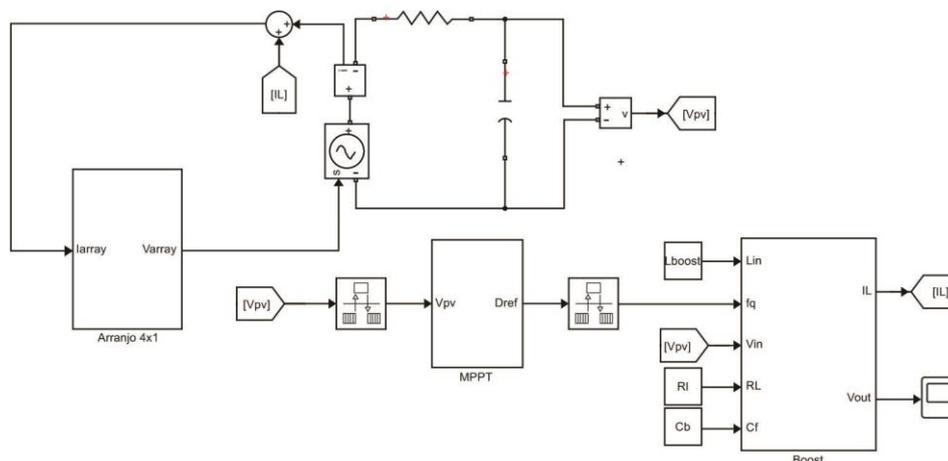
Neste capítulo serão apresentados os resultados das simulações digitais e dos experimentos laboratoriais, conduzidos por meio da implementação do protótipo, visando a avaliação das técnicas *sensorless* propostas neste trabalho.

Os resultados das simulações foram obtidos através da implementação do modelo no software MATLAB/Simulink®. Cada algoritmo foi desenvolvido utilizando ambas as técnicas, ou seja, convencional e *sensorless*. Dessa forma, será realizada uma avaliação por meio de métricas como tempo de busca pelo GMPP, oscilação de potência em estado estacionário, eficiência de rastreamento, além do fator de rastreamento de cada técnica. A mesma análise será realizada para os resultados experimentais, buscando tecer comparações entre as soluções.

4.1. Resultados de simulação

O modelo de simulação completo, desenvolvido no *software* MATLAB/Simulink®, é apresentado na Figura 21. O bloco “Arranjo 4x1” representa a formação de quatro módulos KC200GT conectados em série. O bloco “MPPT” integra os algoritmos implementados, a metodologia *sensorless* e o controle PI, que, por sua vez, é responsável por enviar o ciclo de trabalho ao conversor CC-CC boost, modelado via espaço de estados. Informações sobre a modelação do conversor boost em espaço de estados pode ser encontrado em [25].

Figura 21 — Simulação implementada no software MATLAB/Simulink®.



Fonte: Próprio autor.

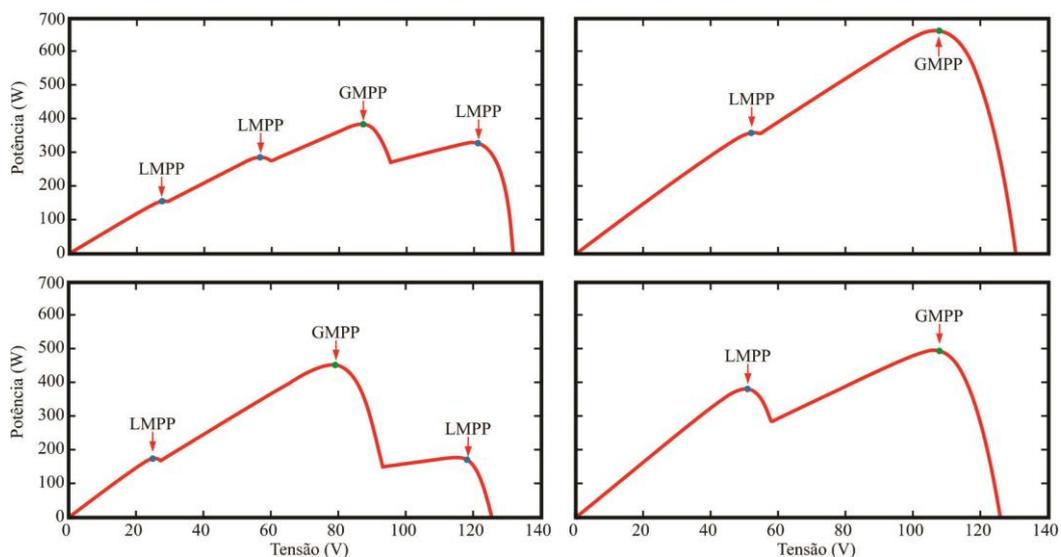
Tabela 2 — Perfis de potência avaliados na simulação

Irradiância (M1; M2; M3; M4) – (W/m ²)	Temperatura – (°C)	Potência esperada no GMPP (W)
750; 650; 580; 360	10	394,50
900; 800; 900; 800	25	665,20
200; 750; 750; 900	30	454,65
1000; 600; 1000; 600	35	499,20

Fonte: Próprio autor.

Nesse contexto, foram utilizados quatro perfis distintos de irradiância e temperatura com sombreamento parcial para avaliar as técnicas de MPPT. Cada perfil representa diferentes condições, abrangendo uma grande variedade de situações com sombreamento. Os valores utilizados de temperatura e irradiância são exibidos na Tabela 2, onde cada perfil será aplicado na simulação durante 10 segundos. Assim, a Figura 22 apresenta os perfis utilizados no estudo, sendo a primeira condição com três máximos locais e um máximo global. Nessa situação, cada módulo do arranjo recebe uma irradiância distinta levando a 4 pontos de máximo. Na segunda situação, o sombreamento é mais leve, com apenas um máximo local e um máximo global. O terceiro perfil avaliado possui dois máximos locais e um máximo global; neste, a diferença de potência entre os pontos locais e o global é considerável. Por fim, o último perfil aplicado no sistema é semelhante ao segundo, porém com o máximo local mais acentuado. Desse modo, todos os algoritmos apresentados anteriormente serão avaliados por meio deste sistema de simulação.

Figura 22 — Curvas de Potência x Tensão dos perfis avaliados.

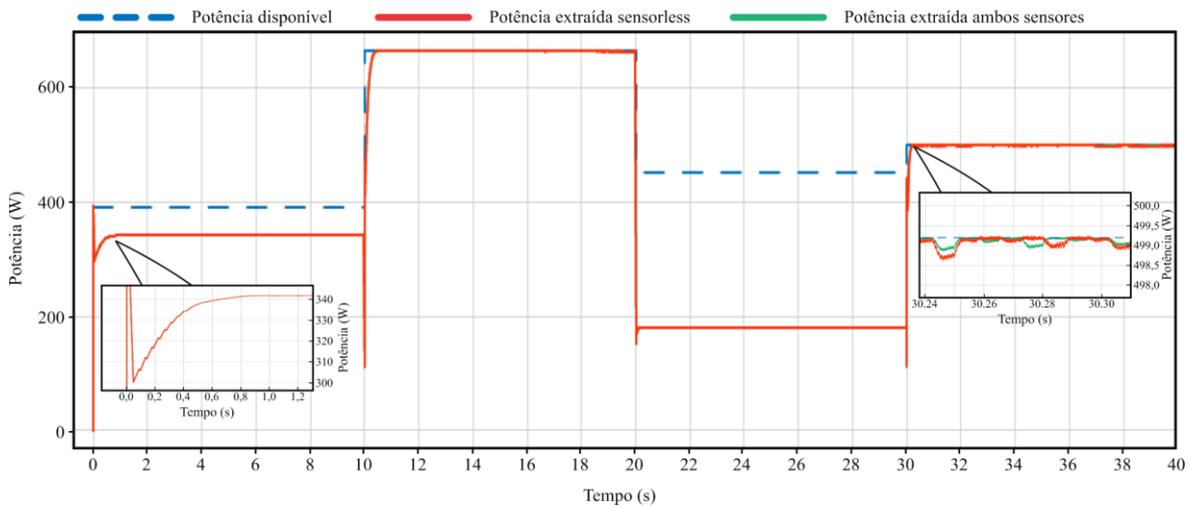


Fonte: Próprio autor.

4.1.1. Perturba e Observa (P&O)

Os resultados de simulação para o algoritmo P&O são exibidos na Figura 23. É válido salientar que o ponto inicial de operação é definido como 78% da tensão de circuito aberto do arranjo fotovoltaico (para ambos os algoritmos), considerando o fato de que para a condição atmosférica padrão, a tensão no MPP está entre 70% e 80% da tensão de circuito aberto [47].

Figura 23 — Potência extraída dos métodos P&O sensorless e P&O com ambos sensores.



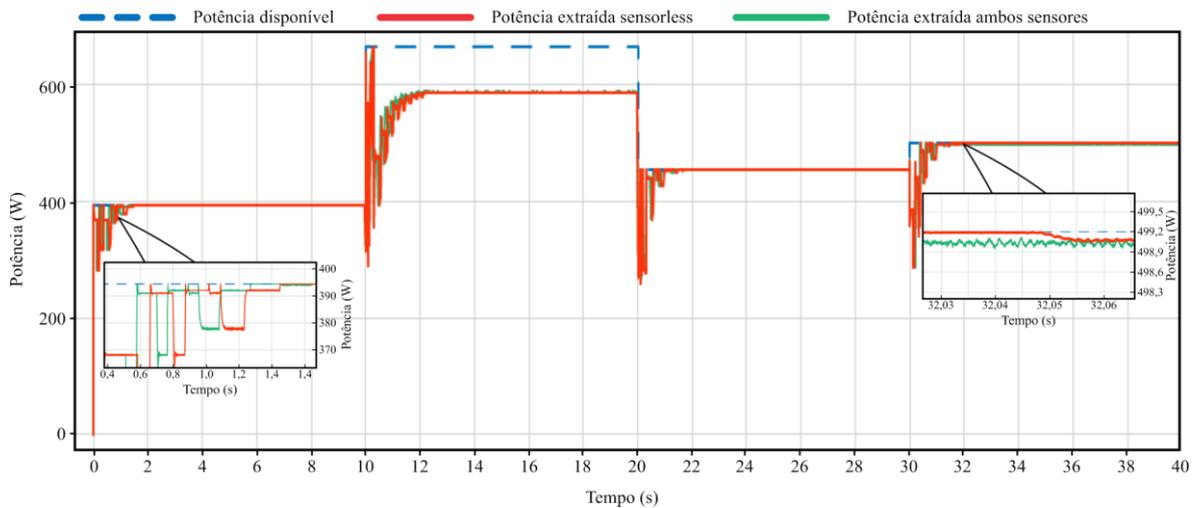
Fonte: Próprio autor.

Ainda na Figura 23 é possível observar que o método P&O, no primeiro e terceiro degraus convergiu para um máximo local, conforme esperado para uma abordagem convencional. Além disso, pelo detalhe exibido no quarto degrau, é possível observar um *ripple* de potência em torno de 0,7%. Para a simulação do algoritmo, utilizou-se de uma perturbação com passo variável. O valor do passo inicial é de 0,8 V e reduz 0,02 V a cada iteração até que o passo atinja 0,1 V e fique operando em torno do MPP. Além disso, o algoritmo monitora constantemente a diferença de potência da iteração atual com a iteração anterior; caso a diferença seja superior a um determinado valor de erro (*threshold*), o passo retorna para o valor inicial, caso contrário a perturbação é mantida em 0,1 V. O erro utilizado foi de 3% entre potências para o cálculo deste limiar. O FR, índice que mensura a quantidade de energia extraída em relação à quantidade de energia disponível, para os métodos com ambos sensores e sem sensor de corrente são respectivamente 83,69% e 83,67% e o tempo de busca pelo GMPP entre 0,2 e 0,8 segundos, considerando todos os degraus aplicados.

4.1.2. Otimização por Seção Áurea (GSO)

Os resultados de simulação para o algoritmo GSO são exibidos na Figura 24. Para isso, utilizou-se um intervalo inicial entre 10% e 90% da tensão de circuito aberto do arranjo fotovoltaico. Além disso, o critério de parada foi definido para quando o comprimento total do intervalo for menor que 1 V, o que ocorre em média após 10 iterações do algoritmo.

Figura 24 — Potência extraída dos métodos GSO sensorless e GSO com ambos sensores.



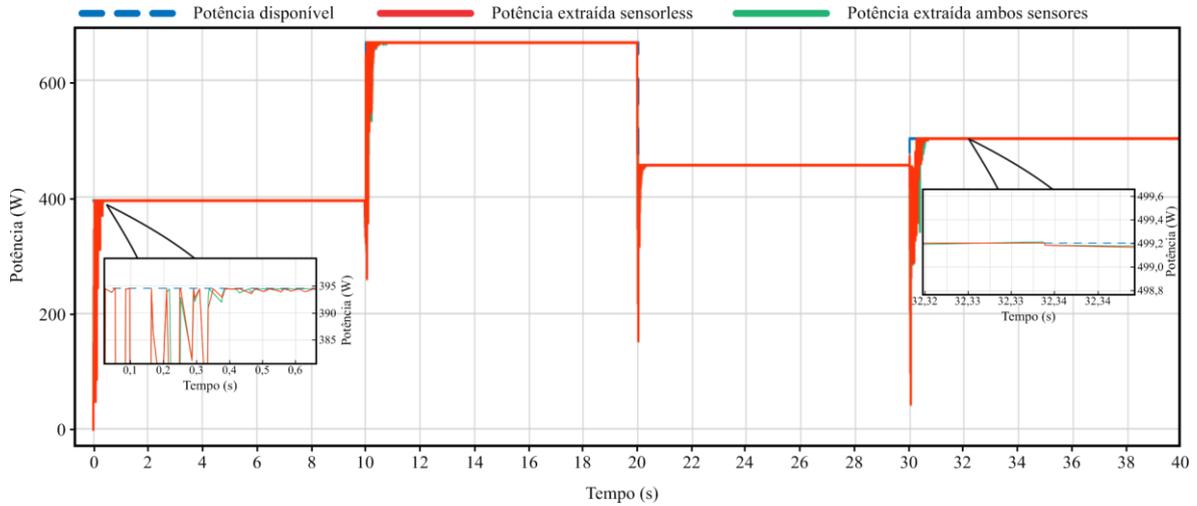
Fonte: Próprio autor.

Os FRs obtidos são de 94,99% e 94,87% para o algoritmo com ambos sensores e para o algoritmo sensorless, respectivamente. Além disso, um tempo de convergência entre 1,22 a 1,68 segundos, considerando todos os degraus aplicados, e um *ripple* de potência em torno de 0,15%. Ainda na Figura 24 é possível observar, no segundo perfil aplicado, que ao invés de convergir para um ponto máximo, o algoritmo encontra um ponto entre o LMPP e GMPP, isso se deve ao fato de que o método não avalia, por definição, alguns subintervalos dentro do intervalo em análise. Ainda assim, o algoritmo conseguiu encontrar três dos quatro GMPP, obtendo um FR superior ao do método P&O.

4.1.3. Otimização por enxame de partículas (PSO)

Os resultados de simulação para o algoritmo PSO são exibidos na Figura 25. Aqui foi definido uma população de 5 partículas, com o número limite de iterações igual a 25. Além disso, utilizou-se das equações (43), (44) e (45) para controlar os parâmetros do algoritmo de forma acompanhem o número de iterações do algoritmo. Conforme proposto por [48] esta abordagem auxilia na convergência do método.

Figura 25 — Potência extraída dos métodos PSO sensorless e PSO com ambos sensores.



Fonte: Próprio autor.

$$c_1 = c_{1,max} - (c_{1,max} - c_{1,min}) \cdot \left(\frac{k}{k_{max}} \right) \quad (43)$$

$$c_2 = c_{2,min} + (c_{2,max} - c_{2,min}) \cdot \left(\frac{k}{k_{max}} \right) \quad (44)$$

$$\omega = \omega_{max} - (\omega_{max} - \omega_{min}) \cdot \left(\frac{k}{k_{max}} \right) \quad (45)$$

A Tabela 3 apresenta os coeficientes máximos e mínimos utilizados nas equações (43) à (45). Observa-se que ao se iniciar com valores elevados para o peso de inércia ω e para a constante c_1 , cada partícula consegue ter maior liberdade individual e assim varrer com maior aleatoriedade os pontos dentro do espaço de busca; por outro lado, ao reduzir esses valores, é possível refinar o ponto de operação, já que os passos são menores. Enquanto isso, a constante c_2 , relacionada à melhor posição global, inicia pequena e soma-se um valor a cada iteração, auxiliando o algoritmo na convergência de toda a população para o GMPP.

Tabela 3 — Coeficientes utilizados na simulação para o algoritmo PSO

Parâmetros	Valores
$c_{1,max}$	2,2
$c_{1,min}$	0,6
$c_{2,max}$	2,2
$c_{2,min}$	0,45
ω_{max}	0,55
ω_{min}	0,25

Fonte: Próprio autor.

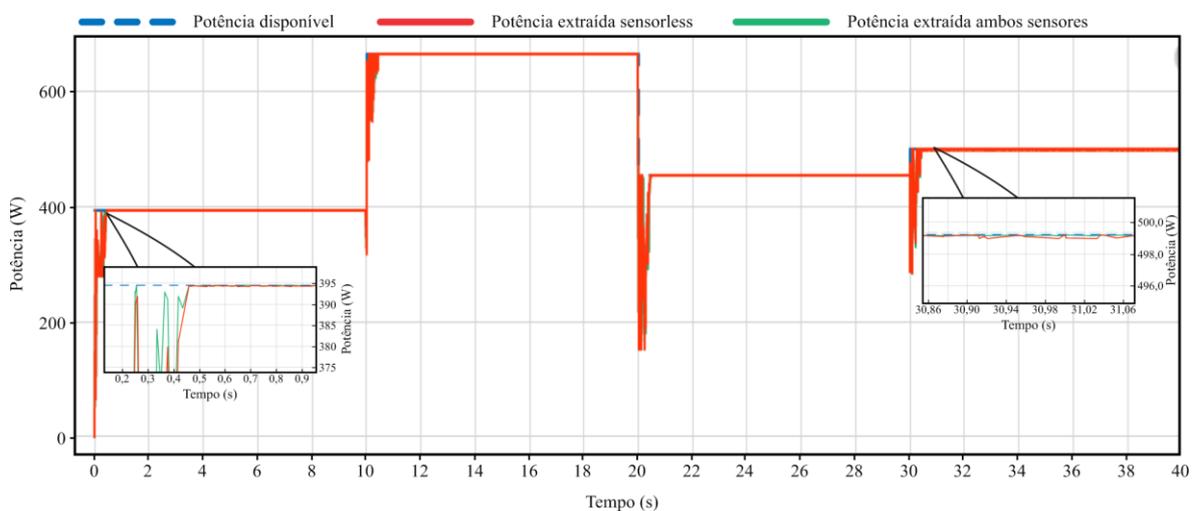
Ainda na Figura 25 é possível observar que os dois algoritmos, PSO com ambos sensores e PSO sensorless, encontraram o GMPP em todos os perfis avaliados. OS FRs são respectivamente de 99,56% e 99,55% e tempo de convergência entre 0,38 e 0,70 segundos, considerando todos os degraus aplicados. Além de um *ripple* de potência menor que 0,1%.

4.1.4. Otimização por lobos cinzentos (GWO)

Os resultados de simulação para o algoritmo GWO são exibidos na Figura 26. A matilha escolhida é composta por 4 lobos e o número limite de iterações é igual a 25. Observa-se que, na metodologia utilizada pelo algoritmo, a nova posição de cada lobo é dada pela média das posições dos lobos que ditam o movimento da matilha. Em [49], utiliza-se de pesos diferentes para cada lobo, conforme mostra a equação (46). Assim é possível atribuir a devida consideração para os lobos, seguindo a cadeia de comando, o que auxilia o algoritmo de MPPT a extrair uma maior potência.

$$X_{wolf}(k + 1) = \frac{X_{wolf,\alpha}}{2} + \frac{X_{wolf,\beta}}{3} + \frac{X_{wolf,\delta}}{6} \quad (46)$$

Figura 26 — Potência extraída dos métodos GWO sensorless e GWO com ambos sensores.



Fonte: Próprio autor.

Ainda na Figura 26 é possível observar que os dois algoritmos, GWO com ambos sensores e GWO sensorless, encontraram o GMPP em todos perfis avaliados. OS FRs encontrados são iguais a 99,27%, o tempo de convergência em torno de 0,50 segundos, considerando todos os degraus aplicados, e o *ripple* de potência em regime permanente menor que 0,15%.

4.1.5. Otimização por Vagalumes (FA)

A Figura 27 apresenta os resultados de simulação para o algoritmo Vagalumes. A população é composta por 3 vagalumes e o número limite de iterações é igual a 5. Semelhante à técnica utilizada no algoritmo PSO, em [50] é proposto utilizar os valores dos coeficientes do algoritmo em função do número de iterações, conforme mostram as equações (47) e (48). A Tabela 4 mostra os coeficientes máximos e mínimos adotados.

$$\alpha = \alpha_{max} + (\alpha_{min} - \alpha_{max}) \cdot \left(\frac{k}{k_{max}}\right) \quad (47)$$

$$\beta_0 = \beta_{0,max} + (\beta_{0,min} - \beta_{0,max}) \cdot \left(\frac{k}{k_{max}}\right) \quad (48)$$

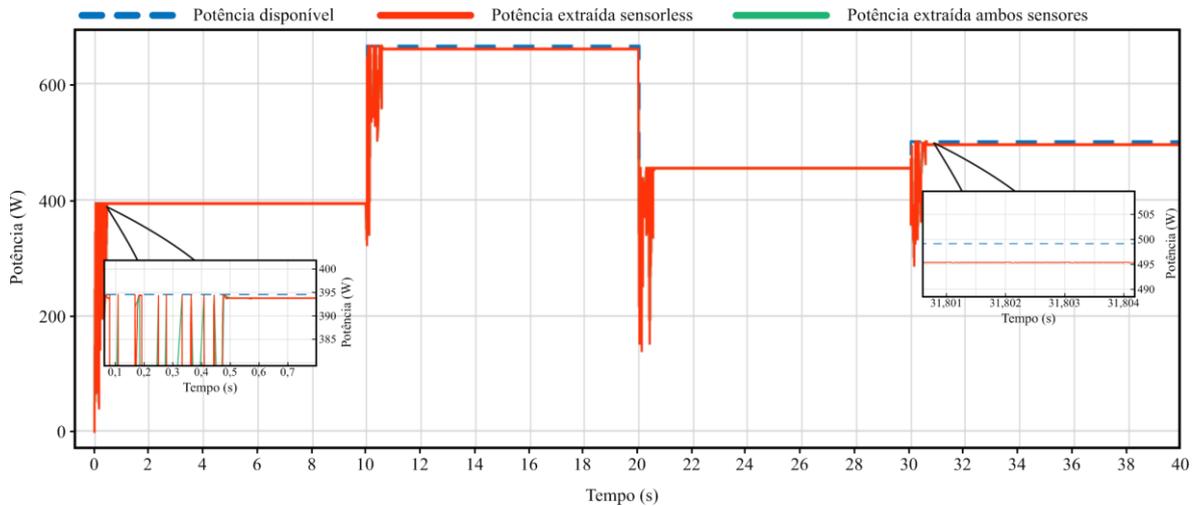
Tabela 4 — Coeficientes utilizados na simulação para o algoritmo FA

Parâmetros	Valores
$\beta_{0,max}$	2,50
$\beta_{0,min}$	1,45
α_{max}	0,58
α_{min}	0,21

Fonte: Próprio autor.

Observa-se que α controla a randomização do algoritmo em busca do GMPP. Nesse sentido, pequenos valores podem ocasionar no aprisionamento do algoritmo em um LMPP, visto que a busca dificilmente saíra do entorno do vagalume. Enquanto isso, altos valores para α auxiliam o algoritmo a percorrer todo o espaço de busca, entretanto acaba aumentando o tempo de convergência. Além disso, a redução de β_0 aumenta a velocidade de convergência, uma vez que a dispersão de luz dos vagalumes é reduzida, ajudando o movimento de um vagalume em direção a outro [50].

Figura 27 — Potência extraída dos métodos FA sensorless e FA com ambos sensores.



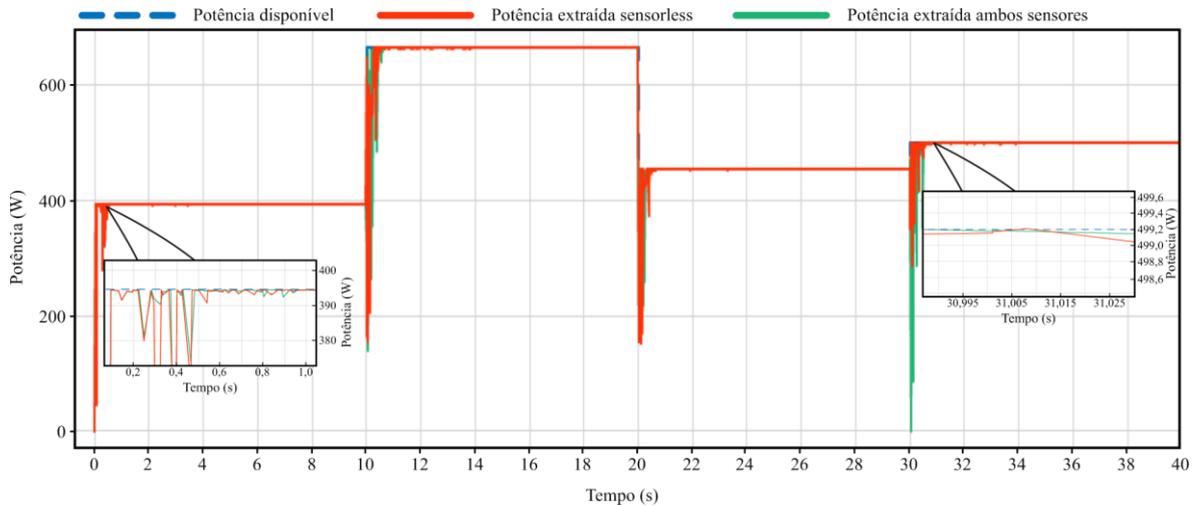
Fonte: Próprio autor.

Ainda na Figura 27 foi possível identificar que o GMPP foi encontrado em todos os perfis analisados, embora nota-se que para o segundo e último perfil aplicado, o algoritmo não conseguiu rastrear com precisão os pontos, ocasionando em uma perda considerável de energia disponível. O tempo de convergência observado está entre 0,50 e 0,60 segundos, considerando todos os degraus aplicados, e o *ripple* de potência em regime permanente menor que 0,1%. Outro ponto que deve ser destacado é que ambos algoritmos obtiveram respostas semelhantes, com FRs de 98,74% e 98,69% respectivamente para os algoritmos com ambos sensores e sem sensor de corrente.

4.1.6. Otimização por Morcegos (BAT)

Os resultados de simulação para o algoritmo BAT são exibidos na Figura 28. A população é composta por 5 morcegos e o número limite de iterações é igual a 50. Além disso, as frequências mínima e máxima são 0 e 1, respectivamente. A constante de redução de volume α foi definida como 0,9. Quanto à taxa de pulso, a constante γ é estabelecida em 0,6 e o valor de r_i^0 é mantido como 1.

Figura 28 — Potência extraída dos métodos BAT sensorless e BAT com ambos sensores.



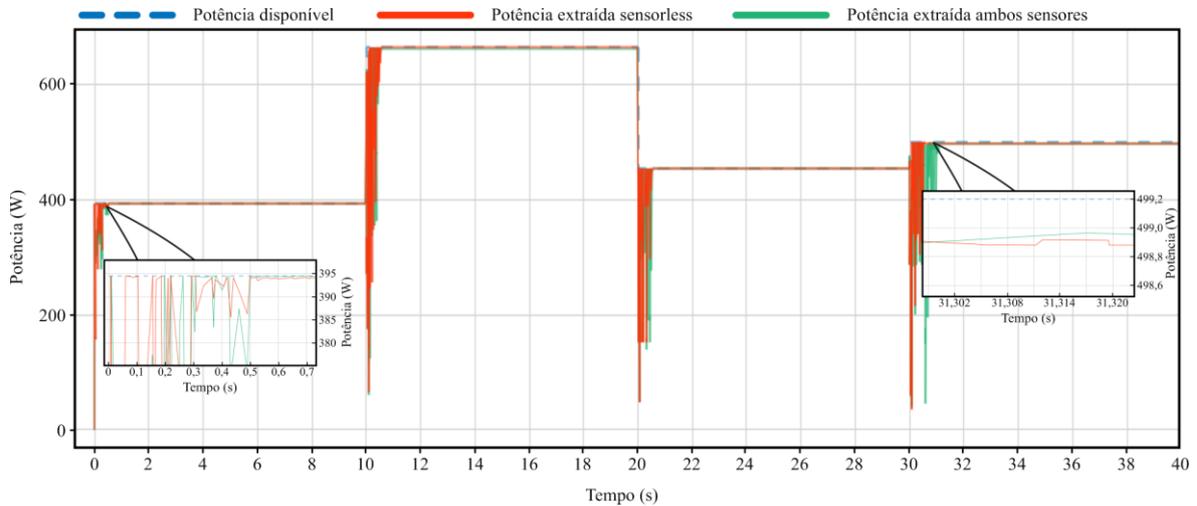
Fonte: Próprio autor.

O algoritmo demonstrou boa resposta durante a avaliação. Na Figura 28 foi possível identificar que o GMPP foi encontrado em todos os perfis analisados. Além disso, ao analisar detalhadamente o primeiro degrau, constata-se um tempo de convergência menor que 0,6 segundos. No último perfil, ao verificar o detalhe na resposta de regime permanente, observa-se um *ripple* de potência inferior a 0,1 %. Outro ponto que deve ser destacado é que ambos algoritmos obtiveram respostas semelhantes, com FRs de 99,42% e 99,39%, respectivamente para os algoritmos com ambos sensores e sem sensor de corrente.

4.1.7. Otimização por Busca Cuco (CS)

Os resultados de simulação para o algoritmo CS são exibidos na Figura 29. A escolhida população é composta por 4 cucos e o número limite de iterações é igual a 20. Além disso, β é utilizado como 1,5 e K igual a 0,08.

Figura 29 — Potência extraída dos métodos CS sensorless e CS com ambos sensores.



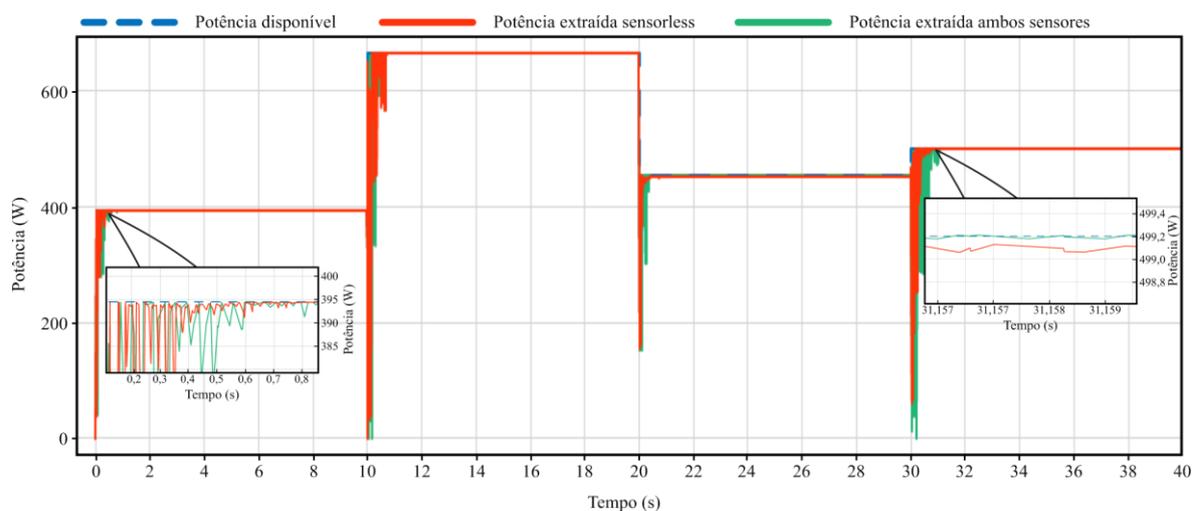
Fonte: Próprio autor.

O algoritmo demonstrou boa resposta durante a avaliação. Na Figura 29 foi possível identificar que o GMPP foi encontrado em todos os perfis analisados. Além disso, ao analisar detalhadamente o primeiro degrau, constata-se um tempo de convergência em torno de 0,50 segundos. No último perfil, ao verificar o detalhe na resposta de regime permanente, observa-se um *ripple* de potência inferior a 0,1%. Outro ponto que deve ser destacado é que ambos algoritmos obtiveram respostas semelhantes, exceto para o último degrau, em que o tempo de busca pelo GMPP do algoritmo com sensor de corrente, foi maior que do algoritmo sensorless. Os FRs encontrados foram de 98,90% e 99,21%, respectivamente para os algoritmos com ambos sensores e sem sensor de corrente.

4.1.8. Otimização por Colônia de Abelhas (ABC)

Os resultados de simulação para o algoritmo ABC são exibidos na Figura 30. A população é composta por 3 abelhas e o número limite de iterações é igual a 25. Além disso, o limite de falhas está limitado a 4, o seja, se uma abelha empregada não conseguir uma melhor posição em até 4 atualizações de posição, a abelha batedora irá definir uma nova posição para a empregada.

Figura 30 — Potência extraída dos métodos ABC sensorless e ABC com ambos sensores.



Fonte: Próprio autor.

O algoritmo demonstrou boa resposta durante a avaliação. Na Figura 30 foi possível identificar que o GMPP foi encontrado em todos os perfis aplicados. Além disso, ao avaliar detalhadamente o primeiro degrau, constata-se um tempo de convergência menor que 0,8 segundos. No último perfil, ao verificar o detalhe na resposta em regime permanente, observa-se um *ripple* de potência inferior a 0,1% para o algoritmo sensorless e praticamente nulo para o algoritmo com ambos sensores, embora nota-se que neste perfil o tempo de convergência foi menor para a primeira técnica. Outro ponto que deve ser destacado é que ambos algoritmos obtiveram respostas semelhantes, com FRs de 99,09% e 99,13%, respectivamente para os algoritmos com ambos sensores e sem sensor de corrente.

4.2. Comparação dos resultados de simulação

Com o propósito de facilitar a comparação e a seleção do algoritmo mais apropriado para cada aplicação específica, a Tabela 5 proporciona uma análise concisa das técnicas avaliadas, permitindo uma visão geral das suas principais características e desempenho de acordo com os perfis de irradiação e temperatura avaliados. Para isso, critérios como tempo de busca pelo GMPP, oscilação de potência em estado estacionário, eficiência de rastreamento e FR são inseridos. Cada métrica é detalhada na sequência [29,51]:

1. **Tempo de busca pelo GMPP:** É o tempo que o algoritmo leva para localizar o GMPP. Está diretamente ligado à velocidade e eficiência do método, uma vez que quanto maior o tempo de busca, menor será o FR.

2. **Oscilação de potência em estado estacionário:** É calculado a partir da amplitude das oscilações que ocorrem após o sistema encontrar o GMPP.
3. **Eficiência de rastreamento:** É quantificado a partir da proporção da energia obtida em relação à energia disponível em regime estacionário, diretamente relacionado à precisão do método.
4. **FR (Fator de Rastreamento):** Relação entre a energia útil extraída e a energia disponível, o que indica a eficiência geral do sistema.

Nesse sentido, observa-se que quanto maior o tempo em que um perfil de irradiância e temperatura é aplicado, menor é a influência do tempo de busca no cálculo de FR e assim, em estado estacionário, o coeficiente tende à eficiência de rastreamento, que está ligada ao quão perto do GMPP está a operação do sistema.

Uma análise dos algoritmos de MPPT é apresentada na Tabela 5. Pôde-se verificar como destaque os métodos PSO e BAT que obtiveram os maiores FRs, sendo o método PSO, o que consegue extrair maior quantidade de energia do sistema fotovoltaico. Os métodos sensorless propostos conseguiram manter a potência extraída bem próxima dos métodos que utilizam de ambos sensores, com uma diferença menor que 0,05%, exceto para o método GSO que teve uma diferença de 0,12%. Observa-se também que para o método CS, a técnica sensorless obteve uma eficiência 0,31% superior em relação ao método com ambos sensores.

Tabela 5 — Avaliação dos resultados de simulação

Caso	Tempo de busca pelo GMPP (s)				Oscilação de potência em estado estacionário (%)				Eficiência de rastreamento (%)				FR (%)
	1	2	3	4	1	2	3	4	1	2	3	4	Global
P&O	-	0,50	-	0,20	0,10	0,10	0,20	0,70	87,22	100	32,72	100	83,69
P&O Sensorless	-	0,50	-	0,20	0,10	0,10	0,20	0,70	87,22	100	32,72	100	83,67
GSO	1,22	-	1,50	1,50	0,15	0,17	0,20	0,15	99,87	88,27	100	100	94,99
GSO Sensorless	1,43	-	1,68	1,65	0,15	0,17	0,10	0,15	99,87	88,27	100	100	94,87
PSO	0,38	0,50	0,34	0,66	0,05	0,03	0,10	0,02	100	100	100	100	99,56
PSO Sensorless	0,38	0,50	0,34	0,70	0,05	0,03	0,10	0,02	100	100	100	100	99,55
GWO	0,46	0,52	0,50	0,45	0,05	0,05	0,10	0,02	100	99,90	99,90	100	99,27
GWO Sensorless	0,46	0,52	0,50	0,45	0,10	0,10	0,15	0,02	100	99,90	99,90	100	99,27
FA	0,51	0,55	0,60	0,60	0,03	0,07	0,01	0,03	100	99,39	100	99,25	98,74
FA Sensorless	0,51	0,55	0,60	0,60	0,03	0,07	0,01	0,03	100	99,39	100	99,25	98,69
BAT	0,50	0,70	0,43	0,80	0,05	0,10	0,10	0,02	100	100	100	100	99,42
BAT Sensorless	0,50	0,70	0,45	0,75	0,05	0,10	0,10	0,03	100	100	100	100	99,39
CS	0,50	0,53	0,55	1,10	0,03	0,01	0,01	0,01	100	99,66	99,93	99,97	98,90
CS Sensorless	0,50	0,55	0,55	0,52	0,01	0,02	0,02	0,01	99,87	100	100	99,95	99,21
ABC	0,80	0,75	0,35	1,05	0,02	0,10	0,02	0,01	100	100	100	100	99,09
ABC Sensorless	0,78	0,75	0,40	0,77	0,02	0,10	0,02	0,01	100	100	99,56	100	99,13

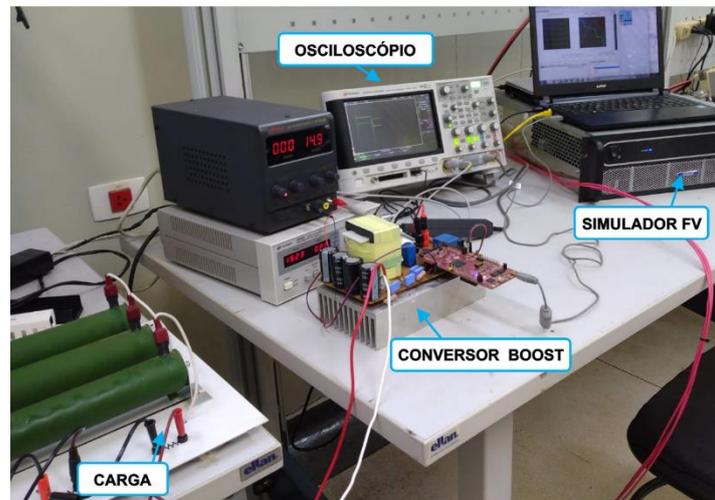
(-) GMPP não encontrado.

Fonte: Próprio autor.

4.3. Resultados experimentais

Os resultados experimentais foram alcançados por meio da implementação laboratorial do sistema mostrado na Figura 31. O TerraSAS é configurado com o mesmo arranjo fotovoltaico da simulação e então é conectado ao conversor CC-CC boost. O osciloscópio é empregado para obter as curvas de potência, corrente e tensão do sistema, enquanto o rastreamento do GMPP é monitorado pelo *software* do simulador fotovoltaico, utilizando um computador portátil.

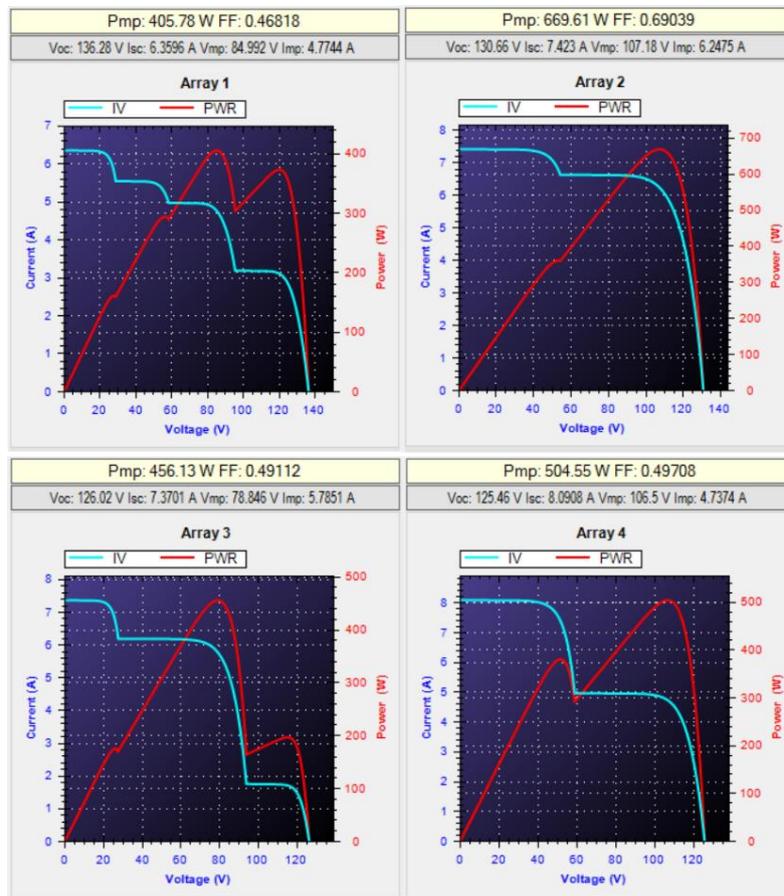
Figura 31 — Bancada experimental.



Fonte: Próprio autor.

Na Figura 32 são apresentadas as formas de ondas obtidas a partir dos perfis utilizados. Aqui foram utilizados os mesmos perfis que na simulação. Nesse sentido, observa-se que a quantidade de pontos locais e globais são idênticos aos perfis da simulação. Entretanto, o fato de que o software do equipamento utiliza de um modelo linearizado para a formulação das curvas, as potências esperadas são levemente diferentes das obtidas no *software* MATLAB/Simulink®, conforme mostrado no topo de cada perfil, como (Pmp). Desse modo, por meio do sistema apresentado, os algoritmos de MPPT também serão avaliados a seguir, comparando as técnicas que utilizam de ambos sensores com as técnicas *sensorless*.

Figura 32 — Curvas de Potência vs Tensão e Corrente vs Tensão dos perfis avaliadas por meio do simulador de arranjos fotovoltaicos.

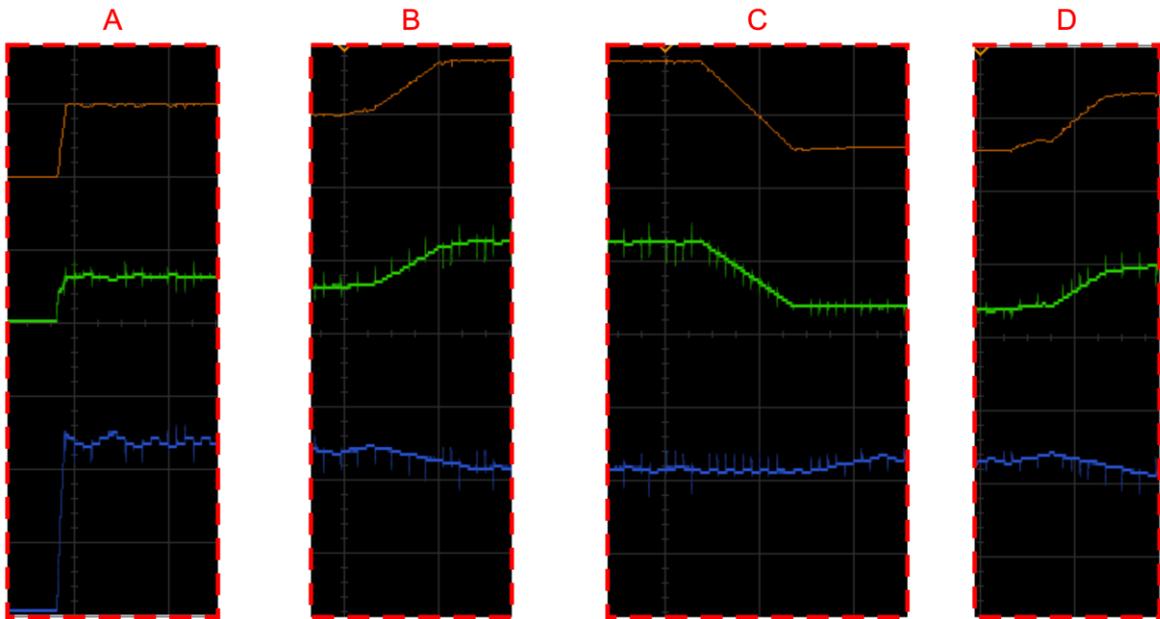
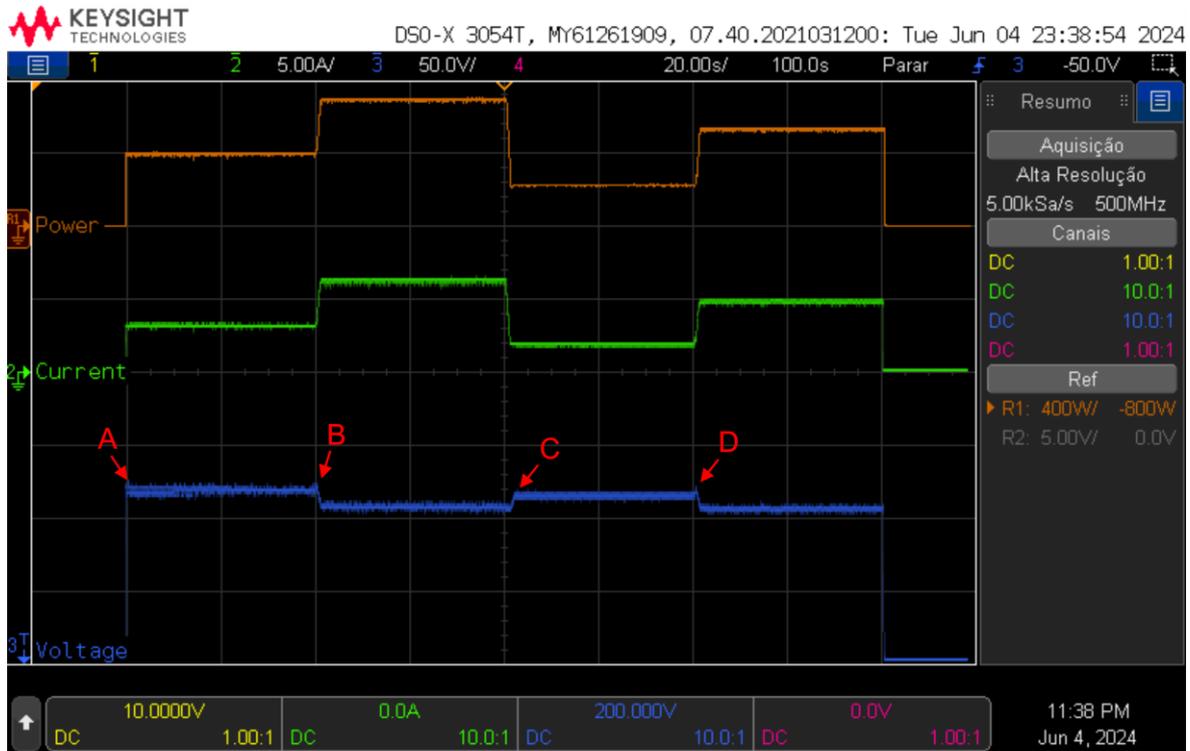


Fonte: Próprio autor.

4.3.1. Perturba e Observa (P&O)

Os resultados experimentais para o algoritmo P&O são exibidos nas Figuras 33 e 34 para os métodos convencional e *sensorless*, respectivamente. Semelhante à metodologia utilizada durante a simulação, aqui o ponto inicial de operação também é definido como 78% da tensão de circuito aberto do arranjo fotovoltaico. A curva em verde representa a corrente do arranjo com escala de 5 A/div; a curva em azul representando a tensão do arranjo em escala 50 V/div. Em laranja, a potência extraída, escala de 400 W/div. A escala de tempo é de 20s/div para a simulação completa e 1s/div para os detalhes das formas de onda (*zoom*).

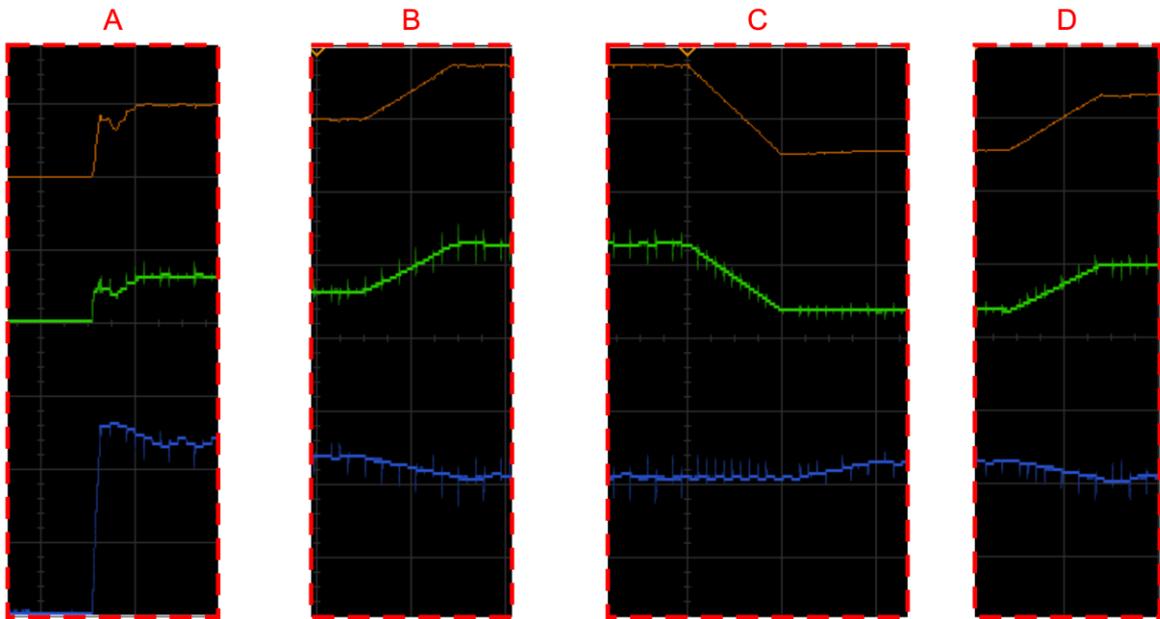
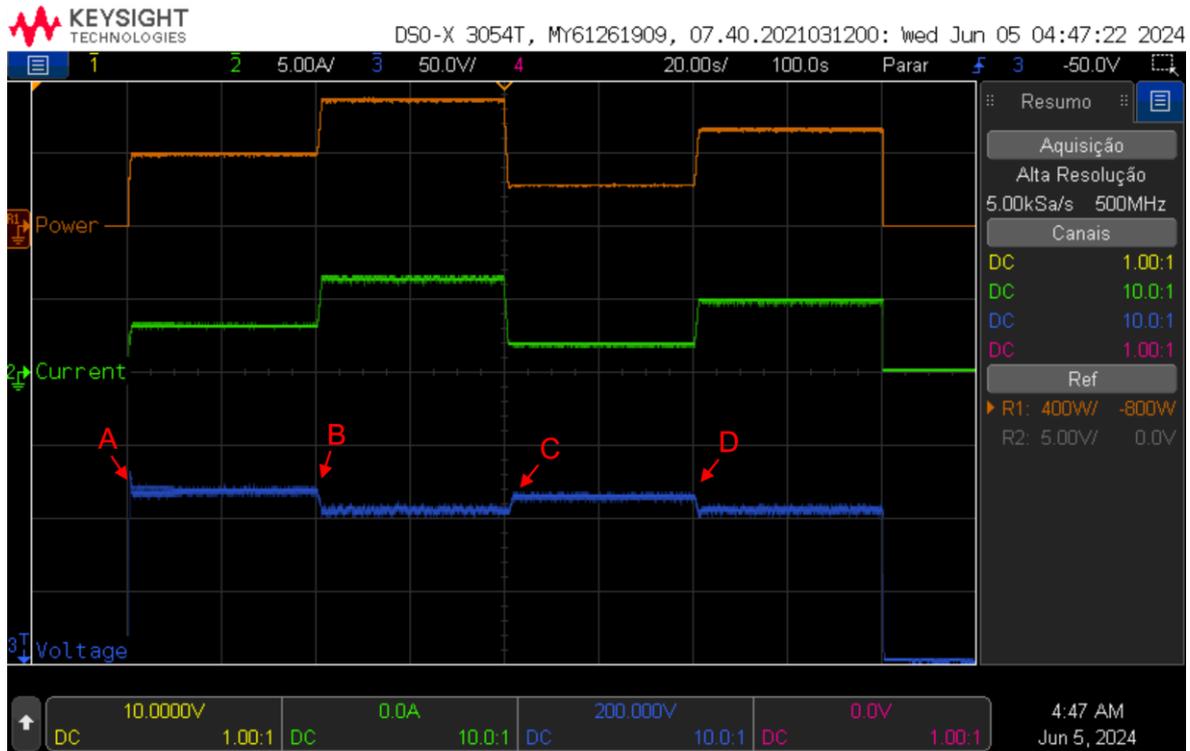
Figura 33 — Resposta do método P&O convencional.



Em laranja: Potência (400W/div); Em verde: Corrente (5A/div); Em azul: Tensão (50V/div). A, B, C e D se referem aos detalhes das formas de onda.

Fonte: Próprio autor.

Figura 34 — Resposta do método P&O sensorless.



Em laranja: Potência (400W/div); Em verde: Corrente (5A/div); Em azul: Tensão (50V/div). A, B, C e D se referem aos detalhes das formas de onda

Fonte: Próprio autor.

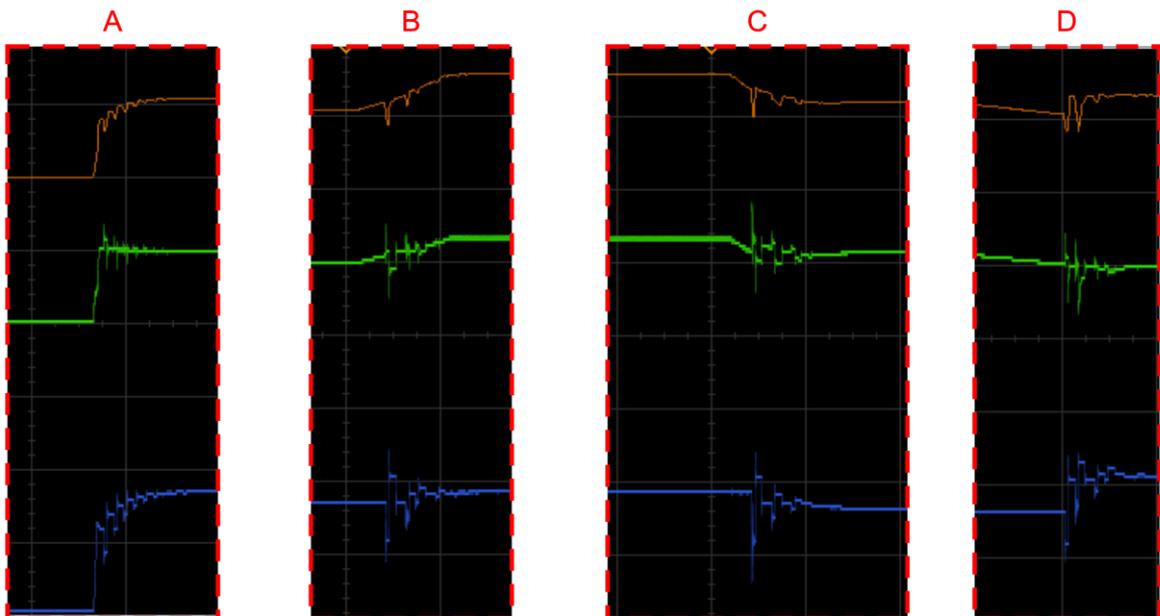
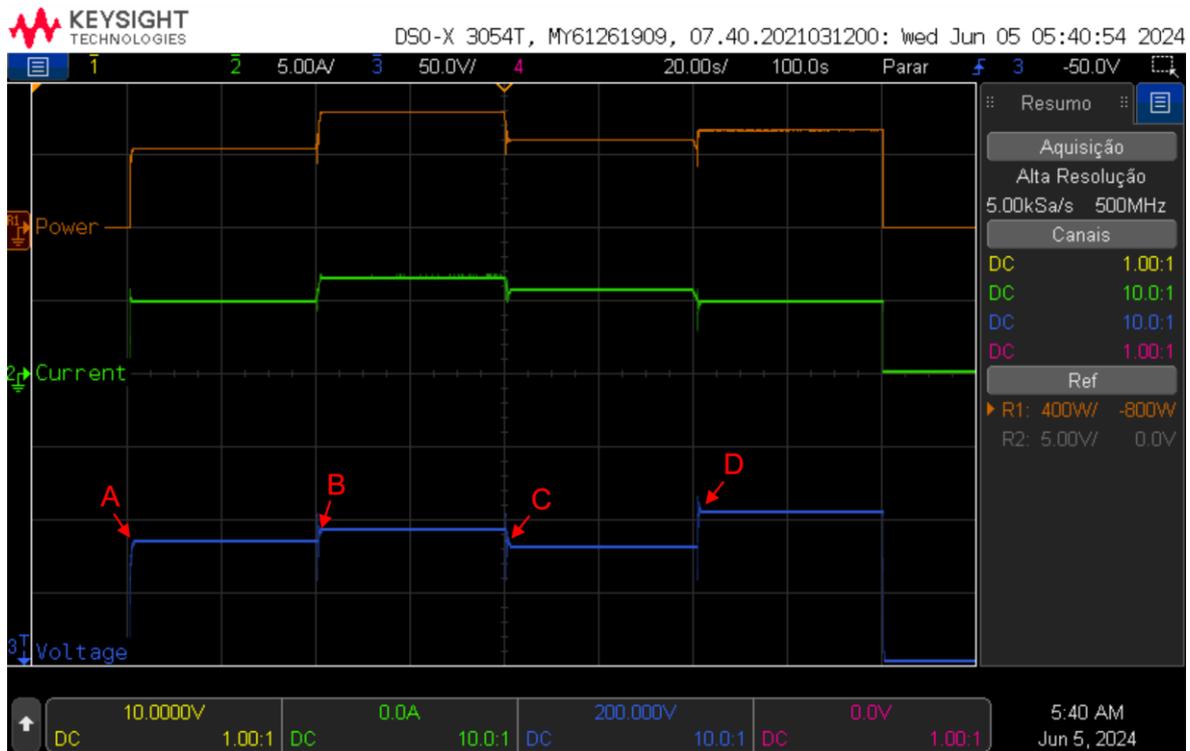
Observa-se que para ambos os casos, no primeiro e terceiro degraus, os métodos localizaram um LMPP, semelhante à simulação. Durante o experimento, a perturbação de passo variável inicia com 2,8 V e reduz 0,05 V em cada iteração até que o passo atinja 1 V e fique operando em torno do MPP. Nota-se que perturbações menores que 1 V, para o experimento, trouxeram dificuldades de precisão de leitura do sistema, fazendo o algoritmo errar a direção da perturbação. Além disso, da mesma forma que a simulação, é monitorado constantemente a diferença de potência da iteração atual com a iteração anterior; caso a diferença seja superior a um determinado erro, o passo retorna para o valor inicial, caso contrário a perturbação é mantida em 1 V. O limiar de erro utilizado foi de 3% entre uma potência e outra. O FR para os métodos com ambos sensores e sem sensor de corrente são respectivamente 84,56% e 84,34% e o tempo de busca pelo GMPP entre 0,50 e 1,10 segundos, para todos os degraus aplicados.

4.3.2 Otimização por Seção Áurea (GSO)

Os resultados experimentais para o algoritmo GSO são exibidos nas Figuras 35 e 36 para os métodos convencional e sensorless, respectivamente, as escalas do osciloscópio são as mesmas utilizadas em todas os experimentos. Da mesma forma que a simulação, o intervalo inicial foi definido entre 10% e 90% da tensão de circuito aberto do arranjo fotovoltaico e o critério de parada foi definido para quando o comprimento total do intervalo for menor que 1 V.

Os FRs obtidos são 96,30% e 96,83% respectivamente para o algoritmo com ambos sensores e para o algoritmo sensorless, ligeiramente superior que os resultados obtidos em simulação. Além disso, considerando todos os degraus aplicados, um tempo de busca pelo GMPP menor que 1,30 segundos e um *ripple* de potência menor que 0,50% foi verificado. Observa-se também que semelhante à simulação, ao aplicar o segundo perfil no experimento, o algoritmo convergiu para um ponto entre o LMPP e o GMPP.

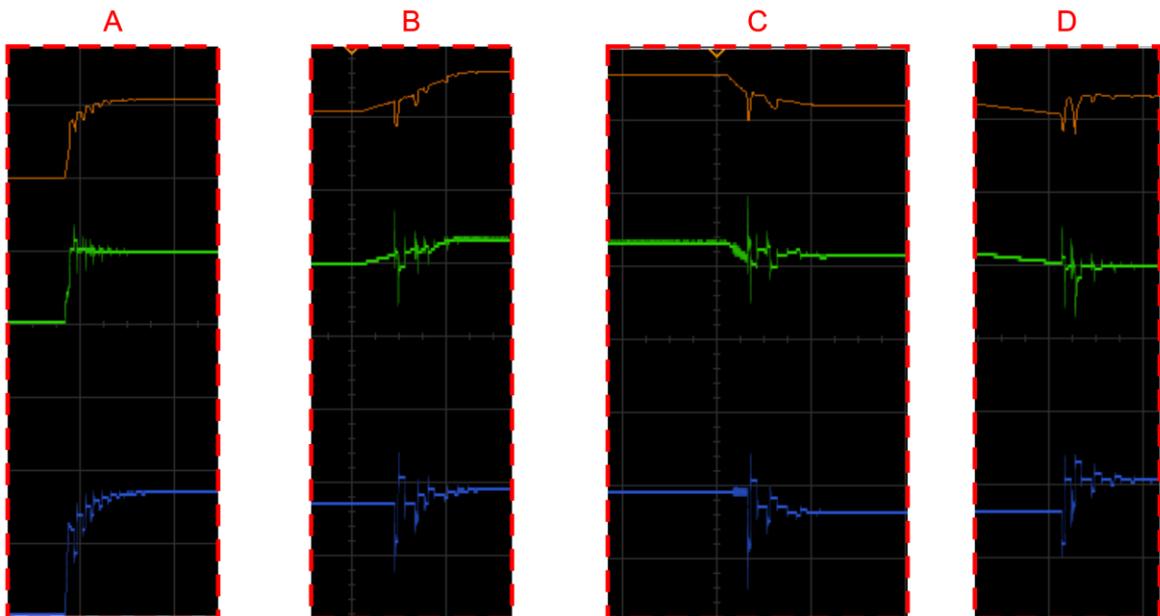
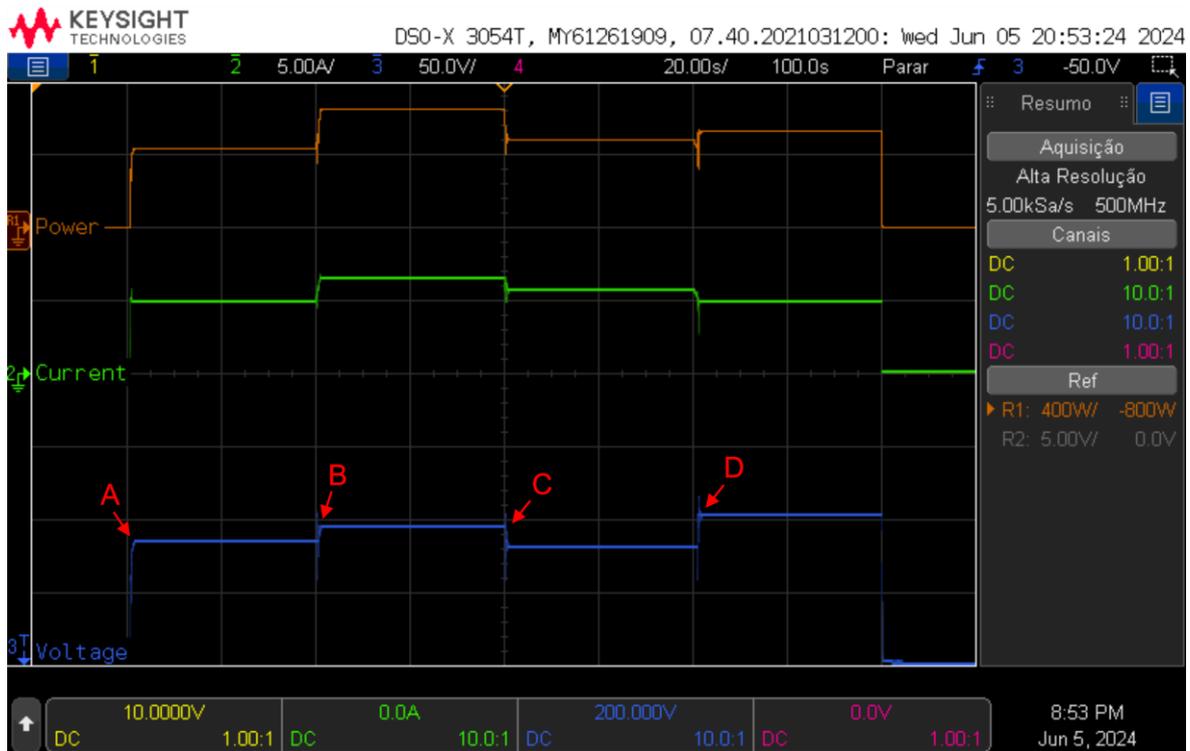
Figura 35 — Resultados do método GSO convencional.



Em laranja: Potência (400W/div); Em verde: Corrente (5A/div); Em azul: Tensão (50V/div). A, B, C e D se referem aos detalhes das formas de onda.

Fonte: Próprio autor.

Figura 36 — Resultados do método GSO sensorless.



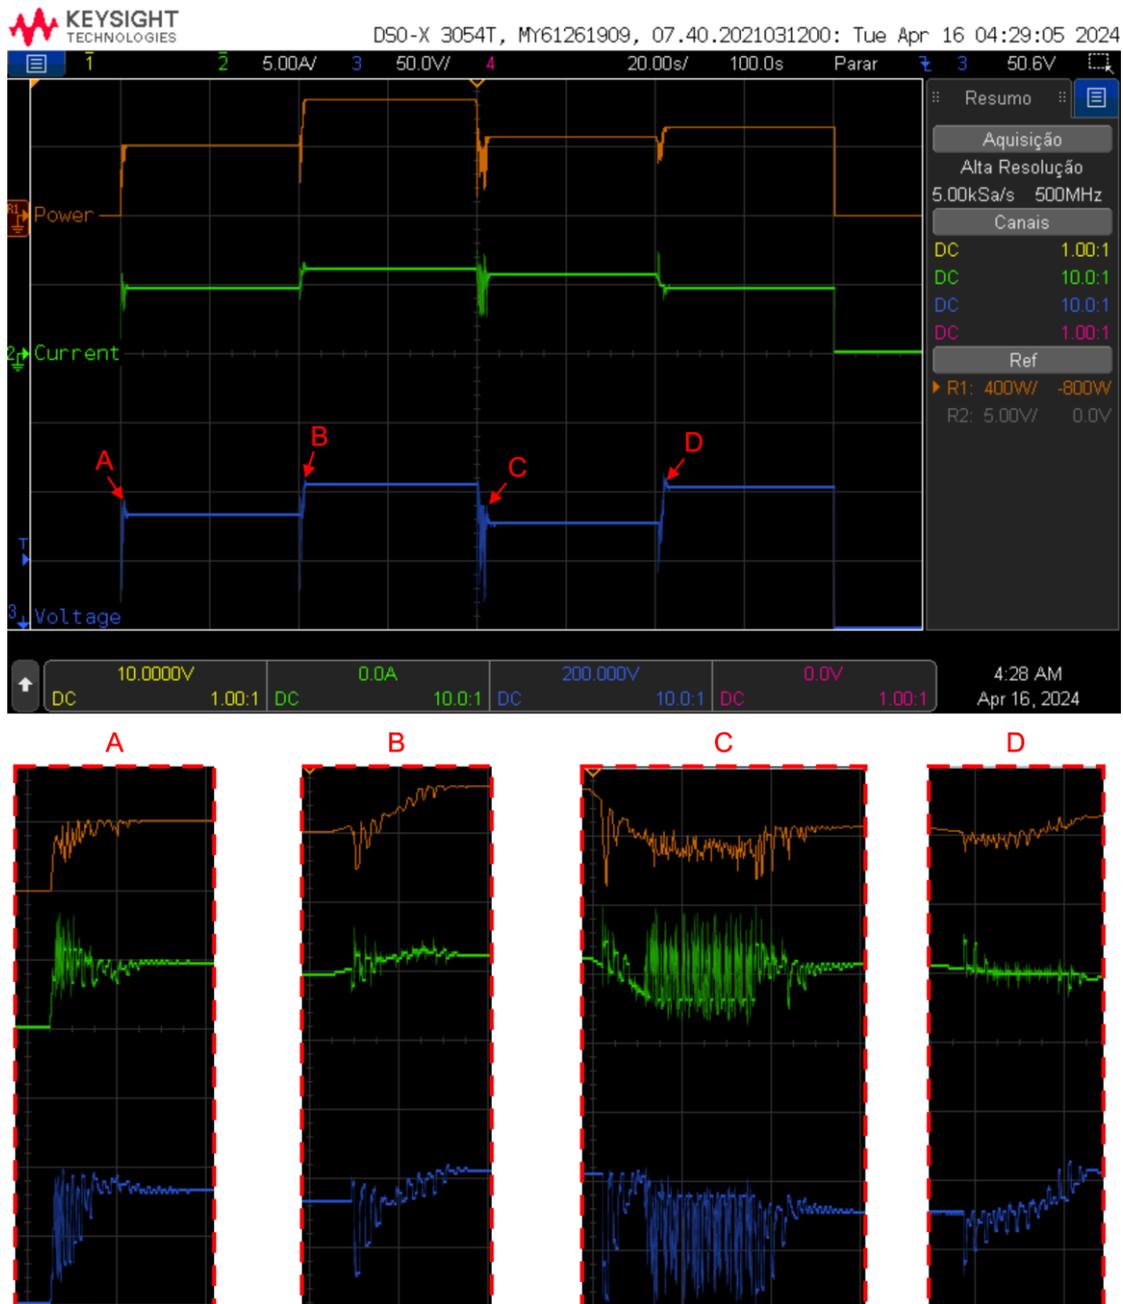
Em laranja: Potência (400W/div); Em verde: Corrente (5A/div); Em azul: Tensão (50V/div). A, B, C e D se referem aos detalhes das formas de onda.

Fonte: Próprio autor.

4.3.3. Otimização por enxame de partículas (PSO)

Os resultados experimentais para o algoritmo PSO são exibidos nas Figuras 37 e 38 para os métodos convencional e *sensorless*, respectivamente. Aqui foi definido uma população de 4 partículas, com o número limite de iterações igual a 20.

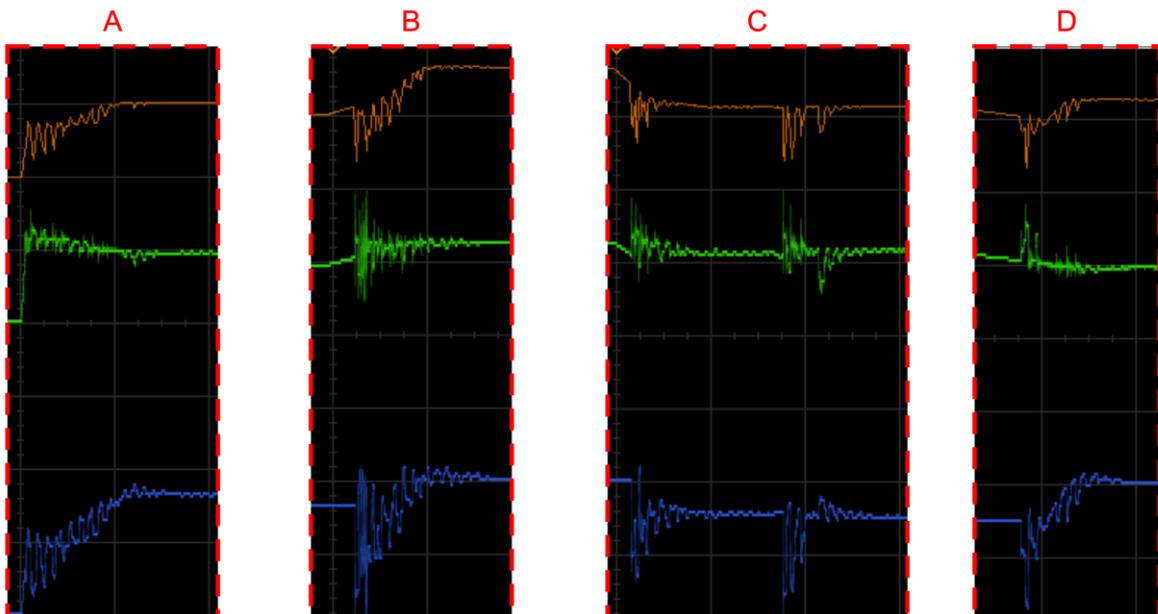
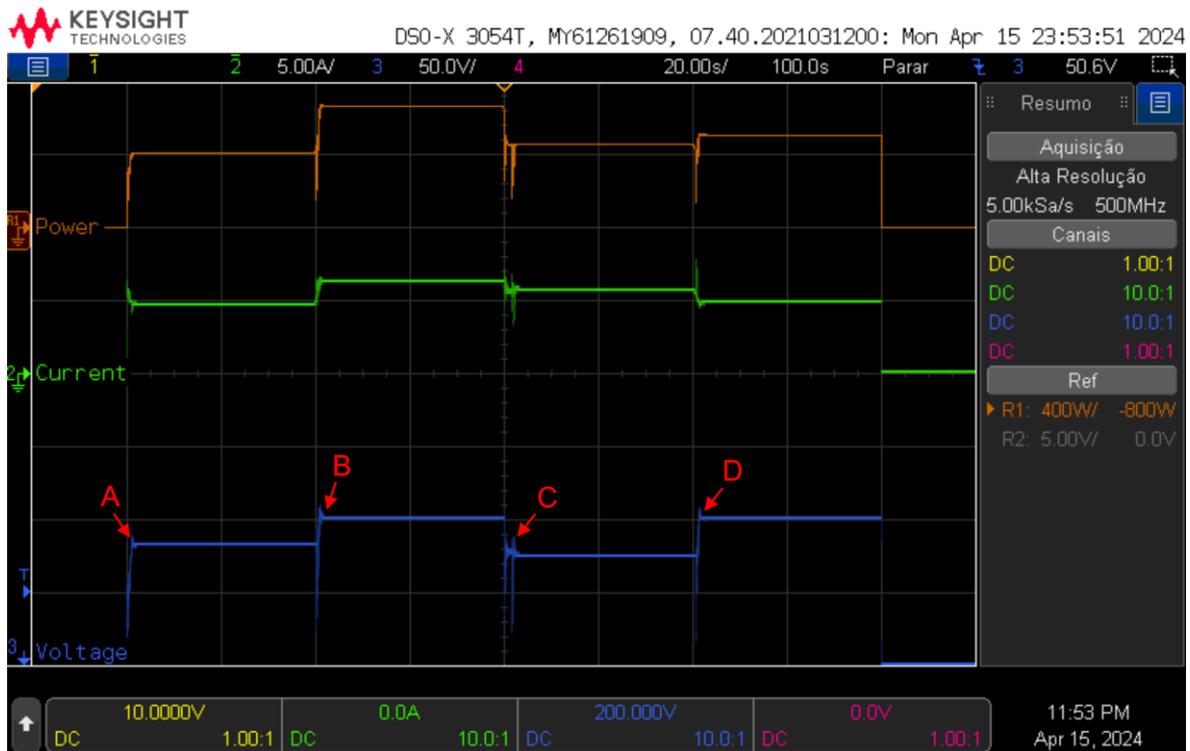
Figura 37 — Resultados do método PSO convencional.



Em laranja: Potência (400W/div); Em verde: Corrente (5A/div); Em azul: Tensão (50V/div). A, B, C e D se referem aos detalhes das formas de onda.

Fonte: Próprio autor.

Figura 38 — Resultados do método PSO sensorless.



Em laranja: Potência (400W/div); Em verde: Corrente (5A/div); Em azul: Tensão (50V/div). A, B, C e D se referem aos detalhes das formas de onda.

Fonte: Próprio autor.

A Tabela 6 apresenta os coeficientes máximos e mínimos utilizados durante o experimento, com a variação acompanhando o número de iterações, da mesma forma que na simulação.

Tabela 6 — Coeficientes utilizados no experimento para o algoritmo PSO

Parâmetros	Valores
$C_{1,max}$	2,2
$C_{1,min}$	0,15
$C_{2,max}$	2,2
$C_{2,min}$	0,57
ω_{max}	0,60
ω_{min}	0,20

Fonte: Próprio autor.

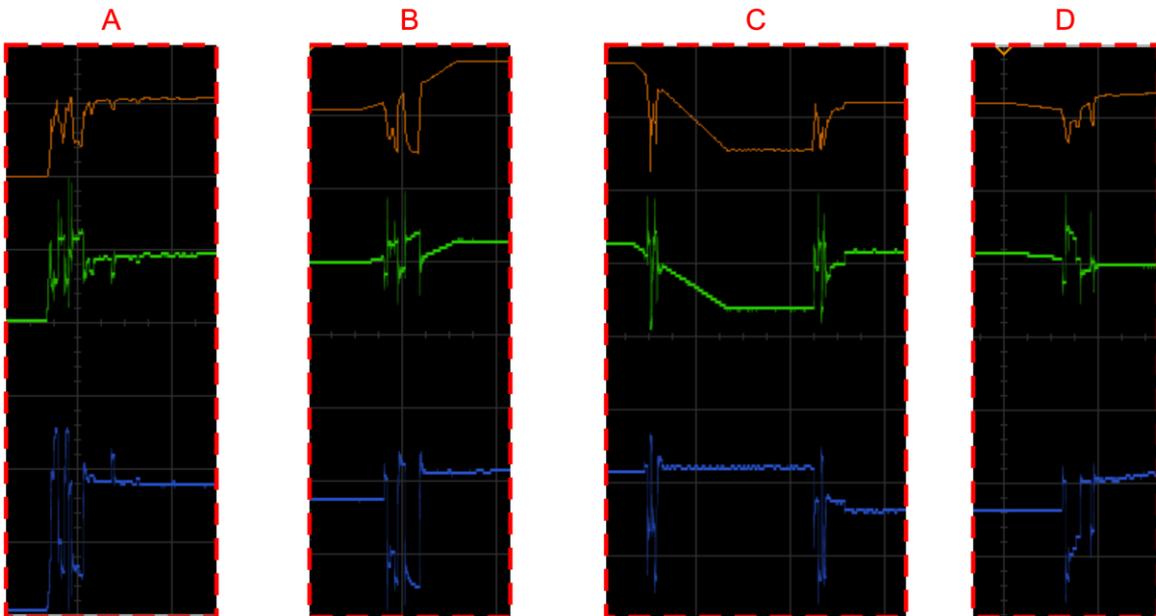
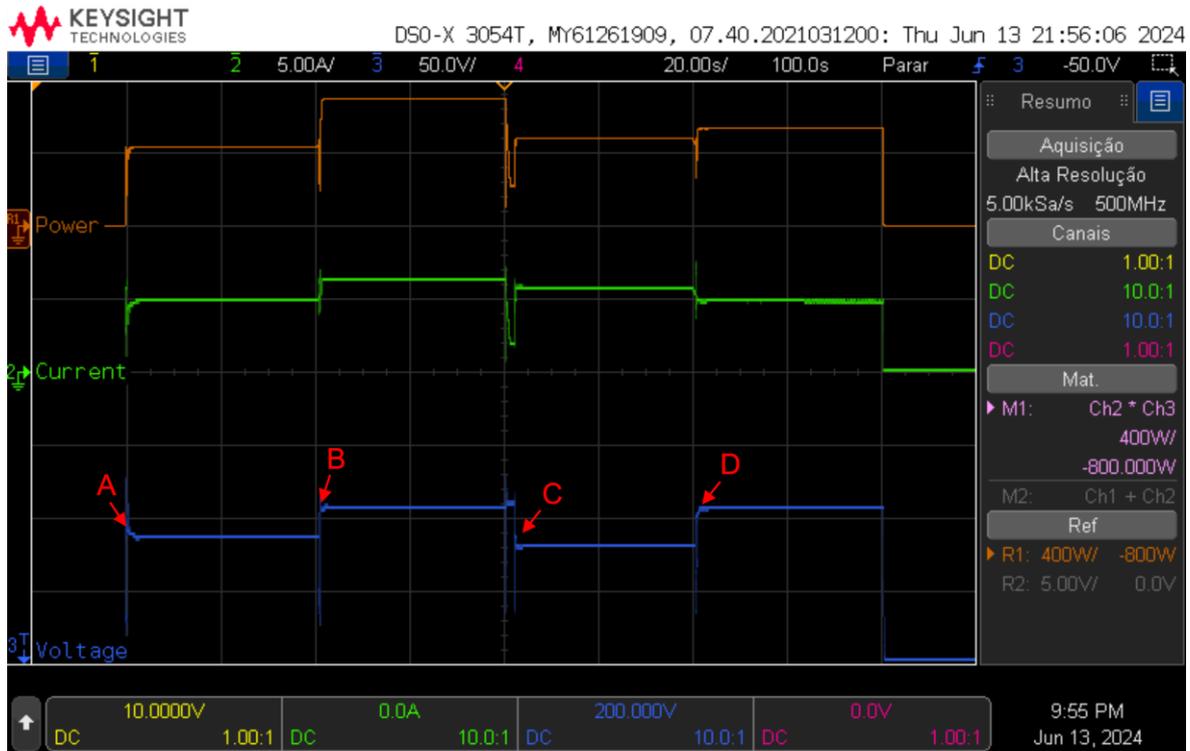
Nota-se que ambos os métodos encontraram o GMPP em todos perfis avaliados. Os FRs são respectivamente de 99,03% e 99,08%, para o algoritmo com ambos sensores e para o algoritmo sensorless. Além disso, observa-se um tempo de busca entre 1,35 e 2,50 segundos, considerando todos os degraus aplicados. Além de um *ripple* de potência menor que 0,50%.

4.3.4. Otimização por Morcegos (BAT)

Os resultados experimentais para o algoritmo BAT são exibidos nas Figuras 39 e 40 para os métodos convencional e *sensorless*, respectivamente. Aqui, as frequências mínima e máxima também são respectivamente definidas como 0 e 1. A constante de redução de volume α foi utilizada como 0,75. Quanto à taxa de pulso, a constante γ é estabelecida em 0,6 e o valor de r_i^0 é mantido como 1.

Nota-se que algoritmo demonstrou boa resposta durante a avaliação, localizando o GMPP em todos os perfis analisados. Além disso, pelo detalhe do primeiro perfil, constata-se um tempo de busca pelo GMPP menor que 0,5 segundos para o método sensorless e 1,65 segundos para o método com ambos sensores. Analisando todos os degraus aplicados, observa-se um *ripple* de potência menor que 0,65%. Além disso, os FRs obtidos são de 98,88% e 98,95% respectivamente para os algoritmos com ambos sensores e sensorless.

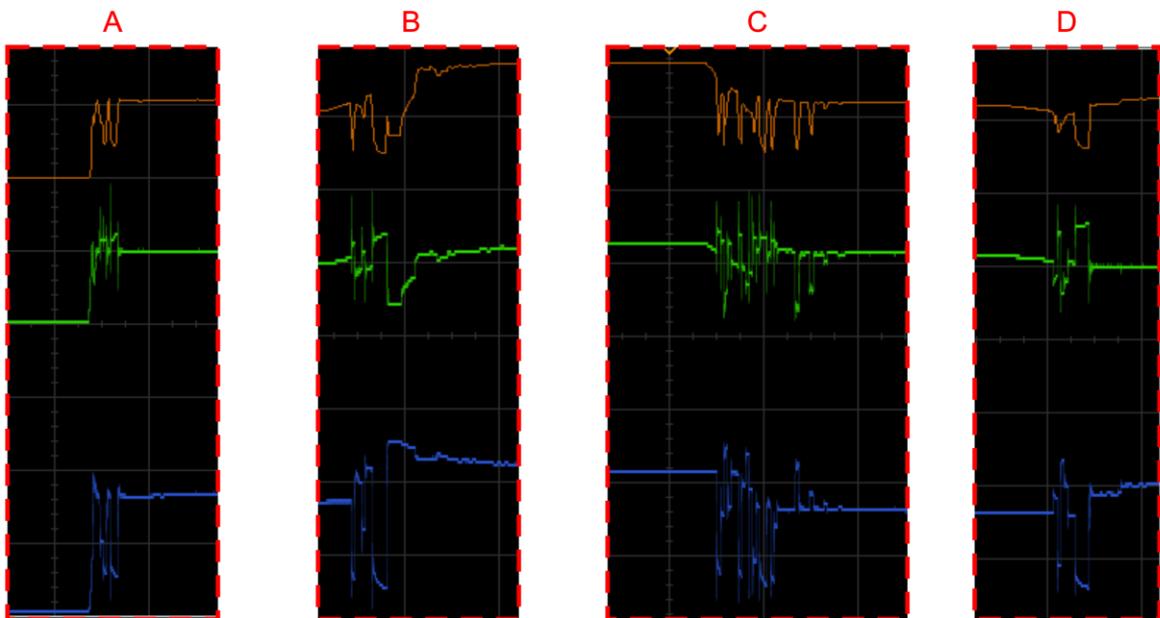
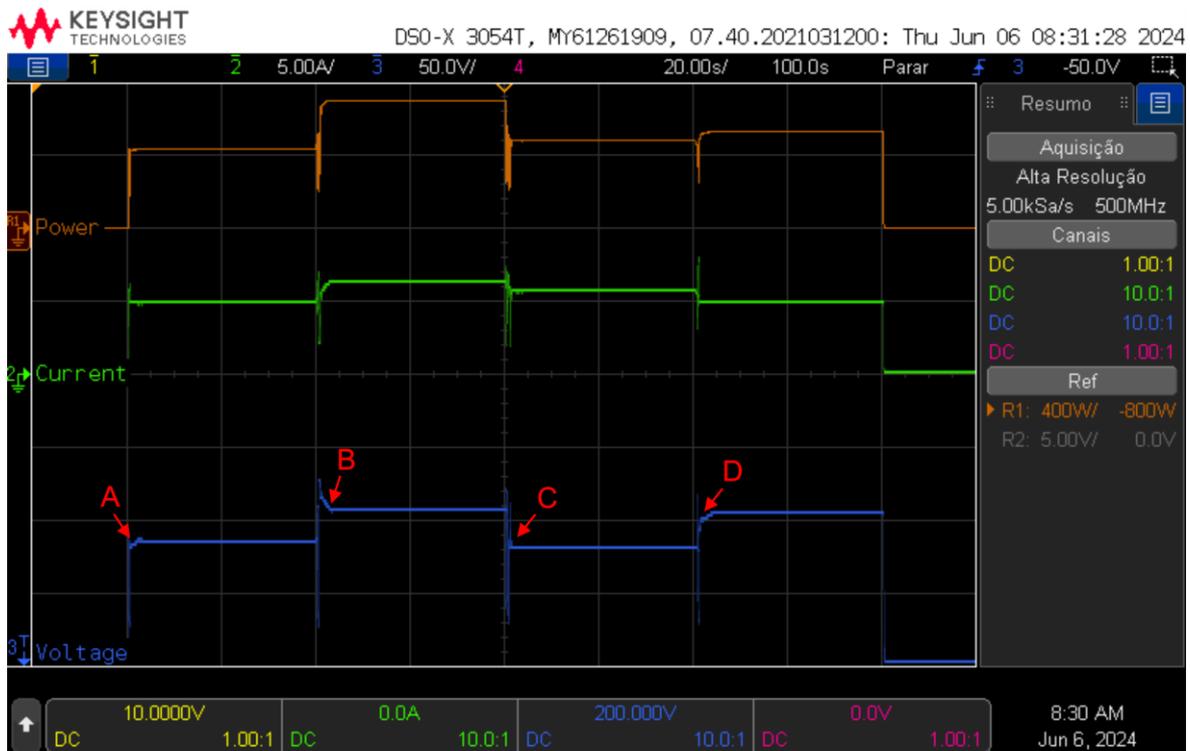
Figura 39 — Resultados do método BAT ambos sensores.



Em laranja: Potência (400W/div); Em verde: Corrente (5A/div); Em azul: Tensão (50V/div). A, B, C e D se referem aos detalhes das formas de onda.

Fonte: Próprio autor.

Figura 40 — Resultados do método BAT sensorless.



Em laranja: Potência (400W/div); Em verde: Corrente (5A/div); Em azul: Tensão (50V/div). A, B, C e D se referem aos detalhes das formas de onda.

Fonte: Próprio autor.

4.4. Comparação dos resultados experimentais

Da mesma forma utilizada para avaliação dos resultados de simulação, a Tabela 7 apresenta a avaliação dos resultados experimentais, analisando as mesmas métricas.

Tabela 7 — Avaliação dos resultados experimentais

Caso	Tempo de busca pelo GMPP (s)				Oscilação de potência em estado estacionário (%)				Eficiência de rastreamento (%)				FR (%)
	1	2	3	4	1	2	3	4	1	2	3	4	
P&O	0,25	1,00	1,00	0,90	0,93	0,35	0,38	1,33	90,25	100	43,24	100	84,56
P&O Sensorless	0,50	0,90	1,10	0,95	0,87	0,64	3,49	1,43	90,28	100	44,53	100	84,34
GSO	0,90	1,30	1,15	0,45	0,06	0,08	0,48	0,22	99,71	90,95	100	100	96,30
GSO Sensorless	0,70	1,25	1,05	0,90	0,06	0,07	0,20	0,50	99,70	93,25	100	100	96,83
PSO	1,35	1,45	2,50	1,60	0,02	0,42	0,31	0,47	100	100	100	100	99,03
PSO Sensorless	1,35	1,45	2,50	1,60	0,02	0,42	0,31	0,47	100	100	100	100	99,08
BAT	1,65	1,00	2,25	0,50	0,11	0,10	1,12	0,20	100	100	100	100	98,88
BAT Sensorless	0,50	2,20	1,80	1,30	0,27	0,11	0,62	0,25	100	100	100	100	98,95

(-) GMPP não encontrado.

Fonte: Próprio autor.

De acordo com os dados da Tabela 7, pôde-se verificar como destaque os métodos PSO e BAT que apresentaram os maiores FRs, sendo o método PSO, dentre os avaliados, o que consegue extrair maior quantidade de energia do sistema fotovoltaico, devido a maior eficiência de rastreamento. Nota-se que experimentalmente, os métodos sensorless propostos também conseguiram manter a potência extraída igual dos métodos que utilizam de ambos sensores e até mesmo superior.

4.5. Considerações do capítulo

Nota-se que as simulações forneceram uma base sólida para os experimentos, refletindo tendências semelhantes nas métricas em análise. Os resultados experimentais e de simulação demonstraram a eficácia dos algoritmos de MPPT baseados em computação suave. Além disso, os métodos sensorless propostos mostraram desempenho comparável e, em alguns casos, superior aos métodos que utilizam ambos sensores, colaborando para viabilidade dos sistemas de MPPT que podem operar com menos componentes e conseqüentemente com menor custo.

5. Conclusões e Considerações finais

O ponto de máxima potência em sistemas fotovoltaicos está diretamente relacionado com as condições ambientais. Desse modo, têm-se que algoritmos de MPPT são essenciais para obter a máxima potência disponível, principalmente em situações de sombreamento parcial, em que múltiplos LMPP ocorrem. Nesses casos, há o risco de convergência para esses pontos, consequentemente ocasionando no não aproveitamento da energia disponível. Assim, algoritmos capazes de rastrear o GMPP são indispensáveis. Para isso, a literatura apresenta diferentes técnicas inteligentes. Normalmente, observa-se a utilização de sensores de corrente e tensão para funcionamento de tais algoritmos. O presente trabalho apresenta uma metodologia para estimar a corrente do sistema, possibilitando a redução de custos e aumento de confiabilidade dos sistemas fotovoltaicos. A metodologia apresentada é aplicada em diferentes tipos de algoritmos, inteligentes e convencionais. Então avaliações são realizadas por meio de métricas como tempo de busca pelo GMPP, oscilação de potência em estado estacionário, eficiência de rastreamento e FR; assim realizando comparações entre as técnicas com ambos sensores e sem o sensor de corrente. Por meio de simulações e experimentalmente foi possível analisar diversos algoritmos do tipo *current sensorless*, que obtiveram desempenho bem próximo dos algoritmos que utilizam de ambos sensores e, em alguns casos, ligeiramente superior, como o algoritmo PSO sensorless que obteve um FR de 99,08%, em comparação aos 99,03% do PSO convencional. Dessa forma, os resultados deste estudo revelam que a metodologia proposta é capaz de rastrear o GMPP em diversas situações de sombreamento parcial, possibilitando o desenvolvimento e a utilização de diversos algoritmos de MPPT sem sensores de corrente mantendo alto desempenho mesmo em relação às técnicas com ambos sensores.

Para trabalhos futuros, propõe-se a implementação de técnicas híbridas que combinem algoritmos inteligentes com métodos convencionais, visando otimizar ainda mais o rastreamento do GMPP em condições de sombreamento parcial. Essas técnicas híbridas podem explorar a ampla busca dos algoritmos baseados em computação suave, com a precisão das técnicas convencionais, como o P&O, criando um algoritmo mais adaptável e eficiente. Além disso, seria interessante a abordagem *sensorless* em sistemas de duplo estágio, que incluem conversores CC-CC seguidos de inversores. Assim, podem ser realizados estudos experimentais mais extensivos, colaborando para validação das técnicas híbridas e da metodologia *sensorless*, por meio de uma avaliação abrangente de sua viabilidade e benefícios.

6. Referências

- [1] GIELEN, Dolf et al. World energy transitions outlook: 1.5°C pathway. Abu Dhabi: International Renewable Energy Agency (IRENA), 2021.
- [2] INTERNATIONAL RENEWABLE ENERGY AGENCY. Renewable Capacity Statistics 2024. Abu Dhabi: IRENA, 2024. Disponível em: <https://www.irena.org/Publications/2024/Mar/Renewable-capacity-statistics-2024>. Acesso em: 18 jun. 2024.
- [3] LIU, Xiaoguang; WANG, Yuefeng. Reconfiguration method to extract more power from partially shaded photovoltaic arrays with series-parallel topology. *Energies*, v. 12, n. 8, p. 1439, 2019.
- [4] DURRANI, Saad Parvaiz et al. Photovoltaic yield prediction using an irradiance forecast model based on multiple neural networks. *Journal of Modern Power Systems and Clean Energy*, v. 6, n. 2, p. 255-267, 2018.
- [5] KUMAR, Nishant et al. Rapid MPPT for uniformly and partial shaded PV system by using JayaDE algorithm in highly fluctuating atmospheric conditions. *IEEE Transactions on Industrial Informatics*, v. 13, n. 5, p. 2406-2416, 2017.
- [6] CASARO, Marcio Mendes; MARTINS, Denizar Cruz. Modelo de arranjo fotovoltaico destinado a análises em eletrônica de potência via simulação. *Eletrônica de Potência*, v. 13, n. 3, p. 141-146, 2008.
- [7] ERICKSON, Robert W.; MAKSIMOVIC, Dragan. *Fundamentals of Power Electronics*. 2nd ed. New York: Springer Science & Business Media, 2007.
- [8] ALI, Mahmoud N. et al. Promising MPPT methods combining metaheuristic, fuzzy-logic and ANN techniques for grid-connected photovoltaic. *Sensors*, v. 21, n. 4, p. 1244, 2021.
- [9] AZAD, Murari Lal et al. P&O algorithm based MPPT technique for solar PV system under different weather conditions. In: 2017 International Conference on Circuit, Power and Computing Technologies (ICCPCT). IEEE, 2017. p. 1-5.
- [10] ZAMORA, A. Canchola et al. Efficiency based comparative analysis of selected classical MPPT methods. In: 2017 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC). IEEE, 2017. p. 1-6.
- [11] ABO-KHALIL, Ahmed G. et al. Influence of a Hybrid MPPT Technique, SA-P&O, on PV System Performance under Partial Shading Conditions. *Energies*, v. 16, n. 2, p. 577, 2023.
- [12] GOSUMBONGGOT, Jirada; FUJITA, Goro. Global maximum power point tracking under shading condition and hotspot detection algorithms for photovoltaic systems. *Energies*, v. 12, n. 5, p. 882, 2019.
- [13] VIEIRA, Romênia G. et al. A comprehensive review on bypass diode application on photovoltaic modules. *Energies*, v. 13, n. 10, p. 2472, 2020.
- [14] ARCHILA VALDERRAMA, John et al. A maximum power point tracking algorithm for photovoltaic systems under partially shaded conditions. *Ingeniería y Universidad*, v. 20, n. 2, p. 391-409, 2016.

- [15] DE BRITO, Moacyr AG et al. Current Sensorless MPPT Algorithms for PV Systems with Partial Shading. In: 2023 IEEE 8th Southern Power Electronics Conference (SPEC). IEEE, 2023. p. 1-8.
- [16] LI, Guiqiang et al. Application of bio-inspired algorithms in maximum power point tracking for PV systems under partial shading conditions—A review. *Renewable and Sustainable Energy Reviews*, v. 81, p. 840-873, 2018.
- [17] ELOBAID, Lina M.; ABDELSALAM, Ahmed K.; ZAKZOUK, Ezeldin E. Artificial neural network-based photovoltaic maximum power point tracking techniques: a survey. *IET Renewable Power Generation*, v. 9, n. 8, p. 1043-1063, 2015.
- [18] KARATEPE, E. et al. Artificial neural network-polar coordinated fuzzy controller based maximum power point tracking control under partially shaded conditions. *IET Renewable Power Generation*, v. 3, n. 2, p. 239-253, 2009.
- [19] A. Mani, S. K and S. Maiti, "A Novel Hybrid Global MPPT Technique for Grid connected PV Systems," 2021 National Power Electronics Conference (NPEC), Bhubaneswar, India, 2021, pp. 1-6, doi: 10.1109/NPEC52100.2021.9672489
- [20] YU, Byunggyu; ABO-KHALIL, Ahmed G. Current estimation based maximum power point tracker of grid connected PV system. In: 2013 IEEE 10th International Conference on Power Electronics and Drive Systems (PEDS). IEEE, 2013. p. 948-952.
- [21] OBEIDI, Nabil et al. A current sensorless control of buck-boost converter for maximum power point tracking in photovoltaic applications. *Energies*, v. 15, n. 20, p. 7811, 2022.
- [22] DASGUPTA, Nivedita; PANDEY, Ashish; MUKERJEE, Ashok K. Voltage-sensing-based photovoltaic MPPT with improved tracking and drift avoidance capabilities. *Solar energy materials and solar cells*, v. 92, n. 12, p. 1552-1558, 2008.
- [23] HARRAG, Abdelghani; MESSALTI, Sabir; DAILI, Yacine. Innovative single sensor neural network PV MPPT. In: 2019 6th International Conference on Control, Decision and Information Technologies (CoDIT). IEEE, 2019. p. 1895-1899.
- [24] JUNG, Youngseok et al. Improved perturbation and observation method (IP&O) of MPPT control for photovoltaic power systems. In: Conference Record of the Thirty-first IEEE Photovoltaic Specialists Conference, 2005. IEEE, 2005. p. 1788-1791.
- [25] BRITO, Moacyr Aureliano Gomes de. *Inversores Integrados Monofásicos e Trifásicos para Aplicações Fotovoltaicas: Técnicas para obtenção de MPPT, detecção e proteção de ilhamento, sincronização e paralelismo com a rede de distribuição de energia elétrica*. 2013.
- [26] JOHN, Riby; MOHAMMED, S. Sheik; ZACHARIAH, Richu. Variable step size Perturb and observe MPPT algorithm for standalone solar photovoltaic system. In: 2017 IEEE International Conference on Intelligent Techniques in Control, Optimization and Signal Processing (INCOS). IEEE, 2017. p. 1-6.
- [27] Yalcin, A., & Kaw, A. (2012, 19 de dezembro). Topic Golden Search Method: Textbook notes for the golden search method [Notas de livro]. Recuperado de <http://numericalmethods.eng.usf.edu>
- [28] YAZICI, İrfan; YAYLACI, Ersagun Kürşat; YALÇIN, Faruk. Modified golden section search based MPPT algorithm for the WECS. *Engineering Science and Technology, an International Journal*, v. 24, n. 5, p. 1123-1133, 2021.
- [29] DA ROCHA, Maykon Vichoski; SAMPAIO, Leonardo Poltronieri; DA SILVA, Sérgio Augusto Oliveira. Comparative analysis of ABC, Bat, GWO and PSO algorithms for

- MPPT in PV systems. In: 2019 8th international conference on renewable energy research and applications (ICRERA). IEEE, 2019. p. 347-352.
- [30] ISHAQUE, Kashif et al. An improved particle swarm optimization (PSO)-based MPPT for PV with reduced steady-state oscillation. *IEEE transactions on Power Electronics*, v. 27, n. 8, p. 3627-3638, 2012.
- [31] PESSIN, Gustavo; OSÓRIO, Fernando. Otimização por Enxame de Partículas aplicado à formação e atuação de grupos robóticos. *Scientia*, v. 20, n. 2, 2009.
- [32] MIRJALILI, Seyedali; MIRJALILI, Seyed Mohammad; LEWIS, Andrew. Grey wolf optimizer. *Advances in engineering software*, v. 69, p. 46-61, 2014.
- [33] WATANABE, Osamu; ZEUGMANN, Thomas (Ed.). *Stochastic Algorithms: Foundations and Applications: 5th International Symposium, SAGA 2009 Sapporo, Japan, October 26-28, 2009 Proceedings*. Springer Science & Business Media, 2009.
- [34] WATANABE, Rodrigo Bairros et al. Implementation of the Bio-Inspired Metaheuristic Firefly Algorithm (FA) Applied to Maximum Power Point Tracking of Photovoltaic Systems. *Energies*, v. 15, n. 15, p. 5338, 2022.
- [35] YANG, Xin-She; HE, Xingshi. Bat algorithm: literature review and applications. *International Journal of Bio-inspired computation*, v. 5, n. 3, p. 141-149, 2013.
- [36] YANG, Xin-She. *Nature-inspired optimization algorithms*. 2. ed. San Diego: Academic Press, 2020.
- [37] YANG, Xin-She. Cuckoo search and firefly algorithm: overview and analysis. *Cuckoo Search and Firefly Algorithm: Theory and Applications*, p. 1-26, 2014.
- [38] BARONCHELLI, Andrea; RADICCHI, Filippo. Lévy flights in human behavior and cognition. *Chaos, Solitons & Fractals*, v. 56, p. 101-105, 2013.
- [39] NUGRAHA, Dimas Aji et al. A novel MPPT method based on cuckoo search algorithm and golden section search algorithm for partially shaded PV system. *Canadian Journal of Electrical and Computer Engineering*, v. 42, n. 3, p. 173-182, 2019.
- [40] KARABOGA, Dervis; BASTURK, Bahriye. Artificial bee colony (ABC) optimization algorithm for solving constrained optimization problems. In: *International fuzzy systems association world congress*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 789-798.
- [41] YAZDANI, Donya; MEYBODI, Mohammad Reza. A novel artificial bee colony algorithm for global optimization. In: *2014 4th International Conference on Computer and Knowledge Engineering (ICCCKE)*. IEEE, 2014. p. 443-448.
- [42] RASHID, Muhammad H. et al. *Eletrônica de potência: circuitos, dispositivos e aplicações*. Makron, 1999.
- [43] DE BRITO, Moacyr Aureliano Gomes et al. Evaluation of the main MPPT techniques for photovoltaic applications. *IEEE transactions on industrial electronics*, v. 60, n. 3, p. 1156-1167, 2012.
- [44] TERRASAS. *ETS600X Photovoltaic Simulator: User Manual*. Disponível em: <https://www.programmablepower.com/products/engineered-systems/terrasas-ets-series>. Acesso em: 16 jun. 2024.
- [45] DOS SANTOS MARTINES, Guilherme Mendonça. Modelagem e Implementação de Sistemas de Controle sem Sensores de Corrente para Obtenção de MPP em Sistemas Fotovoltaicos.

- [46] INSTRUMENTS, Texas. TMS320F2837xD Dual-Core Delfino Microcontrollers. Technical Reference Manual. TMS320F2837xD Dual-Core Delfino Microcontrollers, 2016.
- [47] DE BRITO, Moacyr AG et al. Avaliação das principais técnicas para obtenção de MPPT de painéis fotovoltaicos. In: 2010 9th IEEE/IAS International Conference on Industry Applications-INDUSCON 2010. IEEE, 2010. p. 1-6.
- [48] CHAO, Kuei-Hsiang; LIN, Yu-Sheng; LAI, Uei-Dar. Improved particle swarm optimization for maximum power point tracking in photovoltaic module arrays. *Applied energy*, v. 158, p. 609-618, 2015.
- [49] MILLAH, Ibrahim Saiful et al. An enhanced grey wolf optimization algorithm for photovoltaic maximum power point tracking control under partial shading conditions. *IEEE Open Journal of the Industrial Electronics Society*, v. 3, p. 392-408, 2022.
- [50] FARZANEH, Javad; KEYPOUR, Reza; KHANESAR, Mojtaba Ahmadi. A new maximum power point tracking based on modified firefly algorithm for PV system under partial shading conditions. *Technology and Economics of Smart Grids and Sustainable Energy*, v. 3, p. 1-13, 2018.
- [51] HANZAEI, Saeed H.; GORJI, Saman A.; EKTESABI, Mehran. A scheme-based review of MPPT techniques with respect to input variables including solar irradiance and PV arrays' temperature. *IEEE Access*, v. 8, p. 182229-182239, 2020.

Apêndice A – Produção de Artigos Científicos

A.1 Artigo Publicado – Periódico Internacional

[01] de Brito, M. A., Martines, G. M., Volpato, A. S., Godoy, R. B., & Batista, E. A. (2023). Current Sensorless Based on PI MPPT Algorithms. *Sensors*, 23(10), 4587.

A.2 Artigo Publicado – Congresso Internacional

[02] de Brito, M. A., Martines, G. M., Godoy, R. B., & Batista, E. A. Current Sensorless MPPT Algorithms for PV Systems with Partial Shading. In: BRAZILIAN POWER ELECTRONICS CONFERENCE - COBEP, 17., 2023, Florianopolis.